

Mendelova univerzita v Brně

Provozně ekonomická fakulta

Multi-view profilovanie používateľov vo virtuálnych prostrediach

Habilitačná práca

RNDr. Ján Skalka, PhD.

Brno 2026

Prehlasujem, že som predloženú prácu spracoval samostatne s využitím zdrojov, ktoré uvádzam v zozname literatúry.

Nitra, február 2026

Abstrakt

Skalka, J. Multi-view profilovanie používateľov vo virtuálnych prostrediach, habilitačná práca, Provozná ekonomická fakulta, Mendelova univerzita v Brně, 2026

Práca sa zameriava na viacpohľadové profilovanie používateľov vo virtuálnych prostrediach – v digitálnych hrách, vo vzdelávacom mikroučení a v aplikáciách virtuálnej reality. Východiskom je téza, že rozhodujúcou bariérou súčasnej analytiky nie je primárne dostupnosť dát, ale ich porovnateľnosť. Heterogénne zdroje sa líšia mierkou a distribúciami, nesú odlišné typy šumu a systematických skreslení, pokrývajú populáciu nerovnomerne a často reprezentujú správanie v rozdielnych časových granularitách a horizontoch. Pri priamom spájaní príznakov vzniká riziko dominancie najbohatšieho zdroja, problém dimenzionality a krehkosť záverov voči voľbám spracovania. Práca preto presadzuje prístup orientovaný na stabilitu, v ktorom je cieľom najprv vybudovať spoľahlivé a auditovateľné výstupy v jednotlivých pohľadoch a až následne ich integrovať tak, aby výsledok ostal interpretovateľný a reprodukovateľný aj pri neúplných dátach.

Metodický prínos práce predstavuje viacetapový pipeline. V prvom kroku sa špecifikujú pohľady a harmonizačné kontrakty: pravidlá kvality, mapovania na porovnateľné reprezentácie, štandardizácia a konzervatívne ošetrovanie odľahlostí, spolu s explicitným opisom dostupnosti. V ďalšom kroku sa pre každý pohľad realizuje samostatné profilovanie a segmentácia používateľov (s možnosťou rôzneho počtu segmentov v jednotlivých pohľadoch), pričom sa uprednostňuje pravdepodobnostné vyjadrenie príslušnosti a reportovanie neistoty. Prakticky sa tým zavádza rozlíšenie stabilného jadra a hraničných prípadov, ktoré prirodzene odráža prekryvy v správaní. Následne sa rieši finálny viacpohľadový krok: neskorá fúzia výstupov do spoločného priestoru. Integrácia je postavená na kombinovaní pravdepodobnostných profilov, na vážení pohľadov podľa stability a pokrytia a na explicitnom riešení konfliktov medzi pohľadmi. Takto sa minimalizuje vplyv dominantného zdroja a zároveň sa dá pracovať s asymetrickým pokrytím (keď je napríklad taktický pohľad dostupný len pre podmnožinu používateľov). Výsledkom nie je používateľovi striktne priradený typ, ale kompaktná pravdepodobnostná reprezentácia person, ktorá je použiteľná aj v režime cold startu a umožňuje sledovať proces stabilizácie profilu.

Empirická časť demonštruje viacpohľadový prístup na súbore prepojených štúdií: integračný profil, ktorý spája motivačné dimenzie Bartleho typológie s imerzívnymi tendenciami (ITQ) a poskytuje základ pre stabilné osoby v spoločnom priestore, tvorbu interpretovateľných person z hernej telemetrie ukotvenú v typológii, vrátane prechodu od tvrdých zhlukov k pravdepodobnostnému pohľadu cez resampling, modulárny rámec pre segmentáciu epizód a ťažbu taktických rutín z udalostnej telemetrie s jednotným epizódovým kontraktom naprieč rôznymi segmentačnými nástrojmi, identifikáciu rýchleho hľadania v mikroučení ako zdroja systematického skreslenia výkonových metrík a analýzu vplyvu predchádzajúcej skúsenosti s VR na interpretáciu a validáciu profilov. Celkovo práca prináša ucelenú metodiku, ktorá mení tvorbu person z jednorazovej interpretácie zhlukov na kontrolovaný proces so stabilitou, neistotou, porovnateľnosťou a transparentnou integráciou viacerých dátových pohľadov.

Kľúčové slová: modelovanie správania v hrách, profilovanie používateľov, herná telemetria, behaviorálne profily, persóny hráčov, procesné epizódy a taktiky, dátová fúzia, robustnosť

Abstract

Skalka, J. Multi-view Profiling of Users in Virtual Environments, Habilitation Thesis, Faculty of Business and Economics, Mendel University in Brno, 2026.

This work focuses on multi-view profiling of users in virtual environments – digital games, educational microlearning, and virtual reality (VR) applications. It is grounded in the claim that the primary practical bottleneck of contemporary analytics is not the availability of data per se, but their comparability. Heterogeneous sources differ in scale and distributions, carry different types of noise and systematic bias, cover the population unevenly, and often represent behavior at different temporal granularities and horizons. When features are merged directly, this creates risks of dominance by the richest source, high-dimensionality effects, and fragile conclusions that depend on preprocessing choices. The thesis therefore advocates a stability-oriented approach in which reliable and auditable outputs are first established within each view and only then integrated, so that the final result remains interpretable and reproducible even under incomplete data.

The methodological contribution is a multi-stage pipeline. In the first stage, views and harmonization contracts are specified: quality rules, mappings to comparable representations, standardization, conservative handling of outliers, and an explicit description of view availability. In the next stage, profiling and user segmentation are performed separately for each view (allowing different numbers of segments across views), with preference given to probabilistic membership and explicit reporting of uncertainty. In practice, this introduces a distinction between a stable core and boundary cases, naturally reflecting overlaps in behavior. The final multi-view step then addresses late fusion into a joint space. Integration relies on combining probabilistic profiles, weighting views by stability and coverage, and explicitly handling conflicts across views. This reduces the influence of any dominant source while supporting asymmetric coverage (e.g., when the tactics view is available only for a subset of users). The outcome is not a strictly assigned user type, but a compact probabilistic persona representation that is usable in cold-start settings and enables tracking the stabilization process of the user profile.

The empirical part demonstrates the multi-view approach through a set of connected studies: an integrative profile combining motivational dimensions of the Bartle typology with immersive tendencies (ITQ) as a basis for stable personas in the joint space; the construction of interpretable personas from game telemetry anchored in typology, including the transition from hard clusters to a probabilistic view via resampling; a modular framework for episode segmentation and extraction of tactical routines from event-level telemetry with a unified episode contract across segmentation tools; detection of rapid guessing in microlearning as a source of systematic distortion in performance metrics; and an analysis of how prior VR experience affects the interpretation and validation of profiles. Overall, the thesis delivers a coherent methodology that transforms persona building from a one-off interpretation of clusters into a controlled process grounded in stability, uncertainty, comparability, and transparent integration of multiple data views

Keywords: game behavior modeling, user profiling, game telemetry, behavioral profiles, player personas, process episodes and tactics, data fusion, robustness

Obsah

ÚVOD	9
VÝSKUMNÉ OTÁZKY A CIELE PRÁCE	10
ŠTRUKTÚRA HABILITAČNEJ PRÁCE	12
NADVÄZNOŠŤ NA VÝSKUM PRACOVISKA	13
PREHĽAD PROBLEMATIKY A TEORETICKÉ VÝCHODISKÁ.....	15
OD POUŽÍVATEĽA K DIGITÁLNEJ PERSONE	15
KRÍŽA REPLIKOVATEĽNOSTI A INTERPRETOVATEĽNOSTI	16
POROVNATEĽNOSŤ A PRENOSU ZNALOSTÍ NAPRIEČ PROSTREDIAMI.....	17
DÁTOVÉ ZDROJE A RIZIKÁ	17
<i>Subjektívna vrstva: dotazníky a psychometria</i>	<i>18</i>
<i>Agregačná vrstva: sumarizácie údajov z logov.....</i>	<i>19</i>
<i>Behaviorálna vrstva: event-telemetry a granulórne dáta.....</i>	<i>21</i>
<i>Procesná vrstva: epizódy a taktiky</i>	<i>22</i>
STABILITA KLASTROVANIA AKO KRITÉRIUM VALIDITY PERSON	23
SUBJEKTÍVNA VRSTVA – PREDISPOZÍCIE, SKÚSENOSŤ A KONTEXT	25
PREDCHÁDZAJÚCA SKÚSENOSŤ V IMERZÍVNYCH PROSTREDIACH	25
<i>Prehľad relevantných zdrojov.....</i>	<i>26</i>
<i>Merací rámec akceptácie.....</i>	<i>28</i>
<i>Prahový efekt expozície</i>	<i>29</i>
<i>Metodické dôsledky predchádzajúcej skúsenosti</i>	<i>32</i>
<i>Diskusia.....</i>	<i>34</i>
<i>Prínos pre oblasť habilitácie.....</i>	<i>35</i>
TYPOLOGICKÉ UKOTVENIE A (NE)ZAMENITEĽNOSŤ MODELOV	36
<i>Prehľad relevantných zdrojov.....</i>	<i>37</i>
<i>Metodika výskumu</i>	<i>38</i>
<i>Diskusia a záver.....</i>	<i>43</i>
<i>Prínos pre oblasť habilitácie.....</i>	<i>45</i>
SPRACOVANIE BEHAVIORÁLNYCH DÁT	46
DÁTOVÁ HYGIENA: DETEKCIA NÍZKEJ ANGAŽOVANOSTI.....	47
<i>Prehľad relevantných zdrojov.....</i>	<i>48</i>
<i>Prípadová štúdia: RGB v programovaní</i>	<i>52</i>
<i>Diskusia a záver.....</i>	<i>63</i>
<i>Prínos pre oblasť habilitácie.....</i>	<i>66</i>
AGREGAČNÁ VRSTVA: MIKRO-PERSONY ZO SUMÁRNYCH/TRANSAKČNÝCH LOGOV	66
<i>Prehľad relevantných zdrojov.....</i>	<i>67</i>
<i>Metodika výskumu</i>	<i>70</i>
<i>Diskusia a záver.....</i>	<i>77</i>
<i>Prínos pre oblasť habilitácie.....</i>	<i>78</i>
BEHAVIORÁLNA VRSTVA: TYPOLOGICKY UKOTVENÉ PERSONY Z LOGOV	79
<i>Prehľad relevantných zdrojov.....</i>	<i>80</i>
<i>Metodika výskumu</i>	<i>82</i>
<i>Prípadová štúdia: FPS telemetry</i>	<i>83</i>
<i>Diskusia a záver.....</i>	<i>96</i>
<i>Prínos pre oblasť habilitácie.....</i>	<i>99</i>
PROCESNÁ VRSTVA – EPIZÓDY A TAKTIKY	100
PREHĽAD RELEVANTNÝCH ZDROJOV	101

<i>Abstrakcia správania</i>	101
<i>Detekcia epizód</i>	102
<i>Modely latentných režimov</i>	103
<i>Interpretovateľnosť</i>	103
MODULÁRNA METODOLÓGIA PRE EXTRAKCIU TAKTIKY	104
<i>Fáza 1: Predspracovanie dát</i>	106
<i>Fáza 2: Segmentácia epizód</i>	107
<i>Fáza 3: Post-processing epizód</i>	108
<i>Fáza 4: Ťažba taktík</i>	109
PRÍPADOVÁ ŠTÚDIA: FPS TELEMETRIA	109
<i>Predspracovanie údajov</i>	110
<i>Segmentácia epizód</i>	111
<i>Post-processing epizód</i>	112
<i>Ťažba taktík</i>	113
DISKUSIA A ZÁVER	114
PRÍNOS PRE OBLASŤ HABILITÁCIE	116
STABILITY-FIRST PIPELINE PRE REPLIKOVATEĽNÉ PERSONY	117
PREHĽAD RELEVANTNÝCH ZDROJOV	118
METODIKA STABILITY-FIRST PROFILOVANIA A SEGMENTÁCIE	120
<i>Definícia problému a vstupy</i>	120
<i>Popis pipeline</i>	121
<i>Fáza 1: Príprava vstupov</i>	122
<i>Fáza 2: Robustná segmentácia</i>	123
<i>Fáza 3: Posúdenie stability a reprodukovateľnosti</i>	125
<i>Fáza 4: Kontrola prostredníctvom externých kritérií</i>	126
PRÍPADOVÁ ŠTÚDIA: INTEGRÁCIA MOTIVÁCIE A IMERZÍVNOSTI	127
<i>Prehľad relevantných zdrojov</i>	127
<i>Účastníci a nástroje</i>	128
<i>Príprava vstupov</i>	130
<i>Robustná segmenácia</i>	134
<i>Posúdenie stability a reprodukovateľnosti</i>	136
<i>Kontrola prostredníctvom externých kritérií</i>	137
DISKUSIA A ZÁVER	140
PRÍNOS PRE OBLASŤ HABILITÁCIE	142
VIACPOHĽADOVÉ PROFILOVANIE POUŽÍVATEĽOV	143
PREHĽAD RELEVANTNÝCH ZDROJOV	145
METODIKA MULTI-VIEW PROFILOVANIA	147
<i>Stage 1: Špecifikácia pohľadov a harmonizácia používateľských reprezentácií</i>	148
<i>Stage 2: Materializácia pohľadov a stabilné profilovanie používateľov</i>	150
<i>Stage 3: Integrácia pohľadov a konštrukcia spoločného priestoru</i>	151
<i>Stage 4: Nezávislé overovanie person</i>	154
PRÍPADOVÁ ŠTÚDIA: INTEGRÁCIA A FÚZIA ZDROJOV	156
<i>Špecifikácia pohľadov a harmonizácia používateľských reprezentácií</i>	156
<i>Materializácia pohľadov a stabilné profilovanie používateľov</i>	159
<i>Integrácia pohľadov a konštrukcia spoločného priestoru</i>	160
<i>Nezávislé overovanie person</i>	162
DISKUSIA A ZÁVER	165
DISKUSIA A ZÁVER	167
ZHODNOTENIE CIEĽOV A ODPOVEDE NA VÝSKUMNÉ OTÁZKY	167

PRÍNOS HABILITAČNEJ PRÁCE PRE OBLASŤ VEDECKÉHO POZNANIA	169
PRÍNOS PRE PRAX	171
<i>Analytika a personalizácia</i>	172
<i>Dizajnovanie hier a virtuálnych prostredí</i>	173
<i>Vylepšovanie prostredia mikroučenia</i>	174
LIMITY PRÁCE	175
ĎALŠIE SMEROVANIE VÝSKUMU	176
BIBLIOGRAFIA	178
PRÍLOHY	195

Úvod

Virtuálne prostredia vrátane komerčných hier, tréningových simulácií a systémov mikroučenia sú dnes etablovanými priestormi pre interakciu, vzdelávanie, komunikáciu i zábavu. Osobitná hodnota týchto prostredí spočíva v tom, že interakcia má podobu pozorovateľných akcií a odoziev systému, čím vznikajú digitálne stopy v rozsahu, ktorý nie je v tradičných prostrediach dostupný. Táto dostupnosť údajov prirodzene podporuje ambíciu porozumieť používateľom do takej miery, aby sa systém mohol prispôbovať – upravovať náročnosť a tempo, voliť formu spätnej väzby a včas identifikovať rizikové režimy signalizujúce preťaženie alebo pokles úsilia. V praktických aplikáciách však toto úsilie naráža na zásadné metodologické obmedzenia: správanie vo virtuálnych prostrediach je viacrozmerné, dynamické a kontextovo podmienené, čo vylučuje jeho úplné zachytenie jediným zdrojom údajov.

Profilovanie používateľov ako proces konštruovania interpretovateľných reprezentácií typických režimov správania sa preto presúva od jednorozmerných prístupov k viacpohľadovým metódam. Viac perspektív v tomto kontexte nepredstavuje len kvantitatívny nárast objemu dát, ale najmä možnosť komplexnejšieho opisu správania na základe deklarácií používateľov, dosiahnutých výsledkov a identifikovateľných procesných jednotiek. Zároveň rastú nároky na metodiku, keďže výstupy použiteľné v rozhodovaní musia byť porovnateľné a stabilné voči bežným analytickým voľbám aj pri zmenách platforiem a verzií systému.

Prezentovaná práca sa zaoberá viacpohľadovým profilovaním používateľov vo virtuálnych prostrediach ako metodickým problémom: ako z heterogénnych dátových stôp odvodiť profily a osoby, ktoré sú interpretovateľné, porovnateľné naprieč prostrediami a robustné voči realistickej neúplnosti a rozdielnej kvalite dát. Ťažisko práce je v návrhu a overovaní postupov spracovania jednotlivých zdrojov správania a v tom, ako sa z nich získavajú kompatibilné reprezentácie použiteľné pre následnú integráciu a interpretáciu. Osobitný dôraz sa kladie na stabilitu riešení a na transparentné zachytenie neistoty priradenia, aby výsledky obstáli nielen analyticky, ale aj pri praktickom použití v dizajne a hodnotení systémov.

Z týchto dôvodov práca kategorizuje zdroje správania do niekoľkých dátových vrstiev zodpovedajúcich štruktúre virtuálnych prostredí. Prvú vrstvu tvoria subjektívne zdroje reprezentované dotazníkmi a sebaopisnými škálami, ktoré poskytujú priame prepojenie so skúsenosťami a motiváciou, hoci sú obmedzené citlivosťou na sebaaprezentáciu a neúplným pokrytím. Druhú vrstvu tvoria agregované protokoly sumarizujúce správanie do výkonnostných ukazovateľov, ktoré sú ľahko dostupné, no bez procesného kontextu nesú riziko zámeny príčiny a následku. Tretiu vrstvu definuje telemetria udalostí, ktorá poskytuje vysokú informačnú hodnotu detailným záznamom interakcií, pričom jej interpretácia zostáva úzko viazaná na konkrétny návrh systému. Štvrtú vrstvu predstavujú procesné reprezentácie, ktoré premostujú telemetriu a interpretáciu prepisom správania do časovo ohraničených epizód a taktík, čím umožňujú preklad údajov do jazyka dizajnových intervencií pri zachovaní kontrolovaného spracovania.

Práca sa pohybuje na priesečníku analytiky, herného priemyslu a mikroučenia, pričom v každej z týchto oblastí vystupujú odlišné nároky na robustnosť, interpretovateľnosť a diagnostiku zapojenia. Spoločným menovateľom zostáva požiadavka, aby profilovanie slúžilo ako auditovateľný a metodologicky disciplinovaný nástroj informatiky, ktorý zohľadňuje zdroje neistoty už vo fáze návrhu reprezentácií. Východiskom práce je presvedčenie, že viacpohľadové profilovanie je predovšetkým problémom návrhu pravidiel spracovania a kritérií akceptácie výsledku; na tomto základe sa v nasledujúcej kapitole formulujú výskumné otázky a ciele.

Výskumné otázky a ciele práce

Prezentovaná práca sa zaoberá viacpohľadovým profilovaním používateľov vo virtuálnych prostrediach ako metodickým problémom: ako z heterogénnych dátových vrstiev odvodiť profily a osoby, ktoré sú interpretovateľné, porovnateľné naprieč prostrediami a použiteľné aj pri neúplných a kvalitatívne nerovnomerných dátach. Východiskom je predpoklad, že jednotlivé dátové vrstvy majú odlišnú interpretačnú povahu a odlišný profil rizík, preto sa profilovanie chápe ako riadený postup, ktorý explicitne pracuje s kvalitou signálu, stabilitou riešení a neistotou priradenia. Zároveň sa metodicky odlišuje segmentácia správania (epizódy a taktiky ako procesná reprezentácia) od segmentácie používateľov (profily a osoby ako výsledok profilovania).

Tieto dátové vrstvy slúžia v práci ako organizačný rámec, preto sa ciele a výskumné otázky formulujú tak, aby prirodzene pokrývali subjektívne merania, agregované logy, telemetriu, procesné reprezentácie a zároveň zodpovedali spoločnému metodickému zámeru práce.

Hlavný cieľ práce tak spočíva v návrhu a empirickom podložení metodiky viacpohľadového profilovania používateľov vo virtuálnych prostrediach, ktorá umožní odvodiť profily a osoby z heterogénnych dátových vrstiev tak, aby boli interpretovateľné, porovnateľné naprieč prostrediami a použiteľné aj pri realistickej neúplnosti a nerovnomernej kvalite dát. Dôraz sa kladie na to, aby sa výsledok neopieral o jednorazový analytický výstup, ale o kontrolovaný postup s explicitnou prácou so stabilitou riešení a neistotou priradenia.

Z hlavného cieľa sa odvodzujú tieto podciele:

1. Určiť postupy interpretácie subjektívnych meraní, ktoré zohľadnia vplyv skúsenosti a efekt novosti a umožnia stabilnejšie používanie subjektívnej vrstvy v profilovaní.
2. Navrhnuť a overiť postup porovnania top-down typológií používateľov tak, aby sa dalo posúdiť, do akej miery sú konštruktívne ekvivalentné a prakticky nahraditeľné.
3. Navrhnuť a empiricky overiť postupy na identifikáciu nízkej angažovanosti a rýchleho hľadania v mikroučení vrátane kalibrácie rozhodovacích prahov v homogénnejších podskupinách.
4. Navrhnuť postup profilovania z minimálnych protokolových a agregovaných logov tak, aby vznikali malé, interpretovateľné a stabilné mikro-profily prenositeľné naprieč obsahom a systémami.
5. Navrhnuť postup konštruovania interpretovateľných person z agregovaných herných logov a empiricky posúdiť, do akej miery typologické ukotvenie obmedzuje nadinterpretáciu a zvyšuje komunikovateľnosť stabilnej štruktúry.
6. Navrhnuť postup tvorby porovnateľnej procesnej reprezentácie cez epizódy a taktiky tak, aby procesné črty ostali konzistentné naprieč rozumnými voľbami segmentačného dizajnu a aby sa segmentácia správania metodicky nepletla so segmentáciou používateľov.
7. Formulovať a operacionalizovať stability-first postup výberu a reportovania persona riešení vrátane explicitného vyjadrenia neistoty priradenia (jadro vs. hraničné prípady) a post hoc overenia na externých premenných mimo klastrovania.

Na tomto základe sa hlavný cieľ rozkladá do čiastkových krokov zodpovedajúcich jednotlivým dátovým vrstvám a metodickým komponentom. Aby bolo možné tieto kroky jednoznačne formulovať a empiricky uzavrieť, sú ďalej definované výskumné otázky, ktoré operacionalizujú hlavný cieľ a určujú, aké vlastnosti musia mať navrhnuté postupy (stabilita, porovnateľnosť, interpretovateľnosť a práca s neistotou) v každej z vrstiev.

Hlavná výskumná otázka (HVO):

- Ako navrhnúť a empiricky overiť metodiku viacpohľadového profilovania používateľov v hrách a virtuálnych prostrediach, ktorá integruje heterogénne a neúplné pohľady, explicitne kontroluje stabilitu a neistotu priradenia a vedie k interpretovateľným profilom použiteľným v praxi?

HVO sa operacionalizuje do čiastkových otázok usporiadaných podľa dátových vrstiev:

- SUB1 (subjektívna vrstva): Ako predchádzajúca skúsenosť s VR, meraná kumulatívnym časom expozície, vplýva na dimenzie akceptácie VR obsahu (zaujímavosť, vnímaná jednoduchosť používania, zapojenie a ponorenie) a pri akej úrovni expozície dochádza k oslabeniu vplyvu efektu novosti na tieto hodnotenia?
- SUB2 (porovnanie typológií): Do akej miery sú top-down typológie používateľov (Bartle, HEXAD) konštruktovo ekvivalentné a prakticky nahraditeľné – t. j. aký majú spoločný latentný základ a aké sú limity ich vzájomnej predikcie pri použití jedného nástroja namiesto druhého?
- BEHA1 (nízka angažovanosť): Do akej miery sú metódy nízkej angažovanosti vyvinuté pre tradičné testovanie prenositeľné do nízko-stakes mikrolearningu a zlepši sa ich presnosť/robustnosť, ak sa prahy RGB odhadujú separátne v homogénnych skupinách študentov definovaných rýchlosťou čítania a výkonom (t. j. klastrovaním pred samotnou detekciou)?
- BEHA2 (minimalistické osoby): Ako navrhnúť a empiricky overiť jednotný, platformovo agnostický profilovací model vo virtuálnych (vzdelávacích) prostrediach, ktorý z minimálnych protokolových logov automatizovaného hodnotenia – doplnených o kurikulárny a časový kontext – konštruje malé, interpretovateľné a stabilné mikro-osoby ako prenositeľnú reprezentáciu používateľa naprieč obsahom a systémami?
- BEHA3 (ukotvenie agregovaných logov): Ako konštruovať interpretovateľné behaviorálne osoby z agregovaných herných logov a do akej miery typológiou riadené ukotvenie znižuje riziko nadinterpretácie a zvyšuje vysvetliteľnosť stabilnej štruktúry person?
- PROC1 (procesná vrstva): Ako navrhnúť modulárny pipeline, ktorý extrahuje epizódy a taktiky ako porovnateľnú procesnú reprezentáciu správania – štandardizáciou vstupu a zjednotením epizódového výstupu – tak, aby procesné črty ostali konzistentné naprieč segmentačnými dizajnmi a zároveň tvorili predpoklad integrácie procesného view do spoločného priestoru v multi-view profilovaní?
- STAB1 (stability-first): Ako navrhnúť a reportovať stability-first pipeline pre viacblokové profilovanie tak, aby výsledné osoby boli replikovateľné, mali explicitne vyjadrenú neistotu priradenia (CORE/BOUNDARY) a boli overené na externých kotvách nezahrnutých v klastrovaní?

Prezentované postupy, výsledky a závery sú výstupom dlhodobej práce autora v spolupráci s kolegami z Katedry informatiky FPVal UKF v Nitre v oblasti analýzy správania používateľov. Čiastkové výsledky boli priebežne publikované v časopiseckých aj konferenčných výstupoch a prezentované na medzinárodných fórach s cieľom sprístupniť priebežné zistenia odbornej komunite a zároveň získať spätnú väzbu využiteľnú pri ďalšom rozvoji metodiky.

Štruktúra habilitačnej práce

Práca je koncipovaná tak, aby postupne uzatvárala čiastkové výskumné otázky viazané na jednotlivé dátové vrstvy a následne ich syntetizovala do jednotného metodického rámca. Po úvode, v ktorom sa vymedzí problém, formulujú ciele a výskumné otázky, nasledujú kapitoly usporiadané podľa toho, aký typ signálu spracúvajú a aké metodické riziká riešia. Táto logika zabezpečuje, že k integrácii sa nepristupuje skôr, než sú jednotlivé pohľady stabilizované a interpretovateľné.


Kapitola **Prehľad problematiky a teoretické východiská** poskytuje syntézu súvisiacich prístupov (profilovanie, osoby, viacpohľadové modelovanie, porovnateľnosť, replikovateľnosť) a explicitne pomenúva typické zdroje skreslení a neistôt v jednotlivých dátových vrstvách. Ide o kontextovú kapitolu, ktorá podkladá metodické rozhodnutia naprieč všetkými otázkami.

Subjektívna vrstva – predispozície, skúsenosť a kontext rieši stabilitu a interpretáciu sebaopisných meraní. Časť *Predchádzajúca skúsenosť v imerzívnych prostrediach* uzatvára otázku SUB1 (vplyv skúsenosti a prahový efekt expozície). Časť *Typologické ukotvenie a (ne)zameniteľnosť modelov* uzatvára otázku SUB2 (konštruktová ekvivalencia a praktická nahraditeľnosť top-down typológií, vrátane mapovania HEXAD – Bartle).

Spracovanie behaviorálnych dát je organizované do troch blokov, ktoré postupne riešia kvalitu signálu a profilovanie z rôzne komplexných dát:

- *Dátová hygiena: detekcia nízkej angažovanosti* odpovedá na BEHA1 (prenositelnosť detekcie nízkej angažovanosti do mikroučenia a význam segmentovaného nastavovania prahov).
- *Agregačná vrstva: mikro-persony zo sumárnych/transakčných logov* odpovedá na BEHA2 (profilovanie z minimálnych protokolových logov a tvorba stabilných mikro-person).
- *Behaviorálna vrstva: typologicky ukotvené osoby z logov* odpovedá na BEHA3 (tvorba interpretovateľných person z logov a prínos typologického ukotvenia pre obmedzenie nadinterpretácie).

Kapitola **Procesná vrstva – epizódy a taktiky** rozvíja modulárny postup spracovania event-telemetrie do porovnateľnej procesnej reprezentácie. Jadrom je metodológia extrakcie epizód a taktík a jej demonštrácia na prípadovej štúdii; kapitola uzatvára otázku PROC1.



Obr. 1 Strom príspevkov práce podľa dátových vrstiev a ich väzba na integráciu viacpohľadového profilovania.

Stability-first pipeline pre replikovateľné osoby formalizuje kritériá prijateľnosti riešenia (stabilita, neistota priradenia, reportovanie jadra a hraničných prípadov) a demonštruje ich na prípadovej štúdii integrácie motivačných a imerzívnych premenných. Kapitola uzatvára otázku STAB1.

Viacpohľadové profilovanie používateľov (multi-view integrácia) syntetizuje predchádzajúce kapitoly do jednotnej metodiky viacpohľadového profilovania a ilustruje ju na prípadovej štúdii integrácie zdrojov. Táto kapitola predstavuje priame metodické uzavretie hlavnej výskumnej otázky, keďže ukazuje, ako sa čiastkové riešenia skladajú do kontrolovaného a auditovateľného postupu.

Diskusia a záver sumarizuje odpovede na výskumné otázky, zhodnocuje splnenie cieľov, pomenúva vedecký a praktický prínos, limity a ďalšie smerovanie výskumu.

Štruktúra práce je vizualizovaná na Obr. 1.

V prílohách sú publikované články a práce akceptované na publikovanie.

Nadväznosť na výskum pracoviska

Habilitačná práca tematicky aj metodicky nadväzuje na výskumný profil pracoviska reprezentovaný Laboratóriom analýzy správania sa používateľov (BEHA Lab) na FPVaI UKF v Nitre. Laboratórium sa dlhodobo orientuje na tvorbu a analýzu správania používateľov vo virtuálnych prostrediach určených na tréningové, vzdelávacie, priemyselné aj terapeutické účely, s dôrazom na kognitívne a emočné aspekty správania a na overovanie moderných výskumných trendov v praxi.

Východiská práce priamo reflektujú spôsob, akým BEHA Lab prepája vývoj vlastných digitálnych prostredí s ich meraním a analytikou: študijné a tréningové materiály sa integrujú do vlastných simulácií, hier alebo mikroučiacich platforiem, ktoré umožňujú detailne sledovať interakcie používateľov a využívať zistenia na zlepšovanie stratégií a personalizáciu obsahu. Súčasťou výskumného zázemia je aj využívanie HPC infraštruktúry na spracovanie rozsiahlych dát a budovanie pokročilých modelov.

Z obsahového hľadiska sa témy habilitačnej práce opierajú o kľúčové tematické osi laboratória: virtuálne prostredia a zážitkové učenie, learning analytics, štúdium a podpora kognitívnych procesov, behaviorálna analytika a tvorba didaktických materiálov vrátane microlearning modulov. Tento rámec prirodzene vedie aj k požiadavke metodickej disciplinovanosti pri práci s heterogénnymi dátami a k dôrazu na prenositeľnosť a interpretovateľnosť výstupov.

Výskumné zázemie, na ktoré práca nadväzuje, je budované prostredníctvom projektov z národných aj medzinárodných schém. Medzi nosné projekty patria:

- Skúmanie prínosu generatívnej umelej inteligencie vo vzdelávaní s využitím metód analytiky učenia v kontexte vybraných stratégií autoregulovaného učenia (2025-2027, VEGA 1/0667/25)
- Nitrianske kompetenčné centrum pre kybernetickú bezpečnosť* (Plán obnovy a odolnosti SR, 17R05-04-V01-00003, 2025–2026)
- Future IT Professionals Education in Generative AI (Erasmus+ KA220, 2024-1-SK01-KA220-HED-000249044, 2024–2027)
- Návrh a evaluácia nových modelov pre automatizované hodnotenie otvorených úloh a zadaní z programovania s podporou generatívnej umelej inteligencie (2024-2026, VA 09I03-03-V04-000596)
- Virtuálna realita v programovaní PLC systémov (KEGA 009UKF-4/2023, 2023–2025)
- Návrh a evalvácia vybraných metód objavovania znalostí pre porozumenie a skvalitnenie procesu učenia a virtuálneho vzdelávacieho prostredia (VEGA 1/0490/22, 2022–2024)
- Future IT Professionals Education in Artificial Intelligence (Erasmus+ KA220, 2021-1-SK01-KA220-HED-000032095, 2021–2024)

- Work-Based Learning in Future IT Professionals Education* (Erasmus+ KA2, 2018-1-SK01-KA203-046382, 2018–2021)
- Implementácia nových trendov v informatike do výučby algoritmického myslenia a programovania v predmete informatika v sekundárnom vzdelávaní (2020-2022, KEGA 018UMB-4/2020)

Prepojenie výskumu s praxou sa opiera aj o projekty realizované s priemyselnými partnermi, najmä v oblasti virtuálnej reality a priemyselných dát:

- Modely výrobných procesov v systémoch virtuálnej reality (2023–2024)
- Spracovanie procesných dát priemyselnej výroby (2022-23)

Nadväznosť práce sa opiera aj o výskumnú kultúru pracoviska: tím laboratória organizuje odborné a popularizačné podujatia (workshopy, GameJam-y, hackathony, školenia) a systematicky buduje partnerstvá s firmami, školami a výskumnými inštitúciami.

V rámci medzinárodných aktivít laboratórium spolupracuje s viacerými univerzitami a SME (napr. Mendelova univerzita v Brne, ČVUT v Prahe, ELTE Budapest, University of Las Palmas de Gran Canaria, University of Silesia v Katowiciach a ďalšími) a v mimouniverzitnej spolupráci s partnermi z priemyslu a technologickej praxe (Constellium, EATON, FANUC Slovakia, GAMETHERAPY, Muehlbauer, Powerplay Manager, Prounion, SGDA, UNIQA GSC).

Prehľad problematiky a teoretické východiská

V súčasnej ére digitálnej transformácie sa virtuálne prostredia stali prirodzenou súčasťou ľudskej interakcie, vzdelávania aj zábavy. V kontexte tejto práce chápeme virtuálne prostredie ako široké spektrum digitálnych ekosystémov – od komplexných počítačových hier a aplikácií virtuálnej reality (VR), cez mikrolearningové platformy a webové informačné systémy, až po sofistikované vzdelávacie simulácie. Spoločným menovateľom týchto prostredí je schopnosť generovať kontinuálny prúd dát o používateľských interakciách. Tieto dáta v sebe nesú signály, ktoré možno za určitých predpokladov interpretovať ako indikátory kognitívnych procesov, motivácie, afektívnych stavov a behaviorálnych vzorcov používateľov. Ťažisko práce je zamerané na interaktívne virtuálne prostredia s bohatou telemetriou, najmä hry, VR aplikácie a mikrolearning, v ktorých má navyše správanie používateľa výrazne procesný charakter. Takéto prostredia predstavujú prirodzený priestor pre multi-view prístup, keďže kombinujú behaviorálne záznamy s kontextom, výsledkami a často aj subjektívnymi meraniami.

Je dôležité zdôrazniť, že telemetria a logy spravidla neobsahujú psychologické konštrukty priamo, ale iba ich pozorovateľné prejavy v správaní. Interpretácia takýchto signálov preto závisí od predpokladov o úlohe, prostredí a používateľovi a vyžaduje trianguláciu s ďalšími zdrojmi – napríklad dotazníkmi, kontextovými premennými alebo procesnými abstrakciami. Bez takejto triangulácie hrozí, že z dát vyvodíme síce presvedčivé, no neukotvené závery. Multi-view rámec preto vnímame ako spôsob, ako systematicky znižovať riziko nadinterpretácie a zvyšovať oporu interpretácie o nezávislé pohľady.

Od používateľa k digitálnej persone

Tradičné prístupy k modelovaniu používateľa boli dlhodobo ukotvené v statickej paradigme. Používateľ sa opisoval ako entita definovaná sériou fixných atribútov – demografiou, deklarovateľnými preferenciami alebo explicitne zadanými cieľmi. Tento prístup, síce funguje v jednoduchších systémoch, no v dynamických a nelineárnych virtuálnych prostrediach naráža na svoje limity. Hráč v MMORPG (*Massively Multiplayer Online Role-Playing Game*), študent v adaptívnom e-learningovom kurze alebo operátor vo VR tréningu nie sú statickými objektmi ich správanie je emergentné, kontextovo podmienené a mení sa v čase.

V oblasti profilovania používateľov vo virtuálnych prostrediach sa typicky stretávajú dve rodiny prístupov. Top-down prístupy vychádzajú z vopred definovaných konštruktov a typológií (napr. motivácie, preferencie, skúsenosť), ktoré sa merajú najmä dotazníkmi alebo experimentálnymi protokolmi. Bottom-up prístupy naopak odvodzujú štruktúru populácie priamo z behaviorálnych dát (logy, telemetria) pomocou zhľukovania, sekvenčnej analýzy či modelovania latentných stavov (Mereu et al., 2017). Multi-view prístup umožňuje tieto perspektívy prepojiť: buď ako vzájomnú validáciu, alebo ako doplnenie informácie tam, kde jeden pohľad nestačí.

Motiváciou práce je v úvode kriticky zhodnotiť súčasný stav poznania v tejto oblasti, kde pozorujeme paradoxný fenomén: napriek rýchlemu nárastu objemu dostupných dát, často klesá naša schopnosť tieto dáta zmysluplne interpretovať a pretaviť do robustných a interpretovateľných modelov. Súčasná prax je často charakterizovaná ad-hoc segmentáciou, ktorá síce dokáže rozdeliť používateľov do skupín na základe povrchných metrík, ale zlyháva pri identifikácii hlbších vzťahov a mechanizmov.

V tomto kontexte sa zavádzajú a rozlišujú kľúčové pojmy, ktoré tvoria terminologickú kostru práce: **segment** a **persona**. Zatiaľ čo segmentácia je proces delenia populácie na základe merateľných, často ekonomických alebo výkonnostných kritérií (napr. "hráči s vysokou retenciou", "študenti s nízkym skóre"), tvorba osoby predstavuje kvalitatívne vyšší stupeň modelovania (Hooshyar et al., 2019), (Hemzo, 2023). Persona by nemala byť chápaná len ako štatistický zhľuk; je to behaviorálny archetyp, ktorý v sebe integruje odpovede na otázky *kto* je používateľ (psychometria), *čo* robí (telemetria) a *prečo*

to robí (motivácia). V praxi to znamená opierať interpretáciu o kombináciu behaviorálnych dát a validačných kotiev (napr. psychometrické merania alebo kontextové premenné). Persona slúži ako explanačný model, ktorý umožňuje nielen deskripciu minulého správania, ale aj odhad budúcich reakcií na zmeny v systéme (Salminen et al., 2020).

Tvorba takýchto robustných person si vyžaduje prechod od monolitického pohľadu na dáta k prístupu, ktorý nazývame multi-view profilovanie (Buraya et al., 2018), (L. Li & Xiao, 2022). Tento prístup vychádza z toho, že žiadny jeden dátový zdroj – či už ide o subjektívne dotazníky alebo objektívnu telemetriu – nie je schopný zachytiť celý obraz používateľa bez zavedenia významného skreslenia alebo straty informácie. Cieľom práce je formalizovať metodiku, ktorá syntetizuje heterogénne dátové pohľady do koherentného profilu, pričom kladie dôraz na stabilitu a replikovateľnosť výsledných modelov.

Multi-view profilovanie chápeme ako metodický rámec, v ktorom jeden používateľ nie je reprezentovaný jediným vektorom príznakov, ale viacerými navzájom komplementárnymi reprezentáciami (views). Každý view má vlastnú dátovú podstatu, mieru šumu a špecifické skreslenia. Syntéza pohľadov znamená riadenú trianguláciu pozostávajúcu z **overovania** konvergentnej validity (zhoda signálov naprieč view), **odhaľovanie** konfliktov (kde sa view rozchádzajú) a **konštrukcie** person ako explanačných modelov, ktoré sú interpretovateľné pre doménového experta a zároveň stabilné voči perturbáciám dát, času a analytických nastavení.

Multi-view profilovanie možno realizovať viacerými spôsobmi podľa toho, aký typ záveru chceme dosiahnuť. Prvým prístupom je triangulácia a konvergentná validácia, kde jednotlivé pohľady slúžia na overovanie konzistencie a interpretáciu zistených vzorov. Druhým je fúzia reprezentácií (joint representation), v ktorej sa informácie z rôznych pohľadov integrujú do spoločného priestoru príznakov alebo latentných premenných. Tretím je neskorá integrácia (late fusion), kde sa najprv budujú samostatné modely pre jednotlivé pohľady a ich výstupy sa kombinujú až na úrovni rozhodnutí. V praxi je výber integrácie kompromisom medzi interpretovateľnosťou, robustnosťou a dostupnosťou dát.

Kríza replikovateľnosti a interpretovateľnosti

Jedným z najpálčivejších problémov súčasnej dátovej vedy v kombinácii s behaviorálnymi vedami je tzv. kríza replikovateľnosti. Tento fenomén, pôvodne identifikovaný v psychológii a medicíne, sa výrazne prejavuje aj v oblasti profilovania používateľov a analýzy herných dát (Locey, 2020). Mnohé štúdie, ktoré publikujú nové typológie hráčov alebo študentov, zlyhávajú pri pokusoch o validáciu na nových datasetoch alebo v mierne odlišných kontextoch (Patkar & Seyff, 2023). Nereplikovateľnosť výsledkov v praxi často nevzniká iba voľbou algoritmu, ale kumulatívnym efektom množstva malých analytických rozhodnutí. Patria sem napríklad voľba časového okna, agregácie, normalizácie, spôsobu redukcie dimenzie, parametrov zhľukovania, práce s chýbajúcimi dátami či náhodných inicializácií. Tieto stupne voľnosti vytvárajú priestor, v ktorom môže tá istá dátová situácia viesť k odlišným persónam alebo segmentom, čo logicky vyvoláva potrebu metodík, ktoré tieto rozhodnutia explicitne evidujú, testujú robustnosť a preferujú stabilné riešenia.

Príčinou tohto stavu je často nekritická aplikácia algoritmov strojového učenia a data miningu. Výskumníci a praktici často pristupujú k algoritmom zhľukovania (napr. k-means, hierarchické zhľukovanie) ako k čiernym skrinkám, do ktorých vložia surové dáta a očakávajú, že výstupom bude objektívna pravda o štruktúre používateľskej základne. Ignorujú pritom fakt, že výsledky týchto algoritmov sú silne závislé od počiatočných podmienok, nastavenia hyperparametrov a stochastickej povahy samotných metód (T. Liu et al., 2022), (Ditton et al., 2022). V kontexte profilovania sa tento problém prejavuje ako halucinácia štruktúry. Algoritmy sú navrhnuté tak, aby našli zhľuky aj v dátach,

ktoré sú v skutočnosti náhodným šumom (Iam-On, 2020). Ak sa aplikuje k-means na náhodne vygenerované dáta, algoritmus poslušne rozdelí body do k skupín. Bez rigorózneho validácie stability sú tieto skupiny bezcenné, no v praxi sú často interpretované ako nové typy používateľov.

Práca preto stavia na myšlienke, že interpretovateľnosť a replikovateľnosť nie sú len žiaduce vlastnosti modelu, ale nutné podmienky jeho vedeckej validity. Interpretovateľnosť v našom poňatí znamená schopnosť modelu vysvetliť priradenie používateľa do klastra v pojmoch, ktoré sú zrozumiteľné pre doménového experta (herného dizajnéra, pedagóga). Ak model tvrdí, že používateľ patrí do skupiny "Explorers", musí byť tento záver podložený nielen polohou v n -rozmernom priestore príznakov, ale aj koreláciou s nezávislými premennými, ako sú osobnostné črty (napr. *Openness to Experience* v modeli Big Five) alebo špecifické herné mechaniky (napr. počet odomknutých achievementov spojených s prieskumom) (Tondello et al., 2016).

Porovnateľnosť a prenosu znalostí naprieč prostrediami

Ďalším kľúčovým problémom, ktorý motivuje túto prácu, je fragmentácia poznania. Virtuálne prostredia sú extrémne heterogénne. Typológia hráčov vyvinutá pre akčnú hru z pohľadu prvej osoby (FPS) je len ťažko aplikovateľná na strategickú hru v reálnom čase (RTS) alebo na edukatívnu matematickú hru. Táto neschopnosť prenášať modely medzi doménami vedie k tomu, že pre každé nové prostredie musíme budovať profilovacie modely od začiatku, čo je neefektívne a bráni vytvoreniu všeobecnej teórie interakcie vo virtuálnych svetoch (Zhuang et al., 2021).

Cross-game user modeling a transfer learning predstavujú sľubné smery riešenia, avšak narážajú na problém nekompatibility metrík. "Vysoký výkon" v hre *Counter-Strike* (meraný ako podiel kill/death) a "vysoký výkon" v hre *Civilization* (meraný ako ekonomická efektivita) sú matematicky neporovnateľné veličiny. Je preto potrebné zaoberať sa otázkou, ako extrahovať abstraktné, doménovo nezávislé príznaky alebo vyššie úrovne reprezentácie, ktoré by umožnili porovnateľnosť naprieč rôznymi prostrediami (Shaker & Abou-Zleikha, 2016). V praxi k tomu môže viesť buď procesná abstrakcia správania (napr. epizódy a taktiky), alebo voľba príznakov viazaných na všeobecné aspekty interakcie (napr. tempo, konzistencia výkonu, ochota riskovať či miera sociálnej participácie).

Pri granulárnych dátach sa porovnateľnosť nekomplikuje iba šumom a objemom, ale aj tým, že samotná eventová schéma je dizajnový artefakt. Rôzne aplikácie (alebo aj rôzne verzie tej istej aplikácie) môžu udalosti definovať odlišne, meniť význam parametrov či pridávať nové typy interakcií. Bez explicitného mapovania eventov na spoločný slovník alebo vyššiu abstrakciu tak vzniká riziko, že model zachytí rozdiely v inštrumentácii, nie v správaní používateľov. Z prehľadového hľadiska to podporuje význam procesných reprezentácií a abstrahovaných príznakov, ktoré sú menej citlivé na implementačné detaily.

Jedným z prístupov k riešeniu uvedených problémov je stability-first perspektíva. Tento prístup, ktorý sa bude detailne rozoberať v nasledujúcich kapitolách, postuluje, že validita klastra (a teda persóny) nie je určená jeho kompaktnosťou (ako merajú indexy typu Silhouette), ale jeho odolnosťou voči perturbáciám v dátach. Iba stabilné štruktúry, ktoré pretrvávajú naprieč rôznymi pohľadmi a časovými oknami, môžu slúžiť ako spoľahlivý základ pre tvorbu person (Tarekegn et al., 2025).

Dátové zdroje a riziká

Pre vytvorenie komplexného a robustného modelu používateľa je nevyhnutné pracovať s viacerými dátovými pohľadmi. V nasledujúcej časti sa preto opisujú kategórie dátových zdrojov, s ktorými práca operuje: subjektívne dotazníky, agregované logy, granulárna event-telemetria a procesná abstrakcia v podobe herných epizód a taktík.

Praktickým predpokladom multi-view analýzy je schopnosť spoľahlivo spájať údaje na úrovni používateľa alebo relácie. V reálnych systémoch sa však identita často mení naprieč platformami, časť dát je anonymizovaná a stabilné identifikátory na jednoznačný matching môžu chýbať. Výsledkom je, že jednotlivé pohľady sa prekrývajú len čiastočne a vznikajú nevyvážené podvzorky, ktoré môžu deformovať interpretáciu aj generalizáciu zistení. Preto je v danej situácii potrebné explicitne rozhodnúť, či je cieľom user-level profil alebo session-level profil, a formulovať pravidlá spájania dát tak, aby boli metodicky obhájiteľné.

Subjektívna vrstva: dotazníky a psychometria

Dotazníkové metódy predstavujú subjektívny, explicitný pohľad na používateľa – zachytávajú konštrukty, ktoré v telemetrii často existujú len nepriamo (motivácia, potreby, prítomnosť, osobnostné predispozície). V multi-view profilovaní sa používajú primárne ako validačná a interpretačná vrstva: pomáhajú posúdiť, či behaviorálne zhľady majú psychologicky plausibilnú interpretáciu a či sa viažu na teoreticky ukotvené premenné. Nejde teda o „ground truth“ v meracom zmysle, ale skôr o získanie teoreticky ukotvených konštruktov (osobnosť, motivácia, potreby, prítomnosť), voči ktorým možno posudzovať plausibilitu a vysvetliteľnosť telemetrických modelov.

V oblasti virtuálnych prostredí a hier sa pre profilovanie najčastejšie využívajú nasledovné triedy dotazníkových konštruktov:

- **Osobnostné profilovanie** predstavujúce stabilnejšie dispozičné charakteristiky nezávislé od konkrétnej aplikácie, napr. osobnosť – Big Five, ktoré je psychometrickým štandardom (Roccas et al., 2002). Výskumy konzistentne ukazujú korelácie medzi týmito črtami a herným správaním. Napríklad hráči s vysokou mierou svedomitosti inklinujú k systematickému plneniu úloh a kompletizácii obsahu, zatiaľ čo neurotíckí hráči môžu vykazovať vyššiu mieru fluktuácie a odchodu zo systému pri zlyhaniach (Mustač et al., 2022).
- **Gamifikačné a motivačné typológie** viazané na mechaniky riešia potreby hier a gamifikovaných systémov, kde sa všeobecné modely ukazujú ako príliš hrubé. Napr. model *Hexad* bol vyvinutý s cieľom lepšie mapovať motiváciu na herné mechaniky s priamou prepojitelnosťou na dizajnové prvky (napr. rebríčky, chat), čo z neho robí ideálny nástroj pre personalizáciu (Tondello et al., 2016), (Fong et al., 2024).
- **Meranie zážitku** zachytáva subjektívne prežívanie interakcie a pomáha interpretovať, prečo sa používateľ správa určitým spôsobom. V praxi sa využívajú nástroje ako *Game Experience Questionnaire* (GEQ; (Högberg et al., 2019)) alebo *Player Experience of Need Satisfaction* (PENS; (Ijaz et al., 2020)), pričom PENS vychádza z Teórie sebaurčenia (*Self-determination theory*, SDT) a operacionalizuje naplnenie potrieb kompetencie, autonómie a vzťahovosti (Dunn & Zimmer, 2020), ('Self-Determination Theory: Basic Psychological Needs in Motivation, Development, and Wellness', 2017). Tieto škály sú nevyhnutné na rozlíšenie, či je pozorované správanie (napr. dlhý herný čas) prejavom pozitívneho zapojenia alebo skôr negatívnych mechanizmov.
- **Akceptácia technológií a zámer používania** reprezentované štandardizovanými dotazníkmi *Technology Acceptance Model* (TAM; (Manis & Choi, 2019)), *Unified Theory of Technology Acceptance and Use* (UTAUT; (Ustun et al., 2023)), meria konštrukty ako vnímaná užitočnosť, vnímaná jednoduchosť použitia, behaviorálny zámer. Tieto sú užitočné najmä pri hodnotení prijatia VR tréningu, mikrolearningu alebo gamifikovaných systémov a pri vysvetlení, prečo sa rovnaké správanie (napr. krátke sedenia) môže viazať na odlišné príčiny (nízka akceptácia vs. efektívne plnenie cieľa).

- **Imerzia a prítomnosť** (presence) predstavujú špecifickú triedu konštruktov dôležitú najmä vo VR, kde zachytávajú, ako silno sa používatelia do hry vžívajú a aký silný je pocit, že sú súčasťou daného prostredia. Tento typ merania umožňuje identifikovať, či technické faktory (napr. latencia, nízke rozlíšenie, nestabilné sledovanie) narúšajú ilúziu prítomnosti, a tým skresľujú aj následnú interpretáciu telemetrie a modelov správania. Štandardizované meranie poskytuje napr. ITQ (*Immersive Tendencies Questionnaire*; (Witmer & Singer, 1998)), PQ (*Presence Questionnaire*; (Witmer & Singer, 1998)), IPQ (*Igroup Presence Questionnaire*; (Schubert et al., 2001)), alebo MEC-SPQ (Vorderer et al., 2004) testujúci priestorové vnímanie na základe mentálnych modelov.

Napriek užitočnosti sú dotazníkové dáta zaťažené niekoľkými fundamentálnymi problémami, ktoré je potrebné reflektovať:

- **Skreslenie sebahodnotenia** reprezentuje najväčšie riziko nepresnosti v týchto údajoch. Predstavuje rozdiel medzi tým, čo si používatelia myslia, že robia, a tým, čo skutočne robia. Tento fenomén je zosilnený tzv. skreslením sociálnej žiadanosti, kedy respondenti upravujú svoje odpovede tak, aby vyzerali v lepšom svetle (napr. nadhodnocujú svoju altruistickú motiváciu a podhodnocujú kompetitívnosť) (Bönte et al., 2017). Bez použitia kontrolných mechanizmov sú tieto dáta náchylné na systematickú chybu (Hart et al., 2015).
- **Kríza validity meracích nástrojov** spočíva v nekritickom preberaní nástrojov, ktoré, hoci je v komunite bežné, je problematické. Nedávne systematické revízie, napríklad v prípade GEQ, odhalili vážne nedostatky v jeho psychometrickej štruktúre. Pôvodná 7-faktorová štruktúra GEQ nebola v mnohých nezávislých štúdiách replikovaná, čo naznačuje, že nástroj nemusí merať to, čo autori zamýšľali (Law et al., 2018). Podobne, preklady dotazníkov bez rigoróznejšej spätnej validácie môžu úplne zmeniť význam položiek a zneplatniť medzinárodné porovnania (Rebhi et al., 2023).
- **Problém časovosti a synchronizácie pohľadov** – dotazníky sú zo svojej podstaty statické snímky, ktoré zachytávajú stav používateľa v jednom konkrétnom bode v čase (zvyčajne pred alebo po interakcii), často navyše retrospektívne. Motivácia a prežívanie vo virtuálnom prostredí sú však dynamické procesy a môžu sa meniť v priebehu jednej relácie aj naprieč reláciami. Hráč môže začať ako zvedavý *Explorer*, no po sérii frustrujúcich neúspechov prejsť k agresívnejšiemu alebo rezignovanému správaniu; statický profil vytvorený na začiatku tak nemusí zachytiť reálnu trajektóriu a vedie k desynchronizácii modelu a reality (von Ziegler et al., 2021), (Ellison et al., 2015). Nesúlad sa ďalej zvyšuje tým, že telemetria opisuje správanie v konkrétnom čase a kontexte, zatiaľ čo dotazníky zachytávajú postoj alebo zážitok s časovým odstupom. Vo VR sa navyše môže výrazne prejaviť novelty effect, habituácia na ovládanie či únava, ktoré menia správanie aj subjektívne hodnotenia (Miguel-Alonso et al., 2024). Pri interpretácii multi-view profilov je preto dôležité explicitne uvádzať, kedy bol ktorý pohľad meraný, a či sa profilovanie týka prvej skúsenosti, stabilnej fázy používania alebo dlhodobej trajektórie.

Agregačná vrstva: sumarizácie údajov z logov

Druhý pohľad predstavuje prechod od subjektívneho k objektívnemu, avšak s vysokou mierou kompresie dát. Sumárne logy sú agregácie telemetrických dát na úrovni používateľa alebo sedenia. Tento pohľad je dominantný v priemyselnej praxi a business intelligence, pretože je výpočtovo efektívny a ľahko komunikovateľný manažmentu. Dáta v tejto vrstve majú typickú podobu štruktúrovaných záznamov v relačných databázach pričom kľúčové metriky zahŕňajú:

- **Angažovanosť a retencia** pokrývajú metriky aktivity a návratnosti používateľov, napr. denný/mesačný počet aktívnych používateľov, dĺžku sedenia, frekvenciu hrania a retenciu/churn (napr. návrat po 1., 7. či 30. dni). Tieto charakteristiky sú základom pre hodnotenie akceptácie produktu a v praxi aj pre rýchlu detekciu odchodu používateľov (Mäntymäki et al., 2020), (Drachen et al., 2014).
- **Výkonnosť a progres** zachytávajú úspešnosť a postup používateľa obsahom, napr. skóre/bodové zisky, pomer výhier a prehier, miera dokončenia úrovní, rýchlosť progresu a počet odomknutých prvkov. Ide o typické skill/progression signály, ktoré sa používajú aj na diagnostiku problémových miest v dizajne (Drachen et al., 2013).
- **Ekonomika a monetizácia** reprezentujú obchodnú výkonnosť a konverzné pomery k platbe alebo nákupu (podiel platiacich používateľov). Tieto metriky sú kľúčové najmä pri free-to-play a live-ops rozhodovaní (rozpočty, segmentové kampane, ekonomika hry) (P. P. Chen et al., 2018).

Metriky potom slúžia ako vstup pre základnú segmentáciu – buď **prahovaním** (napr. definícia intenzívneho hráča ako hranie > 20 hod./týždeň), alebo **zhlukovaním** (napr. k-means) nad vektorom sumarizujúcim aktivitu a hodnotu používateľa (Baumann et al., 2018), (Drachen, 2015).

Agregačný pohľad je síce praktický a výpočtovo efektívny, no v kontexte profilovania prináša viacero systematických limitácií a rizík:

- **Strata kontextu a behaviorálny aliasing** v dôsledku agregácie, ktorá predstavuje stratový proces redukcie časovej a sekvenčnej štruktúry správania na sumárne ukazovatele (priemery, súčty, percentá). Nevyhnutne sa tak znižuje interpretovateľnosť a môžu sa tiež zjednotiť odlišné trajektórie do identickej hodnoty. V dôsledku toho agregované analýzy často zachytia dlhodobý priemer, ale skryjú krátkodobé stratégie, prechody medzi režimami správania a príčiny pozorovaných javov, ktoré sa ukážu až pri časovej analýze (Loria et al., 2021).
- **Simpsonov paradox** – pri agregovaných dátach môže trend pozorovaný v celej populácii zmiznúť alebo sa dokonca obrátiť po rozdelení dát do prirodzených podskupín. Ide o klasický štatistický efekt spojený s konfúznymi premennými a nesprávnou interpretáciou asociácií bez kauzálneho kontextu; v praxi vedie k chybným záverom, ak sa segmentácia a kontrola zavádzajúcich faktorov robí až po agregácii (Simpson, 1951), (Pearl, 2013).
- V edukácii a mikrolearningu je navyše potrebné počítať s tým, že agregované metriky výkonu **nemusia odrážať iba znalosti alebo schopnosti**, ale aj stratégiu práce s úlohami. Príkladom je správanie typu rapid guessing alebo iné formy nízkeho úsilia, ktoré môžu umelo znižovať alebo naopak skresľovať indikátory úspešnosti a času riešenia (Jan Skalka & Valko, 2024). Ak takúto kontamináciu ignorujeme, profilovanie môže vytvárať segmenty, ktoré v skutočnosti rozlišujú kvalitu angažovanosti namiesto schopností či preferencií. Z toho dôvodu je vhodné v multi-view rámci dopĺňať agregované metriky o signály správania (tempo, sekvencie, opakované pokusy) alebo o detekciu nekvalitných interakcií (Rios & Soland, 2021a), (Wise & Kuhfeld, 2021).
- **Granularita vs. súkromie** – agregované dáta sa v praxi často používajú ako bezpečnejšia alternatíva, pretože znižujú riziko identifikácie jednotlivcov. Zároveň však agregácia odstraňuje kontext a detaily správania, čím obmedzuje schopnosť robiť hĺbkovú diagnostiku (napr. hľadať príčiny problémov alebo odhaliť konkrétne stratégie). Preto je potrebné vedome nastaviť kompromis: zbierať a uchovávať len takú mieru detailu, ktorá je nevyhnutná pre analýzu, a doplniť ju o primerané anonymizačné a bezpečnostné opatrenia; aj tak však pri zdieľaní dát zostáva určité reziduálne riziko re-identifikácie (Mesana et al., 2025), (Narayanan & Shmatikov, 2008).

Behaviorálna vrstva: event-telemetry a granulórne dáta

Behaviorálna vrstva pracuje s granulórnymi záznamami udalostí, ktoré vznikajú priamo počas interakcie používateľa so systémom. V praxi ide o sekvenciu časovo označených udalostí zachytávajúcich čo sa stalo, kedy a v akom kontexte; tento princíp je príbuzný štandardnému chápaniu event logov v process miningu a existujú aj formálne štandardy na výmenu takýchto logov (napr. XES/IEEE) (Drachen, 2015). Event-telemetry predstavuje metodicky najbohatší zdroj, pretože umožňuje analyzovať správanie ako proces v čase, nie len ako agregovaný výsledok.

- **Priestorové správanie** a trajektórie je možné v 2D a 3D prostrediach prirodzene zachytávať, pričom je bežné pracovať so súradnicami a odvodenými reprezentáciami (napr. heatmaps, smer pohybu, zóny záujmu), ktoré poskytujú rýchlu spätnú väzbu o navigácii, využití priestoru a problémových miestach dizajnu (Drachen et al., 2013), (Moura et al., 2011).
- **Sekvenčný a procesný pohľad** chápu udalosti ako sekvencie (napr. n-gramy, Markovské prechody) alebo ako procesné modely (process mining), čo je užitočné na identifikáciu typických prechodov systémom, odchýlok a opakujúcich sa vzorcov. V hernej doméne sa process mining ukázal ako použiteľný aj na analýzu hráčskych postupov (napr. nad logmi achievementov) (Macak et al., 2022), (Ludwig et al., 2024).
- **Predikcia a adaptácia** sú aktuálne častým cieľom spracovania sekvenčných udalostí. Vďaka množstvu a úrovni detailnosti je možné vykonávať predikciu ďalšej aktivity, časovania alebo pokračovania epizódy často v podobe modelov hlbokého učenia (napr. LSTM, transformery) nielen na predikciu, ale aj detekciu anomálií (botov, podvodníkov) (Bunian et al., 2017), (Gunes et al., 2022).

Granularita síce poskytuje množstvo informácií, ale súčasne zvyšuje riziká nesprávnej interpretácie spočívajúce v nárokoch na reprezentáciu, kvalitu dát a interpretáciu.

- **Kvalita logov a predspracovanie** sú nevyhnutnou súčasťou každého spracovania telemetrických dát. Surové záznamy udalostí často obsahujú nekompletné alebo nepresné časové pečiatky, duplicity, udalosti mimo reálneho toku či nekonzistentné schémy. Preto je pred spracovaním typicky nutné systematické čistenie a štandardizácia event logu (Suriadi et al., 2017), (Marin-Castro & Tello-Leal, 2021).
- **Dimenzionalita a riedkosť** je spôsobená prevodom udalostí na charakteristiky (počty eventov, vysoké kardinality, kombinácie s kontextom), čo vedie často k riedkym a vysoko-dimenzionálnym reprezentáciám. V takomto priestore sa zhoršuje zmyslupnosť vzdialeností a klasické metriky môžu prestať fungovať spoľahlivo. Ide o praktický dôsledok „preklatia“ dimenzionality a problémov vzdialeností vo vysokých dimenziách a s riedkymi údajmi (Keogh & Mueen, 2010), (Aggarwal et al., 2001).
- **Redukcia dimenzionality $\neq$ dôkaz klastrov**. PCA je stabilná lineárna voľba na zachytenie variance, no nemusí vystihnúť nelineárne štruktúry. t-SNE a UMAP sú silné na vizualizáciu lokálnych susedstiev, ale 2D projekcie môžu skresľovať globálne vzťahy; „pekne klastre“ vizualizované v 2D priestore sa preto nemajú interpretovať ako dôkaz reálnych typov bez ďalšej validácie (stabilita, replikácia, externé premenné) (Gewers et al., 2022), (Van Der Maaten & Hinton, 2008). Navyše, pri UMAP majú hyperparametre priamy vplyv na to, ako husto bude embedding vyzeráť, čo zvyšuje riziko vizuálnej nadinterpretácie (McInnes et al., 2018).
- **Šum a chýbajúce dáta** sú typické najmä pre prostredia VR, kde do telemetry vstupuje merací šum zo senzorov, pričom kvalita môže byť citlivá na kalibráciu, pohyb HMD a konkrétny headset. Ak sa tento šum nevyfiltruje, algoritmy môžu chybné interpretovať trhavé pohyby očí ako kognitívnu neistotu. Okrem toho, telemetrické toky sú často nekompletné (výpadky siete,

pády aplikácie) pričom jednoduché metódy imputácie (doplnenie priemerom) môžu zaviesť nevhodný bias (Adhanom et al., 2023), (Hou et al., 2024), (van Buuren & Groothuis-Oudshoorn, 2011).

Procesná vrstva: epizódy a taktiky

Epizódu v tejto práci chápeme časovo ohraničený úsek aktivity používateľa s relatívne konzistentným kontextom alebo cieľom, ktorý je rekonštruovateľný z behaviorálnych dát. Taktika je následne opakujúci sa spôsob postupu v rámci epizódy (vzor krokov a rozhodnutí), ktorý reprezentuje stratégiu riešenia. Segmentácia na epizódy môže byť realizovaná heuristicky (pravidlá, prahy), modelovo (napr. detekcia zmien stavov) alebo modulárne kombináciou viacerých segmentátorov podľa typu prostredia a dát. Procesná vrstva tým poskytuje reprezentáciu, ktorá je často interpretovateľnejšia než surové (nespracované) udalosti a zároveň vhodnejšia na prenos poznatkov medzi rozdielnymi aplikáciami.

Procesná vrstva nadväzuje na event-telemetriu, no posúva ju na vyššiu úroveň abstrakcie: tok udalostí sa segmentuje na epizódy a v rámci nich sa identifikujú taktiky ako opakovateľné vzorce postupu. Tento krok nadväzuje na prístupy procesnej analytiky a game analytics, ktoré kombinujú segmentáciu, zhľukovanie/porovnávanie trás a následnú interpretáciu prostredníctvom procesných modelov alebo vzorcových štruktúr (Teng et al., 2025), (Abb et al., 2022), (Agostinelli et al., 2021).

Procesná reprezentácia sa využíva najmä na:

- **Zvýšenie interpretovateľnosti správania a komunikáciu výsledkov** – epizódy fungujú ako jednotky významu, ktoré sa dajú priamo vysvetliť dizajnérom alebo pedagógom a vizualizovať ako procesné postupy. V hernej doméne sa segmentácia často používa ako medzikrok k ťažbe vysvetliteľných stratégií hráčov a k interpretácii správania na úrovni zmysluplných úsekov, nie iba surových eventov (Teng et al., 2025), (Abb et al., 2022).
- **Ťažbu opakujúcich sa vzorcov (taktík) a ich validáciu** – nad epizódami alebo event logmi je možné hľadať opakujúce sa sekvencie a štruktúry správania, ktoré sa následne interpretujú a validujú ako taktiky relevantné pre balancing, spätnú väzbu alebo intervencie. Osobitne užitočné sú prístupy, kde sa kandidátne vzorce nevyberajú výlučne automaticky, ale vznikajú v iterácii s doménovým expertom: algoritmus navrhne vzorce správania a expert ich priebežne interpretuje, filtruje a pomáha z nich formulovať zmysluplné taktiky (S. Anderson & Falconer, 2025), (Leemans & van der Aalst, 2015).
- **Detekciu zmien stratégií a vývojových trajektórií v čase** – procesná vrstva umožňuje sledovať, ako sa používateľský postup mení v rámci jednej relácie aj naprieč reláciami (prechody medzi epizódami/taktikami, zmeny režimu správania). To je dôležité najmä v prostrediach, kde sa správanie adaptuje na spätnú väzbu, náročnosť alebo frustráciu, a kde statické agregované metriky tieto posuny zakrývajú. Procesné prístupy poskytujú prirodzený rámec na zachytenie takýchto posunov (Abb et al., 2022), (Agostinelli et al., 2021).
- **Diagnostiku dizajnu prostredia a identifikáciu problémových miest** – epizódy a taktiky umožňujú analyzovať, v ktorých častiach úlohy/levelu sa opakovane objavujú nežiaduce postupy (napr. stagnácia, obchádzanie mechaník, náhodné skúšanie), prípadne kde vznikajú úzke miesta vedúce k odchodu používateľov. V porovnaní s čistým vyhodnotením výsledku (skóre/čas) poskytuje procesná reprezentácia konkrétnejší obraz toho, čo presne v dizajne generuje problémový priebeh (Teng et al., 2025), (Agostinelli et al., 2021).
- **Prenos poznatkov naprieč prostrediami a hodnotenie zručností na základe priebehu jeho dosahovania** – konkrétne eventy sa menia medzi aplikáciami, ale procesné štruktúry (postupy, prechody stavmi, typické postupy) bývajú stabilnejšie a lepšie porovnateľné. V serious games sa podobné procesné prístupy používajú aj na hodnotenie zručností z logov, kde je dôležitý

práve priebeh riešenia, nie iba výsledok (Abb et al., 2022), (Caballero-Hernández et al., 2024). Z pohľadu multi-view podporuje porovnateľnosť tým, že prepája rôzne implementácie cez vyššiu procesnú abstrakciu.

Aj keď procesná vrstva zvyšuje explanačnú hodnotu, prináša vlastné riziká vyplývajúce z toho, že ide o modelovací krok nad telemetriou. Typické riziká procesnej vrstvy zahŕňajú:

- **Citlivosť na segmentáciu a parametre** – hranice epizód, minimálne dĺžky, definícia zmeny režimu či heuristiky zoskupovania môžu výrazne zmeniť výslednú štruktúru a tým aj interpretáciu taktík (Agostinelli et al., 2021), (Przymus et al., 2025).
- **Nejednoznačnosť kontextu a citlivosť procesných reprezentácií** – pri rekonštrukcii epizód je často nejasné, ako správne priradiť udalosti ku konkrétnym herným situáciám (session/quest/task), najmä ak logy nie sú navrhnuté procesne alebo sú len čiastočne štruktúrované; chyby v tomto kroku sa následne prenášajú do epizód aj odvodených taktík (Przymus et al., 2025). Zároveň sú procesné reprezentácie citlivé na to, ako je v prostredí definovaná úloha, cieľ či pravidlá interakcie: zmena dizajnu levelu, zadania alebo mechaniky môže spôsobiť, že tá istá taktika bude mať iný význam alebo sa začne prejavovať odlišne v dátach. Pri porovnávaní naprieč prostrediami je preto potrebné uvádzať mieru zjednotenia epizód spoločnou schémou a overiť, či nejde o porovnávanie nekompatibilných procesov; interpretáciu je vhodné opierať aj o externé kotvy alebo validáciu (Ramadan et al., 2019), (Elbert & Flath, 2024).
- **Riziko nadinterpretácie vzorcov** – opakujúci sa vzorec správania nemusí byť stabilná taktika, ale môže ísť o artefakt konkrétneho datasetu, verzie hry alebo heuristiky segmentácie. Preto je vhodné aj procesnú vrstvu budovať stability-first a validovať výskyt epizód/taktík naprieč perturbáciami, oknami času a nastaveniami segmentácie (Abb et al., 2022).

Stabilita klastrovania ako kritérium validity person

Analýza jednotlivých dátových pohľadov ukazuje, že každý z nich nesie vlastný typ neistoty – od subjektivity dotazníkov, cez stratu kontextu pri agregácii, až po šum a artefakty v telemetrii. Bežné klastrovacie metódy pritom vždy vytvoria nejaké rozdelenie populácie, aj keď je skutočná štruktúra slabá alebo sporná. Preto sa validácia person nemôže opierať iba o matematicky získaný výsledok alebo optimalizačný index, ale o to, či sa zistená štruktúra reprodukovateľne udrží pri realistických zmenách dát a analytických nastavení (Hennig, 2007), (Ben-Hur et al., 2002), (Von Luxburg, 2009).

Stabilitu chápeme ako **reprodukovateľnosť klastrov** pri perturbáciách (napr. subsampling, bootstrapping, pridanie šumu) a pri opakovaných behoch algoritmu. Prakticky ju overujeme resamplingom: opakovane vytvárame vzorky, klastrujeme a následne porovnávame získané partície pomocou štandardných mier zhody (napr. *Adjusted Rand Index* alebo *Jaccardov koeficient*, vrátane cluster-wise variantov pre stabilitu jednotlivých klastrov) (Hennig, 2007), (Hubert & Arabie, 1985), (Ben-Hur et al., 2002). Stabilita zároveň slúži ako kritérium výberu nastavení (najmä počtu klastrov), napríklad aj v prístupoch typu consensus clustering (Von Luxburg, 2009), (Monti et al., 2003); v multi-view prostredí ju rozširujeme aj o robustnosť voči zmene reprezentácie, blokov príznakov a časových okien.

Stabilita je nevyhnutná, no nie postačujúca: aj stabilné rozdelenie môže byť triviálne alebo málo informatívne. Preto ju kombinujeme s interpretovateľnosťou a vecnou validáciou – t. j. požadujeme, aby klastre mali zrozumiteľný význam pre doménového experta a vykazovali konzistentné vzťahy k externým premenným (napr. dotazníkové konštrukty či skúsenosť používateľa). V tomto zmysle stability-first prístup posúva tvorbu person od jednorazovej interpretácie zhlukov ku kontrolovanému

procesu, kde sa persona potvrdí až vtedy, keď preukáže robustnosť aj vysvetliteľnosť v širšom validačnom rámci (Tarekegn et al., 2025).

Multi-view profilovanie vo virtuálnych prostrediach stojí na kombinácii heterogénnych dátových zdrojov, ktoré sa navzájom dopĺňajú, no zároveň nesú odlišné typy skreslení a neistôt. Prehľad preto vyúsťuje do troch opakovane sa objavujúcich výziev: porovnateľnosti naprieč prostrediami, interpretovateľnosti výsledkov a robustnosti voči analytickým rozhodnutiam i šumu v dátach. Procesné reprezentácie (epizódy/taktiky) a stabilítne orientované hodnotenie predstavujú prirodzené nástroje, ako tieto výzvy adresovať bez spoliehania sa na jediný zdroj pravdy.

Subjektívna vrstva – predispozície, skúsenosť a kontext

Subjektívna vrstva v tejto práci zahŕňa informácie získané prostredníctvom dotazníkov a sebareportovaných konštruktov, najmä motiváciu, preferencie, imerznú predispozíciu a technologickú skúsenosť. Jej hlavnou výhodou je vysoká interpretovateľnosť: umožňuje explicitne pomenovať východiskové predispozície používateľa a rámcovať, s akými očakávaniami a postojmi vstupuje alebo vychádza z virtuálneho prostredia ešte pred tým, než sa analýza oprie o behaviorálne dáta. Zároveň ide o vrstvu potenciálne prenositeľnú naprieč rôznymi virtuálnymi prostrediami, keďže nie je priamo viazaná na konkrétnu inštrumentáciu a granularitu záznamu udalostí.

Subjektívne meranie však má prirodzené obmedzenia. Merané konštrukty môžu byť citlivé na kontext a formuláciu položiek, respondenti sa líšia v štýle sebahodnotenia a časť používaných typológií sa v praxi uplatňuje ako zameniteľný slovník, hoci nemusí mať ekvivalentný význam ani faktorovú štruktúru. Táto kapitola preto neslúži len ako opis dotazníkových prístupov, ale predovšetkým ako vytvorenie interpretačných kotiev pre neskoršie behaviorálne persony:

- predchádzajúca skúsenosť s imerzívnymi systémami ako faktor ovplyvňujúci akceptáciu a používateľskú skúsenosť,
- typologické rámce ako nástroj interpretácie, ktorých ekvivalencia musí byť empiricky overená,

Predchádzajúca skúsenosť v imerzívnych prostrediach

Virtuálna realita (VR) predstavuje technológiu, ktorá rozširuje možnosti interakcie používateľov s digitálnym prostredím prostredníctvom imerzívneho zážitku. Kľúčovou charakteristikou VR je schopnosť vyvolať pocit ponorenia a prítomnosti (Shu et al., 2019), čo môže zvyšovať motiváciu používateľov k využívaniu prostredia (Hu et al., 2016), (H. M. Huang et al., 2010) a ovplyvňovať ich prežívanie, vnímanie aj správanie vo virtuálnom prostredí (Obukhov et al., 2023). Tieto vlastnosti robia z VR vhodný nástroj pre široké spektrum aplikácií vrátane vzdelávania, zábavy, tréningu a terapií, pričom kvalita imerzívnych a interaktívnych charakteristík významne ovplyvňuje akceptáciu VR a prijatie konkrétnych aplikácií (Fussell & Truong, 2023). Súčasne však VR prináša metodické riziká: používatelia sa líšia mierou zvyku na imerzívnú interakciu, čo môže meniť emocionálnu reakciu, percepciu, kognitívnu záťaž aj zvládnutie ovládania (Shin et al., 2013), (Plotzky et al., 2021).

Výskum správania používateľov v prostrediach VR sa v posledných rokoch výrazne zrýchlil, čo viedlo k vývoju rôznych rámcov, pričom niektoré stavajú na zavedených modeloch, ako napríklad *Technology Acceptance Model* (TAM) (Manis & Choi, 2019), *Unified Theory of Technology Acceptance and Use* (UTAUT) (Ustun et al., 2023), alebo *Theory of Planned Behaviour* (TPB) (Wafra & Akili, 2023). Iné zavádzajú nové koncepty prispôbené špecifickým potrebám a kontextom konkrétneho výskumu. Spoločným znakom väčšiny modelov je zameranie na akceptáciu technológií používateľmi, pričom každý ponúka odlišné prístupy k pochopeniu toho, prečo ich používatelia prijímajú alebo odmietajú.

Kľúčovými aspektmi predchádzajúcich VR skúseností sú miera zvládnutia ovládania a efekt novosti. Skúsení používatelia spravidla zvládajú navigáciu a interakčné schémy plynulo, takže problémy s ovládaním predstavujú len okrajové obmedzenie. Naopak, u nových používateľov sa v úvodných expozíciách kombinuje náročné osvojovanie ovládania s rozptýlením spôsobeným novotou, čo môže znižovať kvalitu používateľskej skúsenosti, angažovanosť a následne aj pravdepodobnosť ďalšieho používania (Alalwan et al., 2020), (W. Huang et al., 2021)

Na druhej strane môže efekt novosti krátkodobo pôsobiť aj opačne: noví používatelia často hodnotia VR pozitívne už samotnou fascináciou z imerzívneho zážitku a nového spôsobu interakcie, takže dočasne tolerujú aj slabšiu použiteľnosť alebo funkčné nedostatky aplikácie. Tento „wow efekt“ môže

viest ku krátkodobému zapojeniu napriek tomu, že dlhodobo sa ako bariéry prijatia ukážu práve ovládanie a navigácia, ktoré skúsení používatelia identifikujú rýchlejšie a posudzujú kritickejšie. Skúsení (nároční) používatelia zároveň lepšie filtrujú irelevantné podnety a sústreďujú sa na podstatné funkcie, čo sa môže premietiť do vyššieho ponorenia a spokojnosti (Miguel-Alonso et al., 2024), (Ball et al., 2021).

Pri opise respondentov výskumníci VR často spomínajú ich skúsenosti s VR, ale zriedkakedy integrujú tieto informácie do svojich analýz, záverov a diskusií (di Lanzo et al., 2020). Prehliadanie rozdielov v predchádzajúcej skúsenosti môže viesť k nepresným záverom a čiastočne vysvetľuje, prečo sa výsledky laboratórnych štúdií niekedy rozchádzajú s reálnym prijatím v praxi. Keďže používateľská skúsenosť je súčasťou väčšiny rámcov akceptácie technológií, je potrebné skúmať, ako predchádzajúca skúsenosť s VR ovplyvňuje jednotlivé dimenzie akceptácie, zapojenia a UX (Villena-Taranilla et al., 2023). Systematické rozlíšenie skupín podľa miery expozície preto umožňuje presnejšie porozumenie akceptácie a poskytuje relevantnejšie implikácie pre optimalizáciu VR pre rôzne používateľské kohorty.

Toto rozlíšenie definuje prvú výskumnú otázku:

- **SUB1: Ako predchádzajúca skúsenosť s VR, meraná kumulatívnym časom expozície, vplyva na dimenzie akceptácie VR obsahu (zaujímavosť, vnímaná jednoduchosť používania, zapojenie a ponorenie) a pri akej úrovni expozície dochádza k oslabeniu vplyvu efektu novosti na tieto hodnotenia?**

Prehľad relevantných zdrojov

Úroveň efektívnosti využívania VR prostredia a aplikácií výrazne závisí od toho, ako ľahko používatelia takýto systém akceptujú a osvoja si ho. Vo výskume akceptácie VR sa typicky uplatňujú dva prístupy:

- aplikácia etablovaných modelov akceptácie technológií, najmä TAM (Davis et al., 1989) a UTAUT (Venkatesh et al., 2003) vrátane ich rozšírení,
- tvorba doménovo špecifických dotazníkov prispôbených konkrétnemu prostrediu a úlohám.

V oboch prípadoch je cieľom identifikovať faktory, ktoré vysvetľujú akceptáciu a zámer používať VR. Rozdiel spočíva v tom, že prístupy založené na TAM/UTAUT vychádzajú z generalizovateľných determinantov akceptácie technológií, zatiaľ čo ad-hoc dotazníky bývajú konštruované tak, aby zachytili špecifiká konkrétného VR prostredia a úloh.

Modely odvodené z TAM sa vo VR kontexte najčastejšie rozširujú o premenné, ktoré zachytávajú špecifiká imerzívnych technológií alebo individuálne charakteristiky používateľa. Už skorý model (van Raaij & Schepers, 2008) vychádzajúci z TAM2 (Venkatesh & Davis, 2000), sa dopĺňa o sociálne normy, osobnú inovatívnosť v IT a úzkosť z počítača, čím posúva interpretáciu od čistej použiteľnosti aj k psychologickým a sociálnym faktorom. *Extended TAM* v (Sagnier et al., 2020) kombinuje premenné TAM s VR-špecifickými výsledkami (napr. pocit prítomnosti a nevoľnosť) a s charakteristikami používateľa; experiment v montážnych úlohách ukazuje typický vzorec: ochota používať VR rastie s vnímanou užitočnosťou, no klesá pri výskyte kybernetickej nevoľnosti. Rozšírenie TAM v (Disztinger et al., 2017) pridáva premenné ako vnímané potešenie, záujem, inovatívnosť, dostupnosť, skepticizmus, technologickú úzkosť a vnímanú imerziu – v turistickej doméne sa potvrdzuje, že vyššia imerzia podporuje zámer používať VR, no autori zároveň upozorňujú na limity masovej adopcie a zdôrazňujú potrebu posilnenia užitočnosti a zážitkovosti.

V edukácii sa TAM rozšírenia často spájajú s premennými súvisiacimi s učením a pozornosťou. Villena-Taranilla a kol. (Villena-Taranilla et al., 2023) analyzujú zámer žiakov používať imerzívnu VR pomocou SEM nad premennými *predchádzajúce vedomosti, vnímaná pozornosť, vnímaná užitočnosť, vnímaná jednoduchosť používania, vnímaná radosť a postoj*. Zistenie, že *predchádzajúce znalosti* neboli

významné pre *zámer používať VR*, naznačuje, že *zámer použiť* nemusí byť citlivý na rozdiely v *predchádzajúcich znalostiach*; zároveň však literatúra ukazuje, že *predchádzajúce znalosti* ovplyvňujú motiváciu, porozumenie a výkon a premietajú sa do postoja k vzdelávaciemu obsahu (Lin et al., 2011), (L. Y. Li, 2019), (Dong et al., 2020). V klinickom kontexte Bertrand & Bouchard (Bertrand & Bouchard, 2008) testujú aplikáciu *TAM* na VR s položkami upravenými na zručnosti a obavy typických používateľov (napr. *sebaúčinnosť, externá kontrola, úzkosť, vnútorná motivácia, vnímané náklady*), pričom finálny model ukazuje dominantnú úlohu *vnímanej užitočnosti* ako prediktora zámeru používať VR.

Na *TAM3* (Venkatesh & Bala, 2008) nadväzuje aj moderovaný mediačný model v (Wong et al., 2023), ktorý prepája *vnímanú užitočnosť* a *jednoduchosť použitia* s otvorenosťou voči skúsenosti a angažovanosťou vo VR vzdelávaní: používatelia otvorenejší novým technológiám hodnotia VR ako hodnotný tréningový nástroj a pozitívny postoj k VR vzdelávaniu súvisí s vyššou angažovanosťou.

Modely odvodené z UTAUT poskytujú pre VR výskum štandardizovaný základ štyroch jadrových determinantov zámeru používať technológiu: *očakávaný prínos, očakávaná náročnosť, sociálny vplyv* a *podporné podmienky* (Venkatesh et al., 2003). Výskum (Ustun et al., 2023) používa upravený dotazník založený na *UTAUT* a adaptuje položky na VR akceptáciu aj akceptáciu rozšírenej reality (augmented reality; AR) (Ustun et al., 2024). *UTAUT2* prístup v (F. H. Huang, 2020) rozširuje *UTAUT* o *hedonickú motiváciu, hodnotu nákladov* a *návyk*; aj tu sú položky modifikované pre VR a overené na konkrétnej skúsenosti (virtuálna jazda na e-kolobežke). Monteiro a kol. (D. Monteiro et al., 2022) aplikujú *UTAUT* v širšom, medzikultúrnom rámci a analyzujú aj *sebaúčinnosť, postoj* a *úzkosť* spolu s moderátormi (vek, pohlavie, VR skúsenosť, kybernetická nevoľnosť, typ regiónu). Výsledky naznačujú, že sociálny vplyv a podporné podmienky významne podporujú pozitívny postoj k VR, pričom kultúra formuje faktory vedúce k adopcii; zároveň však zámer používať VR ako nástroj učenia ostáva naprieč krajinami relatívne konzistentný.

Súhrnne možno povedať, že rozšírenia *TAM* vo VR typicky zachytávajú špecifiká zážitku (imerzia, prítomnosť, potešenie, nevoľnosť) a individuálne predispozície, kým *UTAUT/UTAUT2* poskytuje stabilnejší a porovnateľnejší rámec sociálno-organizačných determinantov (podmienky, normy, očakávania).

Popri týchto rámcoch sa v literatúre často objavujú aj meracie nástroje, ktoré explicitne dopĺňajú VR-špecifické aspekty a pracujú **s vlastnými škálami, rozšírenými dotazníkmi alebo doménovo špecifickými rámcami**, aby zachytili faktory typické pre imerzívne prostredia (napr. prítomnosť, imerzia, nevoľnosť, kognitívna záťaž) a lepšie vysvetlili akceptáciu a účinky VR v konkrétnych kontextoch.

AVRTS (Attitudes toward Virtual Reality Technology Scale) (Bunz et al., 2021) je príkladom rozšírenej škály postavenej na *TAM*, ktorá okrem vnímanej užitočnosti a jednoduchosti používania zahŕňa aj doplnkové skupiny položiek pre bariéry prístupu a charakteristiky používania internetu, čím prepája klasické determinanty akceptácie s praktickými kontextovými obmedzeniami (Porter & Donthu, 2006). V edukácii ide ďalej model *CAMIL (Cognitive Affective Model of Immersive Learning)* (Makransky & Petersen, 2021), ktorý syntetizuje poznatky z literatúry do kognitívno-afektívneho rámca a opisuje, ako faktory ako *záujem, motivácia, sebaúčinnosť, stelesnenie, kognitívna záťaž* a *sebaregulácia* sprostredkujú účinky VR na osvojovanie a transfer znalostí.

Systematické prehľady ukazujú, že kvalita technického a obsahového spracovania a konkrétne dizajnové prvky môžu podporovať prítomnosť, imerziu a realistickosť zážitku, čo sa následne premieta do motivácie a akceptácie (Caldas et al., 2022). Medzi opakovane zdôrazňované prvky patria najmä lepšia alokácia zdrojov pre hardvér a softvér, presnejší dizajn objektov a postáv, spätná väzba na výkon, možnosť prispôsobenia postavy či multiplayer mechaniky. Staršie prehľady potvrdzujú aj vzťah

prítomnosti k akceptácii VR, často však bez prepojenia s tradičnými mierami používateľskej skúsenosti (Shin et al., 2013). Na základe edukačných simulácií sa uvádza, že silnejší pocit prítomnosti zvyšuje pravdepodobnosť prijatia prostredia, hoci jeho vzťah k priamemu zlepšeniu znalostí nemusí byť vždy jednoznačný (Plotzky et al., 2021).

Analýza literatúry (Mütterlein & Hess, 2017) poukazuje na fakt, že výskum akceptácie VR používa premenné a dotazníkové konštrukty nejednotne, čo znižuje porovnateľnosť výsledkov naprieč štúdiami. Zároveň identifikuje VR-špecifické faktory, ktoré sa v empirických prácach často nemerajú, hoci môžu významne ovplyvňovať ponorenie a prítomnosť: kvalitu obsahu, počiatočné vzrušenie (wow efekt), izoláciu a rozptýlenie. Ich systematické zahrnutie (alebo kontrola) by zlepšilo interpretáciu a porovnateľnosť zistení o akceptácii VR v čase.

V existujúcej literatúre o akceptácii VR sa síce opakovane pracuje s konštruktmi užitočnosti a jednoduchej použiteľnosti, no integrácia záujmu (interest) ako samostatného determinantu býva menej systematická, napriek tomu, že práve záujem patrí medzi primárne spúšťače adopcie technológie (Granić, 2022), (Ball et al., 2021). Záujem predstavuje počiatočnú motiváciu technológiu vôbec vyskúšať a skúmať; bez neho je pravdepodobnosť prvého kontaktu a explorácie VR nízka. Na záujem nadväzuje jednoduchosť používania, ktorá priamo ovplyvňuje akceptáciu tým, že určuje, nakoľko ľahko sa používateľ dokáže v prostredí orientovať a interagovať. V praxi tak jednoduchosť používania pôsobí ako kľúčový faktor udržania angažovanosti po tom, čo je počiatočný záujem aktivovaný.

Keďže záujem je zároveň dimenziou citlivou na efekt novosti a predchádzajúcu skúsenosť je vhodné pracovať s nástrojom, ktorý ho meria spolu s použiteľnosťou a vyššími úrovňami imerzie v jednom rámci. Na zachytenie akceptácie aplikácie aj VR-špecifických charakteristík bol preto zvolený existujúci, predtým použitý a validovaný dotazník, pričom výber vychádzal z jeho komplexnosti, pokrytia relevantných oblastí a primeranej časovej náročnosti pre respondentov. Pri výbere sa zohľadnilo aj jeho prijatie a využívanie vo výskume rozšírenej reality. Výskum (Georgiou & Kyza, 2017) tento nástroj definuje, validuje a identifikuje jeho komponenty opisujúce charakteristiky dôležité pre imerzívne zapojenie používateľa.

Merací rámec akceptácie

Hoci bol dotazník pôvodne vytvorený pre meranie imerzie v rozšírenej realite, jeho konštrukcia vychádza z výskumu počítačových hier (Brown & Cairns, 2004) a pokrýva aj aspekty relevantné pre VR (J. H. Kim et al., 2023), (Bonetti et al., 2018), (Lemmens et al., 2022).

V rámci dotazníka bolo odvodených šesť škál usporiadaných do troch úrovní imerzie.

- Úroveň **engagement** zachytáva mieru zapojenia a schopnosť interakcie s aplikáciou a zahŕňa:
 - *interest* – záujem o aktivitu vrátane motivácie a ochoty investovať do nej čas,
 - *usability* – akceptácia používateľského rozhrania a intuitívnosť ovládania.
- Úroveň **engrossment** pokrýva prvky spájané s prítomnosťou a zahŕňa:
 - *emotional attachment* – emocionálne a vnútorné zapojenie do aktivity,
 - *focus of attention* – sústredenie a eliminácia rušivých vplyvov.
- Úroveň **total immersion** kombinuje subjektívnu prítomnosť a objektívnu imerziu a zahŕňa:
 - *presence* – prepojenie medzi reálnou aktivitou používateľa a jeho činnosťou vo virtuálnom svete,
 - *flow* – optimálny zážitok bez rozptýlenia so zžitím sa s vykonávanou aktivitou.

Tento rámec prepája tradičné determinanty akceptácie s VR-špecifickými charakteristikami a ich sumár definuje ako úroveň akceptácie. V ďalšej časti sa tento profil využíva na porovnanie skupín

definovaných kumulatívnym časom expozície vo VR, s cieľom určiť prah, pri ktorom sa oslabuje vplyv efektu novosti na hodnotenia akceptácie.

Prahový efekt expozície

Na zodpovedanie výskumnej otázky je kľúčové určiť, či má predchádzajúca skúsenosť s VR prahový charakter, t. j. či existuje úroveň kumulatívnej expozície, po ktorej sa hodnotenia akceptácie prestávajú významne líšiť v dôsledku novosti a adaptácie. Prvá štúdia preto porovnáva skupiny používateľov definované kumulatívnym časom expozície vo VR a sleduje, ako sa naprieč týmito kohortami menia dimenzie akceptácie merané škálami *engagement*, *engrossment* a *total immersion*. Zámerom je identifikovať ktoré dimenzie sú na efekt novosti najcitlivejšie a pri akom rozsahu expozície dochádza k oslabeniu tohto vplyvu, teda k stabilizácii hodnotení naprieč skupinami.


Metodika a dizajn štúdie

Výskumnú vzorku tvorilo 114 technicky zdatných participantov (26 žien, 88 mužov) rekrutovaných z IT kurzov a workshopov s cieľom minimalizovať skreslenie nízkou digitálnou gramotnosťou. V dotazníku sa zbierali demografické a behaviorálne premenné vrátane veku, pohlavia, predchádzajúcej skúsenosti s VR (v hodinách), týždenného herného času a času stráveného hraním sa na nemobilných platformách.

Každý respondent absolvoval tri typy VR aktivít v pevnom poradí:

- Pasívne 360° video – minimálna interaktivita; cieľom bolo sprostredkovať senzorické a emocionálne aspekty VR.
- Interaktívny úvodný tutoriál – osvojovanie základných ovládacích schém (interakcia s objektmi, gestá, jednoduché interakcie s umelými postavami).
- Akčná VR aktivita – simulácia horskej dráhy s limitovanou kontrolou, s dôrazom na rýchle podnety a vizuálnu imerziu.

Pred každou úlohou prebehlo krátke vysvetlenie špecifik danej aplikácie. Po prvých dvoch aktivitách respondenti vyplnili 7-bodový Likertov dotazník zameraný na používateľskú skúsenosť; druhé meranie nasledovalo po VR hre. Prvá vlna merania obsahovala aj dve ciele poločky na porovnanie zážitku z pasívnej a aktívnej modality. Všetky sedenia prebiehali v kontrolovaných podmienkach na rovnakom zariadení (Oculus Quest 2). Štruktúra participantov je vizualizovaná na Obr. 2a.




Obr. 2a Štruktúra účastníkov. Skúsenosti s VR (v hodinách) boli transformované pomocou prirodzeného logaritmu: $\ln(x+1)$ na účely normalizácie. Veľkosť každého dátového bodu odráža počet respondentov s rovnakou kombináciou skúseností s VR, veku a pohlavia (Ján Skalka & Valko, 2025a).

Predchádzajúca skúsenosť s VR bola meraná ako kumulatívny čas expozície (v hodinách). Pre účely analýzy bola táto premenná normalizovaná transformáciou $\ln(x+1)$. Na odlíšenie používateľských typov boli definované tri skúsenostné skupiny:

- Nováčikovia (0–1 hod.) – používatelia bez skúsenosti alebo s jednorazovým kontaktom; skupina vhodná na zachytenie efektu novosti ($n = 70$),
- Stredne skúsení (2–9 hod.) – používatelia s opakovanou expozíciou a skúsenosťou naprieč viacerými aplikáciami a ovládacími schémami ($n = 22$),
- Skúsení (≥ 10 hod.) – prah 10 hodín je motivovaný zisteniami, ktoré ho uvádzajú ako relevantnú hranicu pre základnú oboznámenosť až expertízu v špecifických systémoch (Atli et al., 2021), (Kluge et al., 2023), (A. F. Monteiro et al., 2023) ($n = 22$).

Dimenzie používateľskej skúsenosti boli počítané ako priemery položiek v rámci jednotlivých škál (*interest, usability, emotional connection, focus of attention, presence, flow*) a sú vizualizované na Obr. 2b. Premenné boli organizované aj podľa času merania:

- prefix *sp* zachytáva skoré hodnotenia (vrátane záujmu o 360° video a úvodnú interaktívnu aktivitu),
- prefix *I* reprezentuje dimenzie viazané na prvú expozíciu v experimentálnej časti,
- prefix *G* reprezentuje druhú vlnu merania po VR hre.



Obr. 2b Krabicové grafy so všetkými pozorovanými charakteristikami z pohľadu jednotlivých skupín (Ján Skalka & Valko, 2025a).

Špecificky boli položky *spInter0* (záujem o 360° video) a *spInter1* (záujem o interaktívny úvod) spracované oddelene, aby bolo možné zachytiť rozdiely medzi pasívnou a aktívnou modalitou.

Najprv prebehla vizuálna kontrola rozdelení a trendov (boxploty podľa skupín), ktorá slúžila na identifikáciu vzorcov a odľahlých hodnôt. Následne sa pre každú dimenziu testovali predpoklady normality a homogenity variácií, na základe ktorých sa použil buď ANOVA, alebo neparametrický Kruskal–Wallis test. Pri významných rozdieloch sa realizovali post-hoc porovnania párov skupín pomocou Dunnovho testu s Bonferroniho korekciou.

Výsledky

Vizuálna analýza naznačila, že skóre je vyššie u nováčikov naprieč viacerými dimenziami, no nie vždy v rozsahu, ktorý vedie k štatistickej významnosti. Najvýraznejší trend sa ukázal pri *spInter0* (záujem o 360° video), kde medián klesal so zvyšujúcou sa skúsenosťou. Pri *spInter1* (záujem o interaktívny úvod) boli mediány naprieč skupinami stabilnejšie.

Testovanie rozdielov medzi tromi skupinami potvrdilo významné efekty predchádzajúcej skúsenosti najmä v skorých, novotou citlivých dimenziách. Štatisticky významné rozdiely sa objavili pre:

- *splInter0* (záujem o 360° video; $p = 0.0038$, Kruskal–Wallis),
- *lInter* (záujem v úvodnej časti; $p = 0.0177$),
- *lEmo* (emočné zapojenie; $p = 0.0415$).

Dimenzia *GInter* bola na hranici významnosti ($p = 0.0518$), zatiaľ čo pri dimenziách viazaných na hranie (G...), ako aj pri *usability*, *focus of attention*, *presence* a *flow* sa významné rozdiely vo všeobecnosti nepotvrdili. To podporuje interpretáciu, že skúsenosť ovplyvňuje najmä ranné hodnotenia a vzrušenie z prvej expozície, kým neskoršie a stabilnejšie aspekty zážitku sú naprieč skupinami podobnejšie.

Post-hoc analýza (Tab. 1) ukázala, že kľúčové rozdiely sa sústreďujú medzi extrémnymi skupinami:

- *splInter0*: nováčikovia hodnotili 360° video významne vyššie než skúsení ($p = 0.0031$).
- *lInter*: nováčikovia hodnotili úvodnú časť ako angažujúcejšiu než skúsení ($p = 0.0138$).
- *lEmo*: rozdiel medzi nováčikmi a skúsenými naznačil trend ($p = 0.0512$), hoci nedosiahol konvenčnú významnosť.

Tab. 1 Výsledky post-hoc analýzy: Dunnove testy s Bonferroniho korekciou (Ján Skalka & Valko, 2025a).

		Beginner	Intermediate	Expert
splInter0	Beginner	1	0.5344	0.0031 **
	Intermediate		1	0.3480
	Expert			1
lInter	Beginner	1	1	0.0138 *
	Intermediate		1	0.3226
	Expert			1
lEmo	Beginner	1	0.5137	0.0512
	Intermediate		1	1
	Expert			1

Doplnková analýza testovala, či postačí dvojskupinové delenie (začiatočníci $\leq$ prah vs. skúsení $>$ prah) pri prahoch 1–12 hodín. Výsledky (Tab. 2) ukázali, že:

- *splInter0* zostáva významné prakticky naprieč prahmi, pričom od prahu 10 hodín sa objavuje veľmi silná diskriminácia ($p < 0.001$),
- *lInter* a *lEmo* vykazujú robustnú citlivosť najmä v rozsahu prahov 1–10 hodín,
- viaceré dimenzie (napr. *focus of attention*, *flow*, *usability*, *presence*) nevykazujú stabilné rozdiely naprieč prahmi, čo naznačuje nižšiu závislosť od predchádzajúcej expozície.

Tab. 1 Súhrn výsledkov testov na rozdelenie skupín používateľov na začiatočníkov a pokročilých používateľov s použitím prahových hodnôt. Farby buniek označujú úroveň štatistickej významnosti: biela = nevýznamná ($p \geq 0,05$), svetlomodrá = $p < 0,05$ (*), modrá = $p < 0,01$ (), červená = $p < 0,001$ (***) (Ján Skalka & Valko, 2025a).**

Dim.	1	2	3	4	5	6	7	8	9	10	11	12
splInter0	0.0033	0.0078	0.0176	0.0203	0.0097	0.0097	0.0097	0.0023	0.0023	0.0001	0.0001	0.0001
splInter1	0.0506	0.0084	0.0239	0.0291	0.0885	0.0885	0.0885	0.0527	0.0527	0.3459	0.3459	0.3459
lAtten	0.1184	0.3819	0.4036	0.4287	0.4693	0.4693	0.4693	0.5604	0.5604	0.3778	0.3778	0.3778
lEmo	0.0171	0.122	0.1428	0.0852	0.0283	0.0283	0.0283	0.0333	0.0333	0.0203	0.0203	0.0203
lFlow	0.0836	0.3484	0.3976	0.3821	0.4455	0.4455	0.4455	0.4017	0.4017	0.2625	0.2625	0.2625
lInter	0.0193	0.0079	0.0022	0.0040	0.0078	0.0078	0.0078	0.0067	0.0067	0.0106	0.0106	0.0106
lPres	0.1771	0.2072	0.1992	0.2588	0.2839	0.2839	0.2839	0.1846	0.1846	0.068	0.068	0.068
lUsab	0.0839	0.2383	0.2216	0.3158	0.4502	0.4502	0.4502	0.2434	0.2434	0.7325	0.7325	0.7325
GAtten	0.4213	0.6199	0.8859	0.9792	0.9528	0.9528	0.9528	0.8293	0.8293	0.8446	0.8446	0.8446
GEmo	0.0639	0.0607	0.1572	0.2674	0.2633	0.2633	0.2633	0.2306	0.2306	0.2951	0.2951	0.2951

Dim.	1	2	3	4	5	6	7	8	9	10	11	12
GFlow	0.0862	0.1818	0.4667	0.5792	0.5772	0.5772	0.5772	0.543	0.543	0.5809	0.5809	0.5809
GInter	0.0174	0.0247	0.0156	0.0212	0.0464	0.0464	0.0464	0.0614	0.0614	0.0789	0.0789	0.0789
GPres	0.1646	0.1532	0.1599	0.2435	0.3551	0.3551	0.3551	0.3275	0.3275	0.0925	0.0925	0.0925
GUsab	0.5531	0.4616	0.4316	0.6297	0.5744	0.5744	0.5744	0.5251	0.5251	0.3037	0.3037	0.3037

Diskusia

Na úrovni analyzovaných dát sa vplyv predchádzajúcej skúsenosti s VR prejavuje najmä v skorých dimenziách zapojenia – predovšetkým v záujme o pasívny 360° obsah (*spInter0*) a v záujme o úvodné interaktívne úlohy (*Inter*); pri emočnom zapojení (*Emo*) sa pozoruje skôr trend než jednoznačný efekt. Výsledky zároveň ukazujú, že rozdiely medzi skupinami sú najkonzistentnejšie v pasívnom scenári, kde nováčikovia hodnotia 360° video vyššie než skúsení používatelia (*spInter0* predstavuje významný rozdiel najmä medzi nováčikmi a skúsenými).

Pri prahovej analýze dvojskupinového delenia sa ukazuje, že pre niektoré skoré dimenzie je možné zachytiť rozdiely už pri nižších prahoch, avšak najrobustnejšie odlišenie (najmä pre *spInter0*) sa objavuje pri vyšších prahoch, pričom od prahu približne 10 hodín je diskriminácia medzi skupinami v tejto dimenzii veľmi silná ($p < 0.001$). V tomto zmysle možno hranicu okolo 10 hodín expozície považovať za prakticky použiteľný referenčný bod pre odlišenie nováčikovského režimu, najmä ak je cieľom minimalizovať skreslenie skorých hodnotení efektom novosti. Zároveň platí, že viaceré dimenzie späté s pokročilejšími aspektmi imerzie (napr. *focus of attention*, *presence*, *flow*) a väčšina herných dimenzií nevykazovali stabilné rozdiely naprieč skupinami, čo naznačuje, že ich citlivosť na skúsenosť je v tomto dizajne slabšia alebo závislá od typu úlohy a intenzity scenára.

Metodické dôsledky predchádzajúcej skúsenosti

Predošlá kapitola ukázala, že rozdiely medzi skúsenostnými kohortami sa koncentrujú najmä do skorých dimenzií zapojenia a záujmu, pričom pasívny obsah (360° video) je na efekt novosti obzvlášť citlivý. Táto kapitola nadväzuje na zistenia rozšírením perspektívy: skúsenosť s VR neberie len ako deskriptívnu charakteristiku vzorky, ale ako metodicky relevantný faktor, ktorý môže meniť interpretáciu výsledkov akceptácie a tým aj externú validitu VR výskumu. Cieľom je overiť, do akej miery sa vplyv predchádzajúcej skúsenosti prejavuje naprieč dimenziami akceptácie.

Metodika a dizajn štúdie

Štúdia prebiehala počas šiestich mesiacov v letnom semestri 2022/23 v dvoch nezávislých prostrediach: komunitné workshopy pre IT komunitu a výučbový proces študentov aplikovanej informatiky. Experiment bol realizovaný v režime bez tlaku na čas, pričom respondenti pracovali v skupinách približne 3–10 osôb, aby bola dostupná okamžitá asistencia pri technických a ovládacích problémoch.

Ako výskumné zariadenie bol použitý headset *Oculus (Meta) Quest 2*. Respondenti boli postupne vystavení viacerým aplikáciám pokrývajúcim rôzne aspekty VR a rastúcu náročnosť interakcie. Scenár bol navrhnutý tak, aby prvou expozíciou podporil adaptáciu používateľa na imerzívne prostredie (pasívny obsah), následne pre nováčikov prezentoval základné ovládanie (tutoriál) a až potom prešiel k aplikáciám vyžadujúcim interakciu na úrovni tvorby a hry. V druhej časti boli zahrnuté aj náročnejšie úlohy (vrátane FPS prostredia), pričom v prípade potreby sa časová dotácia aktivít flexibilne upravovala tak, aby každý respondent stihol dokončiť predpísané kroky.

Do štúdie bolo zapojených 57 participantov (vek 19–68 rokov; všetci s pokročilými znalosťami IT). Experiment predčasne ukončilo 9 osôb (únava, nevoľnosť, diskomfort pri použití headsetu), pričom kompletne dáta poskytlo 48 respondentov (37 mužov, 11 žien; vek 19–47 rokov).

Predchádzajúca skúsenosť s VR bola zisťovaná ako sebahodnotený kumulatívny čas expozície (v hodinách). Na základe tejto premennej boli respondenti podobne ako v predošlej štúdii rozdelení do troch kohort:


- nováčikovia (bez skúsenosti s VR): 22 respondentov (46 %),
- stredne skúsení (max. 9 hodín): 13 respondentov (27 %),
- skúsení (> 10 hodín): 13 respondentov (27 %).

Rozdelenie na tri skupiny bolo zvolené zámerne, aby sa neprekrývali prechodové vzorce zvykania si so stabilnejšou skúsenosťou a aby bolo možné zachytiť aj špecifickú dynamiku strednej kohorty.

Pred samotnými aktivitami respondenti vyplnili vstupný dotazník so základnými demografickými údajmi, vzťahom k hrám a odhadom času stráveného vo VR. Po každej VR interakcii nasledovali post-dotazníky merajúce šesť dimenzií používateľskej skúsenosti: *interest*, *usability*, *emotional attachment*, *focus of attention*, *presence*, *flow* (Georgiou & Kyza, 2017) na zachytenie vývoja hodnotení naprieč rôznymi typmi VR obsahu a rastúcou náročnosťou interakcie.

Keďže skúsenosť s PC alebo konzolovými hrami môže ovplyvňovať výkon v 3D prostrediach, súčasťou vstupu bola aj miera hrania (hodiny/týždeň). V súlade s argumentom, že výkon v 3D hrách nemusí priamo zodpovedať výkonu vo VR (Pallavicini & Pepe, 2019), nebola herná prax použitá ako kritérium tvorby skupín; slúžila ako kontrolná charakteristika vzorky.

Následne prebehla expozícia VR prostredníctvom štyroch aplikácií. Podobne ako v predošlom experimente to bolo 360° video, úvodný tutoriál a akčná hra, no v tomto prípade bol zoznam obohatený o aplikáciu zameranú na tvorbu 3D modelov a FPS akčnú hru z pohľadu prvej osoby s ovládaním pripomínajúcim reálne používanie zbraní.



Obr. 3 Priemerné skóre respondentov v rámci skupín v štyroch experimentálnych segmentoch.

Po každej zo 4 expozícií vyplňali respondenti rovnaký dotazník pozostávajúci z otázok Likertovej škály. Dosiahnuté priemerné skóre jednotlivých skupín je vizualizované na Obr. 3.

Výsledky naznačujú, že rozdiely medzi skupinami sa nekoncentrujú rovnomerne do všetkých dimenzií hodnotenia. Naprieč meranými aspektmi sa väčšinou pozorovala len malá variabilita, no dve dimenzie

vystúpili ako kľúčové: *interest* a *usability*. Pri záujme sa ukázalo, že u nováčikov môže nadšenie klesať už po úvodných aktivitách (v dátach je viditeľný pokles po druhej aplikácii), kým u mierne pokročilých a skúsených sa pri komplexnejších úlohách skôr prejavuje stabilizácia alebo rast záujmu; zároveň sa ukazuje, že hodnotenie môže byť citlivé aj na obsah (napr. časť nováčikov odmietla FPS časť). Pri použiteľnosti sa významné rozdiely typicky objavujú najmä medzi skúsenými a oboma menej skúsenými skupinami a pri vyššej náročnosti ovládania sa tieto rozdiely ešte zvyrazňujú. Naopak, dimenzie ako emočná väzba, fokus pozornosti, prítomnosť a flow sa medzi skupinami systematicky nelíšili, čo podporuje záver, že nie všetky aspekty prežívania vo VR sú rovnako citlivé na mieru predchádzajúcej skúsenosti.

Vyhodnotenie skúsenostných skupín (nováčikovia $n = 22$, mierne pokročilí $n = 13$, skúsení $n = 13$; spolu $n = 48$) sa opieralo o testovanie predpokladov normality (Shapiro–Wilk) a následnú voľbu neparametrických porovnávacích testov. Pri dimenzii záujem sa pre prvý pasívny podnet (*0Int* – 360° video) potvrdili rozdiely medzi skupinami (Kruskal–Wallis $H(2,48) = 8.029$, $p = 0.018$), pričom post-hoc porovnanie ukázalo významný rozdiel najmä medzi nováčikmi a skúsenými ($p = 0.020$; priemerné poradie 28.523 vs. 15.192), kým rozdiel medzi mierne pokročilými a skúsenými bol len trendový ($p = 0.095$).

Podobný obraz priniesla aj úvodná interaktívna aplikácia (*1Int*), kde sa opäť preukázal rozdiel medzi skupinami ($H(2,48) = 7.635$, $p = 0.022$) a post-hoc potvrdil kontrast nováčikovia vs. skúsení ($p = 0.037$; priemerné poradie 27.636 vs. 15.385), pričom mierne pokročilí vs. skúsení vyšli na hranici významnosti ($p = 0.056$).

Pri dimenzii použiteľnosť sa rozdiely koncentrovali na skupinu skúsených: významné rozdiely sa objavili pre *1Usab* ($H = 6.594$, $p = 0.037$), *2Usab* ($H = 12.439$, $p = 0.002$) a *4Usab* ($H = 9.731$, $p = 0.0077$), pričom post-hoc ukázal rozdiely najmä medzi nováčikmi a skúsenými ($p = 0.041 / 0.006 / 0.008$) a pri druhej aplikácii aj medzi mierne pokročilými a skúsenými ($p = .007$); naopak, *3Usab* významná nebola ($H = 2.490$, $p = 0.2879$).

V ostatných dimenziách (*emotional attachment*, *focus of attention*, *presence*, *flow*) sa medzi skupinami štatisticky významné rozdiely nepreukázali (vo všetkých prípadoch $p > 0.05$).

Diskusia

Ak je cieľom porovnávať VR aplikácie, alebo z nich neskôr skladať multi-view profily používateľov, treba dokázať identifikovať, či hodnotenia neodrážajú skôr novosť a adaptáciu na ovládanie než vlastnosti obsahu. Preto sa skúsenosť nebrala ako binárna hodnota reprezentujúca skúsenosť s VR, ale ako kumulatívny čas expozície a rozdelila sa na tri kohorty (0 h, 1–9 h, ≥ 10 h). Už toto nastavenie je dôležitý metodický krok: v multi-view modelovaní totiž podobné kontextové faktory často vytvoria falošné rozdiely medzi skupinami, ktoré potom vyzerajú ako typy používateľov, hoci sú len dôsledkom rozdielnej familiarizácie s technológiou.

Výsledok je selektívny, ale jasný. Skúsenosť s VR vplyva najmä na tie dimenzie akceptácie, ktoré sú citlivé na novosť a ovládanie. Konkrétne:

- Pri záujme (Interest) sa medzi tromi skupinami objavili štatisticky významné rozdiely v prvých aktivitách. Pri *0Int* (úvodný pasívny podnet) vyšiel Kruskal–Wallis $H = 8.029$, $p = 0.018$ a post-hoc rozdiel najmä medzi nováčikmi a skúsenými ($p = 0.020$). Podobne pri *1Int* (prvá interaktívna aplikácia) $H = 7.635$, $p = 0.022$, opäť s rozdielom nováčikovia vs. skúsení ($p = 0.037$) a s hraničným trendom medzi mierne pokročilými vs. skúsenými ($p = 0.056$). Prakticky to znamená, že záujem v úvode experimentu nie je neutrálna veličina: je to miesto, kde sa najviac mieša efekt novosti so skutočnou kvalitou či akceptáciou aktivity.

- Pri použiteľnosti (*Usability*) sú rozdiely ešte priamočiarejšie a viažu sa na kontrast skúsení vs. ostatní. Medzi skupinami boli významné rozdiely v *1Usab*, *2Usab* a *4Usab*. Post-hoc porovnania ukazujú, že najvýraznejšie sú rozdiely nováčikovia vs. skúsení ($p = 0.041, 0.006, 0.008$) a pri druhej aplikácii aj mierne pokročilí vs. skúsení ($p = 0.007$). Tretia aplikácia (*3Usab*) významná nebola ($H = 2.490, p = 0.2879$), čo je dôležitá stopa: skúsenosť nefunguje ako globálny posun všetkých hodnotení, ale ako faktor, ktorý sa prejaví najmä tam, kde sa láme použiteľnosť rozhrania a nároky na ovládanie.

Dimenzie viazané na zapojenie a ponorenie (emočná väzba, pozornosť, prítomnosť, flow) sa medzi skupinami systematicky nelíšili. To je metodicky dobrá správa: nie všetky merané charactersitiky sú kontaminované skúsenosťou. Zároveň je to varovanie: ak sa v niektorej štúdií nájde rozdiel v prítomnosti/flow, môže byť viac viazaný na dizajn aktivity než na samotnú skúsenosť.

Dáta v tejto kapitole naznačujú dva súčasne platné mechanizmy. Prvý je prahový: najstabilnejší kontrast sa objavuje medzi 0 h a ≥ 10 h – teda približne v mieste, kde sa používateľ už nespolieha na wow-efekt a viac hodnotí aplikáciu cez optiku kontroly, čitateľnosti a nárokov na ovládanie. Druhý je sekvenčný v rámci experimentu: u nováčikov sa záujem výrazne prepadá už od druhej aplikácie, zatiaľ čo mierne pokročilí a skúsení majú skôr rastúci alebo stabilnejší trend (s výnimkami pri prudkej zmene ovládania). To je presne obraz „novosti“, ktorá krátkodobo zvýši hodnotenia, no bez opory v použiteľnosti rýchlo vyprchá.

Z týchto výsledkov plynie priama odpoveď na SUB1: **skúsenosť meraná expozíciou mení najmä záujem a použiteľnosť a efekt novosti sa ako dominantný zdroj variability prejavuje najmä u nováčikov v úvodných krokoch; okolo hranice 10 hodín už hodnotenia nesú podstatne menej „novosti“ a viac hodnotenia aplikácie ako takej.**

Prínos pre oblasť habilitácie

Táto kapitola ukazuje, že predchádzajúca skúsenosť s VR je jeden z tichých faktorov, ktorý môže v multi-view nastavení systematicky skresľovať závery, ak sa sleduje iba okrajovo v popise vzorky. Preto sa skúsenosť neberie ako binárna informácia, ale ako kumulatívny čas expozície, čo umožňuje jemnejšie rozlíšenie kohort a priamu kontrolu tohto faktora v analýzach. Zároveň sa ukazuje, že vplyv skúsenosti sa nekoncentruje do všetkých dimenzií rovnako: najcitlivejšie sú hodnotenia viazané na novosť a ovládanie (záujem, použiteľnosť), zatiaľ čo imerzívne dimenzie majú skôr stabilnejší profil alebo väčšiu závislosť od konkrétneho dizajnu aktivity. Prakticky to znamená, že v multi-view profilovaní treba skúsenosť chápať ako kontextovú premennú, ktorá môže meniť interpretáciu dotazníkových výstupov aj správania (napr. nováčikovské stratégie ovládania) a následne aj výsledok integrácie pohľadov. Ak sa v dotazníkovom pohľade záujem a použiteľnosť líšia podľa skúsenosti, potom dotazníkové skóre nie je priamo porovnateľné medzi kohortami. V multi-view profile to môže vytvoriť falošné typy postavené na adaptácii na technológiu, nie na stabilných preferenciách či štýle používania.

Metodicky je kľúčový aj prahový pohľad: približne okolo 10 hodín expozície sa prejavuje oslabenie efektu novosti, čo dáva použiteľnú oporu pre dizajn ďalších štúdií (stratifikácia, kontrolná premenná/kovariát, reportovanie prahov). V rámci habilitačnej línie to priamo podporuje stability-first filozofiu: ešte pred integráciou pohľadov treba zabezpečiť, aby sa porovnávali porovnateľné kohorty a aby sa známe zdroje variability (ako skúsenosť) buď vyrovnali, alebo explicitne modelovali.

Z aplikačného hľadiska kapitola uzatvára praktické rozhodnutie pre ďalší výskum: ak cieľom je testovať jemné efekty dizajnu a modelovať stabilné vzťahy naprieč pohľadmi, je výhodné preferovať skúsených používateľov (alebo aspoň vyvážené strata), lebo u nováčikov môže dominovať adaptácia na ovládanie a novosť. Keďže skúsených VR používateľov je v praxi stále relatívne málo, ďalšie experimenty sa budú v tejto práci primárne opierať aj o iné domény (napr. klasické hry a mikroučenie), kde je možné

robustnejšie budovať a validovať multi-view metodiku; VR ostáva dôležitým referenčným kontextom, no s dôrazom na kontrolu skúsenosti už v dizajne.

Typologické ukotvenie a (ne)zameniteľnosť modelov

Virtuálne prostredia v 21. storočí rýchlo expandovali a stali sa bežným priestorom pre sociálnu interakciu, spoluprácu, učenie aj zábavu (Hwang & Chien, 2022), (Allam et al., 2022). Súčasne sa výrazne zvýšila ich komplexita a dosah – od hier až po metaverzá (Hadi Mogavi et al., 2023), (Njoku et al., 2023). Tieto prostredia prirodzene priťahujú používateľov rôzneho veku, kultúr, záujmov a úrovni skúsenosti. Heterogenita v kombinácii so špecifikami prostredí, ktoré sú precízne kalibrované na poskytovanie čo najimmerzívnejšieho zážitku však ľahko sklzáne k situácii, ktorá môže časť publika odradiť. Praktické bariéry, ako technická nekompatibilita, obmedzenia rozhraní či rozdielne používateľské zručnosti, môžu zároveň skresľovať hodnotenia použiteľnosti a maskovať skutočné dizajnové problémy (Sanchez-Gordon et al., 2021), (Bojic, 2022), (Sally Wu & Alan Hung, 2022).

Aj preto sa výskum v game-dizajne a HCI čoraz viac sústreďuje na to, ako osobné atribúty – demografia, osobnostné črty či cieľová orientácia – formujú používateľský zážitok. Naprieč štúdiami sa opakovane objavujú štandardné motivačné dimenzie ako socializácia, eskapizmus, dosahovanie výkonu, vyhľadávanie odmien či potreba nezávislosti (Kirchner-Krath et al., 2024), (Klock et al., 2020), (Mosadeghi et al., 2016), (Toda et al., 2022). Cieľom je lepšie porozumieť, predikovať a merať mieru zapojenia tak, aby sa zážitky dali prispôbiť individuálnym potrebám. Personalizovaný dizajn opretý o princípy HCI tak prekračuje prístup rovnakého riešenia pre všetkých a využíva poznatky o ľudskom správaní, kognícii a psychológii na zlepšenie zapojenia a výsledkov (Klock et al., 2020), (González-González et al., 2022).

V digitálnych platformách je miera zapojenia navyše kľúčovou metrikou úspechu pre retenciu a dlhodobú udržateľnosť (Nwaimo et al., 2024), (Engert et al., 2023). Keďže imerzívna povaha virtuálnych prostredí zosilňuje nielen pozitívne, ale aj negatívne skúsenosti, riziká (napr. šikana, manipulatívne personalizované podnety, emocionálna ujma pri zlom dizajne) posúva sa inkluzívny dizajn z komerčnej výhody na etickú nevyhnutnosť (Pushpakumar et al., 2023), (Lomba Perez et al., 2025), (Rózsa et al., 2022).

V tejto kapitole sa profilovanie používateľov a tvorba person chápu ako jeden z praktických nástrojov, ako heterogenitu uchopiť interpretovateľne a replikovateľne naprieč rôznymi dátovými pohľadmi. V prostredí hier a gamifikovaných systémov sa profilovanie často opiera o top-down typológie, ktoré zoskupujú používateľov podľa motivačných a interakčných vzorcov a slúžia ako rámec pre dizajnové rozhodnutia. Medzi najpoužívanejšie kategórie patria:

- Bartleho štyri typy (Bartle, 1996), Lazzarove *Four Keys to Fun* (Lazzaro, 2004),
- rámce pre gamifikáciu (napr. HEXAD (Tondello et al., 2016)),
- neuro-afektívne alebo žánrovo orientované modely (napr. *BrainHex* (Nacke et al., 2014)),
- veľkorozmerné empiricky odvodené modely motivácie (napr. Yee (Yee, 2006b), *Quantic Foundry Model* (Yee, 2016)).

Hoci tieto rámce cielia na prekrývajúce sa aspekty angažovanosti, líšia sa rozsahom, granularitou aj meracími predpokladmi, čo komplikuje syntézu naprieč štúdiami a systémami.

V praxi sa typológie často používajú ako zameniteľné označenia alebo ako jednoduchý výber jedného nástroja, no bez kvantitatívneho mapovania nie je jasné, či zachytávajú rovnaké latentné konštrukty alebo skôr komplementárnu informáciu. Ak sa jeden nástroj nahradí druhým bez overenia ekvivalencie, môže to viesť k špecifikačnej chybe v personalizačných rozhodnutiach, zvýšeniu

respondentovej záťaže (ak sa nástroje zdvojujú „pre istotu“) a k slabej porovnateľnosti výsledkov medzi štúdiami.

Preto sa v tejto kapitole sústreďujeme na dva etablované a široko používané zástupné rámce – gameplay-orientovanú typológiu (Bartle) a gamifikáciu orientovanú typológiu (HEXAD) – a skúmame ich spoločný základ aj rozdiely, čo vedie k výskumnej otázke:

- ***SUB2: Do akej miery sú top-down typológie používateľov (Bartle, HEXAD) konštruktovo ekvivalentné a prakticky nahraditeľné – t. j. aký majú spoločný latentný základ a aké sú limity ich vzájomnej predikcie pri použití jedného nástroja namiesto druhého?***

Prehľad relevantných zdrojov

Rámce profilovania hráčov prevádzajú motivačné teórie do prakticky použiteľných dizajnových prvkov a postupov. Zoskupovaním používateľov podľa relatívne stabilných orientácií sa umožňuje cielene voliť mechaniky, spätnú väzbu a štruktúry progresu, čím sa zvyšuje zapojenie a zlepšuje prispôsobenie zážitku heterogénnym publikám (Kirchner-Krath et al., 2024). Historicky medzi najvplyvnejšie klasifikácie patrí Bartleho taxonómia typov hráčov, pôvodne vybudovaná na pozorovaní správania v multi-user dungeonoch (MUDs), ktorá rozlišuje štyri základné kategórie (Bartle, 1996):

- **Achievers** (orientovaní na dosiahnutie výsledku) sú motivovaní najmä nadobúdaním kompetencií a merateľným progresom. Sleduje sa pri nich plnenie cieľov, body a rozvoj postavy, optimalizuje sa výkon a často sa súťaží aj s vlastným predošlým výkonom.
- **Explorers** (orientovaní na zvedavosť) sa zapájajú najmä interakciou so svetom a jeho systémami. Vyhľadávajú nové miesta, experimentujú s mechanikami, objavujú skryté prvky a uprednostňujú porozumenie prostrediu.
- **Socializers** (orientovaní na vzťahy) čerpajú motiváciu z interakcie s inými. Cenia si komunikáciu, spoluprácu a budovanie komunity, pričom veľa investujú do vzťahov vo virtuálnom priestore.
- **Killers** (orientovaní na dominanciu) sú motivovaní dosahovaním vplyvu nad inými hráčmi. Atraktívne je pre nich porážanie (alebo aj provokovanie) súperov, presadzovanie nadvlády a niekedy aj narušanie ako forma kompetitívneho prejavu.

V praxi sa Bartleho typológia používa ako dizajnový kompas pri tvorbe a prevádzke komerčných hier: pomáha vyvažovať populáciu hráčov, uvažovať o koexistencii rôznych štýlov hry a priradovať mechaniky (ciele, odmeny, sociálne nástroje, kompetitívne prvky) k očakávaným motiváciám jednotlivých typov. Pôvodný text zdôrazňuje účel vyvažovania populácie v MUDs, čo sa dnes premieta do rozhodnutí live-ops, community manažmentu a dizajnu sociálnych funkcií (Hamari & Tuunanen, 2014). Typológia zároveň funguje ako spoločný slovník pre UX výskum a segmentáciu, ako to popisujú syntézy hráčskych typológií. V edukačnom dizajne sa často prepája s princípmi motivácie a dizajnovými pákami (štruktúra cieľov, spätná väzba, progres) (Kapp, 2019). Treba však priznať, že model vznikol v špecifickom kontexte MUDs a jeho prenos do iných žánrov si vyžaduje opatrnosť (Dixon, 2011).

Mimo zábavného priemyslu sa Bartleho taxonómia využíva pri personalizácii gamifikovaných systémov, najmä vo vzdelávaní: študenti sa zoskupujú podľa dominantných preferencií a následne sa akcentujú prvky ako spolupráca, súťaž alebo objavovanie. Viaceré práce klasifikovali študentov podľa Bartleho typu a skúmali vzťah k výsledkom učenia a k zapojeniu (Aldemir et al., 2018), (S. Kim & Ko, 2013). Novšie adaptívne gamifikačné rámce, ktoré dynamicky upravujú prvky na základe priebežných behaviorálnych dát, posúvajú použitie typológií od statickej segmentácie k adaptívnym intervenciám (Guimarães et al., 2025). Súčasne sa objavuje kritická línia: meta-analýzy a validačné štúdie poukazujú na obmedzenú prenositeľnosť, potrebu psychometrickej validácie (stabilita faktorov, prediktívna validita) a na to, že preferencie sa menia v čase a kontexte, čo zdôrazňuje potrebu opatrnosti pri

priamom mapovaní typológií na intervenčné rozhodnutia (Nacke et al., 2014), (Busch, Mattheiss, Orji, et al., 2016), (Kirchner-Krath et al., 2024).

HEXAD (Marczewski, 2015) sa etabloval ako praktický rámec pre personalizáciu gamifikovaných systémov aj mimo striktne herného kontextu (Lopez & Tucker, 2019), (Tondello et al., 2016), (Sipone et al., 2025). Šesť typov explicitne nadväzuje na Self-Determination Theory (autonómia, kompetencia, vzťahovosť; doplnené o extrinsické odmeny a motívy zmeny) a poskytuje tvorcom mapu medzi používateľskými profilmi a dizajnovými prvkami (spolupráca, sociálne väzby, explorácia, progres, odmeny, remix mechaník) (Tyack & Mekler, 2020):

- **Philanthropists** (orientovaní na zmysel a prosociálnosť) sú motivovaní prínosom pre iných a pocitom užitočnosti; preferujú mechaniky uľahčujúce pomoc (mentoring, zdieľanie znalostí, darovanie zdrojov) a podporujúce spoluprácu a komunitnú starostlivosť.
- **Socialisers** (orientovaní na vzťahy) sú vedení sociálnou interakciou, spoluprácou a pocitom spolupatričnosti; vyhľadávajú nástroje na komunikáciu, skupinové úlohy, guildy a reputačné systémy, ktoré posilňujú väzby a koordináciu.
- **Free Spirits** (orientovaní na autonómiu a sebarealizáciu) priťahuje sloboda konania, explorácia a kreativita; reagujú na otvorené zadania, bohaté možnosti prispôsobenia, sandbox nástroje a alternatívne cesty k cieľom bez striktných obmedzení.
- **Achievers** (orientovaní na kompetenciu a progres) smerujú k zvládnutiu systému, jasným cieľom a merateľnému postupu; preferujú stupňované výzvy, výkonovú spätnú väzbu, vylepšovanie postavy a rozvojové stromové štruktúry.
- **Players** (orientovaní na odmeny a stimuly) reagujú primárne na externé odmeny a maximalizáciu zisku; motivujú ich bodové systémy, odznaky a časované odmeny – ideálne viazané na ciele, aby sa predišlo čisto kolektívnemu správaniu bez učenia.
- **Disruptors** (orientovaní na zmenu systému) sú motivovaní možnosťou ovplyvňovať pravidlá, testovať hranice a iniciovať inovácie; konštruktívne ich aktivujú mechaniky ako hlasovanie, návrhy, modding a experimentálne módy, no bez smerovania môže dochádzať aj k tendencii k rušivému správaniu.

Kľúčovým prínosom tejto typológie je štandardizovaná 30-položková škála (HEXAD-30) s preukázanou reliabilitou a štrukturálnou validitou, ktorá sa bežne používa vo výskume aj praxi pri výbere gamifikačných prvkov (Tondello et al., 2016). V aplikáciách sa objavuje vo vzdelávaní a práci, vo fitnes a zdraví, v citizen science aj v UX evaluácii. Empirické štúdie ukazujú vzťahy medzi HEXAD profilmi a výkonom alebo preferenciami prvkov a podporujú použiteľnosť rámca pre ciele intervencie (napr. triedenie prvkov podľa profilu, adaptívne rozhrania) (Lopez & Tucker, 2019), (Sienel et al., 2021).

Psychometrické a kontextové spresňovanie pokračuje prostredníctvom validačných prác na rôznych vzorkách a jazykoch, vrátane kratšej formy HEXAD-12 (Krath et al., 2023), pričom sa však zdôrazňuje potreba testovať stabilitu/invarianciu štruktúry naprieč populáciami a citlivo pristupovať najmä k typom *Player* a *Disruptor*. Pre robustnú personalizáciu sa odporúča kombinovať sebaopisné profily s behaviorálnou telemetriou a overovať účinnosť prvkov v samostatnom hodnotení, čím sa používanie HEXAD posúva od statickej segmentácie k adaptívnej, priebežne aktualizovanej gamifikácii (Fong et al., 2024).

Metodika výskumu

Cieľom analýzy je empiricky posúdiť, či medzi vybranými typológiami existujú systematické vzťahy, kde sa prekrývajú (t. j. ktoré dimenzie zachytávajú podobný latentný obsah) a kde sa rozchádzajú (t. j. ktoré črty nie je možné uspokojivo aproximovať druhým nástrojom). Výsledky sa interpretujú ako mapovanie

Na vzorke $N = 84$ dospelých respondentov (18–40 rokov) sa realizoval prierezný dotazníkový zber. Respondenti vyplnili dva profilovacie nástroje: HEXAD-30 (šesť subškál; (Tondello et al., 2016)) a štandardizovaný Bartle dotazník, skórovaný prostredníctvom 4 ipsatívnych proporcií v štyroch dimenziách. Analytická stratégia bola zámerne parsimoniózna a sústredila sa na vzťah medzi dvoma typológiami.

Fáza 1: Odvodenie latentnej štruktúry HEXAD. Najprv sa zhodnotí vhodnosť položiek HEXAD pre faktorovú analýzu (KMO a Bartlettov test). Následne sa odhadnú exploračné faktorové modely metódou minimum-residual s oblique rotáciou (Promax), aby sa umožnila korelácia dimenzií.

Retencia faktorov sa riadi paralelnou analýzou a kvalitatívnymi kritériami (ukotvenie faktora min. 3–4 indikátormi, primárne loadings $\geq 0,40$, krížové loadings $\geq 0,30$ ako varovanie, komunalita približne $h^2 \geq 0,30$). Keďže HEXAD konceptualizuje šesť typov, posúdi sa aj 6-faktorové riešenie pričom reliabilita faktorov sa dokumentuje pomocou Cronbachovho α a McDonaldovho ω . Pre následné mapovanie sa použije regresné faktorové skóre.

Fáza 2: Príprava Bartle skóre a ipsativita. Bartle skóre je vyjadrené prostredníctvom kompozičných / ipsatívnych proporcií ($A + S + E + K = 1$), z čoho vyplývajú dva metodické dôsledky:

- **Lineárna závislosť medzi zložkami** (kolinearita) – štyri proporcie nemôžu byť nezávislé.
- **Relatívna interpretácia** – nárast jednej dimenzie nutne znamená pokles aspoň jednej ďalšej, čo môže vytvárať zdanlivé negatívne vzťahy.

Aby sa odstránila lineárna závislosť, v hlavných modeloch sa použije **drop-one kódovanie**: jedna dimenzia sa vynechá a modelujú sa zvyšné tri (vynechaná je rekonštruovateľná zo súčtu). Výber vynechanej dimenzie sa posúdi cez absolútne interkorelačné väzby. Zároveň sa kompozičný charakter Bartle skóre ošetrí aj na úrovni asociácií: popri Spearmanových koreláciách na proporciách sa reportujú aj Pearsonove korelácie po CLR transformácii, ktorá prevádza proporcie na logaritmické pomery a znižuje vplyv konštantného súčtu.

Analytické kroky mapovania pozostávajú z nasledovných častí:

- Identifikácia deskriptívneho prekrývania – najprv sa vyhodnotia bivariátne asociácie medzi faktorovými skóre HEXAD a Bartle dimenziami (A, S, E; po drop-one) s korekciou Benjamini–Hochberg ($FDR, q = 0,05$). Tento krok slúži ako rýchly screening na poskytnutie vstupov do ďalšieho modelovania.
- Simultánne OLS modely a semi-partial ΔR^2 slúžia na odhad OLS regresie, vždy samostatne pre každú Bartle dimenziu (A, S, E), s piatimi HEXAD faktormi ako simultánnymi prediktormi. Reportujú sa štandardizované koeficienty, robustné HC3 štandardné chyby a R^2 . Kolinearita medzi prediktormi HEXAD sa overuje cez VIF. Aby sa interpretácia neopierala iba o štatistickú významnosť, ale bolo možné pomenovať v čom typológie súviseli, kvantifikuje sa aj unikátna vysvetlená variancia jednotlivých HEXAD faktorov prostredníctvom semi-partial prístupu: pre každý faktor sa porovná R^2 plného modelu a R^2 modelu po jeho vynechaní ($\Delta R^2 = R^2_{full} - R^2_{drop}$).
- Asymetria nahraditeľnosti – doplnkovo sa odhadnú aj reverzné modely (Bartle A/S/E – HEXAD faktory), aby sa posúdila asymetria mapovania (t. j. či jeden nástroj dokáže aproximovať druhý lepšie než naopak).

Odvodenie latentnej štruktúry HEXAD

Primeranosť položiek HEXAD na faktorovú analýzu sa potvrdila ($KMO = 0,715$; Bartlettov $\chi^2, p < 0,001$). Odhadli sa exploračné faktorové modely metódou minimum-residual s oblique rotáciou (Promax), aby sa umožnila korelácia latentných dimenzií. Retencia faktorov sa riadila paralelnou analýzou a

pragmatickými kvalitatívnymi kritériami: každý faktor mal byť ukotvený aspoň 3–4 indikátormi, s primárnym faktorovým zaťažením $\geq 0,40$, s nízkymi krížovými zaťaženiami (hodnoty $\geq 0,30$ sa považovali za problematické) a s akceptovateľnými komunalitami (približne $h^2 \geq 0,30$).

Keďže pôvodná typológia HEXAD predpokladá šesť typov, otestovalo sa aj konkurenčné 6-faktorové riešenie. Toto riešenie však prinieslo dodatočný faktor so slabým nasýtením (najviac 1–2 jasné indikátory s $|\text{loading}| \geq 0,40$) a s viacerými krížovými zaťaženiami, bez zmysluplného zlepšenia komunalít. Naopak, 5-faktorové riešenie poskytlo päť interpretovateľných a dobre nasýtených faktorov (tri faktory boli ukotvené ≥ 4 indikátormi a vykazovali čistejší vzor zaťaženia). Preto sa pre ďalšie analýzy ponechalo $k = 5$ a v mapovaní medzi typológiami sa použili regresné faktorové skóre. Konečná matica faktorových zaťažení je uvedená v Tab. 3.

Tab. 3 Identifikované faktory a ich vnútorná konzistencia.

Faktor	Počet položiek	Položky	Cronbach α	McDonald ω
Faktor 1 (Socializer)	6	H5, H6, H7, H8, H9, H10	0.850	0.858
Faktor 2 (Player)	5	H26, H27, H28, H29, H30	0.798	0.804
Faktor 3 (Free Spirit)	4	H1, H2, H3, H4	0.817	0.819
Faktor 4 (Achiever)	3	H13, H16, H19	0.694	0.702
Faktor 5 (Philanthropist)	3	H11, H14, H15	0.700	0.712

Vnútorná konzistencia bola dobrá pre faktory F1–F3 ($\alpha/\omega = 0,85/0,86$; $0,80/0,80$; $0,82/0,82$), zatiaľ čo F4 a F5 ako trojpoložkové škály dosiahli iba hraničné hodnoty ($\alpha/\omega = 0,69/0,70$ a $0,70/0,71$). Z tohto dôvodu sa F4 a F5 ponechali s opatrnou interpretáciou a v ďalších krokoch sa využili regresné faktorové skóre, pričom identifikované dimenzie sa interpretovali nasledovne:

- **Faktor 1 – Socializer (H5–H10)** zachytáva vzťahovo orientovanú motiváciu (komunikácia, spolupráca, dlhodobjšie sociálne zapojenie). Silné a konzistentné zaťaženia spolu s vysokou reliabilitou naznačujú dobre definovaný konštrukt v súlade so *Socializer* profilom.
- **Faktor 2 – Player (H26–H30)** vyjadruje orientáciu na externé odmeny (body, odznaky, rebríčky). Faktor je kompaktný a homogénny, s robustnými zaťaženiami všetkých piatich položiek.
- **Faktor 3 – Free Spirit (H1–H4)** vyjadruje autonómiu, kreativitu a exploráciu; položky zdôrazňujú agentnosť, adaptáciu a nelineárne cesty. Štvorpoložkový set vykazuje dobrú vnútornú konzistenciu.
- **Faktor 4 – Achiever (H13, H16, H19)** reprezentuje kompetenciu a pokrok (sledovanie cieľov, prekonávanie výziev, merateľný progres). Napriek hraničnej reliabilite danej krátkou škálou sú obsahové jadro aj primárne zaťaženia konvergentné, preto sa faktor ponecháva a ďalej sa pracuje s faktorovým skóre.
- **Faktor 5 – Philanthropist (H11, H14, H15)** zachytáva zmysluplnú prosociálnu orientáciu (pomoc, mentoring). Aj tu ide o krátku škálu s hraničnou reliabilitou, avšak s jasným tematickým jadrom, preto sa faktor ponecháva pre úplnosť.

Dimenzia **Disruptor** sa v tomto súbore neukázala ako stabilný, samostatne ukotvený faktor, pričom tento výsledok je kompatibilný s pozorovaniami z iných prác, podľa ktorých sa indikátory *Disruptor* v menších vzorkách alebo po úpravách položiek niekedy rozptyľujú do dimenzií spojených s autonómiou (*Free Spirit*) alebo kompetenciou (*Achiever*).

Ponechané 5-faktorové riešenie poskytuje teoreticky ukotvené a empiricky interpretovateľné zhrnutie priestoru HEXAD v analyzovanom súbore. V ďalších krokoch sa príslušné regresné faktorové skóre

použije na mapovanie vzťahov k Bartle dimenziám, aby sa posúdil rozsah spoločnej variability a praktické limity nahraditeľnosti oboch typológií.

Príprava Bartle skóre

Hoci sa Bartle dotazník v praxi často interpretuje ako priradenie respondenta do jednej skupiny používateľov, jeho skórovanie je v skutočnosti multidimenzionálne: každá odpoveď prispieva k jednej zo štyroch črt (*Achiever*, *Socializer*, *Explorer*, *Killer*) a výsledné skóre má podobu proporcií, ktoré sa naprieč črtami sčítajú na konštantu. Z tohto pohľadu poskytujú nástroj spojitú kompozičné merania.

Keďže proporcie spĺňajú obmedzenie $A + S + E + K = 1$, jednoduché korelácie sú ovplyvnené konštantným súčtom a systém štyroch premenných je lineárne závislý, preto sa v hlavných modeloch použilo štandardné **drop-one kódovanie**: jedna Bartle dimenzia sa vynechala a analyzovali sa zvyšné tri, ktoré ju plne determinujú. Výber vynechanej dimenzie sa oprel o posúdenie redundancie medzi črtami pomocou matice absolútnych interkorelácií (Tab. 4).

Tab. 4 Analýza redundancie Bartle črt – absolútne interkorelácie.

	Achiever	Socializer	Explorer	Killer	priemerná korelácia
Achiever	1	0.364	0.399	0.148	0.304
Socializer		1	0.047	0.463	0.292
Explorer			1	0.628	0.358
Killer				1	0.413

Najsilnejšie párové väzby sa pozorovali medzi črtami *Explorer* a *Killer* ($|r| = 0,628$) a medzi *Socializer* a *Killer* ($|r| = 0,463$); výraznejšie prekrývanie sa ukázalo aj pre dvojice *Achiever*–*Explorer* ($|r| = 0,399$) a *Achiever*–*Socializer* ($|r| = 0,364$). Najslabšie väzby sa pozorovali pre *Socializer*–*Explorer* ($|r| = 0,047$) a *Achiever*–*Killer* ($|r| = 0,148$).

Priemerovaním absolútnych korelácií každej črty s ostatnými tromi sa ukázalo, že najredundantnejšou dimenziou bol *Killer* (priemer $|r| = 0,413$), nasledovaný *Explorer* (0,358), *Achiever* (0,304) a *Socializer* (0,292). Na základe tohto kritéria sa v drop-one kódovaní vynechal *Killer* a pre modelovanie sa ponechali dimenzie *Achiever*, *Socializer* a *Explorer*; vynechané skóre ostalo spätne rekonštruovateľné ako $K = 1 - (A + S + E)$.

Mapovanie HEXAD - Bartle

Cieľom mapovania je odhadnúť, ktoré dimenzie HEXAD prispievajú k jednotlivým Bartle črtám unikátne a do akej miery je možné považovať oba nástroje za prakticky nahraditeľné.

Z metodologického hľadiska sa berú do úvahy limity práce s ipsatívnymi proporciami. Drop-one kódovanie predstavuje pragmatické riešenie lineárnej závislosti, avšak nemení fakt, že Bartle skóre zostáva kompozičné a odhady môžu byť čiastočne ovplyvnené relatívnou povahou mier (presunom podielu medzi zložkami). V tejto kapitole sa preto výsledky chápu predovšetkým ako **orientačné mapovanie** vzťahov medzi **interpretovateľnými** črtami oboch typológií (*Achiever*, *Socializer*, *Explorer*), ktoré je použiteľné pre rozhodovanie o výbere nástroja pre ďalší výskum. Kompozičný pohľad sa nezanedbal, ale bol využitý skôr ako citlivostná kontrola (porovnanie s CLR-koreláciami v Tab. 5), aby sa overilo, či hlavné vzorce pretrvávajú aj mimo obmedzenia konštantného súčtu.

Formálnejšie log-ratio prístupy (napr. ILR), ktoré mapujú kompozície do $n-1$ -rozmerného euklidovského priestoru pomocou ortonormálnej bázy sa v tejto časti nepoužili ako primárny analytický rámec, pretože by posunuli interpretáciu smerom k abstraktnejším kontrastom medzi zložkami a oslabili priamu čitateľnosť väzieb medzi konkrétnymi dimenziami typológií. Takéto transformácie budú realizované v ďalších kapitolách, kde je cieľom presné odhadovanie a inferencia

na kompozičných dátach; v tomto kontexte však bola prioritou kladená na porovnateľnosť a praktickú interpretáciu vzťahov medzi pôvodnými škálami.

Najprv sa vyhodnotili biviariálne väzby medzi faktorovými skóre HEXAD (*Socializer*, *Player*, *Free Spirit*, *Achiever*, *HEXAD*, *Philanthropist*) a Bartle proporciami (*Achiever*, *Socializer*, *Explorer*). Vzhľadom na viacnásobné testovanie sa p-hodnoty korigovali postupom Benjamini–Hochberg (FDR, $q = 0,05$). Ako ukazuje Tab. 4, po tejto korekcii zostala robustná iba asociácia **Player – Explorer** (Spearmanovo $p = 0,359$; $p = 0,00079$; $p_{FDR} = 0,0118$); ostatné efekty boli malé alebo po kontrole FDR nevýznamné. Negatívny vzťah **Free Spirit – Explorer** sa ukázal ako naznačujúci trend ($p = -0,272$; $p = 0,012$; $p_{FDR} = 0,092$), ale bez potvrdenia pri FDR = 0,05.

Tab. 5 Medzirámkové korelácie medzi faktormi HEXAD a Bartleovými znakmi (Spearman - proporcie; Pearson - CLR).

	Bartle	Socializer HEX	Player HEX	FreeSpirit HEX	Achiever HEX	Philanthropist HEX
Spearman	Achiever	-0.003	-0.237*	0.106	0.02	0.075
	Socializer	-0.228*	0.085	-0.066	-0.054	0.145
	Explorer	0.072	0.359*	-0.272	0.018	-0.176
Pearson	Achiever	-0.007	-0.223*	0.034	0.054	0.086
	Socializer	-0.224*	0.125	-0.067	-0.029	0.113
	Explorer	0.058	0.285*	-0.316*	0.004	-0.109

Na citlivosťnú kontrolu kompozičného charakteru Bartle skóre sa popri Spearmanových koreláciách na proporciách uviedli aj Pearsonove korelácie na CLR-transformovaných hodnotách. Kvalitatívny obraz sa nemení: väzba **Player – Explorer** ostáva pozitívna a väzba **Free Spirit – Explorer** negatívna, čo naznačuje, že pozorovaný signál nie je iba artefaktom konštantného súčtu. Zároveň platí, že pri kompozíciách môžu znamienka čiastočne odrážať relatívny presun podielu medzi zložkami, preto sa biviariálne výsledky interpretujú primárne **deskriptívne** a ďalší krok sa sústreďuje na multivariálne modelovanie.

Následne sa odhadol súbor simultánných viacnásobných OLS regresíí (samostatne pre každú Bartle črtu A, S, E), v ktorých všetkých päť HEXAD faktorov vstupovalo naraz ako prediktory. Reportovali sa štandardizované koeficienty, robustné HC3 štandardné chyby a R^2 ako súhrnná miera vysvetlenej variability. Diagnostika kolinearit medzi HEXAD prediktormi indikovala nízku zdieľanú varianciu (VIF = 1,09–1,59; tolerance 0,63–0,92), preto sa zachoval simultánný vstup všetkých faktorov a inferencia sa oprela o HC3-robustné odhady.

Aby bolo možné identifikovať, ktoré prediktory prinášajú informatívny príspevok nad rámec ostatných premenných, vyčíslil sa unikátny podiel jednotlivých HEXAD faktorov pomocou semi-partial prístupu (ΔR^2). Pre každý faktor sa porovnávalo R^2 plného modelu a R^2 modelu po vynechaní daného faktora ($\Delta R^2 = R^2_{full} - R^2_{drop}$), čím sa získala unikátna vysvetlená variancia (Tab. 6).

Tab. 6 Unikátny príspevok HEXAD faktorov k Bartle črtám (semi-partial R^2). R^2_{full} – koeficient determinácie z úplného štandardizovaného OLS modelu pre danú závislú premennú, v ktorom sú zahrnuté všetky (päť) HEXAD prediktory; R^2_{drop} – koeficient determinácie z modelu po vynechaní uvedeného prediktora (ostatné štyri HEXAD prediktory zostávajú v modeli); Unique_ R^2 – unikátne (semi-partial) vysvetlená variancia pripísateľná danému prediktoru, vypočítaná ako Unique_ $R^2 = R^2_{full} - R^2_{drop}$.

Prediktor (HEXAD)	Dep. var. (BARTLE)	R^2_{full}	R^2_{drop}	Unique_ R^2
Socializer	Achiever	0.075	0.072	0.004
Player	Achiever	0.075	0.013	0.063
FreeSpirit	Achiever	0.075	0.075	0
AchieverHEX	Achiever	0.075	0.075	0.001

Prediktor (HEXAD)	Dep. var. (BARTLE)	R2_full	R2_drop	Unique_R2
Philanthropist	Achiever	0.075	0.068	0.007
Socializer	Socializer	0.088	0.034	0.053
Player	Socializer	0.088	0.06	0.028
FreeSpirit	Socializer	0.088	0.087	0.001
AchieverHEX	Socializer	0.088	0.087	0
Philanthropist	Socializer	0.088	0.069	0.018
Socializer	Explorer	0.24	0.233	0.006
Player	Explorer	0.24	0.159	0.08
FreeSpirit	Explorer	0.24	0.131	0.109
AchieverHEX	Explorer	0.24	0.223	0.017
Philanthropist	Explorer	0.24	0.222	0.018

Výsledky simultánných modelov ukázali nízku vysvetlenú varianciu pre Bartle *Achiever* ($R^2 = 0,075$) a *Socializer* ($R^2 = 0,088$), ale strednú pre *Explorer* ($R^2 = 0,240$). Analýza ΔR^2 naznačila, že Bartle *Achiever* bol v tomto nastavení prakticky vysvetľovaný najmä faktorom HEXAD Player ($\Delta R^2 = 0,063$), pričom príspevok HEXAD *Achiever* bol zanedbateľný. To podporuje interpretáciu, že charakteristika *achievement* v oboch nástrojoch neodkazuje na identický dôraz (externý progres/status vs. kompetencia/majstrovstvo). Bartle *Socializer* bol primárne viazaný na HEXAD *Socializer* ($\Delta R^2 = 0,053$), s menšími príspevkami *Player* (0,028) a *Philanthropist* (0,018), čo je konzistentné so selektívnym prekryvaním v oblasti vzťahovosti. Bartle *Explorer* bol najlepšie predikovaný kombináciou HEXAD *Free Spirit* ($\Delta R^2 = 0,109$) a HEXAD Player ($\Delta R^2 = 0,080$), čo naznačuje spoločnú úlohu autonómie/kreativity a externých progresných slučiek v exploračnej orientácii.

Doplňujúco sa odhadli aj reverzné OLS modely (Bartle A/S/E na HEXAD faktory; štandardizované, HC3-robust). Modely vykazovali celkovo slabšiu mieru vysvetlenia; najkonzistentnejšie vzorce sa pritom koncentrovali v oblasti explorácie: Bartle *Explorer* predikoval vyšší HEXAD *Player* ($\beta = 0,28$; $\Delta R^2 = 0,063$) a nižší HEXAD *Free Spirit* ($\beta = -0,33$; $\Delta R^2 = 0,088$), avšak po FDR kontrole nepretrval žiadny efekt pri $q = 0,05$. Zvýšené VIF (5,8–7,8) v týchto reverzných modeloch sú kompatibilné s kompozičnou povahou Bartle skóre; preto sa pri interpretácii uprednostnili ΔR^2 a celkové R^2 pred izolovaným čítaním koeficientov.

Diskusia a záver

Niektoré potvrdzujúce zdroje naznačujú čiastočný prienik medzi typológiami a ich praktickú použiteľnosť na úrovni konkrétnych dizajnových úloh (napr. výber mechaník alebo segmentačné rozhodnutia) (Yee et al., 2012), (Krath & von Korflesch, 2021), (Tondello & Nacke, 2020). Zároveň však existuje línia prác, ktorá upozorňuje na neekvivalenciu konštruktov, silnú kontextovosť typológií a psychometrické obmedzenia (stabilita faktorov, prenositeľnosť medzi populáciami, citlivosť na spôsob merania), čo limituje ich priamu zameniteľnosť (Kirchner-Krath et al., 2024), (Fong et al., 2024), (Santos et al., 2023).

Konštruktová ekvivalencia porovnávaných typológií v použitých dátach sa potvrdila len čiastočne a selektívne. V rámci HEXAD sa identifikovala koherentná päťfaktorová štruktúra (sociálny typ / *Socializer*, orientácia na odmeny / *Player*, autonómia a kreativita / *Free Spirit*, kompetencia a progres / *Achiever*, prosociálny zmysel / *Philanthropist*). Pri mapovaní na Bartleho proporčné skóre sa ukázalo, že prekryvanie medzi rámcami je celkovo skôr mierne: po korekcii na viacnásobné testovanie zostal ako robustný najmä vzťah medzi orientáciou na odmeny (HEXAD *Player*) a Bartle dimenziou prieskumu (*Explorer*). Výsledky simultánných modelov spresnili, že Bartle *Explorer* čerpá informáciu spoločne z

dimenzií autonómie/kreativity (HEXAD *Free Spirit*) a orientácie na odmeny (HEXAD *Player*), zatiaľ čo sociálnosť vykazuje len čiastočnú konvergenciu (HEXAD *Socializer* prispieva k Bartle *Socializer*, ale efekt je skôr menší). Najvýraznejší nesúlad sa týka pocitu úspechu: Bartle *Achiever* sa neviaže na HEXAD *Achiever*, ale skôr na HEXAD *Player*, čo naznačuje rozdielny význam progresu (status/odmeny vs. kompetencia/majstrovstvo). Takýto obraz je v súlade s tým, že typológie často zdieľajú niektoré spoločné osi, no ich dimenzie nebývajú striktné zameniteľné naprieč rámcami a kontextmi (Kirchner-Krath et al., 2024), (Hamari & Tuunanen, 2014).

Odpoveď na výskumnú otázku SUB2: Praktická zastupiteľnosť či nahraditeľnosť typológií sa na základe skúmaných dát nepotvrdila. Predikčné modely vysvetlili len obmedzenú časť variability (najmä pre Bartle *Explorer*; pre *Achiever* a *Socializer* skôr nízku), pričom spätné mapovanie Bartlovej typológie na HEXAD bolo ešte slabšie. Tam, kde sa predikcia objavila, išlo o ciele prepojenia (najmä *Explorer*), nie o všeobecnú substitúciu typológie ako celku. Z praktického hľadiska to znamená, že **použitie jedného nástroja namiesto druhého vedie k stratám informácie minimálne v niektorých konštruktoch** (typicky v oblasti *achievement* a v dimenziách bez priameho ekvivalentu, napr. prosociálny zmysel v HEXAD).

Zistenia podporujú prístup, v ktorom sa typológie nezamieňajú mechanicky, ale volia sa podľa toho, aký psychologický konštrukt má byť ukotvený a aké dizajnové prvky majú byť profilom riadené. V aplikačnej praxi sa tým presadzuje pragmatická stratégia, ktorá pripúšťa selektívne premostenia medzi typológiami, no zároveň rešpektuje ich neekvivalenciu tam, kde sa ukazuje ako podstatná:

- Ak je cieľom podporiť objavovanie, Bartle *Explorer* sa v dátach približuje kombinácii HEXAD *Free Spirit* (autonómia/kreativita) a HEXAD *Player* (citlivosť na odmeny a cykly postupu).
- Pri sociálnych mechanikách sa objavuje priamy, hoci skôr mierny prienik medzi Bartle *Socializer* a HEXAD *Socializer*, čo umožňuje relatívne konzistentné ukotvenie dizajnu v oblasti vzťahovosti a spolupráce.
- Najväčšia opatrnosť je potrebná pri orientácii na úspech – Bartle *Achiever* a HEXAD *Achiever* nepredstavujú tú istú charakteristiku; pri rozhodovaní o intervenciách sa preto vyžaduje explicitne rozlíšiť orientáciu na status/progres od orientácie na kompetenciu a zvládnutie výzvy.

Ako dôsledok prezentovaných výsledkov sa v ďalšej časti práce uprednostní postup, v ktorom sa bude spravidla pracovať s jedným primárnym typologickým nástrojom, zvoleným podľa povahy dizajrovej úlohy. Tento krok je pragmatický aj metodický: kombinovanie viacerých typológií zvyšuje záťaž respondentov, komplikuje interpretáciu rozdielov medzi skupinami a pri čiastočne neekvivalentných konštruktoch môže viesť k nejasným alebo rozporným implikáciám pre dizajn. Výber jedného nástroja preto podporí konzistentnejšie profilovanie, jasnejšie prepojenie profilov na konkrétne prvky dizajnu (napr. sociálne mechaniky, autonómia a tvorivosť, odmeňovanie a postup) a zároveň zlepší replikovateľnosť postupov naprieč štúdiami.

Prakticky sa bude postupovať tak, že sa najprv identifikuje cieľ profilovania, následne sa vyberie typológia, ktorá dané konštrukty operacionalizuje najpriamejšie, a napokon sa overí, či poskytuje dostatočne stabilné a interpretovateľné profily v danom kontexte. Každé prípadné premostenie alebo kombinácia musí byť zároveň vecne zdôvodniteľná a opretá o empirickú oporu, nie o zdanlivú podobnosť názvov. Tento princíp sa neskôr prezentuje na príklade cielenej kombinácie ITQ s Bartle typológiou, kde sa typologické ukotvenie využije ako interpretačná kotva pre vybrané dimenzie zážitku.

Zovšeobecniteľnosť výsledkov a presnosť odhadov je limitovaná malou populačnou vzorkou (N = 84). V rámci HEXAD sa dve dimenzie (s 3 položkami) ukázali len hranične reliabilné a dimenzia *Disruptor* sa neukotvila ako stabilný faktor, čo môže oslabovať mapovanie naprieč typológiami. Všetky merania sú

sebaopisné; bez behaviorálnej telemetrie a longitudinality nie je možné testovať stabilitu typov v čase ani kauzálne interpretácie. Pri Bartleho proporciách navyše platí kompozičné obmedzenie, ktoré zvyšuje nároky na opatrnú interpretáciu vzťahov.

Aktuálne zistenia je žiaduce overiť na väčších a diverzifikovanejších vzorkách a dôslednejšie otestovať meracie modely, vrátane toho, či majú škály porovnateľnú štruktúru naprieč jazykmi a populáciami. Pri Bartleho skóre je vhodné systematickejšie pracovať s kompozičnými postupmi založenými na logaritmických pomeroch a ukázať, do akej miery závery závisia od zvoleného spracovania ipsatívnych dát.

Prínos pre oblasť habilitácie

Prínos tejto sekcie pre oblasť habilitácie možno zhrnúť do nasledujúcich bodov:

- Teoretický prínos spočíva v potvrdení, že typologické modely nie sú automaticky zameniteľné: často zachytávajú odlišné konštrukty a používajú odlišnú operacionalizáciu aj pri podobných pomenovaniach. Rozlišuje sa spoločné jadro opakujúcich sa dimenzií a modelovo špecifická vrstva viazaná na konkrétny teoretický a merací prístup, čím sa spresňujú hranice interpretácie person.
- Metodický prínos spočíva v tom, že nezameniteľnosť modelov priamo podporuje multi-view prístup: typológie sa majú spracúvať ako samostatné pohľady s vlastnou neistotou, nie ako vstupy na skoré zlievanie príznakov. Zároveň sa potvrdzuje potreba harmonizačných kontraktov pred integráciou (porovnateľný formát výstupov, škály, kontrola kvality) a práce s neistotou pri reportovaní výsledkov.
- Praktický prínos spočíva v znížení rizika chybných dizajnových záverov tým, že sa bráni prekladu modelov podľa podobnosti názvov a dôraz sa presúva na overiteľné významy, ktoré sa majú validovať na externých premenných mimo klastrovania.
- Pre multi-view modelovanie sekcia spresňuje cieľ integrácie ako harmonizáciu porovnateľných výstupov a neskorú fúziu, nie ako zjednotenie typov do jedného členenia. Tým podporuje úvodné spracovanie vstupov ako nevyhnutný špecifikačný krok a vytvára oporu pre konštrukciu spoločného priestoru založeného na konzistentných pravidlách integrácie, vážení podľa stability a práci s neúplnosťou.

Spracovanie behaviorálnych dát

Vo virtuálnych prostrediach vzniká pri každej interakcii bohatá stopa správania – od jednoduchých klikov myši a odovzdaní úloh až po detailnú telemetriu pohybu a akcií. Práve tieto dáta umožňujú opísať používateľov na úrovni toho, čo robia, nie iba čo deklarujú v dotazníkoch. V praktickej rovine to znamená, že správanie používateľov sa dá spoľahlivo merať a vyhodnocovať priamo z ich interakcií so systémom, čo umožňuje cielene optimalizovať prostredie a opierať rozhodnutia o empirické dáta namiesto subjektívnych dojmov (Gris & Bengtson, 2021).

Spracovanie behaviorálnych dát z pohľadu procesu však nepredstavuje jednotný presne popísateľný postup, ale škálu rozhodnutí o granularite a reprezentácii. Na jednom konci stoja sumarizačné profily z transakčných logov (počty, pomery, trvania), ktoré rýchlo poskytujú základný odtlačok používateľa. Na druhom konci je event-telemetria, ktorá zachytí priebeh správania v čase, no zároveň zvyšuje citlivosť na šum, neúplnosť a analytické voľby. V hernej analytike je práca s takýmito logmi štandardom, ale dôveryhodnosť výstupov stojí na tom, ako sa dáta pripravujú a zjednotia do porovnateľnej formy (Teng et al., 2025).

Prvou podmienkou zmysluplného profilovania je dátová hygiena: odfiltrovať správania, ktoré nie sú prejavom stratégie, ale dôsledkom iného prístupu k riešeniu, napr. nízkej angažovanosti. V edukačných mikro-prostrediach sa to typicky prejavuje ako rýchle hádanie (*rapid guessing behaviour*; RGB) – extrémne rýchle odpovede bez riešenia, ktoré skresľujú odhady schopnosti, profilov aj následnú segmentáciu. Dôležitým faktom je, že takéto správanie sa dá zachytiť priamo z logov, najmä cez čas odpovede a jeho vzťah k úspešnosti (napr. prístupy typu response-time effort a následné detekčné procedúry) (H. Guo et al., 2016), (Jan Skalka & Valko, 2024).

Táto kapitola preto začína blokom o detekcii nízkej angažovanosti ako o čistiacom kroku, ktorý má priamy dopad na downstream analýzy. Nejde len o to, či sa RGB identifikuje, ale ako: rôzne metódy môžu vyprodukovať odlišné množiny označených odpovedí, a tým aj odlišný obraz o používateľských profiloch. Prakticky dôležitá je porovnateľnosť metód a transparentné reportovanie toho, čo sa odstránilo a čo zostalo ako základ pre ďalšie modelovanie (Soland et al., 2021), (Ján Skalka & Valko, 2025b).

Na vyčistené dáta nadväzuje agregáčna vrstva – mikro-persony zo sumárnych/transakčných logov. V mikro-učení je práve táto úroveň často najviac nasaditeľná: z jednoduchých stôp (kedy a koľko sa rieši, ako sa rozkladá aktivita v čase, aký je typický rytmus odovzdaní) sa dajú zostaviť interpretovateľné profily typu *front-loaders* či *prokrastinátori*. V porovnaní so štandardnou event-telemetriou ide o ľahkú reprezentáciu, ktorá je lacná na zber aj výpočet a je použiteľná veľmi skoro – aj pri obmedzenej histórii používateľa, čo je dôležité pre personalizáciu v praxi (Taylor & Hung, 2022), (Monib et al., 2025).

Agregácia má však svoje metodické limity: redukcia sekvenčného správania na malý súbor sumarizačných ukazovateľov síce zvyšuje porovnateľnosť, no zároveň oslabuje priamu väzbu na priebeh interakcie v čase. Tým sa rozširuje interpretačný priestor pri vysvetľovaní klastrov a rastie riziko post hoc naratívov odvodených primárne len z rozdielov v priemeroch. Z tohto dôvodu kapitola zdôrazňuje aj druhú líniu spracovania – prácu s teoretickými rámcami tak, aby pôsobili ako opora. Typológie sa tu preto chápu predovšetkým ako spoločný pojmový aparát pre dizajn príznakov a disciplinované pomenovanie výsledných skupín: usmerňujú, ktoré metriky sú významovo relevantné, a zároveň štandardizujú spôsob, akým sa výsledky interpretujú a komunikujú (Kahila et al., 2025), (O'Shea & Freeman, 2019).

Vzniká tým rámec, v ktorom sa interpretovateľnosť neopiera o dodatočné atraktívne pomenovania klastrov, ale o transparentný a sledovateľný postup: logy - konštrukcia príznakov - významové bloky - segmentácia - kontrola dôsledkov. V dátovo orientovaných metodikách je takáto explicitná špecifikácia krokov základným východiskom: kvalita výsledku závisí od toho, či je celý proces prípravy a modelovania replikovateľný a auditovateľný, nie od toho, že bol jednorazovo vyladený na jednej dátovej sade (G. H. Lee et al., 2019), (Hayes & Beling, 2018).

V ďalších častiach kapitoly sa postupne ukáže prečo je dátová hygiena nevyhnutná pre férové porovnania a stabilné profily, ako agregované logy podporujú rýchlu konštrukciu prakticky použiteľných mikro-person a ako typológie slúžia ako opora pri návrhu príznakov aj interpretácii segmentov bez toho, aby sa zamieňali za priame meranie latentných čŕt. V štruktúre práce táto kapitola vytvára metodický základ spracovania behaviorálnych dát; naň následne nadväzuje detailnejšia telemetria a procesné reprezentácie v ďalších kapitolách.

Dátová hygiena: detekcia nízkej angažovanosti

Virtuálne vzdelávacie prostredia produkujú nielen výstupné výsledky učenia, ale aj rozsiahle behaviorálne logy, ktoré sa využívajú na hodnotenie kvality obsahu, odhad znalostí, konštrukciu používateľských profilov a vylepšovanie vzdelávacích ciest. V tomto rámci sa mikrolearning javí ako obzvlášť vhodný formát pre dnešné dynamické prostredie: sprostredkúva poznatky a podporuje rozvoj zručností prostredníctvom krátkych, koncentrovaných jednotiek zameraných na jeden koncept, pričom kladie dôraz na learning-by-doing a priebežné overovanie porozumenia (Dolasinski & Reynolds, 2020), (Hug, 2005), (Sankaranarayanan et al., 2023). Zároveň ho možno chápať ako prakticky ukotvenú podobu e-learningu, ktorá prenáša jeho princípy do menších, interaktívnych krokov (Jan Skalka & Drlík, 2020) a typicky využíva osvedčené techniky inštrukčného dizajnu (Paparella & Papeo, 2022). Pre analýzu správania je kľúčové, že mikrolearning **granuluje obsah aj interakcie**: každá mikrolekcia vytvára prirodzené, opakovateľné body merania (čas, úspešnosť, pokusy, návraty), vďaka čomu sa proces učenia dá detailne sledovať priamo z logov a následne prekladať do interpretovateľných indikátorov učenia a práce s obsahom (Canagarajah, 2019).

Z metodického hľadiska nemožno hodnotenie mikrolekcí a ich kvality opierať iba o hrubé výsledkové ukazovatele. Súčasťou evaluácie má byť aj overovanie náročnosti, zrozumiteľnosti a akceptácie používateľmi, typicky prostredníctvom interaktívnych prvkov v prostredí a dotazníkov (Betancur-Chicué & García-Valcárcel Muñoz-Repiso, 2023), (Simaremare et al., 2022). Dôležitú doplnkovú informáciu pritom prináša analýza správania a úspešnosti priamo z logov, ktorá umožňuje interpretovať výsledky v kontexte reálneho používania a objektivizovať subjektívne hodnotenia (Puah et al., 2022), (Sung et al., 2023).

Častým zdrojom takéhoto skreslenia je hádanie odpovedí pri veľmi krátkom čase riešenia, označované ako *rapid guessing behavior* (RGB). RGB je detailne popísané najmä v kontexte tradičného testovania, kde sa spája s oslabením validity merania a s podhodnotením odhadov výkonu, keďže odpoveď nie je výsledkom riešenia, ale náhodnej voľby (H. Guo et al., 2016), (Wise, 2017), (Rios & Deng, 2021). Pri práci s logmi je však jeho dopad širší: neovplyvňuje iba individuálne skóre, ale prenáša sa aj do odvodených ukazovateľov používaných na hodnotenie položiek (napr. zdanlivá náročnosť či „diskriminačná schopnosť“), do profilových metrík používateľa a následne aj do segmentácie, ktorá z týchto metrík vychádza. Praktickým dôsledkom je, že klastre alebo osoby môžu zachytávať mieru nízkej angažovanosti, namiesto významových rozdielov v stratégii učenia.

Toto riziko je obzvlášť vysoké v situáciách, kde výsledok odpovede nemá veľký vplyv na celkové hodnotenie či známku študenta (hodnotenia bez výrazných dôsledkov, nízkostávkový režim) a kde je typická flexibilita času, opakované pokusy a okamžitá spätná väzba (Simaremare et al., 2022). V takom

prostredí sa režim práce s úlohami môže v rámci jednej aktivity meniť: časť odpovedí vzniká ako dôsledok skutočného riešenia, časť ako rýchle „testovanie možností“ alebo snaha udržať kontinuitu postupu. Preto je RGB v tomto nastavení nielen problémom validity výsledkov, ale aj problémom porovnateľnosti profilov – rovnaké agregované metriky môžu vzniknúť z interakcií s rozdielnou kvalitou a odlišnou mierou kognitívneho úsilia.

Z toho vyplýva, že detekcia nízkej angažovanosti má v pipeline spracovania behaviorálnych dát funkciu predbežnej sanitácie: jej úlohou nie je zlepšiť výsledok, ale stabilizovať vstup pre následné modelovanie. Ak sa RGB neošetrí, následné analýzy môžu pôsobiť číselne stabilne, no vecne zavádzať: model sa prispôsobí šumu v dátach, segmentácia začne zachytávať rýchle odklikávanie namiesto štýlov práce a popis skupín sa ľahko zmení na dodatočné domýšľanie, ktoré nie je opreté o reálne údaje z procesu (Alahmadi & DeMars, 2025). Naopak, kontrolované odstránenie nízko-informatívnych odpovedí zvyšuje šancu, že odvodené ukazovatele budú reprezentovať stabilnejšie tendencie používateľa a že segmentácia bude vychádzať z relevantných behaviorálnych rozdielov.

Výskum RGB sa tradične sústreďuje na dva smery: identifikáciu RGB v prostredí klasického testovania (Wise, 2019), (Deribo et al., 2023) a štatistickú identifikáciu problematických položiek (Rios, 2022b), (Rios, 2022a). Otvorenou otázkou však zostáva prenositeľnosť týchto postupov do prostredí, kde je režim práce s úlohami iný než v štandardizovanom teste. Špecificky, prahové rozhodnutia (napr. časové prahy pre „rýchlu odpoveď“) môžu byť systematicky skreslené heterogenitou používateľov: rozdiely v rýchlosti čítania, v rutine a výkone môžu viesť k tomu, že rovnaký prah bude pre niekoho príliš prísny a pre iného príliš benevolentný. To naznačuje, že robustnosť detekcie môže zlepšiť postup, ktorý prahy neodhadzuje globálne, ale separátne v homogénnejších skupinách používateľov.

Na tomto pozadí sa dá prirodzene formulovať výskumná otázka, ktorá je priamo v súlade s cieľom dátovej hygieny v kapitole:

- ***BEHA1: Do akej miery sú metódy nízkej angažovanosti vyvinuté pre tradičné testovanie prenositeľné do nízko-stakes mikrolearningu a zlepši sa ich presnosť/robustnosť, ak sa prahy RGB odhadujú separátne v homogénnych skupinách študentov definovaných rýchlosťou čítania a výkonom (t. j. klastrovaním pred samotnou detekciou)?***

V ďalšej analýze sa RGB nechápe len ako vlastnosť položiek, ale ako zdroj systematického skreslenia logových metrík, ktorého dopad sa testuje porovnaním globálneho prahovania s adaptívnym prahovaním v predsegmentovaných skupinách.

Prehľad relevantných zdrojov

Základným predpokladom zodpovedného hodnotenia vzdelávacích výsledkov je, že dosiahnuté skóre odráža hodnotené vedomosti, zručnosti alebo schopnosti. Problém však nastáva vtedy, keď sa študenti odchýlia od očakávaného spôsobu riešenia a pri odpovedaní nevyužijú svoje vedomosti, ale zvolia alternatívny postup (Rios & Deng, 2021). RGB predstavuje výber odpovede prevažne náhodne spomedzi ponúkaných možností, pričom najčastejšie sa vyskytuje v situáciách, keď je správna iba jedna možnosť. Respondent zvolí odpoveď tak rýchlo, že si otázku ani možnosti odpovede reálne neprečíta, prípadne sa nepokúsi úlohu vyriešiť na základe svojich vedomostí. K prvým autorom, ktorí sa tejto téme venovali, patrí Schnipke (Schnipke & Scrams, 1997), ktorá ukázala, že keď sa v časovo náročných testoch blíži koniec času, časť respondentov začne odpovedať na zostávajúce položky veľmi rýchlo v nádeji, že niektoré odpovede budú správne na základe pravdepodobnosti, resp. „náhodou“ (Wise, 2017).

Dôvody RGB

Pri riešení úloh možno pozorovať dva základné režimy správania: rýchle hádanie, keď respondent odpovedá bez plnej pozornosti, a riešenie, keď uplatní vedomosti a vynaloží kognitívne úsilie (Wise, 2017). Ak je zvolený režim riešenia, respondent sa snaží identifikovať správnu odpoveď a „pracuje“ s úlohou; ak je zvolený režim rýchleho hádania, odpoveď je zvolená bez zmysluplného pokusu problém vyriešiť (Wise & Kuhfeld, 2020).

RGB v testoch môže mať viacero príčin:

- Najčastejšie sa uvádza **nízka motivácia** (Wise & Kong, 2005). Ak respondenti nemajú motiváciu podať dobrý výkon alebo motiváciu počas testu stratia, môžu prejsť na rýchle hádanie. Toto správanie je výrazne častejšie v situáciách hodnotenia bez výrazných dôsledkov, kde sú následky nesprávnej odpovede minimálne. Nízku motiváciu potvrdzuje viacero štúdií, ktoré ukazujú vyšší výskyt rýchleho hádania u demotivovaných respondentov (Lindner et al., 2019), (Halvonik et al., 2023), (T. Y. Tan et al., 2020).
- Ďalší typický scenár nastáva vtedy, keď respondent po prečítaní úlohy zistí, že **nemá potrebné vedomosti** a uprednostní rýchly odhad pred stratou času pri probléme, o ktorom vie, že ho nevyrieši (Wise, 2020), (Rios, 2022c).
- Podobná situácia vzniká pri **časovom tlaku**, najmä ku koncu testu, keď respondenti volia rýchle odpovede ako stratégiu „záchranu“ výsledku (Wise, 2017), (Schnipke & Scrams, 1997).
- Ďalším faktorom je postupne narastajúca **(mentálna) únava**. Dlhé testy môžu študentov vyčerpať, najmä ak nie sú dostatočne pripravení. Únava sa pritom nemusí vždy prejaviť kratším časom odpovede – ak sa kombinuje s nižším porozumením, študent môže mať nižší výkon pri dlhších časoch odpovede. Ide o komplexné správanie ovplyvnené vedomosťami, dĺžkou testu, angažovanosťou a zostávajúcim časom (Nagy et al., 2023).
- Posledným dôvodom môže byť **chybne formulovaná alebo nejasná otázka**. Ak je položka nejednoznačná, zavádzajúca alebo obsahuje chyby, respondent nemusí byť schopný efektívne aplikovať vedomosti. Namiesto snahy „dešifrovať“ chybnú otázku môže zvoliť hádanie, pretože považuje ďalšie úsilie za zbytočné (Browne & Keeley, 2002), (Bachiri & Mouncif, 2023).

V prostredí mikrolearningu sa k týmto dôvodom pridávajú špecifiká formátu. Možnosť opakovaných pokusov môže znižovať tlak na správnosť na prvýkrát a podporovať stratégiu rýchlych tipov s následnou korekciou v ďalších pokusoch (Korosi et al., 2018), (T. Y. Yang et al., 2017), (Sanchez et al., 2021). Dokonca v niektorých prípadoch môže ísť o akceptovateľnú stratégiu a môže byť aj zámerne podporená autorom kurzu.

RGB môže podporovať aj nízka angažovanosť a slabšia motivácia, keďže mikrolearningové aktivity majú často malú váhu v celkovom hodnotení (Nikou & Economides, 2018), (Arslan et al., 2023), (Khong & Kabilan, 2022). Ak je mikrolearning súčasťou formálneho vzdelávania a je nastavený ako povinný, RGB môže posilniť aj tlak na termíny a „dobiehanie“ úloh pri zlom časovom manažmente (Jan Skalka & Drlik, 2020). Napokon, mikrolearning sa často používa v krátkych, fragmentovaných intervaloch a popri iných aktivitách, čo znižuje koncentráciu a zvyšuje pravdepodobnosť rýchlych, málo premyslených odpovedí.

Identifikácia RGB

Prvé snahy o vysvetlenie nespoľahlivých testových výsledkov sa opierali o dotazníky po teste, ktoré zachytávali subjektívne prežívanie a motiváciu respondentov. Wise a DeMars (Wise & DeMars, 2005) syntetizovali viacero štúdií a ukázali, že dotazníky motivácie môžu dopĺňať skóre: nemotivovaní respondenti dosahovali v priemere približne o polovicu smerodajnej odchýlky nižší výkon než motivovanejší spolužiaci. Nedostatok motivácie tak zrejme znižuje výkon aj validitu interpretácie

výsledkov, pričom problém sa typicky zintenzívňuje v situáciách bez významných dôsledkov na finálne hodnotenie, kde účastníci vnímajú slabý výkon ako málo podstatný (Wise & Gao, 2017).

Záujem o motiváciu viedol k rozvoju dotazníkových prístupov (Piaw Chua, 2012), (Mastuti & Handoyo, 2018), (Zamarro et al., 2019), (Silm et al., 2020), ktoré sú rýchle a často vykazujú vysokú vnútornú konzistenciu (Wise & Gao, 2017). Ich limity sú však zásadné: respondenti si len ťažko vybavajú, pri ktorých konkrétnych položkách sa ich úsilie zmenilo, a výsledky sú subjektívne a náchylné na skreslenie; navyše, nestranné vyplnenie samo predpokladá plné zapojenie do všetkých položiek dotazníka (Wise & Smith, 2016), čo sa v praxi – najmä pri hodnotení bez osobných dôsledkov – často nenapĺňa (List et al., 2018).

Presnejší prístup umožňuje počítačovo podporované testovanie (*computer based testing*; CBT), ktoré zachytáva správanie na úrovni jednotlivých položiek: čas odpovede, správnosť a ďalšie signály úsilia. CBT tak umožňuje skúmať, ako sa úsilie mení naprieč položkami a vlastnosťami úloh (Wise & Gao, 2017), (Heber et al., 2017), (Paiva et al., 2022), (Lepper & Malone, 2021). Viaceré štúdie potvrdili vzťah medzi motiváciou, časom odpovede a výkonom, čím vytvorili priestor pre behaviorálnu analýzu RGB v CBT (Wise & Kong, 2005), (Silm et al., 2020), (Lundgren & Eklöf, 2023).

Wise (Wise, 2017) na základe nich sumarizuje tri typické empirické odlišnosti medzi režimom hľadania a režimom riešenia: významne odlišné trvanie odpovedí (rýchle tipy vs. riešenie), odlišná miera presnosti a rozdiely viditeľné aj na úrovni psychometrických modelov.

Metódy identifikácie RGB sa prirodzene delia podľa toho, aké dôkazy využívajú (Rios & Deng, 2021):

- postupy bez využitia empirických dát o odpovediach (opierajú sa o teóriu a predpoklady) (Rios & Soland, 2021b), (Deribo et al., 2021),
- postupy používajúce iba čas odpovede (*response time*; RT) (H. Guo et al., 2016), (Wise & Kuhfeld, 2020),
- postupy kombinujúce čas odpovede a správnosť (*response time and response accuracy*; RTRA) (Chun Wang & Xu, 2015), (H. Guo et al., 2016),
- ostatné metódy integrujúce ďalšie premenné a komplexnejšie modely (Rios, 2022c), (Nagy et al., 2023).

Postupy bez empirických dát o odpovediach


Niektoré prístupy odhadujú prah RGB z vlastností položky, najmä z jej „povrchovej“ náročnosti na čítanie. Podľa (Baumann et al., 2018) sa predpokladá, že dlhšie položky vyžadujú dlhší čas, a prah sa preto môže viazať na dĺžku textu a odhadovanú rýchlosť čítania populácie. V praxi je však tento prístup komplikovaný, keďže prah sa líši položku od položky a potrebné metadáta nemusia byť dostupné.

Ako praktická aproximácia Wise a Kong definovali pravidlá pre prah pri zodpovednom riešení (*response time effort*; RTE) (Wise & Kong, 2005): pre položky kratšie než 200 znakov 3 sekundy, pre položky dlhšie než 1000 znakov 10 sekúnd a inak 5 sekúnd. Štúdia na teste NAW-8 (Wise et al., 2009) uvádza prahy pre 63 položiek v rozsahu 3–15 sekúnd (priemer 4,4 s) a zároveň ukazuje, že textovo bohatšie položky častejšie vedú k hľadaniu odpovede. Zároveň platí, že pri CBT je vhodné uvažovať aj technický „čas reakcie“ a kliknutia, keďže pri RGB respondent otázku nespracúva, ale len vyberá možnosť.

Osobitným prípadom je prístup *common k seconds*, ktorý stanoví jediný prah RTT pre všetky položky. Je jednoduchý a používa sa napr. v programe PIAAC (Rios & Deng, 2021), (Goldhammer et al., 2016) no jeho slabinou je ignorovanie variability položiek: rovnaký limit pre textové porozumenie aj pre jednoduchú aritmetiku môže viesť k systematickým chybám v detekcii.

Postupy využívajúce iba čas odpovede

Metódy využívajúce čas odpovede (RT) už vychádzajú z empirických dát a prah sa odvodzuje z rozdelenia časov odpovedí. Jednou z najstarších praktík je vizuálna identifikácia prahu pri bimodálnom rozdelení: jedna „vlna“ zodpovedá premysleným odpovediam a druhá príliš rýchlym odpovediam. Schnipke (Schnipke & Scrans, 1997), navrhla určiť prah ako priesečník rozdelení správnych a nesprávnych odpovedí (v ilustračnom príklade na Obr. 4 sú to 4 sekundy).



Obr. 4 Bimodálne rozdelenie odpovedí. Červená krivka predstavuje rozdelenie nesprávnych odpovedí v čase; zelená krivka predstavuje správne odpovede. Podľa Schnipke možno na základe vizuálnej kontroly určiť prahovú hodnotu času odozvy ako priesečník kriviek – 4 sekundy.


Vizuálne určovanie prahu však nesie subjektivitu a nákladnosť; Kong et al. odporúčajú zapojenie expertov, no treba počítať s tým, že výsledok pri nich nemusí byť konzistentný (Kong et al., 2007). Navyše, reálne dáta často nemajú ideálne bimodálne rozdelenie, takže prah nie je zjavný. Ako alternatívu Rios a Guo navrhli automatizáciu cez zmes log-normálnych rozdelení, ktorá hľadá „najnižší bod“ medzi módmí (Rios & Guo, 2020).

Ďalšou vetvou je percentilové prahovanie. Wise a Ma predstavili normatívny prah (*normative threshold*; NT), ktorý stanoví prah ako percentil z rozdelenia časov položky; následné práce preferovali variant NT10 (Wise & Kuhfeld, 2021), (Y. Liu et al., 2020), (Svetina Valdivia et al., 2023), ktorý definuje prah na úrovni 10 % typického času odpovede (s horným limitom 10 sekúnd).

Kombinácia času odpovede a správnosti

Metódy kombinujúce RT a presnosť pracujú s princípom, že pri rýchlom hadaní sa správnosť približuje náhode, zatiaľ čo pri riešení nad úrovňou náhody rastie. **RTRA** (*response time and response accuracy*) pomenovali Guo et al. (H. Guo et al., 2016), a opisujú ho ako postup, ktorý porovnáva presnosť v časových intervaloch s pravdepodobnosťou náhodného tipu; prah je bod, kde sa presnosť začne systematicky odlišovať od náhody. Guo zároveň integruje zistenia z (Ma et al., 2011), (Y. H. Lee & Jia, 2014), (Wise, 2006) a zdôrazňuje výhodu akumulácie pozorovaní aj pri riedkych dátach.

Špecifickou variantou RTRA je **CUMP** (*cumulative proportional method*) (H. Guo et al., 2016), ktorá neurčuje prah podľa presnosti v jednom intervale, ale podľa kumulatívnej presnosti od začiatku až po daný čas. Prah je čas, keď kumulatívny podiel správnych odpovedí prvýkrát prekročí mieru náhody; výhodou je formálna, ne-vizuálna definícia a dobrá použiteľnosť vo veľkých dátach. Guo et al. ukázali, že CUMP môže byť účinnejší než alternatívy vrátane NT10, práve preto, že nízke úsilie vedie k presnosti blízkej náhodnému tipovaniu (Soland et al., 2021).



Obr. 5 Frekvencia správnych a nesprávnych odpovedí pre úlohu so štyrmi možnosťami – zelené stĺpce predstavujú správne odpovede, červené nesprávne (zobrazené v záporných hodnotách osi).

Tab. 7 Údaje predstavujúce frekvencie a kumulatívne frekvencie odpovedí z Obr. 5.

sekunda	0	1	2	3	4	5	6	7	8
správne	0	2	0	1	2	5	9	7	15
nesprávne	4	7	12	5	9	12	10	13	13
pomer správnych v intervale	0.00	0.22	0.00	0.17	0.18	0.29	0.47	0.35	0.54
kumulatívne správnych	0	2	2	3	5	10	19	26	41
kumulatívne nesprávnych	4	11	23	28	37	49	59	72	85
podiel správnych	0.00	0.15	0.08	0.10	0.12	0.17	0.24	0.27	0.33

V ilustračnom príklade (Obr. 5, Tab. 7) so štyrmi možnosťami (náhodná správnosť 0,25) môže intervalové prahovanie viesť k prahu 5 sekúnd, kým kumulatívny prístup identifikuje prvé prekročenie úrovne náhody až pri 7 sekundách. Rozdiel ukazuje, že rozhodnutie „kedy sa správanie mení“ závisí od toho, či sa hodnotí lokálne po intervaloch alebo kumulatívne.

Prípadová štúdia: RGB v programovaní

Metodika prípadovej štúdie vychádza z metodiky CRISP-DM a je organizovaná do nasledujúcich krokov:

- porozumenie problému a cieľom – spresnenie výskumného kontextu, požiadaviek a postupov pre získanie odpovede na výskumnú otázku,
- porozumenie dátam a príprava dát – opis zberu a spracovania údajov:
 - deskripcia dát,
 - mapovanie atribútov,
 - čistenie a filtrovanie,
 - výpočet odvodených premenných,
- analýza dát – realizácia analytických krokov:
 - výber metód identifikácie RGB,
 - nastavenie vhodných časových prahov (RTT) pre jednotlivé metódy,
 - identifikácia RGB položiek ako prieniku *študent × otázka* pre každú metódu,
 - odvodenie premenných pre kategorizáciu študentov podľa správania a výkonu,
 - overenie, či sa presnosť detekcie RGB zlepší, ak sa metódy aplikujú separátne v identifikovaných skupinách študentov,
- porozumenie výsledkom – zhodnotenie výstupov a formulácia odpovedí na výskumné otázky,
- uplatnenie výsledkov – diskusia využitia zistení v prostredí mikrolearningu.

Porozumenie problému

Mikrolearning sa stal rozšíreným prístupom v rôznych oblastiach a v programovaní je vhodný najmä na budovanie základov algoritmizácie, dátových štruktúr a elementárnych konceptov. Jeho praktickú adopciu ilustrujú aj platformy ako *Sololearn* (Yama Adi Putra et al., 2022), (Botte et al., 2020), *FreeCodeCamp* (Elhalid et al., 2023), alebo *Datacamp* (B. Anderson, 2022). Popri dostupnosti krátkych, fragmentovaných jednotiek je dôležitou výhodou mikrolearningu aj to, že umožňuje detailne sledovať


správanie používateľa: obsah sa typicky strieda s overovaním porozumenia cez otázky, takže z logov možno identifikovať problémové miesta, upravovať formulácie úloh a cielene doladovať mikrolekcie.

Z hľadiska dátovej analýzy je kľúčové, že systém vie zaznamenať čas potrebný na spracovanie každej jednotky, úspešnosť odpovedí aj počet pokusov. Takéto dáta podporujú jemnejšiu diagnostiku: nerozhoduje len výsledná odpoveď, ale aj to, **ako** študent k výsledku prišiel (rýchlo vs. po čítaní, na prvý pokus vs. po opakovaní). Pri validácii obsahu a vyhodnocovaní efektívnosti výučby však treba rátať s tým, že časť odpovedí nemusí odrážať plnohodnotné riešenie. Keďže úlohy sa majú priebežne dokončovať, opakovanie pokusov je prirodzenou súčasťou učenia a systém je nastavený skôr podporne než sankčne, môže sa v dátach objaviť aj rýchle tipovanie odpovedí (RGB).

Predpokladom detailnej analýzy je vhodné technologické zázemie a dostatočne štruktúrovaný obsah. Hoci aj klasické LMS dokážu poskytovať mikrolearning a zbierať záznamy o aktivite (Halvoník & Kapusta, 2020), (Kapusta et al., 2019), pre výskumné účely sa ako efektívnejšie ukazujú špecializované nástroje, ktoré monitorujú aj elementárne kroky používateľa. V tejto štúdii sa využíva webová platforma **Priscilla**, navrhnutá práve na detailné sledovanie učenia a správania študentov (Ján Skalka, 2022), (Jan Skalka & Drlik, 2018). Platforma je zameraná na výučbu programovacích jazykov a poskytuje viacero typov mikroúloh (obsahové lekcie, krátke odpovede, výber jednej možnosti, viacnásobný výber, skladanie kódu/textu z ponúknutých fragmentov, dopĺňanie, preskupovanie riadkov, a viaceré formy overenia správnosti zdrojového kódu).

Na zvýšenie motivácie sú do systému integrované gamifikačné prvky: študenti získavajú skúsenostné body (XP) a virtuálnu menu, pričom „minca“ je viazaná na správnu odpoveď na prvý pokus. K dispozícii sú aj rebríčky na úrovni kurzu aj celého systému, ktoré umožňujú porovnať progres a výkon v rámci rovesníckej skupiny.

Pri odhaľovaní RGB sú nosným prvkom úlohy ponúkajúce jednu správnu z viacerých možností (Obr. 6).



Obr. 6 Kurz programovania v systéme Priscilla – ukážka typickej mikrolearningovej úlohy na výber z možností.

Pre analýzu RGB bol vybraný kurz **Python Introduction** pre študentov prvého ročníka. Kurz obsahuje 19 kapitol (od premenných a radiaciach štruktúr po reťazce a funkcie), 210 mikrolekcií, 299 úloh rôznych typov a 134 programovacích úloh.

Porozumenie dátam a príprava dát

Pre aktuálny výskum sa vybrali údaje používateľov, ktorí sú študentmi UKF; všetci poskytli súhlas so spracovaním anonymizovaných dát v súlade so schválením Etickej komisie UKF pre tento výskum.

Dôležitou vlastnosťou vzorky je heterogenita vstupných znalostí: časť študentov prichádza s predchádzajúcou skúsenosťou a kurz využíva najmä ako opakovanie, zatiaľ čo iní začínajú prakticky od nuly. Táto variabilita je pre skúmanie RGB podstatná, lebo prirodzene vytvára rozdiely v tempe práce, vo výkone aj v pravdepodobnosti „rýchlych“ odpovedí.

Systém Priscilla sleduje správanie a výkon používateľa na dvoch úrovniach.

- **Sledovanie pohybu používateľov v systéme**, ktoré pre účely tejto štúdie poskytuje najmä informácie o vstupoch a výstupoch z mikrolekcií. Log obsahuje typ operácie (napr. *open*, *close*), identifikáciu používateľa, identifikáciu kurzu, identifikáciu objektu (mikrolekcia/úloha), čas udalosti a opisný parameter, ktorého význam závisí od typu operácie (napr. čas, počas ktorého bol prvok zobrazený do ukončenia). Príklad je v Tab. 8.
- **Sledovanie správnosti odpovedí** – systém zaznamenáva informácie o správnosti odpovedí. Pri odoslaní riešenia na vyhodnotenie sa zaznamená **čas odpovede**, odpoveď sa vyhodnotí a výsledok sa odošle späť používateľovi. Záznam pokusu obsahuje informácie o používateľovi, kurze, objekte (otázka), odpovedi (konkrétna odpoveď alebo zoznam odpovedí), čas odoslania a čas potrebný na odpoveď – od zobrazenia otázky po jej odoslanie na vyhodnotenie. Príklad je v Tab. 9.

Tab. 8 Štruktúra a príklad záznamov o pohybe používateľa a systémových udalostiach

id	actor_id	actions	object_type_1	object_value_1	object_type_2	object_value_2	timestamp_to	descript
207	3597	close	course	121	task	9360	08:34	2
208	3597	open	course	121	task	9360	08:34	0
209	3597	close	course	121	task	9360	08:34	1
210	3567	evaluate	course	61	task-chapt	5150	08:34	100
211	3567	XP+ course	course	61	task	5150	08:34	5
212	3597	open	course	61	task	5517	08:34	0
213	3567	open	course	61	task	5216	08:34	0
214	3567	close	course	61	task	5150	08:34	14

Tab. 9 Zjednodušená štruktúra a príklad záznamov o pokusoch (odpovediach)

id	USER_ID	COURSE_ID	TASK_ID	SCORE	TIME_LENGTH	TIME_STAMP	ANSWERS
90	2813	1	1034	7	42	08:23	["SCANNER","SYSTEM.IN","INT","NEXTINT()","___","___...
91	2858	1	1049	5	9	08:23	["FOR",""]
92	2876	1	1001	10	12	08:23	["//"]
93	2834	1	1062	0	21	08:23	["4"]
94	2858	1	1049	10	18	08:23	["FOR","5"]

Tieto údaje poskytujú základný obraz o tom, ako sa študent pohybuje v obsahu kurzu a ako odpovedá na úlohy. V prvom kroku sa preto zostaví matica mikrolekcií (obsah aj úlohy) a pre každého používateľa sa zaznamená čas strávený pri jednotlivých položkách. Keďže mikrolearning prirodzene umožňuje opakované pokusy, tá istá úloha sa môže objaviť viackrát. V tejto štúdii sa však RGB hodnotí len pri prvom kontakte s úlohou, a preto sa do analýzy berú iba prvé odpovede používateľa na každú otázku.

Rýchlosť čítania sa ukazuje ako dôležitá premenná pri zoskupovaní študentov, pretože priamo ovplyvňuje, ako rýchlo dokážu spracovať zadanie ešte pred samotným riešením úlohy. Bez zohľadnenia tejto variability sa môžu krátke reakčné časy mylne interpretovať ako nízka angažovanosť, hoci v skutočnosti odrážajú iba rýchle čítanie alebo vyššiu plynulosť práce s textom (Wise & Kong, 2005), (Pools, 2022). Preto sa ako jeden z parametrov uvažuje i čas spracovania pevného počtu znakov – časové údaje pre ďalšie spracovanie normalizujú podľa dĺžky textu. Na úrovni kurzu sa rozsah jednotlivých mikrolekcií určil ako počet znakov v obsahu alebo v otázke (vrátane znakov v možnostiach odpovede) a časy pri obsahových mikrolekciách aj otázkach sa štandardizovali na 100 znakov. V tejto

štúdiu sa nezohľadňujú obrázky ani počet možností odpovede; pracuje sa iba s celkovým počtom znakov.

Mapovanie atribútov. Integráciou logov s výberom prvých výskytov odpovedí sa vytvorila matica obsahujúca 580 používateľov so 643 mikrolekciami. Položka matice predstavuje čas, ktorý i-ty používateľ strávil pri j-tej položke, meraný od zobrazenia po opustenie (pri obsahu) alebo po odoslanie na vyhodnotenie (pri otázkach). Ak používateľ mikrolekciu nedokončil alebo neodoslal odpoveď, položka má hodnotu 0. Aby sa v jednej hodnote spojila správnosť a čas prvého pokusu, časové údaje pre nesprávne odpovede sa kódovali so záporným znamienkom. Tento krok zároveň zjednodušuje vizualizáciu (pozri Obr. 5).

Čistenie dát a filtrovanie. Vytvorená matica obsahuje viacero atribútov, pri ktorých je súvis s RGB nepravdepodobný alebo sa nedá rozumne preukázať. Preto sa v prvom kroku odstránili stĺpce reprezentujúce iné aktivity, než ktoré sú relevantné pre analýzu RGB. Zostali tri typy položiek:

- **Mikroobsah (typ 1)** – čas (v sekundách), počas ktorého bol edukatívny obsah zobrazený; zjednodušene sa interpretuje ako čas čítania.
- **Krátka odpoveď (typ 2)** – čas potrebný na prečítanie a zodpovedanie otázky s krátkou voľnou odpoveďou; tento typ otázok môže slúžiť aj ako alternatívny indikátor čítania (správna odpoveď predpokladá prečítanie zadania).
- **Otázka s výberom jednej odpovede (typ 3)** – výber jednej správnej možnosti; ide o štandardný typ položky používaný na identifikáciu RGB. V matici je uložený čas odpovede, pričom znamienko vyjadruje správnosť.

Po tomto výbere sa matica zredukovala z 643 na 293 stĺpcov: 177 položiek typu 1, 50 položiek typu 2 a 66 položiek typu 3.

Následne sa vyradili používatelia, ktorí v kurze nemali žiadne relevantné odpovede (ani správne, ani nesprávne), ako aj servisné účty (učitelia, administrátori) a ďalšie záznamy, ktoré nereprezentovali študijné správanie. Po filtrácii zostalo 494 z pôvodných 580 používateľov.

Výpočet odvodených premenných. Z pripraveného datasetu sa odvodili premenné potrebné pre identifikáciu RGB štandardnými postupmi a premenné popisujúce čitateľské/odpovedové tempo a výkon pri prvých pokusoch.

Normalizácia časov sa realizovala podľa vzťahu (1):

$$T'_{ij} = \frac{T_{ij}}{L_j} \times 100 \quad (1)$$

kde T'_{ij} je čas normalizovaný na 100 znakov pre i -teho používateľa pri j -tej mikrolekcii, T_{ij} je nameraný čas a L_j je počet znakov v j -tej mikro-lekcii.

Pri otázkach sa osobitne sleduje čas pre správne a nesprávne odpovede. Všade sa používa **medián** (nie priemer) a nulové hodnoty sa ignorujú, keďže typicky znamenajú preskočenie položky. Nasledovné premenné reprezentujú rýchlosť čítania a odpovedania:

- $Cont1_T$ – medián normalizovaných časov čítania obsahových mikrolekcií (typ 1),
- M_Cor_T – medián času prvého pokusu pre otázky typu 2 a 3, ak bol prvý pokus správny,
- M_InCor_T – medián času prvého pokusu pre otázky typu 2 a 3, ak bol prvý pokus nesprávny,
- $Cor2_T$ – medián času prvého pokusu pre typ 2, správne,
- $InCor2_T$ – medián času prvého pokusu pre typ 2, nesprávne,
- $Cor3_T$ – medián času prvého pokusu pre typ 3, správne,
- $InCor3_T$ – medián času prvého pokusu pre typ 3, nesprávne.

Ďalšia skupina reprezentuje výkon, úspešnosť a angažovanosť:

- *Good2* – počet správnych odpovedí na otázky typu 2 pri prvom pokuse,
- *Bad2* – počet nesprávnych odpovedí na otázky typu 2 pri prvom pokuse,
- *Good3* – počet správnych odpovedí na otázky typu 3 pri prvom pokuse,
- *Bad3* – počet nesprávnych odpovedí na otázky typu 3 pri prvom pokuse,
- *Perc2* – podiel správnych odpovedí pri type 2, počítaný len z riešených úloh (nie zo všetkých),
- *Perc3* – podiel správnych odpovedí pri type 3, počítaný len z riešených úloh,
- *Solved* – podiel riešených úloh (typ 2 alebo 3) zo všetkých úloh bez ohľadu na správnosť; aproximuje mieru angažovanosti v riešení,
- *DoneToAll* – úspešnosť vyjadrená ako počet úloh vyriešených na prvý pokus vzhľadom na celkový počet úloh typu 2 a 3 v kurze,
- *Non_1* – podiel „neprečítaných“ obsahových mikrolekcií (typ 1); zachytáva, do akej miery sa študent sústreďí primárne na riešenie úloh bez práce s obsahom.

Dátová analýza

Analýza je rozdelená do troch logických fáz:

- detekcia RGB na úrovni celého súboru,
- vytvorenie viac homogénnych skupín študentov na základe behaviorálnych a výkonových charakteristík
- porovnanie výsledkov získaných globálnym prístupom s výsledkami odhadovanými separátne v rámci týchto skupín.

Najprv sa odhadne výskyt RGB pomocou etablovaných postupov z oblasti testovania, doplnených o štyri vlastné odvodené metriky, aby sa zachytil rozsah a základné charakteristiky rýchleho hádania v mikrolearningu. Následne sa určia premenné, v ktorých sa používatelia systematicky líšia (najmä rýchlosť práce s textom a výkon), a tieto rozdiely sa využijú na vytvorenie homogénnejších skupín. V poslednej fáze sa tie isté detekčné metódy aplikujú separátne v rámci každej skupiny a výsledky sa porovnávajú s globálnym prístupom. Cieľom je overiť, či odhad prahov a identifikácia RGB dosahujú vyššiu stabilitu a robustnosť, keď sa prahy neodvodzujú jednotne pre celú populáciu, ale prispôbujú sa homogénnejším podskupinám.

Na identifikáciu RGB sa použije sada metód inšpirovaná existujúcou literatúrou (Wise, 2019). Zvolená zostava pokrýva dva typy prístupu: metódu založenú iba na čase odpovede a metódy, ktoré kombinujú čas odpovede a úspešnosť (RTRA). Boli použité nasledovné metódy:

- **NT10** – referenčný prístup založený len na čase odpovede; prah RTT sa nastaví ako 10 % priemerného času odpovede na položku, s horným limitom 10 sekúnd (Wise & Ma, 2012).
- **RTRA-VI** – kombinovaný prístup čas + úspešnosť; ak je v dátach viditeľná bimodálna štruktúra, prah sa určí podľa prieniku distribúcií, inak sa postupuje po intervaloch a hľadá sa bod, kde úspešnosť presiahne úroveň náhodného tipovania (v duchu VITP-M v (Wise, 2019)).
- **RTRA-UP** – variant „zdola nahor“; RTT sa hľadá postupným prechodom intervalov od najkratších časov, pričom sa porovnáva úspešnosť s náhodným tipovaním a interval, na ktorom úspešnosť prekročí náhodu sa považuje za RTT.
- **RTRA-DOWN** – variant „zhora nadol“; štartuje od intervalu odvodeného z NT10 a postupuje smerom ku kratším časom, kým nájde hraničný interval podľa rovnakej logiky ako RTRA-UP.
- **CUMP** (kumulatívna proporčná metóda) – ako prah RTT sa určí sekundový interval, keď kumulatívna úspešnosť od času 0 po daný interval prvýkrát presiahne úroveň náhody; v experimente sa použijú dve implementácie:
 - **CUMP-UP** – kumulácia od najkratších časov smerom nahor,

Obr. 7 Výsledky identifikácie prahu času odozvy pomocou šiestich vybraných metód.

- **CUMP-DOWN** – zrkadlový variant, ktorý hľadá interval, kde sa správanie začne správať ako „pod úrovňou náhody“ (pričom sa začína klesať od hodnoty definovanej pomocou NT10 alebo NT20).


Prah RTT sa odhaduje pre každú otázku v sekundových intervaloch. Pri odhade úrovne náhody sa berie do úvahy len počet možností (pravdepodobnosť náhodného trafenia), nie dĺžka textu; cieľom je, aby sa metódy dali porovnať v jednotnom nastavení.

Výsledky identifikácie RTT naprieč metódami sumarizuje Obr. 7. Pri niektorých položkách môžu metódy produkovať aj nezvyčajne vysoké prahy; ide o dôsledok algoritmického postupu a v diskusii sa k tomu vraciame ako k praktickému limitu, ktorý si môže vyžadovať stropovanie alebo jemnejšiu parametrizáciu.

V analyzovaných dátach (494 študentov, 66 otázok; spolu 32 604 potenciálnych odpovedí) bolo reálne zodpovedaných 18 449 položiek. Tabuľka 4 sumarizuje, koľko odpovedí označila každá metóda ako RGB a aký je ich podiel.

Novonavrhnuté metódy Up/Down majú nasledovné charakteristiky:

- UP postupy prechádzajú časové intervaly od najkratších odpovedí smerom k dlhším (t. j. od 1. sekundy ďalej). V každom intervale testujú jednoduchú logiku: je úspešnosť v tomto intervale už vyššia než by sa dalo vysvetliť náhodným tipovaním? Ak áno, metóda vyhodnotí, že už v tomto čase sa vyskytuje „riešenie“ (nie len hádanie), a často nastaví prah RTT veľmi nízko. Praktický dôsledok je, že stačí malý počet veľmi rýchlych, ale správnych odpovedí (napr. ľahká otázka, známy fakt, alebo opakovaná expozícia) a UP metóda začne považovať celé skoré pásmo za „legitímne“. To vedie k tomu, že RGB sa identifikuje len vtedy, keď je v úplne najkratších časoch úspešnosť konzistentne na úrovni náhody.
- DOWN postupy naopak začínajú v „bezpečnejšom“ bode – typicky pri časovej hranici odvodennej z NT10 (alebo z jej násobku) – a idú smerom ku kratším časom. V každom kroku



kontrolujú, či úspešnosť ešte stále vyzerá ako riešenie, alebo už padá na úroveň náhody. Týmto spôsobom sa DOWN metódy správajú konzervatívnejšie: neuspokoja sa s tým, že niekde na začiatku je pár správnych odpovedí, ale hľadajú hraničný bod, kde sa správanie začne meniť z „riešenia“ na „tipovanie“. V dátach, kde sa rýchle riešenia miešajú s rýchlym hádaním, to typicky vedie k vyššiemu a realistickejšiemu RTT než pri UP prístupe.

Tab. 10 Počet odpovedí identifikovaných ako RGB

metóda	NT10	RTRA-VI	RTRA-UP	RTRA-DOWN	CUMP-UP	CUMP-DOWN
počet odpovedí označených ako RGB	941	1866	192	1059	603	1464
podiel RGB	5.10%	10.11%	1.04%	5.74%	3.27%	7.94%

RTRA UP/DOWN pracujú s úspešnosťou po intervaloch (sekundách) samostatne, pričom tento prístup je citlivý na šum: v krátkych intervaloch môže byť málo odpovedí a pomery správnych/nesprávnych odpovedí kolíše. CUMP (kumulatívny) prístup rieši tento nedostatok: v každom kroku nehodnotí len aktuálny interval, ale všetky odpovede od času 0 po daný interval spolu. Kumulatívny pomer správnych odpovedí je stabilnejší (menej kolíše) a preto lepšie zachytí situácie, kde neexistuje ostrá hranica, ale skôr plynulý prechod: na úplnom začiatku dominuje tipovanie, potom sa postupne pridáva riešenie, až sa úspešnosť odseparuje od úrovne náhody. CUMP metódy tak dávajú prahy, ktoré sú menej extrémne (nie príliš nízke ani príliš vysoké) a lepšie reflektujú prechodové pásmo medzi dvoma režimami správania.

Metódy typu **UP** majú tendenciu zastaviť sa veľmi skoro: ak je už v prvých intervaloch úspešnosť nad úrovňou náhody, metóda prirodzene RGB neoznačí. Naopak, **DOWN** varianty bývajú citlivejšie, lebo štartujú z konzervatívnejšieho prahu a systematicky kontrolujú, kde sa úspešnosť začne správať ako riešenie (nie ako tipovanie). **CUMP** prístupy sú jemnejšie v tom, že pracujú s kumulatívnou informáciou a lepšie zachytia prechodové pásma.

NT10 tu funguje ako jednoduchá referenčná línia: poskytuje stabilný, ľahko interpretovateľný prah odvodený z typického času odpovede na danú položku a umožňuje porovnávať, či ostatné metódy označujú RGB výrazne prísnejšie alebo benevolentnejšie.

Identifikácia skupín. Aby sa dalo správanie porovnávať naprieč položkami s rôznou dĺžkou textu, všetky časy odpovedí sa už v predspracovaní normalizovali na čas na 100 znakov. Zároveň sa odvodenými premennými zachytila rýchlosť práce s textom a výkon/angažovanosť pri riešení úloh (Wise & Kong, 2005), (Nagy et al., 2023), (Pools, 2022) sa ako cieľové rozlíšenie uvažujú kombinácie (**rýchle/pomalé čítanie**) × (**vysoký/nízky výkon**).

Najprv sa analyzovala korelačná štruktúra odvodených premenných (Tab. 11) a odstránili sa silne redundantné ukazovatele. Výrazná väzba medzi *Solved* a *DoneToAll* (a zároveň negatívny vzťah k *Non_1*) ukazuje, že tieto premenné nesú podobnú informáciu o angažovanosti a úspešnosti. Z praktických dôvodov sa ponechala premenná *DoneToAll*, ktorá najlepšie sumarizuje dokončovanie úloh aj výkon v kurze.

Premenné *M_Cor_T* a *M_InCor_T* sa vyradili, keďže agregujú typy otázok (2 a 3) a sú menej špecifické než časové ukazovatele viazané na konkrétny typ položky. Z dvojice *Cor3_T* a *InCor3_T* sa pre ďalšiu analýzu ponechala *Cor3_T* ako reprezentatívny čas úspešnej odpovede pri type 3.

Tab. 11 Korelačná matica odvodených premenných.

	M_COR_T	M_INCOR_T	COR2_T	INCOR2_T	COR3_T	INCOR3_T	PERC2	PERC3	SOLVED	DONETOALL	NON_1
CON	0.33	0.53	0.23	0.29	0.44	0.47	0.13	0.43	0.07	0.16	-0.14
T1_T											
M_COR_T		0.47	0.59	0.34	0.76	0.42	0.23	0.09	0.03	0.07	-0.06
M_INCOR_T			0.24	0.45	0.64	0.85	0.1	0.54	0.01	0.12	-0.07
COR2_T				0.28	0.35	0.15	-0.07	-0.02	-0.05	-0.06	0.03
INCOR2_T					0.28	0.24	0.08	0.07	-0.02	0	0.01
COR3_T						0.63	0.16	0.34	0.11	0.19	-0.15
INCOR3_T							0.19	0.46	-0.03	0.07	-0.03
PERC2								0.39	-0.03	0.13	0.04
PERC3									0.04	0.26	-0.09
SOLVED										0.96	-0.96
DONETOALL											-0.94


Výber premenných a klastrovanie študentov. Po redukcii redundancie sa skupiny študentov hľadali pomocou k-means, pričom sa testovali jednoduché kombinácie premenných a ich schopnosť vytvárať konzistentné zhľuky. Najprv sa orientačne posúdil príspevok jednotlivých premenných cez Silhouette skóre pre 2–4 klastre (Tab. 12). Ako najsilnejšie a zmysluplné ukazovatele sa stabilne ukázali:

- *Cont1_T* (čas čítania obsahových mikrolekcií) ako priama aproximácia rýchlosti čítania,
- *DoneToAll* (podiel úloh splnených na prvý pokus vzhľadom na celkový rozsah kurzu) ako súhrnný ukazovateľ výkonu/angažovanosti.

Tab. 12 Silhouette score pre jednotlivé premenné v 2 – 4 klastroch.

premenná	SS 2 klastre	premenná	SS 3 klastre	premenná	SS 4 klastre
Cont1_T	0.945	InCor2_T	0.856	Cont1_T	0.700
InCor2_T	0.902	Cont1_T	0.693	InCor2_T	0.604
DoneToAll	0.733	DoneToAll	0.646	DoneToAll	0.551
Cor2_T	0.643	Perc2	0.572	Perc3	0.547
Perc3	0.594	Perc3	0.557	Cor3_T	0.532
Perc2	0.583	Cor3_T	0.523	Cor2_T	0.531
Cor3_T	0.523	Cor2_T	0.522	Perc2	0.521

Následne sa otestovali kombinácie premenných pre $k = 2-6$ a vyhodnotili sa cez Silhouette a Davies–Bouldin index (Tab. 13). Ako najvhodnejšia a zároveň interpretačne čistá sa ukázala dvojica [*Cont1_T*, *DoneToAll*], pričom optimálny počet klastrov bol $k = 4$ (Obr. 8). Táto voľba zároveň priamo zodpovedá zamýšľanému rozlíšeniu rýchlostí práce s textom × výkon.



Obr. 8 Preskúmanie vzťahov odvodených premenných na kategorizáciu študentov na základe ich silhouette grafov.

Tab. 13 Súhrn kombinácií premenných pre zhľukovanie metódou k-means – výber najvhodnejších kombinácií spolu s poradím vhodnosti podľa Silhouette koeficientu a Davies–Bouldinovho indexu.


Kombinácia premenných	Počet klastrov	Silhouette score	Davies-Bouldin index	Silhouette score poradie	Davies-Bouldin index poradie
Cont1_T + DoneToAll	4	0.498	0.656	2	1
Perc2 + DoneToAll	3	0.522	0.679	1	2
Perc3 + DoneToAll	4	0.48	0.691	4	3

Kombinácia premenných	Počet klastrov	Silhouette score	Davies-Bouldin index	Silhouette score poradie	Davies-Bouldin index poradie
Perc3 + DoneToAll	3	0.497	0.693	3	4
Cont1_T + DoneToAll	3	0.47	0.732	5	5

Výsledkom je rozdelenie študentov do štyroch skupín (Obr. 9):

- rýchle čítanie + vysoký výkon (n = 104),
- pomalé čítanie + vysoký výkon (n = 89),
- rýchle čítanie + nízky výkon (n = 186),
- pomalé čítanie + nízky výkon (n = 115).

Obr. 9 Vizualizácia klastrovaných dát



Toto členenie sa ďalej používa ako základ pre skupinový odhad prahov RTT a porovnanie s globálnym prístupom v ďalšej časti analýzy.

Identifikácia RGB na úrovni klastrov. V záverečnej fáze sa detekcia rýchleho hľadania nevyhodnocuje iba na úrovni celého súboru, ale osobitne v skupinách študentov definovaných dvoma dimenziami tempom práce s textom a výkonom. Dôvod tohto prístupu je metodický: globálna detekcia predpokladá jeden časový prah RTT použiteľný pre celú populáciu avšak v heterogénnej vzorke rozdiely v rýchlosti čítania a v úrovni znalostí spôsobujú, že rovnaký prah môže byť pre rôzne podskupiny systematicky neekvivalentný (pre niekoho príliš prísny, pre iného príliš benevolentný).

Pracovný predpoklad je preto nasledovný: ak zhlukovanie zníži heterogenitu v relevantných faktoroch, odhad RTT bude konzistentnejší a výsledné označenie RGB férovejšie než pri jednom prahu pre všetkých. Následne sa rovnaké detekčné postupy aplikujú globálne aj v skupinách a porovná sa, do akej miery sa výsledky líšia.

NT10 je zvolený ako jednoduchý referenčný prístup: ignoruje správnosť a pracuje iba s časovým prahom odvodeným z typického času odpovede. O to lepšie sa na ňom ukáže, či segmentácia mení „časový obraz“ položiek a tým aj označenie RGB. Porovnanie je zobrazené v Tab. 14.

Tab. 14 Identifikácia RGB metódou NT10 v zhlukoch a v celom datasete.

Skupina / zhluk	RGB identifikácie	Počet zodpovedaných otázok	Podiel RGB	Odlišné označenia (globál vs. zhluk)	Zhodné označenia (globál vs. zhluk)
Celý súbor	941	18,449	5.10%		
3 – rýchle čítanie + vysoká úspešnosť	337	6,570	5.13%	132	326
2 – pomalé čítanie + nízka úspešnosť	24	2,108	1.14%	12	15
1 – rýchle čítanie + nízka úspešnosť	205	4,194	4.89%	213	200
0 – pomalé čítanie + vysoká úspešnosť	89	5,577	1.60%	27	65
Súhrn				384	606

V NT10 sa výrazne ukazuje rozdiel medzi rýchlymi a pomalými čitateľmi: zhľuky s pomalším tempom majú nízke podiely RGB (1–2%), zatiaľ čo rýchli čitatelia sú bližšie globálnemu priemeru (5%). Dôležitá je aj zhoda s globálnym prístupom: približne **38.8%** (384 z 990) označení sa pri zhľukovej aplikácii zmení, čo signalizuje, že globálny prah nemusí byť neutrálny naprieč skupinami.

RTRA-VI dopĺňa čisto časové pravidlá o štruktúru dát: snaží sa zachytiť bimodálne rozdelenie časov a/alebo nájst interval, kde úspešnosť prekročí úroveň náhodného tipovania. V menších zhľukoch (najmä pomalí čitatelia) však častejšie naráža na problém riedkych dát v prvých intervaloch, čo môže viesť k nulovým RTT.

Tab. 15 Identifikácia RGB metódou RTRA-VI v zhľukoch a v celom datasete.

Skupina / zhluk	RGB identifikácie	Počet zodpovedaných otázok	Podiel RGB	Odlíšné označenia (globál vs. zhluk)	Zhodné označenia (globál vs. zhluk)
Celý súbor	1,866	18,449	10.11%		
3 – rýchle čítanie + vysoká úspešnosť	946	6,570	14.40%	339	738
2 – pomalé čítanie + nízka úspešnosť	99	2,108	4.70%	90	41
1 – rýchle čítanie + nízka úspešnosť	981	4,194	23.39%	512	581
0 – pomalé čítanie + vysoká úspešnosť	208	5,577	3.73%	139	150
Súhrn				1,080	1,510

Tu sa rozdiel medzi skupinami ešte zvýrazní: rýchli čitatelia, najmä s nízkou úspešnosťou, majú najvyššie RGB (23.39%). Zároveň sa mení aj samotné označovanie položiek: približne 41.7% (1,080 z 2,590) rozhodnutí sa líši oproti globálnemu pohľadu (Tab. 15).

UP postupy majú typický „skorý stop“ efekt: ak už v prvých intervaloch úspešnosť presiahne úroveň náhody, metóda nemá dôvod označiť RGB a prah môže zostať nízky alebo nulový. To sa prejaví aj nízkymi globálnymi podielmi RGB. Pre RTRA-UP sú výsledky sumarizované v Tab. 16.

Tab. 16 Identifikácia RGB metódou RTRA-UP v zhľukoch a v celom datasete.

Skupina / zhluk	RGB identifikácie	Počet zodpovedaných otázok	Podiel RGB	Odlíšné označenia (globál vs. zhluk)	Zhodné označenia (globál vs. zhluk)
Celý súbor	192	18,449	1.04%		
3 – rýchle čítanie + vysoká úspešnosť	72	6,570	1.10%	72	41
2 – pomalé čítanie + nízka úspešnosť	35	2,108	1.66%	34	2
1 – rýchle čítanie + nízka úspešnosť	126	4,194	3.00%	113	54
0 – pomalé čítanie + vysoká úspešnosť	60	5,577	1.08%	62	5
Súhrn				281	102

Hoci absolútne podiely RGB sú nízke, rozdiel v označení oproti globálnemu pohľadu je obrovský: **73%** (281 z 383) rozhodnutí sa zmení. To je dôležitý signál, že táto metóda je veľmi citlivá na lokálnu štruktúru dát v skupine.

DOWN postupy vychádzajú z konzervatívnejšieho východiska (napr. NT10) a systematicky hľadajú bod, kde sa úspešnosť prestáva správať ako tipovanie. V praxi bývajú stabilnejšie než UP, no stále reagujú na rozdiely medzi skupinami. RTRA-DOWN je sumarizovaná v Tab. 17.

Tab. 17 Identifikácia RGB metódou RTRA-DOWN v zhlukoch a v celom datasete.

Skupina / zhluk	RGB identifikácie	Počet zodpovedaných otázok	Podiel RGB	Odlišné označenia (globál vs. zhluk)	Zhodné označenia (globál vs. zhluk)
Celý súbor	1,059	18,449	5.74%		
3 – rýchle čítanie + vysoká úspešnosť	474	6,570	7.21%	121	431
2 – pomalé čítanie + nízka úspešnosť	23	2,108	1.09%	23	11
1 – rýchle čítanie + nízka úspešnosť	223	4,194	5.32%	217	217
0 – pomalé čítanie + vysoká úspešnosť	116	5,577	2.08%	42	87
Súhrn				403	746

RTRA-DOWN ukazuje konzistentný obraz: pomalí čitatelia majú nízke RGB, rýchli vyššie (najmä zhluk 3). Z hľadiska zhody s globálom je rozdiel menší než pri UP: **35.1%** (403 z 1,149) rozhodnutí sa líši.

CUMP-UP používa kumulatívnu úspešnosť od času 0 po aktuálny interval. Je presnejší než RTRA-UP, ale stále môže reagovať na to, že v prvotných intervaloch úspešnosť lokálne prekročí náhodu.

Tab. 18 Identifikácia RGB metódou CUMP-UP v zhlukoch a v celom datasete.

Skupina / zhluk	RGB identifikácie	Počet zodpovedaných otázok	Podiel RGB	Odlišné označenia (globál vs. zhluk)	Zhodné označenia (globál vs. zhluk)
Celý súbor	603	18,449	3.27%		
3 – rýchle čítanie + vysoká úspešnosť	213	6,570	3.24%	254	125
2 – pomalé čítanie + nízka úspešnosť	64	2,108	3.04%	54	12
1 – rýchle čítanie + nízka úspešnosť	341	4,194	8.13%	238	159
0 – pomalé čítanie + vysoká úspešnosť	168	5,577	3.01%	145	53
Súhrn				691	349

Najvýraznejšie vyčnieva zhluk 1 (rýchli + nízka úspešnosť), kde RGB stúpne na 8.13%. Zhoda s globálom je nízka: **66.4%** (691 z 1,040) označení sa líši.

CUMP-DOWN analyzuje kumulatívnu úspešnosť v opačnom smere: začína od vyššieho limitu (tu NT20) a hľadá bod, kde sa správanie prestáva javiť ako riešenie. Táto varianta často stabilizuje problém lokálneho preváženia náhody v nízkych intervaloch.

Tab. 19 Identifikácia RGB metódou CUMP-DOWN v zhlukoch a v celom datasete.

Skupina / zhluk	RGB identifikácie	Počet zodpovedaných otázok	Podiel RGB	Odlišné označenia (globál vs. zhluk)	Zhodné označenia (globál vs. zhluk)
Celý súbor	1,464	18,449	7.94%		
3 – rýchle čítanie + vysoká úspešnosť	494	6,570	7.52%	408	387
2 – pomalé čítanie + nízka úspešnosť	41	2,108	1.94%	40	27
1 – rýchle čítanie + nízka úspešnosť	412	4,194	9.82%	367	303
0 – pomalé čítanie + vysoká úspešnosť	166	5,577	2.98%	108	110
Súhrn				923	827

Aj tu je obraz stabilný: pomalí čitatelia majú RGB nízke, rýchli (najmä s nízkou úspešnosťou) vysoké. Rozdiel oproti globálnemu pohľadu je napriek tomu **52.7%** (923 z 1,750) označení.

Štatistická významnosť rozdielov

Keďže zhluková aplikácia metód dáva systematicky iné označenia než globálna, hodnotí sa, či ide o náhodné odchýlky alebo o štatisticky významný posun. Na porovnanie dvoch párových binárnych meraní (RGB = 1 / nie-RGB = 0) je vhodný McNemarov test (Gönen, 2004), kde *Meranie 1* predstavuje globálne označenie na celom datasete a *Meranie 2* je kombinované označenie získané z aplikácie metódy v klastroch.

Tab. 20 Vstupy a výsledky McNemarovho testu pre použité metódy

Metóda	b (zhluky = 1, globál = 0)	c (zhluky = 0, globál = 1)	χ^2	p-hodnota	Veľkosť efektu
NT10	49	335	213.010	0	0.744 – veľký
RTRA-VI	724	356	125.392	0	0.34 – stredný
RTRA-UP	191	90	36.302	0	0.359 – stredný
RTRA-DOWN	90	313	123.397	0	0.553 – veľký
CUMP-UP	437	254	48.465	0	0.265 – stredný
CUMP-DOWN	286	637	133.479	0	0.38 – stredný

Vo všetkých prípadoch sa nulová hypotéza zamietá (p-hodnoty sú v tabuľke zaokrúhlené na 0; prakticky ide o $p < 0.001$). To znamená, že rozdiel medzi globálnym a zhlukovým označením nie je náhodný, ale systematický. Z hľadiska praktickej významnosti sú efekty prevažne stredné až veľké; najvýraznejší posun vychádza pri NT10 a RTRA-DOWN.

Diskusia a záver

Výsledky ukazujú, že základné metódy vyvinuté a validované v kontexte tradičného testovania je možné aplikovať aj v mikrolearningu a že pri rozumnej interpretácii poskytujú zmysluplné výstupy. V prvom rade je dôležité, že odhady podielu RGB na úrovni položiek sa pohybujú v porovnateľných rádoch ako v literatúre, čo podporuje predpoklad, že mikrolearning neprodukuje „iný“ fenomén, ale skôr fenomén rovnakého typu v odlišnom režime interakcie.

Čisto časová metóda NT10, ktorá pracuje len s reakčným časom, identifikovala v súbore 494 študentov 5.10 % odpovedí ako podozrivé z RGB. Tento výsledok je konzistentný s publikovanými odhadmi z prostredia testovania, kde sa pri NT prístupoch uvádzajú podobné úrovne (napr. približne 5.74 % v štúdiu s ôsmakmi (Svetina Valdivia et al., 2023), 5.44 % v PISA dátach (Michaelides et al., 2020), alebo 3.6–5.6 % v závislosti od študijného kontextu (Wise & Gao, 2017)). Takýto súlad je metodicky významný: naznačuje, že aj v nízko-stakes mikrolearningu existuje stabilne merateľná vrstva správania s nízkou angažovanosťou, ktorú je možné zachytiť prahovým prístupom založeným na čase.

Metóda RTRA-VI, zvolená ako vizuálne-inšpirovaný variant využívajúci bimodalitu rozdelenia a kontrolu nad úrovňou náhody v duchu metodických zlepšení (Wise, 2019), identifikovala 10.11 % podozrivých odpovedí. Tento rozsah je v súlade s odhadmi uvádzanými v prístupoch typu RTE (11.34 %) a zároveň je kompatibilný so staršími reportmi, kde Schnipke uvádza aj výrazne vyššie podiely v závislosti od položiek (18–30 %) (Schnipke & Scrams, 2005). Z toho vyplýva, že aj keď mikrolearningové položky môžu mať odlišný didaktický účel než štandardizované testové položky, empirické signály spájané s RGB (krátke časy, zmenený vzťah času a správnosti) sa v dátach objavujú spôsobom, ktorý je zachytiteľný rovnakými triedami postupov.

Prenositelnosť však treba chápať opatrne: to, že metódy poskytujú porovnateľné rády výskytu, ešte neznamena, že budú rovnako robustné a rovnako interpretovateľné v každom mikrolearningovom nastavení. Mikrolearning sa od testovania líši najmä tým, že úlohy často slúžia na bezprostredné upevnenie obsahu, práca je rozložená v čase, opakovanie je bežné a motivácia či pozornosť môžu byť volatilnejšie. To sa môže premietiť do tvaru rozdelení reakčných časov aj do vzťahu reakčný čas –

úspešnosť, ktorý priamo využívajú metódy typu RTRA/CUMP. Okrem toho je realistické očakávať vyššiu heterogenitu kvality položiek (formulácia, jednoznačnosť, náročnosť), čo môže meniť úroveň „náhody“ v krátkych intervaloch a zvyšovať citlivosť algoritmov na lokálne fluktuácie v dátach.

Práve v tomto bode je analyticky dôležité, že porovnané metódy sa v mikrolearningu nelíšia iba prísnosťou, ale aj citlivosťou na šum a veľkosť vzorky. UP varianty (RTRA-UP, CUMP-UP) postupujú od najkratších intervalov smerom nahor. Ak už v prvých intervaloch úspešnosť presiahne úroveň náhody, algoritmus prirodzene uzatvára, že ide o riešenie, a RGB v danom režime neoznačí. V mikrolearningových dátach, najmä pri menších skupinách, sa však môže stať, že takýto „nadprahový“ signál vznikne aj náhodne, pretože počet odpovedí v prvých intervaloch je nízky. Tento efekt sa zosilňuje pri položkách s viacerými možnosťami (napr. až osem), kde aj malý absolútny počet správnych odpovedí môže stačiť na prekročenie očakávanej úrovne náhody. V tomto svetle je interpretovateľné, prečo UP varianty v globálnej analýze identifikovali nízke podiely RGB (RTRA-UP 1.04 %, CUMP-UP 3.27 %) a prečo sú ich výsledky náchylnejšie na zmeny pri rozklade dát na menšie skupiny.

Naopak, DOWN varianty (RTRA-DOWN, CUMP-DOWN) štartujú z konzervatívnejšieho horného prahu naviazaného na NT10 (resp. jeho rozšírenia) a hľadajú bod, kde sa úspešnosť začne správať ako tipovanie. Tým sa znižuje riziko, že algoritmus „zastaví“ príliš skoro len na základe náhodne priaznivého prvého intervalu. Osobitne CUMP-DOWN je konštrukčne opretý o kumulatívnu logiku a nadväzuje na vývoj v literatúre (H. Guo et al., 2016), čo podporuje jeho interpretáciu ako metodicky robustnejšieho kandidáta pre mikrolearningový kontext. Aj v tomto prípade však platí, že priestor na zlepšenie môže existovať (napr. harmonizácia susedných intervalov), čo je tematizované aj v relevantných prehľadoch (Wise & Gao, 2017). Celkovo sa tak dá povedať, že prenositeľnosť klasických metód je najpresvedčivejšia pri postupoch, ktoré sú menej závislé od prvých intervalov a viac využívajú kumulatívnu informáciu alebo konzervatívny štartovací bod (DOWN, CUMP), nie pri postupoch, ktoré robia skoré rozhodnutie v najnižších intervaloch (UP).

Druhá časť výskumnej otázky sa týka toho, či sa robustnosť a férovosť detekcie zlepší, ak sa prahy RTT neodhadujú globálne, ale v homogénnejších skupinách študentov definovaných spracovaním obsahu a výkonom. Tento predpoklad stojí na jednoduchom, no metodicky dôležitom fakte: reakčný čas nie je len indikátor angažovanosti, ale aj indikátor schopnosti spracovať text a zorientovať sa v položke. Pri populácii heterogénnej v rýchlosti čítania môže jeden globálny RTT prah systematicky znevýhodňovať pomalších čitateľov (označí ich rýchle odpovede ako pomalé, teda legitímne) alebo naopak prehliadať rýchle tipovanie u rýchlych čitateľov (ktoré sa pri globálnom prahu stratí v nízkych intervaloch). Podobne heterogenita výkonu mení distribúciu správnych odpovedí v intervaloch, a tým priamo ovplyvňuje prahové rozhodovanie v metódach založených na prekročení úrovne náhody.

Voľba segmentačných premenných v tejto štúdii je preto metodicky odôvodnená. Rýchlosť čítania sa v literatúre objavuje ako relevantná premenná pri zoskupovaní a interpretácii správania v testovaní aj v prístupoch typu RTE (Wise & Kong, 2005), (Pools, 2022). Zároveň výkonové a pravdepodobnostné charakteristiky úspešnosti sa ukazujú ako dôležité prvky pre následné vysvetľovanie variability správania a jeho dopadov (Nagy et al., 2023), (Rios & Soland, 2022). Zhlukovanie založené na Cont1_T (tempo práce s obsahom) a DoneToAll (miera úspešného dokončenia úloh) tak nepredstavuje ad hoc rozhodnutie, ale realizuje princíp kalibrácie: prahy sa odhadujú v skupinách, v ktorých má čas odpovede podobný význam z hľadiska spracovania textu a v ktorých je rozdelenie úspešnosti dostatočne homogénne na to, aby metódy typu RTRA/CUMP neboli deformované heterogenitou populácie.

Kľúčový empirický výsledok je, že segmentácia pred detekciou vedie k systematicky odlišným výstupom než globálny prístup. Nejde o marginálne rozdiely, ale o zmeny na úrovni stoviek položiek pri viacerých metódach. Pri NT10 sa rozdiel medzi globálnym a zhukovým označením týkal 384 z 990 položiek; pri RTRA-VI 1080 z 2590; pri CUMP-DOWN 923 zo 1750. Takéto rozdiely sú metodicky relevantné už samy

osebe, lebo ukazujú, že „jeden prah pre všetkých“ nie je invariantný voči prirodzenej heterogenite používateľov.

Zároveň sa ukazuje, že zmeny nie sú náhodné: McNemarov test, použitý na porovnanie párových binárnych označení RGB (globál vs. agregovaný zhlukový výsledok), zamietá nulovú hypotézu pre všetky metódy pri hladine významnosti 0.05 s p-hodnotami prakticky nulovými. Efekty sa pohybujú od stredných po veľké (napr. NT10 veľký efekt, RTRA-DOWN veľký efekt), čo podporuje interpretáciu, že rozdiel medzi globálnym a zhlukovým prístupom má nielen štatistický, ale aj praktický význam. V kontexte integrovanej RQ je to priamy argument, že segmentácia pred detekciou mení detekciu RGB systematicky a nie iba v dôsledku náhodného kolísania.

Ďalším konzistentným vzorom je, že najvyššie podiely RGB sa naprieč metódami objavujú v zhluku „rýchli čitatelia + nízky výkon“. Tento výsledok je očakávateľný aj teoreticky: práve v tejto skupine sa kombinuje schopnosť veľmi rýchlo prejsť položkou s nižšou úspešnosťou, čo zvyšuje pravdepodobnosť krátkych intervalov s úspešnosťou blízkou náhode. Zároveň pomalšie skupiny vykazujú výrazne nižšie podiely RGB pri viacerých metódach (napr. NT10 približne 1–1.6 %, CUMP-DOWN približne 1.9–3.0 %), čo naznačuje, že segmentácia redistribuuje detekciu RGB smerom k skupinám, kde má behaviorálny zmysel, namiesto toho, aby plošne „zvyšovala“ podiel nízkej angažovanosti.

Vzhľadom na formuláciu výskumnej otázky je vhodné rozlíšiť dve roviny robustnosť/férovosť prahov a presnosť voči základnej pravde. **Výsledky tejto štúdie poskytujú silnú oporu pre tvrdenie, že segmentácia zvyšuje metodickú adekvátnosť detekcie, pretože prahy sa kalibrujú v skupinách s podobným tempom spracovania textu a podobnou distribúciou výkonu, čo znižuje riziko systematickej chyby,** ktorá vzniká pri použití jedného globálneho RTT prahu pre heterogénnu populáciu. Na druhej strane, bez externého označenia (ground truth) nie je možné priamo tvrdiť „vyššiu presnosť“ v zmysle klasickej klasifikačnej validity. Preto je presnejšie hovoriť o zvýšení robustnosti a férovosti prahov a o znížení pravdepodobnosti, že detekcia bude skreslená heterogenitou čítania a výkonu. V tomto rámci je segmentácia interpretovateľná ako kalibračný krok, ktorý upravuje detekciu tak, aby reakčný čas v jednotlivých skupinách niesol porovnateľný význam.

Synteticky možno konštatovať, že metódy RGB detekcie vyvinuté pre tradičné testovanie sú do nízko-stakes mikrolearningu prenositeľné a produkujú porovnateľné rády výskytu nízkej angažovanosti (napr. NT10 - 5 %, RTRA-VI - 10 %, CUMP-DOWN - 8 %), ktoré korešpondujú s publikovanými výsledkami (Wise & Gao, 2017), (Svetina Valdivia et al., 2023), (Michaelides et al., 2020). Zároveň sa však ukazuje, že mikrolearningový kontext zvýrazňuje citlivosť niektorých algoritmických voľieb, najmä v UP variantoch, kde môže malá vzorka a viac možností odpovede viesť k skorému prekročeniu úrovne náhody a k podhodnoteniu RGB. Robustnejšie pôsobia postupy opreté o kumulatívnu informáciu a konzervatívny štart, čo je konzistentné s metodickým smerovaním v literature (H. Guo et al., 2016), (Wise, 2019), pri zachovaní vedomia, že aj tieto prístupy možno ďalej stabilizovať harmonizáciou intervalov (Wise & Gao, 2017).

Druhá časť otázky je podporená ešte priamočiarejšie: segmentácia študentov podľa indikátorov spracovania obsahu a výkonu (Cont1_T, DoneToAll) vedie k štatisticky významne odlišnej detekcii RGB oproti globálnemu prístupu, čo potvrdzuje McNemarov test (Göner, 2004). Prirodzené rozdiely v rýchlosti čítania a výkone teda nie sú len „šum“, ale štruktúra, ktorá má priamy dopad na odhad prahov RTT. Odhad prahov v homogénnejších skupinách preto zvyšuje metodickú férovosť a robustnosť detekcie tým, že redukuje systematické skreslenie spojené s aplikáciou jedného prahu na heterogénnu populáciu.

Výsledky ukazujú, že postupy detekcie rýchleho hľadania vyvinuté pre tradičné testovanie sú v mikrolearningu použiteľné a poskytujú interpretovateľné signály nízkej angažovanosti. Zároveň sa však

potvrďuje, že mikrolearningový kontext (odlišný účel položiek, flexibilný režim práce a kolísajúca motivácia) zvyšuje nároky na kalibráciu prahov a na opatrnú interpretáciu výsledkov.

Kľúčovým metodickým zistením je, že segmentácia študentov podľa tempa práce s textom a výkonu mení označenie RGB systematicky, nie náhodne: prahy odvodené v homogénnejších skupinách vedú k odlišným a štatisticky významným výsledkom oproti globálnemu prístupu. To podporuje záver, že „jeden prah pre všetkých“ môže byť v heterogénnej populácii nespravodlivý a menej stabilný, zatiaľ čo skupinová kalibrácia je vhodným krokom dátovej sanitácie pred downstream analýzami.

Praktický prínos práce spočíva v tom, že prepája klasické RGB metodiky s mikrolearningovou praxou a ukazuje, ako jednoduché indikátory spracovania obsahu a výkonu môžu zlepšiť robustnosť detekcie. Limitom zostáva veľkosť vzorky po segmentácii a fakt, že testované algoritmické varianty neboli optimalizované; ďalší výskum by sa mal zamerať na stabilnejšie odhady prahov pri menších skupinách, na vplyv kvality položiek a na rozlíšenie medzi neinformatívnym tipovaním a strategickým využívaním opakovaných pokusov.

Prínos pre oblasť habilitácie

Prínos kapitoly zameranej na identifikáciu RGB časti pre oblasť habilitácie možno zhrnúť ako:

- Teoretický prínos spočíva v spresnení, že rapid guessing behavior nie je len technický artefakt merania, ale systematická forma nízkeho úsilia, ktorá narúša interpretáciu výkonu a môže odrážať odlišné motivačné režimy používateľov v mikroučení. Tým sa RGB prirodzene prepája s profilovaním používateľov a s interpretáciou ich správania v digitálnych prostrediach.
- Metodický prínos spočíva v tom, že RGB je formalizované ako detekovateľný vzorec správania založený na kombinácii časových a výkonových signálov, ktorý sa dá implementovať priamo v logoch bez dodatočných dotazníkov. Zároveň sa ukazuje potreba skupinovo špecifických prahov a interpretácie, pretože rovnaké pravidlo môže mať odlišnú chybovosť v rôznych kohortách (napr. podľa čitateľskej rýchlosti alebo náročnosti položiek), čo je v súlade so stability-first filozofiou.
- Praktický prínos spočíva v tom, že detekcia RGB zvyšuje férovosť a spoľahlivosť hodnotenia v mikroučení: umožňuje oddeliť nízke skóre z neznalosti od nízkeho skóre z nízkeho úsilia, a tým cielene voliť intervencie (úprava položiek, spätná väzba, pacing, adaptívna náročnosť) bez penalizácie používateľov, ktorí sa snažia.
- Pre multi-view modelovanie RGB predstavuje procesný signál kvality dát a angažovanosti, ktorý sa dá zaradiť ako samostatný pohľad alebo ako kontrolná vrstva pred integráciou. V multi-view profilovaní môže RGB slúžiť na váženie spoľahlivosti behaviorálnych a výkonových výstupov, na identifikáciu hraničných prípadov a na stabilnejšiu konštrukciu spoločného priestoru, keďže eliminuje časť šumu spôsobeného nízkym úsilím a neporovnateľnosťou medzi používateľmi.

Agregačná vrstva: mikro-persony zo sumárnych/transakčných logov

Personalizácia výučby sa v praxi stáva kľúčovou podmienkou zvyšovania efektívnosti učenia v prostredí rastúcej heterogenity študentov a obmedzených možností poskytovať včasnú a cieleňú spätnú väzbu (Imamah et al., 2024), (Aeiad & Meziame, 2019), (Abulibdeh, 2025). V programovaní tento trend ďalej zosilňuje nástup AI/ML a generatívnych nástrojov (GenAI), ktoré umožňujú adaptívnu správu obsahu, okamžité odporúčania a interaktívnu podporu pri riešení úloh (Lim et al., 2023). Zároveň však prinášajú aj nové riziká – najmä prehnanú oporu o asistenciu, oslabenie metakognície a intervencie, ktoré nemusia odrážať skutočné správanie študentov v čase (Kowitlawakul et al., 2024), (Ji et al., 2025).

Cieľom tejto kapitoly je rozvinúť jednotný, platformovo agnostický model pre návrh personalizácie vo virtuálnych prostrediach. Existujúce prístupy sú často ad-hoc, pevne viazané na konkrétne platformy a predpokladajú bohaté dáta, ktoré nie sú vždy dostupné (napr. detailné chybové stopy, hinty či explicitné znalostné stavy). Zriedkavejšie ponúkajú prenositeľný a opakovateľný proces, ktorý systematicky prepája zber signálov, profilovanie a (ak je relevantné) aj intervencie vrátane ich vhodného načasovania (Bauer et al., 2025). Z tohto dôvodu sa v tejto časti cieľi na **minimalistický, ale informatívny** súbor behaviorálnych indikátorov, ktorý je realizovateľný naprieč kurzami a systémami..

Programovanie predstavuje vhodnú doménu na empirické overenie takéhoto prístupu. Úlohy sú objektívne hodnotiteľné a prirodzene podporujú iteratívne zlepšovanie riešení (Fernandes et al., 2023). Zároveň však nie je vhodné tvrdiť, že správanie je bez hádania v absolútnom zmysle; aj v programovaní sa vyskytuje trial-and-error a opakované odovzdávanie bez porozumenia. Práve preto je dôležité opierať profilovanie o procesné signály. Protokoly automatizovaného hodnotenia (AAS) typicky nezachytávajú len výsledok, ale aj trajektóriu práce – počet a rozostupy pokusov, progres skóre vzhľadom na maximum, zmeny dĺžky riešenia či rytmus odovzdávania (Jan Skalka & Drlik, 2023). Tieto signály umožňujú odvodiť malé a interpretovateľné vzorce správania aj vtedy, keď sú dostupné iba ľahko získateľné protokolové dáta.

Praktickou otázkou tak zostáva nielen dostupnosť pokročilých dát a modelov, ale najmä to, či sa dá z minimálnych, bežne dostupných protokolov automatizovaného hodnotenia vytvoriť reprezentácia študenta, ktorá bude zároveň interpretovateľná a dostatočne stabilná na použitie naprieč úlohami, kurzami a potenciálne aj platformami. Model sa chápe ako open-loop proces *Zber dát – Profilovanie – Reprezentácia (micro-persóny) – Overenie*, kde výstup tvorí univerzálna reprezentačná vrstva použiteľná v rôznych implementáciách doplnených o kurikulárny kontext (pozícia úlohy v kapitole/kurze a náročnosť) a hrubý časový index odvodený z času odovzdania. Tým sa prirodzene formuluje nasledujúca výskumná otázka:

- **BEHA2: Ako navrhnuť a empiricky overiť jednotný, platformovo agnostický profilovací model vo virtuálnych (vzdelávacích) prostrediach, ktorý z minimálnych protokolových logov automatizovaného hodnotenia – doplnených o kurikulárny a časový kontext – konštruje malé, interpretovateľné a stabilné mikro-persony ako prenositeľnú reprezentáciu používateľa naprieč obsahom a systémami?**

Prehľad relevantných zdrojov

Personalizované učenie je všeobecne uznávané ako účinný spôsob zlepšovania výkonu učiacich sa. Odkláňa sa od prístupu „one-size-fits-all“, ktorý sa vzhľadom na rozmanitosť schopností, zručností a charakteristík študentov považuje za málo zmysluplný (Somasundaram et al., 2020), (Manorat et al., 2025). Študenti nie sú homogénne entity; prinášajú si odlišné zázemie, históriu učenia, záujmy, kognitívne štýly a široké spektrum kognitívnych aj emočných charakteristík. Táto diverzita znamená, že rôzni študenti majú odlišné štýly učenia, tempo a typické prekážky naprieč vekovými skupinami, predmetmi aj kultúrnymi kontextmi (Abulibdeh, 2025), (S. Y. Chen & Wang, 2021).

V tradičných podmienkach je poskytovanie spätnej väzby v reálnom čase na individuálnej úrovni často neuskutočniteľné z dôvodu limitovaných pedagogických kapacít (Deeva et al., 2021). Personalizované učenie je v tradičných prostrediach náročné a ekonomicky nevýhodné, avšak pokrok v AI pomáha tento cieľ približovať. Adaptívne vzdelávacie systémy (*Adaptive Learning Systems*, ALS) a inteligentné tutoriálne systémy (*Intelligent Tutoring Systems*, ITS) sú navrhnuté tak, aby poskytovali vysoko personalizované vzdelávacie skúsenosti tým, že priebežne analyzujú dáta o študentovi a v reálnom čase upravujú učebné materiály (Cavanagh et al., 2020), (Buciuman & Potra, 2025). Tieto systémy prispôsobujú učenie silným stránkam, potrebám, zručnostiam a záujmom jednotlivca.

Adaptívne vzdelávacie systémy sú sofistikované e-learningové platformy, ktoré využívajú adaptívne technológie na dynamické prispôsobovanie obsahu a študijných ciest podľa individuálnych potrieb študentov (L. Y. Tan et al., 2025), (du Plooy et al., 2024). Nemusia poskytovať krokové (step-by-step) tutorovanie; môžu fungovať aj ako odporúčací systém. Kľúčové charakteristiky ALS zahŕňajú:

- **Dynamická adaptácia** – ALS automaticky prispôsobuje obsah, tempo a štruktúru v reálnom čase a reaguje na výkon, progres a interakcie študenta tak, aby dostával primeranú mieru náročnosti a podpory (Katona & Gyonyoru, 2025).
- **Dátová analytika** – zber a analýza dát o študentovi (napr. predchádzajúce znalosti, preferencie, reakčný čas, presnosť, angažovanosť) slúžia na tvorbu profilov, výber zdrojov a návrh personalizovaných študijných ciest (L. Y. Tan et al., 2025).
- **Personalizácia v ALS** presahuje „one-size-fits-all“ prístup tým, že umožňuje prechod od kolektívneho učenia k individualizovanému poskytovaniu zdrojov a prispôbeným cestám. Modelovanie študenta je integrálnou súčasťou, keďže identifikuje individuálne štýly učenia a podľa nich odporúča zdroje (Bahassi et al., 2024), (Avella et al., 2016).
- **Pokročilé algoritmy** podporené AI kombinujú spracovanie prirodzeného jazyka, prediktívnu analytiku a metódy strojového učenia na spracovanie veľkého množstva dát a dynamické prispôsobovanie vyučovacích techník, obsahu a spätnej väzby (Joshi, 2023).

Inteligentné tutoriálne systémy (ITS) typicky pracujú na jemnej granularite krokov riešenia (step-level), obsahujú doménový model, model študenta a pedagogický model a poskytujú okamžitú spätnú väzbu alebo hinty, prípadne vedenie riešenia až po úroveň korekcie chýb. Adaptujú sa priebežne počas riešenia, využívajú AI techniky na napodobnenie roly ľudského tútora a poskytujú individualizované vyučovanie a tréning. Kľúčové charakteristiky ITS zahŕňajú:

- **Adaptívna podpora** – umožňuje prispôsobenie študijných ciest, štýlov učenia a odhad náročnosti kurikula (Marciniak & Szczepanski, 2020). ITS poskytujú okamžitú a personalizovanú inštrukciu alebo spätnú väzbu (Horvers et al., 2025).
- **Repozitáre obsahu** – pre včasnosť a efektívnosť pracujú s priebežne aktualizovanými repozitármi, aby študenti dostávali aktuálne zdroje vyhľadateľné podľa predmetu a rozsahu; systém volí úroveň detailu a veľkosť obsahu podľa toho, s čím študent doteraz pracoval (Marciniak & Szczepanski, 2020).
- **Modelovanie študenta** – ITS využívajú komplexné výpočtové modely zachytávajúce kognitívne a motivačné stavy, čo umožňuje diagnostikovať progres, identifikovať silné stránky a vedomostné medzery a poskytovať ciele podporu a vedenie (S. Wang et al., 2024).
- **Novšie prístupy** integrujú veľké jazykové modely s cieľom zvýšiť adaptívnosť a kontextovú relevantnosť rád a spätnej väzby (Gaeta et al., 2025).

Napriek tomu pretrváva zreteľná medzera medzi ambíciou vysoko adaptívneho učenia a prakticky nasaditeľnými rámcami, ktoré by prekladali behaviorálne snímanie do transparentných personalizačných rozhodnutí o tom, aký obsah zobrazíť a kedy (du Plooy et al., 2024), (Ronksley-Pavia et al., 2025). Slabé miesta sú konceptuálne aj procedurálne: ktoré signály učiaceho sa zachytávať, ako ich označiť a agregovať a v akej časovej škále aktualizovať model študenta tak, aby rozhodnutia zostali aktuálne. Zavedenie vysvetliteľnosti (napr. princípov XAI) nie je voliteľné; je to mechanizmus, cez ktorý môže učiteľ auditovať a dôverovať profilovaniu a následným odporúčaniam (Khosravi et al., 2022), (Tiukhova et al., 2024). Personalizácia preto musí fungovať podľa explicitných dizajnových pravidiel, ktoré zachovávajú ľudský dohľad a robia správanie modelu „čitateľným“.

V kontraste s tým sú mnohé súčasné prístupy ad-hoc a platformovo špecifické, často viazané na jednotlivé systémy alebo scenáre 1-na-1 tutorovania, ktoré sa ťažko škálujú na kolaboratívne alebo

kurzovo riadené prostredia (Arnau-González et al., 2025), (Chiu et al., 2023). Ich účinnosť je silno závislá od kontextu (predmet, implementácia, prostredie) a limitovaná nedostatkom dát: dátové sady pre knowledge tracking často nemajú metadáta položiek a vykazujú nerovnomernú expozíciu; interakčné záznamy sú úzke (kliknutia, navigácia, stlačenia klávesov) a zriedka integrujú ďalšie modalitty; kvalita dát a skreslenia navyše obmedzujú zovšeobecniteľnosť. Výsledkom je, že poznatky sa ťažko prenášajú medzi prostrediami a robustné porovnávacie dôkazy zostávajú vzácne (Han et al., 2025), (Aymane et al., 2024).

Pokrok v oblasti preto závisí od prenositeľného, opakovateľného dizajnového procesu, ktorý systematicky prepája zber signálov, profilovanie a intervenčnú logiku (vrátane načasovania) (Han et al., 2025). Pragmatickou stratégiou je cieľiť na minimalistickú, ale informatívnu množinu indikátorov – signály, ktoré sú lacné na zber, stabilné naprieč platformami a postačujú na zachytenie kľúčových dimenzií učenia (úspešnosť, úsilie, iteratívnosť, denný návyk). Z nich sa dajú odvodiť malé a interpretovateľné mikro-persony a ich stabilita sa dá priebežne monitorovať, čím vzniká spoločná personalizačná vrstva, ktorú si učitelia môžu prispôbiť lokálnym pedagogikám. Takáto vrstva nepredpisuje intervencie; namiesto toho štruktúruje rozhodnutia (čo/kedy) a robí ich vysvetliteľnými, čo umožňuje dôsledné hodnotenie a replikáciu naprieč kurzami a systémami.

Profilovanie používateľov je v týchto prostrediach kľúčové, pretože vytvára most medzi surovými behaviorálnymi dátami a informovaným rozhodovaním. Štandardizované, interpretovateľné profily (mikro-persony) transformujú heterogénne logy na stabilné reprezentácie prenositeľné naprieč kurzami a platformami. Umožňujú vyhnúť sa „naviazaniu“ na konkrétne položky alebo UI udalosti a zároveň redukovú šum: namiesto tisícok úloh a pokusov sa pracuje s niekoľkými kompaktnými dimenziami (výkon, úsilie, iteratívnosť, denný rytmus) ukotvenými v kurikulárnom kontexte (Fernandes et al., 2023).

Programovanie poskytuje nezvyčajne čistý a objektívny substrát pre profilovanie študentov. Úlohy sú realizovateľné a overiteľné – riešenia sa dajú kontrolovať spustením na testovacích sadách (dynamická evaluácia) alebo statickou analýzou kompilovateľnosti a štruktúry – čo vedie k presným a porovnateľným signálom výkonu (Manorat et al., 2025), (Katona & Gyonyoru, 2025). Na rozdiel od rozpoznávacích formátov programovanie výrazne obmedzuje náhodné hádanie a vyžaduje plánovanie, dekompozíciu a doladovanie, takže pozorované výsledky sú diagnostickejšie vzhľadom na kompetenciu a stratégiu. Táto kombinácia – objektívne hodnotenie spolu s väzbou na vyššie kognitívne procesy – znižuje šum pri označovaní a posilňuje inferencie z behaviorálnych dát (Miller et al., 2019), (Kolpikova et al., 2019). Rovnako dôležité je, že programovanie má prirodzene iteratívny charakter. Študenti odovzdávajú čiastkové riešenia, čítajú spätnú väzbu a upravujú kód. Nástroje automatizovaného hodnotenia a tútorovania vracajú okamžité, detailné odpovede v jednotlivých krokoch. Vznikajúce stopy – vrátane počtu a rozstupov pokusov, času do prvého maxima, trajektórií dĺžky kódu a progresu skóre – zachytávajú výkon aj proces. Takéto signály sa priamo mapujú na interpretovateľné dimenzie mikro-person (napr. tempo a vytrvalosť, štýl zlepšovania, skoré vs. neskoré zapojenie), čo umožňuje kompaktné, ale zmysluplné profily opisujúce ako študent postupuje, nielen kam sa dostal (Manorat et al., 2025).

Ekosystém navyše generuje bohatú longitudinálnu telemetriu nad rámec samotných skóre. Záznamy môžu obsahovať časové pečiatky odovzdaní (odhaľujú pracovné rytmy), dynamiku písania, používanie hintov a črty zdrojového kódu (napr. čitateľnosť, štruktúrne úpravy či štýlové zmeny). Modely knowledge trackingu využívajú tieto histórie na odhad vyvíjajúcej sa miery zvládnutia a na rozlíšenie efektu praxe od samotnej expozície. Programovacie kurzy rutinne produkujú protokolové dáta, ktoré v mnohých iných predmetoch chýbajú, čo z nich robí vhodnú doménu pre vývoj a validáciu profilovacích pipeline.

Napokon, základné metriky potrebné na tvorbu mikro-person sú platformovo nezávislé a škálovateľné, vrátane pomerov najlepších skóre, počtu pokusov, času do prvého osobného maxima, dĺžky kódu v danom bode, priemerného prírastku kódu a surového času dňa. Tieto minimálne črty sú prenositeľné naprieč kurzami a systémami a pritom ostávajú interpretovateľné pre učiteľov, čím podporujú transparentné a vysvetliteľné rozhodovanie o tom, aký obsah ponúknuť ďalej a kedy pokračovať. Z týchto dôvodov je programovanie presvedčivým testovacím prostredím pre odvodenie malých, stabilných a prenositeľných mikro-person, ktoré sa môžu zovšeobecniť aj na iné virtuálne úlohy s podobnou iteratívnou štruktúrou overiteľnou výsledkom (Katona & Gyonyoru, 2025), (Haldar et al., 2025).

Metodika výskumu

S cieľom zabezpečiť systematickosť analýzy sa štúdiá riadi metodikou **CRISP-DM**, ktorá poskytuje štruktúrovaný postup od definície problému až po analýzu dát a interpretáciu výsledkov.

- **Porozumenie problému** vychádza z porozumenia kontextu zbieraných dát (protokolové logy automatizovaného hodnotenia) a z posúdenia, do akej miery umožňujú mapovať správanie používateľov do malého počtu interpretovateľných mikro-person prenositeľných naprieč obsahom a systémami.
- **Porozumenie dátam** zahŕňa pochopenie problému vo vzťahu k dostupným záznamom, definovanie jednotky analýzy (pokús o odovzdanie) a výber merateľných indikátorov správania (úspešnosť, úsilie, čas, iteratívnosť, denný rytmus) spolu s pravidlami ich výpočtu a interpretácie.
- **Predspracovanie údajov** predstavuje výber a transformáciu dát zo základných protokolov do podoby vhodnej na profilovanie: z logov odovzdaných riešení sa odvodzujú premenné na úrovni úloh (napr. skóre úlohy, počet pokusov a čas do prvého osobného maxima, dĺžka kódu, prírastky kódu, čas dňa), následne sa agregujú do kapitolových deskriptorov a do trajektórnych blokov G1–G4, pričom sa aplikujú jednoduché transformácie na stabilizáciu šikmých rozdelení.
- **Dátová analýza a modelovanie** sú založené na zhľukovaní študentov do kandidátnych mikro-person pomocou **K-means** v transformovanom priestore blokových príznakov; počet zhľukov sa volí podľa interných validačných metrík (Silhouette, Davies–Bouldin) a praktických kritérií interpretovateľnosti a vyváženosti skupín.
- **Porozumenie výsledkom** spočíva v interpretácii výstupov prostredníctvom reprezentatívnych charakteristík zhľukov, typicky mediánov kľúčových indikátorov v blokoch G1–G4 (výkon, úsilie, časová investícia, iteratívnosť, diurnálny návyk), a v ich vizualizácii pomocou profilových grafov.
- **Implementácia** sa týka prenosu identifikovaných mikro-person do praxe: profily slúžia ako kompaktná a auditovateľná reprezentačná vrstva pre virtuálne prostredia (primárne vzdelávacie), pričom konkrétne intervenčné politiky (čo/kedy personalizovať) sa môžu líšiť podľa lokálneho kurikula a implementácie.

Porozumenie problému a dátam

Dáta pochádzajú z webovej mikrolearningovej platformy Priscilla (Jan Skalka & Drlik, 2018) využívanej vo výučbe programovania a umelej inteligencie v rámci konzorcia FITPED. Analýza bola realizovaná na kurze Úvod do programovacieho jazyka Python pre študentov prvého ročníka bakalárskeho štúdia (19 kapitol, cca 500 mikrolekcí, 134 programovacích úloh). V práci sa berú do úvahy iba programovacie úlohy hodnotené automatizovaným systémom, pri ktorých študent odovzdáva zdrojový kód a môže vykonať opakované pokusy s postupným zlepšovaním riešenia. Zahnutých je 1130 používateľov.

Sledovanie správania prebieha na úrovni **pokusov o odovzdanie (attempts)**; každý pokus je okamžite vyhodnotený a uložený. Pracuje sa s tabuľkou pokusov so stĺpcami:

- *user_id* – anonymizovaný identifikátor študenta,
- *task_id, task_type_id* – identifikátor úlohy a typu úlohy,
- *score, max_score* – body získané v každej úlohe a maximálne možné skóre pre danú úlohu,
- *time_length* – čas (s) od spustenia úlohy po jej odoslanie na vyhodnotenie,
- *code_length* – dĺžka odoslaného kódu (počet znakov),
- *task_order, lesson_order, chapter_order* – kurikulárna pozícia (poradie) úlohy v kurze,
- *time_stamp* – čas odoslania.

Takto definovaná schéma zachytáva autentické správanie pri riešení problémov: študent môže iterovať na riešení, postupne ho vylepšovať a dosahovať vyššie skóre. Zároveň ide o úlohy, kde nie je možné „uhádnuť“ správnu možnosť jedným kliknutím.

Predspracovanie údajov

Prvý krok prevádza surové logy odovzdaní do **kontingenčnej tabuľky**, kde každý riadok zodpovedá jednému študentovi a stĺpce zachytávajú výsledky viazané na konkrétne úlohy. Úlohy sa usporiadajú podľa ich kurikulárnej pozície (najprv podľa poradia kapitoly, následne podľa poradia úlohy), aby sa zachoval prirodzený tok kurzu. Pre každý *task_id* sa odvodí kompaktná množina premenných:

- **task<ID>** ukladá najlepší dosiahnutý výkon ako pomer $\max(score)/\max_score$ pre daný pár študent–úloha, čím kvantifikuje mieru vyriešenia,
- **task<ID>_attempts** zaznamenáva počet odovzdaní do a vrátane prvého pokusu, v ktorom študent dosiahne svoje maximum; odovzдания po prvom maxime sa vylúčia, aby sa neskreľovalo úsilie,
- **task<ID>_time** akumuluje čas (v sekundách) strávený do dosiahnutia prvého maxima,
- **task<ID>_length** zachytáva dĺžku kódu (počet znakov) v odovzdaní, ktoré dosiahlo prvé maximum,
- **task<ID>_tod** kóduje čas odovzdania do štyroch pevných intervalov (08–16, 16–20, 20–02, 02–08) na reprezentáciu denných/večerných/nočných pracovných vzorcov,
- **task<ID>_avg_incr** vyjadruje priemerný prírastok veľkosti kódu od druhého pokusu po pokus, v ktorom sa dosiahne prvé maximum, čím charakterizuje mieru iteratívneho doladovania riešenia.

Takto definovaná reprezentácia zachováva pre každú úlohu zároveň výkonové aj procesné signály, zaraďuje ich do poradia kurikula a vytvára konzistentný základ pre následnú agregáciu a zhlukovanie.

Na zníženie dimenzionality pri zachovaní kurikulárnej štruktúry sa ďalej konštruuje **agregovaná tabuľka na úrovni kapitol**. Keďže úlohová reprezentácia je veľmi rozsiahla, údaje sa sumarizujú pre každého študenta a každú kapitolu tak, aby vznikli kompaktné a vzájomne porovnateľné signály. Výber aj váženie agregátov je zámerne minimálne a transparentné; optimalizácia agregácie (a testovanie alternatív) sa ponecháva na budúcu prácu.

Konkrétne sa z kontingenčnej tabuľky (jeden riadok na študenta, stĺpce po úlohách a črtách) vypočíta pre každú kapitolu sada kapitolových deskriptorov:

- **mean success ratio** je priemer pomeru $\max(score)/\max_score$ naprieč všetkými úlohami v kapitole; chýbajúce úlohy sa berú ako NaN, takže hodnota leží v intervale (0,1>),
- **maximum ratio** ukladá najlepší dosiahnutý podiel v rámci kapitoly (často 1.0, ak bola aspoň jedna úloha vyriešená kompletne),

- **mean attempts** priemeruje počet odovzdaní potrebných do a vrátane prvého pokusu, v ktorom študent dosiahne svoje maximum v danej úlohe (pokusy po prvom maxime sa vylúčia),
- **time sum** je celkový čas (v sekundách) akumulovaný do prvého maxima naprieč úlohami v kapitole; v tejto základnej variante sa nuly ponechávajú (t. j. pred sčítaním sa 0 nenahrádza chýbajúcou hodnotou),
- **mean code length** je priemer dĺžky kódu (v znakoch) v odovzdaní, ktoré dosiahlo prvé maximum v každej úlohe; chýbajúce hodnoty sa ignorujú,
- **mean code increment** zachytáva priemerný nárast dĺžky kódu od druhého pokusu po prvé maximum (interpretovateľné ako „znaky na krok vylepšenia“), opäť spriemerované len cez úlohy s dostupnými dátami,
- **number of tasks** (samostatne pre deň a noc) vyjadruje, koľko úloh v kapitole prispelo validným výsledkom, a slúži ako jednoduchý indikátor pokrytia.

Aby sa pri redukcii dimenzionality zachovala sekvencia kurikula, kapitoly sa zoradia podľa kurikulárneho indexu a rovnomerne sa rozdelia do štyroch kvartilových blokov. V rámci každého bloku sa kapitoly deskriptory agregujú jednoduchými priermi na úrovni študenta (priemery z kapitol patriacich do daného bloku; chýbajúce hodnoty sa ignorujú). Výsledkom je jeden kompaktný vektor črt na blok (teda štyri vektory na študenta). Táto operácia vytvára kompaktnú, interpretovateľnú reprezentáciu, ktorá zachováva výkonové aj procesné signály naprieč trajektóriou a slúži ako priamy vstup pre zhlukovanie metódou K-means.

Dátová analýza

Najprv sa stručne charakterizuje **vzorka a pokrytie kurzu**, potom sa rozdelenia hlavných ukazovateľov zhrnú podľa štyroch kurikulárnych blokov (kvartilov) G1–G4. Keďže údaje z aktivít bývajú silne „ťahané“ extrémami, pre každý blok sa uvádza **medián** a **interkvartilové rozpätie** (p25–p75), ktoré lepšie vystihujú typické správanie než priemer. Tab. 21 pre každý kvartil uvádza: súčet maximálnych skóre (súčet podielov maxima dosiahnutého v úlohách), súčet pokusov (pokusy do dosiahnutia prvého maxima), súčet stráveného času (v sekundách; čas do prvého maxima), priemernú dĺžku kódu (znaky; dĺžka kódu v pokuse s prvým maximom), počet denných/nočných úloh (odovzdania v intervaloch 08–20 a 20–08) a priemerný prírastok kódu (priemerný nárast počtu znakov na krok od 2. pokusu po prvé maximum). Riadok *n* udáva počet validných pozorovaní.

Tab. 21 Blokové deskriptíva naprieč kurikulárnymi kvartilmi (medián a IQR pre výkon, úsilie, čas, veľkosť kódu a diurnálnu aktivitu).


group	metric	sum of max score	sum of attempts	sum of spent time	mean code length	tasks day	tasks night	avg of code increment
G1	n	1130	1130	1130	1130	1130	1130	1029
	p25	11.3	25	3365.5	3581.25	9	0	3.125
	median	36.9	65	10877	11591.5	23	2	5.49
	p75	37	99	22829.75	12671	33	10	9.06
G2	n	1130	1130	1130	1130	1130	1130	777
	p25	0	0	0	0	0	0	5.64
	median	28.9	70	15598	7757	15.5	1	9.52
	p75	44.8	159	54763.25	10206.5	34	11	16.53
G3	n	1130	1130	1130	1130	1130	1130	604
	p25	0	0	0	0	0	0	7.14
	median	4	11	1208.5	1258	2	0	14.47
	p75	21.815	66	20986	5348.5	15	4	27.12
G4	n	1130	1130	1130	1130	1130	1130	600
	p25	0	0	0	0	0	0	6.30
	median	5.25	17	2353.5	1518	3	0	10.27
	p75	29	106	26387.25	9185.75	23	4	16.03

Z tabuľky vyplýva, že:

- G1 (úvodné kapitoly) má najvyššie mediány naprieč indikátormi (napr. súčet maximálnych skóre je 36.9; súčet pokusov je 65; čas: 10 877 s; dĺžka kódu: 11 592 znakov), čo zodpovedá vysokej participácii a intenzívnej práci na úvodných úlohách.
- G2–G4 vykazujú pri viacerých metrikách výrazné $p_{25} = 0$, čo znamená, že významná časť študentov dané bloky vôbec nezačala alebo v nich nemá aktivitu; mediány však zároveň ukazujú nezanedbateľnú aktivitu časti populácie (napr. v G2: čas = 15 598 s, pokusy = 70).
- Denný vs. nočný režim naznačuje dominanciu dennej aktivity (typicky $p_{25} = 0$ pre nočnú), teda väčšina odovzdaní prebieha medzi 8:00 a 20:00.
- Iteratívnosť riešenia (priemerný prírastok kódu) rastie z G1 (5.49) do G3 (14.47) a v G4 mierne klesá (10.27), čo môže súvisieť s vyššou náročnosťou stredných blokov alebo so selekciou študentov, ktorí pokračujú do neskorších kapitol.

Deskriptory tak potvrdzujú výraznú heterogenitu správania a postupný pokles participácie v priebehu kurzu.

V záverečnom modelovacom kroku sa cieľovo deteguje malý počet mikro-person metódou K-means. Pred pomenovaním zhlukov je potrebné zvoliť počet k na základe interných validačných metrík v transformovanom príznakovom priestore. Ako primárna metrika sa použila Silhouette (vyššie je lepšie) a ako sekundárna Davies–Bouldin index (nižšie je lepšie). Rozhodnutie sa posudzovalo aj z hľadiska interpretovateľnosti a vyváženosti veľkostí zhlukov.



Obr. 10 Silhouette a Davies–Bouldin v závislosti od k v transformovanom príznakovom priestore (zvolené $k = 5$).

Obr. 10 ukazuje, že Silhouette dosahuje najvyššie hodnoty pre $k = 2–3$ (0.41–0.42) a pri väčších k postupne klesá (0.25 pre $k \geq 6$). Davies–Bouldin index má minimum pri $k = 5$ (0.96), čo naznačuje, že päťskupinové rozdelenie poskytuje lepšiu kompaktnosť a separáciu než $k = 3–4$, bez dramatického zhoršenia Silhouette. Takýto obraz je typický pre dáta s hrubou binárnou štruktúrou (zachytenou $k = 2$) a zároveň s jemnejšími podskupinami správania, ktoré sa objavujú okolo $k = 5$.

Pre ďalšiu analýzu sa $k = 5$ definuje ako pragmatický kompromis:

- zodpovedá minimu Davies–Bouldin,
- umožňuje bohatšiu typológiu než binárne rozdelenie,
- vyhýba sa pre-segmentácii naznačenej poklesom Silhouette pri $k \geq 6$.

Najprv sa hodnotí vnútorná kvalita riešenia pre $k = 5$. Tab. 22 uvádza veľkosti zhlukov a štatistiky Silhouette. Celková Silhouette je 0.379, čo je konzistentné s heterogénnym, ale štruktúrovaným správaním v logaritmicke odvodených črtách.


Tab. 22 Veľkosti zhlukov a kvalita podľa Silhouette pre k = 5 na transformovaných kvartilových črtách (vyššie je lepšie); celková silhouette = 0.379.

cluster	n	sil_mean	sil_median	sil_p25	sil_p75
0	81	0.273	0.288	0.090	0.479
1	688	0.457	0.515	0.364	0.569
2	132	0.251	0.269	0.138	0.382
3	148	0.235	0.253	0.116	0.366
4	81	0.292	0.343	0.139	0.444
overall	1130	0.379			

Klaster 1 je dominantný (n = 688; 60.9 %) s mediánom Silhouette 0.515 (IQR 0.364–0.569), čo naznačuje najkompaktnejšiu a najlepšie separovanú mikro-personu. Klastre 0 a 4 (každý n = 81; 7.2 %) a zhluky 2 (n = 132; 11.7 %) a 3 (n = 148; 13.1 %) vykazujú primeranú separáciu (mediány 0.25–0.34), čo je pri behaviorálnych dátach s prekrývajúcimi sa stratégiami typické. Žiadny zhluk nie je degenerovaný ani zanedbateľne malý, riešenie je teda vyvážené a vhodné na ďalšie profilovanie.


Tab. 23 Mediánové profily zhlukov naprieč kurikulárnymi kvartilmi (G1–G4): výkon (sum_max_score), úsilie (sum_attempts), čas (hodiny), iteratívnosť (avg_code_increment) a diurnálny podiel (day_share). Hodnoty sú mediány na klaster; uvádzajú sa na pôvodných škálach pre interpretovateľnosť.

Group	Feature	cluster 0 median	cluster 1 median	cluster 2 median	cluster 3 median	cluster 4 median
G1	sum_max_score	37	21	37	37	37
	sum_attempts	85	46	86	84	101
	sum_time	4.856	1.705	4.95	4.674	5.204
	day_share	0.824	1	0.889	0.833	0.813
	avg_code_increment	5.301	5.346	6.58	5.845	5.559
G2	sum_max_score	37.4	2	45	44.625	43
	sum_attempts	123	5	152.5	139.5	129
	sum_time	8.728	0.129	13.88	14.402	8.793
	day_share	0.793	1	0.744	0.775	0.774
	avg_code_increment	8.173	8.429	11.957	11.522	8.158
G3	sum_max_score	8	0	22.32	20.75	14.2
	sum_attempts	21	0	64	56.5	34
	sum_time	1.413	0	5.087	5.003	1.801
	day_share	1	0	0.795	0.813	0.8
	avg_code_increment	1.056	12	41.072	19.387	11.282
G4	sum_max_score	12.9	0	29.55	23.95	14.1
	sum_attempts	55	0	113	85.5	52
	sum_time	3.174	0	7.667	6.111	2.761
	day_share	1	0	0.818	0.867	0.917
	avg_code_increment	10.382	9.66	8.382	21.315	2.337



Obr. 11 Výkon vyjadrený skóre (stĺpce) a pokusmi (čiary) naprieč blokmi kurzu podľa zhluku.

Na interpretovateľné profilovanie piatich zhlukov sa reportujú mediány naprieč kvartilmi G1–G4 na kompaktnom sete indikátorov: výkon (*sum_max_score*), úsilie (*sum_attempts*), časová investícia (*sum_time*, uvádzaná v hodinách), iteratívne doladovanie (*avg_code_increment*) a diurnálny návyk (*day_share* = $\text{sum_8_20} / (\text{sum_8_20} + \text{sum_20_08})$). Mediány znižujú vplyv ťažkých chvostov typických pre logaritmické rozloženie údajov.



Obr. 12 Heatmapa profilov mikro-person zoskupených podľa G1–G4 (normalizácia po stĺpcoch; tmavšie = vyššie).

Porozumenie výsledkom

Výsledné profily ukazujú odlišné trajektórie štúdia – od počiatočného zapojenia až po udržaný progres, čo ilustruje Obr. 11. Obr. 12 zobrazuje zhľady mikro-person (riadky) voči indikátorom zoskupeným podľa G1–G4 (stĺpce), so stĺpcovou normalizáciou a v odtieňoch sivej (tmavšie odtiene znamenajú vyššie hodnoty). Vynikajú kontrasty skoré–neskoré a spoločné zvýšenia, napr. zhľad 2 vrcholí v G2–G4, zatiaľ čo zhľad 0 je výrazne „front-loaded“ v G1.


Stručné zhrnutie charakteristického vzorca každého klastra naprieč G1–G4 (rozdiely vo výkone, úsilí, čase, iterácii a čase dňa):

- Klaster 1 ($n = 688$; skorí ukončovatelia) – pozorovateľné počiatočné zapojenie v G1 (medián *max_score* = 21, pokusy = 46, čas = 1.7 h), potom prudký pokles k takmer nulovej aktivite v G2–G3; v G4 sa objaví mierny nárast vyriešeného podielu, no medián pokusov/času = 0 naznačuje, že viac než polovica v neskorších blokoch nepracuje. Aktivita je takmer výlučne cez deň.
- Klaster 0 ($n = 81$; stabilní do polovice kurzu) – vysoká aktivita v G1–G2 (*max_score* = 37 a 37.4; pokusy = 85 a 123; čas = 4.9 h a 8.7 h), potom ľahká aktivita v G3 a mierna v G4. Iterácia je skôr mierna (*avg_code_increment*: 5–10); *day_share*: 0.80–1.00.
- Klaster 2 ($n = 132$; intenzívni vytrvalci) – vysoká aktivita vo všetkých blokoch, najmä v G2 a G4 (pokusy = 153 a 113; čas = 13.9 h a 7.7 h; *max_score* = 45 a 29.6). Iterácia je výrazná (*avg_code_increment* = 12 v G2, 8.4 v G4). Premenná *day_share* je mierne nižšia než pri ostatných (0.74–0.89), teda pracujú relatívne viac večer/nočných aktivít.
- Klaster 3 ($n = 148$; neskorí doladovači) – udržané zapojenie od G1 po G4, s výrazným časovým rozpočtom (G2 = 14.4 h; G4 = 6.1 h) a najvyššou neskorou iteráciou (G4 *avg_code_increment* = 21.3); *day_share*: 0.78–0.87.
- Klaster 4 ($n = 81$; intenzívni štartéri) – veľmi vysoké pokusy v G1 (101) a čas (5.2 h), stredná aktivita v G2, následne nízka v G3–G4; minimálna iterácia v G4 (2.34), prevažne denný režim.

Na vizualizáciu separácie (nie na fitovanie modelu) sa štandardizované kvartilové črty premietnu do dvoch hlavných komponentov PCA a body sa zafarbia podľa priradenia pri $k = 5$ (Obr. 13).

PC1 predstavuje všeobecnú os intenzity/zapojenia. Najvyššie záťaž majú premenné úsilia naprieč blokmi, najmä *group{2–4} sum_attempts* a *group{2–4} sum_time* (a v menšej miere aj sumy vyriešených častí v blokoch). Posun doprava teda znamená viac odovzdaní, viac času a celkovo vyššiu váhu vyriešených úloh vo viacerých blokoch; posun doľava odráža riedku aktivitu a veľa núl. Keďže

vstupy boli log-transformované a robustne škálované, PC1 možno interpretovať ako *celkové pracovné zaťaženie* v štandardizovaných jednotkách.



Obr. 13 PCA projekcia štandardizovaného kvartilového priestoru črt (body zafarbené podľa k = 5 zhlukov). Klastrovanie prebehlo v pôvodnom priestore; PCA slúži iba na vizualizáciu. Podtitul uvádza vysvetlenú varianciu PC1 a PC2.

PC2 porovnáva skoré a neskoré zapojenie do kurikula a zároveň denné vs. nočné načasovanie. Pozitívne sa viaže na premenné z neskorších blokov (napr. `group{3–4} sum_time`, `group{3–4} sum_max_score`, `group{3–4} avg_increments`) a na večerné/nočné odovzdania, a negatívne na signály zo skorých blokov (`group{1–2}_*`) a na dennú aktivitu (`*_day_share`). Posun nahor preto znamená viac práce v neskorších blokoch, intenzívnejšie iterovanie v týchto blokoch a vyšší podiel večer/nočných aktivít; posun nadol znamená sústredenie na skoré bloky, typicky realizované prevažne cez deň.

Implementácia

Rámec pracuje s exportmi na úrovni pokusov, ktoré väčšina vzdelávacích platforiem už generuje. Zoznam požadovaných polí je definovaný v úvodnej časti metodiky a je pomerne univerzálny a vo vzdelávacích prostrediach široko dostupný – možno ho priamo použiť ako kontrolný zoznam pri implementácii.

- **Vstupné dáta** majú obsahovať minimálne: identifikátor študenta, identifikátor úlohy, získané a maximálne možné body, trvanie pokusu, indikátor rozsahu riešenia (počet znakov alebo riadkov), poradie úloh v kurikule a časovú pečiatku odovzdania.
- **Odvožené premenné na úrovni úlohy** sa získajú výpočtom (pre každého študenta a úlohu): podielu úspešnosti (najlepší výsledok vzhľadom na maximum), indexu pokusu, v ktorom študent prvýkrát dosiahne svoje osobné maximum, kumulatívneho času do tohto bodu, dĺžky riešenia v danom pokuse, priemernej zmeny dĺžky riešenia medzi pokusmi do tohto bodu a kategórie času dňa odvodennej z časovej pečiatky.
- **Agregácia do blokov trajektórie** sa realizuje chronologickým usporiadaním jednotiek kurzu a ich rozdelením do blokov podľa času alebo náročnosti. Uvedené indikátory sa v rámci každého bloku agregujú (podľa typu metriky priemerom alebo súčtom). Takto vznikne kompaktný profil, ktorý zachytáva skoré aj neskoré trendy bez potreby pracovať s detailnými, úlohovými záznamami. Pred zoskupovaním sa aplikujú ľahké transformácie na zmiernenie šikmosti rozdelení a premenné sa škálujú tak, aby sa obmedzil vplyv odľahlostí, pričom sa zachovávajú hodnoty indikujúce neaktivitu.
- **Tvorba mikro-person** vychádza zo zoskupenia blokových profilov do malého počtu dobre separovaných a interpretovateľných klastrov. Počet klastrov sa určuje pomocou štandardných

kritérií separácie, spolu s posúdením interpretovateľnosti a primeranej veľkosti skupín, nie použitím fixného defaultu.

- **Zhrnutie a použitie výsledkov** spočíva v tom, že každý klaster sa popíše mediánmi kľúčových metrik v rámci blokov (napr. G1–G4) a priradí sa mu stručný deskriptívny názov a krátky textový profil vhodný pre učiteľské prehľady alebo analytické reporty. Zároveň sa ponechajú dostupné hlavné metriky (výkon, úsilie, čas, iteratívnosť, čas dňa), aby bolo možné výsledky auditovať a postupne rozširovať o ďalšie premenné alebo alternatívne agregácie.

Odporúča sa dokumentovať použité dátové polia, voľby transformácií a zdôvodnenie počtu klastrov, a zabezpečiť, aby bolo prípadné použitie v kontakte so študentmi transparentné, primerané a revidovateľné z hľadiska férovosti.

Diskusia a záver

Cieľom kapitoly bolo navrhnúť a demonštrovať prenositeľný, protokolovo založený rámec na odvodenie profilov učenia z odovzdaní a získať malý, interpretovateľný a dostatočne stabilný súbor mikro-person použitelných naprieč virtuálnymi (vzdelávacími) prostrediami.

Zistenia tieto ciele podporujú. Použitá sada črt je zámerne minimalistická a vychádza zo signálov, ktoré poskytuje prakticky každý systém automatizovaného hodnotenia: podiel najlepšieho skóre, počet pokusov a čas do prvého osobného maxima, dĺžka obsahu pri najlepšej odpovedi, priemerný prírastok obsahu a jednoduché časovanie odvodené z odovzdaní, ukotvené v poradí kurikula. Predspracovanie ostáva rovnako úsporné (sanitizácia, $\log(1+x)$ pre počty/časy, robustné škálovanie). Skutočnosť, že aj takýto minimalistický protokol vedie k zmysluplnej štruktúre bez platformovo špecifických stôp, naznačuje, že relevantné signály pre profilovanie sú už prítomné v štandardných záznamoch. Tým sa posilňuje argument prenositeľnosti aj pre prostredia, kde nie je možné zavádzať dodatočnú inštrumentáciu alebo upravovať uzavreté systémy.

Agregácia priebehu kurzu do kvartilov trajektórie (G1–G4) viedla k riešeniu s piatimi klastrami, ktoré je konzistentné s PCA geometriou aj s internými validačnými metrikami. Typológia zachytáva dominantný vzorec sústredenia aktivity do úvodu, dve trajektórie pokračujúcej práce do neskorších blokov (s rozdielmi v iteratívnosti a v časovaní aktivity) a dve varianty postupného poklesu po polovici kurzu. Hoci celková Silhouette (0.38) naznačuje prekrývanie očakávateľné pri behaviorálnych dátach, mediánové profily po blokoch zostávajú koherentné a interpretovateľné. Diurnálny signál prispieva k separácii najmä v kombinácii s udrжанým zapojením v neskorších blokoch; v opačnom prípade sa presadzuje úspornejšie vysvetlenie založené na výkone a úsilí, čo je v súlade s princípom ponechať črty len vtedy, keď pridávajú vysvetľovaciu hodnotu.

Odpoveď na výskumnú otázku teda znie: **Jednotný, platformovo agnostický profilovací model sa navrhuje tak, že sa profilovanie opiera výlučne o protokolové logy automatizovaného hodnotenia doplnené o kurikulárny a časový kontext**, z ktorých sa odvodí minimalistická a prenositeľná sada črt a následne sa harmonizuje výstup do porovnateľnej reprezentácie trajektórie (napr. kvartily G1–G4). Mikro-persony sa potom konštruujú ako malé množstvo segmentov s jasnou interpretáciou, pričom empirické overenie stojí na kombinácii geometrickej konzistencie (PCA), interných validačných metrik (vrátane očakávaného prekrývania pri behaviorálnych dátach) a koherencie blokových mediánových profilov; stabilita a prenositeľnosť sa posilňujú konzervatívnym ponechávaním črt len vtedy, keď pridávajú vysvetľovaciu hodnotu. Výsledkom je malý, interpretovateľný a dostatočne stabilný súbor mikro-person použitelný ako prenositeľná reprezentácia používateľa naprieč obsahom a systémami, aj v prostrediach bez možnosti dodatočnej inštrumentácie.

Z metodologického hľadiska mikro-persony predstavujú kompaktnú reprezentačnú vrstvu, ktorá sprostredkuje prechod od protokolových logov k čitateľným profilom používateľov. Keďže sú

definované prenositeľnými funkciami (úspešnosť, úsilie, časová investícia, miera zmeny riešenia) a ich pozíciou v kurikule, možno ich chápať ako všeobecnú vrstvu profilovania aj mimo programovania. Analógie týchto signálov existujú v laboratórnych a simulačných situáciách (úspešnosť ako splnenie scenára, pokusy ako revízie postupu, čas do maxima ako čas k zvládnutiu zručnosti) aj v úlohách orientovaných na tvorbu textu (rozsah a štruktúra výstupu, rozsah revízií). Praktická prenositeľnosť však vyžaduje prispôbiť voľbu blokov trajektórie (kvartilov alebo iných typov delení) tak, aby zodpovedala časovej alebo obsahovej štruktúre konkrétneho kurzu.

Z aplikačného hľadiska mikro-persony neposkytujú intervenčnú politiku samy osebe; slúžia skôr ako stabilný podklad pre následné rozhodovanie o podpore a jej načasovaní. V kontexte práce je podstatné zdôrazniť dve zásady:

- osoby zachytávajú spôsob práce a nie sú priamou mierou kvality alebo výkonu študenta;
- väzba na výsledky je časovo podmienená a mala by sa opierať o longitudinalitu (napr. stabilizácia signálov po G1 alebo G2).

Z toho vyplýva, že profilovanie na úrovni klastrov je vhodné kombinovať s nízko-invazívnymi individuálnymi indikátormi (napr. stagnácia, opakované neskoré odovzdania), aby sa znížilo riziko neprimeraných generalizácií.

Limity a smery ďalšieho výskumu. Štúdia je viazaná na jeden kurz a jednu doménu, preto je potrebné overiť externú validitu replikáciou v ďalších kurikulách a na iných platformách. Protokolové záznamy popisujú správanie, nie porozumenie; termíny a paralelné predmety môžu skresľovať vzorce úsilia. Časť indikátorov je viazaná na dosiahnutie prvého osobného maxima; skoré ukončenie sa premieta do núl, ktoré sú informatívne, no zároveň zvyšujú riziko skreslenia pri interpretácii. Interné validačné metriky hodnotia geometriu klastrov v príznakovom priestore, nie pedagogickú hodnotu, ktorá vyžaduje následné prepojenie na výsledky a (ideálne) experimentálne overenie.

Prirodzené pokračovania zahŕňajú replikáciu pipeline v ďalšom programovacom kurze (a ideálne na odlišnej platforme), prepojenie mikro-person s výsledkami (retencia, skúška, prechod do nadväzujúcich kurzov) a mapovanie profilov na kontrolované intervencie s hodnotením dopadu a férovosti. Súčasne je možné rámec rozšíriť o ľahké, široko dostupné signály (napr. blízkosť k termínu), pri zachovaní minimalistického charakteru protokolu.

V súhrne výsledky naznačujú, že jednotný, platformovo agnostický model profilovania môže byť postavený na štandardných protokoloch doplnených o kurikulárnu sekvenciu a hrubé časovanie. Takto odvodené mikro-persony sú malé, interpretovateľné a lokálne stabilné, a predstavujú realistický základ pre ďalšiu adaptívnu orchestráciu vo virtuálnych vzdelávacích prostrediach.

Prínos pre oblasť habilitácie

Prínos tejto sekcie pre oblasť habilitácie možno zhrnúť do nasledujúcich bodov:

- Teoretický prínos spočíva v tom, že sa explicitne ukazuje, ako sa dajú nízkoúrovňové záznamy správania previesť na vyššie, interpretačne uchopiteľné konštrukty bez dotazníkov. Typologické ukotvenie (bloky správania inšpirované hráčkou typológiou) vytvára transparentný most medzi mechanikami hry a významom odvodených črt a zároveň pomenúva hranice: nie všetky konštrukty sú v každom prostredí zodpovedne izolovateľné (napr. sociálna dimenzia v singleplayeri).
- Metodický prínos spočíva v štandardizovanom postupe, ktorý robí agregované profily prenositeľnými a reprodukovateľnými: od rekonštrukcie relácií, cez odvodenie a normalizáciu metrikami na jednotku času, ošetrovanie šikmých rozdelení a redundancií, až po redukciu dimenzie (PCA) a segmentáciu (k-means). Kľúčovým prvkom je stabilné overenie riešenia cez

jadrové prerezanie podľa individuálnej istoty priradenia a bootstrap resampling s kvantifikáciou stability (ARI), čím sa z jednorazového zhľukovania stáva kontrolovaný protokol tvorby mikro-person.

- Praktický prínos spočíva v tom, že výsledné mikro-persony sú priamo použiteľné pre dizajn a adaptáciu systému: ide o malé množstvo zrozumiteľných profilov správania odvodených zo štandardnej telemetrie, ktoré vedia odlišiť napríklad rizikovo-agresívny štýl, opatrné prežívanie alebo prieskumne orientované hranie. Tým sa posilňuje prenositeľnosť aj do prostredí, kde nie je možné zavádzať dodatočnú inštrumentáciu alebo zasahovať do uzavretých systémov.
- Pre multi-view modelovanie sekcia prináša stabilný agregatívny pohľad, ktorý sa prirodzene integruje s ostatnými vrstvami: poskytuje kompaktné, interpretovateľné profily používateľov na úrovni sumárnych črt a zároveň umožňuje pracovať s neistotou (jadro vs. hraničné prípady) tak, aby sa tvrdé priradenia dali používať ako pravdepodobnostné skóre pre neskorú fúziu. V rámci stability-first logiky tým táto vrstva plní úlohu robustného behaviorálneho základu, ktorý sa dá vážiť podľa stability a pokrytia a bezpečne zapojiť do konštrukcie spoločného priestoru.

Behaviorálna vrstva: Typologicky ukotvené osoby z logov

V moderných digitálnych hrách je pochopenie správania hráčov pre vývojárov kľúčové a predstavuje centrálnu tému game analytics (Fu et al., 2017), (J. Tan & Katchabaw, 2022). Modelovanie hráčov – tvorba abstraktnej reprezentácie toho, ako sa hráč správa v hernom prostredí – podporuje optimalizáciu dizajnu, kvalitu používateľskej skúsenosti a personalizáciu či adaptáciu hry (Bakkes et al., 2012), (Alvarez et al., 2022). Obzvlášť dôležité je v situáciách, kde sa obsah alebo obtiažnosť upravujú podľa preferencií, zručností a štýlov hry jednotlivcov (Paraschos & Koulouriotis, 2023), (Mortazavi et al., 2024).

Tradičné prístupy k segmentácii a typológiám často vychádzajú z top-down pohľadu, ako sú dotazníky alebo dizajnérske riadené taxonómie. Modely typu Bartleho typy hráčov (Bartle, 1996) či HEXAD (Tondello et al., 2016), (Tondello et al., 2019) sa zvyčajne opierajú o sebahodnotenie zbierané mimo hernej relácie a môžu trpieť skresleniami, slabšou ekologickou validitou a obmedzenou použiteľnosťou naprieč žánrami (Bicalho et al., 2019), (Kirchner-Krath et al., 2024). Oproti tomu herné event logy a telemetria predstavujú najbežnejší kvantitatívny zdroj informácií o správaní: zachytávajú tisíce akcií na jednu reláciu a umožňujú objektívnejšie analyzovať interakciu hráčov s hernými systémami (Melo et al., 2025).

Hoci sa bottom-up klastrovanie telemetrie v literatúre objavuje, log-based behaviorálne profilovanie je stále metodicky fragmentované a často ťažko reprodukovateľné (Sifa et al., 2018), (Su et al., 2021), (Ferguson et al., 2020). V praxi sa to prejavuje tromi opakujúcimi sa problémami.

- Pokročilé metódy dokážu zachytiť komplexné vzorce v telemetrii, no často sú vnímané ako black-box: ich reprezentácie sa ťažko prepájajú s intuitívnymi pojmami relevantnými pre dizajn (taktika, stratégia, motivácia), čo brzdí ich prijatie v praxi (Barredo Arrieta et al., 2020), (Dwivedi et al., 2023), (Rai, 2020).
- Rôzne klastrovacie algoritmy, parametre alebo aj náhodné inicializácie môžu viesť k výrazne odlišným segmentáciám tej istej populácie; robustnosť výsledkov sa pritom často neoveruje prevzorkovaním ani v čase (J. Tan & Katchabaw, 2022), (El-Nasr et al., 2021), (Su et al., 2021).
- Neexistuje všeobecne akceptovaný, jasne zdokumentovaný analytický postup, ktorý by sa dal ľahko replikovať: logy sú heterogénne a slabo štandardizované, takže predspracovanie a konštrukcia črt dominujú práci, no v publikáciách bývajú popísané nedostatočne na to, aby boli znovupoužiteľné (J. Tan & Katchabaw, 2022), (Kirchner-Krath et al., 2024), (Ferguson et al., 2020).

Táto kapitola reaguje na uvedenú medzeru tým, že predstavuje znovupoužiteľný pipeline, ktorý odvádza interpretovateľné, typológiou ukotvené behaviorálne metriky z herných logov a zároveň explicitne overuje stabilitu výsledných person. Postup sa demonštruje na telemetrii zo single-player FPS scenára a zahŕňa:

- odvodzovanie behaviorálnych čŕt z event logov, inšpirovaných rámcami typov hráčov (najmä Bartleho rozlíšením *Achiever/Killer/Explorer*) (Bartle, 1996),
- redukciu redundancie a odhalenie latentnej štruktúry pomocou korelačného skríningu a analýzy hlavných komponentov (PCA),
- stabilizované orientované klastrovanie v latentnom priestore (k-means + bootstrap prevzorkovanie) so siluetovo riadeným pruningom na oddelenie stabilného jadra person od nejednoznačných hraničných prípadov,
- tvorbu person opísateľných konkrétnymi hernými metrikami, použiteľných pre analytiku, dizajn a potenciálnu personalizáciu.

Kapitola využíva hernú telemetriu na rýchle získanie základných charakteristík hráča vo forme agregovaného behaviorálneho profilu. Udalosti z hry sa zhrnú do kompaktného súboru indikátorov (napr. intenzity, pomery, miery výkonu a progresu) a z týchto agregátov sa následne konštruujú osoby. Keďže agregácia oslabuje časový kontext, interpretácia klastrov môže byť príliš voľná. Preto sa používa typológiou riadené ukotvenie: ešte pred analýzou sa zvolí typológia (napr. Bartle) a podľa nej sa navrhnu bloky metrík, ktoré následne usmerňujú interpretáciu a pomenovanie person. Druhou podmienkou je stabilita – ak sa segmenty menia pri bežných analytických perturbáciách, výsledok nie je použiteľný.

Z toho vyplýva jadro kapitoly: ukotvenie má zvýšiť zrozumiteľnosť bez toho, aby sa „vymyslel“ význam, a stabilizované overenie má ukázať, ktoré osoby tvoria robustné jadro a ktoré sú hraničné prípady a definícia výskumnej otázky:

- **BEHA3: Ako konštruovať interpretovateľné behaviorálne osoby z agregovaných herných logov a do akej miery typológiou riadené ukotvenie znižuje riziko nadinterpretácie a zvyšuje vysvetliteľnosť stabilnej štruktúry person?**

Ambíciou kapitoly nie je identifikovať univerzálnu množinu typov hráčov, ale ukázať, že transparentný, log-driven pipeline – doplnený o typológiou riadené ukotvenie a explicitnú validáciu stability – môže viesť k psychologicky interpretovateľným a empiricky robustným personám, ktoré sú vhodné pre game analytics aj dizajn.

Prehľad relevantných zdrojov

Modelovanie hráčov má v hernom výskume a v interakcii človek–počítač dlhú tradíciu, najmä vo forme typológií založených na motiváciách alebo preferenciách (Ballou et al., 2024), (Bunian et al., 2017), (Nacke et al., 2011). Klasické „top-down“ prístupy, ako Bartleho typy hráčov pre prostredia MUD a MMO (Bartle, 1996), či neskoršie modely ako Yeeho motivácie (Yee, 2006a) alebo HEXAD (Tondello et al., 2016), definujú niekoľko ideálnych typov (napr. *Achiever*, *Killer*, *Explorer*, *Socializer*) a hráčov k nim priradujú pomocou dotazníkov alebo kvalitatívnych metód.

Tieto rámce poskytujú spoločný jazyk pre dizajnérov a výskumníkov. V praxi sa používajú pri návrhu obsahu, monetizačných stratégií a gamifikačných systémov a často fungujú ako „mentálne modely“ pri uvažovaní o segmentoch hráčov (Kirchner-Krath et al., 2024), (Nacke et al., 2014). Novšie systematické prehľady však upozorňujú na viacero obmedzení takýchto typológií (Kirchner-Krath et al., 2024), (Bris et al., 2021), (Passalacqua et al., 2021). Empirické štúdie poukazujú na prekryvanie dimenzií medzi modelmi, slabšiu replikovateľnosť faktorových štruktúr, problémy so spoľahlivosťou škál a nejasnú

prenositeľnosť naprieč žánrami a platformami (Tondello et al., 2019), (Bateman et al., 2011), (Busch, Mattheiss, Orji, et al., 2016). Často sa ukazuje, že rôzne typológie v jadre zachytávajú podobné latentné faktory (napr. výkon, sociálnu interakciu, exploračnú), no používajú odlišné názvy a kategórie, čo sťažuje porovnávanie výsledkov (Tuunanen & Hamari, 2012), (Kirchner-Krath et al., 2024), (González-González et al., 2022). Zároveň ide väčšinou o nástroje sebahodnotenia, ktoré merajú deklarované preferencie, nie správanie v konkrétnych herných situáciách.

Tým vzniká rozdiel medzi tým, ako hráči opisujú sami seba v dotazníkoch, a tým, ako sa reálne správajú, čo je zachytené v herných event logoch (Tondello et al., 2016), (Drachen et al., 2014), (Colombo et al., 2023). Z tohto dôvodu dáva zmysel kombinovať typológie s modelovaním založeným na logoch: existujúce rámce poskytujú psychologicky ukotvený interpretačný slovník, no samy osebe neponúkajú konkrétny algoritmický postup. Herné logy naopak poskytujú bohaté behaviorálne dáta, ale neposkytujú názvy a významové kotvy pre segmenty (Fiş Erümit et al., 2021). Aktuálny výskum preto otvára otázku, ako navrhovať črty odvodené z logov tak, aby boli zároveň interpretovateľné v terminológii známych typológií a zároveň vhodné na ďalšie spracovanie (napr. redukciu dimenzie a segmentáciu) (Bunian et al., 2017), (Drachen et al., 2014), (Konert et al., 2015), (Żuchowska et al., 2021).

Event logy a telemetria sú dnes štandardnou súčasťou komerčného vývoja hier. V reálnom čase sa sleduje retencia, progres, monetizácia aj detailné herné akcie (Bauckhage et al., 2015), (Perišić & Pahor, 2023), (Mustač et al., 2022). Na tejto infraštruktúre vyrástla oblasť game analytics – od deskriptívnych štatistík a A/B testovania až po pokročilé modely (J. Tan & Katchabaw, 2022), (Melhart et al., 2020). Približne od roku 2010 sa zároveň výrazne rozšírili práce, ktoré pomocou klastrovania odvodzujú štýly hry priamo z logov: od MMO (napr. *World of Warcraft* (Drachen et al., 2014)) a free-to-play hier (Normoyle & Jensen, 2015) až po mobilné casual tituly (Fu et al., 2017), (Saas et al., 2016). Používajú sa rôzne postupy vrátane k-means, hierarchického a modelového klastrovania, self-organizing maps, NMF či archetypálnej analýzy (Bicalho et al., 2019), (Mustač et al., 2022), (García-Sánchez et al., 2020).

Výsledky z telemetrie často odhaľujú zrozumiteľné vzorce správania. Typickým príkladom je kontrast PvP (player-versus-player) vs. PvE (player-versus-environment) orientácie alebo rozdiel medzi speedrunnermi a completionistami (Fu et al., 2017), (Drachen et al., 2013), (Sipone et al., 2025). V hrách s mikrotransakciami sa zase v logoch pravidelne identifikuje malá skupina hráčov (tzv. whales), ktorá míňa neúmerne veľa v porovnaní s bežnými platiacimi hráčmi (Close et al., 2021). Zároveň sa však ukazuje, že segmentácia je citlivá na výber črt a kontext konkrétnej hry. Mnohé štúdie používajú ad hoc indikátory (napr. počty killov, navštívené zóny, počty prihlásení) a len zriedkavo systematicky odlišujú črty na úrovni relácie, hráča a času (Fu et al., 2017), (Milošević et al., 2017). Často tiež nie je jasne oddelené, čo v črtách reprezentuje schopnosti, motivácie a čo je dôsledok štrukturálnych podmienok (napr. dĺžka hrania, dostupný obsah). To komplikuje psychologickú interpretáciu klastrov (Żuchowska et al., 2021), (Habibi et al., 2023).

Ďalším problémom je prenositeľnosť postupov. Postupnosť od logov ku klastrom býva prispôsobená jednej dátovej sade a často nie je opísaná tak, aby sa dal spoľahlivo zopakovať inde (Tlili et al., 2021). Aj keď existujú metodické príspevky (napr. porovnania viacerých klastrovacích metód na rovnakých logoch), stále chýbajú ucelené, krokové postupy pre výber črt, redukciu dimenzie a validáciu segmentov naprieč hrami (Banihashem et al., 2024), (K. K. Yu et al., 2024).

V log-based modelovaní hráčov sa opakovane ukazujú dve metodické osi: **interpretovateľnosť** a **stabilita** (Bauckhage et al., 2015), (Busch, Mattheiss, Hochleitner, et al., 2016). Komplexné modely (autoenkóдеры, hlboké siete, zložené zmesové modely) vedia zachytiť jemné vzorce, no latentné reprezentácie sa ťažko prekladajú do pojmov, s ktorými pracuje dizajn (tempo boja, miera rizika, miera

explorácie) (Cheng et al., 2022), (X. Wang et al., 2025). Preto viacero prác odporúča jednoduchšie a čitateľné techniky, ako PCA alebo rotované faktory, aj za cenu miernej straty prediktívneho výkonu (Fu et al., 2017), (Yannakakis & Togelius, 2018b). Stabilita sa týka toho, či sa osoby objavujú konzistentne pri zmene metódy, parametrov a prevzorkovania dát. Štúdie ukazujú, že k-means, fuzzy c-means, hierarchické klastrovanie či archetypálna analýza môžu nad rovnakými črtami nájsť odlišné štruktúry; citlivosť sa prejavuje aj pri voľbe k a inicializáciách (Bauckhage et al., 2015), (Ferguson et al., 2020), (Yannakakis & Togelius, 2018b). Stabilita sa pritom často hodnotí len internými indexmi, ktoré málo hovoria o tom, ktorí hráči sú priradení spoľahlivo a ktorí sú „hraniční“. Bootstrap, validácia naprieč datasetmi alebo prístupy typu core-vs-periphery sa používajú skôr výnimočne (Agrawal et al., 2021), (Normoyle & Jensen, 2021).

S interpretovateľnosťou a stabilitou úzko súvisí aj otázka workflow. Aj keď je všeobecný postup známy, v praxi rozhoduje množstvo implicitných volieb: ktoré eventy zahrnúť, ako agregovať relácie na hráča, ako transformovať rozdelenia či aké korelácie tolerovať. Keďže tieto kroky bývajú v článkoch opísané stručne, replikácia je často nemožná. Aj preto sa objavujú výzvy na znovupoužiteľné metodológie a na precíznejšiu dokumentáciu celého postupu – od logov až po validované osoby (J. Tan & Katchabaw, 2022), (Bicalho et al., 2019), (Kirchner-Krath et al., 2024), (Ferguson et al., 2020), (Tricomi et al., 2023). Reprezentatívne práce porovnávajúce metódy segmentácie alebo aplikácie na veľké multiplayer logy pritom často prezentujú segmentáciu ako jednorazový výsledok a prinášajú len obmedzené dôkazy robustnosti pri prevzorkovaní či zmene parametrov, čo naznačuje, že stabilné overovanie zostáva v praxi skôr zanedbávané (Drachen et al., 2014), (Bauckhage et al., 2015), (Normoyle & Jensen, 2015), (Saas et al., 2016), (Normoyle & Jensen, 2021).

Metodika výskumu

V tejto časti sa opisujú dáta, predspracovanie a analytický postup, ktorým sa z hernej telemetrie odvodí interpretovateľné a stabilné osoby hráčov. Pracuje sa s telemetriou z *Another Useless Zombie Game*, single-player FPS experimentálneho prostredia navrhnutého a vytvoreného pre výskum. Každé hranie generuje časovo označený tok udalostí, ktorý zachytáva pohyb (polohu) a akcie (streľbu, zber zdrojov, interakcie so zombie a nabíjanie únikového portálu energiou ako cieľovú aktivitu).


Kľúčovou vlastnosťou prístupu je prepojenie celého postupu s explicitnou typológiou hráčov. V tejto štúdii sa používa Bartleho taxonómia (*Achiever*, *Explorer*, *Socializer*, *Killer*) ako dizajnerský slovník, nie ako meraný konštrukt (neodhaduje sa Bartle-skóre z dotazníkov). Typológia sa používa na návrh blokov metrík, interpretáciu latentných dimenzií a pomenovanie výsledných person. Rovnaký rámec je použiteľný aj s inými typológiami (napr. HEXAD, Yee), ak sa zmení mapovanie metrík na iné koncepty.

Postup spája surové záznamy z hry s personami, ktoré sú zároveň interpretovateľné a stabilné. Skladá sa z nasledujúcich krokov:

1. **Predspracovanie herných záznamov** – eventy sa premapujú zo surového formátu na jednotnú reprezentáciu základných akcií a relácií (pohyb, streľba, zber zdrojov, práca s portálom, udalosti so zombíkmi). Výstupom je reláciový záznam vhodný na extrakciu metrík.
2. **Konštrukcia behaviorálnych metrík a blokov** – z nízkoúrovňových udalostí sa odvodí metriky, ktoré majú priamu interpretáciu v pojmoch herných mechaník (napr. tempo a intenzita boja, miera explorácie, expozícia riziku, využitie zdrojov). Metriky sa organizujú do významových blokov a každý blok sa anotuje podľa primárnej väzby na typologické tendencie (v tomto datasete najmä *Achiever/Killer/Explorer*). Keďže ide o single-player hru, vlastnosti *Socializer* sa nedajú izolovať ako samostatný, zodpovedne interpretovateľný blok a zohľadňujú sa len nepriamo tam, kde to dáva zmysel.

3. **Agregácia a hygienizácia metrík na úrovni hráča** – metriky sa vypočítajú na úrovni hráča a skontrolujú sa ich rozdelenia, šikmosť a redundancia. Podľa potreby sa aplikujú transformácie a odstránia sa problematické alebo duplicitné premenné. Výstupom je normalizovaný vektor stabilných behaviorálnych charakteristík pre každého hráča (nie surový tok udalostí).
4. **Redukcia dimenzie a odhalenie latentnej štruktúry** – najprv sa odstránia vysoko redundantné premenné (korelačný skríning). Následne sa použije PCA, aby sa získali ortogonálne komponenty sumarizujúce širšie vzorce správania (napr. intenzita boja, exploratívny pohyb, miera rizika). Komponenty sa volia tak, aby zostali čitateľné v terminológii hry.
5. **Identifikácia kandidátnych person klastrovaním v PCA priestore** – v latentnom priestore sa preskúmajú kandidátne riešenia segmentácie a zvolí sa variant, ktorý poskytuje zmysluplné a interpretovateľné rozdelenie populácie. V tejto fáze sa hranice segmentov považujú za predbežné.
6. **Validácia stability a oddelenie jadra od hraničných prípadov** – stabilita sa overí postupom založeným na pruningu: hráči sa zoradia podľa individuálnej hodnoty siluety a vytvorí sa jadro z prípadov s vysokou koherenciou, pričom hraničné prípady s nejednoznačným členstvom sa do stabilného testu nezahŕňajú. Na jadre sa vykoná bootstrap prevzorkovanie, znovu-fit klastrovania a stabilita sa kvantifikuje pomocou ARI medzi referenčným a prevzorkovanými rozdeleniami. Za dôveryhodné sa považujú len riešenia s konzistentne vysokou stabilitou.
7. **Spätné mapovanie person do metrík a typologických blokov** – stabilné osoby sa premietnu späť do pôvodných metrík a blokov. Pre každú personu sa vyhodnotí profil naprieč metrikami (napr. tempo, expozícia riziku, exploračia, využitie zdrojov) a posúdi sa, či je interpretácia v súlade s vopred definovanými blokmi. Tento krok uzatvára segmentáciu do formy použiteľnej pre analytiku a dizajn.

Štruktúra pipeline je znázornená na Obr. 14.



Obr. 14 Vizualizácia postupu spracovania herných event logov s väzbou na typológiu.

Prípadová štúdia: FPS telemetria

Účastníci a herné prostredie

Empirickým základom štúdie je herná telemetria z *Another Useless Zombie Game*, single-player first-person shooter vyvinutej ako výskumný prototyp.

Hra sa odohráva v malom mestskom prostredí s viacerými generátormi zombíkov a centrálnou oblasťou továrne. Hráč sa voľne pohybuje v 3D priestore, strieľa na približujúcich sa zombíkov, zbiera

muníciu a balíčky zdravia a dodáva energiu na nabíjanie únikového portálu, ktorý predstavuje hlavný cieľ každého behu. Ukážka herného prostredia je na Obrázku 15.

Dataset obsahuje záznamy z 1 962 herných relácií, ktoré odohralo 156 unikátnych anonymizovaných hráčov. Každý hráč je dobrovoľne prepojitelný so svojou mailovou adresou pre porovnanie s inými view-mi. Hráči mohli odohrať ľubovoľný počet hier (relácií). V hre neboli skriptované scenáre ani vynútené zmeny obtiažnosti. Všetky pozorovania pochádzajú z prirodzeného hrania na rovnakej úrovni a s rovnakým súborom pravidiel.



Obr. 15 Herné prostredie a vizualizácia typickej scény útoku zombíkov..

Logované udalosti

Herný engine zaznamenáva aktivitu hráča ako sekvenciu časovo označených udalostí. Každý záznam obsahuje minimálne identifikátor hráča, identifikátor relácie, typ udalosti, časovú pečiatku a parametre špecifické pre danú udalosť. Základné typy udalostí sú:

- **Pohybové udalosti**, ktoré zachytávajú pozíciu a orientáciu hráča v čase.
- **Udalosti streľby**, vrátane informácie o zásahu zombíka, type zásahu (hlava/telo) a o pozícii, resp. vzdialenosti.
- **Interakcie so zombíkmi**, napr. uhryznutia a úmrtia zombíkov.
- **Udalosti zdrojov**, napr. zdvihnutie munície, batérií a balíčkov zdravia.
- **Udalosti portálu a spawnerov**, napr. streľba na spawner, zničenie spawneru, dodanie energie do únikového portálu a finálny stav portálu.
- **Hraničné udalosti relácie**, ktoré označujú začiatok a koniec hry (výhra, smrť alebo ukončenie hráčom).

Predspracovanie dát

Ako prvý krok sa z rekonštruovaných logov vytvorili individuálne herné relácie. Udalosti sa zoradili podľa času a zoskupili podľa identifikátora hráča. Nová relácia sa začala vždy vtedy, keď sa v logu objavil marker začiatku relácie, aj keď sa ten istý identifikátor hráča vyskytol už predtým. Opakované hranie toho istého hráča sa tak reprezentuje ako viacero samostatných relácií.

Následne sa odfiltrovali neúplné alebo chybné sekvencie a triviálne krátke či neaktívne relácie, ktoré nereprezentujú zmysuplné hranie. Konkrétne sa odstránili hry kratšie ako 40 sekúnd. Tento prah zodpovedá približne polovici najrýchlejšieho úspešného behu a efektívne vylučuje relácie, ktoré hráči ukončili takmer okamžite po štarte. Po tomto kroku zostalo 855 relácií.

Pre každú validnú reláciu sa následne vypočítal súbor behaviorálnych metrík na úrovni relácie (napr. dĺžka relácie, pohyb, boj, riziko a indikátory práce so zdrojmi).

Aby sa zachytili počiatočné parametre modelu, predspracované herné event logy sa transformujú na behaviorálne charakteristiky na úrovni hráča, ktoré sa dajú zmysluplne interpretovať v terminológii

známych typológií. Postup vychádza z Bartleho taxonómie a pre Another Useless Zombie Game definuje štyri široké štýly kompatibilné s hernými mechanikami. Pre každý štýl sa identifikujú tie aspekty správania (pohyb, streľba, zber zdrojov, spôsobené poškodenie, interakcia s portálom), ktoré najlepšie reprezentujú jeho tendencie, a agregujú sa do numerických charakteristík počítaných na úrovni relácie a následne hráča.

Definícia parametrov vychádza z nasledujúcich úvah o motivačných skupinách:

- **Achiever** je orientovaný na výkon a splnenie cieľa – snaží sa čo najrýchlejšie a najefektívnejšie nabiť portál, optimalizuje zber batérií, ničí spawnery a maximalizuje kill rate.
- **Explorer** uprednostňuje prieskum priestoru – veľa sa pohybuje, pokrýva veľkú časť mapy, skúša rôzne trasy a zóny, menej mu ide o časovo optimálne dokončenie.
- **Socializer** sa v single-player verzii najlepšie približuje uvoľnenému, zážitkovému štýlu. To, čo by v klasickej typológii bola sociálna interakcia, sa tu prejavuje skôr nízko-súťaživým hraním (viac chôdze bez streľby, zber zdrojov skôr pre pocit bezpečia než pre výkon). V tomto type hry sa však tento profil nepovažuje za samostatný typ – jeho vyčlenenie by bolo nútené a opieralo by sa o špekulatívne závery.
- **Killer** má agresívny bojový štýl – vyhľadáva súboje, často strieľa za pohybu, približuje sa k zombíkom, riskuje uhryznutie, ale dosahuje vysoký kill rate. Zaujíma ho dominancia v boji, nie nevyhnutne efektívny progres k portálu.

Výsledkom konceptuálneho mapovania je Tab. 24, ktorá sumarizuje všetky extrahované charakteristiky na úrovni hráča. Pre každú metriku sa uvádza názov, zdroj(e) v logu, stručný význam v kontexte hry, primárny Bartle štýl(y) a konceptuálny opis výpočtu.

Pri definícii charakteristík sa uprednostňujú najmä minútové miery (per-minute), pretože surové počty udalostí sú silno ovplyvnené dĺžkou hry. Hráč, ktorý prežije dlhšie, takmer nevyhnutne nazbiera viac killov, predmetov, uhryznutí či výstrelov aj pri podobnej intenzite hry. Normalizáciou podľa herného času (napr. kills/min, dĺžka dráhy/min, bites/min, zbery/min) sa získajú charakteristiky, ktoré lepšie odrážajú stabilné tendencie (tempo boja, intenzitu pohybu, rizikovosť, vyhľadávanie zdrojov) než samotnú expozíciu času.

Naopak, intrinsicky časové indikátory (napr. čas do prvej dodávky energie, čas do prvého uhryznutia, priemerný čas medzi uhryznutiami) a ohraničené pomery (napr. headshot ratio, presnosť streľby, bites-per-kill) sa ponechávajú v pôvodnej mierke, keďže už vyjadrujú správanie vzhľadom na čas alebo úspešnosť.

Tab. 24 Prehľad behaviorálnych metrík

Názov metriky	Popis	Zdroj(e) v logu	Bartle	Výpočet z event logov
Čas do prvej dodávky energie	Ako rýchlo hráč začne prispievať k hlavnému cieľu (nabíjanie portálu).	collect, portal, game start	A	$t(\text{prvá návšteva portálu}) - t(\text{game_start})$
Miera zberu batérií	Tempo zbierania energetických batérií.	collect	A	$\# \text{batérií} / \text{playtime}$
Čas do zničenia prvého spawnru	Ako rýchlo hráč zneškodní prvý zdroj zombíkov.	shoot, spawner, game start	A	pre prvý zničený spawner: $t(\text{destroy}) - t(\text{game_start})$
Priemerný čas zničenia spawnru	Typická rýchlosť ničenia spawnrov.	shoot, spawner	A	pre každý spawner: $t(\text{destroy}) - t(\text{prvý výstrel na spawner})$; potom priemer
Intenzita „focus fire“ na spawner	Intenzita streľby na spawner počas jeho likvidácie.	shoot, spawner	A	pre každý spawner: $\# \text{shots_on_spawner} / (t(\text{destroy}) - t(\text{prvý výstrel}))$; potom priemer
Headshot zásahy za minútu	Počet presných zásahov zombíkov do hlavy za minútu.	shoot	A/K	počet shoot eventov s hit = true a hit_type = head / playtime

Názov metriky	Popis	Zdroj(e) v logu	Bartle	Výpočet z event logov
Ne-head zásahy za minútu	Počet menej efektívnych zásahov (telo) za minútu.	shoot	A/K	počet shoot eventov s hit = true a hit_type≠head / playtime
Pomer headshotov	Normalizovaná presnosť: aký podiel zásahov sú headshoty.	shoot	A/K	headshot_hits / (headshot_hits + non_head_zombie_hits)
Presnosť streľby	Efektivita streľby bez ohľadu na lokalizáciu zásahu.	shoot	A/K	#hits_total / #shots_total
Počet výstrelův na spawner	Do akej miery hráč preferuje ničenie zdrojov pred jednotlivými zombíkmi.	shoot	A/K	počet shoot eventov s target_type = spawner
Energia do portálu za minútu	Rýchlosť nabíjania únikového portálu v čase.	portal	A	total_energy_delivered_to_exit_portal / playtime
Killy za minútu	Tempo eliminácie zombíkov (bojový výkon v čase).	shoot/kill	A/K	#kills / playtime
Celkový počet killov	Celková bojová produktivita v relácii.	shoot/kill	A/K	počet zombie kill eventov
Dĺžka dráhy za minútu	Ako aktívne sa hráč pohybuje.	move	E	total_path_length / playtime
Celková dĺžka dráhy	Absolútny objem pohybu v leveli.	move	E	súčet vzdialeností medzi po sebe idúcimi pozíciami
Trvanie relácie	Ako dlho hráč ostane v hre pred ukončením.	všetky eventy	A/E	t(posledný event) – t(prvý event)
Pokrytie plochy	Koľko z mapy hráč preskúma.	move	E	počet unikátnych buniek navštívených v diskretizovanej mape
Zbery zdravia za minútu	Ako často hráč obnovuje zdravie (sebazáchova).	collect	E	počet collect s item_type = health/heart / playtime
Zbery munície za minútu	Tendencia manažovať muníciu a vyhľadávať zdroje.	collect	A/E	počet collect s item_type = ammo / playtime
Podiel minút bez streľby	Podiel času strávený pohybom/pozorovaním bez boja.	shoot, time	E	podiel 1-minútových binov bez shoot eventov
Priemerná dĺžka dráhy bez streľby	Typická dĺžka „pokojných presunov“ medzi bojmi.	move, shoot	E	priemer dráh medzi po sebe idúcimi výstrelmi
Počet uhryznutí	Ako často sa zombíci dostanú na dosah a zasiahnu hráča.	bite	K/E	počet bite eventov
Priemerný čas medzi uhryznutiami	Správanie po zásahu: či hráč ostáva v nebezpečí.	bite	K/E	zoradiť bite eventy podľa času, počítať $\Delta t(i+1) - \Delta t(i)$, potom priemer
Index campovanie vs. roaming	Rozlišuje pobyt v malej oblasti vs. pohyb po mape.	move	E/K	(#unique_grid_cells_visited) / total_path_length
Počet hier/relácií na hráča	Celková angažovanosť: koľkokrát sa hráč vráti hrať.	session metadata	All	počet unikátnych session_id pre user_id
Typ ukončenia hry	Či hráč zvyčajne dokončí cieľ, zomrie alebo odíde.	final, death, exit	A/K/E	kategória z posledného eventu: {final_portal_open, death, leave}
Výstrely počas pohybu za minútu	Agresívny „kiting“ štýl (streľba bez zastavenia).	move, shoot	K	pre shoot event: rýchlosť z blízkych move eventov; počítať výstrely s speed>prahová hodnota / playtime
Pohyb dozadu za minútu	Miera ústupu pri konfrontácii s nepriateľmi.	move (s rotáciou)	K	informácia je uložená vo finálnom evente
Priemerná vzdialenosť streľby	Preferovaná bojová vzdialenosť (na blízko vs. bezpečný odstup).	shoot, pozície cieľov	K/E	pre každý zásah: vzdialenosť medzi pozíciou hráča pri výstrele a pozíciou cieľa; potom priemer
Čas do prvého uhryznutia	Ako dlho sa hráč vyhne zásahu; indikátor rizika/opatrnosti.	bite, game start	K/E	t(prvé uhryznutie) – t(game_start); ak bez uhryznutia, výsledok = playtime
Rizikový pomer (uhryznutia na kill)	Rovnováha medzi prijatým poškodením a efektivitou v boji.	bite, kill	K	#bites / max(#kills, 1); vyššie = viac poškodenia na dosiahnutý kill

Pre následné modelovanie sa dáta agregovali na úroveň hráča. Ponechali sa všetci hráči, ktorí mali aspoň jednu validnú (≥ 40 s) reláciu, čo viedlo k finálnej vzorke 156 hráčov. Pre každého hráča sa vypočítal priemer všetkých numerických charakteristík naprieč jeho ponechanými reláciami a zároveň

sa zaznamenal počet hier ako doplnkový deskriptor angažovanosti. Výsledný dataset na úrovni hráča obsahuje jeden riadok na hráča a použil sa ako vstup do klastrovania a ďalších analýz.

Deskriptívna štatistika a vizualizácia charakteristík

Aby sa získal celkový obraz o výslednom datasete na úrovni hráča, pre všetky charakteristiky sa vypočítali základné deskriptívne štatistiky (priemer, smerodajná odchýlka, minimum, maximum, medián). Charakteristiky sa zoradili do štyroch konceptuálnych kategórií: *Angažovanosť* (počet a trvanie herných relácií), *Explorácia* (pohyb a priestorové pokrytie), *Výkon* (bojová a taktická efektivita) a *Zdroje* (zber a používanie batérií, munície a zdravia). Tab. 25 uvádza tieto štatistiky a ukazuje výraznú variabilitu v každej kategórii, vrátane širokých rozsahov pri ukazovateľoch viazaných na herný čas, pohyb a bojový výkon.


Tab. 25 Deskriptívna štatistika charakteristík hráča.

	priemer	sd	min	max	medián
Angažovanosť					
Počet hier/relácií na hráča	12.6	53.4	1	560	3
Trvanie relácie	409	306.4	45.8	2261	347.3
Počet hier s dĺžkou > 40 s	5.5	12.2	1	92	2
Hra – výhra	1.2	2.6	0	20	1
Hra – smrť	2.6	6.5	0	55	1
Hra – prerušená	1.7	4.4	0	43	1
Explorácia					
Dĺžka dráhy za minútu	472.5	221.2	172.6	2736.8	444.4
Celková dĺžka dráhy	3118	2372.2	231.8	18276	2630.4
Pokrytie plochy	213.1	144	21.8	1044	187.3
Podiel minút bez strelby	0.1	0.3	0	3.1	0.1
Priemerná dĺžka dráhy bez strelby	35.3	169.4	2.1	1956.6	10.6
Index campovanie vs. roaming	0.1	0.3	0	2.6	0.1
Výkon					
Čas do zničeného prvého spawnru	252.6	241.5	11.5	1308.8	177.3
Priemerný čas zničeného spawnru	195.5	217.7	0.6	1224	122.3
Intensita „focus fire“ na spawner	1.7	2.2	0	14.2	0.8
Headshot zásahy za minútu	6.8	5.4	0	30.1	5.8
Ne-head zásahy za minútu	14.9	10.9	0	53.5	11.9
Pomer headshotov	0.3	0.2	0	1	0.3
Presnosť strelby	0.5	0.2	0	1	0.6
Počet výstrelů na spawner	12.4	12.6	0	56	8.3
Energia do portálu za minútu	76.1	169	0	1310	40.8
Killy za minútu	9.2	6.6	0	46	8.1
Celkový počet killov	58.5	48.8	0	399	48.5
Počet uhryznutí	14.5	10.4	0	63	13.7
Priemerný čas medzi uhryznutiami	32.6	63.5	0	692	18.9
Výstrely počas pohybu za minútu	34.6	19.3	0	106.5	32.8
Pohyb dozadu za minútu	35.2	18.3	0	101.5	34.9
Priemerná vzdialenosť strelby	8.1	2.8	3.7	18.4	7.8
Čas do prvého uhryznutia	102.9	63.8	13.9	390.2	85.5
Rizikový pomer (uhryznutia na kill)	0.6	1	0	5.9	0.3
Zdroje					
Čas do prvej dodávky energie	184.4	173.2	11.5	1308.8	142
Miera zberu batérií	0.1	0.1	0	0.4	0.1
Zbery zdravia za minútu	6.4	6.9	0	42	4.7
Zbery munície za minútu	14.6	15.3	0	102	10.5

Viacere črty majú výrazne pravostranné (right-skewed) rozdelenia, čo je viditeľné aj na rozdiel medzi mediánom a maximom (napr. celková dĺžka dráhy, energia do portálu za minútu, časové metriky spawnrov a viacere „počtové“ metriky ako killy či uhryznutia). Na zníženie vplyvu extrémnych hodnôt a stabilizáciu variability sa na všetky striktné nezáporné počtové a časové črty v kategóriách

Angažovanosť, Explorácia, Výkon, Riziko a Zdroje aplikovala transformácia $\log(1 + x)$. Ohraničené pomery (napr. pomer headshotov, presnosť streľby) sa ponechali v pôvodnej mierke.

Obr. 16 ukazuje pôvodné rozdelenia štyroch reprezentatívnych črt (energia do portálu za minútu, celková dĺžka dráhy, celkový počet killov a rizikový pomer uhryznutia na kill) a ilustruje výraznú pravostrannú šikmosť, ktorá motivuje použitie logaritmickkej transformácie. Všetky ďalšie analýzy sú založené na takto transformovanom súbore črt.



Obr. 16 Pôvodné rozdelenia (histogramy) štyroch reprezentatívnych behaviorálnych črt na úrovni hráča: (a) energia do portálu za minútu, (b) celková dĺžka dráhy, (c) celkový počet killov a (d) rizikový pomer (uhryznutia na kill). Všetky štyri miery sú výrazne pravostranné; malá podmnožina hráčov tvorí extrémne hodnoty.

Na základe konštrukcie črt a agregácie opísanej vyššie sa ďalej analyzujú transformované charakteristiky na úrovni hráča. Cieľom je identifikovať systematické vzorce správania v hre a pripraviť reprezentáciu vhodnú pre klastrovanie.

Redukcia dimenzií

Aby sa získala kompaktná a numericky stabilná reprezentácia správania, najprv sa zníži dimenzionalita priestoru črt a následne sa pristúpi ku klastrovaniu.


Ako prvý krok sa preskúmala **korelačná štruktúra** transformovaných charakteristík na úrovni hráča. Z atribútov transformovaných pomocou $\log(1 + x)$ sa vypočítala Pearsonova korelačná matica a vizualizovala sa ako heatmapa (Obrázok 4), aby sa identifikovali skupiny silno korelovaných premenných a redundancia medzi indikátormi. V súlade so štandardnou praxou sa za podstatnú redundanciu považujú absolútne korelácie s hodnotou $|r| > 0.7$.

Korelačná matica odhalila viacero koherentných skupín silno korelovaných črt, ktoré sa dajú interpretovať ako vyššie úrovne behaviorálnych faktorov.

Prvá skupina zachytáva kontrast medzi bezpečným pohybom a agresívnym bojom, druhá skupina spája čas do zničenia prvého spawneru s časom do prvej dodávky energie a tretia skupina zahŕňa priemerný čas zničenia spawneru, počet výstrelův na spawner a intenzitu „focus fire“ na spawner.

Najväčší zhľuk tvoria premenné súvisiace s celkovou aktivitou a „objemom hry“, vrátane trvania relácie, celkovej dĺžky dráhy, pokrytia plochy, headshot zásahov za minútu, killov za minútu, celkového počtu killov, počtu uhryznutí, zberov zdravia za minútu a zberov munície za minútu. Vysoké korelácie tu do veľkej miery odrážajú fakt, že hráči, ktorí prežijú dlhšie a viac sa pohybujú, zároveň zabijú viac zombíkov, nazbierajú viac zdrojov a častejšie dostanú zásah.

Napokon sa ukázala aj „meta“ skupina, ktorá spája ukazovatele angažovanosti (počet hier/relácií na hráča, resp. počet hier nad 40 sekúnd) s výsledkami relácií (výhra, smrť, prerušenie). Táto skupina zachytáva dlhodobejšie zapojenie a typický spôsob ukončovania behov.



Obr. 17 Heatmapa Pearsonových korelácií medzi transformovanými behaviorálnymi črtami na úrovni hráča.

Na základe týchto zhľukov sa z pôvodnej sady črt odstránili redundantné indikátory a ponechali sa konceptuálne odlišné proxy metriky, ktoré reprezentujú hlavné osi variability (explorácia, tempo boja, rizikovosť a angažovanosť). Úplný zoznam vyradených a ponechaných premenných spolu s definíciami metrik je uvedený v článku (Ján Skalka et al., 2026); ďalšie analýzy (PCA a klastrovanie) pracujú už s týmto redukovaným setom.

Do **PCA** sa zahrnuli všetky zostávajúce behaviorálne črty (21 dimenzií), keďže silno redundantné premenné už boli odstránené v korelačnej analýze. PCA sa tu teda nepoužíva na „vyhadzovanie duplicit“, ale na získanie reprezentácie širších vzorcov kovariácie medzi pohybom, bojom, rizikom, zdrojmi a angažovanosťou. Takto vzniknutý latentný priestor je numericky stabilnejší a vhodný ako vstup pre následné klastrovanie.

Tab. 26 uvádza podiel vysvetlenej variability pre jednotlivé komponenty. Prvý komponent (PC1) vysvetľuje 19.9 % variability, PC2 17.1 % a PC3 10.4 %. Prvé tri komponenty spolu vysvetľujú 47.4 % a prvých päť 63.5 % variability; následne sa prírastky splošťujú (typicky 2–4 % na komponent). Ako kompromis medzi kompaktnosťou a stratou informácie sa ponechalo 12 komponentov, ktoré spolu vysvetľujú 91.0 % variability. Tým sa pôvodných 21 črt nahradilo 12 ortogonálnymi komponentmi pri zachovaní väčšiny variability správania.

Tab. 26 Podiel vysvetlenej variability pre jednotlivé komponenty.

PC	podiel vysvetlenej variability	kumulatívna variabilita
PC1	0.199	0.199
PC2	0.171	0.370
PC3	0.104	0.474
PC4	0.085	0.559
PC5	0.076	0.635
PC6	0.065	0.701
PC7	0.058	0.758
PC8	0.039	0.798
PC9	0.035	0.833
PC10	0.030	0.863
PC11	0.025	0.888
PC12	0.022	0.910

Na podporu interpretácie PCA riešenia sa analyzovali loadings; v Tabuľke 27 sa uvádzajú len hodnoty s $|loading| \geq 0.30$. Prvé komponenty sa dajú čítať aj v jazyku typologického ukotvenia (bloky metrík), čo zjednodušuje prechod k pomenovaniu person.

Tab. 27 Vplyv prvých piatich komponentov na behaviorálne črty (uvedené len $|loading| \geq 0.30$).

Kategória / črta	PC1	PC2	PC3	PC4	PC5
Angažovanosť					
Počet hier s dĺžkou > 40 s		-0.33			
Explorácia					
Dĺžka dráhy za minútu			-0.41		
Pokrytie plochy		0.32		0.41	
Podiel minút bez strelby			0.34		0.50
Priemerná dĺžka dráhy bez strelby	-0.33				
Index campovanie vs. roaming			0.45		0.36
Výkon / riziko					
Priemerný čas zničenia spawneru					0.47
Presnosť strelby	0.31				
Energia do portálu za minútu		-0.32		0.39	
Killy za minútu	0.44				
Počet uhryznutí	0.30				
Priemerný čas medzi uhryznutiami				0.36	
Výstrely počas pohybu za minútu	0.35				
Pohyb dozadu za minútu				-0.36	
Rizikový pomer (uhryznutia na kill)			0.47		
Čas do prvého uhryznutia		0.29	-0.27		
Zdroje					
Čas do prvej dodávky energie		0.43			
Miera zberu batérií		-0.37			
Zbery munície za minútu	0.33				0.34

Stručná interpretácia prvých komponentov (ukotvenie)

- PC1 – bojová intenzita a efektivita (Killer/Achiever pól): vyššie skóre znamená viac killov, viac strelby počas pohybu, lepšiu presnosť, častejší zber munície a viac „close encounters“ (uhryznutia), pri kratších úsekoch pohybu bez boja.
- PC2 – cieľový progres vs. rozptýlený prieskum (Achiever vs. Explorer): vyššie skóre sa viaže na neskoršiu prvú dodávku energie a väčšie pokrytie plochy, pri nižšej efektivite nabíjania portálu a zberu batérií; nižšie skóre zodpovedá viac „goal-oriented“ priebehu.
- PC3 – statický, rizikový štýl (campovanie + vysoké bites-per-kill): vyššie skóre znamená menej pohybu, viac času bez strelby a vyšší rizikový pomer; nižšie skóre opisuje mobilnejšie a priebežnejšie zapojenie.

- PC4 – kontrola priebehu (proaktívny vs. defenzívny štýl): vyššie skóre sa spája s pohybom po mape, stabilným progresom portálu a dlhšími intervalmi medzi uhryznutiami, pri menšom ústupe dozadu.
- PC5 – extrémne pomalé/statické hranie: dominuje vysoký podiel času bez streľby, campovanie a pomalšia práca so spawnermi.

Celkovo PCA sumarizuje pôvodné črty do kompaktného súboru dimenzií, ktoré stabilizujú vstup pre klastrovanie a zároveň ostávajú čitateľné cez bloky metrík definované typologickým ukotvením.

Klastrová analýza

Po extrakcii prvých 12 hlavných komponentov (PC1–PC12; spolu vysvetľujú 91 % variability) sa hráči klastrovali v PCA priestore pomocou k-means pre $k = 2$ až 8. Pre každé riešenie sa vypočítali tri štandardné interné validačné indexy: silueta, Calinski–Harabasz a Davies–Bouldin. Výsledky sumarizuje Tab. 28.

Tab. 28 Interné validačné indexy pre $k = 2 \dots 8$


k	Silhouette score	Calinski-Harabasz index	Davies-Bouldin index
2	0.267	24.874	2.148
3	0.174	25.242	1.793
4	0.191	23.511	1.528
5	0.148	23.401	1.696
6	0.168	23.761	1.484
7	0.161	22.939	1.484
8	0.152	23.468	1.422

Riešenie s dvoma klastrami dosiahlo najvyššiu siluetu (0.27) a relatívne vysoký Calinski–Harabasz index (24.9), no viedlo len k hrubej dichotómii, ktorá spájala odlišné štýly hry do širokých skupín typu viac vs. menej aktívni. Pre $k \geq 3$ sa silueta pohybovala približne medzi 0.15–0.19 (lokálne maximum pri $k = 3$, $k = 4$ a $k = 6$). Calinski–Harabasz bol najvyšší pri $k = 3$ (25.2), ale pre $k = 4$ až $k = 8$ boli hodnoty veľmi podobné (cca 23–24), čo naznačuje, že interné indexy samy osebe neukazujú jednoznačné optimum. Davies–Bouldin sa s rastúcim k zlepšoval (klesal z 2.15 pri $k = 2$ na 1.42 pri $k = 8$), čo je typické pri jemnejšom rozdelení, no zlepšenie sa po $k = 6$ už javí ako marginálne. Spolu tieto ukazovatele naznačujú, že riešenia v rozsahu $k = 3$ až 6 ponúkajú porovnateľný kompromis medzi kompaktnosťou a separáciou a že zvyšovanie k nad tento rozsah prináša klesajúci prínos.

Ako doplnok ku centroidovému klastrovaniu sa fitovali aj Gaussian mixture modely (GMM) s rôznym počtom komponentov a optimalita sa hodnotila pomocou BIC. Minimum BIC vyšlo pre osemkomponentnú zmes ($k = 8$, BIC = 5766.1, AIC = 3548.9), čo naznačuje, že jemnejšia Gaussovská aproximácia hustoty v PCA priestore vyžaduje viac komponentov. Komponenty GMM však nemusia zodpovedať psychologicky odlišným typom: ďalšie Gaussovské krivky môžu zachytávať lokálnu šikmost alebo ťažké chvosty v rámci širších štýlov, pričom nepredstavujú nutne samostatné osoby.

Vyskúšalo sa aj DBSCAN klastrovanie založené na hustote priamo na PCA reprezentácii. Pri širokom rozsahu parametrov DBSCAN priradil všetkých hráčov k šumu ($\{-1:156\}$), t. j. nenašiel stabilné ostrovy vysokej hustoty. To naznačuje, že správanie v datasete skôr tvorí plynulé kontinuum než súbor prirodzene oddelených, hustotne výrazných klastrov.

Ako doplnková kontrola dimenzionality sa vykonala Hornova paralelná analýza pôvodných aj log-transformovaných črt (Obr. 18).



Obr. 18 Paralelná analýza pôvodných behaviorálnych črt.


Hoci paralelná analýza formálne informuje počet latentných dimenzií (nie počet klastrov), zistenie približne piatich až šiestich podstatných komponentov podporuje voľbu riešení s $k = 5$ až $k = 6$ personami ako rozumný kompromis medzi granularitou a interpretovateľnosťou. Preto sa riešenia v tomto rozsahu ďalej analyzovali podrobnejšie.

Profily klastrov

Na základe PCA sa na klastrovanie použili skóre prvých dvanástich komponentov (PC1–PC12), ktoré spolu vysvetľujú 91 % variability, ako ortogonálna reprezentácia správania. Keďže cieľom je získať menší počet kompaktných a približne sférických zhľukov v kontinuálnom behaviorálnom priestore, zvolilo sa k-means klastrovanie s euklidovskou vzdialenosťou ako primárna metóda. Na základe vyššie uvedených indexov sa pozornosť sústredila na riešenia so strednou granularitou ($k = 5$ a $k = 6$).

Na charakterizáciu klastrov sa analyzovali priemerné hodnoty na pôvodných behaviorálnych črtách a vizualizovali sa pomocou radarových grafov. Ako prvé sa preskúmalo päť-klastrové riešenie k-means, ktoré rozdelilo 156 hráčov do klastrov veľkostí 77, 40, 31, 4 a 4 (Obrázok 19).

Pre každé riešenie sa najprv vybrané herné metriky štandardizovali naprieč hráčmi pomocou z-skóre. Následne sa v radarových grafoch zobrazili priemery klastrov, kde hodnoty nad nulou indikujú nadpriemerné správanie a hodnoty pod nulou podpriemerné správanie na danej osi.




Obr. 19 Priemerné behaviorálne profily hráčskych klastrov ($k = 5$).

Pri použití z-skóre na osiach radarového grafu (každá os je normalizovaná naprieč hráčmi) sa ukazuje, že tri klastre tvoria hlavné, interpretovateľné persóny, zatiaľ čo dva predstavujú malé hraničné prípady:

- Klaster 2 (n = 77) – hráči s najvyšším pokrytím plochy, killmi za minútu, strelbou počas pohybu a pohybom dozadu. Majú tiež nadpriemernú presnosť, energiu do portálu, zbery munície aj batérií a zároveň nízke hodnoty pohybu bez strelby.
- Klaster 0 (n = 31) – hráči s najvyšším počtom odohraných hier, vysokou presnosťou strelby a pomerom headshotov, rýchlym ničením spawnerov a skorou prvou dodávkou energie. Majú slušné tempo killov, no menej extrémne roaming správanie než klaster 2. Profil pôsobí ako skupina skúsenejších, efektívnych hráčov, ktorí hrajú efektívne a optimalizujú priebeh, nie surovú agresivitu.
- Klaster 1 (n = 40) – hráči s nízkym počtom odohraných hier, priemerným pohybom, stredným pokrytím plochy, presnosťou a killmi, no veľmi nízkym podielom neaktívneho času. Súčasne majú zvýšené miery smrti a predčasného ukončenia relácie. Hráči sú aktívni (pohyb aj strelba), no aktivitu slabšie premieňajú na progres a behy často končia prerušením.
- Klaster 3 (n = 4) – malá skupina s veľmi vysokým podielom času bez strelby, extrémne vysokým indexom campovania a podpriemernou dĺžkou dráhy. Napriek určitej energii do portálu a killom majú dlhý čas medzi uhryznutiami a vysokú mieru smrti. Ide o extrémny štýl „zostať na mieste a minimalizovať riziko“, ktorý sa výrazne odlišuje od ostatných.
- Klaster 4 (n = 4) – ďalší malý klaster s najvyššou dĺžkou dráhy za minútu a vysokou dĺžkou dráhy bez strelby, no s nízkym pokrytím plochy a výrazne nízkymi hodnotami takmer všetkých bojových metrík (presnosť, headshoty, killy, uhryznutia, energia do portálu, zber munície). Hráči zriedkavo zomierajú a málokedy sú uhryznutí – prevažne sa pohybujú bez kontaktu s nepriateľmi.

Celkovo riešenie k = 5 prináša tri veľké, dobre interpretovateľné profily a dva malé, extrémne klastre, ktoré zachytávajú zriedkavé správanie na okrajoch priestoru.



Obr. 20 Priemerné behaviorálne profily hráčskych klastrov (k = 6).

Šesť-klastrové riešenie má veľmi podobnú štruktúru. Veľkosti klastrov sú 68, 37, 24, 20, 4 a 3. Oproti k = 5 sa dodatočná granularita prejavuje najmä v oblasti vysoko-aktívnych hráčov; malé okrajové klastre pretrvávajú.

V rámci výkonnej skupiny sa pôvodný „silný bojovník“ rozdelí na dva podtypy.

- Klaster 2 (n = 24) vykazuje najvyššie tempo killov za minútu, najvyššiu presnosť strelby a pomer headshotov a zároveň výrazný zisk energie do portálu – ide o najefektívnejších „killerov“.
- Klaster 3 (n = 68) má o niečo nižší, ale stále vysoký výkon: vysoké pokrytie plochy, dobrú presnosť aj energiu do portálu, pričom má relatívne nízky počet hier na hráča.

Dva malé hraničné klastre zostávajú. Klaster 4 ($n = 4$) sa prakticky nemení a zodpovedá profilu „nízko angažovaný chodec“ ako pri $k = 5$. Klaster 5 ($n = 3$) predstavuje ešte extrémnejší „camping“ profil s veľmi vysokým indexom campovania a podielom času bez streľby, krátkou dráhou, zvýšenou mortalitou a vysokým počtom uhryznutí na kill.

Prechod z piatich na šesť klastrov teda mikroklastre neeliminuje: zachováva zriedkavé profily „chodcov“ a „camping“ hráčov a zároveň jemnejšie delí vysoko-výkonnú oblasť na dva podtypy.

Stabilita klastrov

Bootstrap stabilita sa vyhodnotila pomocou Adjusted Rand Index (ARI) pri 300 prevzorkovaniach. Pre riešenie $k = 5$ bol priemerný ARI 0.51 (medián 0.52); pre $k = 6$ boli zodpovedajúce hodnoty 0.53 a 0.50. Obe riešenia teda vykazujú len strednú reprodukovateľnosť. Navyše, pri $k = 6$ vznikli dva mikroklastre ($n = 3$ a $n = 4$), zatiaľ čo pri $k = 5$ sa objavili tri veľké klastre ($n = 31, 40, 77$) a dva malé okrajové klastre ($n = 4$ a $n = 4$). Keďže rozdiel v ARI je zanedbateľný a mikroklastre sa objavujú v oboch prípadoch, $k = 5$ sa zvolilo ako parsimonnejšia možnosť, pričom tri veľké klastre sa interpretujú ako jadrové osoby a dva malé ako zriedkavé okrajové prípady.

Na oddelenie stabilných jadier od variabilnej šumovej zložky správania sa použil siluetovo riadený pruning. Pre riešenia $k = 5$ a $k = 6$ sa pre všetkých hráčov vypočítali siluety a hráči sa v rámci každého klastra zoradili podľa hodnoty siluety. Na základe tohto poradia sa vytvorili „jadrové“ vzorky tak, že sa v každom klastri ponechala len horná proporcia q hráčov s najvyššou koherenciou ($q = 0.70$ až 0.95). Každá takto orezaná jadrová vzorka sa znovu klasifikovala s rovnakým nastavením k -means a reprodukovateľnosť priradenia v jadre sa opäť vyhodnotila bootstrap ARI (300 prevzorkovaní).

Pre $k = 5$ viedlo ponechanie horných 70 % hráčov v každom klastri k jadrú s 110 hráčmi, priemernou siluetou 0.235 a veľmi vysokou stabilitou (medián ARI 0.924, priemer ARI 0.887). Pri zvyšovaní q (0.80 a 0.90) jadro rástlo (127 a 143 hráčov), no zároveň klesala koherencia (silueta 0.21 a 0.17) aj stabilita (medián ARI klesol na 0.83 a 0.72).


Vzorec pre $k = 6$ bol veľmi podobný: pri $q = 0.70$ malo jadro 111 hráčov, siluetu 0.242 a medián ARI 0.882; väčšie jadrá opäť viedli k monotónnemu poklesu stability (Tab. 29).

Tab. 29 Stabilita jadra pri siluetovom pruningu (bootstrap ari, 300 prevzorkovaní).

q	N core	Silhouette score	ARI median	ARI priemer	ARI SD
k = 5					
0.7	110	0.235	0.924	0.887	0.119
0.75	118	0.219	0.9	0.85	0.14
0.8	127	0.216	0.83	0.791	0.158
0.85	135	0.196	0.759	0.729	0.169
0.9	143	0.166	0.723	0.672	0.175
0.95	151	0.166	0.611	0.592	0.194
k = 6					
0.7	111	0.242	0.882	0.851	0.12
0.75	118	0.227	0.866	0.833	0.129
0.8	128	0.212	0.819	0.771	0.167
0.85	135	0.2	0.773	0.737	0.172
0.9	144	0.184	0.685	0.673	0.172
0.95	151	0.165	0.559	0.58	0.163

Najkoherentnejších približne 70–75 % hráčov v každom klastri tvorí jadro, v ktorom je riešenie k -means vysoko reprodukovateľné (medián ARI = 0.9). Naopak, pridanie hráčov s nízkou siluetou zvyšuje najmä nejednoznačnosť a lokálny šum v priradení. Keďže profily stability pre $k = 5$ a $k = 6$ sú porovnateľné a $k = 5$ poskytuje transparentnejšiu štruktúru (tri veľké klastre + dva zriedkavé okrajové prípady), ako primárny model sa prijalo riešenie $k = 5$ s $q = 0.70$.

Aby sa overilo, že pruning odstraňuje najmä nejednoznačné prípady a nemení samotnú štruktúru person, porovnávalo sa riešenie $k = 5$ na plnej vzorke s príslušným jadrom pri $q = 0.70$. Vo všetkých piatich klastroch boli profily pozoruhodne podobné: rozdiely v jednotlivých črtách boli malé a usporiadanie klastrov pozdĺž kľúčových behaviorálnych dimenzií zostalo prakticky nezmenené. Obr. 21 zobrazuje radarové profily jadra, ktoré možno priamo porovnať s takmer identickými personami z Obr. 19.



Obr. 21 Priemerné behaviorálne profily jadrových klastrov hráčov ($k = 5$, $q = 0.70$).

Analýza jadra tak slúži ako kontrola robustnosti a je konzistentná s ARI výsledkami: po odstránení hráčov s nízkou koherenciou tvorí zostávajúcich približne 70–75 % hráčov na klastre stabilné jadro, v ktorom je priradenie k-means takmer dokonale reprodukovateľné, zatiaľ čo zvyšných 25–30 % prispieva najmä k nejednoznačnosti a lokálnej nestabilite.

Priradenie profilov person k Bartleho typom

Aby sa päť person prepojilo so zavedenými typmi hráčov, ich profily sa zhrnuli pomocou všetkých 21 behaviorálnych charakteristík a usporiadali sa do štyroch kategórií: **Angažovanosť**, **Explorácia**, **Výkon** a **Zdroje**. Obr. 22 zobrazuje výslednú heatmapu, kde zelená označuje vyššie hodnoty a červená nižšie hodnoty v rámci každej črty.

Category	Bartle	Feature	P1	P2	P3	P4	P5
Engagement		Game-length>40 s	2.51	1.04	1.38	2.06	0.79
Exploration	E	Path length per minute	6.15	6.07	6.12	5.59	6.47
Exploration	E	Area coverage	4.69	5.02	5.51	4.66	4.34
Exploration	E/S	Minutes ratio without shooting	0.08	0.07	0.08	0.75	0.32
Exploration	E/S	Mean path length without shooting	3.07	2.43	2.34	2.35	6.09
Exploration	E/K	Camping vs roaming index	0.07	0.08	0.07	1.06	0.07
Performance	A	Mean spawner destruction time	3.66	5.14	4.43	4.98	4.54
Performance	A/K	Headshot hits per minute	0.49	0.3	0.32	0.25	0
Performance	A/K	Shooting accuracy	0.68	0.42	0.57	0.51	0
Performance	A	Portal energy per minute	4.77	0.68	3.73	3.63	1.75
Performance	A/K	Kills per minute	2.22	1.67	2.33	2.02	0
Performance	K/E	Number of bites taken	2.33	2.09	2.81	2.58	0.55
Performance	K/E	Mean time between bites	2.94	2.65	3.2	3.14	2.06
Performance	K	Shots while moving per minute	30.07	26.81	42.46	30.1	1.54
Performance	K	Backward movement per minute	29.54	34.55	39.53	35.61	2.64
Performance	K/E	Mean shooting distance	1.97	2.39	2.14	1.98	0
Performance	K/E	Time to first bite	3.94	4.7	4.6	4.24	4.35
Performance	K	Risk ratio (bites per kill)	0.52	0.43	0.27	0.78	0
Resources	A	Time to first energy delivery	3.8	5.41	5.08	4.92	4.54
Resources	A	Battery collection rate	0.15	0.03	0.08	0.06	0.06
Resources	A/E	Ammo pickups per minute	1.72	1.69	2.97	2.43	0.6

Obr. 22 Heatmapa behaviorálnych črt naprieč personami hráčov ($k = 5$).

Tri výrazné klastre tvoria jadro populácie, zatiaľ čo dva malé klastre zachytávajú zriedkavé extrémny:

- P1 – Efektívni achieveri (n = 31) vykazujú konzistentne vysoké hodnoty výkonových a zdrojových indikátorov kódovaných ako *Achiever*. Títo hráči odohrali nadpriemerný počet hier, dosahovali cieľ (nabíjanie portálu) nadpriemerným tempom, mali najvyššiu presnosť streľby a frekvenciu headshotov a zároveň solídne tempo killov aj zberu munície. Exploračné metriky sú skôr stredné než extrémne: hráči sa pohybujú efektívne, bez výrazného blúdenia či campovania. Celkovo ide o prevažne *Achiever* profil s len miernou zložkou *Killer*.
- P2 – Učiaci sa wandereri (n = 40) majú porovnateľný pohyb a pokrytie plochy ako ostatné veľké klastre, no zaostávajú vo väčšine *Achiever* metrik: nižšia presnosť, nižší podiel headshotov, slabšie nabíjanie portálu a nižšie tempo killov. Napriek aktívnemu pohybu a streľbe menej efektívne premieňajú aktivitu na progres a často končia kratšie relácie. Profil kombinuje stredné signály *Explorer* a *Killer* so slabším *Achiever* výkonom, čo je konzistentné skôr s „prechodnou“ personou (napr. fáza učenia) než s čistým typom.
- P3 – Aktívni bojovníci (n = 77) vykazujú najextrémnejšie úrovne aktivity a boja. Majú najvyšší počet výstrelov počas pohybu, vysoké pokrytie plochy, vysoké tempo killov aj zberu munície a zároveň nízky rizikový pomer uhryznutí na kill. Kombinácia vysokej aktivity a bojovej orientácie robí z P3 jasný hybrid *Achiever* + *Killer*, teda najagresívnejší bojovo orientovaný štýl.
- P4 – Extrémni camperi (n = 4) sú charakteristickí veľmi vysokým indexom campovania a veľkým podielom času aj dráhy bez streľby. Napriek relatívne dlhým hrám a nezanedbateľnému progresu sa správajú prevažne staticky, čo zvyšuje zraniteľnosť voči priblíženiu nepriateľov a riziko uhryznutí. Ide o zriedkavý, extrémny „camping“ vzorec, ktorý nie je úplne dobre pokrytý klasickými štítkami *Achiever*/*Killer*/*Explorer*, no v behaviorálnom priestore je jednoznačne odlíšený.
- P5 – Chodci s nízkou angažovanosťou (n = 4) majú najvyššiu prejdenú vzdialenosť za minútu pri takmer nulovej bojovej angažovanosti: veľmi nízke killy, presnosť, uhryznutia, energia do portálu aj miery zberu zdrojov. Väčšinu času trávajú pohybom, často bez toho, aby systematicky pokrývali nové oblasti alebo sa zapájali do boja či cieľov. Táto persona pripomína explorer-like štýl s minimálnou *Achiever*/*Killer* zložkou.

Spolu profily na Obr. 22 ukazujú, že päť person sa dá zmysluplne opísať pomocou vopred definovaných A/E/K indikátorov: dve veľké osoby sú dominantne výkonovo orientované (P1, P3), jedna kombinuje stredné prvky všetkých troch tendencií (P2) a dve malé osoby predstavujú zriedkavé extrémny – buď statickú pasivitu (P4), alebo pohyb s minimálnym zapojením do boja a cieľov (P5).

Diskusia a záver

Táto kapitola prezentuje a schematizuje postup, ako sa z herných event logov vytvoria interpretovateľné behaviorálne osoby na báze agregovaných indikátorov, a súčasne preskúmať, do akej miery typológiou riadené ukotvenie znižuje interpretačnú voľnosť a zvyšuje vysvetliteľnosť výslednej, stabilnej štruktúry person.

Konštrukcia stojí na tom, že surové udalosti sa najprv prevedú na semantické, herne zmysluplné metriky (pohyb, boj, riziko, práca so zdrojmi, progres k cieľu) a až potom sa tieto metriky agregujú na úroveň hráča. Následná redukcia dimenzie (PCA) nefunguje len ako technická kompresia, ale odhaľuje opakujúce sa osi variability, ktoré sú čitateľné v pojmoch mechaník hry. V našom prípade prvé komponenty sumarizujú najmä: bojovú intenzitu/efektivitu, blúdenie vs. cieľový progres, riziko spojené so statickým hraním (camping) a tempo hry. Dôležité je, že tieto osi nevznikajú ako ľubovoľné numerické zmesi, ale zoskupujú metriky, ktoré spolu prirodzene súvisia v rámci FPS mechaník (napr. tempo killov, streľba za pohybu, riziková expozícia).

V PCA priestore sa následne identifikujú osoby **klastrovaním**. Riešenie $k = 5$ nevedlo k jednej dominantnej kategórii, ale k štruktúre jadra + extrémov: tri veľké, dobre zastúpené osoby pokrývajú väčšinu populácie a dve malé osoby zachytávajú zriedkavé okrajové stratégie. To je v súlade s tým, že správanie FPS hráčov je skôr kontinuum s hustejšími oblasťami okolo niekoľkých preferovaných štýlov než súbor striktne oddelených typov.

Pri agregovaných profiloch je rizikom, že klastre sa dajú pomenovať „ex post“ príbehmi, ktoré nie sú priamo opreté o mechaniky hry. Typológiou riadené ukotvenie tu funguje ako **kontrolovaný slovník** a dizajn metriky: ešte pred analýzou sa špecifikuje, ktoré metriky sú indikátormi tendencií typu Achiever/Killer/Explorer a tieto anotácie sa následne používajú konzistentne v troch bodoch:

- pri návrhu blokov metrík (čo sa vôbec meria a ako sa metriky grupujú),
- pri čítaní latentných dimenzií (loadings sa interpretujú cez vopred definované bloky),
- pri pomenovaní person (persona sa neoznačí ľubovoľným štítkom, ale cez vzťah k ukotveným blokom).

Výsledkom je, že osoby sa dajú opísať cez stabilné kombinácie ukotvených indikátorov: napr. „efektívni achieveri“ a „aktívni bojovníci“ majú dominantné výkonovo-cieľové signály (Achiever) s rôzne silnou bojovou zložkou (Killer), zatiaľ čo „learning wanderers“ ukazujú aktívne správanie, ktoré sa slabšie premieňa na progres (slabší Achiever pri zachovaní pohybu a kontaktu s prostredím). Pri dvoch okrajových personách ukotvenie zároveň ukazuje svoje limity: extrémny camping a „low-engagement walking“ sú síce zrozumiteľné behaviorálne extrémy, ale nezapadajú čisto do klasických štítkov, čo je dôležité priznanie – typológia pomáha, ale neprepisuje realitu dát.

V tomto zmysle ukotvenie zvyšuje vysvetliteľnosť tým, že obmedzuje priestor interpretácie na vopred definované bloky a **núti pomenovania opierať o merané indikátory**, nie o dodatočné príbehy. Zároveň znižuje riziko „nadinterpretácie“ tým, že oddeľuje, čo je v dátach stabilne prítomné (opakovateľné metriky a ich vzťahy) od toho, čo je len naratívne doplnenie.

Stabilita na plnej vzorke bola len stredná (ARI je okolo 0.5), čo je konzistentné s nízkymi siluetami a naznačuje, že hranice medzi osobami sú rozmazané a citlivé na malé zmeny dát. Kľúčové však je, že nestabilita nie je rovnomerne rozložená. Po siluetovom pruningu sa ukazuje jasný obraz: najkoherentnejších približne 70–75 % hráčov v každom klastri tvorí jadro, ktoré je pri bootstrap prevzorkovaní vysoko reprodukovateľné (medián ARI = 0.9), zatiaľ čo zvyšok tvorí perifériu s nejednoznačným členstvom.

Pre odpoveď na RQ je dôležité, že **pruning nemení príbeh person: profily jadra sú prakticky totožné s profilmi na plnej vzorke. To znamená, že pipeline nekonštruje osoby ako krehké artefakty jedného nastavenia, ale odhaľuje stabilnú makro-štruktúru správania, pričom otvorene priznáva, že nie všetkých hráčov možno spoľahlivo priradiť (hraničné prípady).**

Ukotvenie nie je meranie motivácie podľa Bartla. V single-player FPS scenári sa navyše nedá zodpovedne operacionalizovať Socializer a aj Achiever/Killer indikátory sa v tomto type hry prirodzene prekrývajú (efektívny progres často znamená efektívny boj). Preto treba A/E/K čítať ako interpretačné mapovanie založené na a priori anotácii metrík, nie ako dôkaz skutočných motívov hráča. Práve tým sa znižuje riziko nadinterpretácie: typológia poskytuje rámec na komunikáciu, ale výsledná štruktúra person je ukotvená v telemetrii a overená stabilitou, nie odvodená z predpokladu, že existuje malý fixný set čistých typov.

Táto sekcia predstavuje a empiricky overuje protokolovo riadený model hráča so zameraním na stabilitu na prípadovej štúdii *Another Useless Zombie Game*. Od surových event logov sa postupuje cez konštrukciu behaviorálnych charakteristík inšpirovaných rámcami typov hráčov, odstránenie redundancie korelačným skrútingom a PCA až po klastrovanie v latentnom priestore (k-means)

doplnené o bootstrap prevzorkovanie a siluetovo riadený pruning. Výsledkom je malý počet interpretovateľných person, pričom jadro person je robustné a vysoko reprodukovateľné. Ukazuje sa tak, že aj relatívne jednoduchý, transparentný protokol dokáže viesť k nuansovaným a empiricky stabilným reprezentáciám štýlov hry.

Cieľom nebolo navrhnúť novú univerzálnu taxonómiu hráčskych typov ani nahradiť existujúce modely (napr. Bartle či HEXAD). Práca skôr obhajuje praktický a replikovateľný postup, ktorý vychádza z konkrétnych mechaník danej hry a vytvára persony, ktoré sú zároveň behaviorálne interpretovateľné aj štatisticky kontrolované.

Hoci konkrétne dimenzie a persony vyplývajú z mechaník tohto FPS scenára, prenositeľná je najmä **logika pipeline** a spôsob, akým sa kontroluje interpretácia a stabilita. V iných žánroch sa mení „obsah“ metrík (napr. ekonomické rozhodovanie v stratégiách, navigácia a tempo riešenia úloh v puzzle hrách, kooperácia a koordinácia v multiplayer tituloch), no princíp zostáva rovnaký:

- preložiť udalosti na **semantické metriky viazané na mechaniky**,
- organizovať ich do **ukotvených blokov** podľa zvoleného rámca (typológia ako slovník, nie ako meraná pravda),
- odstrániť redundanciu a vytvoriť latentný priestor,
- odvodiť persony klastrovaním
- overiť, či persony majú **stabilné jadro** a kde sú hranice nejednoznačné.

Zovšeobecnenie teda nespočíva v prenose konkrétnych štítkov typu „warrior“ či „camper“, ale v prenose kontrolovaného postupu, ktorý umožní v každom žánri vytvoriť vlastné, mechanikami definované persony a zároveň transparentne oddeliť robustné vzorce od hraničných prípadov. Prakticky to znamená, že pri prenose na inú hru sa nemení metodická kostra, ale len mapovanie udalostí, metrík, blokov a interpretácia dimenzií sa opäť viaže na tieto vopred definované bloky.

Táto štúdia má viacero **obmedzení**, ktoré znižujú zovšeobecniteľnosť záverov. Analýzy vychádzajú z jednej hry a jednej dominantnej mechaniky (krátky, bojovo orientovaný FPS scenár s fixnými cieľmi), takže pozorované dimenzie a persony sú špecifické pre tento dizajn a nemusia sa priamo preniesť do iných žánrov. V práci sa nepoužili dotazníky motivácie či imerzie, preto zostáva prepojenie medzi behaviorálnymi personami a typologickými rámcami interpretačné, nie validované sebahodnotením. Zároveň logy neobsahujú sociálne interakcie; kooperácia, kompetícia medzi hráčmi a komunikácia absentujú, čo znemožňuje zmysluplne zachytiť Socializer-like vzorce a skúmať sociálnu dynamiku.

Tieto limity prirodzene otvárajú viacero smerov **ďalšieho výskumu**. Priamy krok je aplikovať rovnaký pipeline na iné hry a žánre – meniť mechaniky, tempo aj sociálny kontext – a otestovať, ktoré dimenzie a persony sa opakujú a ktoré sú striktne herne-špecifické. Ďalšou cestou je kombinovať log-derived persony s dotazníkovými profilmi (motivácia, preferencie, ponorenie), aby sa kalibroval vzťah medzi „prečo a ako hlboko chce hráč hrať“ a „ako sa reálne správa v situáciách hry“.

Z dlhodobej perspektívy stability-orientovaný prístup vytvára predpoklad pre online adaptívne systémy: priebežne odhadovať polohu hráča v latentnom priestore, sledovať presuny medzi jadrovými personami a túto informáciu využiť na dynamickú adaptáciu obtiažnosti, výber obsahu alebo personalizovanú spätnú väzbu. Okrem zábavnej analytiky sa rovnaký prístup môže uplatniť aj v tréningových simuláciách, kde je rozlíšenie stabilných vs. nejednoznačných behaviorálnych stratégií (opatrné vs. rizikové postupy) kľúčové pre návrh účinných intervencií a rozvoj kompetencií.

Prínos pre oblasť habilitácie

Prínos tejto sekcie pre oblasť habilitácie možno zhrnúť do nasledujúcich bodov:

- Teoretický prínos spočíva v prezentácii postupu umožňujúceho spojiť dátovo odvodené profilovanie z telemetrie s typologickým slovníkom bez toho, aby sa typológia vydávala za priamu mieru motivácií. Bartleho kategórie tu fungujú ako interpretačné ukotvenie blokov črt, nie ako dotazníkové konštrukty. Zároveň sa explicitne pomenúvajú hranice mapovania: v single-player FPS nie je možné zodpovedne izolovať sociálnu dimenziu a viaceré motívy sa prirodzene prekrývajú, takže osoby treba čítať ako behaviorálne profily viazané na mechaniky prostredia.
- Metodický prínos spočíva v presne špecifikovanom a reprodukovateľnom postupe od event-telemetrie po osoby. Kapitola dokumentuje kompletný protokol: rekonštrukciu relácií (1 962 relácií, 156 hráčov), odvodenie hráčskych metrík pokrývajúcich tempo, prieskum, bojový výkon, riziko a manažment zdrojov, redukciu redundancie a transformácie rozdelení, PCA reprezentáciu (12 komponentov, 91 % variability) a následnú segmentáciu. Dôležitý je aj spôsob výberu riešenia: interné indexy naznačujú viac prijateľných hodnôt K , DBSCAN na rovnakej reprezentácii nenachádza prirodzene oddelené ostrovy hustoty (správanie tvorí skôr kontinuum), preto sa osobitná váha kladie na stabilitu a interpretovateľnosť. Stabilita sa testuje bootstrapovým prevzorkovaním (ARI, 300 prevzorkovaní), pričom celé riešenie je ďalej spresnené siluetovým prerezaním na jadro: pri $K = 5$ a ponechaní 70 % najkoherentnejších členov v každom klastri vzniká jadro 110 hráčov s vyššou koherenciou a veľmi vysokou reprodukovateľnosťou (medián ARI 0,924; priemer ARI 0,887). Tým sa z jednorazového zhľukovania stáva kontrolovaný postup s explicitnou neistotou.
- Praktický prínos spočíva v definovaní postupu na vytvorenie malého, zrozumiteľného súboru behaviorálnych person, ktoré sa dajú priamo preložiť do rozhodnutí o dizajne, ladení a adaptácii. Riešenie $K = 5$ poskytuje tri dominantné osoby a dve zriedkavé hraničné: efektívni orientovaní na cieľ (31), aktívni bojovo orientovaní (77), aktívni, ale neefektívni učitelia sa hráči (40) a dve extrémne okrajové skupiny (campovanie a nízka angažovanosť; po 4). Takéto profily sú použiteľné pre ciele onboarding, úpravu náročnosti, detekciu rizikového štýlu a tvorbu tréningových scenárov v serious games, a to bez potreby dotazníkov.
- Pre multi-view modelovanie kapitola prináša behaviorálny pohľad s prvkami, ktoré sú pre jadro habilitácie zásadné: interpretovateľnosť ukotvenú v typológii, takže osoby majú čitateľnú väzbu na mechaniky a vyššie konštrukty, a prácu s neistotou cez jadro vs. hraničné prípady. To je priamo kompatibilné so stability-first integráciou: tvrdé priradenia z k-means sa dajú v ďalšej vrstve spracovania previesť na pravdepodobnostné skóre (napr. cez siluetové poradie a frekvenciu priradenia pri prevzorkovaní), čím sa tento pohľad stáva vhodným vstupom do neskorej fúzie a do konštrukcie spoločného priestoru s vážením podľa stability a pokrytia.

Procesná vrstva – epizódy a taktiky

Telemetria poskytuje bohaté záznamy udalostí, ktoré sa bežne využívajú na objavovanie vzorcov správania a segmentáciu používateľov (Grosu & Nicola, 2025), (Iwasaki & Hasebe, 2021), (Chengyu Wang et al., 2024). Ak však ostaneme pri samotných udalostiach alebo pri agregovaných ukazovateľoch, porovnateľnosť rýchlo slabne: rovnaké metriky môžu reprezentovať odlišné charakteristiky v inej mape, inom režime alebo inom type hry. Táto potreba sa prirodzene objavuje v dvoch zdanlivo odlišných líniiach. Na jednej strane stojí snaha porozumieť používateľom v konkrétnych typoch hier a scenárov tak, aby bolo možné ich profilovať a odlíšiť stabilné rozdiely v štýle správania. Na druhej strane je cieľom modelovať správanie postáv v hre či virtuálnom prostredí tak, aby čo najvernejšie zodpovedalo ľudským vzorom – bolo presvedčivé a konzistentné (Uludağlı & Oğuz, 2023), (Yannakakis & Togelius, 2025). Obe línie sa v jadre stretávajú v rovnakom probléme: potrebujeme reprezentáciu, ktorá zachytí správanie **v kontexte a v čase**.

Hoci sa hranie často sumarizuje pomocou agregácií na úrovni celej session – napríklad zásahy za minútu alebo celková presnosť – takéto globálne metriky často nepostihnú to, čo je pre správanie podstatné v kontexte. Po predspracovaní možno eventové prúdy previesť na multidimenzionálny, fixne vzorkovaný časový rad, ktorý v čase sleduje stav hráča a situačný kontext (napr. zdroje, signály proximity, indikátory rizika, tlak v boji). Táto reprezentácia je prirodzená pre modelovanie časových radov a podporuje profilovanie aj analýzu presvedčivosti správania, pretože uveriteľná hra stojí na lokálnych, situačne podmienených rozhodnutiach, ktoré sa opakujú v krátkych intervaloch (Uludağlı & Oğuz, 2023), (Iwasaki & Hasebe, 2021).

V rámci tejto práce preto hľadáme úroveň abstrakcie, ktorá je dostatočne blízko telemetrii (aby zostala ukotvená v merateľnom správaní), ale zároveň dostatočne všeobecná (aby sa dala prepojiť s personami a preniesť naprieč podobne zameranými prostrediami). Tieto krátkodobé, temporálne lokálne režimy správania označujeme ako **taktiky** (napr. opatrné premiestňovanie, agresívny tlak, udržiavaný konflikt, správanie orientované na zdroje). Taktiky poskytujú interpretovateľnú strednú vrstvu medzi surovou telemetriou a vyššou charakterizáciou používateľa: sumarizujú v akom režime sa hráč nachádza bez potreby komplexných politík, ktoré sa ťažko auditujú a kontrolujú (Tondello et al., 2016), (Zhuang et al., 2021). V multi-view profilovaní práve táto procesná vrstva umožňuje prepojiť správanie z telemetrie s personami a zároveň podporiť porovnanie správania naprieč zdrojmi (rôzne hry alebo prostredia s podobným zameraním).

Aby bolo možné taktiky spoľahlivo odhaliť z časových radov, analýza typicky vyžaduje medzi-krok – **segmentáciu na epizódy** – ktorá rozdelí multidimenzionálnu sekvenciu na súvislé intervaly s relatívne konzistentným správaním. Doterajšie práce ukazujú, že telemetriu je možné segmentovať na epizódy a že sekvenčné vzorce možno ťažiť na opis taktík. Existujúce riešenia sú však často prispôbené konkrétnym hrám alebo dátovým zdrojom, vyžadujú iteratívne nastavovanie, aby boli interpretovateľné, a poskytujú len obmedzenú podporu pre systematické porovnanie segmentačných volieb pri konzistentnej výstupnej reprezentácii (Teng et al., 2025), (Haley et al., 2021). V praxi to sťažuje odlíšenie toho, čo je v získanej štruktúre správania stabilné, od toho, čo je len artefaktom konkrétneho segmentačného dizajnu.

Tieto obmedzenia motivujú modulárnu metodiku zameranú na porovnateľnosť, ktorá

- štandardizuje prevod telemetrie na stavovú reprezentáciu,
- zjednotí výstupy epizód do jednotnej schémy,
- umožní konzistentnú extrakciu a hodnotenie taktických vzorcov naprieč alternatívnymi segmentačnými modulmi.

Cieľom tejto časti je preto navrhnuť modulárny prístup na extrakciu taktík z hernej telemetrie. Najprv bude konštruovaná fixne vzorkovaná stavová sekvencia z eventových logov. Následne sa sekvencia segmentuje na epizódy pomocou výmenných neštruktúrovaných návrhov (napr. oknovanie + klastrovanie verzus duration-aware modely režimov) a napokon sa nad sekvenciami epizód realizuje objavovanie temporálnych vzorcov s cieľom získať interpretovateľnú reprezentáciu taktík a prechodovú štruktúru.

Kľúčovým cieľom návrhu je porovnateľnosť: rôzne segmentačné moduly produkujú výstupy v jednotnej epizódovej schéme, takže následná extrakcia taktík aj ich vyhodnocovanie zostávajú konzistentné naprieč metódami.

Aby bola navrhovaná modulárna metodika operacionalizovateľná a aby sa jej dizajnové voľby dali empiricky testovať, formuluje sa nasledujúca výskumná otázka:

- ***PROC1: Ako navrhnuť modulárny pipeline, ktorý extrahuje epizódy a taktiky ako porovnateľnú procesnú reprezentáciu správania – štandardizáciou vstupu a zjednotením epizódového výstupu – tak, aby procesné črty ostali konzistentné naprieč segmentačnými dizajnmi a zároveň tvorili predpoklad integrácie procesného view do spoločného priestoru v multi-view profilovaní?***

Prehľad relevantných zdrojov

Profilovanie používateľov v hrách a príbuzných virtuálnych prostrediach dnes stojí na tom, či vieme z telemetrie odlíšiť stabilné rozdiely v štýle správania a nie iba rozdiely vo výsledku. V praxi to znamená zachytiť, aké typy rozhodnutí používateľ preferuje, ako reaguje na tlak a riziko, a aké opakujúce sa režimy konania sa uňho objavujú naprieč situáciami. Takáto charakterizácia je dôležitá aj ako predpoklad personalizácie: bez procesne ukotvených profilov je adaptácia často buď príliš hrubá, alebo viazaná na konkrétnu hru a jej metriky.

Zároveň má profilovanie aj druhý, menej explicitný dopad: poskytuje empirický základ pre správanie aktérov v prostredí. Ak chceme, aby reakcie oponentov a NPC pôsobili presvedčivo v rôznych situáciách, potrebujeme vedieť, aké strategické vzorce ľudia v danom type úloh reálne používajú. Tradičné ručne navrhnuté rozhodovacie systémy (napr. konečné automaty, behaviorálne stromy či plánovače orientované na ciele) síce umožňujú kontrolu nad logikou správania, ale dlhodobo narážajú na ťažkosť dosiahnuť skutočne ľudské správanie naprieč kontextmi (Yannakakis & Togelius, 2018a), (Justesen et al., 2020). Keď sa správanie aktérov odchýli od očakávanej logiky situácie, narúša to ponorenie a znižuje angažovanosť (Uludağlı & Oğuz, 2023), (Zhao et al., 2021). Tento problém je obzvlášť viditeľný vo variabilných prostrediach, kde statické skripty a fixné pravidlá vedú k robotickým reakciám, ktoré sa zle prenášajú do nových (napr. AI generovaných) kontextov (Al-Surayhi et al., 2025), (Zhao et al., 2021). V posledných rokoch sa preto kladie dôraz na modely, ktoré sa vedia učiť z pozorovaného správania hráčov a adaptovať na strategické vzorce typické pre dané prostredie (Hare & Tang, 2023), (Reis et al., 2021).

Abstrakcia správania

Pri odvodení správania z herného eventového logu sa v literatúre bežne používa viacúrovňová abstrakcia, ktorá premostí rozdiel medzi surovými dátami a vyššie interpretovaným zámerom správania (Bakkes et al., 2012), (Zhao et al., 2021). Typicky sa rozlišujú tieto úrovne:

- **Akcie** predstavujú najnižšiu úroveň. Ide o atómové udalosti, jednotlivé herné kroky alebo zmeny reprezentujúce momentálne rozhodnutia (Shih et al., 2022).

- **Epizódy** zoskupujú akcie a slúžia ako medziúroveň organizácie. Epizóda sa chápe ako sekvencia súvisiacich (alebo rovnakých) krokov alebo ako špecifický cyklus správania (od zámeru po dosiahnutie bezprostredného cieľa), ktorý kompaktne sumarizuje komplexné interakčné vzorce (Shih et al., 2022), (Ramadan et al., 2019).
- **Taktiky** stoja nad epizódami a opisujú krátkodobé, lokálne ciele režimy správania realizované konkrétnymi sekvenciami epizód, ktoré smerujú k okamžitému cieľu (Bakkes et al., 2012).
- **Stratégie** predstavujú najvyššiu úroveň a zachytávajú dlhodobé globálne plány, „záväzky“ k herným štýlom alebo koordináciu viacerých taktík s cieľom dosiahnuť celkové herné výsledky (Heuser, 2010), (Sukthakar & Sycara, 2010).

Takéto hierarchické oddelenie umožňuje analyzovať taktické a strategické rozhodovanie ako odlišné vrstvy rozhodovacieho procesu. Herná telemetria tieto abstrakcie umožňuje tým, že poskytuje vysoké časové rozlíšenie a jemnozrnnú stopu interakcií používateľa (S. Anderson & Falconer, 2025), (Alonso-Fernández et al., 2022). Surová telemetria však často trpí vysokou dimenzionalitou a veľmi veľkým stavovým priestorom, čo výrazne sťažuje priamu extrakciu taktických informácií. Preto je potrebný predspracovací krok, ktorý transformuje heterogénne eventové logy do konzistentnej, modelovo orientovanej reprezentácie (S. Anderson & Falconer, 2025), (Zhao et al., 2021), (Drachen et al., 2013).

Štandardným prístupom je konštrukcia multidimenzionálnej stavovej sekvencie s fixnou frekvenciou, typicky vzorkovanej v pravidelných intervaloch (Grosu & Nicola, 2025), (Alonso-Fernández et al., 2022). Počas tejto transformácie sa surové udalosti agregujú do deskriptorov, ktoré zachytávajú kľúčový kontext, napríklad ekonomiku pohybu, intenzitu boja či manažment zdrojov. Príprava dát môže zahŕňať aj identifikáciu kľúčových akcií – teda významných udalostí reprezentujúcich aspekty používateľskej skúsenosti – a zároveň odstránenie nepotrebného nízkoúrovňového šumu (Grosu & Nicola, 2025), (S. Anderson & Falconer, 2025).

V posledných rokoch sa zároveň zdôrazňuje potreba štandardizácie významu (sémantiky) telemetrických údajov, aby sa zvýšila porovnateľnosť a znovupoužiteľnosť dát naprieč hrami a analytickými kanálmi (Alonso-Fernández et al., 2022), (Tlili et al., 2021). Prijatie štandardov systematizuje zber, a tým uľahčuje vývoj nástrojov na analýzu a vizualizáciu nezávislých od konkrétnej hry (Pérez-Colado et al., 2021), (Tori et al., 2022).

Detekcia epizód

Keď je telemetria transformovaná do konzistentného časového radu, proces extrakcie taktík možno matematicky formulovať ako problém segmentácie časových radov (Chengyu Wang et al., 2024). Spracovanie spočíva v rozdelení správania hráča na súvislé epizódy, ktoré nesú relatívne konzistentný sémantický význam (Gharghabi et al., 2019). Nedávny výskum v tejto oblasti rozlišuje tri základné typy segmentačných úloh:

- **Detekcia zmien** identifikuje konkrétne časové body, v ktorých sa menia štatistické vlastnosti radu (napr. priemer alebo variancia) (Aminikhanghahi & Cook, 2017), (Truong et al., 2020), (Ghaderpour et al., 2021).
- **Detekcia hraníc** sa snaží nájsť sémantické rozhrania medzi odlišnými segmentmi bez toho, aby im nevyhnutne priradila konkrétny stavový štítok (Chengyu Wang et al., 2024).
- **Detekcia stavov** priraduje každému časovému bodu stavový štítok, pričom hranice segmentov prirodzene vznikajú ako dôsledok prechodov medzi štítkami (Gharghabi et al., 2019), (Fan et al., 2022).

Táto taxonómia podporuje architektúru orientovanú na porovnateľnosť: rôzne segmentačné dizajny – od klastrovania až po modely latentných režimov – môžu fungovať ako výmenné moduly, ktoré produkujú výstupy v jednotnej epizódovej schéme. Široko využívaným neštruktúrovaným prístupom je kombinácia oknovania (windowing) a klastrovania, kde sa fixne dlhé časové okná vložia do reprezentácie a následne zoskupujú do opakujúcich sa behaviorálnych módo (Tavenard et al., 2020), (Ismail Fawaz et al., 2019). Varianty k-means sú pre túto úlohu atraktívne najmä preto, že sú výpočtovo efektívne, dobre škálujú na veľké herné datasety a dajú sa jednoducho operacionalizovať (S. Anderson & Falconer, 2025), (Cuturi & Blondel, 2017), (Vera & Angulo, 2023). Moderné knižnice pre časové rady (napr. *tslearn*) tieto pracovné postupy explicitne podporujú tým, že poskytujú špecializované odhadovače a API pre temporálne dáta (Tavenard et al., 2020).

Príbuznú rodinu metód tvoria prístupy založené na hustote, ako napríklad HDBSCAN (Vijayan & Aziz, 2023), (Fuchs & Höpken, 2022). Na rozdiel od partičných metód dokáže HDBSCAN identifikovať klastre s rôznou hustotou a ľubovoľným tvarom, čo je výhodné pri nepredvídateľných priestorových a temporálnych distribúciách typických pre hráčku telemetriu. Kľúčovou vlastnosťou HDBSCAN je aj schopnosť označiť nejednoznačné pozorovania ako šum. To je užitočné pri izolovaní zriedkavých stavov alebo prechodov, no literatúra upozorňuje na kompromis: ak sa taktické odchýlky na vyššej úrovni klasifikujú ako šum, môžeme neúmyselne odstrániť cenné informácie o unikátnych alebo inovatívnych hráčskych stratégiách (S. Anderson & Falconer, 2025), (Canossa et al., 2018).

Modely latentných režimov

Komplementárny smer pri objavovaní epizód využíva modely latentných režimov, napríklad skryté Markovove modely (HMM) (Chengyu Wang et al., 2024), (Zucchini et al., 2017). HMM patria medzi silné nástroje na klasifikáciu, pretože zohľadňujú temporálnu závislosť: predpokladajú, že pozorovania blízke v čase sú s vysokou pravdepodobnosťou generované tým istým stavom. HMM však majú aj štrukturálne obmedzenie – implicitne predpokladajú, že doba zotrvania v stave má geometrické rozdelenie (Ruiz-Suarez et al., 2022).

Na riešenie tohto problému slúžia skryté semi-Markovove modely (HSMM), ktoré trvania stavov explicitne reprezentujú, a tým umožňujú realistickejšie a flexibilnejšie modelovanie behaviorálnych cyklov (S. Z. Yu, 2010), (Merlo et al., 2022). Modely zohľadňujúce trvanie prirodzene korešpondujú s pojmom epizódy alebo taktiky, pretože perzistencia správania sa modeluje ako vnútorná vlastnosť stavu, nie ako niečo, čo sa dodatočne vnucuje cez ľubovoľne zvolený krok oknovania. Nedávny vývoj v literatúre časových radov zároveň poukazuje na moderné formulácie HSMM pre multivariačné sekvencie, ktoré dokážu zachytiť komplexné rozdelenia trvaní stavov, aké HMM nedokážu reprezentovať (Chengyu Wang et al., 2024), (Merlo et al., 2022).

Interpretovateľnosť

Po identifikácii behaviorálnych epizód extrakcia taktík typicky pokračuje objavovaním temporálnych vzorcov v vzniknutej sekvencii. Namiesto spoliehania sa výlučne na globálne agregácie sa využíva ťažba sekvenčných vzorcov, ktorá identifikuje opakujúce sa subsekvencie (Chengyu Wang et al., 2024), (Halim et al., 2019). Pre tento krok je rozhodujúce práve poradie udalostí, pretože poskytuje procesný kontext potrebný na pochopenie toho, ako hráči dosahujú lokálne ciele (S. Anderson & Falconer, 2025). Takto získané taktické vzorce možno chápať ako model preferencií nad možnými akciami v závislosti od aktuálneho stavu hry – teda ako most medzi elementárnymi krokmi a dlhodobými cieľmi (Sukthankar & Sycara, 2010).

V hernej analytike však samotné vyťaženie častých vzorcov nestačí; výsledky musia zostať interpretovateľné a prakticky použiteľné pre dizajnérov alebo výskumníkov (Teng et al., 2025), (W. Li

et al., 2019). Na podporu ľudskej interpretácie sa v literatúre typicky uplatňujú dve komplementárne rodiny reprezentácií:

- **Hráčske trajektórie**, reprezentované ako grafy uzlov a hrán, zvýrazňujú typické trasy a prechody medzi stavmi. Tento formát umožňuje analytikom intuitívne odvodzovať procesy a zároveň skúmať aj zriedkavé, no významné cesty, ktoré by sa inak mohli zahodiť ako šum (Teng et al., 2025), (Teng et al., 2022).
- **Strategické signatúry** sú spôsob, ako preložiť dlhú sekvenciu správania do krátkeho, vizuálne zrozumiteľného odtlačku. Namiesto toho, aby sme porovnávali celé sekvencie krok po kroku, každú sekvenciu zhrnieme do kompaktného symbolu (ako malý grafický vzor), ktorý zachytí jej typický priebeh. Vďaka tomu sa dajú rôzne režimy správania rýchlo porovnávať – stačí porovnať tieto „odtlačky“, nie celé logy. Takáto reprezentácia je užitočná najmä vtedy, keď chceme vidieť, ako sa správanie mení v čase: napríklad či hráč po úspechu okamžite končí, alebo naopak pokračuje v doladení a optimalizácii aj po dosiahnutí cieľa (W. Li et al., 2019).

Opísané prístupy podporujú posun od analýzy založenej iba na agregovaných sumároch výsledkov k procesným poznatkom o tom, ako sa taktiky formujú a menia. Z tohto dôvodu by sa modulárny pipeline na extrakciu taktík nemal hodnotiť len kvalitou segmentácie, ale aj kompromisom medzi stabilitou a užitočnosťou následných výstupov (Grosu & Nicola, 2025), (S. Anderson & Falconer, 2025), (Teng et al., 2025). Následné prepojenie taktických vzorcov s výsledkami (napr. výhra/prehra, čas prežitia alebo špecifické výkonové metriky) predstavuje praktickú cestu k záverom relevantným pre dizajn (Al-Surayhi et al., 2025), (Hsieh & Sun, 2008). Identifikáciou taktík silno asociovaných so zlyhaním alebo úspechom môžu vývojové tímy získať dôkazy potrebné na prioritizáciu balansovania alebo úprav modelov správania botov (S. Anderson & Falconer, 2025), (Alobaidi et al., 2021).

Modulárna metodológia pre extrakciu taktiky

Navrhuje sa modulárna metodika, ktorá prevádza hernú telemetriu do jednotnej časovej reprezentácie a následne z nej odvodzuje procesné vzorce správania. Eventové logy transformujeme na pravidelnú stavovú sekvenciu, ktorú segmentujeme na epizódy pomocou výmenných neštruktúrovaných metód. Z epizódových sekvencií potom extrahujeme opakujúce sa vzorce interpretované ako taktiky.

Rámec reaguje na dve kľúčové obmedzenia:


- Vysokodimenzionálna telemetria musí ostať interpretovateľná, preto pracujeme s doménovo motivovanou abstrakciou, ktorá zachováva význam signálov a zároveň znižuje zložitosť (Javvaji et al., 2020),
- Rozhodnutia v segmentácii výrazne ovplyvňujú následné zistenia; preto musia byť výsledky porovnateľné naprieč rôznymi segmentačnými dizajnmi (Chengyu Wang et al., 2024).

Aby bolo porovnanie férové a efektívne, zavádzame jednotnú epizódovú schému ako medzi-výstup v rámci spoločného pipeline pre ťažbu sekvenčných vzorcov. To umožňuje testovať stabilitu taktických štruktúr naprieč analytickými voľbami a oddeliť stabilné (zdieľané) jadro od metodicky podmienenej vrstvy prípadne hľadať dôvody rôznorodosti výsledkov (Chengyu Wang et al., 2024), (S. Anderson & Falconer, 2025).

Pri interpretácii herného správania sa bežne používajú viaceré úrovne abstrakcie, ktoré prepájajú surové dáta so zámerom (Bakkes et al., 2012). **Akcie** (atómové logované udalosti) tvoria **epizódy** (súvislé sekvencie príbuzného správania) (Shih et al., 2022), z ktorých sa skladajú **taktiky** (krátkodobé režimy s lokálnymi cieľmi) a na najvyššej úrovni **stratégie** (dlhodobé globálne plány). Surovú telemetriu je často ťažké analyzovať priamo pre vysokú dimenzionalitu a veľký stavový priestor (S. Anderson & Falconer, 2025), preto sa v predspracovaní heterogénne udalosti zvyčajne agregujú do fixne

vzorkovaného multidimenzionálneho stavového radu, v ktorom sa zvýraznia kľúčové signály a zároveň sa redukuje šum (Chengyu Wang et al., 2024), (Zhao et al., 2021). Navrhovaná metodika transformuje jemnozrnnú hernú telemetriu na použiteľné taktické poznatky v štyroch krokoch (Obr. 1):

- **Fáza 1: Predspracovanie dát** – surové eventové logy sa vyčistia a agregujú do multidimenzionálnej stavovej sekvencie s fixnou frekvenciou, aby sa heterogénne eventové prúdy (napr. úroveň zdrojov, bojová aktivita, priestorová blízkosť) previedli do konzistentného režimu vzorkovania (Chengyu Wang et al., 2024), (Chung, 2015).
- **Fáza 2: Segmentácia epizód** – segmentáciu časových radov možno rámcovať ako detekciu zmien, detekciu hraníc alebo detekciu stavov. Naša metodika vychádza z pohľadu detekcie stavov: neštruktúrovaná segmentácia priradzuje v čase štítky (napr. klastrovanie okien alebo duration-aware modely latentných režimov) a hranice epizód sa následne odvodí z prechodov medzi štítkami (Chengyu Wang et al., 2024), (Zefeng Chen & Gan, 2024).
- **Fáza 3: Post-processing epizód** – aby boli výstupy rôznych segmentačných prístupov konzistentné, sekvencie označení prevádzame na súvislé epizódy a redukuje fragmentáciu spájaním identických behov a zlučovaním epizód pod minimálnym prahom trvania. Takéto spresnenie hraníc generuje štandardizované epizódové sekvencie s porovnateľnými vlastnosťami naprieč použitými segmentačnými technikami (Javvaji et al., 2020).
- **Fáza 4: Ťažba taktík** – zo štandardizovaných epizódových sekvencií vyťažíme opakujúce sa sekvenčné vzorce (frekventované subsekvencie alebo motívy). Taktiky následne kvantifikujeme identifikáciou ich výskytov v jednotlivých herných stopách a odhadom prechodovej štruktúry medzi taktikami, čo umožňuje opísať evolúciu správania a podľa potreby prepojiť taktické



Obr. 23 Modulárna metodika pre extrakciu taktík z hernej telemetrie.

rozhodnutia s výsledkami (S. Anderson & Falconer, 2025), (Teng et al., 2025), (W. Li et al., 2019).

Fáza 1: Predspracovanie dát

Fáza 1 prevádza heterogénne, surové eventové logy na multidimenzionálnu stavovú sekvenciu s fixnou frekvenciou, ktorú následne dokážu spracovať všetky segmentačné moduly. Tento krok je nevyhnutný, pretože surová telemetria býva vysokodimenzionálna, v čase riedka a silno závislá od typu udalostí; bez spoločného časového základu a stabilných stavových premenných je neštruktúrovaná segmentácia krehká a výsledky sa ťažko porovnávajú naprieč metódami (Chengyu Wang et al., 2024), (Zhao et al., 2021), (Chung, 2015). Predspracovanie preto cieľi na odstránenie redundantných alebo nevhodných stôp a na vytvorenie 1 Hz stavovej reprezentácie, ktorá zachová kontext hry, no zníži šum a nekonzistencie.

Čistenie dát

Aplikujú sa ľahké, no prísne pravidlá čistenia, aby triviality alebo štrukturálne neplatné stopy nedeformovali neštruktúrované modely. Konkrétne:

- Odstránia sa príliš krátke hry (napr. < 30 s) – veľmi krátke sessiony nadreprezentujú inicializáciu a neposkytujú stabilné fázy správania vhodné na extrakciu epizód.
- Odstránia sa prerušené/odpojené sessiony – prerušované stopy môžu zavádzať umelé hranice a chýbajúce segmenty, čo skresľuje segmentáciu aj ťažbu vzorcov.
- Overí sa časová integrita – vyžadujú sa monotónne časové značky v rámci session a podľa potreby sa odstránia duplicitné alebo poškodené záznamy.

Tieto pravidlá zodpovedajú bežnej praxi v telemetrii: zabezpečiť, aby odvodené behaviorálne miery stáli na konzistentných dôkazoch a nie na artefaktoch logovania, pričom predspracovanie má ostať minimálne, ale zdôvodnené a interpretovateľné (Chung, 2015).

Konštrukcia stavovej sekvencie

Po vyčistení transformujeme nepravidelný eventový prúd na pravidelne vzorkovanú stavovú sekvenciu v 1 Hz, kde každý „tick“ agreguje stav používateľa a kontext v rámci 1-sekundového intervalu. Fixná frekvencia je praktický kompromis: je dostatočne jemná na zachytenie krátkodobých zmien relevantných pre taktiky, no zároveň znižuje riedkosť a umožňuje konzistentné porovnanie naprieč segmentačnými dizajnmi (Chengyu Wang et al., 2024), (Chung, 2015).

Používajú sa agregáčne pravidlá, ktoré udržiavajú stabilnú sémantiku v čase:

- Perzistentné stavy (napr. munícia/zdravie/energia) sa prenášajú do sekvencie ako „poslednú známu hodnotu“ vtedy, keď v danom ticku nepríde aktualizácia.
- Intenzity udalostí (napr. výstrely, zásahy, poškodenie) sa agregujú ako počty alebo miery na tick (často riedke, ale porovnateľné).
- Kontextové signály (napr. vzdialenosti/proximity) sú vzorkované alebo agregované konzistentne (napr. aktuálna vzdialenosť na konci ticku alebo súhrn v rámci intervalu) podľa dostupnosti.

Výsledkom je multidimenzionálny časový rad zosúladený na spoločnej časovej mriežke – teda vstupný formát potrebný pre oknové klastrovanie aj pre duration-aware modely režimov (Chengyu Wang et al., 2024).

Pre robustnosť a znovupoužiteľnosť definujeme dve sady črt odvođené z tej istej 1 Hz sekvencie:

- Core črty pokrývajú všeobecné behaviorálne dimenzie, ktoré očakávame aj v podobných hrách (pohyb, bojová aktivita, stav zdrojev).

- Full črty rozširujú core o dodatočné kontextové premenné, ak sú dostupné (napr. špecifické herné alebo cieľovo orientované signály).

Toto rozdelenie umožňuje citlivostné porovnanie (core vs. full) bez zmeny logiky postupu a zároveň obmedzuje „preplnenie“ reprezentácie špecifickými signálmi v situáciách, kde je cieľom prenositeľná metodika (Chengyu Wang et al., 2024), (Zhao et al., 2021).

Fáza 1 produkuje fixne vzorkovanú stavovú sekvenciu (vo variantoch core/full), ktorú používajú všetky segmentačné moduly. Pred pokračovaním realizujeme jednoduché kontroly správnosti (rozsahy hodnôt, chýbajúce hodnoty a základné rozdelenia), aby sme potvrdili, že reprezentácia je numericky stabilná a zároveň interpretovateľná.

Fáza 2: Segmentácia epizód

Fáza 2 transformuje 1 Hz stavovú sekvenciu na surovú sekvenciu behaviorálnych štítkov tým, že každému časovému kroku (prípadne krátkemu oknu) priradí diskretný režim správania. Tento krok predstavuje kľúčovú abstrakciu: namiesto priamej práce s vysokodimenzionálnym spojitým stavovým priestorom identifikujeme opakujúce sa módy správania a zachytávame ich perzistenciu aj prepínanie v čase. Segmentáciu preto rámcujeme ako úlohu detekcie stavov – model produkuje časovo usporiadaný zoznam štítkov, ktorý poskytuje explicitnú symbolickú reprezentáciu správania.

Samotné epizódy v tejto fáze ešte neinterpretujeme; vznikajú až následne vo Fáze 3 ako súvislé úseky rovnakého štítku, pričom hranice epizód zodpovedajú prechodom medzi štítkami. Takéto zarámčovanie je pre telemetriu praktické, lebo zjednocuje formát výstupu naprieč segmentačnými návrhmi: rôzne metódy sa dajú férovo porovnávať pri zachovaní spoločného downstream pipeline, keďže všetky produkujú rovnaký typ minimálneho, štandardizovateľného výstupu (Chengyu Wang et al., 2024), (Zefeng Chen & Gan, 2024).

Všetky segmentačné moduly pracujú nad tou istou 1 Hz multivariačnou stavovou sekvenciou. Aby bolo porovnanie férové, Fáza 2 je navrhnutá tak, aby sa jednotlivé moduly líšili iba tým, ako štítky odvodzujú. Výstup je preto zámerne minimálny a štandardizovaný: časovo usporiadaný zoznam štítkov.

Windowing

Pri klastrovaní sa najprv použijú krátke časové okná (napr. 3–6 s). Oknovanie má dve výhody: agreguje lokálny kontext (znižuje citlivosť na šum na úrovni jedného ticku) a vytvára kompaktnú reprezentáciu vhodnú pre klastrovanie vo vektorovom priestore. Každé okno sumarizujeme jednoduchými štatistikami nad tickmi, ktoré obsahuje (napr. priemery/mediány pre spojitý stav a sumy/intenzity pre počty udalostí). Výslednú sekvenciu oknových vektorov následne klastrujeme a získané oknové štítky mapujeme späť do surovej sekvencie štítkov.

Segmentačné moduly

V tomto kroku sa implementujú rôzne (napr. tri ako v tomto prípade) komplementárne segmentačné dizajny: dva založené na klastrovaní (k-means a HDBSCAN) a jeden duration-aware model latentných režimov (HSMM). Všetky tri produkujú surovú sekvenciu behaviorálnych štítkov z tej istej stavovej reprezentácie.

- **K-means** predstavuje jednoduchý a široko používaný baseline, ktorý zoskupuje podobné lokálne „snímky“ správania do fixného počtu módo. Bude aplikovaný na oknové vektory (voliteľne po PCA, ak redukcia dimenzie zlepši stabilitu). Výstupom je štítok pre každé okno, definovaný ako najbližší centroid klastru.
- **HDBSCAN** sa používa ako doplnkový nástroj, ktorý nevyžaduje určiť počet klastrov a dokáže explicitne označiť nejednoznačné okná ako šum. To je pre telemetriu atraktívne, keďže správanie môže tvoriť nerovnomerné skupiny s rôznou hustotou a zriedkavé či prechodové

okná nie je nutné nasilu priradiť ku klastru. V štandardnom porovnatelnom nastavení sa aplikuje HDBSCAN na tie isté oknové vektory ako k-means (oknová úroveň); tick-level variantu vektora možno chápať ako citlivostnú analýzu.

- **HSMM** priraduje latentný stavový štítok ku každému 1 Hz ticku a explicitne modeluje, ako dlho proces typicky zotrúva v danom stave. To ho robí vhodným pre režimy správania s variabilným trvaním a zároveň znižuje nadmernú fragmentáciu bez potreby fixných hraníc okien. Výstupom je tick-level sekvencia štítkov, pričom perzistencia je vynútená modelom trvania.

Fáza 2 produkuje surovú sekvenciu štítkov, ktorá opisuje odhadnutý behaviorálny mód v čase. V závislosti od modulu sú štítky definované na úrovni okna (k-means/HDBSCAN) alebo ticku (HSMM), no vo všetkých prípadoch ich možno reprezentovať ako usporiadaný zoznam označených časových indexov (ticky alebo mapované pozície okien). V tomto kroku sú štítky ešte metodicky špecifické a neinterpretujú sa ako epizódy; štandardizácia do súvislých epizód a prototypových súhrnov prebieha vo Fáze 3.

Fáza 3: Post-processing epizód

Fáza 3 prevádza surovú sekvenciu štítkov z Fázy 2 do jednotnej epizódovej schémy a vytvára epizódové sekvencie, ktoré sú porovnateľné naprieč segmentačnými dizajnmi. Tento post-processing je potrebný, pretože výstupy detekcie stavov (či už z klastrovania alebo z modelov latentných režimov) často vykazujú krátkodobé kolísanie štítkov okolo prechodov. To vedie k fragmentovaným segmentom a nestabilným hraniciam, čo je typický problém segmentácie časových radov a stavového modelovania (Chengyu Wang et al., 2024), (Ruiz-Suarez et al., 2022), (Javvaji et al., 2020).

Vyhľadanie a zlučovanie epizód

Najprv sa transformuje sekvencia štítkov na kandidátov epizód tak, že po sebe idúce identické štítky sa agregujú do súvislých intervalov. Každý interval sa považuje za epizódu so začiatkom, koncom, trvaním a štítkom. Na redukciu fragmentácie sa následne aplikuje pravidlo minimálneho trvania: epizódy kratšie než vopred definovaný prah sa zlúčia so susednou epizódou podľa pravidla konzistencie (napr. časová susednosť alebo podobnosť črt). Tento krok stabilizuje epizódy a znižuje citlivosť na „trasenie“ hraníc, čím zlepšuje porovnateľnosť výstupov segmentácie (Chengyu Wang et al., 2024).

Pre každú session a každú segmentačnú metódu sa tak vytvorí sekvencia epizód ako usporiadaný zoznam dvojíc (štítok, trvanie). Zdieľaná epizódová schéma je pre porovnateľnosť kľúčová: rôzne segmentačné moduly možno ďalej hodnotiť a porovnávať iba vtedy, ak poskytujú kompatibilné medzi-výstupy (Chengyu Wang et al., 2024).

Aby sa podporila interpretácia a porovnanie naprieč metódami, sumarizuje sa každý epizódový štítok pomocou prototypu. Pre každý štítok sa agregujú jeho epizódové výskyty a vypočíta sa robustný prototypový vektor (mediány) s odhadom variability pomocou interkvartilového rozpätia naprieč charakteristikami. Výsledkom je auditovateľný a škálovateľný opis typov epizód na základe profilov, ktorý podporuje spoločnú interpretáciu (Javvaji et al., 2020). Následne sa klastrujú prototypy štítkov pomocou aglomeratívneho hierarchického klastrovania (Wardovo viazanie), čím sa získa menší počet zdieľaných meta-módov. Metodicky špecifické štítky sa potom mapujú do tohto spoločného slovníka, ktorý sa používa v ďalšej ťažbe taktík.

Fáza 3 vytvorí zdieľaný slovník meta-módov a mapovanie z každého metodicky špecifického epizódového štítku na meta-štítok. Tento slovník zabezpečí, že všetky následné analýzy pracujú s porovnateľnými epizódovými sekvenciami, aj keď pochádzajú z odlišných segmentačných dizajnov.

Fáza 4: Ťažba taktík

Fáza 4 pracuje so štandardizovanými epizódovými sekvenciami z Fázy 3 a extrahujú sa z nich taktiky ako opakujúce sa temporálne štruktúry. Postup vychádza z hernej analytiky a ťažby sekvencií: keď je správanie zakódované ako symbolická sekvencia, vyššie rutiny sa dajú objaviť identifikáciou opakovaných subsekvencií a analýzou toho, ako sa stavy a vzorce v čase menia (Ramadan et al., 2019), (W. Li et al., 2019), (Canossa et al., 2018). Taktiky sa zámerne definujú **nad úrovňou epizód** (taktika = 1+ epizód), pretože to podporuje interpretovateľné behaviorálne rutiny a zároveň zachováva porovnateľnosť naprieč alternatívnymi segmentačnými dizajnmi (S. Anderson & Falconer, 2025), (Teng et al., 2025).

Každá session sa chápe ako usporiadaná sekvencia epizód. Kandidátne taktiky sa identifikujú ako opakujúce sa subsekvencie epizód prostredníctvom ťažby frekventovaných sekvenčných vzorcov (napr. n-gramy alebo motívom podobné štruktúry). Tento krok je konzistentný s prístupmi, ktoré analyzujú hranie ako sekvencie udalostí alebo epizód s cieľom odvodiť behaviorálnu štruktúru a opakujúce sa rutiny (Canossa et al., 2018), aj s cielenejšími formuláciami ťažby epizódových pravidiel, ktoré explicitne vyhľadávajú opakované, neprekrývajúce sa sekvenčné štruktúry v symbolických dátach (Zefeng Chen & Gan, 2024).

Zároveň sa odhaduje prechodová štruktúra medzi epizódovými štítkami (a voliteľne aj medzi objavenými taktickými vzorcami), aby sa zachytila dynamika prepínania správania. Prechodové sumarizácie predstavujú kompaktný a široko používaný spôsob, ako popísať, ako sa hráči presúvajú medzi behaviorálnymi módmami; dopĺňajú výstupy frekventovaných vzorcov o globálny pohľad na „tok“ správania (S. Anderson & Falconer, 2025), (W. Li et al., 2019).

Surový výstup ťažby zvyčajne obsahuje veľa vzorcov, ktoré si sú navzájom veľmi podobné alebo neprinášajú novú informáciu – napríklad ide o takmer rovnaké subsekvencie, triviálne opakovania, prípadne vzorce, ktoré sa líšia len krátkym „prívlastkom“ na začiatku či na konci. Preto sa najprv odstránia zjavne triviálne a redundantné kandidáty a následne sa veľmi podobné vzorce zlučujú do jednej, konsolidovanej definície taktiky. Výsledkom je menší a prehľadnejší slovník rutín, s ktorým sa dá pracovať pri interpretácii aj pri ďalšej analýze (Ramadan et al., 2019), (W. Li et al., 2019), (Zefeng Chen & Gan, 2024).

Sémantické názvy sa taktikám priradujú až v tomto kroku, pričom sa využívajú epizódové prototypy z Fázy 3 ako evidencia toho, čo daný vzorec reprezentuje. Takýto postup podporuje auditovateľnosť interpretácie (S. Anderson & Falconer, 2025), (Teng et al., 2025), (Javvaji et al., 2020). Následne sa výskyty taktík získajú mapovaním každej konsolidovanej štruktúry späť do epizódových sekvencií, čím sa určia časové intervaly jednotlivých výskytov v rámci každej session. Objavovanie vzorcov je založené na štítkoch; trvania sa ukladajú na úrovni výskytov a podľa potreby sa sumarizujú až dodatočne (S. Anderson & Falconer, 2025), (Zefeng Chen & Gan, 2024).

Fáza 4 tak ako výsledok poskytne:

- konsolidovaný súbor taktík definovaných ako subsekvencie epizód,
- výskyty taktík v jednotlivých sessionoch
- prechodovú štruktúru sumarizujúcu prepínanie správania medzi módmami.

Prípadová štúdia: FPS telemetry

V nasledujúcej prípadovej štúdii sa demonštruje realizovateľnosť a porovnateľnosť navrhovaného pipeline na telemetrickom datasete z FPS zombie shooter hry. V hre zabíjanie zombie uvoľňuje energiu vo forme batérií, ktoré hráči zbierajú a opakovane doručujú do portálu, aby ho dobýjali, pričom zároveň

musia prežiť v stupňujúcom sa množstve nepriateľov (obr. 2). Hra bola vyvinutá autorom s cieľom podporiť zber telemetrie na úrovni zmysluplných herných akcií a stavov (napr. pohyb, boj, zber zdrojov, doručenie), nie na úrovni nízkoúrovňových vstupov typu kliknutia myšou alebo stlačenia klávesov. Dataset obsahuje sekundové snímky polohy a orientácie hráča, ako aj záznamy udalostí o herných akciách (napr. výstrel, udalosť poškodenia, zber predmetov a inicializácia prostredia). Celkovo zahŕňa 504 538 záznamov z 1 938 sessionov odohraných 157 unikátnymi hráčmi.

Na operacionalizáciu metodiky sa z eventových záznamov konštruuje 1 Hz multivariačná stavová sekvencia, aplikujú sa tri segmentačné schémy (oknové klastrovanie k-means, hustotné klastrovanie HDBSCAN a duration-aware HSMM) a ich výstupy sa mapujú do jednotnej epizódovej schémy. Následne sa z výsledných epizódových sekvencií vyťažia taktiky a vyhodnotí sa, ktoré epizódové štruktúry a taktické vzorce pretrvávajú naprieč segmentačnými voľbami pri vopred definovaných kritériách kvality.



Obr. 24 Základná slučka prostredia prípadovej štúdie FPS.

Predspracovanie údajov

Cieľom tejto fázy je vytvoriť interpretovateľný stavový vektor, ktorý je dostatočne hustý pre segmentáciu, porovnateľný naprieč metódami a ukotvený v herných mechanikách.

V rámci **čistenie dát** sa vylúčili sessiony kratšie než 30 sekúnd a prerušované alebo nekompletné sessiony, čo viedlo k odstráneniu 1 073 sessionov. Finálna vzorka obsahuje 846 sessionov odohraných 156 unikátnymi hráčmi.

Konštrukcia stavovej sekvencie vychádza z prevodu prúdu udalostí v každej hre na multidimenzionálnu stavovú sekvenciu s fixnou frekvenciou vzorkovania 1 Hz. Ide o praktický kompromis: frekvencia je dostatočne vysoká na zachytenie krátkych taktických prepnutí, no zároveň dostatočne nízka na redukciu šumu a na tvorbu interpretovateľných epizódových súhrnov pomocou agregáčnych pravidiel pre jednotlivé premenné (napr. priemery v rámci intervalu, počet udalostí za sekundu). Vytvorila sa core sada črt, ktorá pokrýva hlavné behaviorálne dimenzie potrebné na extrakciu taktík (Tab. 30):

- Zdroje a prežitie opisujú „ekonomiku“ hráča a umožňujú identifikovať kritické okná na základe úrovni batérií, zdravia a munície, vrátane ich zmien za sekundu.
- Aktivita a pohyb sú reprezentované priemernou rýchlosťou a smerovou stabilitou, čo umožňuje odlíšiť zber, kempovanie, presuny, únikové manévry alebo agresívny pohyb.
- Priestorový kontext je zachytený vzdialenosťou ku kľúčovým cieľom (najmä k portálu) a rýchlosťou zmeny tejto vzdialenosti za sekundu, čo signalizuje približovanie alebo odpájanie sa od cieľa.
- Bojová aktivita je sumarizovaná indikátorom výstrelu a počtom výstrelův za sekundu, zatiaľ čo bojový tlak/výsledok je vyjadrený intenzitou prijatého poškodenia za sekundu..

Tab. 30 Hlavné (core) charakteristiky identifikované v prípadovej štúdii.

Zdroje a prežitie	Aktivita a pohyb	Priestorový kontext	Bojová aktivita
• battery_change_per_s • health_change_per_s • ammo_change_per_s • battery_state_mean • health_state_mean • ammo_state_mean	• speed_state_mean • directional_stability	• dist_to_portal_mean • dist_to_portal_delta_per_s • moving_towards_portal	• shots_total_per_s • has_shot • damage_taken_intensity_per_s

Segmentácia epizód

Segmentácia epizód predstavuje kľúčový metodologický bod prípadovej štúdie: aby sa pred taktickou analýzou postupne vytvorili porovnateľné reprezentácie epizód, použili sa segmentačné mechanizmy. Segmentácia v tomto prípade riešila dvoma komplementárnymi dizajnmi: oknovým prístupom založeným na klastrovaní, ktorý priradzuje krátkodobé behaviorálne štítky na základe agregovaných okien, a duration-aware sekvenčným modelom (HSMM), ktorý odhaduje latentné režimy priamo z 1 Hz tickovej sekvencie.

Pred klastrovaním sa generujú prekrývajúce sa časové okná dĺžky 3 až 6 sekúnd s krokom 1 s. Každé okno sa reprezentuje agregáciou hodnôt (spojité stavy sa spriemerujú, zmeny zdrojov a vzdialeností sa sčítajú). Aby sa znížil vplyv dlhých chvostov v riedkych signáloch, aplikuje sa transformácia log1p a pred klastrovaním sa použije robustné škálovanie.

Behaviorálne štítky sa následne odvodzujú pomocou k-means a HDBSCAN.

k-means. Počet klastrov sa volí na základe internej validity a temporálnej stability. Naprieč oknami 3–6 s (14 črt) skóre silhouette konzistentne vrcholilo pri $K = 3$, zatiaľ čo index Davies–Bouldin (DB) preferoval väčšie K , najmä $K = 6$ pre 4 s a 5 s okná (a $K = 5$ pre 6 s okno). Pre nastavenia 4 s a 5 s sa zvolilo $K = 6$ ako hladšia alternatíva, ktorá v následnej štítkovej sekvencii znižovala rýchle prepínanie režimov. Konkrétne: pri 4 s okne mala silhouette maximum pri $K = 3$ (0,352), no DB sa zlepšil pri $K = 6$ (1,011) v porovnaní s $K = 5$ (1,020). Podobne pri 5 s okne silhouette vrcholilo pri $K = 3$ (0,313), zatiaľ čo DB dosiahlo minimum pri $K = 6$ (1,078). Krivka inercií nebola diagnostická – vykazovala plynulý pokles bez jasného „kolena“. Vzhľadom na relatívne nízku dimenzionalitu črt a použité robustné škálovanie sa PCA nepoužilo.

HDBSCAN. Okrem k-means sa vyhodnotilo hustotné klastrovanie (HDBSCAN), aby sa prekročil predpoklad sférických klastrov a aby bolo možné explicitne modelovať nejednoznačné okná ako šum. Na zlepšenie separácie v oblastiach s vysokou hustotou sa najprv oknové vektory embedovali pomocou UMAP (8 dimenzií, euklidovská metrika) a následne sa klastrovali v embedovacom priestore pomocou HDBSCAN s výberovým pravidlom EOM. Realizoval sa cielený parameter sweep, ktorého cieľom bolo vyvážiť temporálnu fragmentáciu a stabilitu režimov. Tabuľka 31 sumarizuje hlavné testované konfigurácie a ich výsledky pre varianty okien 3–6 s.

Tab. 31 Parametre HDBSCAN a stabilita klastra.

UMAP (dim, n_neighbors, min_dist)	HDBSCAN (min_cluster_size, min_samples, method)	clusters (3–6s)	noise %	mean persistence
(8, 100, 0.05)	(300, 20, eom)	25–34	1.1–5.1	0.045–0.077
(8, 50, 0.02)	(400, 25, eom)	27–31	1.1–4.6	0.057–0.069
(8, 50, 0.20)	(800, 40, eom)	12–19	1.5–2.4	0.309–0.380

Pre následné porovnanie sa zvolila posledná možnosť, pretože ponúka lepší kompromis medzi fragmentáciou a stabilitou: vedie k 12–19 klastrom so výrazne vyššou perzistenciou a konzistentne nižším podielom šumu.

Popri oknovom klastrovaní sa aplikoval aj skrytý semi-Markovov model (**HSMM**) priamo na 1 Hz tickovú sekvenciu, aby odvodené latentné režimy zohľadňovali trvanie bez zavádzania hraníc okien. Na zníženie vplyvu špičiek a zlepšenie kompatibility s emisným modelom sa použila transformácia $\log_{1p}$ a následne sa sada čít štandardizovala. Vyhodnotili sa konfigurácie HSMM s $K = 6$ stavmi a $D_MAX \in \{10, 30, 60\}$ s, a alternatíva s väčšou granularitou $K = 8$ s $D_MAX = 30$ s a $K = 12$ s $D_MAX = 10$ s (oboje s $N_ITER = 25$, $VAR_FLOOR = .001$; $MIN_EP_LEN = 3$ s).

Nastavenie $K = 8$ viedlo k stavom s nízkou podporou a krátkym trvaním a zvyšovalo fragmentáciu; pre porovnávaciu analýzu sa preto ponechalo $K = 12$.

Fáza 2 tak vyprodukovala výstup v podobe sekvencie surových štítkov v čase (oknové štítky mapované na ticky pre k-means/HDBSCAN; tickové štítky pre HSMM). Hoci inferencia HSMM je už svojou povahou „epizodická“, na zabezpečenie jednotného formátu epizód sa aj tu použijú rovnaké post-processing pravidlá ako pri klastrovaní.

Post-processing epizód

V prvej časti Fázy 3 sa segmentačné výstupy jednotlivých metód porovnávajú tak, že sa prúd štítkov z Fázy 2 prevedie na zoznam epizód. Najprv sa po sebe idúce identické štítky zlučujú do súvislých segmentov. Následne sa zavedie spoločné minimálne trvanie epizódy 5 sekúnd tak, že každý kratší segment sa zlúči s príľahlým segmentom. Tento krok odstráni krátke „bliknutia“ v časovaní štítkov a zabráni tomu, aby sa epizódy menili rýchlejšie než časový kontext používaný v oknových dizajnoch (4–5 s). Tým sa zabezpečí spoločná časová mierka naprieč metódami.

V prípade HDBSCAN sa dodatočne spracujú okná označené ako šum. Pred vytvorením epizód sa „šumové“ okná priradia k najbližšiemu ne-šumovému štítku, aby nevznikali umelé prerušenia sekvencie.

Tab. 32 kvantifikuje dopad tohto post-processingu naprieč segmentačnými dizajnmi. Vynútenie minimálnej dĺžky epizódy 5 sekúnd výrazne znižuje prepínanie štítkov a fragmentáciu epizód.

Tab. 32 Účinky post-processingu epizód.

metóda	% epizódy <5 s (pre)	zmeny/min (pre / post)	zmeny pokles (%)	epizódy (pre / post)	epizódy pokles (%)	median dur s (pre / post)
hsmm_1s	18.6	3.5 → 2.6	27	14,165 → 10,555	25	11.0 → 15.1
kmeans_4s_k6	30.5	9.0 → 5.6	38	34,469 → 21,688	37	5.0 → 7.1
kmeans_5s_k6	15.7	8.2 → 6.6	20	31,630 → 25,522	19	7.0 → 7.1
hdbscan_4s	39.8	12.6 → 6.9	46	48,197 → 26,617	45	5.0 → 7.1
hdbscan_5s	21.8	11.6 → 8.7	25	44,416 → 33,556	24	6.1 → 7.1

Po vyhladení sa každá epizóda zhrnula pomocou agregovaných deskriptorov a pre každý štítok sa vypočítali robustné prototypy (mediány čít s variabilitou vyjadrenou pomocou IQR). Následne sa tieto prototypy štítkov zhluovali (aglomeratívne hierarchické klastrovanie s Wardovým viazaním) do šiestich zdieľaných **meta-módov** s odlišnými profilmi (Obr. 25) a každý metodicky špecifický štítok sa namapoval do tohto spoločného slovníka (Tab. 33).

meta_label	battery	health	ammo	Δbattery	Δhealth	Δammo	speed	dir_stab	dist_portal	Δdist_portal	shots	has_shot
0	100	90	83.3	0	0	0	6.5	0.7	96.4	-0.1	2.5	0.7
1	31	100	93	2.5	0	-0.3	6.3	0.8	124.2	0	3	0.9
2	100	75	68.6	0	-4.9	-1.2	5	0.5	95.4	-0.1	3.9	1
3	100	64	254	0	6	0	3.5	1.2	99.4	-3	0	0
4	53.6	93.8	75.1	7	0	-1	4.2	0.5	101.1	-0.2	4.5	1
5	100	86.1	79.1	0	0	0	9.2	1.2	82.5	4	1.8	0.1

Obr. 25 Identifikované prototypy epizód naprieč kľúčovými charakteristikami

Mapovanie zároveň odhaľuje rozdiely v pokrytí jednotlivých meta-módov naprieč segmentačnými dizajnmi. Kým viaceré meta-štítky sú spoločné pre všetky metódy (napr. meta-0, 2 a 4), iné sa objavujú len v podmnožine prístupov: k-means neobsahuje meta-1, zatiaľ čo HSMM pridáva meta-3 a 5. Dôležité je, že tieto „metódo-spezifické“ epizódy nemusia byť nutne artefaktmi; zostávajú konceptuálne koherentné vzhľadom na prechodovú štruktúru zachytenú danou metódou (napr. modelovanie trvania v HSMM môže oddeliť režimy, ktoré oknové klastrovanie absorbuje do širších módov).

Tab. 33 Pokrytie meta-režimu podľa dizajnu segmentácie (počet označení na meta-označení).

meta label	HDBSCAN 4s	HDBSCAN 5s	HSMM	k-means 4s, k = 6	k-means 5s, k = 6
0	10	10	4	4	4
1	1	4	3	-	-
2	3	3	1	1	1
3	-	-	1	-	-
4	2	2	1	1	1
5	-	-	2	-	-

HDBSCAN navyše rozkladá bežné formy správania na jemnejšie štítky. Práve meta-módy preto umožňujú zmysluplné porovnanie naprieč dizajnmi aj vtedy, keď sa použité metódy líšia v tom, aké režimy správania priamo rozlišujú.

Ťažba taktík

Výstup z Fázy 3 sa pre každú hernú session reprezentuje ako usporiadaná sekvencia zdieľaných meta-módov. Následne sa vyhľadávajú opakujúce sa subsekvencie pomocou n-gramov ($n = 2-5$) a kandidáti sa akceptujú na základe výskytu v sessionoch ($\geq 5\%$). Z každého vzorca sa extrahujú neprekrývajúce sa výskyty, pričom výťažok ťažby sa výrazne líši v závislosti od segmentačného dizajnu (Tab. 34).

HDBSCAN generuje najdlhšie sekvencie, a preto aj najrozsiahlejší slovník vzorcov a najväčší ponechaný slovník (112 vzorcov), kým k-means produkuje kratšie sekvencie a menší súbor vzorcov (18–27). HSMM si ponecháva podobne veľký súbor (110), no jeho mediánová dĺžka sekvencie je len 5,5 s a zároveň zavádza dodatočné meta-módy, ktoré sú v oknových dizajnoch zriedkavé alebo sa v nich vôbec nevyskytujú.

Tab. 34 Výsledok ťažby a frekvencia n-gramov.

Method	Mean/median episodes per session	Tactics kept	Top bigram (support)	Top trigram (support)
KMeans-4s (K = 6)	6.75 / 6.0	18	0-2 (77.5%)	0-2-0 (72.7%)
KMeans-5s (K = 6)	7.76 / 7.0	27	0-2 (80.6%)	0-2-0 (75.3%)
HDBSCAN-4s	9.16 / 8.0	63	0-1 (65.2%)	0-1-0 (59.8%)
HDBSCAN-5s	15.78 / 13.0	112	1-0 (91.0%)	0-1-0 (78.6%)
HSMM-1s	11.11 / 5.5	110	1-0 (70.7%)	1-0-1 (41.6%)

Okrem samotných vzorcov sa odhadujú aj prechody prvého rádu medzi meta-módmi, aby sa zachytila globálna dynamika prepínania správania. Naprieč dizajnmi sa meta-mód 0 správa ako hub – teda režim, cez ktorý sa prechádza najčastejšie. Tabuľka 35 však neuvádza pravdepodobnosti prechodov, ale podporu na úrovni session (percento sessionov, v ktorých sa daný prechod aspoň raz vyskytne). Z toho vyplýva, že v jednej session sa môže vyskytovať viacero prechodových vzorcov súčasne.

V prípade k-means je prepínanie dominované módmi 0 a 2 (KMeans-5s: prechod $0 \rightarrow 2$ sa vyskytuje v 80,6 % sessionov; $2 \rightarrow 0$ v 76,6 %). Pri HDBSCAN-5s sessiony často obsahujú prechody z 0 do 1 aj do 2 ($0 \rightarrow 1$ v 87,5 %; $0 \rightarrow 2$ v 71,6 %), čo je konzistentné so silnou alternáciou $0 \leftrightarrow 1$. HSMM sa v tomto bode správa odlišne: zdieľané bojové vzorce 0-2 a 0-2-0 sú takmer neprítomné (1,3 % a 0,5 % sessionov), zatiaľ čo dominujú prechody súvisiace s portálom ($1 \rightarrow 0$ v 70,7 %, $0 \rightarrow 1$ v 47,4 %).

Tab. 35 Pomenované taktiky s podporou relácií (%)

Taktika	Vzorec	KMeans 4s	KMeans 5s	HDBSCAN 4s	HDBSCAN 5s	HSMM 1s
Eskalácia boja	0–2	77.5	80.6	64.3	71.6	1.3
Obnova/ústup	2–0	74.0	76.6	59.8	67.6	0.8
Nabitie portálu	0–1	-	-	65.2	87.5	47.4
Presun zdrojov k portálu	1–0	-	-	63.1	91.0	70.7
Bezpečná strelba	0–4	38.9	48.9	55.1	53.0	1.4
Bojový cyklus	0–2–0	72.7	75.3	57.7	61.5	0.5
Cyklus dobíjania portálu	0–1–0	-	-	59.8	78.6	27.1
Cyklus bezpečnej strelby	0–4–0	35.5	44.0	46.8	34.6	-

Konsolidácia a pomenovanie taktík. Aby výsledky ostali interpretovateľné, za primárny „slovník“ taktík sa považujú bigramy a trigramy; dlhšie vzorce sa využívajú najmä ako evidencia opakovania, nie ako samostatné taktiky. Taktiky sa pomenúvajú na základe prototypových profilov z Fázy 3. Bigramy zachytávajú dominantné prechody, vrátane *Eskalácia boja* (0–2) a *Obnova/ústup* (2–0). V prípade HDBSCAN sa pozorujú aj prechody orientované na portál, napríklad *Nabitie portálu* (0–1) a *Presun zdrojov k portálu* (1–0), popri vzorci *Bezpečná strelba* (0–4). Trigramy už zachytávajú celé mikro-rutiny, ktoré začínajú a končia v hub režime 0, napríklad *Bojový cyklus* (0–2–0), *Cyklus dobíjania portálu* (0–1–0) a *Cyklus bezpečnej strelby* (0–4–0). Štvorgramy sú väčšinou skôr rozšírením slučiek než novými rutinami (napr. opakovaná alternácia 0–2–0–2 sa vyskytuje v 52,6–57,0 % sessionov pri k-means; 1–0–1–0 v 66,5 % a 0–1–0–1 v 60,4 % sessionov pri HDBSCAN-5s).

Takto konsolidované formulácie môžu slúžiť ako kompaktný taktický slovník pre porovnanie dizajnov a pre následnú analýzu toku správania.

Diskusia a záver

Navrhnutý prístup sa dá interpretovať ako modulárny pipeline pre extrakciu taktík, v ktorom sa porovnateľnosť neodvodzuje z „výberu jednej najlepšej segmentácie“, ale z návrhu kontraktu medzi modulmi: fixovaním reprezentácie, zjednotením epizódového medzi-výstupu a použitím rovnakého ťažobného protokolu sa segmentačné metódy donútia produkovať kompatibilné výstupy. Tým sa rozdiely medzi segmentérmi sústreďujú do jednej časti pipeline (generovanie štítkov), zatiaľ čo následné kroky (epizódová schéma, post-processing, mapovanie na meta-módy a ťažba vzorcov) zostávajú spoločné. Výsledky sa tak stávajú merateľné a priamo porovnateľné naprieč dizajnmi.

Výsledky podporujú princípové **oddelenie behaviorálnej reprezentácie od segmentácie**. Nepravidelné eventové logy sa transformujú na fixne vzorkovaný multivariačný stavový časový rad, čím vzniká spoločný vstupný priestor aj pre zásadne odlišné neštruktúrované segmentéry. Interpretovateľnosť sa zachováva ukotvením črt v herných mechanikách (v prípadovej štúdii: zdroje a prežitie, pohyb, priestorový kontext a bojová aktivita). Porovnateľnosť sa vynucuje zafixovaním „rozhrania“: jednotná epizódová schéma, zdieľaný slovník meta-módov a identický protokol ťažby vzorcov. V tomto nastavení sa segmentéry porovnávajú férovo, pretože pracujú nad rovnakou reprezentáciou a odlišujú sa iba tým, akým mechanizmom odvodí štítky.

Pri fixnej reprezentácii a spoločných pravidlách spracovania sa ukazujú predvídateľné kompromisy medzi granularitou a interpretovateľnosťou epizód, najmä cez fragmentáciu (prepínanie) a štruktúru trvaní epizód. Zároveň sa potvrdzuje, že **post-processing je nevyhnutný** pre všetky metódy: pri minimálnej dĺžke epizódy 5 s klesá fragmentácia o 19–46 % v prepnutiach za minútu a o 19–45 % v celkovom počte epizód. Tento krok odstraňuje krátke „bliknutia“ štítkov okolo prechodov a harmonizuje časovú mierku naprieč oknovými a tickovými prístupmi, čím robí porovnania obhájiteľnejšími.

Pri rovnakom vstupe a zjednotenom epizódovom kontrakte sa segmentéry líšia najmä v granularite. k-means poskytuje nízko-fragmentačný baseline medzi oknovými metódami (v priemere 6,75–7,76 meta-módových epizód na session) a po mapovaní a zlučovaní vedie na menší slovník vzorcov (18–27). HDBSCAN prináša vyššie rozlíšenie: generuje dlhšie sekvencie a výrazne väčší ponechaný slovník vzorcov (až 112). HSMM sa správa odlišne od oknových dizajnov: ponecháva veľký súbor vzorcov (110), no mediánová dĺžka sekvencie je len 5,5 a pribúdajú meta-módy, ktoré sú v oknových dizajnoch zriedkavé alebo absentujú. Tieto rozdiely sú dôležité práve preto, že pipeline ich nerobí „neviditeľnými“ – naopak, robí ich kvantifikovateľnými a porovnateľnými.

Prototypovo riadené meta-módy **zlepšujú interpretovateľnosť aj porovnateľnosť** tým, že metodicky špecifické štítky sa mapujú do spoločného sémantického slovníka (napr. bezpečný stav, boj, portálový cyklus, bezpečná streľba). Tým sa predchádza ad hoc interpretáciám viazaným na konkrétnu segmentáciu a vytvára sa jednotná „jazyková“ vrstva, na ktorej sa dá konzistentne stavať ťažba taktík aj ich hodnotenie. Zároveň mapovanie ukazuje, že metódy sa nemusia zhodnúť v pokrytí všetkých meta-módov: niektoré meta-štítky sa zdieľajú naprieč dizajnmi, iné sa objavujú len v podmnožine prístupov. Takéto „metódo-špecifické“ epizódy pritom nemusia byť artefaktmi; môžu byť konceptuálne koherentné vzhľadom na prechodovú štruktúru, ktorú daný segmentér zachytí (napr. HSMM môže oddeliť režimy, ktoré oknové klastrovanie absorbuje do širších módov).

Objavené rutiny sú čiastočne závislé od segmentačnej metódy a táto závislosť je systematická. Vzorce sa prirodzene delia na dve vrstvy: **robustné jadro**, ktoré pretrváva naprieč oknovými dizajnmi (vysoko podporované vstupné a výstupné rutiny medzi často navštevovanými režimami), a **metódo-závislú vrstvu** (jemnejšie, cieľovo špecifické rutiny). Táto citlivosť zostáva interpretovateľná, pretože meta-mód 0 sa naprieč dizajnmi konzistentne objavuje ako spoločný východiskový stav a poskytuje referenčný bod, z ktorého cykly odchádzajú a do ktorého sa vracajú. Segmentéry sa potom špecializujú: k-means zvyrazňuje frekventované hrubé prechody, HDBSCAN zvyšuje rozlíšenie a oddeľuje subrutiny, ktoré oknové klastrovanie môže pohltiť do širších módov, kým HSMM prináša iné rozdelenie než oknové metódy a vykazuje slabší prekryv so zdieľaným taktickým jadrom.

Dôležité je, že citlivosť sama osebe neimplikuje chybu alebo šum. Často ide o správania na hranici časovej mierky, ktoré rôzne segmentéry prirodzene rozdeľujú alebo zlúčia odlišne. Práve preto je rozhodujúce, že reprezentácia, post-processing kontrakt a ťažobný protokol sú fixované: závislosť na segmente sa tým stáva merateľnou a reportovateľnou, a výsledkom sú tvrdenia typu „robustné naprieč dizajnmi“ vs. „podmienené segmentáciou“.

Z hľadiska odpovede na výskumnú otázku i z habilitačnej línie je podstatné, že pipeline produkuje procesné výstupy v jednotnej forme: meta-módové epizódy a taktické vzorce predstavujú porovnateľné procesné črty, ktoré sa dajú použiť ako samostatný view popri dotazníkoch a sumárnych logoch. **Oddelenie robustného jadra (vhodného na integráciu) od metódo-závislej vrstvy (vhodnej skôr na kontextovú interpretáciu) vytvára praktický predpoklad pre integráciu do spoločného priestoru bez toho, aby integrácia stála na jednom konkrétnom segmente metodických rozhodnutí.**

V tejto kapitole bola predstavená modulárna metodika na extrakciu taktík z telemetrie na úrovni udalostí, ktorej jadrom je porovnateľnosť naprieč segmentačnými dizajnmi. Postup je herne nezávislý v štruktúre: logy sa prevádzajú na interpretovateľnú stavovú sekvenciu s fixnou frekvenciou (Fáza 1), tá sa segmentuje do surovej štítkovej sekvencie (Fáza 2), epizódy sa stabilizujú jednotným post-processing kontraktom (Fáza 3) a zo štandardizovaných epizódových sekvencií sa vyťažujú opakujúce sa rutiny interpretované ako taktiky (Fáza 4). Prenositeľné ostáva to, čo je medzi vstupom a interpretáciou: jednotná epizódová schéma, meta-módy a jednotný protokol ťažby umožňujú férové, citlivosťou kontrolované porovnanie segmentérov, pričom rozdiely sa dajú reportovať ako systematická závislosť na segmente, nie ako nejasný „šum“. Doménovo ukotvené sú zámerne len dva

kroky: vo Fáze 1 sa črty viažu na mechaniky hry (podmienka interpretovateľnosti) a vo Fáze 4 sa rutiny pomenúvajú v doménových termínoch (podmienka použiteľnosti).

Ostatné časti pipeline sú navrhnuté tak, aby sa dali opakovane aplikovať naprieč hrami s tým, že sa menia najmä herne závislé parametre. Takto získané taktiky a ich prechodová štruktúra zároveň tvoria procesný view ako predpoklad integrácie do spoločného priestoru v multi-view profilovaní, keďže výstupy majú jednotný formát a sú porovnateľné naprieč analytickými voľbami.

Limity tejto časti spočívajú v tom, že evidencia vychádza z jednej prípadovej štúdie ukotvenej v jednom hernom cykle a sade črt, mechanicky odvodené črty sa navrhujú manuálne (čo síce podporuje interpretovateľnosť, ale ovplyvňuje, čo je v dátach viditeľné), niektoré segmentéry môžu aj po zjednotenom post-processingu viesť k čiastočne nekompatibilným slovníkom a n-gramová ťažba zachytáva najmä lokálne rutiny, nie kontextovo vetvenú štruktúru (najmä v pomalších žánroch).

Prínos pre oblasť habilitácie

Prínos tejto sekcie pre oblasť habilitácie možno zhrnúť do nasledujúcich bodov:

- Teoretický prínos spočíva v zavedení procesnej reprezentácie správania ako samostatnej vrstvy medzi surovou telemetriou a globálnymi profilmi používateľa. Epizódy sa chápu ako lokálne stabilné úseky správania a taktiky ako vyššia, opakujúca sa rutina zložená z jednej alebo viacerých epizód. Tým sa dá správanie vysvetľovať v pojmoch prechodov medzi režimami a opakovaných vzorcov, nie iba cez agregované sumáre.
- Metodický prínos spočíva v modulárnom rámci, ktorý oddeľuje reprezentáciu, segmentáciu, post-processing a ťažbu taktík tak, aby výsledky ostali porovnateľné aj pri výmene segmentačného dizajnu. Kľúčové je, že sa najprv vytvorí pevná vstupná reprezentácia ako viacrozmerná stavová časová rada vo fixnej frekvencii, následne sa epizódy segmentujú zameniteľnými prístupmi (oknové zhlukovanie, hustotné zhlukovanie, model s explicitnou dĺžkou trvania), no výstup sa zjednotí spoločným epizódovým kontraktom: vyhladenie, zlučovanie krátkych úsekov a mapovanie metódovo-špecifických značiek do malého slovníka meta-módov odvodeného z prototypov. Tento spoločný post-processing má empiricky preukázaný efekt: zavedenie minimálnej dĺžky epizódy výrazne redukuje fragmentáciu a tým zlepšuje porovnateľnosť sekvencií naprieč metódami. Rámec zároveň umožňuje transparentne oddeliť stabilné jadro výsledkov od metódo-závislej vrstvy, ktorá je analyticky informatívna, no nesmie sa zamieňať za univerzálnu pravdu.
- Praktický prínos spočíva v tom, že výsledkom nie sú len epizódy, ale auditovateľný a kompaktný slovník taktík a prechodových štruktúr, ktorý sa dá priamo použiť pri analýze správania, návrhu mechaník, ladení obtiažnosti, tréningu alebo pri modelovaní správania agentov. Dôležité je aj to, že rámec nevyžaduje platformovo špecifické doplnenia logovania: opiera sa o štandardnú event-telemetriu a o mechanicky ukotvené črty, ktoré sa dajú implementovať naprieč hrami a virtuálnymi scenármi.
- Pre multi-view modelovanie kapitola dodáva procesný pohľad, ktorý je porovnateľný naprieč segmentačnými voľbami, a tým je pripravený na integráciu do spoločného priestoru. Kľúčový prínos je v porovnateľnosti výstupu: fixovaná reprezentácia a jednotný epizódový kontrakt zaručujú, že následné procesné črty (frekvencie meta-módov, dĺžky epizód, prechodové miery, podpora taktík) majú rovnaký význam bez ohľadu na použitú segmentáciu. Zároveň rámec prirodzene podporuje stability-first integráciu: umožňuje rozlíšiť robustné jadro taktík, ktoré sa drží naprieč metódami, od citlivej vrstvy, ktorú treba vážiť opatrne podľa stability a pokrytia. Tým procesná vrstva funguje ako kontrolovane konštruovaný zdroj signálu pre neskorú fúziu a pre následné mapovanie taktík na úroveň používateľa v ďalších etapách profilovania

Stability-first pipeline pre replikovateľné persony

Interaktívne systémy a virtuálne prostredia sú dnes všadeprítomné, no ich publikum je výrazne heterogénne. Univerzálny dizajn preto nie vždy spoľahlivo pokrýva potreby rôznych skupín používateľov a mnohé aplikácie smerujú k personalizácii. Jej východiskom sú používateľské modely, ktoré musia byť psychologicky zmysluplné, prakticky použiteľné a zároveň dostatočne robustné na podporu dizajnových rozhodnutí aj adaptačných politík (Sanchez-Gordon et al., 2021), (Bojic, 2022), (Sally Wu & Alan Hung, 2022).

V praxi sa persony často odvodzujú pomocou metód unsupervised learning, najmä prostredníctvom klastrovania. Na rozdiel od kontrolovanej predikcie, kde existuje cieľová premenná a úspešnosť modelu možno overiť voči externému referenčnému kritériu, nekontrolovaná segmentácia takúto „základnú pravdu“ pre správne persony neponúka (Wongabut et al., 2025). Segmenty tak vznikajú ako výsledok analytických rozhodnutí – voľby atribútov, škálovania, metód klastrovania či parametrov – a preto zostáva otvorené, do akej miery zachytávajú stabilnú štruktúru populácie a do akej miery odrážajú len nastavenie analýzy. Rizikom je krehká segmentácia: zdanlivo koherentné klastre sa môžu pri malých zmenách v údajoch alebo modelovacích voľbách posunúť, zlúčiť, rozdeliť alebo zmeniť význam. V prípade person zameraných na dizajn by sa preto kvalita riešenia mala posudzovať predovšetkým z hľadiska reprodukovateľnosti a istoty priradenia, a nie výlučne na základe interných indexov validity z jedného behu (H. Yu et al., 2019), (Hennig, 2007), (Hassan et al., 2024).

Druhým problémom je situácia, keď sa profily používateľov skladajú z heterogénnych meracích blokov, ktoré sa líšia spôsobom zberu aj povahou zachytávaných údajov (napr. psychometrické sebahodnotenie, záznamy správania a telemetria, hodnotenia skúsenosti či kontextové deskriptory). V hrách a gamifikovaných systémoch sa tieto bloky často navrhujú, zbierajú a analyzujú paralelne a až následne sa dodatočne kombinujú (Yannakakis & Togelius, 2018b). Takáto operačná fragmentácia potom oslabuje spoločné inferencie: výsledný profilovací priestor býva citlivý na zvolené reprezentácie a váhy jednotlivých blokov, čo sťažuje konštrukciu person, ktoré by zostávali zároveň stabilné a interpretovateľné aj pri pohľade naprieč rôznymi dátovými blokmi (Klock et al., 2020), (Meriläinen & Ruotsalainen, 2023), (Phosanarack et al., 2025).

Táto kapitola predstavuje stability-first metodiku pre viacblokové profilovanie a replikovateľnú segmentáciu person. Pipeline je postavený na piatich krokoch, ktoré sú navrhnuté tak, aby obmedzili krehkosť riešení a spriehľadnili neistotu:

1. Kontrola kvality dát a vstupné preverovanie (upfront) – najprv overí úplnosť, konzistentnosť a rozsahy premenných, identifikujú sa chýbajúce hodnoty, duplicitné záznamy a zjavné anomálie. Cieľom je odstrániť zdroje artefaktov ešte pred tým, než sa dostanú do profilovacieho priestoru a „zabetónujú“ sa v segmentácii.
2. Blokovovo uvedomelá reprezentácia v súlade s meraním (measurement-consistent) vychádza z faktu, že každý dátový blok (napr. rôzne typy dotazníkov, telemetria) sa reprezentuje spôsobom, ktorý rešpektuje jeho škálu, šum a interpretačný význam, a preto sa explicitne rieši vyváženie blokov, aby jeden blok nedominoval len kvôli mierke či početnosti premenných. Výsledkom má byť spoločný profilovací priestor, kde porovnanie používateľov nie je artefaktom reprezentácie.
3. Konzervatívne ošetrenie odľahlých hodnôt a šumu vyžaduje robustné spracovanie odľahlých a extrémnych hodnôt tak, aby jednotlivé záznamy neskresľovali podobu klastrov. Zmyslom je zvýšiť stabilitu riešenia bez toho, aby sa stratili reálne, ale zriedkavé vzorce správania.
4. Segmentácia s explicitnou neistotou zabezpečí, aby používatelia neboli napevno priradení k jednej persone, pipeline pracuje s neistotou priradenia – buď priamo cez probabilistické

(vektorové) členstvá, alebo cez post hoc skóre istoty. Na tejto báze sa potom odlišuje CORE (stabilné jadro osoby) od BOUNDARY (hraničné prípady), ktoré sú analyticky informatívne a nemajú byť ignorované.

5. Stabilitné a kritériové kontroly s externými kotvami a premennými vylúčenými z klastrovania zabezpečia ďalšiu úroveň kontroly, aby sa kvalita nehodnotila len internými indexmi z jedného behu, ale stabilitou pri perturbáciách (resampling, matching klastrov) a zároveň cez premenné, ktoré boli zámerne vynechané z klastrovania a slúžia ako externé kritériá. Tým sa znižuje riziko kruhového dokazovania a kvalita segmentácie sa opiera o nezávislé indície, že identifikované osoby sú reprodukovateľné a zároveň použiteľné pre interpretáciu a dizajnové rozhodnutia.

Po špecifikácii metodiky je rámec demonštrovaný v dvojblokovvej prípadovej štúdií s použitím dotazníkov bežne používaných v personalizácii a UX modelovaní: nástroj typu hráč s nútenou voľbou v štýle Bartleho (Bartle, 1996), dotazník *Immersive Tendencies Questionnaire* (ITQ) (Witmer & Singer, 1998), pričom aplikácia je určená ako metodologická demonštrácia a nemala by sa interpretovať ako validačná štúdia nástroja.

Tento zámer sumarizuje výskumná otázka kapitoly:

- **STAB1: Ako navrhnúť a reportovať stability-first pipeline pre viacblokové profilovanie tak, aby výsledné osoby boli replikovateľné, mali explicitne vyjadrenú neistotu priradenia (CORE/BOUNDARY) a boli overené na externých kotvách nezahrnutých v klastrovaní?**

Prehľad relevantných zdrojov

Východiskom pri návrhu pipeline je to, čo sa v profilovaní person opakovane ukazuje ako kritické: stabilita výsledkov a spôsob, akým reprezentácia dát formuje segmentáciu. Keďže používateľské profily majú spravidla spojitý a viacrozmerný charakter, osoby nie sú ostré kategórie, ale aproximácie heterogenity populácie. Táto časť preto mapuje metodické piliere, ktoré rozhodujú o spoľahlivosti osoby: stabilitu a reprodukovateľnosť segmentácie, neistotu priradenia, integráciu heterogénnych blokov merania a kritériovo orientované kontroly na zadržaných premenných.

Pri učení bez dozoru je „správnosť“ klastrov bez externého kontextu v zásade neurčitá a rôzne algoritmy, prípadne aj malé zmeny v modelovaní, môžu viesť k riešeniam, ktoré sa líšia, no každé z nich je vnútorne vierohodné (Masoero et al., 2023). Tento efekt sa prirodzene zvyrazňuje v behaviorálnych a psychometrických dátach, kde sa latentná štruktúra často prekrýva, je zašumená a len slabo oddelená (García-Escudero & Mayo-Isacar, 2024). V takýchto podmienkach môžu byť bežné segmentačné metódy, najmä k-means, nestabilné: opierajú sa o pomerne reštriktívne geometrické predpoklady, používajú tvrdé priradenia a bývajú citlivé na odľahlé hodnoty (Scrucca et al., 2016), (López-Pernas et al., 2024). Následkom môže byť nízka reprodukovateľnosť naprieč vzorkami a perturbáciami, čo degraduje výsledky a motivuje hľadanie prístupov, ktoré uprednostňujú stabilnú štruktúru pred snahou pokryť všetky pozorovania za každú cenu (Farcomeni & Punzo, 2020). Ako flexibilnejšia alternatíva sa preto často odporúča modelovo založené klastrovanie, vrátane gaussovských zmesových modelov (GMM), ktoré vedia reprezentovať eliptické klastre (napr. pri diagonálnom kovariančnom obmedzení) a zároveň poskytujú pravdepodobnostné členstvá podporujúce interpretáciu s ohľadom na neistotu (Von Luxburg, 2009).

Tradičné prístupy ku kvantifikácii istoty priradenia používateľa k segmentu, ktoré sa opierajú najmä o indexy vnútornej validity (napr. Silhouette), bývajú pri behaviorálnych dátach často nedostatočné. V typológiách používateľov, kde sú hranice medzi skupinami prirodzene mäkké a populácia skôr tvorí kontinuum než ostré triedy, môže spoliehanie sa výlučne na vnútornú validitu nadhodnotiť prítomnosť

štruktúry – algoritmus potom „vyrobí“ zhľuky aj v situácii, keď dáta v skutočnosti reprezentujú len jeden relatívne homogénny oblak bodov (Von Luxburg, 2009).

Výber modelu založený na stabilite sa namiesto jednorazovej „kvality“ pýta, či riešenie pretrvá aj pri perturbáciách dát. Ak segmentácia zachytáva zmysluplnú štruktúru, mala by byť reprodukovateľná naprieč prevzorkovanými alebo inak narušenými verziami toho istého súboru údajov (García-Escudero & Mayo-Isacar, 2024), (Von Luxburg, 2009), (Ben-Hur et al., 2002). Bežnou voľbou sú bootstrapové procedúry, ktoré opakovane pretrénujú klastrovací model na resamplovaných dátach a následne kvantifikujú zhodu medzi jednotlivými behmi (typicky po zladení labelov), čím poskytujú priamy odhad stability riešenia (Tian et al., 2021).

Okrem výberu stabilného počtu segmentov si personalizácia vyžaduje aj informáciu o tom, s akou istotou možno konkrétneho používateľa priradiť k persone. Tvrdé priradenie síce poskytne jednoznačný label, no neukáže, kde sú hranice medzi personami prirodzene neostre. Pravdepodobnostné (modelovo založené) klastrovanie naopak umožňuje pracovať s neistotou priamo – cez posteriórne miery členstva, ktoré vyjadrujú silu dôkazov pre jednotlivé priradenia. Takýto pohľad prirodzene odlišuje jasných jadrových členov od nejednoznačných hraničných prípadov a zosúladzuje rozhodnutia založené na persone s mierou istoty, namiesto toho, aby všetky priradenia považoval za rovnako spoľahlivé (P. Wang et al., 2024). V dizajnovej praxi je tento rozdiel podstatný. Ak dizajnér prispôsobuje hru pre kompetitívnu personu, najodolnejšia interpretácia vychádza z jadra skupiny, kde sú prejavy motivácie a správania konzistentné. Hraničná zóna naopak zahŕňa prípady, ktoré sú medzi personami na okraji, takže intervencie riadené personou majú vyššiu šancu minúť cieľ alebo vytvoriť zmiešaný efekt (Wu et al., 2022). Modelovo založené prístupy pritom poskytujú aj diagnostiky, ktoré túto istotu priradenia kvantifikujú priamo a umožňujú ju transparentne reportovať (Zhu & Melnykov, 2015).

Profilovanie používateľov v interaktívnych systémoch čoraz častejšie spája heterogénne bloky – napríklad miery sebahodnotenia, stopy správania a kontextové deskriptory – no naivné „zreťazenie“ týchto zdrojov môže segmentáciu skresliť. V euklidovských reprezentáciách majú totiž bloky s väčším počtom premenných alebo s vyššou variabilitou tendenciu dominovať v mierach podobnosti, a tým neúmerne ovplyvniť výsledné klastrovanie, aj keď iné bloky nesú pre dizajn rovnako dôležitý signál (L. Zhou et al., 2024), (U. Fang et al., 2023).

Schémy regularizácie a váženia fúzie sa preto používajú na to, aby sa príspevok jednotlivých blokov k celkovej odlišnosti kontroloval explicitne, a nebol len vedľajším dôsledkom mierky či dimenzionality. V literatúre sa pritom najčastejšie rozlišujú tri základné prístupy k fúzii údajov (Chao et al., 2021b), (Wan et al., 2023), (Lakatos et al., 2024).

- Skorá fúzia spája prvky z rôznych blokov do jedného spoločného vektora ešte pred analýzou; je implementačne jednoduchá, no citlivá na dominanciu jedného bloku a na problémy vysokej dimenzie, takže si vyžaduje dôsledné predspracovanie, škálovanie a váženie.
- Neskorá fúzia spracúva každý blok samostatne a až následne kombinuje výsledky; lepšie rešpektuje špecifiká blokov, no môže prehliadnuť vzťahy, ktoré sa ukážu až v ich prieniku.
- Stredná fúzia napokon konštruuje zdieľané latentné reprezentácie, čo je metodologicky elegantné, ale často menej transparentné pre interpretáciu, keďže latentné dimenzie nemusia mať jednoznačný význam.

Hoci stabilita a robustnosť zvyšujú istotu, že klastre sú matematicky konzistentné a reprodukovateľné, samy osebe ešte nehovoria nič o ich dizajnovej relevantnosti. Segmentácia môže byť veľmi stabilná, no pre personalizáciu hier úplne nepoužiteľná (napr. ak v praxi len odráža triviálne pravidlo typu abecedné zoradenie hráčov), pričom kľúčovým rizikom je nadmerná interpretácia – situácia, keď sa štatistický

artefakt začne čítať ako zmysluplné osoby (Von Luxburg, 2009), (Hosseini et al., 2020). Posledný pilier metodiky preto posúva hodnotenie za rámec internej validity smerom ku kritériovej validácii, ktorá pracuje s externými premennými zámerne nezahrnutými do klastrovania ani do výberu modelu (Indu et al., 2025).

Bežným úskalím segmentačných štúdií je kruhovitosť, keď sa tie isté premenné použijú na konštrukciu klastrov aj na ich následné overenie správnosti (Hosseini et al., 2020). Aby sa tomuto efektu predišlo, sledované atribúty sa rozdelia na dve skupiny: vyhradené (ad-hoc) kritériá sa používajú výlučne na post hoc hodnotenie (napr. demografia, behaviorálne výsledky alebo preferencie), zatiaľ čo profilovací priestor zahŕňa len premenné potrebné na vytvorenie segmentačného modelu. Hodnotenie sa potom prirodzene mení na testovanie hypotéz: ak osoby odvodené z profilovacieho priestoru vykazujú prakticky zmysluplné rozdiely vo vyhradených kritériách – a zároveň sa pritom zohľadní neistota priradenia – zvyšuje sa dôvera, že segmentácia zachytáva relevantné rozdiely, nie len formálnu štruktúru dát (Zaki & Meira, 2014).

Metodika stability-first profilovania a segmentácie

Profilovanie používateľov v interaktívnych systémoch zriedka vychádza z jedného homogénneho merania. Skôr naopak, profily sa typicky skladajú z heterogénnych blokov, ktoré sa líšia tým, čo zachytávajú aj ako sa údaje získavajú – od dotazníkov cez stopy správania až po hodnotenia skúsenosti. Tieto bloky pritom nesú odlišné mierky, šumové vlastnosti a implicitné obmedzenia, takže naivné zreťazenie premenných a jednorazové klastrovanie býva krehké (Moujahid & Dornaika, 2025), (Haris et al., 2024). Zároveň je ľudské správanie prirodzene variabilné: používatelia menia stratégie naprieč kontextmi, mnohí sa nachádzajú medzi prototypmi a netriviálna časť pozorovaní je skôr nejednoznačná, než aby jednoznačne patrila do jedného segmentu (L. Liu et al., 2023), (T. Liu et al., 2022). Práve táto kombinácia heterogénnych blokov a šumovej štruktúry správania motivuje metodiku, ktorá uprednostňuje stabilitu, rešpektuje meracie špecifiká jednotlivých blokov a odvodzuje osoby reprodukovateľné pri perturbáciách dát, pričom explicitne zohľadňuje neistotu členstva aj vplyv odľahlých hodnôt.

Definícia problému a vstupy

Majme prostredie, v ktorom viacero heterogénnych blokov merania opisuje každého používateľa. Každý blok zachytáva iný aspekt používateľa (napr. škály z rôznych dotazníkov, súhrn správania alebo deskriptor kontextu) a je vytvorený vlastným procesom merania, potenciálne s rôznymi škálami, charakteristikami šumu a obmedzeniami. Metodologickým cieľom je integrovať tieto bloky do jedného, spoločného profilovacieho priestoru, ktorý podporuje segmentáciu osoby bez toho, aby sa znehodnotili vlastnosti merania špecifické pre daný blok.

Nech $i = 1 \dots N$ je index používateľov a $b = 1 \dots B$ index blokov merania. Pre používateľa i , blok b poskytuje vektor znakov $x_i^{(b)} \in \mathbb{R}^{d_b}$. Kompletný viacblokový profil je kolekcia $X_i = \{x_i^{(1)} \dots x_i^{(B)}\}$. Pred integráciou je každý blok namapovaný na reprezentáciu vhodnú pre spoločnú analýzu prostredníctvom blokovo špecifickej transformácie $g_b()$, ktorá rešpektuje vlastnosti merania bloku (napr. škálovanie, ohraničenosť alebo iné obmedzenia). Výsledná spoločná reprezentácia je jeden vektor definovaný v (1)

$$z_i = [g_1(x_i^{(1)}), \dots, g_B(x_i^{(B)})] \quad (1)$$


ktorý definuje priestor profilovania spoločného priestoru použitý na segmentáciu.

Premenné použité na zostavenie z_i a na natrénovanie segmentačného modelu sú oddelené od premenných vyhradených na ad-hoc vyhodnotenie. Nech h_i označuje nevyhradené kritériá (napr. demografické údaje, intenzitu používania alebo indikátory preferencií), ktoré sa nepoužívajú pri zoskupovaní a nastaveniach modelu. Tieto nevyhradené premenné slúžia ako externé kontroly relevantnosti dizajnu: po odvodení person sa segmenty testujú na zmysluplné rozdiely v h_i bez toho, aby sa tieto premenné zahrnuli do procesu segmentácie.

Popis pipeline

Vychádzajúc z reprezentácie spoločného profilovania $\{z_i\}_{i=1}^N$ a rezervujúc $\{h_i\}_{i=1}^N$ pre hodnotenie založené na kritériách, je segmentačný kanál zameraný na stabilitu organizovaný do nasledujúcich fáz (Obr. 26):

- **Fáza 1: Príprava vstupov** – skríning a príprava vstupov, posúdenie správnosti meraní a chýbajúcich vzorov, skríning kandidátskych vstupov na informatívnosť a redundanciu a vytvorenie mapovaní blokov konzistentných s meraniami pre spoločné profilovanie pomocou $g_b()$.
- **Fáza 2: Robustná segmentácia** – prispôbuje pravdepodobnostný model segmentácie priestoru spoločného profilovania, aplikuje konzervatívne spracovanie atypickej štruktúry a podporuje členstvo jadra vs. hraníc prostredníctvom posteriorných pravdepodobností.
- **Fáza 3: Posúdenie stability a reprodukovateľnosti** – hodnotí, či sa podobné segmenty obnovia pri kontrolovaných perturbáciách (napr. prevzorkovanie) na úrovni riešenia, klastra a jednotlivca.
- **Fáza 4: Kontrola prostredníctvom externých kritérií** – charakterizácia a porovnanie person pomocou premenných $\{h_i\}$ vylúčených z konštrukcie klastrovacieho priestoru, ktoré budeme označovať ako externé.



Obr. 26 Štruktúra metodiky segmentácie zameranej na stabilitu. Diagram sumarizuje štvorstupňový postup – prípravu vstupov, robustnú segmentáciu založenú na modeli s posteriorným členstvom CORE/BOUNDARY, posúdenie stability pri prevzorkovaní a hodnotenie orientované na kritériá s použitím vyhradených premenných zo segmentácie.

Fáza 1: Príprava vstupov

Pred segmentáciou sa heterogénne meracie bloky najprv upravajú tak, aby z nich vznikol spoločný profilovací priestor, v ktorom žiadny blok nedominuje len preto, že má inú mierku alebo viac premenných. Postup má dve hlavné časti, pričom najprv sa v každom bloku skontroluje, či dáta zodpovedajú špecifikácii merania, aký je rozsah chýbajúcich hodnôt, či sa nevyskytujú degenerované premenné (napr. takmer konštantné) a či nie je blok zbytočne redundantný. Zachovaný blok sa následne transformuje na reprezentáciu $z^{(b)} = g_b(X^{(b)})$, ktorá rešpektuje jeho meracie vlastnosti a dá sa ďalej štandardizovať a kombinovať s ostatnými blokmi. Pri kompozičných blokoch (alebo blokoch obsahujúcich kompozície) sa transformácie definujú priamo na úrovni bloku; výsledné súradnice sa potom vložia do euklidovského profilovacieho priestoru.

Sanitácia vstupov

V prvom kroku sa každá premenná skontroluje voči svojej špecifikácii merania (povolené rozsahy a kategórie, reverzné kódovanie, nemožné hodnoty). Hodnoty mimo špecifikácie sa nastavujú ako chýbajúce (nie „vynútené“) a položky s reverzným kódovaním sa opravujú ešte pred akoukoľvek agregáciou. Chýbajúce odpovede sa pritom neposudzujú len podľa celkovej miery, ale aj podľa toho, či sa koncentrujú v konkrétnych blokoch alebo u konkrétnych respondentov, keďže systematické chýbanie môže skresľovať profily aj vtedy, keď je priemerná miera nízka (Jakobsen et al., 2017), (Hughes et al., 2019). Prahové hodnoty sa používajú ako explicitné skríningové pomôcky, nie ako univerzálne pravidlá (Hughes et al., 2019), (Madley-Dowd et al., 2019). Prakticky sa ako orientačné hranice uvažuje napr. 5 % missingness pre citlivosť analýzy úplných prípadov; premenné s veľmi vysokou mierou chýbajúcich hodnôt (napr. > 40 %) sa vylučujú z klastrovacích vstupov; a respondenti s > 20 % chýbajúcich odpovedí v rámci bloku sa označia na vylúčenie na úrovni bloku alebo na analýzu citlivosti. Tieto hranice slúžia ako prevádzkové záruky, motivované tým, že analýza úplných prípadov môže byť pri realistických mechanizmoch chýbania skreslená. Primárny klastrovací priestor sa následne zostaví len z respondentov, ktorí majú kompletné mapované súradnice pre všetky ponechané klastrovacie bloky (po aplikovaní uvedených pravidiel). Prípady, ktoré nespĺňajú úplnosť blokov, sa podľa potreby využijú už len v deskriptívnych analýzach. Pri dotazníkových blokoch sa navyše konzervatívne označuje nedostatočné úsilie pri odpovedaní vtedy, keď sa zhodne viacero indikátorov nízkej snahy (napr. priame zoradenie alebo dlhé reťazce rovnakých odpovedí, nízka variabilita a súčasne vnútroosobné nekonzistentnosti), aby sa rozhodnutie neopieralo o jedinú potenciálne zašumenú diagnostiku.

Blokovo špecifické mapovanie

Ak si to návrh merania vyžaduje, surové indikátory sa pred mapovaním najprv agregujú do profilov na úrovni blokov. Pri inventároch s vynúteným výberom sa položky zvyčajne zhlukujú do niekoľkých častí a následne sa vyjadria ako kompozičný profil s pevným súčtom; pri viacpoložkových Likertových blokoch sa surové položky naopak redukovujú na menší počet latentných dimenzií (napr. faktorové skóre). Pre každý merací blok b sa potom zachované premenné $X^{(b)}$ mapujú do reprezentácie konzistentnej s vlastnosťami daného bloku podľa (2):

$$z^{(b)} = g_b(X^{(b)}) \quad (2)$$

Kompozičné profily (t. j. časti, ktoré sa sčítavajú do konštanty) sa mapujú zo simplexného do euklidovského priestoru pomocou izometrických súradníc logaritmického pomeru (ILR), pričom logaritmy sa aplikujú vo forme logaritmických pomerov ešte pred akoukoľvek štandardizáciou (Egozcue et al., 2003). Pri viacpoložkových Likertových blokoch sa extrakcia faktorov a jej hodnotenie realizujú v

rámci bloku (napr. exploratívne modelovanie faktorov so šikmou faktorovou štruktúrou) a výsledné súradnice faktorových skóre sa následne použijú ako vstupy pre klastrovanie.

Skríning informatívnosti

Aby sa v profilovacom priestore zachoval aspoň minimálny segmentačný signál, medzi mapovanými euklidovskými súradnicami určenými na klastrovanie sa najprv skrínajú prediktory s takmer nulovou variáciou (napr. ILR súradnice pri kompozičných blokoch a súradnice faktorových skóre pri Likertových blokoch). Premenné sa považujú za efektívne neinformatívne vtedy, keď nadobúdajú len malý počet odlišných hodnôt a rozdelenie je prakticky ovládané jednou hodnotou, čo naznačuje zanedbateľnú efektívnu variabilitu a môže viesť aj k numerickej nestabilite.

Redundancia sa následne rieši iteratívnym skríningom asociácií v rámci bloku (napr. vynútením $|r| < 0.90$) (Kuhn & Johnson, 2019). V rámci silne korelovaných skupín sa odstráni premenná s najvyššou priemernou absolútnou koreláciou voči ostatným, aby sa znížila redundancia a zlepšila interpretovateľnosť. Skríning korelácií sa pritom aplikuje primárne v rámci každého bloku, takže asociácie medzi blokmi – ktoré môžu niesť zmysluplnú štruktúru – sa štandardne neeliminujú. Ako sekundárna, kontextovo závislá diagnostika (nie ako primárne pravidlo odstraňovania) sa doplnkovo uvádzajú aj hodnoty VIF, ktoré slúžia ako varovný signál možného problematického prekryvania (Hair et al., 2019).

Štandardizácia

Pre nekompozičné spojité vstupy používané na klastrovanie sa pred štandardizáciou aplikujú monotónne mocninové transformácie vtedy, keď sú rozdelenia výrazne zošikmené (napr. $|skewness| > 2$ and $|kurtosis| > 7$). Pre striktné kladné premenné sa používa Box–Cox transformácia, kým Yeo–Johnson transformácia je vhodná v prípadoch, keď sa môžu vyskytovať aj nuly alebo záporné hodnoty (Rojas-Perilla et al., 2020).

Po mapovaní blokov (a prípadných transformáciách zošikmenia) sa všetky dimenzie spoločného priestoru štandardizujú, aby sa znížila závislosť od merných jednotiek – známy metodologický problém klastrovej analýzy. Štandardizácia síce vyrovná mierku na úrovni jednotlivých dimenzií, no sama osebe ešte nebráni tomu, aby blok s väčším počtom dimenzií dominoval vzdialenostiam alebo príspevkom pravdepodobnosti. Preto sa pri zreťazovaní blokov aplikuje váženie na úrovni blokov (Edmondson, 2020), napríklad podľa (3):

$$u = [w_1 z^{(1)} \parallel \dots \parallel w_B z^{(B)}], w_b = 1/\sqrt{p_b}, \quad (3)$$

kde p_b počet zachovaných dimenzií v bloku b , takže každý blok prispieva do spoločného priestoru porovnateľnou mierou. Výsledný vážený vektor u následne slúži ako euklidovský vstup pre segmentáciu v 2. fáze.

Fáza 2: Robustná segmentácia

Po zostavení spoločného profilovacieho priestoru u sa segmentácia realizuje pomocou gaussovských zmesových modelov (GMM). GMM poskytujú pravdepodobnostný rámec klastrovania v spojitých euklidovských priestoroch a výstup Fázy 1 má presne takúto podobu, takže gaussovské komponenty predstavujú prirodzený spôsob, ako modelovať heterogénne skupiny prostredníctvom interpretovateľných centier a variácií (Scrucca et al., 2016). Okrem flexibilnej geometrie klastrov GMM priamo poskytujú aj posteriórne pravdepodobnosti členstva, ktoré kvantifikujú neistotu priradenia. To umožňuje prakticky rozlíšiť prípady s vysokou istotou (jadro/CORE) od hraničných prípadov (BOUNDARY), namiesto toho, aby sa všetky priradenia považovali za rovnako spoľahlivé. Zmesový rámec zároveň podporuje robustnosť voči atypickým pozorovaniam: tie sa dajú konzervatívne ošetriť buď prerezaním (pruning), alebo ich dočasným priradením do samostatnej

nízko-hustotnej/šumovej komponenty ako predbežným skríningovým krokom (García-Escudero et al., 2008).

Ošetrovanie odľahlých prípadov

Odľahlé pozorovania môžu mať na odhad zmesových modelov neúmerený vplyv a najmä v malých až stredne veľkých vzorkách môžu posunúť segmentáciu tak, aby „vysvetľovala“ niekoľko extrémnych prípadov namiesto dominantnej štruktúry dát. Namiesto spoliehania sa na univariačné prahy sa preto používa konzervatívna, modelovo založená brána, ktorá potenciálnu odľahlú štruktúru reprezentuje ako nízko-hustotnú komponentu v tom istom pravdepodobnostnom rámci (Coretto, 2022), (Farcomeni & Punzo, 2020).

V spoločnom priestore u sa najprv odhadne jednoduchý dvojkomponentový GMM (4),

$$p(u_i) = \sum_{k=1}^2 \pi_k \mathcal{N}(u_i | \mu_k, \Sigma_k), \quad (4)$$

pričom tento krok sa chápe výlučne ako robustnostný skríning, nie ako vecná segmentácia. Za kandidáta na odľahlý/šumový komponent sa považuje ten komponent, ktorý má menšiu váhu v zmesi π_k a zároveň mu zodpovedá systematicky nižšia modelom odhadovaná hustota – prakticky napríklad nižšia typická log-pravdepodobnosť pozorovaní podľa odhadnutého zmesového modelu. Ako šumový sa tento komponent akceptuje len vtedy, keď je zreteľne minoritný a zároveň oddelený hustotou; ak takáto separácia nie je presvedčivá, samostatný odľahlý komponent sa nepredpokladá.

Jednotlivé pozorovania sa následne označia ako atypické vtedy, keď je ich najvyššie posteriórne členstvo práve v šumovom komponente, prípadne keď posteriórna pravdepodobnosť tohto komponentu prekročí konzervatívny prah. Výsledkom sú dve analytické množiny: FULL, ktorá obsahuje všetky prípady vstupujúce do Fázy 2, a CLEAN, ktorá vylučuje iba prípady označené pravidlom odľahlosti/šumu; ak podmienky pre dôveryhodný šumový komponent nie sú splnené, platí CLEAN = FULL.

Hlavná segmentácia

Segmentácia sa realizuje na množine CLEAN pomocou GMM odhadnutých algoritmom EM (Expectation–Maximization). Pre kandidátny počet klastrov K je model definovaný v (5):

$$p(u_i) = \sum_{k=1}^K \pi_k \mathcal{N}(u_i | \mu_k, \Sigma_k) \quad (5)$$

Počet klastrov K sa určuje viac-kriteriálnym postupom (Scrucca et al., 2016), (Baudry, 2015). Najprv sa hodnotí stabilita pri prevzorkovaní: model sa opakovane preodhadne na resamplovaných dátach a zhoda medzi riešeniami sa kvantifikuje pomocou Adjusted Rand Index (ARI), pričom sa uprednostnia tie hodnoty K , ktoré vedú k konzistentne reprodukovateľným partíciám. Súčasne sa sleduje zhoda modelu s dátami a penalizácia zložitosti pomocou informačných kritérií (napr. BIC; voliteľne aj ICL), aby sa predišlo voľbe zbytočne komplexných riešení bez jasného dôkazu pre dodatočné komponenty. Ďalej sa kontroluje separácia priradení cez správanie posteriórnych členstiev, napríklad podiel nízkych maximálnych posteriórnych pravdepodobností, ktorý signalizuje výrazné prekryvy medzi klastrami. Napokon sa uplatní princíp parsimónie a interpretovateľnosti: preferuje sa najmenšie K , ktoré pri uvedených kontrolách zároveň poskytuje stabilné, primerane oddelené a vecne interpretovateľné klastre.

Neistota priradenia a CORE/BOUNDARY

Nech $\{u_i\}_{i=1}^N$ označuje pozorovania v spoločnom priestore a nech je odhadnutý K komponentový GMM. „Mäkké“ členstvo sa potom prirodzene vyjadruje posteriórnymi pravdepodobnosťami v (6):

$$\gamma_{ik} = P(z_i = k | u_i) = \frac{\pi_k \mathcal{N}(u_i | \mu_k, \Sigma_k)}{\sum_{j=1}^K \pi_j \mathcal{N}(u_i | \mu_j, \Sigma_j)} \quad (6)$$

Pre každého respondenta tvorí $(\gamma_{i1}, \dots, \gamma_{iK})$ vektor pravdepodobností členstva (súčet je 1). Tvrdý label sa následne definuje ako maximum-a-posteriori (MAP) priradenie, t. j. výber komponentu s najvyššou hodnotou γ_{ik}

$$\hat{k}_i = \arg \max_k \gamma_{ik} \quad (7)$$

Hodnota $\max_k \gamma_{ik}$ zároveň sumarizuje silu podpory pre MAP priradenie a používa sa ako explicitná miera neistoty priradenia v súlade so štandardnou praxou v zmesových modeloch (Scrucca et al., 2016), (Fraley & Raftery, 2002). Hodnoty blízke 1 znamenajú vysokú istotu, kým nižšie hodnoty typicky signalizujú prekryv komponentov a teda nejednoznačné priradenie.

Aby sa odlíšili prípady s vysokou istotou od prípadov z oblasti prekryvu, respondenti sa rozdelia na CORE a BOUNDARY podľa vopred zvoleného posteriórneho prahu τ :

- prípad patrí do CORE, ak $\max_k \gamma_{ik} \geq \tau$
- prípad patrí do BOUNDARY, ak $\max_k \gamma_{ik} < \tau$

Toto rozlíšenie slúži výlučne na reportovanie s vedomím neistoty a nemení samotný fit segmentačného modelu. Prah τ pritom operacionalizuje kompromis medzi pokrytím a istotou: vyššie τ znižuje CORE, ale zvyšuje spoľahlivosť priradení; nižšie τ ponechá viac prípadov za cenu väčšieho podielu hraničných priradení. Primárna hodnota τ sa stanoví a priori (napr. $\tau = 0,75$) a citlivosť sa overí na blízkych hodnotách (napr. $\tau \in \{0.70, 0.80\}$), aby sa potvrdilo, že vecné závery neriadia hraničné prípady a že CORE zostáva dostatočne reprezentované celkovo aj v rámci jednotlivých segmentov. Preto sa profily klastrov a následné porovnania reportujú paralelne pre FULL MAP priradenia aj pre CORE podmnožinu definovanú τ , pričom BOUNDARY tvorí explicitne priznané pásmo neistoty.

Profilovanie osoby (interpretácia segmentov)

Fáza 2 sa uzatvára profilovaním person, ktorého cieľom je zhrnúť segmenty podľa ich typickej polohy v profilovacom priestore a zároveň ich prepojiť späť na pôvodné stavebné bloky, z ktorých bol tento priestor zostavený. Profilovanie sa opiera najmä o premenné vstupujúce do segmentácie a pre každý segment reportuje charakteristické hodnoty a rozptyl (napr. priemery/mediány a mieru variability).

Aby opis osoby nebol významne ovplyvňovaný prípadmi z oblasti prekryvu, profilovanie sa uvádza paralelne pre FULL MAP priradenia aj pre CORE podmnožinu definovanú vopred zvoleným prahom τ , pričom BOUNDARY prípady sa z CORE-súhrnov vylučujú. Miera zhody medzi FULL a CORE profilmi sa následne interpretuje ako indícia, že interpretácia osoby je robustná voči nejednoznačnosti priradenia.

Fáza 3: Posúdenie stability a reprodukovateľnosti

Stabilita sa hodnotí cez reprodukovateľnosť pri prevzorkovaní: zvolená segmentácia sa považuje za stabilnejšiu vtedy, keď sa po malých, kontrolovaných zmenách vzorky opakovane obnovia podobné segmenty. Táto fáza preto reportuje mieru reprodukovateľnosti pri resamplingu a zároveň skúma, ako konzistentnosť naprieč resamplami súvisí s rozlíšením CORE/BOUNDARY z Fázy 2.

Postup prevzorkovania

Pri prevzorkovaní sa používa mapovanie z Fázy 1 a fixná špecifikácia modelu zvolená vo Fáze 2. Následne sa vygenerujú opakované resamplované vzorky (napr. bootstrapom) a celý postup sa

zopakuje vopred určený počet ráz. Pre každý resample sa segmentačný model znovu odhadne pri nezmenenej špecifikácii z Fázy 2 a získajú sa MAP priradenia spolu s posteriornými pravdepodobnosťami členstva. Ak resample neobsahuje všetkých respondentov, zhoda sa vyhodnocuje len na tých respondentoch, ktorí sú v danom resampli prítomní.

Keďže označenia klastrov sú medzi resamplami permutovateľné, pred výpočtom stabilitných indexov sa klastre z resamplu najprv zosúladiť s referenčným riešením. Zosúladenie sa realizuje explicitným matching pravidlom, ktoré maximalizuje prekryv (overlap) medzi klastrami, aby sa stabilita nezhodnocovala umelo len v dôsledku prehodených labelov.

Zhrnutie a akceptácia stability

Stabilita sa sleduje na troch úrovniach, aby bolo jasné, či je reprodukovateľné celé riešenie, jednotlivé segmenty aj priradenia konkrétnych respondentov:

- **Celková stabilita** (úroveň riešenia) zachytáva zhodu medzi každou resamplovanou partíciou a referenčnou partíciou, typicky pomocou ARI. Namiesto jedného čísla sa stabilita sumarizuje ako rozdelenie hodnôt naprieč resamplami, aby bolo viditeľné kolísanie aj extrémny.
- **Stabilita na úrovni klastrov** pre každý referenčný klaster meria, ako silno sa jeho členstvo prekrýva s najlepšie zladeným klastrom v každom resampli (napr. prekryv/Jaccardova podobnosť). Tento pohľad odlišuje klastre, ktoré sa konzistentne obnovujú, od tých, ktoré majú tendenciu sa štiepiť alebo zlievať.
- **Stabilita na úrovni jednotlivca** pre každého respondenta sa kvantifikuje konzistentnosť priradenia naprieč resamplami (napr. podiel resamplov, v ktorých je priradený k tomu istému klastru ako v referenčnom riešení). Toto skóre sa následne používa na prepojenie stability priradenia s rozlíšením CORE/BOUNDARY.

Pri interpretácii stability sa nepredpokladá žiadny univerzálny prah „dostatočnosti“. Silnejšia opora pre stabilné riešenie sa však typicky prejaví vtedy, keď sú hodnoty ARI naprieč resamplami konzistentne nad nulou (t. j. nad úrovňou náhodnej zhody podľa ARI), keď sa prekryv na úrovni klastrov len zriedkavo rozpadá na štiepenie alebo zlievanie a keď sa nestabilné priradenia sústreďujú najmä do BOUNDARY zóny, namiesto toho, aby narúšali jadro (CORE) jednotlivých klastrov.

Fáza 4: Kontrola prostredníctvom externých kritérií

Kritériovo orientované kontroly skúmajú, či sa získané segmenty líšia v externých kritériách, ktoré boli zámerne nezahrnuté do konštrukcie spoločného priestoru u , do robustnostného skrínungu odľahlostí, do výberu modelu (vrátane stability-orientovanej voľby K) ani do CORE/BOUNDARY reportovania. Toto oddelenie sa udržiava zámerne, aby sa predišlo kruhovitosti: externé kritériá sa používajú výlučne ako post hoc kritériá hodnotenia.

Typy externých kritérií

Externé kritériá sa vyberajú tak, aby zachytávali zmysluplné charakteristiky mimo segmentačného modelu, a typicky zahŕňajú:

- **Behaviorálne ukazovatele**, napr. intenzitu používania a perzistenciu, frekvenciu/recenciu, časové miery (time-spent), proxy premenné progresu či achievementov a štruktúru sedení.
- **Preferenčné indikátory**, napr. voľby obsahu/žánru, preferované módy alebo aktivity a deklarované preferencie.
- **Zapojenie a postojoyé miery** nezahrnuté do klastrovania, napr. sebahodnotené zapojenie, spokojnosť a zámer pokračovať.
- **Kontextové alebo demografické deskripty**, napr. vek, skupina, predchádzajúca skúsenosť, platformový kontext a pod.

Testovanie a reportovanie efektov

Asociácie medzi segmentovým členstvom a externými kritériami sa vyhodnocujú postupmi primeranými škále a rozdeleniu premenných:

- **Kategorické kritériá** používajú kontingenčné metódy (napr. χ^2 test); veľkosť efektu sa reportuje cez Cramerovo V; pri nízkych očakávaných početnostiach sa používajú permutačné p-hodnoty alebo exaktné alternatívy.
- **Spojité/ordinálne kritériá** používajú poradia založené omnibus testy (napr. Kruskal–Wallis); reportuje sa primeraná veľkosť efektu (napr. ϵ^2); post-hoc porovnania sa robia až po signifikantnom omnibus teste.
- **Viacnásobné testovanie** – pri väčšom počte externých kritérií sa multiplicita rieši cez FDR (napr. Benjamini–Hochberg) pričom dôraz sa kladie na veľkosti efektov a neistotu, nie len na signifikanciu.

Robustnosť voči neistote priradenia sa zvyšuje tým, že kritériové analýzy sa uvádzajú paralelne pre celú vzorku s MAP priradením (FULL) aj pre podmnožinu CORE definovanú posteriorným pravidlom istoty. Konzistentné závery naprieč FULL a CORE sa interpretujú ako silnejší dôkaz, že rozdiely v externých kritériách odrážajú segmentovú štruktúru, a nie nejednoznačnosť priradenia.

Prípadová štúdia: Integrácia motivácie a imerzívnosti

Táto časť aplikuje stabilítne orientovaný prístup v dvojblokovej prípadovej štúdii profilovania a postupne prezentuje výstupy jednotlivých fáz, pričom dôraz kladie na reprodukovateľnosť a neistotu priradenia, nie na psychometrickú validáciu použitých nástrojov. Anonymizovaný dataset, kódová kniha a použité dotazníkové nástroje sú archivované na Figshare (Jan Skalka & Valko, 2025).

Prehľad relevantných zdrojov

Herné profilovanie sa postupne posúva od izolovaných typológií k integračným modelom, ktoré kombinujú viacero pohľadov na hráčske charakteristiky. V literatúre sa opakovane objavuje tvrdenie, že takéto integračné prístupy môžu v niektorých nastaveniach lepšie zachytávať a predikovať dizajnové relevantné preferencie než riešenia postavené na jedinom frameworku, hoci prínos závisí od konkrétnej reprezentácie a spôsobu integrácie (Högberg et al., 2019), (Lomba Perez et al., 2025), (Fiş Erümit et al., 2021), (Sienel et al., 2021).

V hrách a gamifikovaných systémoch sa motivačná orientácia – teda prečo používatelia hrajú – bežne operacionalizuje pomocou inventárov motívov alebo rámcov inšpirovaných typológiami. Popri klasických typológiách (napr. Bartle (Bartle, 1996), Yee (Yee, 2006b), Hexad (Diamond et al., 2015), BrainHex (Nacke et al., 2014)), a v novej literatúre ďalej rozvíjajú a validujú aj širšie, dotazníkovo definované miery motívov (napr. *Motivation to play scale* (Holl et al., 2024), *Motives of Autonomous Players* (Vahlo & Tuuri, 2025), *Videogaming Motives Questionnaire* a komplexnejšie, žánrovo neutrálne inventáre (napr. *Gaming motivation inventory* (Király et al., 2022)).

Napriek pretrvávajúcej kritike skorých typológií – najmä pre ich žánrovo špecifický pôvod a ipsatívne obmedzenia núteného výberu – sa typologické výstupy v praxi často interpretujú ako kontinuálne tendencie vhodné pre profilovanie, nie ako striktne vzájomne sa vylučujúce kategórie (Kirchner-Krath et al., 2024). Bartleho taxonómia (Bartle, 1996) zostáva vplyvná najmä preto, že sa dá priamo mapovať na herne orientované dizajnové vzory (napr. cykly zvládnutia, objavovanie, sociálne rituály, adverzárne mechaniky) (Guimarães et al., 2025). Zároveň sú však jej limity dobre zdokumentované – od žánrových východísk a obmedzenej empirickej validácie až po kategorickú rigiditu a skreslenia vynúteného výberu, ktoré môžu prekryvať hybridné profily (Hamari & Tuunanen, 2014), (Dixon, 2011), (Nacke et

al., 2014). Aj preto sa Bartleho štýl v profilovaní často používa skôr ako kontinuálne skórovanie tendencií než ako typológia v silnom zmysle, čím sa časť týchto obmedzení zmierňuje (Kirchner-Krath et al., 2024).

Konštrukty súvisiace s imerziou opisujú, do akej miery sa používatelia po zapojení do hry „pohlť“, čo následne formuje kvalitu zážitku v interaktívnych a virtuálnych prostrediach (Colombo et al., 2023), (Dombrovskis et al., 2025). Nižšia miera imerzie sa pritom typicky spája so slabším zapojením a menej pozitívnym hodnotením skúsenosti (Brockmyer et al., 2009), (Guerra-Tamez, 2023), (Nah et al., 2022). Dotazník o imerzívnych tendenciách (ITQ) zostáva jedným z najpoužívanejších meradiel dispozičnej (trait-like) náchylnosti k imerzii, hoci štúdie uvádzajú viacero faktorových štruktúr – napríklad *Involvement / Attentional Focus / Gaming; Emotional Involvement / Absorption; Focus / Engagement* (Witmer & Singer, 1998), (Rózsa et al., 2022).

Porovnávacie syntézy naznačujú, že mnohé rámce hráčov a používateľov sa napriek odlišným označeniam opakovane zbiehajú v malej sade podobných dimenzií (napr. socializácia; úspech / odmena; ponorenie / únik / objavovanie; autonómia / nezávislosť) (Kirchner-Krath et al., 2024), (Hamari & Tuunanen, 2014). Toto prekrývanie je pre viacblokové profilovanie podstatné, pretože ponorenie sa v literatúre objavuje jednak ako motív (čo používatelia vyhľadávajú), jednak ako zážitková alebo dispozičná tendencia (ako používatelia reagujú po hraní), pričom ortogonalita medzi motiváciou a ponorením sa spravidla nemá automaticky predpokladať (Ryan et al., 2006), (Brockmyer et al., 2009), (Högberg et al., 2019). Pri kombinovaní blokov motivácie a ponorenia sa preto otázky redundancie a interpretácie najspoľahlivejšie riešia empiricky, nie a priori (Yee, 2006a), (Tondello et al., 2016). To následne motivuje profilovanie v spojenom priestore, ktoré integruje oba bloky a explicitne testuje, či každý z nich prináša komplementárnu (neredundantnú) informáciu relevantnú pre konštrukciu osoby.

Prípadová štúdia kombinuje Bartleho inventár s vynúteným výberom, ktorý zachytáva motivačnú orientáciu a poskytuje proporčné skóre pre dimenzie *Achiever*, *Explorer*, *Socializer* a *Killer* (Bartle, 1996) a *Dotazník imerzívnych tendencií* (ITQ), ktorý sa realizuje na Likertovej škále a v analýze sa reprezentuje empiricky určenou faktorovou štruktúrou (Witmer & Singer, 1998). Táto dvojica vstupov je typická pre viacblokové profilovanie: spája kompozičný blok z vynúteného výberu s faktorovo reprezentovaným Likertovým blokom, a preto umožňuje názorne ukázať prínos jednotlivých krokov navrhovanej metodiky.


Účastníci a nástroje

Cieľovú populáciu tvorili osoby so záujmom o interaktívne digitálne technológie, konkrétne študenti IT a pedagógovia v IT, keďže ide o skupiny priamo relevantné pre gamifikáciu, serious games a virtuálne prostredia. Nábor prebiehal počas univerzitných kurzov a na workshopoch zameraných na vývoj hier a VR. Pred zapojením boli respondenti oboznámení s priebehom štúdie, vrátane anonymizácie dát a práva kedykoľvek odstúpiť bez sankcie. Aby sa znížila únava a možný prenos medzi nástrojmi, dotazníky sa spravidla administrovali v oddelených sedeniach s odstupom približne jedného týždňa. Ak sa oba nástroje vyplňovali v rámci jedného workshopu, administrácia bola preložená nesúvisiacimi praktickými aktivitami, ktoré poskytli kognitívne prestávky a znížili riziko skreslenia odpovedí.

Účastníci

Východisková vzorka predstavovala N = 190 respondentov. Počas zberu päť respondentov odvolalo súhlas a ich záznamy boli pred analýzou odstránené. Po ďalších vylúčeníach (10 účastníkov) z dôvodu neúplných odpovedí a/alebo nesúhlasu s vedeckým použitím dát tvorila finálna analytická vzorka N =

175 respondentov. Demografické a behaviorálne deskriptory (vek, pohlavie, týždenný herný čas a žánrové preferencie) sa zbierali v samostatnej časti dotazníka a boli vyhradené ako externé kritériá pre post hoc kritériovo orientované porovnania (Fáza 4). Charakteristiky účastníkov sumarizuje Tabuľka 1 a vizualizuje Obr. 27.



Obr. 27 Štruktúra účastníkov (čas hrania, vek, pohlavie). Veľkosť každého dátového bodu odráža počet respondentov, ktorí zdieľajú rovnakú kombináciu parametrov.

Tab. 36 Charakteristiky participantov

Premenná	Popis
Veľkosť vzorky	N = 175
Vek (roky)	Mean $\pm$ SD: 26.0 $\pm$ 8.1; Median [IQR]: 23 [21–26]; Min–Max: 18–54
Pohlavie	mužské: 138 (78.9%); ženské: 37 (21.1%)
Týždenný hrací čas (hodín / týždenne)	Mean $\pm$ SD: 15.8 $\pm$ 17.3; Median [IQR]: 12.0 [3.5–20.0]; Min–Max: 0–100

Týždenný čas hrania bol skreslený doprava (väčšina účastníkov uviedla < 20 h/týždeň) a vek bol sústredený na rannú dospelosť (Tab. 36).

Nástroje

Dáta pre túto štúdiu pozostávali z troch hlavných častí zbieraných prostredníctvom zloženého online dotazníka administrovaného v systéme Moodle (LMS):

- **Demografia a herné návyky** pokrývali vek, pohlavie, týždenný čas hrania (celkovo aj mimo mobilných hier), preferované žánre a orientáciu na singleplayer vs. multiplayer.
- **Motivačná orientácia** bola operacionalizovaná 30-položkovým inventárom s vynúteným výberom vychádzajúcim z Bartleho taxonómie, použitým vo forme Andreassen and Downey Bartle Test (Bartle, 1996), (Park et al., 2021) (znenia položiek použité v tejto štúdii sú archivované v materiáloch na Figshare (Jan Skalka & Valko, 2025)). Hoci tieto položky dlhodobo kolujú online a sú široko používané (napr. cez GamerDNA), pre tento konkrétny set otázok nebola identifikovaná úspešná psychometrická validácia (Hamutoğlu et al., 2020). Tento fakt je v súlade s kritikou, že dichotomické Bartle testy s vynúteným výberom môžu skôr posilňovať

hypotetickú typológiu než poskytovať empirickú validáciu (Yee, 2016). Nástroj v tejto práci preto slúži primárne ako reprezentatívny príklad populárneho inštrumentu, ktorý sa v prácach o hrách a gamifikácii stále často objavuje a napriek dlhodobej kritike ostáva súčasťou zdieľaného dizajnového slovníka (Park et al., 2021).

- **Dispozičná imerzia** sa merala 18-položkovým *Immersive Tendencies Questionnaire* (Witmer & Singer, 1998) na 7-bodovej Likertovej škále. Faktorová štruktúra nástroja aj finálne škály použité v analýze boli určené empiricky pomocou exploračnej faktorovej analýzy.

Príprava vstupov

Kontroly merania sa realizovali v rámci každého meracieho bloku. Každá premenná sa overila voči špecifikácii merania (povolené kategórie alebo rozsahy odpovedí, smer kódovania a nemožné hodnoty). Hodnoty mimo špecifikácie by sa nastavili ako chýbajúce; v tomto datasete sa však nevyskytli a zároveň sa nepoužívali žiadne reverzne kódované položky. Chýbajúce hodnoty sa kontrolovali na úrovni premenných aj respondentov. Rovnako všetky odpovede v Bartleho bloku s vynúteným výberom (B1–B30) spadali do povolených kategórií {A, E, K, S} a v Bartleho bloku sa nepozorovali ani hodnoty mimo špecifikácie, ani chýbajúce odpovede. Rovnako všetky odpovede v ITQ bloku (ITQ1–ITQ18) boli v zamýšľanom Likertovom rozsahu 1–7, bez hodnôt mimo rozsah a bez missingness. Ani deskriptory (vek, pohlavie a týždenný herný čas) neobsahovali hodnoty mimo špecifikácie; jedna preferenčná premenná (*loved_type*) však obsahovala chýbajúce záznamy a bola preto ponechaná ako missing pri kritériovej analýze.

Blokovo špecifické mapovanie

Blokovo špecifické mapovanie previedlo oba dotazníkové bloky na súradnice vhodné pre profilovanie v spoločnom priestore.

V Bartleho bloku sa 30 položiek s vynúteným výberom (B1–B30), kódovaných ako {A, S, E, K}, najprv agregovalo do počtov odpovedí pre Achiever (A), Socializer (S), Explorer (E) a Killer (K). Pre každého respondenta i tak vznikol vektor počtov (8):

$$c_i = (c_{iA}, c_{iS}, c_{iE}, c_{iK}) \quad (8)$$

kde c_i vyjadruje počet položiek priradených danej kategórii. Následne sa tieto počty previedli na štvorčastový kompozičný profil (fixed-sum) pomocou uzáveru (9):

$$x_i = (A_i, S_i, E_i, K_i) = \frac{c_i}{\sum_j c_{ij}} \quad (9)$$

pričom platí $A_i + S_i + E_i + K_i = 1$.

V tomto datasete sa u malej časti respondentov vyskytla nulová hodnota (konkrétne $K = 0$ v 5 z 175 prípadov). Nulové podiely sú síce prípustné v proporciách, ale nie sú kompatibilné s logaritmicke-pomerovými transformáciami. Keďže cieľom bolo získať euklidovské súradnice pre klastrovanie, kompozícia sa mapovala do priestoru pomocou izometrických logaritmických pomerov (ILR) (Egozcue et al., 2003). ILR však vyžaduje striktné kladné časti, preto sa pred uzáverom k počtom pridal malý symetrický pseudopočet $\varepsilon = 0,5$:

$$c_i^* = c_i + \varepsilon, x_i^* = \frac{c_i^*}{\sum_j c_{ij}^*} \quad (10)$$


Táto hodnota zodpovedá „pol položke“ v 30-položkovom inventári a zároveň sa vyhýba nadmernému nafúknutiu log-pomerov, ktoré by vznikalo pri príliš malých náhradách. Po renormalizácii tak vznikla striktné kladná kompozícia x_i^* , ktorá sa deterministicky transformovala na tri ILR súradnice (ILR1–ILR3) v pevnom poradí častí (A, S, E, K) pomocou ortonormálnej Helmertovej bázy (11):

$$ILR1_i = \sqrt{\frac{1}{2}} \ln \left(\frac{A_i^*}{S_i^*} \right), ILR2_i = \sqrt{\frac{2}{3}} \ln \left(\frac{\sqrt{A_i^* S_i^*}}{E_i^*} \right), ILR3_i = \sqrt{\frac{3}{4}} \ln \left(\frac{(A_i^* S_i^* E_i^*)^{1/3}}{K_i^*} \right) \quad (11)$$

Súradnice ILR1–ILR3 sa použijú ako vstupy Bartleho bloku pre klastrovanie, zatiaľ čo pôvodné proporcie (A, S, E, K) sa ponechali na deskriptívne reportovanie.

Odpovede v ITQ spĺňali predpoklady pre faktorovú analýzu (KMO = .863; Bartlett's test, $p < .001$). Bol použitý principal axis factoring so šikmou rotáciou Promax ($\kappa = 4$). Za salientné sa považovali záťaže $\geq .40$; krížové záťaže mali byť $\leq .30$ pri súčasnom rozdiely $\Delta \geq .20$.

Paralelná analýza (Obr. 28) odporučila tri faktory. Postup bol realizovaný na Pearsonovej korelačnej matici 18 položiek ITQ ($n = 175$), pričom empirické vlastné čísla sa porovnali s 95. percentilom vlastných čísel z $B = 1\,000$ náhodných datasetov zhodných v n a p . Prvé tri empirické vlastné čísla tento benchmark prekročili, zatiaľ čo štvrtá a ďalšie komponenty už nie. Podľa Hornovho kritéria to zodpovedá $m = 3$ ponechaným faktorom.



Obr. 28 Paralelná analýza (Horn) pre položky ITQ. Modré body = empirické vlastné čísla; oranžové značky = 95. percentil náhodných vlastných čísel ($B = 1\,000$); červená prerušovaná čiara označuje $m = 3$ pomocou PA.

Hoci paralelná analýza naznačila $m = 3$, porovnali sme dvoj- a štvorfaktorové alternatívy, aby sme dosiahli rovnováhu medzi šetrnosťou a kvalitou merania.

Tab. 37 sumarizuje členstvo položiek v konkurenčných modeloch a konečný stav skóre. V zachovanej dvojfaktorovej špecifikácii boli vylúčené nasledujúce položky: ITQ3, ITQ7, ITQ9 a ITQ12 (buď nevýrazné, alebo zaťažené slabými faktormi v riešeníach 3F/4F).

Tab. 37 Identifikované faktory ponorenia v 2-4 faktorových modeloch a ich vnútorná konzistencia (Cronbachova alfa).

Položka	2-factor	3-factor	4-factor	Final status
ITQ1	✓	✓	✓	Alm
ITQ2	✓	✓	✓	Alm
ITQ3	—	✓ (F3 weak)	✓ (F3 weak)	vylúčiť
ITQ4	✓	✓	✓	Alm
ITQ5	✓	✓	✓	Alm

Položka	2-factor	3-factor	4-factor	Final status
ITQ6	✓	✓	✓	Alm
ITQ7	—	✓ (F3 weak)	✓ (F3 weak)	vylúčiť
ITQ8	✓	✓ (F3 weak)	✓ (F3 weak)	Alm
ITQ9	—	—	—	vylúčiť
ITQ10	✓	✓	✓	Alm
ITQ11	✓	✓	✓	Alm
ITQ12	—	—	✓ (F4 weak)	vylúčiť
ITQ13	✓	✓ (F3 weak)	✓ (F3 weak)	Alm
ITQ14	✓	—	—	Alm
ITQ15	✓	✓	✓	EmR
ITQ16	✓	✓	✓	EmR
ITQ17	✓	✓	✓	EmR
ITQ18	✓	✓	✓ (F4 weak)	Alm

Tab. 38 uvádza zloženie faktorov a indexy internej konzistencie pre riešenia s 2, 3 a 4 faktormi. Trojfaktorové riešenie viedlo k dvom koherentným faktorom, no tretí faktor bol z hľadiska reliability slabý ($\alpha = .575$). Štvorfaktorové riešenie zachovalo tie isté dva koherentné faktory, avšak pridalo ďalšie dva slabé faktory ($\alpha = .575$ a $.567$), čo je v súlade s pre-faktorovaním.

Table 38. Identifikované faktory ponorenia v 2-4 faktorových modeloch a ich vnútorná konzistencia (Cronbachova alfa).

Model	Factors	Položky	Cronbach alpha	McDonald ω	Label
2-factor	Factor 1	ITQ1, ITQ2, ITQ4, ITQ5, ITQ6, ITQ8, ITQ10, ITQ11, ITQ13, ITQ14, ITQ18	0.851	0.860	Absorptive immersion
	Factor 2	ITQ15, ITQ16, ITQ17	0.750	0.756	Emotional reactivity
3-factor	Factor 1	ITQ1, ITQ2, ITQ4, ITQ5, ITQ6, ITQ10, ITQ11, ITQ18	0.871	0.873	Absorptive immersion
	Factor 2	ITQ15, ITQ16, ITQ17	0.750	0.756	Emotional reactivity
	Factor 3	ITQ3, ITQ7, ITQ8, ITQ13	0.575	0.583	Weak
4-factor	Factor 1	ITQ1, ITQ2, ITQ4, ITQ5, ITQ6, ITQ10, ITQ11	0.859	0.862	Absorptive immersion
	Factor 2	ITQ15, ITQ16, ITQ17	0.750	0.756	Emotional reactivity
	Factor 3	ITQ3, ITQ7, ITQ8, ITQ13	0.575	0.583	Weak
	Factor 4	ITQ12, ITQ18	0.567	0.575	Weak

V analýze sa ponechal dvojfaktorový model; tretí a štvrtý faktor v alternatívnych riešeniach vykazovali nízku reliabilitu ($\alpha \leq .58$), čo naznačuje pre-faktorovanie.

Prvý faktor dosiahol výbornú reliabilitu ($\alpha = 0.851$, $\omega = 0.860$) a zachytáva hlboké ponorenie do médií a hier spojené so zníženým uvedomovaním si okolitého diania a plynutia času (položky 1, 2, 4, 6, 10, 18), čo je v súlade s konceptmi absorpcie a flow (Weibel & Wissmath, 2011), (Csikszentmihalyi, 2012). Súčasne odráža identifikáciu s postavami a „transport“ do naratívu (položka 5) (Van Laer et al., 2014), (Cohen, 2018), schopnosť blokovať vonkajšie rušivé podnety a udržať pozornosť počas pútavých aktivít (položky 8, 13) (Wirth et al., 2007), (Cummings & Bailenson, 2016), aj post-zážitkové snové stavy (položka 11) (Rózsa et al., 2022), ktoré naznačujú imaginatívnu absorpciu. Na základe tejto štruktúry ho označujeme ako *Absorpčná imerzia (Alm)*.

Druhý faktor mal akceptovateľnú reliabilitu ($\alpha = 0.75$, $\omega = 0.75$). V dvoj-, troj- aj štvorfaktorových riešeniach sa položky ITQ15–ITQ17 zoskupovali konzistentne, čo poukazuje na stabilnú subškálu (Patkar & Seyff, 2023). Tieto položky zachytávajú afektívne reakcie na vzrušenie a strach pri filme/TV vrátane pretrvávajúceho strachu po expozícii. Keďže odpovede kombinujú vysoké vzrušenie s negatívnym afektom, konštrukt označujeme ako *Emočná reaktivita (EmR)*.

V rámci reliability analýzy identifikovaných faktorov sa pre každú škálu realizovala aj item-total analýza, ktorá hodnotila príspevok jednotlivých položiek k internej konzistencii. Pre Faktor 1 (*Absorpčná imerzia*) sa ukázalo, že položka ITQ14 len slabo korelovala s ostatnými položkami škály; jej odstránenie zvýšilo Cronbachovo alfa z 0.851 na 0.863.

Skríning informatívnosti

Prediktory s takmer nulovou varianciou sa skrínovali na mapovaných euklidovských vstupoch určených pre segmentáciu (ILR1–ILR3 z Bartleho kompozície; ITQ faktorové skóre *Alm* a *EmR*). Žiadna premenná nebola označená ako neinformatívna (rozsah SD 0.33–1.24), preto sa neuplatnili žiadne vylúčenia na základe NZV.

Skríning redundancie sa uplatnil v rámci blokov (ILR blok; ITQ blok), aby sa štandardne neodstraňovali potenciálne zmysluplné asociácie medzi blokmi. V tejto prípadovej štúdii boli korelácie v rámci blokov výrazne pod stanoveným prahom (maximum $|r| = 0.273$ v ILR bloku; 0.360 v ITQ bloku), takže sa nevykonali žiadne odstránenia na základe redundancie. Podrobnosti uvádzajú Tab. 39 a Tab. 40.

Tab. 39 Korelácie v rámci bloku (Pearsonov r) - blok ILR (Bartle v priestore ILR).

	ILR1	ILR2	ILR3
ILR1	1.000	0.025	-0.249
ILR2	0.025	1.000	-0.273
ILR3	-0.249	-0.273	1.000

Tab. 40 Korelácie v rámci bloku (Pearsonov r) - blok ITQ (faktorové skóre).

	Factor1	Factor2
Factor1	1.000	0.360
Factor2	0.360	1.000

Ako sekundárna diagnostika sa vypočítali aj faktory nafúknutia variability (VIF; Tab. 41), ktoré naznačili len minimálne prekrytie medzi všetkými mapovanými vstupmi (rozsah VIF 1.07–1.17).

Tab. 41 Diagnostika VIF (všetky mapované vstupy spoločne).

Predictor	VIF
ILR1	1.074
ILR2	1.084
ILR3	1.166
Factor1	1.171
Factor2	1.160

Prediktory s takmer nulovou varianciou sa skrínovali na mapovaných euklidovských vstupoch určených pre segmentáciu (ILR1–ILR3 z Bartleho kompozície; ITQ faktorové skóre *Alm* a *EmR*). Žiadna premenná nebola označená ako neinformatívna (rozsah SD 0.33–1.24), preto sa neuplatnili žiadne vylúčenia na základe NZV. Skríning redundancie v rámci blokov (ILR; ITQ) rovnako nevedol k odstráneniam, keďže korelácie zostali pod prahom (max $|r| = 0.273$ pre ILR; 0.360 pre ITQ); VIF ako doplnková diagnostika potvrdil minimálne prekrytie (1.07–1.17).

Štandardizácia

Zošíkmenie sa vyhodnotilo pre nekompozičné spojité vstupy ešte pred štandardizáciou. V tejto prípadovej štúdii sa to týkalo dvoch faktorových súradníc odvodených z ITQ (Factor1, Factor2). Rozdelenia sa skrínovali pomocou vopred stanovených prahov pre výraznú odchýlku od normality (absolútna šikmosť >2 a absolútna nadbytočná špicatosť >7). Obe faktorové dimenzie boli výrazne pod

týmito prahmi (Factor1: skew = 0.047, excess kurtosis = -0.333; Factor2: skew = 0.288, excess kurtosis = -0.353; n = 175 pre obe), preto sa neaplikovali žiadne transformácie a vstupy sa do ďalšieho predspracovania preniesli bez zmeny.

Po blokovom mapovaní sa všetky dimenzie spoločného priestoru štandardizovali na nulový priemer a jednotkovú varianciu (z-štandardizácia) na analytickej množine (n = 175). Následne sa zostavil spoločný profilovací vektor ako zreťazenie štandardizovaných súradníc s váhami na úrovni blokov (12):

$$u = [w_1 z^{(1)} \parallel \dots \parallel w_B z^{(B)}], \quad w_b = \frac{1}{\sqrt{p_b}} \quad (12)$$

kde p_b je počet ponechaných dimenzií v bloku b. Toto váženie po štandardizácii vyrovnáva celkový príspevok blokov, keďže platí (13)

$$\sum_{j \in b} \text{Var}(w_b z_j) = p_b w_b^2 = 1 \quad (13)$$

V tejto prípadovej štúdii spoločný priestor tvorili dva bloky:

- Bartleho kompozícia reprezentovaná tromi ILR súradnicami ($p_{\text{ILR}} = 3$).
- ITQ blok reprezentovaný dvomi faktorovými súradnicami ($p_{\text{ITQ}} = 2$).

Tomu zodpovedali váhy: $w_{\text{ILR}} = 1 / \sqrt{3} = 0.577$ a $w_{\text{ITQ}} = 1 / \sqrt{2} = 0.707$.

Robustná segmenácia

GMM sú vhodnou voľbou, pretože Fáza 1 vytvára spojitý euklidovský profilovací priestor u , v ktorom gaussovské zmesi poskytujú interpretovateľnú pravdepodobnostnú reprezentáciu heterogénnych subpopulácií a zároveň vracajú posteriórne pravdepodobnosti členstva, ktoré priamo kvantifikujú neistotu priradenia.

Ošetrovanie odľahlých prípadov

Dvojkomponentový GMM sa použil ako konzervatívna brána na detekciu malého, izolovaného komponentu, ktorý by mohol vierohodne reprezentovať atypickú alebo šumovú štruktúru. Odhadnutý model však nevytvoril zreteľne minoritný komponent (menšia váha komponentu bola $\pi = 0.455$), čo naznačuje, že dáta v rámci tejto brány neobsahovali presvedčivú malú skupinu odľahlých prípadov. Preto neboli žiadne pozorovania označené ako atypické a množina CLEAN sa nastavila rovnaká ako FULL (n = 175).

Hlavná segmentácia

Diagnostiky výberu modelu (Tab. 42) pokrývali tri komplementárne aspekty: zhodu modelu s dátami a penalizáciu zložitosti cez BIC, stabilitu pri prevzorkovaní cez bootstrapový ARI ($B = 200$), a separáciu priradení vyjadrenú podielom hraničných priradení $\Pr(\max_k \gamma_{ik} < 0.75)$.

Tab. 42 Diagnostika výberu modelu pomocou K (diagonálno-kovariančná GMM; n = 175; bootstrap B = 200).

K	BIC	$\Delta \text{BIC (vs K = 2)}$	ARI _{mean}	ARI _{median}	Pr ($\max_k \gamma_{ik} < 0.75$)
2	1704.05	0.00	0.321	0.195	0.280
3	1708.15	4.09	0.431	0.413	0.200
4	1730.85	26.80	0.391	0.384	0.223
5	1762.63	58.58	0.339	0.306	0.217
6	1778.13	74.08	0.281	0.266	0.251

BIC preferoval parsimónne riešenie s K = 2, pričom K = 3 zostalo z hľadiska fitu stále blízko ($\Delta \text{BIC} = 4.09$). Zároveň však K = 3 prinieslo reprodukovateľnejšie partície pri resamplingu (ARI_{mean} = 0.431, ARI_{median} = 0.413) než K = 2 (ARI_{mean} = 0.321; ARI_{median} = 0.195) a znížilo podiel hraničných priradení (0.200 vs 0.280).

Zvyšovanie K nad 3 už neprineslo lepšiu rovnováhu medzi fitom, stabilitou a separáciou. Z tohto dôvodu sa zvolilo K = 3 ako najmenšie riešenie s porovnateľne stabilnými a zároveň lepšie oddelenými priradeniami.

Neistota priradenia a CORE/BOUNDARY

Pre zvolené riešenie K = 3 (GMM s diagonálnou kovarianciou) odhadnuté v spoločnom profilovacom priestore u ($n = 175$) sa pre každého respondenta vypočítali posteriórne pravdepodobnosti členstva γ_{ik} . Tým vznikol vektor $(\gamma_{i1}, \gamma_{i2}, \gamma_{i3})$, ktorého súčet je 1. Tvrdé priradenie sa definovalo ako maximum-a-posteriori (MAP) výber $k_i = \arg \max_k \gamma_{ik}$, pričom neistota priradenia sa sumarizovala hodnotou $\max_k \gamma_{ik}$. Celkovo boli priradenia pomerne isté (priemer $\max \gamma = 0.867$; median = 0.924)., no istota sa líšila medzi segmentmi: segment 0 vykazoval najsilnejšiu separáciu (priemer = 0.900; medián = 0.960; $P_{10} = 0.710$), zatiaľ čo segmenty 1 a 2 mali výraznejší prekryv (segment 1: priemer = 0.849, medián = 0.902, $P_{10} = 0.598$; segment 2: priemer = 0.827, medián = 0.886, $P_{10} = 0.517$).

Aby boli opisy person robustné voči oblasti prekryvu, prípady sa rozdelili na CORE a BOUNDARY podľa vopred určeného prahu τ , kde CORE je definované pre $\max_k \gamma_{ik} \geq \tau$. Pri primárnom nastavení $\tau = 0.75$, bolo ako CORE klasifikovaných 140 z 175 respondentov (0.80). Citlivostná analýza (Tab. 43) ukazuje očakávaný kompromis medzi pokrytím a istotou: pri bežných hodnotách prahu okolo $\tau = 0.75$ ostáva CORE veľká časť vzorky (0.743–0.829 pre $\tau \in \{0.70, 0.75, 0.80\}$), zatiaľ čo prísnejšie nastavenie $\tau = 0.90$ znižuje CORE na 0.537.

Tab. 43 Podiel CORE podľa prahu τ (celkovo a podľa segmentu; K = 3, n = 175).


τ	CORE celkovo (n/N)	CORE podiel celkovo	Cluster 0	Cluster 1	Cluster 2
			CORE podiel (n = 79)	CORE podiel (n = 56)	CORE podiel (n = 40)
0.70	145/175	0.829	0.899	0.768	0.775
0.75	140/175	0.800	0.861	0.732	0.775
0.80	130/175	0.743	0.797	0.696	0.700
0.90	94/175	0.537	0.620	0.500	0.425

Profilovanie osoby (interpretácia segmentov)

Pri zvolenom modeli K = 3 a primárnom prahu $\tau = 0.75$ sa profily person sumarizovali v pôvodných premenných – v proporciách Bartle A/S/E/K a v ITQ faktorových skóre (*Absorpčná imerzia*, *Emočná reaktivita*). Reportovanie sa uvádza paralelne pre FULL (všetky MAP priradenia) aj CORE (Tab. 44). Blízka zhoda medzi FULL a CORE profilmi podporuje interpretáciu, že opisy person nie sú ovplyvňované neistejšími hraničnými priradeniami (Obr. 29).

Tab. 44 Súhrny profilov osôb pre riešenie k = 3 (FULL vs CORE, $\tau = 0.75$).

Cluster	0		1		2	
	FULL	CORE ($\tau = 0.75$)	FULL	CORE ($\tau = 0.75$)	FULL	CORE ($\tau = 0.75$)
Set						
n	79	68	56	41	40	31
core_share	0.86	0.86	0.73	0.73	0.78	0.78
mean max post	0.90	0.94	0.85	0.94	0.83	0.91
Achiever %	28.3	29.1	27.3	27.9	27.7	27.1
Socializer %	22.0	21.6	26.9	26.8	20.0	20.8
Explorer %	27.2	26.2	37.5	38.9	26.0	26.7
Killer %	22.5	23.1	8.3	6.3	26.3	25.5
Absorpčná imerzia	4.43	4.48	3.86	3.91	3.48	3.23
Emočná reaktivita	4.03	4.07	2.99	3.02	1.73	1.61



Obr. 29 Radarové profily person K = 3 (FULL – podklad; CORE - čiary). Osi zobrazujú priemery klastrov s vnútroblokovým Z-skórovaním vypočítané na základe pôvodných profilovacích premenných (pomery Bartle A/S/E/K a skóre faktora ITQ: Absorpčná imerzia, emocionálna reaktivita). Pre každú personu je ako podklad zobrazený PLNÝ profil (priesvitný vyplnený polygón; priradenia MAP) a CORE profil (čiara; prípady s maximálnym posteriorným $\geq 0,75$, $\tau = 0,75$) je prekrytý rovnakou farbou.

Pre riešenie K = 3 pri $\tau = 0.75$, sa veľkosti segmentov zmenšili z FULL na CORE nasledovne: C₀ 79 → 68 (CORE podiel 0.86), C₁ 56 → 41 (0.73), a C₂ 40 → 31 (0.78). Tomu zodpovedá aj nárast priemernej maximálnej posteriornej pravdepodobnosti v CORE (C₀: 0.900 → 0.942, C₁: 0.849 → 0.937, C₂: 0.827 → 0.914), čo potvrdzuje, že CORE zachytáva priradenia s vyššou istotou.

Identifikácia persón

Na základe CORE profilov boli tri interpretovateľné osoby pomenované podľa ich najviac diskriminačných charakteristík:

- **Hráči s vysokou imerziou** (segment 0) sa vyznačujú najvyššími hodnotami *Absorpčnej imerzie* aj *Emočnej reaktivity* pri zároveň relatívne vyváženom Bartle profile.
- **Explorer–socializer** (segment 1) má dominantnú zložku *Explorer* pri stabilne minimálnom zastúpení *Killer*.
- **Kompetitívny Killer** (segment 2) vykazuje výraznejší *Achiever–Killer* mix a zároveň nižšie ITQ skóre, najmä v dimenzii *Emočnej reaktivity*.

Posúdenie stability a reprodukovateľnosti

Stabilita zvoleného riešenia sa hodnotila ako reprodukovateľnosť pri prevzorkovaní pre fixnú špecifikáciu z Fázy 2 (GMM s diagonálnou kovarianciou, K = 3) pomocou bootstrapu (B = 200). V každom resampli sa model znovu odhadol pri nezmenenej špecifikácii, získali sa MAP priradenia aj posteriorne pravdepodobnosti a zhoda s referenčnou partíciou sa vyhodnocovala na respondentoch prítomných v danom resampli. Keďže labely klastrov sú medzi resamplami permutovateľné, klastre sa pred výpočtom stabilitných indexov zosúladi s referenčným riešením maximalizáciou prekryvu (Hungarian matching).

Tab. 45 Stabilita pri prevzorkovaní pre zvolené riešenie K = 3 (ARI; diag GMM; n = 175; bootstrap B = 200).

B	ARI_mean	ARI_median	ARI_p10	ARI_p25	ARI_p75	ARI_p90	ARI_min	ARI_max	share_ARI_gt_0
200	0.475252	0.452848	0.224162	0.30807	0.642789	0.79048	-0.01819	0.966789	0.99

Celkovú úroveň riešenia prezentuje Tab. 45, ktorá sumarizuje rozdelenie ARI naprieč všetkými resamplami (priemer, medián, percentily, minimum/maximum a podiel resamplov s ARI > 0). Reprodukovateľnosť bola stredne vysoká: ARI mal priemer 0.475 a medián 0.453, pričom

interkvartilové rozpätie bolo 0.308–0.643 a rozsah siahahal od -0.018 do 0.967. Dôležité je, že 99 % resamplov malo $ARI > 0$, čo znamená zhodu nad úrovňou náhody prakticky vo všetkých prefitovaniach.

Úroveň segmentov prezentuje Tab. 46, ktorá ukazuje, ako dobre sa jednotlivé referenčné segmenty obnovujú v resamploch – cez prekryv s najlepšie zladeným segmentom (Jaccardova podobnosť). Segment 0 sa obnovoval najkonzistentnejšie (medián 0.698), zatiaľ čo segmenty 1 a 2 mali nižší medián (0.573 a 0.506). Zároveň percentily naznačujú, že slabšie obnovy sa koncentrujú najmä v spodnej časti rozdelenia (napr. P_{10} je 0.155 pre segment 1 a 0.000 pre segment 2), čo je typický signál štiepenia/zlievania v časti resamplov.

Tab. 46 Obnoviteľnosť segmentov pri prevzorkovaní (Jaccardov prekryv s najlepšou zhodou; diag GMM; K = 3; n = 175; bootstrap B = 200).

ref_cluster	jaccard_mean	jaccard_median	jaccard_p10	jaccard_p25	jaccard_p75	jaccard_p90
0	0.669467	0.698263	0.403158	0.563681	0.8	0.900196
1	0.552908	0.573214	0.155	0.391865	0.746011	0.882689
2	0.520126	0.505814	0	0.354505	0.724922	0.885043

Úroveň jednotlivca a väzba na CORE/BOUNDARY je obsiahnutá v Tab. 47, ktorá prepája stabilitu priradenia s neistotou: pre každého respondenta sa vyhodnotil podiel resamplov, v ktorých bol priradený do rovnakého segmentu ako v referenčnom riešení, a tieto hodnoty sa sumarizovali zvlášť pre CORE a BOUNDARY ($\tau = 0.75$), celkovo aj po segmentoch. Rozdiel je výrazný: CORE prípady boli podstatne stabilnejšie (priemer 0.800; medián 0.829) než BOUNDARY prípady (priemer 0.514; medián 0.508). Vnútri segmentov sa tento vzor zopakoval: jadro segmentu 0 bolo najstabilnejšie (CORE priemer 0.880), zatiaľ čo BOUNDARY prípady v segmente 2 boli najnestabilnejšie (priemer 0.354), čo presne zodpovedá tomu, že neistota sa koncentruje na hraniciach a nie v jadre.

Tab. 47 Stabilita na úrovni jednotlivca a jej väzba na CORE/BOUNDARY (konzistentnosť priradenia; $\tau = 0.75$; diag GMM; K = 3; n = 175; bootstrap B = 200).

core_status	ref_cluster	n	stab_mean	stab_median	stab_p10	stab_p25	stab_p75	stab_p90
BOUNDARY	Overall	35	0.513531	0.507937	0.352383	0.366692	0.621097	0.690841
CORE	Overall	140	0.800181	0.829268	0.624751	0.755853	0.888222	0.928329
BOUNDARY	0	11	0.645076	0.603306	0.5	0.584164	0.722215	0.792593
BOUNDARY	1	15	0.512876	0.516129	0.36701	0.406299	0.619444	0.658621
BOUNDARY	2	9	0.353847	0.354839	0.291935	0.343284	0.360294	0.396324
CORE	0	68	0.880453	0.889757	0.805833	0.850295	0.917525	0.946518
CORE	1	41	0.728687	0.756522	0.580645	0.656489	0.820313	0.846774
CORE	2	31	0.718656	0.772059	0.539568	0.650326	0.800763	0.822581

Spolu tieto tri pohľady tvoria konzistentný obraz: celkové riešenie má zhodu nad náhodou takmer vo všetkých resamploch (Tab. 45), segment 0 sa obnovuje najspoľahlivejšie a segmenty 1–2 sú citlivejšie na štiepenie/zlievanie v časti resamplov (Tab. 46) a nestabilita sa do veľkej miery sústreďuje do BOUNDARY zóny, kým CORE jadro segmentov zostáva reprodukovateľné (Tab. 47).

Kontrola prostredníctvom externých kritérií

V súlade s metodikou sa analyzovali externé kritériá, aby sa overilo, či sa odvodené osoby líšia aj v charakteristikách mimo modelu, ktoré neboli použité pri konštrukcii spoločného profilovacieho priestoru. Skúmané kritériá pokrývali behaviorálne charakteristiky (týždenný herný čas celkovo aj

mimo mobilných hier), preferenčné indikátory (preferované žánre a ich popularita, orientácia na singleplayer vs. multiplayer) a kontextové a demografické deskriptory (vek a pohlavie).

Tab. 48 Testy externých kritérií (omnibus; BH-FDR).

Criterion	Type	Effect metric	FULL n	FULL test	FULL effect	FULL p	FULL q (BH)	CORE n	CORE test	CORE effect	CORE p	CORE q (BH)
Age	Cont	ϵ^2	175	H = 9.405	0.043	0.009	0.048	140	H = 8.802	0.050	0.012	0.098
Gender	Cat	Cramér's V	175	$\chi^2 = 11.780$, df = 2	0.259	0.003	0.044	140	$\chi^2 = 12.125$, df = 2	0.294	0.002	0.037
Game_play_hours	Cont	ϵ^2	175	H = 5.910	0.023	0.052	0.139	140	H = 7.302	0.039	0.026	0.106
Game_play_hours_no_mobile	Cont	ϵ^2	175	H = 7.048	0.030	0.029	0.118	140	H = 6.917	0.036	0.032	0.106
Game_play_hours_bin_q4	Cat	Cramér's V	175	$\chi^2 = 11.105$, df = 6	0.178	0.085	0.170	140	$\chi^2 = 11.969$, df = 6	0.207	0.063	0.111
multi_single	Cat	Cramér's V	175	$\chi^2 = 2.806$, df = 2	0.127	0.246	0.393	140	$\chi^2 = 5.984$, df = 2	0.207	0.050	0.107
loved_type	Cat	Cramér's V	161	$\chi^2 = 29.058$, df = 14	0.300	0.007	0.048	128	$\chi^2 = 24.526$, df = 14	0.310	0.033	0.106
play_Action	Cat	Cramér's V	175	$\chi^2 = 3.781$, df = 2	0.147	0.151	0.268	140	$\chi^2 = 5.850$, df = 2	0.204	0.054	0.107
play_Multiplayer	Cat	Cramér's V	175	$\chi^2 = 5.280$, df = 2	0.174	0.071	0.163	140	$\chi^2 = 3.454$, df = 2	0.157	0.178	0.285
play_Puzzle	Cat	Cramér's V	175	$\chi^2 = 6.620$, df = 2	0.194	0.037	0.125	140	$\chi^2 = 6.061$, df = 2	0.208	0.048	0.107
play_RPG	Cat	Cramér's V	175	$\chi^2 = 1.757$, df = 2	0.100	0.415	0.554	140	$\chi^2 = 0.255$, df = 2	0.043	0.880	0.732
play_Simulation	Cat	Cramér's V	175	$\chi^2 = 0.780$, df = 2	0.067	0.677	0.833	140	$\chi^2 = 1.387$, df = 2	0.100	0.499	0.667
play_Sports	Cat	Cramér's V	175	$\chi^2 = 0.475$, df = 2	0.052	0.789	0.901	140	$\chi^2 = 0.003$, df = 2	0.004	0.998	1.000
play_Strategy	Cat	Cramér's V	175	$\chi^2 = 1.757$, df = 2	0.100	0.415	0.554	140	$\chi^2 = 2.187$, df = 2	0.125	0.335	0.487
play_Other	Cat	Cramér's V	175	$\chi^2 = 0.000$, df = 0†	0.000	1.000	1.000	140	$\chi^2 = 0.000$, df = 0†	0.000	1.000	1.000
play_None	Cat	Cramér's V	175	$\chi^2 = 0.000$, df = 0†	0.000	1.000	1.000	140	$\chi^2 = 0.000$, df = 0†	0.000	1.000	1.000

Kategóriové kritériá sa vyhodnocovali pomocou testov asociácie v kontingenčných tabuľkách (χ^2), pričom veľkosť efektu sa reportovala cez Cramerovo V. V situáciách s nízkymi očakávanými početnosťami (napr. premenná *loved_type*) sa použili permutačné p-hodnoty. Spojité alebo ordinálne kritériá sa testovali pomocou Kruskal–Wallisovho testu s reportovaním veľkosti efektu ϵ^2 ; pri veku (signifikantnom vo vzorke FULL) sa následne realizovali post-hoc párové Mann–Whitneyho testy s Holmovo-korekciou na určenie smeru rozdielov. Pri viacnásobnom testovaní naprieč kritériami sa

aplikovala kontrola miery falošných objavov Benjamini–Hochberg (FDR) a vzhľadom na kritériovo špecifickú missingness sa pri každom kritériu uvádzal aj príslušný počet pozorovaní *n* (Tab. 48).

Reportovanie efektov

Externé kritériá sa použili ako post hoc kontrola, či sa tri osoby ($K = 3$) líšia aj v charakteristikách mimo modelu. Tieto premenné neboli použité ani pri konštrukcii spoločného profilovacieho priestoru *u*, ani pri výbere *K*, ani pri definovaní CORE/BOUNDARY, s cieľom predísť kruhovitosti. Výsledky sa reportujú paralelne pre FULL (všetky MAP priradenia; $n = 175$) aj pre CORE ($\tau = 0.75$; $n = 140$), aby sa overila robustnosť voči neistote priradenia. Kategóriové kritériá sa testovali χ^2 asociáciou s reportovaním Cramerovho *V* (pri nízkych očakávaných početnostiach sa použili permutačné *p*-hodnoty, napr. pri *loved_type*), spojité kritériá sa vyhodnocovali Kruskal–Wallisovým testom s efektom ϵ^2 a multiplicita sa kontrolovala Benjamini–Hochberg FDR osobitne v každej vzorke (FULL, CORE).

Tab. 48 sumarizuje omnibus testy pre všetky externé kritériá (typ kritéria, metrika efektu, testová štatistika, *p* a FDR-korigované *q* zvlášť pre FULL a CORE). Najrobustnejšia asociácia bola *pohlavie*, ktoré zostalo signifikantné aj po FDR v oboch analýzach (FULL: $V = 0.259$, $q = 0.044$; CORE: $V = 0.294$, $q = 0.037$). *Vek* vykázal v FULL mierny rozdiel medzi osobami ($\epsilon^2 = 0.043$, $q = 0.048$), pričom v CORE sa zachoval rovnaký smer efektu ($\epsilon^2 = 0.050$), ale po zmenšení vzorky už neprešiel FDR ($q = 0.098$). Ostatné behaviorálne ukazovatele intenzity hrania (týždenné hodiny celkovo aj bez mobilu) mali síce nenulové efekty, no po FDR neboli podporené ani v FULL, ani v CORE. Preferenčné kritériá boli celkovo slabšie: *loved_type* bol v FULL ešte signifikantný ($V = 0.300$, $q = 0.048$), no v CORE sa tento signál oslabil ($q = 0.106$); žánrové indikátory a single/multiplayer premenné FDR neprešli, hoci deskriptívne vzory zostali smerovo podobné.

Tab. 49 dopĺňa interpretáciu tým, že pre kritériá s omnibus rozdielmi uvádza segmentové deskriptívy (FULL aj CORE). Pri *veku* je viditeľný stabilný smer: segment 1 má vyšší medián (FULL: 24; CORE: 25) než segmenty 0 a 2 (FULL: 22 a 23; CORE: 22 a 23). Pri *pohlaví* sa ukazuje, že segment 2 je výrazne mužský (FULL: 95 % mužov; CORE: 93.5 %), kým segment 1 má vyšší podiel žien (FULL: 33.9 %; CORE: 41.5 %) a segment 0 je medzi nimi (FULL: 20.3 %; CORE: 22.1 %).

Tento obraz je konzistentný naprieč FULL a CORE, čo podporuje záver, že pozorované rozdiely v externých kritériách sú ukotvené najmä v jadre segmentov a nie sú primárne artefaktom hraničných (BOUNDARY) priradení.

Tab. 49 Segmentové deskriptívy pre kritériá s omnibus rozdielmi (FULL vs CORE)

Segment	FULL n	Vek (medián)	Vek (priemer $\pm$ SD)	Ženy %	Muži %	CORE n	Vek (medián)	Vek (priemer $\pm$ SD)	Ženy %	Muži %
0	79	22	24.91 $\pm$ 7.28	20.3	79.7	68	22	24.65 $\pm$ 6.96	22.1	77.9
1	56	24	29.05 $\pm$ 9.97	33.9	66.1	41	25	30.07 $\pm$ 10.46	41.5	58.5
2	40	23	24.03 $\pm$ 5.40	5.0	95.0	31	23	24.23 $\pm$ 5.85	6.5	93.5

Na záver je potrebné zdôrazniť, že ide o prípadovú štúdiu určenú na ilustráciu metodiky, nie o základ pre generalizované závery o populácii hráčov. Výsledky preto netreba čítať ako dôkaz, že osoby majú univerzálne platné demografické či preferenčné rozdiely; ich úlohou je ukázať, že pipeline dokáže produkovať segmenty s explicitne reportovanou neistotou a že pozorované rozdiely v externých kritériách sa (ak sa objavia) koncentrujú skôr v jadre než v hraničných priradeniach. Zároveň táto ilustrácia naznačuje, že spoločné profilovanie motivačnej orientácie (Bartle) a dispozičnej imerzie (ITQ) môže byť prakticky zmysluplné: kombinácia oboch blokov vedie k interpretovateľným osobám a poskytuje viacrozmerný opis, ktorý by jeden blok samostatne zachytával len čiastočne.

Diskusia a záver

Táto kapitola odpovedá na otázku, ako navrhnúť a transparentne reportovať stability-first pipeline pre viacblokové profilovanie, aby výsledné osoby boli replikovateľné, mali explicitne vyjadrenú neistotu priradenia (CORE/BOUNDARY) a boli overené na externých kotvách nezahrnutých v klastrovaní. Navrhnutá metodika preto nepracuje s personami ako s jednorazovým výstupom jedného behu, ale ako s výsledkom kontrolovaného rozhodovacieho reťazca, v ktorom sú kľúčové kroky explicitné, auditovateľné a testované pod perturbáciami dát (Scrucca et al., 2016), (T. Liu et al., 2022). Prezentovaný rámec zároveň reaguje na dlhodobé artikulované riziko, že bez jasnej väzby medzi procedúrou a merateľnými dôkazmi sa osoby môžu posúvať od empirického základu k „príbehu“ a stávajú sa ťažko overiteľné či falzifikovateľné (Chapman & Milham, 2006), (Salminen et al., 2020).

Konkrétne, pipeline najprv oddelí konštrukciu spoločného profilovacieho priestoru od hodnotenia, čím minimalizuje kruhovitosť: heterogénne meracie bloky sa mapujú do reprezentácií konzistentných s meraním, štandardizujú a vyvažujú na úrovni blokov tak, aby jeden blok nemohol „prehlasovať“ druhý len kvôli šírke či variancii. Tento krok je rozhodujúci pre viacblokové nastavenia, kde naivné zreťazenie vedie ku krehkým segmentáciám a k interpretáciám, ktoré v skutočnosti odrážajú dominanciu jedného bloku. Zároveň sa explicitne rieši robustnosť voči odľahlým pozorovaniam konzervatívnym skrýningom, aby sa segmentácia neohýbala podľa extrémov v malých až stredných vzorkách (Farcomeni & Punzo, 2020).

V druhej fáze sa segmentácia realizuje pravdepodobnostne (GMM), čo prirodzene poskytuje mäkké priradenia a teda aj priamu kvantifikáciu neistoty priradenia cez posteriórne pravdepodobnosti (Scrucca et al., 2016). a tomto základe sa zavádza CORE/BOUNDARY reportovanie: CORE zachytáva prípady s vysokou oporou pre priradený segment a BOUNDARY explicitne mapuje oblasť prekryvu, ktorá by inak bola pod tvrdým klastrovaním vynútené „dočistená“ a potenciálne nadinterpretovaná. Prakticky to znamená, že osoby sa interpretujú primárne cez stabilné jadro a neistota sa nepokrýva ad hoc, ale je súčasťou reportovania aj následných kontrol.

Replikovateľnosť sa potom netvrdí deklaratívne, ale testuje: stabilita riešenia sa hodnotí resamplingom, zladením segmentov naprieč resamplami a kvantifikáciou zhody na úrovni riešenia, segmentov aj jednotlivcov. Tým sa výber K posúva od „najlepšieho interného indexu“ k obhájiteľnej voľbe, ktorá vyvažuje fit, stabilitu a separáciu priradení – presne tie vlastnosti, ktoré rozhodujú o tom, či sú osoby použiteľné pre dizajn a personalizáciu. V tejto logike stabilita neznamena maximalizovať jeden ukazovateľ, ale ukázať, že identifikovaná štruktúra pretrváva pri malých kontrolovaných zmenách a že nestabilita sa koncentruje skôr v BOUNDARY než v CORE.

Napokon, aby osoby neboli len „matematicky pekné“, pipeline uzatvára kritériovo orientovanými kontrolami na externých kotvách, ktoré neboli použité pri konštrukcii priestoru, pri výbere K ani pri CORE/BOUNDARY (t. j. sú striktné post hoc). Takéto oddelenie priamo adresuje metodologické riziko kruhového dokazovania a umožňuje interpretovať rozdiely ako nezávislú oporu pre praktickú zmysluplnosť segmentov (H. Yu et al., 2019), (Mourer et al., 2023).

Dôležité je, že **odpoveď na otázku nie je len v popise pipeline, ale aj v tom, že bola predviedená na prípadovej štúdii: dva odlišné bloky (kompozičný Bartle a faktorovo reprezentovaný ITQ) boli mapované do spoločného euklidovského priestoru, vyvážené, segmentované GMM a následne vyhodnotené stabilitou aj externými kritériami.** Prípadová štúdia nepretvaruje výsledky na populačné závery, ale ukazuje, že integrácia motivácie (Bartle) a dispozičnej imerzie (ITQ) v spoločnom priestore je prakticky realizovateľná a vedie k interpretovateľným personám s explicitne reportovanou neistotou priradenia – teda k presne takému typu výstupu, ktorý stability-first pipeline sľubuje.

Hlavný prínos kapitoly je metodologický. **Rámec formalizuje end-to-end pipeline od viacblokového profilovania po segmentáciu a reportovanie, explicitne zavádza stabilitu a neistotu priradenia ako kritériá pri voľbe a opise riešenia a predpisuje kritériovo orientované post hoc hodnotenie na externých kotvách, ktoré je od začiatku navrhnuté tak, aby sa vyhlo kruhovitosti.** V prípadovej štúdii to viedlo k personám v spoločnom priestore reportovaným spolu s istotou priradenia (core vs. hraničné prípady) a overeným pomocou externých premenných. Výsledkom je transparentný základ pre dizajnovú interpretáciu bez nafukovania naratívov z čisto vnútromodelovej štruktúry

Generalizáciu obmedzuje viacero faktorov.

- Metodologicky je workflow auditovateľný, no výsledky sa môžu meniť aj pri rozumných analytických voľbách (napr. predspracovanie, váženie blokov, ošetrovanie núl, počet komponentov, nastavenia stability).
- Keďže segmentácia používa gaussovské zmesové modely (a zjednodušenú kovariančnú štruktúru), odvodené osoby odrážajú predpoklady o tvare komponentov a môžu prehliadnúť neeliptickú alebo výrazne negaussovskú štruktúru; podobne ako pri EM odhade môže byť riešenie citlivé na inicializáciu (zmiernené viacnásobnými štartmi, nie úplne odstránené).
- Resamplingová stabilita navyše neznamena časovú stabilitu; na tú by boli potrebné longitudinálne alebo test–retest dáta. Keďže CORE/BOUNDARY vzniká prahovaním podľa posteriórnej istoty, stabilné sumarizácie vypočítané na CORE môžu byť mechanicky „optimistickejšie“; preto je CORE vhodné chápať ako neistotou riadené reportovanie, nie ako dôkaz externej replikovateľnosti, ktorú treba overiť na nezávislých vzorkách. CORE/BOUNDARY zároveň závisí od zvoleného prahu τ a iné hodnoty môžu meniť veľkosť jadra aj následné porovnania.
- Z pohľadu prípadovej štúdie ide o jednu vzorku získanú cez IT-orientované univerzitné kurzy a workshopy; osoby tak môžu odrážať špecifické pozadie, normy a herné návyky nadreprezentované v tomto náboře a nemožno ich interpretovať ako univerzálne typy hráčov. Oba bloky sú dotazníkové, a preto nesú merací šum a potenciálnu závislosť od vzorky (napr. faktorová štruktúra imerzie).
- Ani Bartleho blok s vynúteným výberom, ani ITQ sa tu nevalidujú; používajú sa ako meracie vstupy na demonštráciu stability-first metodiky, takže vecné interpretácie sú limitované ich psychometrickým základom. Nútený výber v Bartleho skórovaní zároveň indukuje kompozičnú (ipsatívnu) závislosť; kompozičné spracovanie je metodicky primerané, no obmedzuje priamu porovnateľnosť s normatívnymi (neipsatívnymi) škálami.
- Externé kritériá predstavujú len nepriamu aproximáciu dizajnovej relevancie a pozorované asociácie môžu byť oslabené meracím šumom, limitovanou silou, kvalitou dostupných externých premenných (často sebahodnotenie) alebo vysokou neistotou priradenia pri hraničných prípadoch.
- Napokon, práca sa nezaobrá AI-orientovaným alebo dátovo-centrickým profilovaním (napr. prediktívne modely trénované na veľkoobjemovej behaviorálnej telemetrii), ktoré je v personalizácii čoraz bežnejšie. Príspevok preto treba čítať ako dizajnovú a meraním informovanú stability-first metodiku segmentácie demonštrovanú na dotazníkových vstupoch, nie ako end-to-end AI systém profilovania.

V rámci ďalšej práce je v prvom kroku potrebné replikovať postup v rozmanitejších vzorkách a kontextoch a overiť stabilitu nielen segmentácie, ale aj samotných mapovaní meracích blokov.

Ďalším rozšírením je prechod od dotazníkov k behaviorálnej telemetrii a longitudinálnym signálom, ktoré lepšie reprezentujú reálne zapojenie a adaptačné ciele.

Napokon je vhodné posunúť sa od post hoc rozdielov k intervenčným testom: overiť praktickú hodnotu person tým, že sa podľa nich bude reálne prispôbovať obsah alebo mechaniky (napr. tempo dávkovania úloh či miera príbehového kontextu) a následne sa experimentálne otestuje, či takáto personalizácia prináša merateľné zlepšenie výkonu, zapojenia alebo používateľskej skúsenosti oproti nepersonalizovanej verzii.

Prínos pre oblasť habilitácie

Prínos tejto sekcie pre oblasť habilitácie možno zhrnúť do nasledujúcich bodov:

- Teoretický prínos spočíva v posune chápania person od jednorazovej interpretácie zhukov k disciplinovanému konštraktu, pri ktorom je stabilita predpokladom validity. Persona sa tu neinterpretuje ako objavený typ, ale ako empiricky reprodukovateľná štruktúra, ktorá pretrváva pri rozumných perturbáciách dát a analytických rozhodnutí, a preto je vhodná na prenos medzi prostrediami a na opretie dizajnových rozhodnutí o dáta.
- Metodický prínos spočíva v formalizácii end-to-end postupu, ktorý je použiteľný naprieč pohľadmi a dátovými vrstvami. Pipeline zavádza blokovo konzistentné mapovanie do spoločného priestoru, štandardizáciu a váženie blokov podľa kvality a pokrytia, konzervatívne ošetrovanie odľahlostí, probablistickú segmentáciu (napr. GMM) s voľbou K podľa kombinácie stability, fitu a separácie, explicitné reportovanie neistoty cez rozlíšenie CORE a BOUNDARY podľa posteriórnej istoty, resamplingovú reprodukovateľnosť ako štandardný test robustnosti a post hoc validáciu na externých premenných mimo klastrovania, aby sa predišlo kruhovitosti.
- Praktický prínos spočíva v tom, že pipeline produkuje persony, ktoré sú použiteľné v aplikácii bez nafukovania naratívov: okrem názvu a profilu poskytuje mieru istoty priradenia, identifikuje exemplárnych používateľov vhodných na dizajnové scenáre a oddeľuje hraničné prípady, pri ktorých je riziko nesprávnej personalizácie vyššie. Tým sa zvyšuje transparentnosť aj férovosť rozhodnutí odvodených z person.
- Pre multi-view modelovanie pipeline tvorí centrálny integračný mechanizmus celej habilitácie: umožňuje najprv stabilizovať každý pohľad samostatne, premeniť typy s napevno definovaným zaradením na pravdepodobnostné členstvá a až potom ich integrovať neskorou fúziou so zohľadnením stability a pokrytia. V dôsledku toho sa spoločný priestor nekonštruuje z nekontrolovane zmiešaných príznakov, ale z harmonizovaných a auditovateľných výstupov, čím sa znižuje dominancia bohatších zdrojov, zlepšuje sa práca s neúplnosťou a zvyšuje sa prenositeľnosť naprieč virtuálnymi prostrediami.

Viacpohľadové profilovanie používateľov

Súčasná herná analytika aj výskum virtuálnych prostredí pracujú s dátami, ktoré majú prirodzene viacpohľadový charakter: ten istý používateľ je súčasne zachytený sebaopisom, agregovanými ukazovateľmi účtu a ekonomiky, telemetriou udalostí a pohybu, ako aj odvodenými procesnými opismi správania. Predchádzajúce kapitoly tieto zdroje analyzujú oddelene z hľadiska merania, reprezentácie, rizík a interpretácie a ukazujú, že jednotlivé pohľady sa odlišujú nielen typom neseného signálu, ale aj štruktúrou a mierou neistoty. Táto kapitola na tieto zistenia nadväzuje integračne: syntetizuje pojmy a postupy z predchádzajúcich častí do jednotného metodického rámca, ktorý umožní kombinovať pohľady pri zachovaní ich sémantiky a bez nežiaducej dominancie jedného zdroja.

Jadrom problému nie je samotná dostupnosť dát, ale porovnateľnosť a spoľahlivosť odvodených záverov. Pohľady sa líšia mierkami, štatistickými vlastnosťami a kvalitou a v reálnych nasadeniach je typické aj neúplné pokrytie: časť používateľov nevyplní dotazník, časť má len krátku telemetriu a niektoré pohľady existujú iba v špecifických scenároch alebo na určitých zariadeniach. Priame spájanie príznakov do jedného vektora preto často zvyšuje dimenzionalitu, zväčšuje dominanciu najbohatšieho pohľadu a vedie k riešeniam citlivým na analytické rozhodnutia. Zároveň sa v aplikačnom kontexte vyžaduje interpretovateľnosť: profily musia byť vysvetliteľné tak, aby bolo možné zdôvodniť priradenie používateľa a preložiť zistené rozdiely do návrhových a produktových rozhodnutí.

Východiskom integračnej časti je rámec, v ktorom sa viacpohľadové dáta najprv harmonizujú v rámci vrstiev a až následne sa porovnávajú a integrujú medzi vrstvami. Vrstvy predstavujú skupiny zdrojov s podobnou povahou merania a typickými chybami:

- subjektívne údaje (sebaopis a dotazníky),
- agregované ukazovatele (profil účtu, ekonomika, sumárne štatistiky),
- časové rady telemetrie (priebehy správania v čase),
- procesné reprezentácie (odvodené opisy správania vo forme epizód, stavov alebo postupov).

Harmonizácia v tomto kontexte znamená, že sa v každej vrstve uplatnia primerané transformácie, škálovanie a pravidlá agregácie tak, aby boli premenné porovnateľné a aby sa obmedzil vplyv šumu, odľahlostí a rozdielnej dimenzionality ešte pred samotnou integráciou. V organizačnom zmysle tento postup prirodzene smeruje k neskorej (rozhodovacej) fúzii, v ktorej sa modelovanie realizuje na jednotlivých modalitách alebo pohľadoch pred ich spojením; výskum potvrdzuje, že tento prístup umožňuje flexibilnejšie pracovať s chýbajúcimi modalitami, keďže nevyžaduje okamžitú synchronizáciu na úrovni príznakov, ako je tomu pri skoršej fúzii (Gu et al., 2017), (Halim & Uzma, 2018).

Osobitnú pozornosť si vyžaduje voľba integračnej stratégie, najmä v režime výraznej neúplnosti a nerovnomernej kvality pohľadov (Ye et al., 2018), (Brbić & Kopriva, 2018). V takomto nastavení je prakticky obhájiteľné začať neskorou fúziou, keď sa každý pohľad spracuje samostatne a integrácia prebieha až na úrovni výstupov. Rozhodovacia fúzia tak umožňuje kombinovať unimodálne výstupy (napr. skóre alebo pravdepodobnosti) a flexibilne pracovať s chýbajúcimi modalitami, čo potvrdzujú prehľady multimodálnej fúzie aj komparatívne analýzy skorých a neskorých integračných režimov (Jiao et al., 2024), (Pereira et al., 2023). Praktickou výhodou je aj to, že sa znižuje potreba imputovať chýbajúce hodnoty vo vysokodimenzionálnom spojenom priestore; ad hoc dopĺňanie (najmä pri nenáhodnom chýbaní) môže zvyšovať šum a viesť k skresleniu, preto výskum o chýbajúcich dátach zdôrazňuje opatrnosť pri jednoduchých imputáciách a potrebu transparentného modelovania chýbania (Demirtas, 2018).

Takto zvolený integračný rámec zároveň umožňuje presnejšie pomenovať medzeru v existujúcich prístupoch. Komponenty viacpohľadového modelovania sa často riešia izolovane: integrácia sa

optimalizuje primárne na výkon, zatiaľ čo kvantifikácia neistoty zostáva vedľajšia, hoci práve ona rozhoduje o dôveryhodnosti výstupov pri praktickom rozhodovaní (Obayemi & Nguyen, 2026), (L. Huang et al., 2025). Podobne, bez resamplingovej kontroly stability môžu vznikať segmentácie, ktoré sa menia pri primeraných perturbáciách dát a sú citlivé na analytické voľby; literatúra o stabilite zhukovania pritom ukazuje, že stabilita na úrovni zhukov je použiteľným kritériom na odlíšenie reálnych štruktúr od artefaktov a že detegovaná nestabilita má byť varovaním pred interpretáciou (Dresen et al., 2008). Z tohto dôvodu sa v tejto kapitole stabilita a neistota chápu ako podmienka interpretácie, nie ako dodatočný diagnostický doplnok.

Na úrovni interpretácie sa prepojenie zistení naprieč vrstvami opiera o triangulačnú logiku (konvergencia, komplementarita, vysvetľovanie rozporov), ktorú metodologická literatúra o integrácii v zmiešanom výskume považuje za kľúčový nástroj spájania heterogénnych dôkazov bez preinterpretovania jedného zdroja (Hitchcock & Onwuegbuzie, 2022). Metodika navrhnutá v tejto kapitole preto stavia na „stability-first“ logike: segmentácia sa nepovažuje za použiteľnú pre interpretáciu, kým sa empiricky nepreukáže jej stabilita, a kým sa zároveň transparentne neodreportuje neistota priradenia. Vrstvová harmonizácia vytvára podmienky porovnateľnosti, neskorá fúzia poskytuje robustnú integračnú líniu pri neúplných pohľadoch a stabilitné hodnotenie spolu s neistotou slúžia ako brzda proti preinterpretovaniu štruktúr, ktoré vznikli ako artefakt reprezentácie alebo algoritmického nastavenia.

Cieľom kapitoly je z uvedeného rámca odvodiť prakticky použiteľný a auditovateľný pipeline pre viacpohľadové profilovanie používateľov v hrách a virtuálnych prostrediach. Východiskom je, že jednotlivé zdroje nevstupujú do integrácie v rovnakej podobe: subjektívne dotazníky prirodzene poskytujú pravdepodobnostné priradenie (napr. cez zmesné modely), agregované ukazovatele zo súhrnných logov často vedú k „tvrdým“ typológiám bez explicitnej miery istoty a procesné dáta (taktiky a epizódy) si vyžadujú najprv segmentáciu správania v čase a až následne umožňujú segmentovať používateľov podľa distribúcie týchto prvkov. Metodika preto predpokladá, že sa v každom pohľade najprv vytvorí porovnateľný výstup – ideálne vo forme pravdepodobnostného priradenia alebo stabilitne odvodeného „mäkkého“ členstva – a až potom sa rieši integrácia naprieč pohľadmi, pričom sa explicitne zohľadní neúplnosť a nerovnomerná kvalita zdrojov.

Pipeline sa opiera o šesť nadväzujúcich krokov:

- zdefinovať vrstvy a pohľady a určiť, ktoré z nich tvoria procesné reprezentácie správania (epizódy/taktiky) a ktoré nesú informáciu na profilovanie používateľov,
- harmonizovať dáta v rámci vrstiev vrátane časového ukotvenia a segmentácie časovej osi tam, kde je potrebná pre tvorbu procesných črt,
- vykonať pohľadové profilovanie používateľov so soft priradením (pravdepodobnosti) a explicitnou mierou istoty; zároveň materializovať pokrytie a kvalitu pohľadu pre používateľa,
- zvoliť a aplikovať integračnú stratégiu so zreteľom na neúplnosť a interpretovateľnosť (ako konzervatívny východiskový režim sa uvažuje neskorá fúzia na úrovni pohľadových výstupov do spoločného priestoru),
- vyhodnotiť stabilitu riešení pri prevzorkovaní a primeraných perturbáciách (na úrovni pohľadov aj po integrácii),
- interpretovať profily pomocou triangulácie naprieč pohľadmi a nezávislého overovania na premenných vyhradených mimo zhukovania..

Následná prípadová štúdia ukáže, do akej miery je takto formulovaný postup realizovateľný na reálnych dátach, ako sa správa pri čiastočnom pokrytí pohľadov a aké kompromisy prináša pri výbere integračného režimu, počtu profilov a prahov istoty.

Komplexnosť tejto úlohy vedie k hlavnej výskumnej otázke:

- **HVO: Ako navrhnúť a empiricky overiť metodiku viacpohľadového profilovania používateľov v hrách a virtuálnych prostrediach, ktorá integruje heterogénne a neúplné pohľady, explicitne kontroluje stabilitu a neistotu priradenia a vedie k interpretovateľným profilom použiteľným v praxi?**

Prehľad relevantných zdrojov

Každý používateľ vo virtuálnom systéme je definovaný rôznymi sadami atribútov: od statického profilu (demografia, nákupy) a dynamickej telemetrie (pohyb, sekvencie akcií) až po odvodené procesné opisy správania a sociálne interakcie. Tradičné prístupy k analýze dát, ktoré sa spoliehajú na jeden zdroj informácií, prestávajú byť dostatočnými, pretože zachytávajú len čiastkový obraz a ľahko prehliadnu väzby medzi zložkami správania. Metódy založené na spájaní údajov do jedného vektora narážajú na problém vysokej dimenzionality a na stratu špecifických vzorov v jednotlivých doménach. Riešením situácie je viacpohľadové profilovanie, ktoré integruje jednotlivé aspekty tak, aby výsledné profily poskytovali komplexnejší a informatívnejší obraz než analýza izolovaných pohľadov (Chao et al., 2021a), (Y. Wen & Li, 2025).

Základom tohto profilovania je spojenie dvoch typov signálov: konsenzuálneho, ktorý sa prejavuje v podobe zhodných vzorcov naprieč viacerými pohľadmi, a komplementárneho, ktorý prináša pohľadovo špecifické informácie dostupné len v niektorých zdrojoch. Kombináciou zhody a doplnenia sa tak dá dosiahnuť robustnejší a informatívnejší výsledok než pri použití jediného zdroja (Haris et al., 2024), (Chenfeng Guo & Wu, 2022). Do profilu tak možno začleniť heterogénne typy dát v podobe relatívne stabilných charakteristík (napr. účet, história platieb a iné dlhodobéjšie indikátory), priebežného správania (časové vzorce hrania, voľby v hre, úspešnosť a progres), priestorové a interakčné stopy (trajektórie pohybu, kontakty s objektmi a udalosťami v hernom svete), ako aj sociálne väzby (interakcie medzi hráčmi, členstvo v skupinách, sociálny vplyv). Každý z týchto pohľadov nesie vlastný typ informácie, no súčasne môže potvrdiť alebo spresniť obraz odvodený z iných zdrojov (Niu et al., 2023), (Chao et al., 2021b).

Súčasne však platí, že heterogénnosť pohľadov je zdrojom metodických rizík. Rôzne pohľady často pochádzajú z odlišných zdrojov, majú rôzne štatistické rozdelenia, sémantiku a mieru nepresnosti či neurčitosti, čo komplikuje ich priamu integráciu a pri naivnom spájaní sa môže zvýrazniť šum, dominancia jedného pohľadu a zároveň sa môžu stratiť vzťahy medzi pohľadmi (Chowdhury et al., 2025), (Zhenshan Chen et al., 2025). Typickým príkladom je práca v prostredí virtuálnej reality, kde sa problémy prejavujú už na úrovni merania: nástroje na hodnotenie zážitku sa líšia v konštruktoch, položkách aj psychometrických vlastnostiach, čo priamo ovplyvňuje porovnateľnosť a interpretáciu profilov odvodených z dotazníkov. Systematický prehľad dotazníkov vo VR ukazuje, že hoci sa často merajú rovnaké konštrukty (napr. prítomnosť, používateľská skúsenosť), definície a položky sa v jednotlivých nástrojoch značne líšia, chýba im štandardizácia, krížová kultúrna validácia a sú tiež zaťažené subjektivitou, skreslením pamäti a interpretáciou používateľa (Bareišytė et al., 2024), (Bruni et al., 2025). Pri telemetrii sa zase stretáva šum, odľahlosti neštandardného správania, rozdielne mierky a významy premenných, spôsoby čistenia a predspracovania dát (Sifa et al., 2018) a pri odvodených procesných reprezentáciách rozhoduje aj voľba segmentácie a post-processingu (Chao et al., 2021a), (Russell & Norvig, 2021).

Viacpohľadové profilovanie preto musí byť postavené najmä na návrhu postupu, ktorý udrží porovnateľnosť naprieč pohľadmi, obmedzí dominanciu jedného zdroja a umožní kontrolovať neistotu. V konkrétnej situácii je jedným z hlavných rozhodnutí kedy a ako pohľady integrovať. V literatúre sa bežne rozlišuje skorá fúzia (spojenie príznakov pred modelovaním) (Haris et al., 2024), (van Loon et al.,

2024), neskorá fúzia (spájanie rozhodnutí alebo pravdepodobností z jednotlivých pohľadov) (Ye et al., 2018) a integrácia cez spoločnú reprezentáciu, teda mapovanie do spoločného priestoru, v ktorom sa následne vykoná zhľukovanie (Hauptmann & Kramer, 2023), (M. S. Chen et al., 2022), (R. Zhou & Shen, 2020), (Trosten et al., 2021). Skorá fúzia pracuje so spojením vstupov, neskorá s kombináciou výstupov a intermediárna s učením spoločných podpriestorov (napr. pomocou CCA alebo neurónových sietí) (J. Wen et al., 2019), (Sahbi, 2019).

Skorá a neskorá fúzia majú odlišné predpoklady a odlišné režimy zlyhania (Gu et al., 2017), (Halim & Uzma, 2018). Zatiaľ čo skorá fúzia je citlivá na dimenzionalitu a škálovanie (Purificato et al., 2024), neskorá fúzia môže strácať korelácie medzi pohľadmi (van Loon et al., 2020), (Xiong & Cao, 2025). Výber prístupu preto treba vnímať ako priestor pre porovnávanie kandidátnych integračných riešení a nie ako správnu voľbu (Pereira et al., 2023).

Samotné viacpohľadové metódy sa v prehľadoch často členia na prístupy, ktoré optimalizujú rozdelenie priamo (diskriminačné), a prístupy, ktoré modelujú proces a poskytujú pravdepodobnostné priradenie (generatívne) (Chao et al., 2021a), (Ullmann et al., 2022). V kontexte profilovania používateľov je prakticky dôležité, že pravdepodobnostné formulácie prirodzene nesú mieru istoty priradenia, a tým podporujú konzervatívne rozlišovanie medzi jadrom profilu a hraničnými prípadmi (Ramos et al., 2018), (Chuan Guo et al., 2017). Na druhej strane, moderné prístupy využívajú aj nelineárne reprezentácie (napr. autoenkóдеры, kontrastívne zarovnávanie či grafové neurónové siete), ktoré rozširujú vyjadrovaciu schopnosť modelov, no zároveň posilňujú napätie medzi výkonom a vysvetliteľnosťou a často komplikujú preklad výsledkov do návrhových rozhodnutí v dôsledku nižšej interpretovateľnosti (Chowdhury et al., 2025), (Haris et al., 2024), (Kauffmann et al., 2024). V tejto práci sa preto neurónové siete chápu najmä ako konceptuálne pozadie, nie ako cieľová technológia. Hoci neurónové siete ponúkajú silné nástroje na extrakciu príznakov, v doménach vyžadujúcich pochopenie (ako je psychologické alebo herné profilovanie) je často potrebné uprednostniť modely, ktoré umožňujú prepojenie výsledkov so štruktúrou dát (Haris et al., 2024).

Kľúčovou praktickou komplikáciou multi-view modelovania je **neúplnosť dát**. V reálnych nasadeniach je nepravdepodobné, že všetci používatelia budú mať dostupné všetky pohľady: časť používateľov nevyplní dotazník, časť má iba krátku telemetriu, niektoré pohľady sú viazané na špecifické scenáre alebo zariadenia. Viacpohľadové metódy preto musia počítať s tým, že integrácia sa bude realizovať v režime čiastočného pokrytia, a že kvalita jednotlivých pohľadov bude nerovnomerná. Metódy neúplného viacpohľadového zhľukovania (*Incomplete Multi-View Clustering* - IMVC) sú navrhnuté tak, aby sa vysporiadali s čiastočným pokrytím dát a integrovali informácie aj z chýbajúcich pohľadov (C. Yang & Yue, 2025), (A. Li et al., 2024), (J. Yu et al., 2023). Niektoré pohľady môžu obsahovať silný signál, zatiaľ čo iné sú zaťažené šumom, čo môže negatívne ovplyvniť výsledný model, ak sa s tým nepočíta (napr. pri jednoduchej imputácii priemerom). Štruktúra chýbajúcich dát zvyčajne nie je náhodná, preto takéto dopĺňanie môže vnieść do analýzy skreslenie (van Loon et al., 2024), (J. Yu et al., 2023).

Navyše, v multi-view profilovaní nestačí iba navrhnúť integračný mechanizmus; rovnako dôležité je preukázať stabilitu segmentácie pri prevzorkovaní a perturbáciách dát a transparentne reportovať neistotu priradenia. Stabilitu možno hodnotiť resamplingovo (napr. konsenzus/zhoda naprieč behmi, predikovateľnosť rozdelenia, stabilita jednotlivých klastrov), pričom pravdepodobnostné formulácie prirodzene umožňujú pracovať s mierou istoty priradenia (Monti et al., 2003), (Tibshirani & Walther, 2005), (Fraley & Raftery, 2002), (Haris et al., 2024).

Pre aplikačné použitie je súčasne rozhodujúce, aby boli profily interpretovateľné, t. j. aby bolo možné ich odôvodniť v termínoch správania a preferencií, ktoré sa dajú preložiť do návrhových a produktových rozhodnutí. Z hľadiska návrhu profilovania to priamo otvára otázku, ktoré premenné patria do zhľukovania (t. j. definujú profil) a ktoré majú zostať bokom na nezávislé overenie (Hennig, 2007). Na

tomto základe sa následne uplatňuje triangulácia ako rámec interpretácie a validácie naprieč pohľadmi (Valencia, 2022), (Hussain et al., 2018):

1. Konvergencia, ktorej primárnym cieľom je hľadať zhodu výsledkov naprieč nezávislými metódami. Ak kvantitatívne dáta (napríklad herná telemetria) a kvalitatívne dáta (napríklad sebahodnotenie v dotazníku) vedú k rovnakému záveru, dochádza ku krížovej validácii, ktorá výrazne zvyšuje istotu, že pozorovaný jav je reálny a nie je len výsledkom náhody (Heale & Forbes, 2013), (Valencia, 2022), (Flick, 2017).
2. Komplementarita je postavená na skutočnosti, že rôzne pohľady odhaľujú odlišné aspekty toho istého javu. Kým jeden pohľad (napr. logy správania) môže presne opísať štruktúru a frekvenciu javu ("čo sa stalo"), druhý pohľad (napr. rozhovor alebo kontextové dáta) objasňuje motiváciu a príčiny ("prečo sa to stalo"), čím sa vytvára úplnejší a detailnejší obraz o používateľovi (Obikwelu & Read, 2017), (Schoonenboom & Johnson, 2017).
3. Riešenie rozporov je nevyhnutnou súčasťou procesu, pričom nezhoda sa nepovažuje za zlyhanie, ale za signál, že je potrebné prehodnotiť meranie, overiť kvalitu dát alebo zvážiť, či sa správanie nemení v závislosti od kontextu (Heale & Forbes, 2013), (Valencia, 2022).

V multi-view profilovaní má teda triangulácia dvojitú úlohu. Na jednej strane posilňuje dôveryhodnosť stabilných zistení tým, že eliminuje bias spojený s použitím jednej metódy. Na druhej strane chráni pred preinterpretovaním segmentov, ktoré vznikli ako artefakt jednej reprezentácie. Bez triangulácie hrozí, že výskumníci budú interpretovať chyby merania alebo špecifiká jedného zdroja dát ako skutočné črty profilu používateľa (Denzin, 2018), (Heale & Forbes, 2013), (Valencia, 2022).

Metodika multi-view profilovania

Štvorstupňová stability-first pipeline je organizovaná tak, aby najprv zafixovala porovnateľné vstupy, potom vytvorila stabilné pohľadové profily, následne ich integrovala do spoločného priestoru a napokon nezávisle overila, čo z výsledkov je robustné a prenositeľné:

- **Stage 1:** Špecifikácia pohľadov a harmonizácia používateľských reprezentácií zabezpečuje vytvorenie východiskových predpokladov a prostredia pre multi-view profilovanie: definujú sa pohľady ako typy zdrojov, určia sa pravidlá harmonizácie a konštrukcie reprezentácie používateľa, definujú sa funkcie použiteľnosti a kvality a nastaví sa rámec triangulácie a nezávislého overovania.
- **Stage 2:** Materializácia pohľadov a stabilné profilovanie používateľov premieňa špecifikáciu na výpočtové výstupy pripravené na integráciu: materializujú sa reprezentácie v jednotlivých pohľadoch, vypočíta sa pokrytie a kvalita na úrovni používateľ–pohľad, vykoná sa pohľadová segmentácia s konzervatívnym výberom granularít podľa stability a diagnostiky, doplní sa štandardizovaná neistota aj pri metódach s tvrdým priradením (pseudo-pravdepodobnosti z prevzorkovania a používateľská istota) a určia sa CORE/BOUNDARY prípady.
- **Stage 3:** Integrácia pohľadov a konštrukcia spoločného priestoru spája stabilizované pohľadové výstupy neskorou fúziou tak, aby bola integrácia konzistentná aj pri neúplnosti zdrojov: vyberú sa integračné a triangulačné pohľady, určia sa globálne a používateľsky špecifické váhy podľa stability, pokrytia a kvality, skonštruje sa spoločný priestor ako vážená kombinácia harmonizovaných podpisov a príslušností, priebežne sa porovnáva robustnosť cez alternatívne kombinácie pohľadov a prípadná segmentácia v spoločnom priestore sa reportuje s explicitnou neistotou a CORE/BOUNDARY rozlíšením.
- **Stage 4:** Nezávislé overovanie person uzatvára pipeline tým, že oddeľuje robustné tvrdenia od citlivých interpretácií a rieši nezhody diagnosticky: vyhodnotí sa konvergencia a

komplementarita naprieč pohľadmi, rozpory sa vysvetľujú postupne cez pokrytie, kvalitu, neistotu, stabilitu, časové ukotvenie a citlivosť na konfiguráciu, osoby sa nezávisle overujú na vyhradených premenných mimo zhlukovania (prioritne na CORE, doplnkovo vážené analýzy) a výstupom je rozlíšenie robustného jadra, metodovo závislej vrstvy a odporúčaní pre bezpečný prenos do praxe.

Stage 1: Špecifikácia pohľadov a harmonizácia používateľských reprezentácií

Stage 1 predstavuje špecifikačnú a harmonizačnú etapu pipeline. Jej cieľom je zafixovať, aké dátové pohľady sa používajú, ako sa v nich vytvára porovnateľná reprezentácia používateľa a aké budú výstupové kontrakty pre ďalšie kroky. V tejto etape sa ešte nevykonáva segmentácia používateľov; Stage 1 iba pripraví jednotné vstupy, ktoré sa následne v Stage 2 profilujú a segmentujú stabilitne orientovaným postupom.

Typy zdrojov a časové ukotvenie

Za jednotku analýzy sa považuje používateľ $i \in \{1, \dots, N\}$. Pre každý pohľad $v \in \{1, \dots, V\}$ sa evidujú surové dáta $D_i^{(v)}$. Keďže jednotlivé zdroje často pokrývajú odlišné časové horizonty, Stage 1 zavádza spoločné časové ukotvenie τ , ktoré určuje režim porovnateľnosti (napr. prvé obdobie expozície, pevné okno, alebo pravidlá pre longitudinálne zhrnutie). Cieľom je, aby rozdiely medzi používateľmi neboli artefaktom toho, že jeden pohľad zachytáva prvý kontakt s technológiou a iný celý rok používania.

V Stage 1 sa zadefinuje množina pohľadov tak, aby pokrývala heterogénne zdroje informácie, pričom sa nepredpisuje ich konkrétna podoba – dôležitá je rola pohľadu a jeho výstupový kontrakt. Typicky sa uvažujú napríklad:

- sebaopisné alebo dotazníkové zdroje (konštrukty, preferencie, subjektívne hodnotenia),
- sumárne používanie (agregované charakteristiky aktivity),
- časové vzorce správania (napr. rozdelenie štúdia podľa mesiacov v roku alebo počas semestra),
- procesné/taktické zdroje (používanie taktík alebo režimov správania odvodených z telemetrie),
- prípadne ďalšie špecifické zdroje podľa prostredia.

Z hľadiska pipeline je rozhodujúce, či pohľad poskytuje reprezentáciu vhodnú na profilovanie používateľov, alebo doplnkový opis, ktorý slúži najmä na interpretáciu a trianguláciu. Stage 1 týmto krokom explicitne nastaví, že taktiky alebo mesiace štúdia sú len jeden z pohľadov, nie dominantná vrstva metodiky.

Harmonizácia v rámci pohľadu

Pre každý pohľad sa zafixujú pravidlá harmonizácie a konštrukcie používateľskej reprezentácie. Formálne sa špecifikuje transformácia

$$\tilde{\mathcal{D}}_i^{(v)} = g_v(\mathcal{D}_i^{(v)}), \quad (14)$$

kde g_v pokrýva najmä jednotné škálovanie a konzervatívne ošetrovanie extrémov, pravidlá práce s chýbaním, zjednotenie mierok a agregácií, ktoré sú špecifické pre daný zdroj. V tejto etape sa rieši porovnateľnosť vstupu, nie optimálny model.

Harmonizácia sa definuje tak, aby bola auditovateľná a reprodukovateľná; t. j. analytické rozhodnutia (okná, prahy, agregácie) sa stanovujú ako súčasť metodiky, nie až pri interpretácii výsledkov.

Reprezentácia používateľa v pohľade

Výsledkom Stage 1 je pre každý pohľad definícia používateľskej reprezentácie

$$r_i^{(v)} \in \mathbb{R}^{d'_v}, \quad (15)$$

ktorá sa v Stage 2 materializuje pre všetkých použiteľných používateľov. Reprezentácia môže mať rôzny význam podľa zdroja, no kontrakt ostáva jednotný: ide o vektor charakteristík používateľa v danom pohľade, napr.:

- pri časových vzorcoch správania môže $r_i^{(v)}$ vyjadriť rozdelenie aktivity používateľa v čase (napr. po mesiacoch),
- pri taktickom pohľade môže $r_i^{(v)}$ zachytávať mieru používania vybraných taktík alebo ich kombinácie,
- pri dotazníkoch môže $r_i^{(v)}$ obsahovať škálové skóre alebo stabilizované dimenzie.

Stage 1 týmto krokom jasne stanoví, že charakteristiky používateľa sú vždy pohľadovo viazané. Segmentácia používateľov sa realizuje až neskôr nad týmito reprezentáciami.

Politika pokrytia a kvality

Keďže v multi-view nastavení nie každý používateľ disponuje všetkými pohľadmi v rovnakej kvalite, Stage 1 zafixuje pravidlá pre dve veličiny, ktoré sa materializujú až v Stage 2:

- použiteľnosť pohľadu pre používateľa: $m_{i,v} = \mathcal{M}_v(\tilde{\mathcal{D}}_i^{(v)}) \in \{0,1\}$,
- kvalita pohľadu pre používateľa: $q_{i,v} = \mathcal{Q}_v(\tilde{\mathcal{D}}_i^{(v)}) \in [0,1]$.

Stage 1 špecifikuje, aké minimálne podmienky musí zdroj spĺňať (napr. minimálna expozícia, minimálny objem pozorovaní), a ako sa bude narábať s nízkou kvalitou (maskovanie, zníženie vplyvu, alebo vyradenie). Tým sa už na úrovni metodiky predíde tomu, aby sa neskôr rozpory medzi pohľadmi zamieňali za dôsledok chýbania a šumu.

Stage 1 zároveň stanoví interpretačný rámec, podľa ktorého sa v Stage 4 vyhodnocuje, ako spolu pohľady súvisia:

- Konvergencia sa chápe ako súlad signálov naprieč pohľadmi tam, kde to vzhľadom na ich rolu a kvalitu dáva zmysel.
- sa chápe ako legitímne doplnenie perspektív: pohľady nemusia hovoriť to isté, ale majú prispieť odlišnými, vzájomne kompatibilnými informáciami.
- Rozpory sa neriešia pocitovou interpretáciou, ale diagnostickým sledom, ktorý začne pokrytím $m_{i,v}$, kvalitou $q_{i,v}$ a neistotou, a až následne zvažuje časové ukotvenie τ , kontextové premenné a metodické rozhodnutia.

Tento rámec je dôležitý najmä preto, že v heterogénnych zdrojoch je časť nezhôd očakávaná a informatívna, kým iná časť je len artefakt merania alebo neúplnosti.

Nezávislé overovanie a auditovateľnosť

Na zabránenie kruhovitosti Stage 1 vyčlení množinu premenných Z , ktoré sa nepoužijú na tvorbu segmentov, ale až na neskoršie nezávislé overovanie a interpretáciu. Súčasne sa vedie register rozhodnutí (verzie kontraktov, parametre harmonizácie, definície pohľadov), aby bolo možné späťne vysvetliť, z ktorých pravidiel výsledky vznikli.

Výstupy

Stage 1 je ukončený vtedy, keď existuje kompletná a auditovateľná špecifikácia, ktorá umožní v Stage 2 materializovať pohľadové reprezentácie a vykonať profilovanie. Praktickým výstupom Stage 1 sú:

- **Katalóg pohľadov** – stručný opis každého pohľadu (typ zdroja, rola v pipeline, časové ukotvenie τ , očakávané riziká a typ neistoty).

- **Harmonizačné kontrakty** – zoznam pravidiel transformácie surových dát na harmonizovaný vstup: škálovanie, ošetrovanie extrémov, pravidiel chýbania, agregácie a normalizácie.
- **Výstupové kontrakty reprezentácie používateľa** – formálna definícia, akú formu má mať reprezentácia používateľa v pohľade vrátane pomenovania dimenzií/črt a pravidiel interpretácie (čo znamená vyššia/nížšia hodnota, aké normalizácie sa použijú).
- **Definície pokrytia a kvality** – špecifikácia funkcií použiteľnosti a kvality spolu s prahmi a pravidlami, ako sa bude narábať s nízkou kvalitou (maskovanie alebo zníženie vplyvu).
- **Rámec triangulácie a riešenia rozporov** obsahuje pravidlá, podľa ktorých sa v Stage 4 bude rozlišovať konvergencia, komplementarita a rozpory.
- **Množina premenných pre nezávislé overovanie** – zoznam premenných vyhradených pre post hoc validáciu mimo zhľukovania a pravidlo ich nepoužitia pri tvorbe segmentov.

Stage 2: Materializácia pohľadov a stabilné profilovanie používateľov

Stage 2 je výpočtová etapa, v ktorej sa podľa špecifikácie zo Stage 1 materializujú pohľadové reprezentácie používateľa, vypočíta pokrytie a kvalita a v rámci jednotlivých pohľadov sa vykoná profilovanie/segmentácia používateľov tak, aby výstupy boli porovnateľné a pripravené na neskorú integráciu. Kľúčovou požiadavkou Stage 2 je, aby aj segmentácie, ktoré prirodzene produkujú iba tvrdé priradenie, boli doplnené o štandardizovanú mieru neistoty.

Materializácia reprezentácií

Pre každý pohľad v sa aplikujú harmonizačné pravidlá g_v a skonštruuje sa používateľská reprezentácia $r_i^{(v)} \in \mathbb{R}^{d'_v}$.

Súčasne sa materializujú:

$$m_{i,v} = \mathcal{M}_v(\cdot), q_{i,v} = \mathcal{Q}_v(\cdot), \quad (16)$$

t. j. použiteľnosť a kvalita pohľadu na používateľa a pohľad. Tieto veličiny sa následne používajú na konzervatívne obmedzenie analýzy (použiteľní používateľa) a na zohľadnenie neistoty vstupu v ďalších krokoch.

Pohľadové profilovanie

Stage 2 vzhľadom na potenciálne rôzne zdroje pohľadov pripúšťa dva ekvivalentné režimy segmentácie:

- **Segmentácie s prirodzeným pravdepodobnostným výstupom** – ak použitý model poskytuje pravdepodobnostné priradenie, výstupom je matica príslušností

$$P^{(v)} = (p_{i,k}^{(v)}), \sum_{k=1}^{K_v} p_{i,k}^{(v)} = 1, \quad (17)$$

a odvodené tvrdé priradenie $\hat{z}_i^{(v)} = \arg \max_k p_{i,k}^{(v)}$. Tento režim je výhodný pre neskorú integráciu, keďže zachováva informáciu o neistote.

- **Segmentácie s tvrdým priradením** (napr. k-means) – kde metóda produkuje iba tvrdé zaradenie do jedného z identifikovaných klastrov. V takomto prípade Stage 2 doplní štandardizovanú neistotu tak, aby pohľad spĺňal výstupový kontrakt. Prakticky sa používajú dve komplementárne doplnkové informácie:
 - istota založená na geometrii riešenia (napr. vzdialenosť od prototypu alebo separácia voči najbližšiemu alternatívnemu klastru), ktorá dáva používateľsky špecifické skóre $u_i^{(v)}$,

- reprodukovateľnosť priradenia pri prevzorkovaní, ktorá pre používateľa vytvorí frekvenciu priradenia do klastra a tým aj pseudo-pravdepodobnosti

$$\hat{p}_{i,k}^{(v)} = \frac{1}{B} \sum_{b=1}^B \mathbf{1} \left[\hat{z}_i^{(v,b)} = k \right], \quad (18)$$

kde b indexuje replikácie (bootstrap alebo iná primeraná perturbácia).

Výsledkom je teda transformácia, ktorá umožňuje pracovať s neistotou aj v prípadoch, kde pôvodná metóda pravdepodobnostný výstup neposkytuje.

Stabilita riešenia a neistota priradenia

Pre pohľady, kde sa volí počet segmentov K_v , sa kandidátne riešenia porovnávajú na základe stability pri prevzorkovaní a primeraných perturbáciách. Výber K_v sa robí konzervatívne: preferuje sa riešenie, ktoré je reprodukovateľné a interpretovateľné. Ak je segmentácia prevzatá (napr. fixné K z predchádzajúcej štúdie), Stage 2 ju neprepisuje, ale musí ju aspoň stabilizovať a kvalitatívne diagnostikovať, aby bola kompatibilná s ďalšími etapami.

Stage 2 zabezpečí odlíšenie jadra profilu (CORE) a hraničných prípadov (BOUNDARY) na základe dostupnej neistoty. Pri pravdepodobnostných modeloch sa využíva priamo $P^{(v)}$; pri tvrdých segmentáciách sa využijú doplnkové miery $u_i^{(v)}$ a/alebo $p_i^{(v)}$. Pointa je rovnaká: segmentácia sa neprezentuje ako jedna kategória a pevný typ pre všetkých, ale ako štruktúra s explicitne vyznačenými nejednoznačnými priradeniami.

Výstupy

Stage 2 je ukončený vtedy, keď je každý pohľad spracovaný do jednotnej podoby výsledkov, ktorá je pripravená na integráciu a prípadné váženie. Praktickým výstupom Stage 2 sú preto vždy:

- **Materializované reprezentácie používateľa** reprezentovaná vektormi charakteristík podľa kontraktu zo Stage 1. Tieto reprezentácie sa vytvoria len pre používateľov, pre ktorých je daný pohľad použiteľný; preto sa súčasne pre každý pohľad doplní aj **použiteľnosť a kvalita** na úrovni používateľa, t. j. hodnoty $m_{i,v}$ a $q_{i,v}$. Tým sa jednoznačne určí, kto je v pohľade pokrytý, a zároveň sa zachytí, či ide o robustné alebo hraničné pozorovania.
- **Výsledok segmentácie** v podobe informácie o pokrytí, kvalite a neistote – ak metóda poskytuje pravdepodobnostné priradenia, výstupom je matica $P^{(v)}$, ak ide o segmentáciu s tvrdým priradením, výstupom je priradenie doplnené o štandardizovanú informáciu o neistote – buď vo forme resamplingových pseudo-pravdepodobností alebo vo forme používateľsky špecifickej miery istoty.
- **Granularita K_v a súhrnná stabilita riešenia**, teda miera reprodukovateľnosti profilov pri prevzorkovaní alebo primeraných perturbáciách.
- Na úrovni používateľov sa napokon určí aj rozlíšenie **CORE/BOUNDARY** v rámci pohľadu, aby bolo zrejmé, kde je priradenie robustné a kde ide o prechodové alebo nejednoznačné prípady.

Stage 3: Integrácia pohľadov a konštrukcia spoločného priestoru

Stage 3 je integračná etapa, v ktorej sa výstupy pohľadov pripravené v Stage 2 spoja do jednotného, porovnateľného opisu používateľa. Jej cieľom je skombinovať materializované reprezentácie, segmentačné výstupy a informácie o ich neistote tak, aby vznikol spoločný priestor, v ktorom je možné konzistentne opísať používateľov aj pri neúplnosti jednotlivých zdrojov. Stage 3 zároveň zavádza váženie pohľadov tak, aby integrácia zohľadnila pokrytie, kvalitu a stabilitu – teda aby sa opierala o to, čo sa v jednotlivých pohľadoch ukázalo ako spoľahlivé.

Rozdelenie pohľadov

Pre každý pohľad v sú k dispozícii: používateľské reprezentácie $r_i^{(v)}$, použiteľnosť a kvalita ($m_{i,v}$, $q_{i,v}$), segmentačný výstup (v konečnom dôsledku pravdepodobnostný), a stabilizované zhrnutie riešenia ($stab_v$ a K_v). Keďže pohľady môžu mať rôznu povahu, Stage 3 najprv stanoví, aká časť pohľadového výstupu vstupuje do integrácie: pohľad prispieva buď priamo svojou reprezentáciou $r_i^{(v)}$, alebo príslušnosťami k profilom (pravdepodobnostnými či pseudo-pravdepodobnostnými), prípadne kombináciou, ak to zvyšuje interpretovateľnosť.

Stage 3 pripúšťa, že nie všetky pohľady musia v každom behu priamo vstupovať do konštrukcie spoločného priestoru. Preto sa zavádza flexibilné rozdelenie:

- V_{int} pohľady – sa použijú na integráciu a tvorbu spoločného priestoru,
- V_{tri} pohľady – sa v danom behu ponechajú bokom a použijú sa triangulačne, t. j. na porovnanie a diagnostiku riešení odvodených z integračných pohľadov.

Tento režim má praktický význam: umožňuje budovať riešenie z vybranej sady zdrojov a zároveň mať pripravený mechanizmus, ako ho porovnať s ďalším pohľadom, ktorý sa na jeho vzniku nepodieľal. Vnútoraná triangulácia tým získava formálne miesto už v Stage 3, pričom nezávislé overovanie na premenných mimo zhľukovania ostáva vyhradené pre Stage 4.

Váženie pohľadov

V ďalšom kroku sa určujú váhy, ktoré riadia, do akej miery jednotlivé pohľady prispievajú do integrácie. Najprv sa každému pohľadu priradí globálna váha w_v , ktorá vyjadruje, nakoľko je daný pohľad spoľahlivým zdrojom signálu v rámci datasetu. Táto váha sa odvodí z výstupov Stage 2 – najmä zo stability riešenia a z miery pokrytia a kvality. Následne sa váha spresní na úroveň konkrétneho používateľa. Pre každého používateľa a každý pohľad sa určí používateľská váha príspevku nasledovne:

- ak používateľ v danom pohľade nemá použiteľné dáta ($m_{i,v} = 0$), pohľad k nemu neprispieva,
- ak používateľ dáta má ($m_{i,v} = 1$), príspevok pohľadu sa zmenšuje alebo zväčšuje podľa kvality $q_{i,v}$: vyššia kvalita znamená väčší príspevok, nižšia kvalita menší príspevok,
- výsledná používateľská váha sa teda skladá z globálnej spoľahlivosti pohľadu w_v , dostupnosti pre používateľa $m_{i,v}$ a kvality $q_{i,v}$.

$$\text{váha príspevku používateľa} = w_v \times m_{i,v} \times q_{i,v} \quad (19)$$

Tým sa integrácia prirodzene prispôsobí neúplnosti dát: používateľ nie je penalizovaný tým, že nemá všetky pohľady; jeho reprezentácia sa opiera o dostupné a dostatočne kvalitné zdroje a ich príspevok je primeraný ich spoľahlivosti.

Konštrukcia spoločného priestoru

Po zjednotení formátu a určení váh Stage 3 skonštruje spoločný priestor. Každému používateľovi sa priradí integrovaná reprezentácia z_i , ktorá vznikne ako vážená kombinácia príspevkov integračných pohľadov. Metodicky je podstatné, že ide o **neskorú fúziu výstupov**: integrujú sa už stabilizované pohľadové podpisy a segmentačné informácie, nie surové dáta. Váženie zabezpečí, že pohľady s vyššou stabilitou a lepším pokrytím majú primerane väčší vplyv, zatiaľ čo pohľady so slabým signálom alebo nízkou kvalitou sa premietnu len obmedzene. Stage 3 zároveň zachová auditovateľnosť: pre konkrétneho používateľa je možné spätne ukázať, ktoré pohľady k jeho integrácii prispeli a v akej miere.

Keďže multi-view integrácia je citlivá na to, ktoré pohľady sa použijú, Stage 3 explicitne umožňuje spúšťať integráciu opakovane pre rôzne podmnožiny pohľadov. Cieľom je získať diagnostiku robustnosti a zdrojov konvergencie. V minimálnom režime sa uvažujú najmä:

- riešenia typu leave-one-out, kde sa jeden pohľad dočasne vynechá a použije sa triangulačne,

- single-view baseline, ktoré ukázu, čo prináša každý pohľad samostatne,
- vybrané kombinácie pohľadov tam, kde sa očakáva konvergencia alebo komplementarita.

Táto cirkulácia vytvára priamy most k neskoršiemu hodnoteniu rozporov: ak sa persona objaví len v určitých kombináciách, je to informácia o tom, ktoré zdroje ju skutočne nesú a kde môžu byť limity dané kvalitou alebo pokrytím.

Ak je cieľom tvoriť finálne osoby naprieč pohľadmi, Stage 3 vykoná segmentáciu v spoločnom priestore z_i a výstup reportuje s explicitnou neistotou, preferenčne formou pravdepodobnostného priradenia; ak sa použije metóda s tvrdým priradením, doplní sa neistota analogicky ako v Stage 2 (napr. resamplingovou reprodukovateľnosťou). V súlade so stability-first filozofiou sa aj tu rozlišuje jadro osoby a hraničné prípady (CORE/BOUNDARY), aby bolo zrejmé, ktoré priradenia sú robustné a ktoré predstavujú prechodové typy.

Pohľadové charakteristiky person

Stage 3 ku každej finálnej persone doplní stručný, deskriptívny opis naprieč pohľadmi. Pre integračné pohľady sa zhrnú typické hodnoty reprezentácií aj typické príslušnosti k pohľadovým profilom. Zároveň sa pre triangulačné pohľady, ktoré boli v danom behu ponechané bokom, uvedie, ako sa v nich daná osoba prejavuje – ako doplnková perspektíva k tomu istému segmentu používateľov.

Takto vzniknuté pohľadové podpisy umožnia oddeliť tri situácie, ktoré sa v multi-view nastavení prirodzene objavujú. Ak sa osoba prejaví podobne aj v ďalších pohľadoch, ide o konvergenciu a opis získava väčšiu oporu naprieč zdrojmi. Ak pohľady prinášajú odlišné, no navzájom kompatibilné informácie, ide o komplementaritu – pohľady sa dopĺňajú a spresňujú interpretáciu bez toho, aby si odporovali. Ak sa však objaví nezhoda, ktorá nie je vysvetliteľná rozdielnou rolou pohľadov, popisy slúžia ako východisko pre systematickú diagnostiku v Stage 4 (pokrytie, kvalita, neistota, časové ukotvenie, kontext a citlivosť na kombinácie pohľadov).

Zároveň sa v tejto fáze zámerne neuzatvára otázka validity person. Stage 3 poskytuje prehľad a porovnanie naprieč pohľadmi, teda podklady pre trianguláciu, no nezávislé overovanie sa realizuje až v nasledujúcej etape na premenných vyhradených mimo zhľukovania.

Výstupy

Stage 3 je ukončený vtedy, keď existuje integrovaný opis používateľov v spoločnom priestore a keď je transparentné, ako k nemu jednotlivé pohľady prispeli a ako sa riešenie správa pri alternatívnych kombináciách pohľadov. Praktickým výstupom Stage 3 sú:

- spoločný priestor používateľov – integrované reprezentácie z_i pre používateľov, ktorí majú aspoň jeden použiteľný integračný pohľad,
- váhy integrácie – globálne váhy pohľadov w_v a používateľsky špecifické váhy odvodené zo stability, pokrytia a kvality,
- finálne osoby v spoločnom priestore – segmentačný výsledok (preferenčne s pravdepodobnostným priradením), vrátane zvolenej granularít a súhrnnej stability,
- CORE/BOUNDARY na úrovni person – označenie robustných exemplárov a hraničných prípadov,
- pohľadové opisy person – deskriptívne zhrnutia pre integračné aj triangulačné pohľady, vrátane toho, ktoré zdroje osobu nesú a ktoré ju len dopĺňajú,
- porovnania naprieč kombináciami pohľadov – sada alternatívnych behov (napr. leave-one-out a vybrané podmnožiny), ktoré dokumentujú robustnosť person a zdroje konvergenzie alebo rozdielov.

Stage 4: Nezávislé overovanie person

Stage 4 je validačná a interpretačná etapa. Nadväzuje na osoby zo Stage 3, no pracuje s odlišným cieľom: neoptimalizuje segmentáciu, ale systematicky vyhodnocuje, čo je v osobách robustné, čo je len komplementárny doplnok a kde sa objavujú rozpory, ktoré si vyžadujú opatrný výklad. Zároveň Stage 4 striktné oddelí dva typy evidencie: trianguláciu naprieč pohľadmi a nezávislé overovanie na premenných vyhradených mimo zhľukovania.

Vstupy a rozsah hodnotenia

Stage 4 používa tri skupiny vstupov:

- výstupy zo Stage 3: finálne osoby, CORE/BOUNDARY, spoločný priestor a pohľadové opisy person,
- výstupy zo Stage 2: informácie o pokrytí a kvalite ($m_{i,v}$, $q_{i,v}$) a stabilné zhrnutia riešení v jednotlivých pohľadoch (vrátane správania pri alternatívnych kombináciách pohľadov),
- vyhradené premenné Z zo Stage 1, ktoré sa nepoužili na tvorbu segmentov a slúžia na nezávislé overovanie (napr. retencia, výkonnostné výstupy, záťaž, férovosť, externé škály).

Cieľom kroku je zhrnúť osoby v troch rovinách: naprieč pohľadmi, mimo pohľadov použitých na segmentáciu, naprieč alternatívnymi konfiguráciami, aby sa výsledok neopieral o jedinú analytickú voľbu.

Konvergencia, komplementarita a rozpory

Stage 4 najprv vyhodnotí, do akej miery sú osoby stabilné naprieč pohľadmi. Opiera sa o pohľadové opisy a o to, ktoré pohľady boli použité integračne a ktoré triangulačne.

- Konvergencia sa konštatuje vtedy, keď sa rovnaký segment používateľov prejaví konzistentne aj v ďalších pohľadoch, pri primeranom pokrytí a kvalite. Ide o posilnenie jadra interpretácie: osoba nie je artefaktom jedného zdroja.
- Komplementarita sa konštatuje vtedy, keď pohľady prinášajú rozdielne, ale kompatibilné charakteristiky: osoba môže mať podobné výkonové výstupy ako iná, no odlišný štýl používania alebo odlišné časové vzorce. V multi-view nastavení je komplementarita očakávaná a žiaduca, pokiaľ nevedie k logickému rozporu.

Výstupom tejto časti je kompaktný prehľad toho, ktoré tvrdenia o osobe sú opreté o viac pohľadov a ktoré sú špecifické len pre jeden zdroj.

Ak sa objaví nezhoda medzi pohľadmi, Stage 4 ju najprv diagnostikuje, až potom interpretuje. Postup je konzervatívny a sleduje rovnakú logiku bez ohľadu na to, ktorý pohľad je v konflikte:

- Pokrytie a kvalita – či rozpor nevzniká preto, že pohľad je pre danú osobu slabšie pokrytý alebo nekvalitný.
- Neistota priradenia – či rozpor nie je koncentrovaný v BOUNDARY (t. j. u prechodových používateľov).
- Stabilita riešenia – či je pohľad (alebo spoločný priestor) stabilný pri prevzorkovaní a perturbáciách.
- Časové ukotvenie a kontext – či pohľady nemerajú inú fázu správania alebo iný kontext používania.
- Citlivosť na konfiguráciu pohľadov – či rozpor pretrváva aj pri alternatívnych kombináciách (napr. leave-one-out).

Až po tejto diagnostike sa rozhodne, či ide o merací artefakt, kontextový efekt, komplementaritu, alebo skutočnú heterogenitu, ktorá si vyžaduje opatrný popis (napr. že osoba má vnútorné podtypy).

Nezávislé overovanie a robustnosť

Druhou, striktnejšou časťou Stage 4 je nezávislé overovanie na premenných, ktoré neboli použité na tvorbu segmentov. Cieľom je ukázať, že osoby sa viažu aj na externé vlastnosti alebo výstupy a nie sú len opisom vlastných vstupných črt.

Overovanie sa realizuje tak, aby nebolo citlivé na tvrdé priradenie:

- výsledky sa reportujú prednostne na CORE (kde je segmentácia najistejšia),
- doplnkovo aj s vážením podľa príslušnosti (ak sú k dispozícii pravdepodobnosti),
- s kontrolou relevantných kovariátov, ak by mohli vysvetliť rozdiely lepšie než samotná osoba.

Výstupom nie je len konštatovanie rozdielu, ale aj jeho veľkosť a interpretácia v kontexte pokrytia a neistoty.

Stage 4 uzatvára interpretáciu tým, že odliší:

- robustné jadro osoby – tvrdenia, ktoré sú podporené konvergenciou naprieč pohľadmi a zároveň sa potvrdia nad Z alebo pretrvávajú pri alternatívnych konfiguráciách,
- metódo-závislú vrstvu – tvrdenia, ktoré sú citlivé na výber pohľadov, váhy alebo granularitu a majú byť formulované opatrne.

Výstupy

Stage 4 je ukončený vtedy, keď je jasné, ktoré aspekty osoby sú konvergentne podporené, ktoré sú komplementárnym doplnením a ktoré treba interpretovať opatrne pre možné rozpory alebo obmedzenia dát. Praktickým výstupom Stage 4 sú:

- triangulačný súhrn osoby – prehľad konvergenzie a komplementarity naprieč pohľadmi, vrátane toho, ktoré pohľady osobu nesú a ktoré ju dopĺňajú,
- diagnostika rozporov – zdokumentované príčiny nezhôd (pokrytie, kvalita, neistota, čas, kontext, citlivosť na kombinácie),
- nezávislé overenie nad vyhradenými kontrolnými premennými – výsledky testov/porovnaní na vyhradených premenných mimo zhľukovania (prioritne CORE, doplnkovo vážené analýzy),
- rozdelenie záverov na robustné jadro a metódo-závislú vrstvu,
- odporúčania pre interpretáciu a prenos – čo je možné bezpečne prekladať do aplikačných implikácií a aké sú hranice generalizácie.

Navrhnutá metodika formuluje multi-view profilovanie ako kontrolovaný, auditovateľný proces, v ktorom sa heterogénne zdroje najprv zjednotia na úrovni kontraktov a porovnateľnosti, následne sa v každom pohľade vytvoria stabilné pohľadové profily s explicitnou neistotou, potom sa tieto výstupy integrujú do spoločného priestoru s vážením podľa kvality, pokrytia a stability, a napokon sa osoby vyhodnotia trianguláciou a nezávislým overovaním mimo zhľukovania. Dôležitým výsledkom je, že osoba nie je chápaná ako jednorazový výstup jedného modelu, ale ako štruktúra, ktorá má rozlíšené robustné jadro a hraničné prípady, a ktorej interpretácia sa opiera o konvergenciu naprieč pohľadmi, komplementárne doplnenie aj transparentnú diagnostiku rozporov. Týmto spôsobom sa dosiahne rovnováha medzi interpretovateľnosťou a praktickou použiteľnosťou na jednej strane a metodickou prísnosťou na strane druhej – najmä v situáciách, kde sú dáta neúplné, zdroje nesú odlišné typy neistoty a analytické rozhodnutia môžu výrazne ovplyvniť výsledok. V nasledujúcej prípadovej štúdii sa tento postup uplatní na konkrétnom súbore pohľadov a ukáže sa, ako jednotlivé etapy ovplyvňujú voľbu granularít, stabilitu riešení, integráciu do spoločného priestoru a následnú interpretáciu osoby.

Prípadova štúdia: Integrácia a fúzia zdrojov

Prípadová štúdia demonštruje multi-view profilovanie v dátovo ukotvenom dizajne, kde sa tri heterogénne pohľady zjednotia tak, aby sa dali ďalej integrovať neskorou fúziou a reportovať s podporou neistoty. Zmyslom procesu nie je odpovedať na otázky konkrétne otázky z oblasti správania používateľov, ale ukázať, že pri fixovaní vstupných kontraktov a pri stability-first prístupe vznikne porovnateľný a audítovateľný profil používateľa aj vtedy, keď jednotlivé pohľady majú odlišné merania, šum a chýbajúce dáta.

V prípadovej štúdii sa používajú tieto pohľady:

- V1: sebaopis (motivácia + ponorenie)
- V2: sumárna telemetria (persony z logov) – hráčske metriky odvodené z herných záznamov.
- V3: procesný pohľad (epizódy/taktiky) – získaný z event-telemetrie, kde taktiky mapujú na používateľa.

Výstupom celej case study bude harmonizovaná používateľská tabuľka, v ktorej má každý používateľ: pravdepodobnostný profil vo V1, pravdepodobnostný profil vo V2, procesné črty z V3, a masku dostupnosti a kvalitu po pohľadoch – čo je predpokladom transparentnej neskorej fúzie v spoločnom priestore.

Špecifikácia pohľadov a harmonizácia používateľských reprezentácií

Stage 1 nadväzuje na metodiku rozpracovanú v predchádzajúcich kapitolách a v zmysle „stability-first“ filozofie plní predovšetkým špecifikačnú a harmonizačnú funkciu. Prakticky to znamená, že veľká časť práce, ktorá sa v abstraktnej pipeline realizuje práve v Stage 1, už bola vykonaná samostatne v rámci jednotlivých analytických línií a v tejto case study sa na ňu explicitne nadväzuje a zjednocuje sa do spoločného rámca.

Typy zdrojov a časové ukotvenie. V prípadovej štúdii sa pracuje s tromi dátovými pohľadmi, ktoré sa líšia mierou subjektivity, granularitou aj časovým ukotvením.

- Prvý pohľad (V1) tvoria sebaopisné dotazníky – Bartleho typológia a dotazník ponorenia (ITQ). Tieto údaje poskytujú priamo používateľskú perspektívu a v spracovaní sú reprezentované pravdepodobnostnými členstvami v segmentoch. Zber dotazníkov prebiehal priebežne od roku 2024 do októbra 2025, takže ide o prierezové meranie s dlhším zberovým obdobím.
- Druhý pohľad (V2) je založený na agregovanej telemetrii a reprezentuje typológiu správania odvodenú zo súhrnných herných ukazovateľov. Aj tu sa pracuje s pravdepodobnostným výstupom segmentácie.
- Tretí pohľad (V3) zachytáva procesnú stránku správania cez taktiky. Pre každého používateľa sa najprv z eventovej telemetrie odvodí čas strávený v jednotlivých taktikách odvodených v predošlých kapitolách, ten sa následne normalizuje celkovou dĺžkou hry a vznikne vektor podielov času v taktikách. Tento vektor sa potom segmentuje Gaussovým zmiešaným modelom, pričom výstupom sú posteriórne pravdepodobnosti členstva v taktických segmentoch.

Časové ukotvenie telemetrie (V2 a V3) je sezónne: údaje boli zbierané v mesiacoch máj až október. Keďže dotazníky (V1) vznikali v širšom časovom rozpätí a telemetria je viazaná na pevné okno, nepoužíva sa jemné párovanie medzi zberom údajov, ale dizajn sa interpretuje ako prierezový: sebaopis poskytuje relatívne stabilnú charakteristiku používateľa v období zberu, zatiaľ čo telemetria opisuje správanie v definovanom sezónnom okne.

Výstupové kontrakty reprezentácie používateľa. Stage 1 formálne určuje, akú formu má mať reprezentácia používateľa v danom pohľade. V tejto case study je výstupným kontraktom najmä pravdepodobnostné členstvo používateľa v pohľadových segmentoch:

$$p_i^{(v)} \in [0,1]^{K_v}, \sum_{k=1}^{K_v} p_{ik}^{(v)} = 1, \quad (20)$$

ktoré sa v Stage 2 materializuje pre všetkých používateľov, pre ktorých je pohľad dostupný. Pre V1 (dotazníky) je reprezentácia používateľa priamo daná vektorom (*BITI_k0*, *BITI_k1*, *BITI_k2*), pre V2 (agregovaná telemetria) vektorom (*anchor_k0*, *anchor_k1*, *anchor_k2*, *anchor_k3*, *anchor_k4*). V3 (taktiky) má dvoj krokový kontrakt: najprv sa pre používateľa vytvorí vektor podielov času stráveného v jednotlivých taktikách (čas v sekundách normalizovaný dĺžkou hry) a následne sa tento vektor používa na odvodenie pravdepodobnostného členstva (*tact_k0*, *tact_k1*, *tact_k2*, *tact_k3*, *tact_k4*, *tact_k5*), ktoré je už priamo kompatibilné s neskorou fúziou.

Dostupnosť dát a prekryvy pohľadov. Pred ďalším spracovaním sa na úrovni používateľa zafixovala dostupnosť jednotlivých pohľadov a vyčíslili sa ich prekryvy (Tab. 50). Dostupnosť sa formalizuje binárnou maskou $m_{i,v} \in \{0,1\}$, kde $m_{i,v} = 1$ znamená, že používateľ *i* má k dispozícii príslušný pohľad *v*. V tejto case study platí pravidlo: chýbajúci blok hodnôt v danom pohľade znamená, že pohľad pre používateľa neexistuje (napr. nebol vyplnený dotazník), nejde teda o dodatočné vyradenie z dôvodu nízkej kvality. Základná populácia U^* obsahuje používateľov, pre ktorých existuje aspoň jeden z pohľadov (V1–V3). V dátach sa vyskytol jeden záznam bez pokrytia (chýbajú V1 aj V2 aj V3); tento záznam sa do U^* nezaraďuje.

Tab. 50 Pokrytie pohľadov a prekryvy (U^*).

Ukazovateľ	Počet	Podiel z U^*
U^* (aspoň jeden pohľad)	246	100.0%
V1 = BITI (dotazníky)	175	71.1%
V2 = anchor (telemetria)	156	63.4%
V3 = tact (taktiky)	150	61.0%
$V1 \cap V2 \cap V3$	85	34.6%
len V1	90	36.6%
len V2	6	2.4%
len V3	0	0.0%
$V2 \cap V3$ bez V1	65	26.4%

Štruktúra chýbania nie je symetrická: taktický pohľad (V3) je v tejto vzorke podmnožinou telemetrie (V2), t. j. každý používateľ s taktikami má zároveň anchor profil. Naopak, dotazníkový pohľad (V1) je dostupný nezávisle len pre časť populácie. Táto asymetria priamo určuje, na akej podmnožine používateľov má zmysel porovnávať pohľady a ako treba v ďalších krokoch interpretovať rozdiely: neskorá fúzia musí rešpektovať nerovnaké pokrytie a pracovať s maskou $m_{i,v}$ ako so základnou podmienkou porovnateľnosti.

Chýbajúce hodnoty v blokoch V1–V3 znamenajú, že daný pohľad pre používateľa neexistuje (napr. nebol vyplnený dotazník), nie že by bol dodatočne vyradený pre nízku kvalitu. V dátach sa zároveň ukazuje typická štruktúra pokrytia: taktický pohľad je podmnožinou telemetrie (používateľ s taktikami má zároveň telemetriu), kým dotazníkový pohľad je dostupný nezávisle pre časť populácie.

Kvalita pohľadu sa formalizuje veličinou $q_{i,v} \in [0,1]$, ktorá vyjadruje mieru spoľahlivosti a istoty reprezentácie používateľa v danom pohľade. Keďže v tejto case study sú výstupy pohľadov reprezentované pravdepodobnostným členstvom $p_i^{(v)}$ v segmentoch, kvalita sa operacionalizuje ako

istota priradenia. Ako základná, jednoducho interpretovateľná voľba sa používa maximálna posteriórna pravdepodobnosť

$$q'_{i,v} = \max_k p_{ik}^{(v)}, \quad (21)$$

ktorá je vysoká pri jednoznačnom priradení a nízka pri rozloženej príslušnosti naprieč segmentmi. Pri potrebe jednotnej škály naprieč rôznymi K_v sa táto veličina preškáluje do intervalu $[0,1]$ vzťahom

$$q_{i,v} = \frac{q'_{i,v} - 1/K_v}{1 - 1/K_v}. \quad (22)$$

V dotazníkovom pohľade (V1) sa zároveň používa binárny indikátor jadra (CORE) odvodený z prahu 0.75, ktorý slúži na odlíšenie jadrových prípadov od hraničných:

$$\text{core}_{i,1} = \mathbb{1}[q'_{i,1} \geq 0.75]. \quad (23)$$

Takto zadefinované $m_{i,v}$ a $q_{i,v}$ tvoria základ pre neskorú fúziu a pre interpretáciu prípadných rozdielov medzi pohľadmi: rozpory sa posudzujú s ohľadom na dostupnosť pohľadu a na istotu, s akou daný pohľad používateľa charakterizuje.

Rámec triangulácie a riešenia rozporov. V použitých dátach je porovnateľnosť pohľadov daná najmä štruktúrou pokrytia (Tab. 1): všetky tri pohľady sú dostupné pre 85 používateľov, pričom taktický pohľad V3 je podmnožinou V2 (V3 existuje pre 150 používateľov a vždy spolu s V2). Z toho vyplýva, že triangulácia bude mať dve prirodzené úrovne:

- V2 vs. V3 sa hodnotí na väčšej spoločnej množine ($N = 150$) a slúži ako hlavný test kompatibility telemetrie a procesnej vrstvy,
- V1 vs. (V2, V3) sa hodnotí iba na prieniku všetkých troch pohľadov ($N = 85$), kde sa sebaopis interpretuje ako doplnková perspektíva k správaniu.

Aby sa nezhody nezamieňali s artefaktmi, porovnania sa budú v Stage 4 robiť vždy v režime „najprv pokrytie, potom istota“. Prakticky to znamená, že medzi pohľadmi sa porovnávajú iba tí používatelia, ktorí majú oba relevantné pohľady ($m_{i,v} = 1$ pre príslušné v), a výsledky sa budú čítať oddelene pre **jadrové** a **hraničné** prípady podľa kvality $q_{i,v}$. Ako jadro sa v tejto case study používa: pre V1 indikátor CORE pri prahu 0.75 a pre V2 označenie stability „strong“; pri V3 sa istota odvodí priamo z rozdelenia členstva (napr. $\max p$ alebo normalizovaná entropia). Tým sa získa jednoduché pravidlo interpretácie: ak sa nezhody koncentrujú v hraničných prípadoch (nízka istota), považujú sa primárne za dôsledok nejednoznačnosti; za „rozpor“ sa budú označovať až situácie, kde sa signály systematicky rozchádzajú aj pri vysokokonfidenčných priradeniach.

V praktickej interpretácii sa v Stage 4 budú rozlišovať tri typy vzťahov nasledovne:

- **Konvergencia** - v prieniku pohľadov sa ukáže konzistentná štruktúra najmä u jadrových prípadov (napr. stabilné priradenia vo V2 majú predvídateľné vzory členstva vo V3, prípadne sa podobne správajú aj vo V1 tam, kde je dostupný).
- **Komplementarita** - V3 sa bude čítať ako „procesná špecifikácia“ V2 (t. j. rovnaký telemetrický typ sa môže v taktickom pohľade diferencovať na viac režimov), zatiaľ čo V1 sa očakáva ako vysvetľujúca vrstva preferencií/ponorenia, ktorá nemusí kopírovať segmenty správania, ale môže s nimi byť kompatibilná cez nezávislé premenné.
- **Rozpory** - ak sa pri vysokokonfidenčných prípadoch objaví systematický nesúlad, diagnostika bude postupovať: skontroluje sa, či nejde o efekt pokrytia (porovnanie sa robí len na prieniku), či nejde o efekt nízkej istoty (q), následne sa zohľadní časové ukotvenie (V1: 2024–10/2025 vs. V2/V3: máj–október) a až potom sa použijú premenné vyhradené pre nezávislé overovanie (demografia, expozícia, preferencie a žánrové indikátory) na posúdenie plausibility a vysvetlenie.

Množina premenných pre nezávislé overovanie. Na tento účel sa vopred vyčlenila množina premenných, ktoré sa nepoužijú na tvorbu segmentov – demografické a preferenčné premenné v nasledovnej štruktúre z dotazníkov V1:

- demografia: *Age, Gender*
- expozícia: *Game_play_hours, Game_play_hours_no_mobile*
- preferencie a štýl: *loved_type, multi_single*
- žánrové indikátory: *play_**

Materializácia pohľadov a stabilné profilovanie používateľov

Veľká časť profilovania bola realizovaná už v predchádzajúcich kapitolách samostatne pre jednotlivé pohľady preto je táto sekcie zúžená na zmaterializovanie výstupov, výpočet pokrytia $m_{i,v}$, odvodenie kvality $q_{i,v}$. Hoci výstupom pohľadu zostávajú pravdepodobnostné členstvá, pre účely prehľadných súhrnov a porovnaní sa doplní aj dominantné priradenie $z_i^{(v)}$ a rozlíšenie CORE/BOUNDARY, aby bolo zrejmé, kde je priradenie robustné a kde ide o prechodové prípady.

Materializácia reprezentácií a pokrytia. Základná populácia U^* obsahuje 246 používateľov s aspoň jedným pohľadom. Pre každý pohľad sa reprezentácia používateľa materializuje v kontraktovej podobe pravdepodobnostných členstiev $p_i^{(v)}$, pričom dostupné sú nasledovné pohľady:

- V1 (BITI; dotazníky): $N_1 = 175, K_1 = 3$
- V2 (anchor; telemetria): $N_2 = 156, K_2 = 5$
- V3 (tact; taktiky): $N_3 = 150, K_3 = 7$

Pohľadové profilovanie a počet segmentov. Na úrovni dominantného segmentu $z_i^{(v)}$ sú veľkosti segmentov v jednotlivých pohľadoch:

- V1 (BITI; $K = 3, N = 175$): $k_0 = 79, k_1 = 56, k_2 = 40$
- V2 (anchor; $K = 5, N = 156$): $k_0 = 31, k_1 = 51, k_2 = 2, k_3 = 69, k_4 = 3$
- V3 (tact; $K = 7, N = 150$): $k_0 = 13, k_1 = 2, k_2 = 26, k_3 = 2, k_4 = 4, k_5 = 6, k_6 = 97$

Toto zhrnutie slúži len na kontrolu granularít a pripravenosť na Stage 3–4; interpretácia významu pohľadových segmentov bola riešená v prechádzajúcich kapitolách, globálny pohľad bude vytvorený v Stage3-4.

Stabilita riešenia a neistota priradenia. Stage 2 zabezpečuje pri každom pohľade dostupnosť jednotná informácia o neistote priradenia. V tejto case study sa istota odvodzuje primárne z pravdepodobnostného výstupu cez $q'_{i,v} = \max_k p_{ik}^{(v)}$ (prípadne normalizované na $[0, 1]$). Zároveň sa využívajú pohľadovo špecifické indikátory jadra:

- V1 (BITI): CORE je definované prahom 0.75; v dátach je v jadre 140/175 (80.0%) používateľov.
- V2 (anchor): kvalita je doplnená štítkom stability; „strong“ má 130/156 (83.3%), zvyšok tvorí „medium“ (14) a „weak“ (12).
- V3 (tact): priradenia sú podľa posterii prakticky jednoznačné (maximálna pravdepodobnosť je typicky veľmi vysoká), preto sa CORE/BOUNDARY v tejto fáze opiera najmä o $q'_{i,3}$ (resp. entropiu) a prípadné hraničné prípady sa identifikujú až pri diagnostike vzťahov medzi pohľadmi.

Výsledkom Stage 2 je, že segmentácia v každom pohľade je prezentovaná ako riešenie s explicitne evidovanou neistotou a s vyznačeným jadrom (CORE) a prechodovými prípadmi (BOUNDARY), ktoré sú dôležité pri neskorej fúzii a pri hodnotení konvergencie/komplementarity (Tab. 51).

Tab. 51 Zhrnutie materializovaných pohľadov a pohľadového profilovania (Stage 2).

Pohľad	Reprezentácia používateľa (kontrakt)	K _v	N _v	Veľkosti segmentov podľa $z_i^{(v)} = \arg \max_k p_{ik}^{(v)}$	Istota/kvalita ($q'_{i,v}$)	CORE/BOUNDARY pravidlo	CORE (počet / podiel)
V1 (BITI; dotazníky)	$p_i^{(1)} = (\text{BITI_k0}, \text{BITI_k1}, \text{BITI_k2})$	3	175	$k_0 = 79, k_1 = 56, k_2 = 40$	$q'_{i,1} = \max_k p_{ik}^{(1)}$	CORE, ak ($q'_{i,1} > 0.75$)	140 / 80.0%
V2 (anchor; telemetria)	$p_i^{(2)} = (\text{anchor_k0}, \dots, \text{anchor_k4})$ označenie stability	5	156	$k_0 = 31, k_1 = 51, k_2 = 2, k_3 = 69, k_4 = 3$	$q'_{i,2} = \max_k p_{ik}^{(2)}$ stability: weak/medium/strong	CORE, ak stability = strong	130 / 83.3% (medium = 14, weak = 12)
V3 (tact; taktiky)	$p_i^{(3)} = (\text{tact_k0}, \dots, \text{tact_k6})$ GMM nad podielmi času v taktikách	7	150	$k_0 = 13, k_1 = 2, k_2 = 26, k_3 = 2, k_4 = 4, k_5 = 6, k_6 = 97$	$q'_{i,3} = \max_k p_{ik}^{(3)}$ $\min(q') = 0.9996$	prakticky všetko CORE (napr. ($q'_{i,3} > 0.95$))	150 / 100.0%

Stage 2 týmto krokom zjednocuje pohľadové výstupy do spoločnej, integračne kompatibilnej podoby: všetky tri pohľady poskytujú pravdepodobnostné členstvá $p_i^{(v)}$, takže neistota je v Stage 2 dostupná priamo cez $q'_{i,v} = \max p$. V3 je v tejto vzorke takmer deterministický (minimálna maximálna posteriorná pravdepodobnosť je približne 0.9996), preto sa CORE/BOUNDARY rozdiely budú prakticky prejavovať najmä vo V1 a vo V2.

Integrácia pohľadov a konštrukcia spoločného priestoru

Rozdelenie pohľadov. V použitej vzorke je štruktúra pokrytia výrazne asymetrická (Tab. 1). U* obsahuje 246 používateľov, pričom V1 (dotazníky) má 175 používateľov, V2 (telemetria/anchor) 156 a V3 (taktiky) 150. Zároveň platí, že V3 je podmnožinou V2 (taktiky existujú iba tam, kde existuje telemetria), kým V1 je dostupný nezávisle len pre časť populácie. Táto štruktúra prirodzene vedie k dvom integračným režimom:

- Hlavný integračný beh: $V_{\text{int}} = \{V2, V3\}$, $V_{\text{tri}} = \{V1\}$, kde platí, že V3 (taktiky) je podmnožinou V2 (telemetria), takže získame najväčší behaviorálny prienik bez toho, aby riešenie bolo citlivé na to, či používateľ vyplnil dotazník. Integračná množina má 156 používateľov (všetci s V2), z toho 150 má aj V3.
- Citlivostný beh: $V_{\text{int}} = \{V1, V2, V3\}$ iba na prieniku 85 používateľov s cieľom kontroly, ako sa integrácia správa, keď majú všetci používatelia rovnaké pokrytie (bez rozlišovania na chýbajúci pohľad vs. odlišný typ používateľa).

Váženie pohľadov sa opiera o informácie, zo Stage 2: globálnu spoľahlivosť pohľadu odvodenú z pokrytia a zo stability/istoty riešenia (Tab. 52) a používateľsky špecifickej istotu, ktorá zachytáva, či je priradenie používateľa v danom pohľade jednoznačné.

Tab. 52 Globálne váhy pohľadov odvodené z pokrytia a stability (Globálna stabilita: V1 = podiel CORE0.75, V2 = priemer mapovania stability weak/medium/strong - 0.5/0.75/1.0, V3 = priemerná normalizovaná istota z posteríí).

Pohľad	K _v	N _v	Pokrytie N _v / U*	Globálna stabilita	Priem. kvalita $q_{i,v}$	Globálna váha w_v
V1 (BITI)	3	175	0.711	0.800	0.801	0.569
V2 (anchor)	5	156	0.634	0.939	0.864	0.596
V3 (tact)	7	150	0.610	1.000	1.000	0.610

Na úrovni používateľa sa príspevok pohľadu určí ako

$$a_{i,v} = w_v \cdot m_{i,v} \cdot q_{i,v}, \quad (24)$$

pričom $m_{i,v} = 0$ automaticky znamená nulový príspevok pohľadu. Aby bola reprezentácia porovnateľná naprieč používateľmi s rôznym pokrytím, príspevky sa normalizujú iba cez integračné pohľady:

$$\alpha_{i,v} = \frac{a_{i,v}}{\sum_{u \in V_{\text{int}}} a_{i,u}}. \quad (25)$$

Tým sa zabezpečí, že používateľ nie je penalizovaný za chýbajúci pohľad; jeho spoločný opis sa opiera o to, čo je dostupné, a v primeranej miere zohľadňuje istotu priradenia.

Konštrukcia spoločného priestoru vychádza z toho, že v každom pohľade už existuje pravdepodobnostný vektor členstva. V hlavnom integračnom režime (V2+V3) sa preto pre používateľa vytvorí integrovaná reprezentácia ako vážené spojenie pohľadových členstiev:

$$z_i = [\alpha_{i,2} p_i^{(2)}; \alpha_{i,3} p_i^{(3)}], \quad (26)$$

kde $p_i^{(2)} = (\text{anchor_k0}, \dots, \text{anchor_k4})$ a $p_i^{(3)} = (\text{tact_k0}, \dots, \text{tact_k6})$. Vektor z_i tak tvorí spoločný priestor, ktorý je priamo auditovateľný – pre konkrétneho používateľa je možné spätne ukázať, či prispel iba V2 (napr. v prípadoch bez V3) alebo aj V3, a s akou váhou. V citlivostnom režime na prieniku (V1+V2+V3) sa analogicky konštruuje z_i zo všetkých troch pohľadov, pričom dotazníkový vektor $p_i^{(1)}$ sa stáva plnohodnotnou súčasťou integračného podpisu.

Pohľadové charakteristiky person. V oboch integračných nastaveniach sa počet komponentov GMM volil konzervatívne kombináciou informačného kritéria a požiadavky na minimálnu veľkosť persony. Kandidátne riešenia sa porovnali podľa BIC, pričom sa súčasne kontrolovalo, či nevznikajú mikro-klastre, ktoré sú pre reportovanie person nevhodné.

V behaviorálnom spoločnom priestore V2+V3 BIC klesá pri prechode z $K = 2$ až po $K = 6$ a dosahuje minimum pri $K = 6$ (BIC = -13393.9). Pri $K = 4$ a $K \geq 7$ sa objavujú veľmi malé klastre, čo by viedlo k neinterpretovateľným alebo nestabilným personám. Riešenia $K = 5$ a $K = 6$ už spĺňajú požiadavku na minimálnu veľkosť segmentu ($n = 11$, resp. 13), pričom $K = 6$ poskytuje lepší kompromis medzi fitom a granularitou bez vzniku mikro-klastrov, pre V2+V3 sa preto zvolilo $K = 6$.

V rozšírenom spoločnom priestore V1+V2+V3 na prieniku všetkých pohľadov ($N = 85$) je situácia odlišná najmä v dôsledku menšej vzorky. BIC klesá od $K = 2$ po $K = 4$ a minimum dosahuje pri $K = 4$ (BIC = -7342.2), pričom riešenie zároveň nevytvára malé klastre ($n = 10$). Pri $K = 5$ sa BIC výrazne zhorší a objavujú sa malé segmenty, preto sa ako najlepšia voľba podľa BIC ukázalo $K = 4$.

Podľa metodiky sa ku každej finálnej persone dopĺňa stručný, deskriptívny opis naprieč pohľadmi. V aktuálnej prezentácii sa však kvôli jednoduchšiemu sledovaniu toku zámerne kvôli jednoduchšej auditovateľnosti neprístupuje k pomenovaniu, ale používa sa označovanie založené na pohľadových podpisoch. B pre V1 (BITI), A pre V2 (anchor), T pre V3 (tact). Ak je rozdelenie v pohľade výrazne zmiešané, uvádza sa aj druhý najčastejší profil.

Persony v behaviorálnom spoločnom priestore V2+V3. V hlavnom integračnom behu (V2+V3; $N = 150$; $K = 6$) boli osoby získané segmentáciou v spoločnom priestore. Tab. 53 uvádza veľkosť persony, dominantné pohľadové podpisy V2 a V3 (vrátane druhej najčastejšej voľby, ak je relevantná) a podiel strong v anchor level ako doplnkový indikátor robustnosti V2.

Tab. 53 Persony v spoločnom priestore V2+V3 (GMM, $K = 6$, $N = 150$).

Persona	n	V2 (anchor; top1, top2)	anchor level = strong	V3 (tact; top1, top2)	max p	min max p
P0	26	A3 (80.8%), A4 (11.5%)	96.2%	T2 (100.0%)	1.000000	1.000000
P1	36	A1 (97.2%), A0 (2.8%)	75.0%	T6 (100.0%)	0.997631	0.950513
P2	13	A1 (61.5%), A0 (23.1%)	92.3%	T0 (100.0%)	1.000000	1.000000
P3	36	A3 (100.0%)	80.6%	T6 (100.0%)	1.000000	1.000000
P4	25	A0 (96.0%), A3 (4.0%)	76.0%	T6 (100.0%)	0.999998	0.999938
P5	14	A1 (42.9%), A3 (28.6%)	85.7%	T5 (42.9%), T4 (28.6%)	1.000000	1.000000

Istota priradenia v tomto riešení je vysoká (maximálne posteriorné pravdepodobnosti sú prevažne blízke 1).

Persony na prieniku V1+V2+V3. V citlivostnom behu, kde sa integrujú všetky tri pohľady, sa pracuje iba na prieniku dostupnosti ($N = 85$; $K = 4$). V Tab. 54 sú osoby opäť reportované štruktúrne cez dominantné profily v každom pohľade a dopĺňa sa podiel prípadov označených ako jadro dotazníkového pohľadu (CORE pri prahu 0.75 podľa definície v Stage 2).

Tab. 54 Persony v spoločnom priestore V1+V2+V3 (GMM, $K = 4$, $N = 85$).

Persona	n	Podpis V1 (BITI; top1, top2)	BITI CORE (0.75)	Podpis V2 (anchor; top1, top2)	anchor level = strong	Podpis V3 (tact; top1, top2)	max p	min max p
P0	53	B0 (45.3%), B1 (35.8%)	69.8%	A1 (41.5%), A0 (32.1%)	83.0%	T6 (100.0%)	1.000	1.000
P1	12	B2 (41.7%), B1 (41.7%)	83.3%	A3 (100.0%)	100.0%	T2 (83.3%), T5 (16.7%)	1.000	1.000
P2	10	B0 (50.0%), B1 (30.0%)	70.0%	A1 (70.0%), A0 (20.0%)	90.0%	T0 (100.0%)	1.000	1.000
P3	10	B0 (60.0%), B2 (30.0%)	90.0%	A1 (50.0%), A 2 (20.0%)	80.0%	T4 (40.0%), T1 (20.0%)	1.000	1.000

Väzba medzi riešeniami. Keďže druhý beh používa iba prienik $N = 85$, je užitočné ukázať, ako sa jemnejšie behaviorálne riešenie (6 person) zlieva do konzervatívnejšieho trojpohľadového riešenia (4 person). Nasledujúca kontingenčná tabuľka 6 uvádza mapovanie na spoločných používateľoch.

Tab. 55 Kontingenčná tabuľka: osoby V1+V2+V3 (riadky) vs. osoby V2+V3 (stĺpce), $N = 85$.

V1+V2+V3 \ V2+V3	P0	P1	P2	P3	P4	P5
P0	0	22	0	13	18	0
P1	10	0	0	0	0	2
P2	0	0	10	0	0	0
P3	0	0	0	0	0	10

Tab. 55 ukazuje, že trojpohľadové riešenie spája časť behaviorálnych person (najmä v oblasti dominancie T6) do väčších celkov, čo je konzistentné s konzervatívnejším výberom K pri menšej vzorke. Zároveň je zrejmé, ktoré osoby sú prenesené takmer jednoznačne (napr. P2 na P2; P3 na P5), a ktoré vznikajú z kombinácie viacerých behaviorálnych person. Tieto údaje slúžia ako východisko pre Stage 4, kde sa už systematicky vyhodnotí, či ide o konvergenciu, komplementaritu, alebo o rozpory, ktoré si vyžadujú ďalšiu diagnostiku.

Nezávislé overovanie person

Stage 4 nadväzuje na Stage 3, kde sa ku každej persone vytvoril pohľadový popis (dominantné profily v integračných pohľadoch) a tým sa pripravili podklady na rozlíšenie konvergenzie, komplementarity a rozporov. V tejto case study sa Stage 4 opiera o dva získané pohľady avšak pri reálnom nasadení ich môže byť aj omnoho viac.

Konvergencia, komplementarita a rozpory. V hlavnom riešení V2+V3 sú integračné popisy v telemetrii a taktikách veľmi jednoznačné (zodpovedajú dominantným profilom v V2 aj V3), takže jadro person je dobre čitateľné už v rámci integračných pohľadov. Triangulácia sa realizuje tak, že sa pre každú osobu pozrie, ako sa prejavuje v dotazníkovom pohľade V1 tam, kde je dostupný (t. j. na prieniku s V1). Keďže V1 nie je dostupný pre všetkých v V2+V3, pri interpretácii sa explicitne uvádza aj veľkosť prieniku.

Zároveň sa oddeľuje robustné jadro od menej istých prípadov pomocou kvalitatívnych indikátorov z per-view analýz: pre V2 sa ako CORE používa anchor level = strong, pre V1 sa ako CORE používa prah 0.75 a doplnkovo sa uvádza dual-CORE (súčasne CORE vo V1 aj V2) na tom istom prieniku (Tab. 56).

Tab. 56 Triangulácia person V2+V3 dotazníkovým pohľadom V1 (na dostupnom prieniku).

Persona (V2+V3)	n	Popis V2 (top2)	Popis V3 (top2)	CORE V2 (anchor strong)	n s V1	Popis V1 (top2; len s V1)	CORE V1 (BITI_core_75; len s V1)	Dual-CORE (V1 + V2; len s V1)
P0	26	A3 (80.8%), A4 (11.5%)	T2 (100.0%)	96.2%	10	B1 (40.0%), B2 (40.0%)	80.0%	80.0%
P1	36	A1 (97.2%), A0 (2.8%)	T6 (100.0%)	75.0%	22	B0 (54.5%), B1 (27.3%)	72.7%	59.1%
P2	13	A1 (61.5%), A0 (23.1%)	T0 (100.0%)	92.3%	10	B0 (50.0%), B1 (30.0%)	70.0%	60.0%
P3	36	A3 (100.0%)	T6 (100.0%)	80.6%	13	B1 (61.5%), B0 (23.1%)	61.5%	61.5%
P4	25	A0 (96.0%), A3 (4.0%)	T6 (100.0%)	76.0%	18	B0 (50.0%), B1 (27.8%)	72.2%	61.1%
P5	14	A1 (42.9%), A3 (28.6%)	T5 (42.9%), T4 (28.6%)	85.7%	12	B0 (50.0%), B2 (33.3%)	91.7%	83.3%

V rámci Stage 4 sa pohľadové popisy čítajú v troch režimoch:

- Konvergencia sa v tomto kroku chápe predovšetkým ako fakt, že osoby majú stabilný a jednoznačný podpis v integračných pohľadoch (V2 a V3) a že triangulačný pohľad V1 sa k nim viaže konzistentne všade tam, kde je dostupný, t.j. zmysel osoby nie je opretý o jediný zdroj: tam, kde existujú dotazníkové dáta, nevzniká voči behaviorálnemu jadru náhodný alebo protirečivý obraz. Napríklad v riešení V2+V3 je osoba P2 jasne definovaná integračnými pohľadmi: v telemetrii má dominantný podpis A1 (A1 61.5% ako top1; A0 23.1% ako top2) a v taktikách je prakticky homogénna T0 (100%). Tam, kde je dostupný dotazníkový pohľad (na prieniku je pre P2 n = 10), sa k tejto osobe viaže konzistentný profil aj v V1: dominujú B0 (50%) a B1 (30%) a zároveň je podiel jadra dotazníkového pohľadu CORE V1 = 70% (a pri spoločnom jadre V1&V2 je dual-CORE = 60%). V zmysle Stage 4 to znamená, že osoba má stabilné behaviorálne jadro (V2, V3) a V1 k nej neprináša náhodný alebo protirečivý obraz, ale konzistentne sa pripája tam, kde je k dispozícii.
- Komplementarita sa prejavuje vtedy, keď triangulačný pohľad V1 pridáva informáciu, ktorá je odlišná, no kompatibilná s integračným jadrom. Typickým príkladom je situácia, keď sa v správaní objavujú podobné osoby (napr. skupiny s dominantnou taktikou T6), no V1 ich ďalej diferencuje: osoby P1/P3/P4 sa síce v procesnej vrstve prekrývajú cez T6, ale líšia sa anchor podpisom a zároveň vykazujú odlišné zloženie BITI na prieniku. Takéto rozdiely sa neinterpretujú ako konflikt, ale ako doplnenie perspektívy, ktoré spresňuje opis toho istého segmentu používateľov.
- Za rozpor sa v tejto fáze nepovažuje samotná nezhoda medzi pohľadmi. Rozpor sa konštatuje až po diagnostike, ktorá vylúči jednoduché vysvetlenia: že ide o artefakt nerovnakého pokrytia (malé n s V1 v niektorých osobách), o dôsledok rozdielnej kvality alebo neistoty (CORE vs. BOUNDARY), prípadne o citlivosť na konfiguráciu pohľadov (napr. zmena pri pridaní V1 do integrácie alebo pri leave-one-out behu). Až keď sa nezhoda udrží aj po týchto kontrolách, má zmysel interpretovať ju ako merací artefakt, kontextový efekt alebo skutočnú heterogenitu, ktorá si vyžaduje opatrný popis v ďalšej časti Stage 4.

Nezávislé overovanie a robustnosť. Citlivosť na výber pohľadov sa prezentuje pridaním V1 do integrovaného pohľadu, pričom sa pracuje len na prieniku N = 85 a zároveň sa zmení optimálna

granularita ($K = 4$). Je dôležité zdokumentovať, ktoré osoby sú robustné jadro (prenášajú sa jednoznačne) a ktoré sú skôr metódovo závislá vrstva (jemné delenie, ktoré sa pri zmene konfigurácie zlieva). Výsledky mapuje Tab. 57.

Tab. 57 Mapovanie person V1+V2+V3 (riadky, $K = 4$) na osoby V2+V3 (stĺpce, $K = 6$) na prieniku $N = 85$.

index	P0	P1	P2	P3	P4	P5
P0	0	22	0	13	18	0
P1	10	0	0	0	0	2
P2	0	0	10	0	0	0
P3	0	0	0	0	0	10

Z hľadiska Stage 4 je dôležité posúdiť, do akej miery sú osoby robustné voči zmene konfigurácie pohľadov, teda či sa zachovávajú aj pri alternatívnej integrácii na prieniku V1+V2+V3. Kontingenčná tabuľka mapovania ukazuje, že niektoré osoby sa prenášajú takmer jednoznačne: na spoločnom prieniku sa napríklad pozoruje prakticky priame mapovanie P2 na P2 a P3 na P5. Takéto prípady predstavujú prirodzených kandidátov na robustné jadro – ich existencia a zloženie nie sú viazané na konkrétnu voľbu integračných pohľadov, ale pretrvávajú aj po rozšírení integrácie o dotazníkový pohľad.

Naopak, mapovanie zároveň ukazuje, že výrazná časť používateľov s dominantnou taktikou T6 sa v trojpohľadovej integrácii zlieva do jednej dominantnej osoby (riadok P0). To naznačuje, že jemnejšie delenie T6-skupiny v behaviorálnom riešení V2+V3 (osoby P1/P3/P4) je do istej miery citlivé na konfiguráciu pohľadov a veľkosť prieniku. V terminológii Stage 4 to znamená, že ide skôr o metódovo závislú vrstvu opisu: môže niesť užitočnú informáciu, ale jej formulácia má byť opatrnejšia a má byť podopretá ďalšími diagnostikami (pokrytie, kvalita, alternatívne behy) a následným nezávislým overením na premenných mimo zhlukovania.

Nezávislé overovanie person používa premenné, ktoré nevstupovali do segmentácie (demografia, herné preferencie). Overovanie sa reportuje deskriptívne pre všetkých a prioritne na CORE (aby sa minimalizoval vplyv hraničných prípadov).

Tab. 58 Nezávislé premenné Z podľa person V2+V3.

Perso na	n	Age mean	Age median	Game_pla y_hours median	Game_play_ho urs_no_mobile median	n gender	male	multi	loved type top	loved type top_n	loved_t ype n
P0	26	22.80	23.0	6.25	5.5	10	70.0	50.0	Action	33.3	9
P1	36	22.23	22.0	16.00	11.5	22	77.3	54.5	Action	42.9	21
P2	13	21.50	21.5	15.00	10.0	10	100.0	50.0	Action	33.3	9
P3	36	23.38	23.0	14.50	10.0	13	92.3	69.2	RPG	58.3	12
P4	25	22.44	23.0	14.50	12.0	18	88.9	50.0	Action	38.9	18
P5	14	26.00	22.5	11.50	9.0	12	66.7	41.7	RPG	33.3	9

Formálne porovnania sa navrhujú tak, aby boli robustné voči neidealitám (malé skupiny, negausovské rozdelenia, nerovnaké variancie) a aby minimalizovali vplyv nejstej segmentácie. Všetky porovnania sa robia prioritne na CORE (t. j. na podmnožine s najistejším priradením). CORE sa v tejto case study odvodzuje z dostupných indikátorov istoty v pohľadoch (V2: anchor level = strong; V1: BITI_core_75; prípadne ich kombinácia). Tým sa znižuje riziko, že rozdiely budú dôsledkom hraničných priradení.

Nezávislé premenné (demografia a preferencie) sú dostupné iba na prieniku pohľadov, kde boli vyplnené validačné položky. Preto sa formálne porovnania medzi osobami realizovali prioritne na dual-CORE podvzorke: používateľ je zahrnutý, ak má V2 CORE (anchor level = strong) a zároveň V1

BITI_core_75 = 1, čo predstavuje N = 56 používateľov. V riešení V2+V3 (K = 6) majú osoby veľkosti {8, 13, 6, 8, 11, 10}, v riešení V1+V2+V3 (K = 4) {32, 10, 6, 8}.

Pre číselné premenné (napr. *age*, *Game_play_hours*, *Game_play_hours_no_mobile*) je vhodné použiť neparametrické testy. Ak sa porovnávajú viac než dve osoby, prirodzená voľba je Kruskal–Wallis, pretože nepredpokladá normalitu a je stabilnejší pri rôznych rozdeleniach. Pri signifikantnom výsledku sa následne použijú post hoc párové porovnania (napr. Dunnov test) s korekciou na viacnásobné testovanie, pričom popri p-hodnotách sa reportuje aj veľkosť efektu. Pre premenné v skúmanej vzorke žiadny test nebol signifikantný, tým pádom sa post hoc párové porovnania nevykonávali.

Pre kategorizované premenné (napr. *gender*, *multi_single*, *loved_type*, *play_**) je vhodným testom chí-kvadrát test nezávislosti. Ak sú v tabuľke malé očakávané početnosti (čo je reálne pri menších osobách a viac kategóriách), preferuje sa Fisherov exaktný test (pre 2×2) alebo jeho rozšírenia. Pre *gender*, *multi_single*, *loved_type* a binárne *play_** premenné sa použil chí-kvadrát test nezávislosti s Cramérovým V. Premenné *play_Other* a *play_None* sa na dual-CORE netestovali, lebo boli konštantné (všetci mali hodnotu 0). Premenná *loved_type* obsahovala zriedkavé kategórie; kvôli stabilite testu boli kategórie s výskytom < 5 zlúčené do *play_Other* a test sa počítal na dostupných hodnotách (tu N = 50, keďže časť hodnôt chýbala). Na dual-CORE podvzorke sa nepotvrdili štatisticky významné rozdiely v kategorizovaných premenných medzi osobami ani v riešení V2+V3 (všetky $p_{adj} = 1.0$, najnižšie nominálne p mala premenná *play_Multiplayer*: $p = 0.091$, $V = 0.411$, no po korekcii $p_{adj} = 0.915$); podobne v riešení V1+V2+V3 (najnižšie nominálne p má opäť *play_Multiplayer*: $p = 0.050$, $V = 0.374$, avšak po korekcii ostáva nesignifikantné $p_{adj} = 0.501$).

Stage 4 potvrdila, že osoby sú v tejto case study najlepšie čitateľné cez stabilné podpisy v integračných pohľadoch (V2, V3) a že dotazníkový pohľad V1 sa k nim na dostupnom prieniku spravidla pripája konzistentne. Citlivostná analýza zároveň ukázala, že časť jemnejšieho delenia (najmä v oblasti T6) sa pri pridaní V1 a pri menšom prieniku zlieva do širších skupín, takže tieto detaily patria skôr do metodovo závislej vrstvy a treba ich formulovať opatrne. Nezávislé overovanie na dual-CORE podvzorke neprinieslo jednoznačné rozdiely medzi osobami, čo je pravdepodobne dôsledok malej vzorky a nerovnomerného pokrytia; zároveň si však treba uvedomiť, že cieľom case study bolo ukázať, ako sa stability-first pipeline dá prakticky zrealizovať a ako Stage 4 disciplinovane odlíši robustné jadro od tvrdení citlivých na konfiguráciu a prienik dát.

Diskusia a záver

Navrhnutá metodika reaguje na praktický problém hernej analytiky. Problémom často nie je nedostatok dát, ale ich porovnateľnosť a spoľahlivosť záverov pri heterogénnych zdrojoch. Priame spájanie príznakov (skorá fúzia) v takomto nastavení zvyčajne vedie k dominancii najbohatšieho pohľadu a k problémom s dimenzionalitou. V case study sa preto pracovalo s harmonizáciou v rámci pohľadov a s neskorou fúziou výstupov. Tento režim sa ukázal ako vhodný najmä pri neúplných dátach. Umožnil integrovať zdroje s asymetrickým pokrytím (V3 je podmnožinou V2, kým V1 existuje nezávisle) bez potreby imputácie chýbajúcich hodnôt vo vysokodimenzionálnom priestore. Váženie na úrovni používateľa zabezpečilo, že integrácia nepenalizovala používateľov za chýbajúce pohľady. Opierala sa o dostupné a kvalitné signály.

Dôležitým posunom je explicitná práca s neistotou a stabilitou. Segmentácia sa tu nechápe ako jednorazové priradenie, ale ako štruktúra s jadrom (CORE) a hraničnými prípadmi (BOUNDARY). V case study sa ukázalo, že niektoré osoby sú robustné a dobre čitateľné (napr. P2 v riešení V2+V3 s jednoznačným taktickým profilom). Zároveň sa objavili oblasti citlivé na konfiguráciu pohľadov a veľkosť prieniku dát. Najmä jemnejšie delenie v okolí dominantnej taktiky T6 sa pri pridaní V1 a pri menšom prieniku zlievalo do širších skupín. Zavedenie kvality $q_{i,v}$ a stability priamo do integračného

mechanizmu tu funguje ako brzda proti preinterpretovaniu artefaktov. Stabilita a neistota sa tak stávajú podmienkou interpretácie, nie len dodatočnou diagnostikou. Výsledkom je transparentné rozlíšenie robustného jadra od pohľadovo alebo metódovo závislej vrstvy.

Triangulačná logika (konvergencia, komplementarita, rozpory) sa v dátach ukázala ako prakticky použiteľná. Pohľady nemusia poskytovať identický obraz, stačí, aby bol kompatibilný. V tejto case study sa prejavila najmä komplementarita: procesný pohľad (V3) spresňoval behaviorálne vzorce z telemetrie (V2) a dotazníkový pohľad (V1) sa k nim na dostupnom prieniku spravidla pripájal konzistentne. Zároveň je však potrebné priznať limity nezávislého overovania. Premenné pre externú validáciu boli vyčlenené striktne mimo zhlukovania, no testy na dual-CORE podvzorke nepreukázali štatisticky významné rozdiely. Hlavným dôvodom je malá veľkosť prieniku a nerovnomerné pokrytie, teda nízka štatistická sila, nie zlyhanie metodiky. Naopak, metodická hodnota je v tom, že postup vie tieto limity pomenovať a že citlivostná analýza odhalí, kde sa riešenie mení pri zmene konfigurácie.

Práca predstavila a demonštrovala metodiku viacpohľadového profilovania používateľov v štyroch etapách a odpovedá tak na výskumnú otázku popisom metodiky viacpohľadového profilovania používateľov. Stage 1 špecifikuje pohľady, kontrakty a pravidlá porovnateľnosti. Stage 2 materializuje pohľadové výstupy a dopĺňa ich o stabilitu a neistotu. Stage 3 integruje pohľady neskorou fúziou a vážením podľa pokrytia, kvality a stability. Stage 4 uzatvára interpretáciu trianguláciou a nezávislým overovaním na premenných mimo zhlukovania.

Cieľom kapitoly nie je identifikovať zoznam konkrétnych person v tejto vzorke. Prínosom a zároveň odpoveďou na výskumnú otázku **je auditovateľný proces, ktorý zabraňuje správaniu čiernej skrinky pri integrácii heterogénnych dát. Case study ukázala, že interpretovateľné profily sa dajú vytvoriť aj pri výraznej neúplnosti dát, ak sa namiesto imputácie zvolí transparentné modelovanie dostupnosti a spoľahlivosti. Dôraz na stability-first logiku a CORE/BOUNDARY znižuje riziko prehnaných záverov. Persona sa tým pádom neprezentuje ako nemenný fakt, ale ako výstup s priznanou mierou dôveryhodnosti.** Tým sa naplnil aj zámer case study: ukázať, ako sa pipeline realizuje v praxi, ako sa pracuje s neúplnosťou a neistotou a ako sa v Stage 4 oddelí robustné jadro od metódovo závislej vrstvy.

Diskusia a záver

Táto záverečná kapitola sumarizuje a interpretuje výsledky habilitačnej práce tak, aby bolo zrejmé, ako na seba nadväzujú čiastkové zistenia a ako spolu tvoria odpoveď na hlavnú výskumnú otázku. Zámerom diskusie je ukázať, že interpretovateľné osoby nevznikajú jedným krokom, ale ako výsledok kontrolovaného procesu, ktorý rieši porovnateľnosť, stabilitu a neistotu naprieč pohľadmi.

Štruktúra kapitoly je preto vedená od syntézy k dôsledkom. Najprv sa zhodnotí naplnenie cieľov a stručne sa uzatvoria odpovede na jednotlivé výskumné otázky, následne sa vyvodí príspevky pre vedecké poznanie, aby bolo jasné, v čom je prínos metodický a v čom koncepčný. Potom sa diskusia presunie k praxi, kde sa výsledky prekládajú do rozhodnutí v troch doménach, ktoré práca pokrýva: profilovanie používateľov ako všeobecný rámec, herné dizajnovanie ako aplikačný cieľ behaviorálnych a procesných profilov, a vzdelávanie ako prostredie, kde sa profilovanie opiera o minimalistické logy a angažovanosť. Kapitola sa uzatvára limitmi a ďalším smerovaním výskumu, ktoré vyplýva priamo z identifikovaných rizík merania a z požiadavky replikovateľnosti v multi-view nastavení.

Zhodnotenie cieľov a odpovede na výskumné otázky

Hlavný cieľ habilitačnej práce bol naplnený návrhom a empirickým overením metodiky viacpohľadového profilovania používateľov v hrách a virtuálnych prostrediach, ktorá priamo rieši problém fragmentácie prístupov a nestability výsledkov. Základnou tézou práce je, že integrácia heterogénnych a často neúplných pohľadov je zmysluplná len vtedy, ak sa najprv zvládnu predpoklady: kvalita merania, porovnateľnosť výstupov, kontrola stability a explicitná práca s neistotou priradenia. Preto sú výskumné otázky usporiadané hierarchicky. Skoršie otázky stabilizujú vstupy a význam konštruktov, stredné otázky vytvárajú robustné profilové výstupy v jednotlivých pohľadoch a záverečná otázka formalizuje stabilný postup segmentácie a reportovania, aby sa tieto výstupy dali korektne integrovať.

Táto hierarchia je zároveň logikou hlavnej otázky. Hlavná otázka sa nedá vyriešiť jedným modelom ani jednou dátovou vrstvou, ale až kombináciou čiastkových riešení, ktoré postupne odstraňujú zdroje nestability a neinterpretovateľnosti. Každá čiastková odpoveď je preto predpokladom efektívnej aplikácie celkového rámca: bez stabilného sebaopisu je dotazníkový pohľad rizikový, bez empirického ukotvenia typológií je interpretácia voľná, bez dátovej hygieny sa profily kontaminujú, bez robustných profilov v jednotlivých pohľadoch nie je čo integrovať, bez procesnej reprezentácie chýba vysvetlenie dynamiky správania a bez stability-first reportovania sa výsledok nedá obhájiť ani preniesť do praxe.

Hlavná výskumná otázka: ***Ako navrhnúť a empiricky overiť metodiku viacpohľadového profilovania používateľov v hrách a virtuálnych prostrediach, ktorá integruje heterogénne a neúplné pohľady, explicitne kontroluje stabilitu a neistotu priradenia a vedie k interpretovateľným profilom použiteľným v praxi?***

Vyriešenie hlavnej otázky v návrhu metodiky, ktorý integruje porovnateľné výstupy pohľadov. Každý pohľad je najprv spracovaný tak, aby poskytoval interpretovateľný profil a aby sa dal hodnotiť z hľadiska kvality a stability. Integrácia je potom postavená na neskorej fúzii a na pravidlách, ktoré explicitne zohľadňujú neúplnosť a neistotu. Empirická časť ukazuje, že takto navrhnutý rámec vie viesť k personám, ktoré sú čitateľné, kontrolovateľné a použiteľné aj pri asymetrickom pokrytí dát.

Na získanie odpovede bolo potrebné vyriešiť nasledovné čiastkové otázky:

SUB1: Ako predchádzajúca skúsenosť s virtuálnou realitou vplýva na dimenzie akceptácie a pri akej úrovni expozície sa oslabuje efekt novosti?

Táto otázka je predpokladom pre to, aby sa sebaopisné merania mohli používať ako stabilný pohľad v multi-view profilovaní. Výsledky podporujú interpretáciu prahového efektu kumulatívnej expozície približne na úrovni desiatich hodín, pri ktorom sa oslabuje vplyv novosti na hodnotenia a merania sú porovnateľnejšie. Praktický význam je v tom, že bez zohľadnenia skúsenosti sa dotazníkový pohľad môže správať ako meranie efektu novosti, nie ako meranie vlastností používateľa. Tým sa uzatvára prvý vstupný predpoklad rámca: kontrola spoľahlivosti merania pred integráciou.

SUB2: Do akej miery sú top-down typológie konštruktovo ekvivalentné a prakticky nahraditeľné?

Táto otázka rieši druhý predpoklad: stabilitu významu a interpretácie v dotazníkovom pohľade. Ukázalo sa, že typológie zdieľajú časť spoločného latentného základu, ale nie sú plne zameniteľné, takže mechanické nahradenie jedného nástroja druhým nie je bezpečné. Z toho vyplýva metodický dôsledok pre hlavnú otázku: typológia môže slúžiť ako ukotvenie a interpretačný slovník, ale musí byť empiricky mapovaná v konkrétnych dátach a prostredí. Tým sa znižuje riziko, že integrácia bude spájať neporovnateľné konštrukty len preto, že nesú podobné názvy.

BEHA1: Do akej miery sú metódy detekcie nízkej angažovanosti prenositeľné do mikroučenia a pomôže segmentované nastavovanie prahov?

Otázka rieši predpoklad kvality behaviorálnych dát pred tvorbou profilov. Prenositeľnosť metód sa potvrdila, no zároveň sa ukázalo, že presnosť a robustnosť sa zvyšuje vtedy, keď sa prahy neodhadujú globálne, ale v homogénnejších skupinách definovaných správaním (napríklad rýchlosťou čítania a výkonom). Prakticky to znamená, že čistenie dát je efektívnejšie, keď rešpektuje rozdielne režimy správania, nie keď predpokladá jednu normu pre všetkých. Pre hlavnú otázku je to kľúčové: integrácia viacerých pohľadov má zmysel len vtedy, keď jednotlivé pohľady nevňášajú do spoločného výsledku systematické artefakty.

BEHA2: Ako navrhnúť jednotný profilovací model, ktorý z minimálnych protokolových logov konštruje malé, interpretovateľné a stabilné mikro-persony?

Otázka dodáva rámcu praktický pohľad, ktorý je dostupný aj v prostrediach s obmedzenými dátami a krátkou históriou používateľa. Navrhnutý model ukazuje, že aj minimalistické protokolové logy automatizovaného hodnotenia, doplnené o kurikulárny a časový kontext, stačia na tvorbu prenositeľných mikro-person. Dôležitá je interpretovateľnosť výstupu: profily sú malé a zrozumiteľné, takže sa dajú použiť v praxi bez potreby zložitých latentných reprezentácií. Z pohľadu hlavnej otázky ide o to, že viacpohľadová metodika má byť použiteľná aj v situáciách, kde jeden pohľad dominuje len preto, že ostatné sú chudobné.

BEHA3: Ako konštruovať interpretovateľné behaviorálne osoby a do akej miery ukotvenie typológiou znižuje riziko nadinterpretácie?

Táto otázka rieši prechod od profilu k persone, teda od deskriptívnych ukazovateľov k stabilným a komunikovateľným kategóriám. Výsledky podporujú predpoklad, že typológiou riadené ukotvenie znižuje interpretačnú voľnosť a brzdí tvorbu naratívov, ktoré nie sú opreté o dáta. Zároveň zvyšuje vysvetliteľnosť tým, že persona dostáva konzistentné významové opory a dá sa lepšie preložiť do rozhodnutí v dizajne a evaluácii. Pre hlavnú otázku je to opäť kľúčové, lebo interpretovateľnosť je explicitnou podmienkou integrácie: výsledok musí byť použiteľný, nie len štatisticky akceptovateľný.

PROC1: Ako navrhnúť modulárny pipeline, ktorý extrahuje epizódy a taktiky ako porovnateľnú procesnú reprezentáciu správania?

Otázka dopĺňa statické profily o dynamiku správania a rieši, ako zabezpečiť porovnateľnosť procesných čŕt naprieč rôznymi segmentačnými dizajnmi. Navrhnutý modulárny postup stojí na šandardizácii vstupu a na zjednotení epizódového výstupu do jednotného kontraktu, takže procesné charakteristiky ostávajú konzistentné. Prakticky to znamená, že zmeny segmentačnej metódy nemenia jazyk, v ktorom

sa epizódy a taktiky opisujú, ale len vrstvu detailu. Pre hlavnú otázku je tento pohľad dôležitý, lebo integrácia bez procesnej roviny často vysvetľuje len kto používateľ je, nie ako sa správa.

STAB1 Ako navrhnúť a reportovať stability-first pipeline pre viacblokové profilovanie tak, aby osoby boli replikovateľné a mali explicitnú neistotu priradenia?

Táto otázka uzatvára hierarchiu tým, že formalizuje kritériá prijateľnosti výsledku a spôsob jeho reportovania. Navrhnutý prístup vyžaduje replikovateľnosť riešenia pri perturbáciách a resamplingu, explicitné rozlíšenie jadrových a hraničných priradení a následnú validáciu na externých premenných, ktoré nie sú súčasťou klastrovania. Tým sa rieši problém kruhovitosti a zároveň sa z person stáva obhájitelný výstup, nie len jednorazová interpretácia. Pre hlavnú otázku je tento krok základným predpokladom, lebo stabilita a neistota sú podmienkou toho, aby sa viacpohľadová integrácia dala v praxi použiť zodpovedne.

Všetky čiastkové odpovede tak smerujú k cieľu, aby integrácia viacerých pohľadov nebola len technickým spojením dát, ale kontrolovaným a auditovateľným procesom, ktorý udrží význam, stabilitu a interpretovateľnosť výsledku. SUB1 a SUB2 stabilizujú sebaopis a jeho interpretáciu, BEHA1 zaisťuje kvalitu behaviorálnych dát, BEHA2 a BEHA3 poskytujú robustné profilové výstupy z dvoch odlišných typov logov, PROC1 pridáva porovnateľnú procesnú reprezentáciu správania a STAB1 dáva pravidlá, kedy je možné výsledok považovať za persona riešenie a ako ho transparentne reportovať. V tomto zmysle nie je hlavná otázka ich syntézou: odpoveď vzniká až vtedy, keď sa splnia predpoklady a keď sa výstupy jednotlivých otázok spoja do jedného viacpohľadového rámca.

Prínos habilitačnej práce pre oblasť vedeckého poznania

Vedecký prínos práce spočíva v posune od jednorazového výberu najlepšej segmentácie k metodike, v ktorej sa profilovanie v heterogénnych a neúplných pohľadoch realizuje ako kontrolovaný a reprodukovateľný proces so stabilitnými kritériami a transparentne vyjadrenou neistotou priradenia. Ťažisko sa presúva k identifikácii stabilnej štruktúry v dátach, k rozhodnutiam obhájitelným voči zmenám vzorky a k explicitnému reportovaniu neistoty priradenia. Tento princíp je zabudovaný vo všetkých krokoch návrhu integračného rámca a finálnu podobu nadobúda v záverečnej prípadovej štúdii, kde je vyjadrený prostredníctvom štyroch etáp: špecifikácia, materializácia, integrácia a validácia.

Metodický prínos pokrýva oblasť replikovateľnej segmentácie a neistoty ako vlastnosti výsledku. Stabilita sa v práci presúva z doplnkovej metriky na nutnú podmienku interpretácie segmentácie. V segmentácii bez učiteľa totiž neexistuje vonkajšia správna odpoveď, a preto sa kvalita riešenia nemá opierať o jeden index z jedného behu, ale o jeho odolnosť voči rozumným perturbáciám dát a nastavení. Tento princíp sa v práci operacionalizuje prístupom stability-first: riešenia sa hodnotia súbežne z hľadiska zhody s dátami, reprodukovateľnosti pri prevzorkovaní a separácie priradení. V záverečnej integrácii sa ukazuje, že až takáto kombinácia kritérií poskytuje obhájitelný základ pre výber a interpretáciu persona štruktúry, najmä pri heterogénnych a neúplných pohľadoch.

S tým úzko súvisí práca s neistotou priradenia, ktorá sa neinterpretuje ako chyba, ale ako informatívna vlastnosť výstupu. Práca explicitne uvažuje, že časť populácie ostáva nejednoznačná, a preto zavádza štandard reportovania, ktorý rozlišuje stabilné jadro osoby (CORE) a hraničné prípady (BOUNDARY). Toto rozlíšenie nie je len formálne: priamo usmerňuje interpretáciu aj externú validáciu, keďže znižuje riziko, že závery budú stáť na prípadoch, ktoré sa pri prevzorkovaní alebo miernych zmenách nastavení presúvajú medzi segmentmi. Stabilné jadro sa zároveň opiera o praktické kritériá koherencie profilov

a o opakované prevzorkovanie, ktoré umožňuje oddeliť robustnú časť štruktúry od variabilnej vrstvy na hraniciach segmentov.

Týmto spôsobom sa stabilita a neistota stávajú integrálnou súčasťou viacpohľadového profilovania: umožňujú spájať heterogénne a neúplné pohľady bez toho, aby sa výsledné osoby tvárili jednoznačnejšie, než dovoľujú dáta, a zároveň poskytujú jasné pravidlá, ktoré časti výstupu sú vhodné na praktické rozhodovanie.

Integračný prínos spočíva v popise a operacionalizácii postupu, v ktorom sa pred samotnou integráciou najprv harmonizujú jednotlivé pohľady do porovnateľných profilových výstupov. Integrácia sa tak neopiera o priame spájanie príznakov, ale o kombinovanie kompatibilných výstupov s explicitne definovaným výstupným kontraktom, čo umožňuje korektne pracovať aj s heterogénnymi a neúplnými dátami. Vychádza sa z toho, že priame zlučovanie príznakov zvyšuje dimenzionalitu, posilňuje dominanciu najbohatšieho zdroja a zhoršuje interpretovateľnosť výsledku. Preto sa každý pohľad najprv spracuje samostatne, stabilizuje a prevedie do porovnateľného profilového výstupu. Už v etape špecifikácie sa explicitne určí, ktoré pohľady vstupujú do profilovania, aké sú pravidlá ich kvality a aký výstupný kontrakt majú dodávať. Následná integrácia potom neskladá neúmerne dátové matice, ale kombinuje kompatibilné výstupy tak, aby ostali použiteľné aj v situácii, keď jednotliví používatelia majú k dispozícii rozdielnu kombináciu pohľadov.

Tento spôsob integrácie je prirodzene prepojený s neskorou fúziou a s interpretáciou neúplnosti ako vlastnosti dát. Chýbajúce pohľady sa nekompenzujú imputáciou, ale modeluje sa dostupnosť a kvalita signálu a tieto informácie sa prenášajú do výsledného profilu aj do miery istoty priradenia. Integrácia tým nadobúda charakter kontrolovaného procesu, ktorý nesie informáciu o tom, z akých zdrojov je záver odvodený a kde sú jeho hranice.

Súčasťou integračného prístupu je aj interpretačná disciplína pri kombinovaní pohľadov. V multi-view nastavení sa prirodzene objaví zhoda, dopĺňanie aj rozpor medzi pohľadmi, preto sa interpretácia person neopiera o predpoklad jednej „pravdy“, ale o trianguláciu. Zhoda zvyšuje dôveru v identifikovanú štruktúru, komplementarita rozširuje vysvetlenie a rozpor sa číta ako signál kontextovosti správania alebo limitov merania, nie ako dôvod na dodatočné, ad hoc interpretácie.

Reprezentačný prínos spočíva v tom, že práca nepokladá jednotlivé pohľady za hotové modality, ktoré sa dajú jednoducho zlúčiť, ale za reprezentácie, ktoré treba cielene navrhnuť tak, aby boli porovnateľné, interpretovateľné a následne integrovateľné. Tento prístup presúva pozornosť od samotného výberu modelu k tomu, ako sa z dát konštruuje stabilný a prenositeľný opis správania, použiteľný naprieč prostrediami a typmi úloh.

V mikroučení sa tento prínos prejavuje dôrazom na dátovú hygienu. Profilovanie sa neopiera o nekontrolované záznamy s nízkou angažovanosťou, ale najprv sa rieši kvalita správania a až potom segmentácia, aby výsledné profily neboli artefaktom rýchleho hádania alebo režimov práce, ktoré nesúvisia s cieľovým konštruktom. Zároveň sa ukazuje, že aj minimálne protokolové logy, ak sú doplnené o kurikulárny a časový kontext, môžu tvoriť platformovo agnostickú a prenositeľnú reprezentáciu používateľa vo forme malých mikro-person .

V herných agregovaných logoch je prínos reprezentácie založený na ukotvení interpretácie typológiou. Persony sa tak nečítajú ako voľná interpretácia zhlukov, ale ako štruktúra, ktorej význam je viazaný na konzervatívne interpretačné opory. Typológia v tomto nastavení nefunguje ako zameniteľný nástroj, ale ako brzda nadinterpretácie a ako most k vysvetliteľnosti v pojmoch, ktoré sú pre dizajn a evaluáciu hier prirodzené. Takéto ukotvenie zároveň reaguje na širší problém fragmentácie postupov v logovej segmentácii hráčov a podporuje metodickú štandardizáciu významu výstupov.

V procesnej rovine sa prínos prejavuje tým, že surová eventová telemetria sa nepovažuje za priamo použiteľný vstup do profilovania, ale cielene sa transformuje do konzistentnej reprezentácie epizód a taktík. Modulárny postup stojí na štandardizácii vstupu, na zjednotení epizódového výstupu a na následnej ťažbe opakujúcich sa rutín. Tým sa vytvára procesný pohľad, ktorý umožňuje férové porovnávanie segmentačných dizajnov nad rovnakým procesným kontraktom a oddeľuje robustné taktické vzorce od vrstvy, ktorá je závislá od konkrétneho algoritmu.

V súhrne práca prepája tri línie, ktoré v literatúre často zostávajú oddelené, a to stabilne orientovanú segmentáciu, viacpohľadovú integráciu a procesnú abstrakciu správania. Výsledkom je metodika, ktorá je auditovateľná, prenositeľná medzi doménami hier, virtuálnych prostredí a vzdelávania a zároveň konzervatívna v interpretácii. Stabilná časť štruktúry sa reportuje ako jadro, nejednoznačné priradenia sa otvorene pomenúvajú a analyticky riadia a neúplnosť sa nezahladzuje, ale explicitne modeluje prostredníctvom dostupnosti a kvality jednotlivých pohľadov.

Prínos pre prax

Praktický prínos práce spočíva v tom, že viacpohľadové profilovanie sa interpretuje ako systematický a opakovateľný pracovný postup použiteľný v tímoch, ktoré v praxi kombinujú dotazníky, agregované logy a udalostnú telemetriu. Tento posun je postavený na prierezových princípoch, ktoré zvyšujú použiteľnosť výstupov v prevádzke a zároveň sprísňujú požiadavky na transparentnosť a férovosť rozhodovania:

- **Auditovateľnosť priradenia a vysvetliteľnosť rozhodnutia** spočíva v tom, že priradenie používateľa sa dá spätne zdôvodniť identifikáciou rozhodujúcich pohľadov, použitých signálov a miery istoty. Profilovanie sa tak mení z ťažko interpretovateľného výsledku na proces, ktorý je možné kontrolovať, komunikovať a revidovať.
- **Práca s neistotou a hranicami segmentácie** znamená, že sa namiesto pevného zaradenia zohľadňuje rozdiel medzi stabilným jadrom a hraničnými prípadmi. Výstup je preto konzervatívnejší: podporuje opatrnú interpretáciu a poskytuje mechanizmus na obmedzenie zásahov tam, kde je priradenie nejednoznačné.
- **Ošetrenie skreslení vyplývajúcich z kvality správania a heterogenity používateľov** vychádza z pozorovania, že významná časť chýb nevzniká len vo fáze modelovania, ale už v dátach (napr. rozdielne tempo práce, nízka angažovanosť, situačné režimy). Z toho plynie dôraz na kalibráciu prahov a pravidiel v homogénnejších podskupinách, čím sa znižuje riziko systematicky nespravodlivých záverov.
- **Realizovateľnosť profilovania s bežne dostupnými dátami a dôraz na dátovú minimalizáciu** je podporená tým, že postup zostáva informatívny aj pri bežných signáloch (protokolové logy, štandardná telemetria) bez potreby drahých alebo invazívnych meraní. Praktickým dôsledkom je nižšia bariéra nasadenia a lepšia obhájiteľnosť zberu dát z hľadiska proporcionality a ochrany súkromia.
- **Rozlíšenie stabilných vzorcov od metodicky alebo situačne podmienených javov** vychádza z vyhodnocovania stability ako opory pre rozhodovanie, či má zmysel navrhovať adaptáciu (pri stabilnom vzorci), alebo zvoliť opatrnejší režim použitia a preferovať monitorovanie (pri prechodnom alebo analyticky nestabilnom jave).

Uvedené prierezové posuny sa následne premietajú do troch aplikačných oblastí, v ktorých majú výsledky konkrétny dopad:

- **Dátová analytika a personalizácia** – rieši sa problém neúplných a nerovnomerných dát tým, že integrácia nestojí na dopĺňaní chýbajúcich pohľadov, ale na kontrolovanom kombinovaní toho, čo je pre konkrétneho používateľa dostupné a dostatočne robustné. To podporuje

nasadenie v produkcii, kde sa zber mení medzi platformami a verziami, a zároveň viaže personalizačné rozhodnutia na mieru istoty priradenia vrátane práce so stabilnými a hraničnými prípadmi.

- **Dizajnovanie hier a virtuálnych prostredí** – prínos je založený na prepájaní dotazníkov, agregovaných logov a procesnej telemetrie do jednotného rozhodovacieho rámca, takže segmentácia má jasnejší preklad do mechaník a dizajnových zásahov. Význam person sa ukotvuje typológiami ako interpretačnými kotvami; telemetria sa transformuje na epizódy a taktiky, ktoré umožňujú mapovať správanie na herné slučky, tempo a spätnú väzbu pri zachovaní informácie o neistote priradenia. V kontexte hodnotenia VR sa ukazuje citlivosť sebaopisov na skúsenosť a efekt novosti; skúsenosť sa preto zavádza ako systematický faktor a prahový efekt expozície (orientačne okolo desiatich hodín) sa interpretuje tak, aby sa dizajnový efekt nezamieňal s efektom adaptácie.
- **Vylepšovanie prostredia mikroučenia** – prínos spočíva v riešení kvality správania a v zavedení detekcie nízkej angažovanosti a rýchleho hádania ako systematických zdrojov skreslenia. Ukazuje sa, že rozhodovacie prahy nemajú byť globálne, ale kalibrované v homogénnejších skupinách podľa rýchlosti čítania a výkonu, čím sa zvyšuje férovosť a stabilita interpretácie. Praktickým dôsledkom sú čistejšie vstupy pre adaptáciu a cielennejšie intervencie, ktoré lepšie odlišujú slabý výkon od slabého úsilia.

Analytika a personalizácia

V oblasti produktovej analytiky a nasadzovania personalizácie práca rieši jeden z najtypickejších problémov produkcie: profilovanie sa nedá postaviť na predpoklade, že všetci používatelia budú mať rovnaké dáta. V reálnom nasadení zanechávajú používatelia rozdielne typy stôp a ich dostupnosť sa mení naprieč platformami a verziami systému, takže pokrytie je nerovnomerné a neúplné (van Loon et al., 2024), (Drachen et al., 2013). Práca preto formuluje profilovanie tak, aby bolo použiteľné aj pri takomto pokrytí a aby integrácia nevznikala dopĺňaním chýbajúcich údajov, ale kontrolovaným kombinovaním toho, čo je skutočne namerané a dostatočne kvalitné (Ye et al., 2018), (van Loon et al., 2020), (Purificato et al., 2024). Tento prístup je rozpracovaný v metodickú časť multi-view profilovania, kde sa definuje integrácia pri neúplnosti, a následne sa demonštruje v integračnej časti a v prípadovej štúdii, kde sa pracuje s asymetrickým pokrytím pohľadov.

Z praktického hľadiska práca dáva odporúčanie, aby sa integrácia stavala na explicitnom modelovaní dostupnosti a kvality signálu. To znamená, že pre každý pohľad sa má vedome určiť, kedy je vstup použiteľný, a ako sa táto informácia preniesie do výstupu, namiesto toho, aby sa neúplnosť riešila imputáciou (Ye et al., 2018), (van Loon et al., 2020), (Purificato et al., 2024). V produkcii to znižuje citlivosť profilovania na zmeny zberu a zároveň bráni tomu, aby výsledok dominoval ten pohľad, ktorý je práve v konkrétnej verzii najbohatšie inštrumentovaný. Metodika je tak prenositeľná medzi produktmi aj medzi iteráciami toho istého produktu, pretože stojí na kontrolovanom kombinovaní pohľadov, nie na jedinom spoločnom dátovom priestore, ktorý sa v čase nevyhnutne mení (Ye et al., 2018), (J. Yu et al., 2023).

Ďalší praktický prínos je transparentnosť výstupu. Práca v záverečnej kapitole popisuje postup umožňujúci pri každom profile možnosť spätne uviesť, z ktorých pohľadov vznikol, aká bola ich kvalita a či je priradenie stabilné alebo hraničné. Vďaka tomuto postupu je možné naviazať personalizačné zásahy na mieru istoty: stabilné priradenia môžu podporiť jednoznačnejšie prispôbenie, kým pri hraničných prípadoch sa odporúča opatrnejší režim alebo cielené doplnenie signálu, aby sa znížilo riziko nesprávnej intervencie (Ramos et al., 2018), (Sifa et al., 2018). V praxi to znamená, že

personalizácia sa dá nasadiť konzervatívne a bezpečne aj vtedy, keď je profilovanie vystavené prirodzenej heterogenite používateľov a priebežným zmenám zberu dát.

Viacpohľadové profilovanie má pre prax nasledovné priame dôsledky, ktoré práca nielen odporúča, ale aj operacionalizuje a demonštruje na dátach:

- auditovateľnosť profilu – pri každom používateľovi je možné spätne určiť, z ktorých pohľadov vznikol, aká bola ich kvalita a aká je istota priradenia, čo je kľúčové pri porovnávaní verzií systému, zmien inštrumentácie a pri priebežnom vyhodnocovaní dopadu úprav v produkčnom cykle.
- personalizačné zásahy sa dajú riadiť podľa istoty – práca používa štandard reportovania, ktorý rozlišuje stabilné priradenia a hraničné prípady (CORE a BOUNDARY), čím vytvára praktické pravidlo pre opatrnejší režim personalizácie tam, kde je priradenie prirodzene nejednoznačné, alebo pre cielene doplnený zber signálu,
- integrácia zostáva metodicky korektná aj pri neúplnosti – prevedené sa prevádzajú na rovnaký typ výstupu (pravdepodobnostné profily + kvalita/istota), takže sa neskôr kombinujú kompatibilné profilové výstupy a nie nesúmerné dátové matice, ktoré by v praxi viedli k dominancii najbohatšieho zdroja.

Dizajnovanie hier a virtuálnych prostredí

Pre prax herného dizajnu a návrhu virtuálnych prostredí práca posúva profilovanie používateľov z izolovanej analýzy jedného zdroja do rozhodovacieho rámca, v ktorom sa vedome prepájajú dotazníkové merania, agregované logy a procesný opis správania (Teng et al., 2025), (Alonso-Fernández et al., 2022). Prakticky tým rieši dve typické slabiny dizajnového cyklu. Prvou je zníženie rizika nadinterpretácie, keď numericky presvedčivé segmenty nemajú jasný preklad do zásahov v mechanikách (van Loon et al., 2024), a tak odporúča namiesto typológie používať interpretačné kotvy so slovníkom tendencií (Chung, 2015). Druhou slabinou je, že dotazníkové vstupy nemusia byť stabilné v raných fázach používania imerzívnych systémov, keď efekt novosti a fascinácia z VR zážitku môžu dočasne zvyšovať hodnotenia a maskovať limity použiteľnosti; bez kontroly skúsenosti tak môže dizajnový tím zameniť efekt obsahu za efekt adaptácie používateľa na technológiu (Miguel-Alonso et al., 2024), (Ball et al., 2021), (Villena-Taranilla et al., 2023).

Práca tiež sprístupňuje telemetriu pre dizajnové rozhodovanie tým, že ju premieňa na porovnateľný procesný pohľad cez epizódy a taktiky (S. Anderson & Falconer, 2025). Namiesto interpretácie izolovaných udalostí definuje postup získavania opakujúcich sa rutín, ktoré sa dajú priamo mapovať na herné slučky, náklady a odmeny, tempo, miesta trenia a typické voľby. Týmto prístupom sa kompenzuje strata kontextu v agregovaných dátach, pretože procesná vrstva dopĺňa čo sa deje o ako a v akom poradí. Praktický dopad posilňuje aj explicitná práca s neistotou priradenia (Hare & Tang, 2023), (Melo Do Nascimento et al., 2025). Stabilné priradenia umožňujú cieľiť zásahy na skupiny s konzistentným profilom, kým pri hraničných prípadoch sa volí opatrnejší režim alebo sa cielene dopĺňa meranie. V syntéze prínosov pre prax sa táto línia premieta do odporúčaní pre herné dizajnovanie, kde sa výsledky profilovania používajú ako spoločný jazyk analytika a dizajnéra naprieč subjektívnou, behaviorálnou a procesnou vrstvou (Chung, 2015), (Drachen et al., 2013), (Tarekegn et al., 2025).

Praktickým výstupom je metodika hodnotenia akceptácie vo virtuálnej realite, ktorá je určená priamo pre iteratívne testovanie prototypov a porovnávanie variantov obsahu. Kapitola *Subjektívna vrstva – predispozície, skúsenosť a kontext* ukazuje, že sebaopisné dimenzie akceptácie a prítomnosti nie sú neutrálne vstupy, ale systematicky závisia od predchádzajúcej skúsenosti používateľa a od fázy adaptácie na technológiu. Pri miešaní nováčikov a skúsenejších používateľov preto môže dizajnový tím zameniť rozdiel v hodnotení za efekt úpravy obsahu, hoci ide o efekt novosti a adaptácie. Praktickým

výsledkom je postup, v ktorom sa kumulatívna expozícia meria a reportuje ako štandardná súčasť evaluácie a porovnania sa robia až pri stabilnejšom režime, prípadne sa skúsenosť explicitne zohľadní pri interpretácii rozdielov. V diskusii tejto kapitoly sa zároveň podporuje interpretácia prahového bodu približne okolo desiatich hodín expozície, po ktorom sa vplyv novosti oslabuje a porovnávanie skupín je metodicky spoľahlivejšie. Celé odporúčanie je postavené na bežne používaných konštruktoch akceptácie a prítomnosti, takže je prenositeľné do štandardných UX a produktových procesov vo virtuálnej realite.

V kapitole *Typologicky ukotvené osoby z logov* sa rieši typický problém agregovaných a logových dát: numericky presvedčivé segmenty sa dajú vytvoriť aj vtedy, keď ich význam nie je stabilný a ich pomenovanie je náchylné na nepodložené príbehy. Praktickým príspevkom kapitoly je postup, v ktorom sa osoby opierajú o typologicky inšpirované bloky metrík a ich stabilita sa explicitne overuje, pričom sa odlišuje reprodukovateľná časť populácie od nejednoznačných hraničných prípadov. Tým sa typológia používa ako interpretačná kotva a komunikačný slovník pre dizajn, nie ako definitívne zaradenie hráča, a zároveň sa obmedzuje riziko nadinterpretácie zhľukov pri rozhodovaní o mechanikách.

Nadväzne kapitola *Procesná vrstva – epizódy a taktiky* sprístupňuje udalostnú telemetriu cez štandardizovanú reprezentáciu epizód a následnú ťažbu opakujúcich sa rutín, ktoré už majú priamu väzbu na herné slučky, tempo, miesta trenia, náklady a odmeny. Dôležité je, že sa fixuje jednotná forma výstupu, takže tímy vedú porovnávať alternatívne segmentačné dizajny bez toho, aby sa menil význam výsledku, a v diskusii sa odlišuje to, čo je robustné naprieč dizajnmi, od toho, čo je podmienené konkrétnou segmentáciou. V praxi to znamená, že telemetria prestáva byť len bohatý zdroj, ale stáva sa porovnateľným procesným pohľadom, ktorý sa dá konzistentne integrovať so subjektívnou a agregačnou vrstvou pri dizajnových rozhodnutiach.

Vylepšovanie prostredia mikroučenia

V prostrediach mikroučenia je praktickým prínosom práce obohatenie procesu dizajnu: profilovanie sa nezačína segmentáciou, ale kontrolou kvality správania ako podmienkou zmysluplnej interpretácie. Rýchle hádanie odpovedí a nízka angažovanosť sa nechápu ako okrajový šum, ale ako systematický zdroj skreslenia, ktorý môže deformovať profily používateľov a následne aj rozhodovanie adaptačných mechanizmov (Jan Skalka & Valko, 2024), (Rios & Soland, 2021a), (Rios, 2022b). Z tohto dôvodu sa do pracovného postupu začleňuje detekcia takýchto režimov správania ešte pred samotnou interpretáciou výsledkov.

Z hľadiska praxe je rovnako zásadné, že rozhodovacie prahy sa nenastavujú globálne (Wise, 2019), (Deribo et al., 2023). V nízko-stakes prostredí je populácia heterogénna už na úrovni tempa práce a výkonu, preto jednotný prah zvyšuje riziko systematických zámen medzi rýchlym, ale poctivým správaním a rýchlym správaním založeným na hádaní, prípadne medzi pomalším tempom práce a nízkou angažovanosťou. Práca preto podporuje kalibráciu prahov v homogénnejších skupinách definovaných rýchlosťou čítania a výkonom, čo zvyšuje stabilitu rozhodovania a zlepšuje férovosť interpretácie naprieč odlišnými štýlmi práce (Wise & Kuhfeld, 2020), (Lindner et al., 2019).

Praktický dôsledok výskumu zvyšuje kvalitu vstupov pre adaptáciu. Ak sa slabý výkon presnejšie odliší od slabého úsilia, systém môže voľiť primeranú reakciu podľa príčiny, napríklad dopĺňajúcu podporu, zmenu typu úloh, úpravu spätnej väzby alebo rozhodnutie o preskakaní obsahu. Tým sa znižuje riziko, že adaptácia bude penalizovať používateľov s iným tempom práce, a zároveň sa zvyšuje spoľahlivosť záverov, ktoré sa z mikroučenia prenášajú do ďalších rozhodovacích vrstiev a do hodnotenia účinnosti obsahu.

V práci je tento prístup rozpracovaný v kapitole venovanej identifikácii rýchleho hľadania a nízkej angažovanosti v mikroučení, kde sa ukazuje prenositeľnosť metód z tradičných testovacích prostredí do nízko-stakes kontextu a zároveň sa tematizuje potreba prispôbiť ich rozhodovacie pravidlá špecifikám mikroučenia. Kapitola zdôrazňuje, že bez predchádzajúcej dátovej hygieny môže byť samotné profilovanie metodicky korektné, no prakticky zavádzajúce, pretože segmenty budú do veľkej miery odzrkadľovať režimy úsilia, nie stabilné rozdiely v učení.

Zároveň sa tým vytvára most k multi-view integrácii v záverečnej časti práce. Ak je správanie predspracované tak, aby sa odstránili alebo explicitne označili režimy nízkeho úsilia, výstupy z mikroučenia sa dajú bezpečnejšie kombinovať s inými pohľadmi bez toho, aby sa do integrácie prenášalo skreslenie z nekvalitných odpovedí. Prakticky to znamená, že mikroučenie prestáva byť problematickým zdrojom „šumu“, ale stáva sa kontrolovaným a porovnateľným vstupom pre adaptáciu aj pre syntézu profilov v heterogénnom dátovom prostredí.

Limity práce

Predložená habilitačná práca je zámerne postavená ako syntéza viacerých empirických línií a dátových pohľadov, čo zvyšuje jej praktickú relevanciu, ale zároveň kladie prirodzené limity na rozsah zovšeobecnenia prostredníctvom nasledovných obmedzení.

Rozsah a heterogenita prostredí, s ktorými sa pracuje naprieč kapitolami. Práca cielene kombinuje rôzne domény (VR, mikrolearning, FPS hra) a typy meraní, čo zvyšuje robustnosť navrhnutého procesu, ale zároveň obmedzuje priamočiaru porovnateľnosť výsledkov medzi jednotlivými štúdiami. Každá empirická časť pracuje s iným typom signálu a inou mierou kontrolovanosti podmienok. Preto sa prezentované osoby majú chápať ako dôkaz uskutočniteľnosti metodiky v špecifickom kontexte, nie ako jednotná univerzálna typológia platná naprieč všetkými virtuálnymi prostrediami.

Neúplnosť dát a redukcia vzorky na prienikoch. Viacpohľadové profilovanie je navrhnuté tak, aby s neúplnosťou vedelo pracovať (neskorá fúzia, váženie), no táto vlastnosť v praxi naráža na limity štatistickej sily. Ako ukázala záverečná prípadová štúdia, požiadavka na existenciu viacerých pohľadov (napr. prienik telemetrie a dotazníkov) spolu s požiadavkou na vysokú istotu (dual-CORE) môže výrazne zredukovať veľkosť analytickej vzorky. To vedie k tomu, že niektoré osoby sú lepšie podopreté jedným typom dát než iným, a že pri externom overovaní na malej prienikovej vzorke nemusia byť rozdiely štatisticky významné, aj keď sú vecne prítomné. Tento limit je riešený transparentným reportovaním neistoty, no v empirickej rovine zostáva viazaný na dostupnosť signálu a rozsah skúmanej vzorky.

Závislosť na rozhodnutiach v reprezentácii a ukotvení. Aj pri stability-first logike ostáva výsledok citlivý na expertné rozhodnutia v prípravnej fáze – konkrétne na voľbu časových okien, definície metrík a najmä na teoretické ukotvenie blokov (napr. ktoré metriky reprezentujú *Achiever* tendenciu). Práca tieto rozhodnutia sprístupňuje a kontroluje cez stabilitu, ale neodstraňuje fakt, že v behaviorálnych dátach neexistuje jediná prirodzená reprezentácia. Výsledné osoby sú teda podmienené tým, ako boli zadefinované vstupné kontrakty a mapovania v prvej fáze pipeline.

Deskriptívny charakter výsledkov a absencia intervenčného overenia. Osoby a taktiky sú v práci prezentované ako vysvetľujúce profily a ako podklad pre rozhodovanie, nie ako kauzálne dôkazy. Práca validuje replikovateľnosť a interpretovateľnosť segmentov, ale neoveruje ich úžitkovú hodnotu v experimente. Bez intervenčných štúdií nemožno tvrdiť, že adaptácia obsahu pre konkrétnu osobu reálne zlepší jeho výkon alebo retenciu. Práca týmto smerom pripravuje pôdu auditovateľnými profilmi, no samotnú kauzálnu validáciu ponecháva ako ďalší krok výskumu.

Prenositelnosť sémantiky medzi hrami a žánrami. Metodika je navrhnutá tak, aby bola prenositeľná na úrovni procesu (4-etapový model, kontrakty výstupov), ale konkrétne definície metrík a interpretácia taktík sú nutne viazané na mechaniky danej aplikácie. To znamená, že prenositeľný je postup (napr. extrahovať taktiky, hľadať stabilné jadro), nie automaticky získaný výsledok. Identifikované taktiky alebo osoby sú špecifické pre použitý FPS žáner a v strategickej alebo logickej hre by museli byť nahradené inými, doménovo špecifickými vzorcami.

Ďalšie smerovanie výskumu

V habilitačnej práci bolo predstavených viacero tematických línií a zároveň metodika, ktorá ich integruje do jedného rámca. Z toho vyplýva, že ide o širokú oblasť s prirodzeným priestorom pre ďalší výskum. Otvorené otázky sa dajú formulovať tak, aby terminologicky priamo nadväzovali na koncepty práce a zároveň rozšírili metodiku smerom k automatizácii, interpretovateľnosti a praxi. Otázky sú usporiadané podľa logiky 4-etapového procesu, ktorý rámcuje záverečnú syntézu.

1. Metodika a stabilita
 - Ako určiť minimálnu dĺžku pozorovania alebo minimálnu sadu udalostí, po ktorej sa nový používateľ presunie z nejistej zóny do stabilného jadra profilu? Dá sa tento bod predikovať skôr, než nastane, a použiť ho na riadenie zberu alebo intervencií?
 - Ako sa v čase mení príslušnosť používateľa k stabilnému jadrú profilu? Je presun medzi jadrom a hraničnou zónou signálom zmeny správania, alebo dôsledkom šumu a únavy, a ako tieto prípady algoritmicky rozlíšiť?
 - Dá sa navrhnúť meta-model, ktorý na základe pokrytia a kvality jednotlivých pohľadov odporučí integračnú stratégiu pre konkrétnu subpopuláciu, vrátane práce s rozporom medzi pohľadmi?
2. Dátová vrstva a harmonizácia
 - Ako upraviť spracovanie VR signálov tak, aby sa efekt novosti odstránil bez toho, aby sa museli nováčikovia vylučovať? Dá sa normalizácia riadiť odhadnutou úrovňou skúsenosti používateľa (napr. pod a nad prahom expozície)?
 - Ako premeniť detekciu rýchleho hádania a nízkej angažovanosti z post-hoc analýzy na postup, ktorý funguje online a dokáže priamo ovplyvniť nastavenie úlohy alebo spätnú väzbu?
 - Do akej miery sa dá automatizovať mapovanie položiek nových dotazníkov na latentné dimenzie existujúcich typológií tak, aby sa zachovala kontinuita profilovania pri zmene meracieho nástroja?
3. Procesná a behaviorálna vrstva (Stage 2)
 - Ako definovať univerzálny formát pre epizódové dáta tak, aby bolo možné porovnávať taktiky naprieč hrami a trénovať modely na dátach z viacerých hier súčasne?
 - Sú mikro-persony odvodené z jedného typu prostredia stabilné pri prechode do iných domén, alebo sú viazané na špecifický typ spätnej väzby a pravidiel? Aké podmienky musia platiť, aby bola prenositeľnosť obhájitelná?
4. Interpretácia a aplikácia (Stage 3 a Stage 4)
 - Ako generovať vysvetlenia profilov, ktoré sú zrozumiteľné pre prax, ale zároveň verné váham fúzie a explicitne priznávajú mieru nejistoty priradenia?
 - Aký je dopad personalizácie na používateľov v hraničnej zóne? Je vhodnejšie poskytnúť neutrálny režim, alebo cielene zbierať doplnujúci signál, prípadne použiť experimentálnu alokáciu, aby sa používateľ rýchlejšie presunul do stabilného jadra?

Z praktického hľadiska tieto otázky posúvajú metodiku od deskriptívnej roviny k rovine prediktívnej a preskriptívnej. Dôraz sa presúva na dynamiku v čase, automatizáciu rozhodovania a transparentnú prácu s neistotou vrátane férovosti pri hraničných prípadoch.

Bibliografia

- Abb, L., Bormann, C., Van der Aa, H., & Rehse, J.-R. (2022). Trace Clustering For User Behavior Mining. *European Conference on Information Systems. AIS (2022), Ecis*.
- Abulibdeh, A. (2025). A systematic and bibliometric review of artificial intelligence in sustainable education: Current trends and future research directions. *Sustainable Futures*, 10, 101033. <https://doi.org/https://doi.org/10.1016/j.sftr.2025.101033>
- Adhanom, I. B., MacNeillage, P., & Folmer, E. (2023). Eye Tracking in Virtual Reality: a Broad Review of Applications and Challenges. *Virtual Reality*, 27(2). <https://doi.org/10.1007/s10055-022-00738-z>
- Aeiad, E., & Meziane, F. (2019). An adaptable and personalised E-learning system applied to computer science Programmes design. *Education and Information Technologies*, 24(2). <https://doi.org/10.1007/s10639-018-9836-x>
- Aggarwal, C. C., Hinneburg, A., & Keim, D. A. (2001). On the surprising behavior of distance metrics in high dimensional space. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 1973. https://doi.org/10.1007/3-540-44503-x_27
- Agostinelli, S., Leotta, F., & Marrella, A. (2021). Interactive Segmentation of User Interface Logs. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 13121 LNCS. https://doi.org/10.1007/978-3-030-91431-8_5
- Agrawal, S., Bech, S., Berentsen, K., De Moor, K., & Forchhammer, S. (2021). Method for subjective assessment of immersion in audiovisual experiences. *AES: Journal of the Audio Engineering Society*, 69(9), 656–671. <https://doi.org/10.17743/jaes.2021.0013>
- Al-Surayhi, M. M., Al-Qahtani, M. R., Al-Marshadi, S. N., Al-Ghamdi, A. A. Q., & Al-Surayhi, M. M. (2025). Generative Artificial Intelligence in Game Design: A Narrative Review. *Journal of Ecohumanism*, 4(4). <https://doi.org/10.62754/joe.v4i4.6912>
- Alahmadi, S., & DeMars, C. E. (2025). From Item Estimates to Test Operations: The Cascading Effect of Rapid Guessing. *Journal of Educational Measurement*, 62(4). <https://doi.org/10.1111/jedm.70010>
- Alalwan, N., Cheng, L., Al-Samarraie, H., Yousef, R., Ibrahim Alzahrani, A., & Sarsam, S. M. (2020). Challenges and Prospects of Virtual Reality and Augmented Reality Utilization among Primary School Teachers: A Developing Country Perspective. *Studies in Educational Evaluation*, 66. <https://doi.org/10.1016/j.stueduc.2020.100876>
- Aldemir, T., Celik, B., & Kaplan, G. (2018). A qualitative investigation of student perceptions of game elements in a gamified course. *Computers in Human Behavior*, 78. <https://doi.org/10.1016/j.chb.2017.10.001>
- Allam, Z., Sharifi, A., Bibri, S. E., Jones, D. S., & Krogstie, J. (2022). The Metaverse as a Virtual Form of Smart Cities: Opportunities and Challenges for Environmental, Economic, and Social Sustainability in Urban Futures. *Smart Cities*, 5(3). <https://doi.org/10.3390/smartcities5030040>
- Alobaidi, I. A., Leopold, J. L., Allami, A. A., Elo, N. W., & Tanksley, D. (2021). Predictive analysis of real-time strategy games: A graph mining approach. In *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery* (Vol. 11, Issue 2). <https://doi.org/10.1002/widm.1398>
- Alonso-Fernández, C., Calvo-Morata, A., Freire, M., Martínez-Ortiz, I., & Fernández-Manjón, B. (2022). Game Learning Analytics: Blending Visual and Data Mining Techniques to Improve Serious Games and to Better Understand Player Learning. *Journal of Learning Analytics*, 9(3), 32–49. <https://doi.org/10.18608/jla.2022.7633>
- Alvarez, A., Font, J., & Togelius, J. (2022). Toward Designer Modeling Through Design Style Clustering. *IEEE Transactions on Games*, 14(4), 676–686. <https://doi.org/10.1109/TG.2022.3143800>
- Aminikhanghahi, S., & Cook, D. J. (2017). A survey of methods for time series change point detection. *Knowledge and Information Systems*, 51(2). <https://doi.org/10.1007/s10115-016-0987-z>
- Anderson, B. (2022). Student perceptions of using DataCamp in a data wrangling course. *International Journal of Teaching and Case Studies*, 13(2), 165. <https://doi.org/10.1504/ijtc.2022.125996>
- Anderson, S., & Falconer, R. (2025). Emergence of Player Tactics by expert-guided Machine Learning: An industry tower defence case study. *Entertainment Computing*, 54. <https://doi.org/10.1016/j.entcom.2025.100963>
- Arnau-González, P., Solera-Monforte, S., Wu, Y., & Arevalillo-Herráez, M. (2025). A framework for adapting conversational intelligent tutoring systems to enable collaborative learning. *Expert Systems with Applications*, 271, 126663. <https://doi.org/https://doi.org/10.1016/j.eswa.2025.126663>
- Arslan, Ö., Dennen, V., & Bong, J. (2023). Engaging Learners with Challenges and Badges: Designing and Evaluating a Microlearning System. *International Journal for Educational Media and Technology*, 16(2), 14–24. <https://ijemt.org/index.php/journal/article/view/290>
- Atli, K., Selman, W., & Ray, A. (2021). A Comprehensive Multicomponent Neurosurgical Course with use of Virtual Reality: Modernizing the Medical Classroom. *Journal of Surgical Education*, 78(4). <https://doi.org/10.1016/j.jsurg.2020.11.003>
- Avella, J. T., Kebritchi, M., Nunn, S. G., & Kanai, T. (2016). Learning analytics methods, benefits, and challenges in higher education: A systematic literature review. *Journal of Asynchronous Learning Network*, 20(2). <https://doi.org/10.24059/olj.v20i2.790>
- Aymane, E., Aziz, D., Abdelfatteh, H., & Abdelhak, A. (2024). Enabling Sustainable Learning: A Machine Learning Approach for an Eco-friendly Multi-factor Adaptive E-Learning System. *Procedia Computer Science*, 236, 533–540. <https://doi.org/https://doi.org/10.1016/j.procs.2024.05.063>
- Bachiri, Y. A., & Mouncif, H. (2023). Artificial Intelligence System in Aid of Pedagogical Engineering for Knowledge Assessment on MOOC Platforms: Open EdX and Moodle. *International Journal of Emerging Technologies in Learning*, 18(5), 144–160. <https://doi.org/10.3991/ijet.v18i05.36589>
- Bahassi, H., Azmi, M., & Khiat, A. (2024). Cognitive Systems for Education: Architectures, Innovations, and Comparative Analyses. *Procedia Computer Science*, 238, 436–443. <https://doi.org/https://doi.org/10.1016/j.procs.2024.06.045>
- Bakkes, S. C. J., Spronck, P. H. M., & van Lankveld, G. (2012). Player behavioural modelling for video games.

- Entertainment Computing*, 3(3), 71–79.
<https://doi.org/10.1016/j.entcom.2011.12.001>
- Ball, C., Huang, K. T., & Francis, J. (2021). Virtual reality adoption during the COVID-19 pandemic: A uses and gratifications perspective. *Telematics and Informatics*, 65.
<https://doi.org/10.1016/j.tele.2021.101728>
- Ballou, N., Denisova, A., Ryan, R., Rigby, C. S., & Deterding, S. (2024). The Basic Needs in Games Scale (BANGS): A new tool for investigating positive and negative video game experiences. *International Journal of Human-Computer Studies*, 188, 103289.
<https://doi.org/https://doi.org/10.1016/j.ijhcs.2024.103289>
- Banihashem, S. K., Dehghanzadeh, H., Clark, D., Noroozi, O., & Biemans, H. J. A. (2024). Learning analytics for online game-based learning: a systematic literature review. *Behaviour and Information Technology*, 43(12), 2689–2716. <https://doi.org/10.1080/0144929X.2023.2255301>
- Bareišytė, L., Slatman, S., Austin, J., Rosema, M., van Sintemaartensdijk, I., Watson, S., & Bode, C. (2024). Questionnaires for evaluating virtual reality: A systematic scoping review. *Computers in Human Behavior Reports*, 16, 100505.
<https://doi.org/https://doi.org/10.1016/j.chbr.2024.100505>
- Barredo Arrieta, A., Díaz-Rodríguez, N., Del Ser, J., Bénéttot, A., Tabik, S., Barbado, A., García, S., Gil-Lopez, S., Molina, D., Benjamins, R., Chatila, R., & Herrera, F. (2020). Explainable Artificial Intelligence (XAI): Concepts, taxonomies, opportunities and challenges toward responsible AI. *Information Fusion*, 58, 82–115.
<https://doi.org/10.1016/j.inffus.2019.12.012>
- Bartle, R. (1996). HEARTS, CLUBS, DIAMONDS, SPADES: PLAYERS WHO SUIT MUDS. *Journal of MUD Research*, 1(1), 19.
https://www.hayseed.net/MOO/JOVE/bartle.html%0Ahttps://www.researchgate.net/profile/Richard_Bartle/publication/247190693_Hearts_clubs_diamonds_spades_Players_who_suit_MUDs/links/540058700cf2194bc29ac4f2.pdf
- Bateman, C., Lowenhaupt, R., & Nacke, L. E. (2011). Player typology in theory and practice. *Proceedings of DiGRA 2011 Conference: Think Design Play*, 1–24.
<https://doi.org/10.26503/dl.v2011i1.562>
- Bauchhage, C., Drachen, A., & Sifa, R. (2015). Clustering Game Behavior Data. *IEEE Transactions on Computational Intelligence and AI in Games*, 7(3), 266–278.
<https://doi.org/10.1109/TCIAIG.2014.2376982>
- Baudry, J. P. (2015). Estimation and model selection for model-based clustering with the conditional classification likelihood. *Electronic Journal of Statistics*, 9.
<https://doi.org/10.1214/15-EJS1026>
- Bauer, E., Heitzmann, N., Bannert, M., Chernikova, O., Fischer, M. R., Frenzel, A. C., Gartmeier, M., Hofer, S. I., Holzberger, D., Kasneci, E., Koenen, J., Kosel, C., Küchemann, S., Kuhn, J., Michaeli, T., Neuhaus, B. J., Niklas, F., Obersteiner, A., Pfeffer, J., ... Fischer, F. (2025). Personalizing simulation-based learning in higher education. *Learning and Individual Differences*, 122, 102746.
<https://doi.org/https://doi.org/10.1016/j.lindif.2025.102746>
- Baumann, F., Emmert, D., Baumgartl, H., & Buettner, R. (2018). Hardcore Gamer Profiling: Results from an unsupervised learning approach to playing behavior on the Steam platform. *Procedia Computer Science*, 126.
<https://doi.org/10.1016/j.procs.2018.08.078>
- Ben-Hur, A., Elisseeff, A., & Guyon, I. (2002). A stability based method for discovering structure in clustered data. *Pacific Symposium on Biocomputing. Pacific Symposium on Biocomputing*.
https://doi.org/10.1142/9789812799623_0002
- Bertrand, M., & Bouchard, S. (2008). Applying the technology acceptance model to vr with people who are favorable to its use. *Journal of Cyber Therapy and Rehabilitation*, 1(2).
- Betancur-Chicué, V., & García-Valcárcel Muñoz-Repiso, A. (2023). Microlearning for the Development of Teachers' Digital Competence Related to Feedback and Decision Making. *Education Sciences*, 13(7), 1–13.
<https://doi.org/10.3390/educsci13070722>
- Bicalho, L. F., Baffa, A., & Feijo, B. (2019). A Game Analytics Model to Identify Player Profiles in Singleplayer Games. *Brazilian Symposium on Games and Digital Entertainment, SBGAMES, 2019-October*, 11–20.
<https://doi.org/10.1109/SBGAMES.2019.00013>
- Bojic, L. (2022). Metaverse through the prism of power and addiction: what will happen when the virtual world becomes more attractive than reality? In *European Journal of Futures Research* (Vol. 10, Issue 1).
<https://doi.org/10.1186/s40309-022-00208-4>
- Bonetti, F., Warnaby, G., & Quinn, L. (2018). *Augmented Reality and Virtual Reality in Physical and Online Retailing: A Review, Synthesis and Research Agenda*.
https://doi.org/10.1007/978-3-319-64027-3_9
- Bönte, W., Lombardo, S., & Urbig, D. (2017). Economics meets psychology: Experimental and self-reported measures of individual competitiveness. *Personality and Individual Differences*, 116.
<https://doi.org/10.1016/j.paid.2017.04.036>
- Botte, B., Bakkes, S., & Veltkamp, R. (2020). Motivation in Gamification: Constructing a Correlation Between Gamification Achievements and Self-determination Theory. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 12517 LNCS, 157–166.
https://doi.org/10.1007/978-3-030-63464-3_15
- Brbić, M., & Kopriva, I. (2018). Multi-view low-rank sparse subspace clustering. *Pattern Recognition*, 73.
<https://doi.org/10.1016/j.patcog.2017.08.024>
- Bris, A., Wang, T. Y. H., Zatzick, C. D., Miller, D. J. P., Fern, M. J., Cardinal, L. B., Gregoire, D. A., Shepherd, D. A., Westphal, J. D., Shani, G., Troster, C., Van Quaquebeke, N., Lanaj, K., Hollenbeck, J. R., Ilgen, D. R., Barnes, C. M., Harmon, S. J., Feldman, E. R., DesJardine, M. R., ... Sangiorgi, F. (2021). KNIGHTS, RAIDERS, AND TARGETS - THE IMPACT OF THE HOSTILE TAKEOVER - COFFEE,JC, LOWENSTEIN,L, ROSEACKERMAN,S. *JOURNAL OF BANKING & FINANCE*, 37(1), 547.
- Brockmyer, J. H., Fox, C. M., Curtiss, K. A., McBroom, E., Burkhart, K. M., & Pidruzny, J. N. (2009). The development of the Game Engagement Questionnaire: A measure of engagement in video game-playing. *Journal of Experimental Social Psychology*, 45(4).
<https://doi.org/10.1016/j.jesp.2009.02.016>
- Brown, E., & Cairns, P. (2004). A grounded investigation of game immersion. *Conference on Human Factors in Computing Systems - Proceedings*.
<https://doi.org/10.1145/985921.986048>
- Browne, M. N., & Keeley, S. M. (2002). Asking The Right Questions: A Guide to Critical Thinking 8th ed. In *Action Learning Worldwide*.
<https://play.google.com/store/books/details?id=2OuzQgAACAAJ>
- Bruni, F., Mancuso, V., & Pedrolì, E. (2025). How to evaluate user experience in digital health? A scoping review of

- questionnaires in virtual reality applications. In *Frontiers in Digital Health* (Vol. 7).
https://doi.org/10.3389/fdgth.2025.1561364
- Buciuman, C.-F., & Potra, S. (2025). Revolutionizing Education in Industry 4.0: Eye-Tracking and AI for Personalized Learning. *Procedia Computer Science*, 253, 1658–1667.
https://doi.org/https://doi.org/10.1016/j.procs.2025.01.228
- Bunian, S., Canossa, A., Colvin, R., & El-Nasr, M. S. (2017). Modeling individual differences in game behavior using HMM. *Proceedings of the 13th AAAI Conference on Artificial Intelligence and Interactive Digital Entertainment, AIIDE 2017*, 158–164.
https://doi.org/10.1609/aiide.v13i1.12942
- Bunz, U., Seibert, J., & Hendrickse, J. (2021). From TAM to AVRTS: development and validation of the attitudes toward Virtual Reality Technology Scale. *Virtual Reality*, 25(1).
https://doi.org/10.1007/s10055-020-00437-7
- Buraya, K., Farseev, A., & Filchenkov, A. (2018). Multi-view personality profiling based on longitudinal data. *Lecture Notes in Computer Science*, 11018 LNCS.
https://doi.org/10.1007/978-3-319-98932-7_2
- Busch, M., Mattheiss, E., Hochleitner, W., Hochleitner, C., Lankes, M., Fröhlich, P., Orji, R., & Tscheligi, M. (2016). Using player type models for personalized game design - An empirical investigation. *Interaction Design and Architecture(S)*, 28(1), 145–163.
https://doi.org/10.55612/s-5002-028-008
- Busch, M., Mattheiss, E., Orji, R., Fröhlich, P., Lankes, M., & Tscheligi, M. (2016). Player type models - Towards empirical validation. *Conference on Human Factors in Computing Systems - Proceedings, 07-12-May-, 1835–1841*. https://doi.org/10.1145/2851581.2892399
- Caballero-Hernández, J. A., Palomo-Duarte, M., Dodero, J. M., & Gašević, D. (2024). Supporting Skill Assessment in Learning Experiences Based on Serious Games Through Process Mining Techniques. *International Journal of Interactive Multimedia and Artificial Intelligence*, 8(6).
https://doi.org/10.9781/ijimai.2023.05.002
- Caldas, O. I., Sanchez, N., Mauleudoux, M., Avilés, O. F., & Rodriguez-Guerrero, C. (2022). Leading presence-based strategies to manipulate user experience in virtual reality environments. *Virtual Reality*, 26(4).
https://doi.org/10.1007/s10055-022-00645-3
- Canagarajah, S. (2019). Microlearning in the Digital Age: The Design and Delivery of Learning in Snippets. In *Microlearning in the Digital Age: The Design and Delivery of Learning in Snippets*.
https://doi.org/10.4324/9780367821623
- Canossa, A., Makarovych, S., Togelius, J., & Drachen, A. (2018). Like a DNA string: Sequence-based player profiling in Tom Clancy's the Division. *Proceedings of the 14th AAAI Conference on Artificial Intelligence and Interactive Digital Entertainment, AIIDE 2018*.
https://doi.org/10.1609/aiide.v14i1.13049
- Cavanagh, T., Chen, B., Lahcen, R. A. M., & Paradiso, J. R. (2020). Constructing a design framework and pedagogical approach for adaptive learning in higher education: A practitioner's perspective. *International Review of Research in Open and Distributed Learning*, 21(1).
https://doi.org/10.19173/irrodl.v21i1.4529
- Chao, G., Sun, S., & Bi, J. (2021a). A Survey on Multiview Clustering. *IEEE Transactions on Artificial Intelligence*, 2(2).
https://doi.org/10.1109/TAI.2021.3065894
- Chao, G., Sun, S., & Bi, J. (2021b). A Survey on Multi-View Clustering. *IEEE Transactions on Artificial Intelligence*, 2(2), 146–168. https://doi.org/10.1109/tai.2021.3065894
- Chapman, C. N., & Milham, R. P. (2006). The personas' new clothes: Methodological and practical arguments against a popular method. *Proceedings of the Human Factors and Ergonomics Society*.
https://doi.org/10.1177/154193120605000503
- Chen, M. S., Huang, L., Wang, C. D., Huang, D., & Yu, P. S. (2022). Multiview Subspace Clustering With Grouping Effect. *IEEE Transactions on Cybernetics*, 52(8).
https://doi.org/10.1109/TCYB.2020.3035043
- Chen, P. P., Guitart, A., Del Río, A. F., & Periañez, A. (2018). Customer Lifetime Value in Video Games Using Deep Learning and Parametric Models. *Proceedings - 2018 IEEE International Conference on Big Data, Big Data 2018*.
https://doi.org/10.1109/BigData.2018.8622151
- Chen, S. Y., & Wang, J. H. (2021). Individual differences and personalized learning: a review and appraisal. In *Universal Access in the Information Society* (Vol. 20, Issue 4).
https://doi.org/10.1007/s10209-020-00753-4
- Chen, Zefeng, & Gan, W. (2024). Towards episode rules with non-overlapping frequency and targeted mining. *Information Sciences*, 678. https://doi.org/10.1016/j.ins.2024.121028
- Chen, Zhenshan, Tian, X., Gao, L., Liao, G., Shen, Y., Zheng, K., & Fang, J. (2025). Exploring Dynamic Hierarchical Fusion for Multi-View Clustering. *IEEE Access*, 13.
https://doi.org/10.1109/ACCESS.2025.3550923
- Cheng, F., Liu, D., Du, F., Lin, Y., Zytek, A., Li, H., Qu, H., & Veeramachaneni, K. (2022). VBridge: Connecting the Dots between Features and Data to Explain Healthcare Models. *IEEE Transactions on Visualization and Computer Graphics*, 28(1), 378–388.
https://doi.org/10.1109/TVCG.2021.3114836
- Chiu, T. K. F., Xia, Q., Zhou, X., Chai, C. S., & Cheng, M. (2023). Systematic literature review on opportunities, challenges, and future research recommendations of artificial intelligence in education. *Computers and Education: Artificial Intelligence*, 4.
https://doi.org/10.1016/j.caeai.2022.100118
- Chowdhury, A. R., Gupta, A., & Das, S. (2025). Deep multi-view clustering: A comprehensive survey of the contemporary techniques. *Information Fusion*, 119.
https://doi.org/10.1016/j.inffus.2025.103012
- Chung, G. K. W. K. (2015). Guidelines for the design and implementation of game telemetry for serious games analytics. In *Serious Games Analytics: Methodologies for Performance Measurement, Assessment, and Improvement*. https://doi.org/10.1007/978-3-319-05834-4_3
- Close, J., Spicer, S. G., Nicklin, L. L., Uther, M., Lloyd, J., & Lloyd, H. (2021). Secondary analysis of loot box data: Are high-spending “whales” wealthy gamers or problem gamblers? *Addictive Behaviors*, 117, 106851.
https://doi.org/10.1016/j.addbeh.2021.106851
- Cohen, J. (2018). Defining Identification: A Theoretical Look at the Identification of Audiences With Media Characters. In *Advances in Foundational Mass Communication Theories*.
https://doi.org/10.4324/9781315164441-14
- Colombo, S., Hansson, P., & Nyström, M. B. T. (2023). Mining players' experience in computer games: Immersion affects flow but not presence. *Computers in Human Behavior Reports*, 12, 100334.
https://doi.org/10.1016/j.chbr.2023.100334
- Coretto, P. (2022). Estimation and computations for Gaussian mixtures with uniform noise under separation constraints. *Statistical Methods and Applications*, 31(2).

- <https://doi.org/10.1007/s10260-021-00578-2>
- Csikszentmihalyi, M. (2012). The flow experience and its significance for human psychology. In *Optimal Experience*. <https://doi.org/10.1017/cbo9780511621956.002>
- Cummings, J. J., & Bailenson, J. N. (2016). How Immersive Is Enough? A Meta-Analysis of the Effect of Immersive Technology on User Presence. *Media Psychology*, 19(2). <https://doi.org/10.1080/15213269.2015.1015740>
- Cuturi, M., & Blondel, M. (2017). Soft-DTW: A differentiable loss function for time-series. *34th International Conference on Machine Learning, ICML 2017*, 2.
- Davis, F. D., Bagozzi, R. P., & Warshaw, P. R. (1989). User Acceptance of Computer Technology: A Comparison of Two Theoretical Models. *Management Science*, 35(8). <https://doi.org/10.1287/mnsc.35.8.982>
- Deeva, G., Bogdanova, D., Serral, E., Snoeck, M., & De Weerd, J. (2021). A review of automated feedback systems for learners: Classification framework, challenges and opportunities. *Computers and Education*, 162. <https://doi.org/10.1016/j.compedu.2020.104094>
- Demirtas, H. (2018). Flexible Imputation of Missing Data. *Journal of Statistical Software*, 85(Book Review 4). <https://doi.org/10.18637/jss.v085.b04>
- Denzin, N. K. (2018). Strategies of Multiple Triangulation. In *The Research Act*. <https://doi.org/10.4324/9781315134543-12>
- Deribo, T., Goldhammer, F., & Kroehne, U. (2023). Changes in the Speed–Ability Relation Through Different Treatments of Rapid Guessing. *Educational and Psychological Measurement*, 83(3), 473–494. <https://doi.org/10.1177/00131644221109490>
- Deribo, T., Kroehne, U., & Goldhammer, F. (2021). Model-Based Treatment of Rapid Guessing. *Journal of Educational Measurement*, 58(2), 281–303. <https://doi.org/10.1111/jedm.12290>
- di Lanzo, J. A., Valentine, A., Soheli, F., Yapp, A. Y. T., Muparadzi, K. C., & Abdelmalek, M. (2020). A review of the uses of virtual reality in engineering education. In *Computer Applications in Engineering Education* (Vol. 28, Issue 3). <https://doi.org/10.1002/cae.22243>
- Diamond, L., Tondello, G. F., Marczewski, A., Nacke, L. E., & Tscheligi, M. (2015). The HEXAD Gamification User Types Questionnaire : Background and Development Process. *Workshop on Personalization in Serious and Persuasive Games and Gamified Interactions*.
- Disztinger, P., Schlögl, S., & Groth, A. (2017). Technology Acceptance of Virtual Reality for Travel Planning. In *Information and Communication Technologies in Tourism 2017*. https://doi.org/10.1007/978-3-319-51168-9_19
- Ditton, E., Swinbourne, A., & Myers, T. (2022). Selecting a clustering algorithm: A semi-automated hyperparameter tuning framework for effective persona development. *Array*, 14. <https://doi.org/10.1016/j.array.2022.100186>
- Dixon, D. (2011). Player Types and Gamification. *CHI 2011 Workshop Gamification Using Game Design Elements in NonGame Contexts*.
- Dolasinski, M. J., & Reynolds, J. (2020). Microlearning: A New Learning Model. *Journal of Hospitality and Tourism Research*, 44(3), 551–561. <https://doi.org/10.1177/1096348020901579>
- Dombrovskis, V., Ļevina, J., & Ruža, A. (2025). Extending the game immersion questionnaire to online users. *Frontiers in Psychology*, 16, 1473821. <https://doi.org/10.3389/fpsyg.2025.1473821>
- Dong, A., Jong, M. S. Y., & King, R. B. (2020). How Does Prior Knowledge Influence Learning Engagement? The Mediating Roles of Cognitive Load and Help-Seeking. *Frontiers in Psychology*, 11. <https://doi.org/10.3389/fpsyg.2020.591203>
- Drachen, A. (2015). *Behavioral Telemetry in Games User Research*. https://doi.org/10.1007/978-3-319-15985-0_7
- Drachen, A., Seif El-Nasr, M., & Canossa, A. (2013). Game Analytics – The Basics. In *Game Analytics* (pp. 13–40). https://doi.org/10.1007/978-1-4471-4769-5_2
- Drachen, A., Thureau, C., Sifa, R., & Bauckhage, C. (2014). A comparison of methods for player clustering via behavioral telemetry. *ArXiv Preprint ArXiv:1407.3950*, 1–8.
- Dresen, I. M. G., Boes, T., Huesing, J., Neuhaeuser, M., & Joeckel, K. H. (2008). New resampling method for evaluating stability of clusters. *BMC Bioinformatics*, 9. <https://doi.org/10.1186/1471-2105-9-42>
- du Plooy, E., Casteleijn, D., & Franzsen, D. (2024). Personalized adaptive learning in higher education: A scoping review of key characteristics and impact on academic performance and engagement. *Heliyon*, 10(21), e39630. <https://doi.org/https://doi.org/10.1016/j.heliyon.2024.e39630>
- Dunn, J. C., & Zimmer, C. (2020). Self-determination theory. In *Routledge Handbook of Adapted Physical Education*. <https://doi.org/10.4324/9780429052675-23>
- Dwivedi, R., Dave, D., Naik, H., Singhal, S., Omer, R., Patel, P., Qian, B., Wen, Z., Shah, T., Morgan, G., & Ranjan, R. (2023). Explainable AI (XAI): Core Ideas, Techniques, and Solutions. *ACM Computing Surveys*, 55(9), 1–33. <https://doi.org/10.1145/3561048>
- Edmondson, R. N. (2020). Multi-level Block Designs for Comparative Experiments. *Journal of Agricultural, Biological, and Environmental Statistics*, 25(4). <https://doi.org/10.1007/s13253-020-00416-0>
- Egozcue, J. J., Pawłowsky-Glahn, V., Mateu-Figueras, G., & Barceló-Vidal, C. (2003). Isometric Logratio Transformations for Compositional Data Analysis. *Mathematical Geology*, 35(3). <https://doi.org/10.1023/A:1023818214614>
- El-Nasr, M. S., Dinh, T. H. N., Canossa, A., & Drachen, A. (2021). Clustering Methods in Game Data Science. In *Game Data Science* (pp. 133–178). <https://doi.org/10.1093/oso/9780192897879.003.0006>
- Elbert, N., & Flath, C. M. (2024). Process Mining for Game Analytics. *IEEE Conference on Computational Intelligence and Games, CIG*. <https://doi.org/10.1109/CoG60054.2024.10645544>
- Elhalid, O. B., Alm Alhelal, Z., & HASSAN, S. (2023). Exploring the Fundamentals of Python Programming: A Comprehensive Guide for Beginners. *SSRN Electronic Journal*, 04262975, 1–19. <https://doi.org/10.2139/ssrn.4612765>
- Ellison, A. B., Bliemer, M. C. J., & Greaves, S. P. (2015). Evaluating changes in driver behaviour: A risk profiling approach. *Accident Analysis and Prevention*, 75. <https://doi.org/10.1016/j.aap.2014.12.018>
- Engert, M., Evers, J., Hein, A., & Krcmar, H. (2023). Sustaining complementor engagement in digital platform ecosystems: Antecedents, behaviours and engagement trajectories. *Information Systems Journal*, 33(5). <https://doi.org/10.1111/isj.12438>
- Fan, C., Peng, Y., Peng, S., Zhang, H., Wu, Y., & Kwong, S. (2022). Detection of Train Driver Fatigue and Distraction Based on Forehead EEG: A Time-Series Ensemble Learning Method. *IEEE Transactions on Intelligent Transportation Systems*, 23(8). <https://doi.org/10.1109/TITS.2021.3125737>
- Fang, U., Li, M., Li, J., Gao, L., Jia, T., & Zhang, Y. (2023). A

- Comprehensive Survey on Multi-View Clustering. *IEEE Transactions on Knowledge and Data Engineering*, 35(12). <https://doi.org/10.1109/TKDE.2023.3270311>
- Farcomeni, A., & Punzo, A. (2020). Robust model-based clustering with mild and gross outliers. *Test*, 29(4). <https://doi.org/10.1007/s11749-019-00693-z>
- Ferguson, M., Devlin, S., Kudenko, D., & Walker, J. A. (2020). Player Style Clustering without Game Variables. *ACM International Conference Proceeding Series*, 1–4. <https://doi.org/10.1145/3402942.3402960>
- Fernandes, C. W., Rafatirad, S., & Sayadi, H. (2023). Advancing Personalized and Adaptive Learning Experience in Education with Artificial Intelligence. *EAEIE 2023 - Proceedings of the 2023 32nd Annual Conference of the European Association for Education in Electrical and Information Engineering*. <https://doi.org/10.23919/EAEIE55804.2023.10181336>
- Fiş Erümit, S., Şılıbr, L., Erümit, A. K., & Karal, H. (2021). Determination of Player Types according to Digital Game Playing Preferences: Scale Development and Validation Study. *International Journal of Human-Computer Interaction*, 37(11), 991–1002. <https://doi.org/10.1080/10447318.2020.1861765>
- Flick, U. (2017). Mantras and Myths: The Disenchantment of Mixed-Methods Research and Revisiting Triangulation as a Perspective. *Qualitative Inquiry*, 23(1). <https://doi.org/10.1177/1077800416655827>
- Fong, T. C. T., Lu, S., Ye, X., Junus, A., & Yip, P. S. F. (2024). Validation of the 12-item Gamification User Types Hexad Scale in 1,610 Hong Kong Young Gamers. *International Journal of Mental Health and Addiction*. <https://doi.org/10.1007/s11469-024-01367-0>
- Fraley, C., & Raftery, A. E. (2002). Model-based clustering, discriminant analysis, and density estimation. *Journal of the American Statistical Association*, 97(458). <https://doi.org/10.1198/016214502760047131>
- Fu, X., Chen, X., Shi, Y. T., Bose, I., & Cai, S. (2017). User segmentation for retention management in online social games. *Decision Support Systems*, 101, 51–68. <https://doi.org/10.1016/j.dss.2017.05.015>
- Fuchs, M., & Höpken, W. (2022). Clustering: Hierarchical, k-Means, DBSCAN. In *Tourism on the Verge: Vol. Part F1051*. https://doi.org/10.1007/978-3-030-88389-8_8
- Fussell, S. G., & Truong, D. (2023). Accepting virtual reality for dynamic learning: an extension of the technology acceptance model. *Interactive Learning Environments*, 31(9). <https://doi.org/10.1080/10494820.2021.2009880>
- Gaeta, A., Orciuoli, F., Pascuzzo, A., & Peduto, A. (2025). Enhancing traditional ITS architectures with large language models for generating motivational feedback. *Computers and Education: Artificial Intelligence*, 9, 100433. <https://doi.org/https://doi.org/10.1016/j.caeai.2025.100433>
- García-Escudero, L. A., & Mayo-Iscar, A. (2024). Robust clustering based on trimming. *Wiley Interdisciplinary Reviews: Computational Statistics*, 16(4), e1658.
- García-Escudero, L. A., Gordaliza, A., Matrán, C., & Mayo-Iscar, A. (2008). A general trimming approach to robust cluster analysis. *Annals of Statistics*, 36(3). <https://doi.org/10.1214/07-AOS515>
- García-Sánchez, P., Fernández-Ares, A., Tonda, A. P., & Mora, A. M. (2020). Data mining of deck archetypes in hearthstone. *CEUR Workshop Proceedings*, 2719, 132–144.
- Georgiou, Y., & Kyza, E. A. (2017). The development and validation of the ARI questionnaire: An instrument for measuring immersion in location-based augmented reality settings. *International Journal of Human Computer Studies*, 98, 24–37. <https://doi.org/10.1016/j.ijhcs.2016.09.014>
- Gewers, F. L., Ferreira, G. R., De Arruda, H. F., Silva, F. N., Comin, C. H., Amancio, D. R., & Costa, L. D. F. (2022). Principal component analysis: A natural approach to data exploration. *ACM Computing Surveys*, 54(4). <https://doi.org/10.1145/3447755>
- Ghaderpour, E., Pagiatakis, S. D., & Hassan, Q. K. (2021). A survey on change detection and time series analysis with applications. In *Applied Sciences (Switzerland)* (Vol. 11, Issue 13). <https://doi.org/10.3390/app11136141>
- Gharghabi, S., Yeh, C. C. M., Ding, Y., Ding, W., Hibbing, P., LaMunion, S., Kaplan, A., Crouter, S. E., & Keogh, E. (2019). Domain agnostic online semantic segmentation for multi-dimensional time series. *Data Mining and Knowledge Discovery*, 33(1). <https://doi.org/10.1007/s10618-018-0589-3>
- Goldhammer, F., Martens, T., Christoph, G., & Lüdtke, O. (2016). TEST-TAKING ENGAGEMENT IN PIAAC. In *OECD Education Working Papers* (Issue 133).
- Gönen, M. (2004). Sample size and power for McNemar's test with clustered data. *Statistics in Medicine*, 23(14), 2283–2294. <https://doi.org/10.1002/sim.1768>
- González-González, C. S., Toledo-Delgado, P. A., Muñoz-Cruz, V., & Arnedo-Moreno, J. (2022). Gender and Age Differences in Preferences on Game Elements and Platforms. *Sensors*, 22(9), 3567. <https://doi.org/10.3390/s22093567>
- Granić, A. (2022). Educational Technology Adoption: A systematic review. *Education and Information Technologies*, 27(7). <https://doi.org/10.1007/s10639-022-10951-7>
- Gris, G., & Bengtson, C. (2021). Assessment measures in game-based learning research: A systematic review. *International Journal of Serious Games*, 8(1). <https://doi.org/10.17083/ijsg.v8i1.383>
- Grosu, M.-A., & Nicola, S. (2025). Analyzing Player Behavior in a VR Game for Children Using Gameplay Telemetry. *Multimodal Technologies and Interaction*, 9(9), 96. <https://doi.org/10.3390/mti909096>
- Gu, X., Angelov, P. P., Kangin, D., & Principe, J. C. (2017). A new type of distance metric and its use for clustering. *Evolving Systems*, 8(3). <https://doi.org/10.1007/s12530-017-9195-7>
- Guerra-Tamez, C. R. (2023). The Impact of Immersion through Virtual Reality in the Learning Experiences of Art and Design Students: The Mediating Effect of the Flow Experience. *Education Sciences*, 13(2). <https://doi.org/10.3390/educsci13020185>
- Guimarães, D., Correia, A., Paulino, D., Cabral, D., Alves, L., Teixeira, M., & Paredes, H. (2025). BartleZ: A Gamified Approach to Overturn Traditional Bartle Player Type Attribution. *Proceedings of the 11th International Conference on Software Development and Technologies for Enhancing Accessibility and Fighting Info-Exclusion*, 164–172. <https://doi.org/10.1145/3696593.3696646>
- Gunes, M. A., Kavum, M. F., & Sariel, S. (2022). A Generic Approach for Player Modeling Using Event-Trait Mapping Supported by PCA. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 13262 LNCS, 197–207. https://doi.org/10.1007/978-3-031-11488-5_18
- Guo, Chenfeng, & Wu, D. (2022). A survey on canonical correlation analysis based multi-view learning. *Chinese Journal of Intelligent Science and Technology*, 4(1). <https://doi.org/10.11959/j.issn.2096-6652.202206>
- Guo, Chuan, Pleiss, G., Sun, Y., & Weinberger, K. Q. (2017). On

- calibration of modern neural networks. *34th International Conference on Machine Learning, ICML 2017*, 3.
- Guo, H., Rios, J. A., Haberman, S., Liu, O. L., Wang, J., & Paek, I. (2016). A New Procedure for Detection of Students' Rapid Guessing Responses Using Response Time. *Applied Measurement in Education*, 29(3), 173–183. <https://doi.org/10.1080/08957347.2016.1171766>
- Habibi, R., Pfau, J., & El-Nasr, M. S. (2023). Modeling Player Personality Factors from In-Game Behavior and Affective Expression. *2023 11th International Conference on Affective Computing and Intelligent Interaction Workshops and Demos, ACIIW 2023*, 1–8. <https://doi.org/10.1109/ACIIW59127.2023.10388138>
- Hadi Mogavi, R., Deng, C., Hoffman, J., Haq, E. U., Gujar, S., Bucchiarone, A., & Hui, P. (2023). Your Favorite Gameplay Speaks Volumes About You: Predicting User Behavior and Hexad Type. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 14047 LNCS. https://doi.org/10.1007/978-3-031-35979-8_17
- Hair, J. F., Risher, J. J., Sarstedt, M., & Ringle, C. M. (2019). When to use and how to report the results of PLS-SEM. In *European Business Review* (Vol. 31, Issue 1). <https://doi.org/10.1108/EBR-11-2018-0203>
- Haldar, S., Sengupta, S., & Das, A. K. (2025). Personalized Learning Path Recommendation using Graph Reinforcement Learning. *Procedia Computer Science*, 258, 3480–3489. <https://doi.org/https://doi.org/10.1016/j.procs.2025.04.604>
- Haley, J., Hoehn, R., Singleton, J. L., Ballinger, C., & Carbonara, A. (2021). *Deep Embedded Knowledge Graph Representations for Tactic Discovery*. https://doi.org/10.1007/978-3-030-70296-0_5
- Halim, Z., Atif, M., Rashid, A., & Edwin, C. A. (2019). Profiling Players Using Real-World Datasets: Clustering the Data and Correlating the Results with the Big-Five Personality Traits. *IEEE Transactions on Affective Computing*, 10(4). <https://doi.org/10.1109/TAFFC.2017.2751602>
- Halim, Z., & Uzma. (2018). Optimizing the minimum spanning tree-based extracted clusters using evolution strategy. *Cluster Computing*, 21(1). <https://doi.org/10.1007/s10586-017-0868-6>
- Halvonik, D., & Kapusta, J. (2020). Framework for e-learning materials optimization. *International Journal of Emerging Technologies in Learning*, 15(11). <https://doi.org/10.3991/IJET.V15I11.12721>
- Halvonik, D., Kapusta, J., & Munk, M. (2023). Improve estimated time-on-task calculation in a Virtual Learning Environment. *Interactive Learning Environments*, 31(5), 2914–2929. <https://doi.org/10.1080/10494820.2021.1913609>
- Hamari, J., & Tuunainen, J. (2014). Player Types: A Meta-synthesis. *Transactions of the Digital Games Research Association*, 1(2). <https://doi.org/10.26503/todigra.v1i2.13>
- Hamutoğlu, N. B., Topal, M., Samur, Y., Gezgin, D. M., & Griffiths, M. D. (2020). The development of the online player type scale: Construct validity and reliability testing. *International Journal of Cyber Behavior, Psychology and Learning*, 10(1). <https://doi.org/10.4018/IJCBPL.2020010102>
- Han, X., Peng, H., & Liu, M. (2025). The impact of GenAI on learning outcomes: A systematic review and meta-analysis of experimental studies. *Educational Research Review*, 48, 100714. <https://doi.org/https://doi.org/10.1016/j.edurev.2025.100714>
- Hare, R., & Tang, Y. (2023). Player Modeling and Adaptation Methods Within Adaptive Serious Games. *IEEE Transactions on Computational Social Systems*, 10(4). <https://doi.org/10.1109/TCSS.2022.3203926>
- Haris, M., Yusoff, Y., Mohd Zain, A., Khattak, A. S., & Hussain, S. F. (2024). Breaking down multi-view clustering: A comprehensive review of multi-view approaches for complex data structures. In *Engineering Applications of Artificial Intelligence* (Vol. 132). <https://doi.org/10.1016/j.engappai.2024.107857>
- Hart, C. M., Ritchie, T. D., Hepper, E. G., & Gebauer, J. E. (2015). The Balanced Inventory of Desirable Responding Short Form (BIDR-16). *SAGE Open*, 5(4). <https://doi.org/10.1177/2158244015621113>
- Hassan, B. A., Tayfor, N. B., Hassan, A. A., Ahmed, A. M., Rashid, T. A., & Abdalla, N. N. (2024). From A-to-Z review of clustering validation indices. In *Neurocomputing* (Vol. 601). <https://doi.org/10.1016/j.neucom.2024.128198>
- Hauptmann, T., & Kramer, S. (2023). A fair experimental comparison of neural network architectures for latent representations of multi-omics for drug response prediction. *BMC Bioinformatics*, 24(1). <https://doi.org/10.1186/s12859-023-05166-7>
- Hayes, R., & Beling, P. (2018). Unsupervised Hierarchical Clustering of Build Orders in a Real-Time Strategy Game. *The Computer Games Journal*, 7(1). <https://doi.org/10.1007/s40869-018-0051-1>
- Heale, R., & Forbes, D. (2013). Understanding triangulation in research. In *Evidence-Based Nursing* (Vol. 16, Issue 4). <https://doi.org/10.1136/eb-2013-101494>
- Heber, E., Ebert, D. D., Lehr, D., Cuijpers, P., Berking, M., Nobis, S., & Riper, H. (2017). The benefit of web- and computer-based interventions for stress: A systematic review and meta-analysis. In *Journal of Medical Internet Research* (Vol. 19, Issue 2, p. e32). <https://doi.org/10.2196/jmir.5774>
- Hemzo, M. A. (2023). Defining the Persona: Segmentation and Targeting. In *Marketing Luxury Services*. https://doi.org/10.1007/978-3-030-86073-8_6
- Hennig, C. (2007). Cluster-wise assessment of cluster stability. *Computational Statistics and Data Analysis*, 52(1). <https://doi.org/10.1016/j.csda.2006.11.025>
- Heuser, B. (2010). The evolution of strategy: Thinking war from antiquity to the present. In *The Evolution of Strategy: Thinking War from Antiquity to the Present*. <https://doi.org/10.1017/CBO9780511762895>
- Hitchcock, J. H., & Onwuegbuzie, A. J. (2022). THE ROUTLEDGE HANDBOOK FOR ADVANCING INTEGRATION IN MIXED METHODS RESEARCH. In *The Routledge Handbook for Advancing Integration in Mixed Methods Research*. <https://doi.org/10.4324/9780429432828>
- Högberg, J., Hamari, J., & Wästlund, E. (2019). Gameful Experience Questionnaire (GAMEFULQUEST): an instrument for measuring the perceived gamefulness of system use. *User Modeling and User-Adapted Interaction*, 29(3). <https://doi.org/10.1007/s11257-019-09223-w>
- Holl, E., Sischka, P. E., Wagener, G. L., & Melzer, A. (2024). The Motivation to Play Scale (MOPS) - introducing a validated measure of gaming motivation. *Current Psychology*, 43(39). <https://doi.org/10.1007/s12144-024-06631-z>
- Hooshyar, D., Yousefi, M., & Lim, H. (2019). A systematic review of data-driven approaches in player modeling of educational games. In *Artificial Intelligence Review* (Vol. 52, Issue 3). <https://doi.org/10.1007/s10462-017-9609-8>
- Horvers, A., Molenaar, I., Bosse, T., & Lazonder, A. W. (2025). Emotional responses to feedback in adaptive learning

- technologies for early mathematics education. *Learning and Instruction*, 99, 102192. <https://doi.org/https://doi.org/10.1016/j.learninstruc.2025.102192>
- Hosseini, M., Powell, M., Collins, J., Callahan-Flintoft, C., Jones, W., Bowman, H., & Wyble, B. (2020). I tried a bunch of things: The dangers of unexpected overfitting in classification of brain data. In *Neuroscience and Biobehavioral Reviews* (Vol. 119). <https://doi.org/10.1016/j.neubiorev.2020.09.036>
- Hou, B. J., Abdrabou, Y., Weidner, F., & Gellersen, H. (2024). Unveiling Variations: A Comparative Study of VR Headsets Regarding Eye Tracking Volume, Gaze Accuracy, and Precision. *Proceedings - 2024 IEEE Conference on Virtual Reality and 3D User Interfaces Abstracts and Workshops, VRW 2024*. <https://doi.org/10.1109/VRW62533.2024.00127>
- Hsieh, J. L., & Sun, C. T. (2008). Building a player strategy model by analyzing replays of real-time strategy games. *Proceedings of the International Joint Conference on Neural Networks*. <https://doi.org/10.1109/IJCNN.2008.4634237>
- Hu, R., Wu, Y. Y., & Shieh, C. J. (2016). Effects of virtual reality integrated creative thinking instruction on students' creative thinking abilities. *Eurasia Journal of Mathematics, Science and Technology Education*, 12(3). <https://doi.org/10.12973/eurasia.2016.1226a>
- Huang, F. H. (2020). Adapting UTAUT2 to assess user acceptance of an e-scooter virtual reality service. *Virtual Reality*, 24(4). <https://doi.org/10.1007/s10055-019-00424-7>
- Huang, H. M., Rauch, U., & Liaw, S. S. (2010). Investigating learners' attitudes toward virtual reality learning environments: Based on a constructivist approach. *Computers and Education*, 55(3). <https://doi.org/10.1016/j.compedu.2010.05.014>
- Huang, L., Ruan, S., Decazes, P., & Deneux, T. (2025). Deep evidential fusion with uncertainty quantification and reliability learning for multimodal medical image segmentation. *Information Fusion*, 113. <https://doi.org/10.1016/j.inffus.2024.102648>
- Huang, W., Roscoe, R. D., Johnson-Glenberg, M. C., & Craig, S. D. (2021). Motivation, engagement, and performance across multiple virtual reality sessions and levels of immersion. *Journal of Computer Assisted Learning*, 37(3). <https://doi.org/10.1111/jcal.12520>
- Hubert, L., & Arabie, P. (1985). Comparing partitions. *Journal of Classification*, 2(1). <https://doi.org/10.1007/BF01908075>
- Hug, T. (2005). Microlearning : A New Pedagogical Challenge. *Proceedings of Microlearning Conference 2005*.
- Hughes, R. A., Heron, J., Sterne, J. A. C., & Tilling, K. (2019). Accounting for missing data in statistical analyses: Multiple imputation is not always the answer. *International Journal of Epidemiology*, 48(4). <https://doi.org/10.1093/ije/dyz032>
- Hussain, J., Khan, W. A., Hur, T., Bilal, H. S. M., Bang, J., Ul Hassan, A., Afzal, M., & Lee, S. (2018). A multimodal deep log-based user experience (UX) platform for UX evaluation. *Sensors (Switzerland)*, 18(5). <https://doi.org/10.3390/s18051622>
- Hwang, G. J., & Chien, S. Y. (2022). Definition, roles, and potential research issues of the metaverse in education: An artificial intelligence perspective. *Computers and Education: Artificial Intelligence*, 3. <https://doi.org/10.1016/j.caeai.2022.100082>
- Iam-On, N. (2020). Clustering data with the presence of attribute noise: a study of noise completely at random and ensemble of multiple k-means clusterings. *International Journal of Machine Learning and Cybernetics*, 11(3). <https://doi.org/10.1007/s13042-019-00989-4>
- Iawasaki, Y., & Hasebe, K. (2021). Identifying Playstyles in Games with NEAT and Clustering. *IEEE Conference on Computational Intelligence and Games, CIG, 2021-August*. <https://doi.org/10.1109/CoG52621.2021.9619024>
- Ijaz, K., Ahmadpour, N., Wang, Y., & Calvo, R. A. (2020). Player Experience of Needs Satisfaction (PENS) in an Immersive Virtual Reality Exercise Platform Describes Motivation and Enjoyment. *International Journal of Human-Computer Interaction*, 36(13). <https://doi.org/10.1080/10447318.2020.1726107>
- Imamah, Yuhana, U. L., Djunaidy, A., & Purnomo, M. H. (2024). Enhancing students performance through dynamic personalized learning path using ant colony and item response theory (ACOIRT). *Computers and Education: Artificial Intelligence*, 7, 100280. <https://doi.org/https://doi.org/10.1016/j.caeai.2024.100280>
- Indu, P. V., Vidhukumar, K., Chacko, D., Menon, V., Grover, S., & Gupta, S. (2025). Criterion validity, construct validity, and factor analysis: An introductory overview. *Indian Journal of Psychiatry*, 67(9). https://doi.org/10.4103/indianjpsychiatry_911_25
- Ismail Fawaz, H., Forestier, G., Weber, J., Idoumghar, L., & Muller, P. A. (2019). Deep learning for time series classification: a review. *Data Mining and Knowledge Discovery*, 33(4). <https://doi.org/10.1007/s10618-019-00619-1>
- Jakobsen, J. C., Gluud, C., Wetterslev, J., & Winkel, P. (2017). When and how should multiple imputation be used for handling missing data in randomised clinical trials - A practical guide with flowcharts. *BMC Medical Research Methodology*, 17(1). <https://doi.org/10.1186/s12874-017-0442-1>
- Javvaji, N., Hartevel, C., & Seif El-Nasr, M. (2020). Understanding Player Patterns by Combining Knowledge-Based Data Abstraction with Interactive Visualization. *CHI PLAY 2020 - Proceedings of the Annual Symposium on Computer-Human Interaction in Play*. <https://doi.org/10.1145/3410404.3414257>
- Ji, X., Sun, L., & Huang, K. (2025). The construction and implementation direction of personalized learning model based on multimodal data fusion in the context of intelligent education. *Cognitive Systems Research*, 92, 101379. <https://doi.org/https://doi.org/10.1016/j.cogsys.2025.101379>
- Jiao, T., Guo, C., Feng, X., Chen, Y., & Song, J. (2024). A Comprehensive Survey on Deep Learning Multi-Modal Fusion: Methods, Technologies and Applications. In *Computers, Materials and Continua* (Vol. 80, Issue 1). <https://doi.org/10.32604/cmc.2024.053204>
- Joshi, M. (2023). Adaptive Learning through Artificial Intelligence. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.4514887>
- Justesen, N., Bontrager, P., Togelius, J., & Risi, S. (2020). Deep learning for video game playing. *IEEE Transactions on Games*, 12(1). <https://doi.org/10.1109/TG.2019.2896986>
- Kahila, J., Valtonen, T., López-Pernas, S., Saqr, M., Vartiainen, H., Kahila, S., & Tedre, M. (2025). A Typology of Metagamers: Identifying Player Types Based on Beyond the Game Activities. *Games and Culture*, 20(1). <https://doi.org/10.1177/15554120231187758>
- Kapp, K. M. (2019). The gamification of learning and instruction : game-based methods and strategies for training and education. In *Sustainability (Switzerland)* (Vol. 11, Issue 1).

- Kapusta, J., Munk, M., Halvoník, D., & Drlík, M. (2019). User identification in the process of web usage data preprocessing. *International Journal of Emerging Technologies in Learning*, 14(9), 21–33. <https://doi.org/10.3991/IJET.V14I09.9854>
- Katona, J., & Gyonyoru, K. I. K. (2025). Integrating AI-based adaptive learning into the flipped classroom model to enhance engagement and learning outcomes. *Computers and Education: Artificial Intelligence*, 8, 100392. <https://doi.org/https://doi.org/10.1016/j.caeai.2025.100392>
- Kauffmann, J., Esders, M., Ruff, L., Montavon, G., Samek, W., & Muller, K. R. (2024). From Clustering to Cluster Explanations via Neural Networks. *IEEE Transactions on Neural Networks and Learning Systems*, 35(2). <https://doi.org/10.1109/TNNLS.2022.3185901>
- Keogh, E., & Mueen, A. (2010). *Curse of Dimensionality BT - Encyclopedia of Machine Learning* (C. Sammut & G. I. Webb (eds.); pp. 257–258). Springer US. https://doi.org/10.1007/978-0-387-30164-8_192
- Khong, H. K., & Kabilan, M. K. (2022). A theoretical model of micro-learning for second language instruction. *Computer Assisted Language Learning*, 35(7), 1483–1506. <https://doi.org/10.1080/09588221.2020.1818786>
- Khosravi, H., Shum, S. B., Chen, G., Conati, C., Tsai, Y. S., Kay, J., Knight, S., Martinez-Maldonado, R., Sadiq, S., & Gašević, D. (2022). Explainable Artificial Intelligence in education. *Computers and Education: Artificial Intelligence*, 3. <https://doi.org/10.1016/j.caeai.2022.100074>
- Kim, J. H., Kim, M., Park, M., & Yoo, J. (2023). Immersive interactive technologies and virtual shopping experiences: Differences in consumer perceptions between augmented reality (AR) and virtual reality (VR). *Telematics and Informatics*, 77. <https://doi.org/10.1016/j.tele.2022.101936>
- Kim, S., & Ko, F. I. S. (2013). Toward Gamified Classroom: Classification of Engineering Students Based on The Bartle's Player Types Model. *International Journal of Digital Content Technology and Its Applications*, 7(2).
- Király, O., Billieux, J., King, D. L., Urbán, R., Koncz, P., Polgár, E., & Demetrovics, Z. (2022). A comprehensive model to understand and assess the motivational background of video game use: The Gaming Motivation Inventory (GMI). *Journal of Behavioral Addictions*, 11(3). <https://doi.org/10.1556/2006.2022.00048>
- Kirchner-Krath, J., Altmeyer, M., Schürmann, L., Kordyaka, B., Morschheuser, B., Klock, A. C. T., Nacke, L., Hamari, J., & von Korflesch, H. F. O. (2024). Uncovering the theoretical basis of user types: An empirical analysis and critical discussion of user typologies in research on tailored gameful design. *International Journal of Human-Computer Studies*, 190, 103314. <https://doi.org/https://doi.org/10.1016/j.ijhcs.2024.103314>
- Klock, A. C. T., Gasparini, I., Pimenta, M. S., & Hamari, J. (2020). Tailored gamification: A review of literature. *International Journal of Human Computer Studies*, 144. <https://doi.org/10.1016/j.ijhcs.2020.102495>
- Kluge, M. G., Maltby, S., Kuhne, C., Walker, N., Bennett, N., Aidman, E., Nalivaiko, E., & Walker, F. R. (2023). Evaluation of a Virtual Reality Platform to Train Stress Management Skills for a Defense Workforce: Multisite, Mixed Methods Feasibility Study. *Journal of Medical Internet Research*, 25. <https://doi.org/10.2196/46368>
- Kolpikova, E. P., Chen, D. C., & Doherty, J. H. (2019). Does the format of preclass reading quizzes matter? An evaluation of traditional and gamified, adaptive preclass reading quizzes. *CBE Life Sciences Education*, 18(4). <https://doi.org/10.1187/cbe.19-05-0098>
- Konert, J., Gutjahr, M., Göbel, S., & Steinmetz, R. (2015). Modeling the player: Predictability of the models of Bartle and Kolb based on NEO-FFI (Big5) and the implications for game based learning. In *Gamification: Concepts, Methodologies, Tools, and Applications* (Vols 2–4, pp. 669–682). <https://doi.org/10.4018/978-1-4666-8200-9.ch033>
- Kong, X. J., Wise, S. L., & Bhola, D. S. (2007). Setting the response time threshold parameter to differentiate solution behavior from rapid-guessing behavior. *Educational and Psychological Measurement*, 67(4), 606–619. <https://doi.org/10.1177/0013164406294779>
- Korosi, G., Esztelecki, P., Farkas, R., & Toth, K. (2018). Clickstream-based outcome prediction in short video MOOCs. *CITS 2018 - 2018 International Conference on Computer, Information and Telecommunication Systems*, 1–5. <https://doi.org/10.1109/CITS.2018.8440182>
- Kowitlawakul, Y., Tan, J. J. M., Suebnukarn, S., Nguyen, H. D., Poo, D. C. C., Chai, J., Kamala, D. M., & Wang, W. (2024). Development of an Artificial Intelligence Teaching Assistant System for Undergraduate Nursing Students: A Field Testing Study. *CIN - Computers Informatics Nursing*, 42(5). <https://doi.org/10.1097/CIN.0000000000001103>
- Krath, J., Altmeyer, M., Tondello, G. F., & Nacke, L. E. (2023). Hexad-12: Developing and Validating a Short Version of the Gamification User Types Hexad Scale. *Conference on Human Factors in Computing Systems - Proceedings*. <https://doi.org/10.1145/3544548.3580968>
- Krath, J., & von Korflesch, H. F. O. (2021). *Player Types and Game Element Preferences: Investigating the Relationship with the Gamification User Types HEXAD Scale BT - HCI in Games: Experience Design and Game Mechanics* (X. Fang (ed.); pp. 219–238). Springer International Publishing.
- Kuhn, M., & Johnson, K. (2019). Feature engineering and selection: A practical approach for predictive models. In *Feature Engineering and Selection: A Practical Approach for Predictive Models*. <https://doi.org/10.1201/9781315108230>
- Lakatos, R., Pollner, P., Hajdu, A., & Joó, T. (2024). A multimodal deep learning architecture for smoking detection with a small data approach. *Frontiers in Artificial Intelligence*, 7. <https://doi.org/10.3389/frai.2024.1326050>
- Law, E. L. C., Brühlmann, F., & Mekler, E. D. (2018). Systematic review and validation of the game experience questionnaire (GEQ) – Implications for citation and reporting practice. *CHI PLAY 2018 - Proceedings of the 2018 Annual Symposium on Computer-Human Interaction in Play*. <https://doi.org/10.1145/3242671.3242683>
- Lazzaro, N. (2004). Why We Play Games: Four Keys to More Emotion Without Story. *Game Developer Conference (GDC)*. <https://doi.org/10.1111/j.1464-410X.2004.04896.x>
- Lee, G. H., Jin, W., Alvarez-Melis, D., & Jaakkola, T. S. (2019). Functional transparency for structured data: A game-theoretic approach. *36th International Conference on Machine Learning, ICML 2019, 2019-June*.
- Lee, Y. H., & Jia, Y. (2014). Using response time to investigate students' test-taking behaviors in a NAEP computer-based study. *Large-Scale Assessments in Education*, 2(8), 1–24. <https://doi.org/10.1186/s40536-014-0008-1>
- Leemans, M., & van der Aalst, W. M. P. (2015). Discovery of frequent episodes in event logs. *Lecture Notes in Business Information Processing*, 237. https://doi.org/10.1007/978-3-319-27243-6_1

- Lemmens, J. S., Simon, M., & Sumter, S. R. (2022). Fear and loathing in VR: the emotional and physiological effects of immersive games. *Virtual Reality*, 26(1). <https://doi.org/10.1007/s10055-021-00555-w>
- Lepper, M. R., & Malone, T. W. (2021). Intrinsic motivation and instructional effectiveness in computer-based education. In *Aptitude, Learning, and Instruction* (Vol. 3, pp. 255–286).
- Li, A., Feng, C., Wang, Z., Sun, Y., Wang, Z., & Sun, L. (2024). Anchor-based sparse subspace incomplete multi-view clustering. *Wireless Networks*, 30(6). <https://doi.org/10.1007/s11276-023-03312-w>
- Li, L., & Xiao, J. (2022). Persona profiling: a multi-dimensional model to study learner subgroups in Massive Open Online Courses. *Education and Information Technologies*, 27(4). <https://doi.org/10.1007/s10639-021-10829-0>
- Li, L. Y. (2019). Effect of Prior Knowledge on Attitudes, Behavior, and Learning Performance in Video Lecture Viewing. *International Journal of Human-Computer Interaction*, 35(4–5). <https://doi.org/10.1080/10447318.2018.1543086>
- Li, W., Funk, M., Li, Q., & Brombacher, A. (2019). Visualizing event sequence game data to understand player's skill growth through behavior complexity. *Journal of Visualization*, 22(4). <https://doi.org/10.1007/s12650-019-00566-5>
- Lim, L., Bannert, M., van der Graaf, J., Singh, S., Fan, Y., Surendrannair, S., Rakovic, M., Molenaar, I., Moore, J., & Gašević, D. (2023). Effects of real-time analytics-based personalized scaffolds on students' self-regulated learning. *Computers in Human Behavior*, 139. <https://doi.org/10.1016/j.chb.2022.107547>
- Lin, Y. C., Lin, Y. T., & Huang, Y. M. (2011). Development of a diagnostic system using a testing-based approach for strengthening student prior knowledge. *Computers and Education*, 57(2). <https://doi.org/10.1016/j.compedu.2011.03.004>
- Lindner, M. A., Lüdtke, O., & Nagy, G. (2019). The Onset of Rapid-Guessing Behavior Over the Course of Testing Time: A Matter of Motivation and Cognitive Resources. *Frontiers in Psychology*, 10, 1–15. <https://doi.org/10.3389/fpsyg.2019.01533>
- List, A., Peterson, E. G., Alexander, P. A., & Loyens, S. M. M. (2018). The role of educational context in beliefs about knowledge, information, and truth: an exploratory study. *European Journal of Psychology of Education*, 33(4), 685–705. <https://doi.org/10.1007/s10212-017-0359-4>
- Liu, L., Jones, B. F., Uzzi, B., & Wang, D. (2023). Data, measurement and empirical methods in the science of science. In *Nature Human Behaviour* (Vol. 7, Issue 7). <https://doi.org/10.1038/s41562-023-01562-4>
- Liu, T., Yu, H., & Blair, R. H. (2022). Stability estimation for unsupervised clustering: A review. In *Wiley Interdisciplinary Reviews: Computational Statistics* (Vol. 14, Issue 6). <https://doi.org/10.1002/wics.1575>
- Liu, Y., Cheng, Y., & Liu, H. (2020). Identifying Effortful Individuals With Mixture Modeling Response Accuracy and Response Time Simultaneously to Improve Item Parameter Estimation. *Educational and Psychological Measurement*, 80(4), 775–807. <https://doi.org/10.1177/0013164419895068>
- Locey, M. L. (2020). The Evolution of Behavior Analysis: Toward a Replication Crisis? *Perspectives on Behavior Science*, 43(4). <https://doi.org/10.1007/s40614-020-00264-w>
- Lomba Perez, A., Martín-Quintana, J. C., Alonso-Hernandez, J. B., & Martín-Rodríguez, I. (2025). Validation of the Player Personality and Dynamics Scale. *Applied Sciences*, 15(15). <https://doi.org/10.3390/app15158714>
- López-Pernas, S., Gordillo, A., Barra, E., & Saqr, M. (2024). The Dynamics of Students' Playing Profiles in a Programming Educational Escape Room. In *Lecture Notes in Educational Technology: Vol. Part F3283*. https://doi.org/10.1007/978-981-97-1814-6_2
- Lopez, C. E., & Tucker, C. S. (2019). The effects of player type on performance: A gamification case study. *Computers in Human Behavior*, 91. <https://doi.org/10.1016/j.chb.2018.10.005>
- Loria, E., Rivera-Villicana, J., & Marconi, A. (2021). Do they play as intended? - Comparing aggregated and temporal behavioral analysis in a persuasive gamified system. *Proceedings of the Annual Hawaii International Conference on System Sciences, 2020-January*. <https://doi.org/10.24251/hicss.2021.160>
- Ludwig, S., Rausch, A., Deutscher, V., & Seifried, J. (2024). Predicting problem-solving success in an office simulation applying N-grams and a random forest to behavioral process data. *Computers and Education*, 218. <https://doi.org/10.1016/j.compedu.2024.105093>
- Lundgren, E., & Eklöf, H. (2023). Questionnaire-taking motivation: Using response times to assess motivation to optimize on the PISA 2018 student questionnaire. *International Journal of Testing*, 23(4), 231–256. <https://doi.org/10.1080/15305058.2023.2214647>
- Ma, L., Wise, S. L., Thum, Y. M., & Kingsbury, G. (2011). Detecting response time threshold under the computer adaptive testing environment. *Annual Meeting of the National Council on Measurement in Education, New Orleans*, 1.
- Macak, M., Daubner, L., Jamnicka, J., & Buhnova, B. (2022). Game Achievement Analysis: Process Mining Approach. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 13088 LNAI. https://doi.org/10.1007/978-3-030-95408-6_6
- Madley-Dowd, P., Hughes, R., Tilling, K., & Heron, J. (2019). The proportion of missing data should not be used to guide decisions on multiple imputation. *Journal of Clinical Epidemiology*, 110. <https://doi.org/10.1016/j.jclinepi.2019.02.016>
- Makransky, G., & Petersen, G. B. (2021). The Cognitive Affective Model of Immersive Learning (CAMIL): a Theoretical Research-Based Model of Learning in Immersive Virtual Reality. In *Educational Psychology Review* (Vol. 33, Issue 3). <https://doi.org/10.1007/s10648-020-09586-2>
- Manis, K. T., & Choi, D. (2019). The virtual reality hardware acceptance model (VR-HAM): Extending and individuating the technology acceptance model (TAM) for virtual reality hardware. *Journal of Business Research*, 100. <https://doi.org/10.1016/j.jbusres.2018.10.021>
- Manorat, P., Tuarob, S., & Pongpaichet, S. (2025). Artificial intelligence in computer programming education: A systematic literature review. *Computers and Education: Artificial Intelligence*, 8, 100403. <https://doi.org/https://doi.org/10.1016/j.caeai.2025.100403>
- Mäntymäki, M., Hyrynsalmi, S., & Koskenvoima, A. (2020). How Do Small and Medium-Sized Game Companies Use Analytics? An Attention-Based View of Game Analytics. *Information Systems Frontiers*, 22(5). <https://doi.org/10.1007/s10796-019-09913-1>
- Marciniak, J., & Szczepanski, M. (2020). 'Individualized learning in a course with a tight schedule'. *Procedia Computer Science*, 176. <https://doi.org/10.1016/j.procs.2020.09.242>
- Marczewski, A. (2015). Even Ninja Monkeys like to play. *London: Blur Inc*, 1(1), 28.

- Marin-Castro, H. M., & Tello-Leal, E. (2021). Event log preprocessing for process mining: A review. In *Applied Sciences (Switzerland)* (Vol. 11, Issue 22). <https://doi.org/10.3390/app112210556>
- Masoero, L., Thomas, E., Parmigiani, G., Tyekucheva, S., & Trippa, L. (2023). Cross-Study Replicability in Cluster Analysis. *Statistical Science*, 38(2). <https://doi.org/10.1214/22-STS871>
- Mastuti, E., & Handoyo, S. (2018). *Effects of Individual Differences on the Performance in Computer Based Test (CBT)*. 92–100. <https://doi.org/10.2991/acpch-17.2018.4>
- McInnes, L., Healy, J., Saul, N., & Großberger, L. (2018). UMAP: Uniform Manifold Approximation and Projection. *Journal of Open Source Software*, 3(29). <https://doi.org/10.21105/joss.00861>
- Melhart, D., Gravina, D., & Yannakakis, G. N. (2020). Moment-to-moment Engagement Prediction through the Eyes of the Observer: PUBG Streaming on Twitch. *ACM International Conference Proceeding Series*, 1–10. <https://doi.org/10.1145/3402942.3402958>
- Melo Do Nascimento, I., Oliveira, W., Hamari, J., & Toledo, C. F. M. (2025). Identifying User Types in Gamified Learning Management Systems Based on Behavior Data. *CHI PLAY Companion 2025 - Companion Proceedings of the Annual Symposium on Computer-Human Interaction in Play*. <https://doi.org/10.1145/3744736.3749359>
- Melo, S., Thurler, L., Paes, A., & Clua, E. (2025). Game provenance graph-based representation learning vs metrics-based machine learning: An empirical comparison on predictive game analytics tasks. *Entertainment Computing*, 52, 100755. <https://doi.org/https://doi.org/10.1016/j.entcom.2024.100755>
- Mereu, S., Newman, M., Peterson, M., Taylor, E., White-Sustaita, J., & Yeats, D. (2017). Top-down vs bottom-up approaches to user segmentation: The best of both worlds. *Proceedings of the Human Factors and Ergonomics Society, 2017-October*. <https://doi.org/10.1177/1541931213601613>
- Meriläinen, M., & Ruotsalainen, M. (2023). The light, the dark, and everything else: making sense of young people's digital gaming. *Frontiers in Psychology*, 14. <https://doi.org/10.3389/fpsyg.2023.1164992>
- Merlo, L., Maruotti, A., Petrella, L., & Punzo, A. (2022). Quantile hidden semi-Markov models for multivariate time series. *Statistics and Computing*, 32(4). <https://doi.org/10.1007/s11222-022-10130-1>
- Mesana, P., Vial, G., Jutras, P., Caporossi, G., Crowe, J., & Gambis, S. (2025). Measuring privacy/utility tradeoffs of format-preserving strategies for data release. *Journal of Business Analytics*, 8(3), 147–169. <https://doi.org/10.1080/2573234X.2025.2461507>
- Michaelides, M. P., Ivanova, M., & Nicolaou, C. (2020). The Relationship between Response-Time Effort and Accuracy in PISA Science Multiple Choice Items. *International Journal of Testing*, 20(3), 187–205. <https://doi.org/10.1080/15305058.2019.1706529>
- Miguel-Alonso, I., Checa, D., Guillen-Sanz, H., & Bustillo, A. (2024). Evaluation of the novelty effect in immersive Virtual Reality learning experiences. *Virtual Reality*, 28(1). <https://doi.org/10.1007/s10055-023-00926-5>
- Miller, L. A., Asarta, C. J., & Schmidt, J. R. (2019). Completion deadlines, adaptive learning assignments, and student performance. *Journal of Education for Business*, 94(3). <https://doi.org/10.1080/08832323.2018.1507988>
- Milošević, M., Živić, N., & Andjelković, I. (2017). Early churn prediction with personalized targeting in mobile social games. *Expert Systems with Applications*, 83, 326–332. <https://doi.org/10.1016/j.eswa.2017.04.056>
- Monib, W. K., Qazi, A., & Apong, R. A. (2025). Microlearning beyond boundaries: A systematic review and a novel framework for improving learning outcomes. *Heliyon*, 11(2). <https://doi.org/10.1016/j.heliyon.2024.e41413>
- Monteiro, A. F., Gonçalves, S., & Moreira, A. H. J. (2023). The 50 + 10 Concept for the Development of Future Skills: A Pedagogical Framework. *Lecture Notes in Networks and Systems*, 767 LNNS. https://doi.org/10.1007/978-3-031-41637-8_30
- Monteiro, D., Ma, T., Li, Y., Pan, Z., & Liang, H. N. (2022). Cross-cultural factors influencing the adoption of virtual reality for practical learning. *Universal Access in the Information Society*. <https://doi.org/10.1007/s10209-022-00947-y>
- Monti, S., Tamayo, P., Mesirov, J., & Golub, T. (2003). Consensus clustering: A resampling-based method for class discovery and visualization of gene expression microarray data. *Machine Learning*, 52(1–2). <https://doi.org/10.1023/A:1023949509487>
- Mortazavi, F., Moradi, H., & Vahabie, A. H. (2024). Dynamic difficulty adjustment approaches in video games: a systematic literature review. *Multimedia Tools and Applications*, 83(35), 83227–83274. <https://doi.org/10.1007/s11042-024-18768-x>
- Mosadeghi, S., Reid, M. W., Martinez, B., Rosen, B. T., & Spiegel, B. M. R. (2016). Feasibility of an immersive virtual reality intervention for hospitalized patients: An observational cohort study. *JMIR Mental Health*, 3(2). <https://doi.org/10.2196/mental.5801>
- Moujahid, A., & Dornaika, F. (2025). Advanced unsupervised learning: a comprehensive overview of multi-view clustering techniques. *Artificial Intelligence Review*, 58(8). <https://doi.org/10.1007/s10462-025-11240-8>
- Moura, D., Seif El-Nasr, M., & Shaw, C. D. (2011). Visualizing and understanding players' behavior in video games: Discovering patterns and supporting aggregation and comparison. *Proceedings - Sandbox 2011: ACM SIGGRAPH Video Game*. <https://doi.org/10.1145/2018556.2018559>
- Mourer, A., Forest, F., Lebbah, M., Azzag, H., & Lacaille, J. (2023). Selecting the Number of Clusters K with a Stability Trade-off: An Internal Validation Criterion. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 13935 LNCS. https://doi.org/10.1007/978-3-031-33374-3_17
- Mustač, K., Bačić, K., Skorin-Kapov, L., & Sužnjević, M. (2022). Predicting Player Churn of a Free-to-Play Mobile Video Game Using Supervised Machine Learning. *Applied Sciences (Switzerland)*, 12(6), 2795. <https://doi.org/10.3390/app12062795>
- Mütterlein, J., & Hess, T. (2017). Immersion, presence, interactivity: Towards a joint understanding of factors influencing virtual reality acceptance and use. *AMCIS 2017 - America's Conference on Information Systems: A Tradition of Innovation, 2017-August*.
- Nacke, L. E., Bateman, C., & Mandryk, R. L. (2014). BrainHex: A neurobiological gamer typology survey. *Entertainment Computing*, 5(1), 55–62. <https://doi.org/https://doi.org/10.1016/j.entcom.2013.06.002>
- Nacke, L. E., Bateman, C., & Mandryk, R. L. (2011). BrainHex: Preliminary results from a neurobiological gamer typology survey. *Lecture Notes in Computer Science (Including*

- Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics), 6972 LNCS, 288–293. https://doi.org/10.1007/978-3-642-24500-8_31
- Nagy, G., Ulitzsch, E., & Lindner, M. A. (2023). The role of rapid guessing and test-taking persistence in modelling test-taking engagement. *Journal of Computer Assisted Learning*, 39(3), 751–766. <https://doi.org/10.1111/jcal.12719>
- Nah, K., Oh, S., Han, B., Kim, H., & Lee, A. (2022). A Study on the User Experience to Improve Immersion as a Digital Human in Lifestyle Content. *Applied Sciences (Switzerland)*, 12(23). <https://doi.org/10.3390/app122312467>
- Narayanan, A., & Shmatikov, V. (2008). Robust de-anonymization of large sparse datasets. *Proceedings - IEEE Symposium on Security and Privacy*. <https://doi.org/10.1109/SP.2008.33>
- Nikou, S. A., & Economides, A. A. (2018). Mobile-Based micro-Learning and Assessment: Impact on learning performance and motivation of high school students. *Journal of Computer Assisted Learning*, 34(3), 269–278. <https://doi.org/10.1111/jcal.12240>
- Niu, X., Zhang, C., Zhao, X., Hu, L., & Zhang, J. (2023). A multi-view ensemble clustering approach using joint affinity matrix. *Expert Systems with Applications*, 216. <https://doi.org/10.1016/j.eswa.2022.119484>
- Njoku, J. N., Nwakanma, C. I., Amaizu, G. C., & Kim, D. S. (2023). Prospects and challenges of Metaverse application in data-driven intelligent transportation systems. In *IET Intelligent Transport Systems* (Vol. 17, Issue 1). <https://doi.org/10.1049/itr2.12252>
- Normoyle, A., & Jensen, S. T. (2021). *Bayesian Learning of Play Styles in Multiplayer Video Games* (pp. 1–17). <https://arxiv.org/abs/2112.07437>
- Normoyle, A., & Jensen, S. T. (2015). Bayesian clustering of player styles for multiplayer games. *Proceedings of the 11th AAAI Conference on Artificial Intelligence and Interactive Digital Entertainment, AIIDE 2015, 2015-Novem*, 163–169. <https://doi.org/10.1609/aiide.v11i1.12805>
- Nwaimo, C. S., Adegbola, A. E., & Adegbola, M. D. (2024). Data-driven strategies for enhancing user engagement in digital platforms. *International Journal of Management & Entrepreneurship Research*, 6(6), 1854–1868.
- O'Shea, Z., & Freeman, J. (2019). Game design frameworks: Where do we start? *ACM International Conference Proceeding Series*. <https://doi.org/10.1145/3337722.3337753>
- Obayemi, A., & Nguyen, K. A. (2026). Uncertainty Quantification of Multimodal Models. *Lecture Notes in Computer Science*, 15706 LNAI. https://doi.org/10.1007/978-981-96-8889-0_23
- Obikwelu, C., & Read, J. C. (2017). Evaluating scaffolding in serious games with children. *Procedia Computer Science*, 15.
- Obukhov, A. D., Krasnyanskiy, M. N., Dedov, D. L., & Nazarova, A. O. (2023). The study of virtual reality influence on the process of professional training of miners. *Virtual Reality*, 27(2). <https://doi.org/10.1007/s10055-022-00687-7>
- Paiva, J. C., Leal, J. P., & Figueira, Á. (2022). Automated Assessment in Computer Science Education: A State-of-the-Art Review. In *ACM Transactions on Computing Education* (Vol. 22, Issue 3, pp. 34:1–34:40). <https://doi.org/10.1145/3513140>
- Pallavicini, F., & Pepe, A. (2019). Comparing player experience in video games played in virtual reality or on desktop displays: Immersion, flow, and positive emotions. *CHI PLAY 2019 - Extended Abstracts of the Annual Symposium on Computer-Human Interaction in Play*. <https://doi.org/10.1145/3341215.3355736>
- Paparella, I., & Papeo, L. (2022). Chunking by social relationship in working memory. *Visual Cognition*, 30(5), 354–370. <https://doi.org/10.1080/13506285.2022.2064950>
- Paraschos, P. D., & Koulouriotis, D. E. (2023). Game Difficulty Adaptation and Experience Personalization: A Literature Review. *International Journal of Human-Computer Interaction*, 39(1), 1–22. <https://doi.org/10.1080/10447318.2021.2020008>
- Park, S., Min, K., & Kim, S. (2021). Differences in learning motivation among Bartle's player types and measures for the delivery of sustainable gameful experiences. *Sustainability (Switzerland)*, 13(16). <https://doi.org/10.3390/su13169121>
- Passalacqua, M., Sénécal, S., Frédette, M., Nacke, L. E., Pellerin, R., & Léger, P. M. (2021). Should Gamification be Personalized? A Self-deterministic Approach. *AIS Transactions on Human-Computer Interaction*, 13(3), 265–286. <https://doi.org/10.17705/1thci.00150>
- Patkar, N., & Seyff, N. (2023). Data-Driven Persona Creation, Validation, and Evolution. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 13975 LNCS. https://doi.org/10.1007/978-3-031-29786-1_18
- Pearl, J. (2013). Understanding Simpson's Paradox. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.2343788>
- Pereira, L. M., Salazar, A., & Vergara, L. (2023). On Comparing Early and Late Fusion Methods. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 14134 LNCS. https://doi.org/10.1007/978-3-031-43085-5_29
- Pérez-Colado, V. M., Pérez-Colado, I. J., Martínez-Ortiz, I., Freire-Morán, M., & Fernández-Manjón, B. (2021). Democratizing Game Learning Analytics for Serious Games. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 13134 LNCS. https://doi.org/10.1007/978-3-030-92182-8_16
- Perišić, A., & Pahor, M. (2023). Clustering mixed-type player behavior data for churn prediction in mobile games. *Central European Journal of Operations Research*, 31(1), 165–190. <https://doi.org/10.1007/s10100-022-00802-8>
- Phosanarack, M., Avril, E., Lepreux, S., Wallard, L., & Kolski, C. (2025). User-centered personalized gamification: an umbrella review. *User Modeling and User-Adapted Interaction*, 35(1). <https://doi.org/10.1007/s11257-024-09423-z>
- Piaw Chua, Y. (2012). Effects of computer-based testing on test performance and testing motivation. *Computers in Human Behavior*, 28(5), 1580–1586. <https://doi.org/10.1016/j.chb.2012.03.020>
- Plotzky, C., Lindwedel, U., Bejan, A., König, P., & Kunze, C. (2021). Virtual Reality in Healthcare Skills Training: The Effects of Presence on Acceptance and Increase of Knowledge. *I-Com*, 20(1). <https://doi.org/10.1515/icom-2021-0008>
- Pools, E. (2022). Not-reached Items: An Issue of Time and of test-taking Disengagement? the Case of PISA 2015 Reading Data. *Applied Measurement in Education*, 35(3), 197–221. <https://doi.org/10.1080/08957347.2022.2103136>
- Porter, C. E., & Donthu, N. (2006). Using the technology acceptance model to explain how attitudes determine Internet usage: The role of perceived access barriers and demographics. *Journal of Business Research*, 59(9). <https://doi.org/10.1016/j.jbusres.2006.06.003>
- Przymus, P., Rykaczewski, K., Zielinski, J., & Mikulski, L. (2025). Segmentation and Process Assignment of Semi-Structured Event Logs. *Annals of Computer Science and Intelligence*

- Systems*, 2025. <https://doi.org/10.15439/2025F4755>
- Puah, S., Bin Mohamad Khalid, M. I. S., Looi, C. K., & Khor, E. T. (2022). Investigating working adults' intentions to participate in microlearning using the decomposed theory of planned behaviour. *British Journal of Educational Technology*, 53(2), 367–390. <https://doi.org/10.1111/bjet.13170>
- Purificato, E., Boratto, L., & De Luca, E. W. (2024). User modeling and user profiling: A comprehensive survey. *ArXiv Preprint ArXiv:2402.09660*.
- Pushpakumar, R., Sanjaya, K., Rathika, S., Alawadi, A. H., Makhzuna, K., Venkatesh, S., & Rajalakshmi, B. (2023). Human-Computer Interaction: Enhancing User Experience in Interactive Systems. *E3S Web of Conferences*, 399. <https://doi.org/10.1051/e3sconf/202339904037>
- Rai, A. (2020). Explainable AI: from black box to glass box. In *Journal of the Academy of Marketing Science* (Vol. 48, Issue 1, pp. 137–141). <https://doi.org/10.1007/s11747-019-00710-5>
- Ramadan, S., Ibrahim Baqapuri, H., Roecher, E., & Mathiak, K. (2019). Process mining of logged gaming behavior. *Proceedings - 2019 International Conference on Process Mining, ICPM 2019*. <https://doi.org/10.1109/ICPM.2019.00019>
- Ramos, D., Franco-Pedroso, J., Lozano-Diez, A., & Gonzalez-Rodriguez, J. (2018). Deconstructing cross-entropy for probabilistic binary classifiers. *Entropy*, 20(3). <https://doi.org/10.3390/e20030208>
- Rebhi, M., Aissa, M. Ben, Tannoubi, A., Saidane, M., Guelmami, N., Puce, L., Chen, W., Chalhaf, N., Azaiez, F., Zghibi, M., & Bragazzi, N. L. (2023). Reliability and Validity of the Arabic Version of the Game Experience Questionnaire: Pilot Questionnaire Study. *JMIR Formative Research*, 7. <https://doi.org/10.2196/42584>
- Reis, S., Reis, L. P., & Lau, N. (2021). Game Adaptation by Using Reinforcement Learning Over Meta Games. *Group Decision and Negotiation*, 30(2). <https://doi.org/10.1007/s10726-020-09652-8>
- Rios, J. A. (2022a). A Comparison of Robust Likelihood Estimators to Mitigate Bias From Rapid Guessing. *Applied Psychological Measurement*, 46(3), 236–249. <https://doi.org/10.1177/01466216221084371>
- Rios, J. A. (2022b). Assessing the Accuracy of Parameter Estimates in the Presence of Rapid Guessing Misclassifications. *Educational and Psychological Measurement*, 82(1), 122–150. <https://doi.org/10.1177/00131644211003640>
- Rios, J. A. (2022c). When Should Individual Ability Estimates Be Reported if Rapid Guessing Is Present? *Applied Measurement in Education*, 35(3), 222–236. <https://doi.org/10.1080/08957347.2022.2103138>
- Rios, J. A., & Deng, J. (2021). Does the choice of response time threshold procedure substantially affect inferences concerning the identification and exclusion of rapid guessing responses? A meta-analysis. *Large-Scale Assessments in Education*, 9(1), 1–25. <https://doi.org/10.1186/s40536-021-00110-8>
- Rios, J. A., & Guo, H. (2020). Can Culture Be a Salient Predictor of Test-Taking Engagement? An Analysis of Differential Noneffortful Responding on an International College-Level Assessment of Critical Thinking. *Applied Measurement in Education*, 33(4), 263–279. <https://doi.org/10.1080/08957347.2020.1789141>
- Rios, J. A., & Soland, J. (2021a). Investigating the Impact of Noneffortful Responses on Individual-Level Scores: Can the Effort-Moderated IRT Model Serve as a Solution? *Applied Psychological Measurement*, 45(6), 391–406. <https://doi.org/10.1177/01466216211013896>
- Rios, J. A., & Soland, J. (2021b). Parameter Estimation Accuracy of the Effort-Moderated Item Response Theory Model Under Multiple Assumption Violations. *Educational and Psychological Measurement*, 81(3), 569–594. <https://doi.org/10.1177/0013164420949896>
- Rios, J. A., & Soland, J. (2022). An investigation of item, examinee, and country correlates of rapid guessing in PISA. *International Journal of Testing*, 22(2), 154–184. <https://doi.org/10.1080/15305058.2022.2036161>
- Roccas, S., Sagiv, L., Schwartz, S. H., & Knafo, A. (2002). The Big Five personality factors and personal values. *Personality and Social Psychology Bulletin*, 28(6). <https://doi.org/10.1177/0146167202289008>
- Rojas-Perilla, N., Pannier, S., Schmid, T., & Tzavidis, N. (2020). Data-driven transformations in small area estimation. *Journal of the Royal Statistical Society. Series A: Statistics in Society*, 183(1). <https://doi.org/10.1111/rssa.12488>
- Ronksley-Pavia, M., Nguyen, L., Wheeley, E., Rose, J., Neumann, M. M., Bigum, C., & Neumann, D. L. (2025). A scoping literature review of generative artificial intelligence for supporting neurodivergent school students. *Computers and Education: Artificial Intelligence*, 9, 100437. <https://doi.org/https://doi.org/10.1016/j.caeai.2025.100437>
- Rózsa, S., Hargitai, R., Láng, A., Osváth, A., Hupuczi, E., Tamás, I., & Kállai, J. (2022). Measuring Immersion, Involvement, and Attention Focusing Tendencies in the Mediated Environment: The Applicability of the Immersive Tendencies Questionnaire. *Frontiers in Psychology*, 13. <https://doi.org/10.3389/fpsyg.2022.931955>
- Ruiz-Suarez, S., Leos-Barajas, V., & Morales, J. M. (2022). Hidden Markov and Semi-Markov Models When and Why are These Models Useful for Classifying States in Time Series Data? *Journal of Agricultural, Biological, and Environmental Statistics*, 27(2). <https://doi.org/10.1007/s13253-021-00483-x>
- Russell, S., & Norvig, P. (2021). Artificial Intelligence A Modern Approach (4th Edition). In *Pearson Series*.
- Ryan, R. M., Rigby, C. S., & Przybylski, A. (2006). The motivational pull of video games: A self-determination theory approach. *Motivation and Emotion*, 30(4). <https://doi.org/10.1007/s11031-006-9051-8>
- Saas, A., Guitart, A., & Perianez, A. (2016). Discovering playing patterns: Time series clustering of free-to-play game data. *IEEE Conference on Computational Intelligence and Games, CIG*, 0, 1–8. <https://doi.org/10.1109/CIG.2016.7860442>
- Sagnier, C., Loup-Escande, E., Lourdeaux, D., Thouvenin, I., & Valléry, G. (2020). User Acceptance of Virtual Reality: An Extended Technology Acceptance Model. *International Journal of Human-Computer Interaction*, 36(11). <https://doi.org/10.1080/10447318.2019.1708612>
- Sahbi, H. (2019). Learning CCA representations for misaligned data. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 11132 LNCS. https://doi.org/10.1007/978-3-030-11018-5_39
- Sally Wu, Y. H., & Alan Hung, S. T. (2022). The Effects of Virtual Reality Infused Instruction on Elementary School Students' English-Speaking Performance, Willingness to Communicate, and Learning Autonomy. *Journal of Educational Computing Research*, 60(6). <https://doi.org/10.1177/07356331211068207>
- Salminen, J., Santos, J. M., Jung, S. G., Eslami, M., & Jansen, B. J.

- (2020). Persona Transparency: Analyzing the Impact of Explanations on Perceptions of Data-Driven Personas. *International Journal of Human-Computer Interaction*, 36(8). <https://doi.org/10.1080/10447318.2019.1688946>
- Sanchez-Gordon, S., Aguilar-Mayanquer, C., & Calle-Jimenez, T. (2021). Model for Profiling Users with Disabilities on e-Learning Platforms. *IEEE Access*, 9. <https://doi.org/10.1109/ACCESS.2021.3081061>
- Sanchez, J. D., Tabares, M. S., & Vallejo, P. (2021). Towards a Method to Predict the Evaluation Result in a Microlearning Context. *Journal of Physics: Conference Series*, 1944(1), 012005. <https://doi.org/10.1088/1742-6596/1944/1/012005>
- Sankaranarayanan, R., Leung, J., Abramenska-Lachheb, V., Seo, G., & Lachheb, A. (2023). Microlearning in Diverse Contexts: A Bibliometric Analysis. *TechTrends*, 67(2), 260–276. <https://doi.org/10.1007/s11528-022-00794-x>
- Santos, A. C. G., Muramatsu, P. K., Oliveira, W., Joaquim, S., Hamari, J., & Isotani, S. (2023). Psychometric investigation of the gamification Hexad user types scale with Brazilian Portuguese adolescents speakers. *Scientific Reports*, 13(1). <https://doi.org/10.1038/s41598-023-45544-y>
- Schnipke, D. L., & Scrams, D. J. (1997). Modeling item response times with a two-state mixture model: A new method of measuring speededness. *Journal of Educational Measurement*, 34(3), 213–232. <https://doi.org/10.1111/j.1745-3984.1997.tb00516.x>
- Schnipke, D. L., & Scrams, D. J. (2005). Exploring issues of examinee behavior: Insights gained from response-time analyses. In *Computer-Based Testing: Building the Foundation for Future Assessments* (pp. 237–266). <https://doi.org/10.4324/9781410612250-20>
- Schoonenboom, J., & Johnson, R. B. (2017). How to Construct a Mixed Methods Research Design. *KZfSS Kölner Zeitschrift Für Soziologie Und Sozialpsychologie*, 69(S2). <https://doi.org/10.1007/s11577-017-0454-1>
- Schubert, T., Friedmann, F., & Regenbrecht, H. (2001). The experience of presence: Factor analytic insights. *Presence: Teleoperators and Virtual Environments*, 10(3). <https://doi.org/10.1162/105474601300343603>
- Scrucca, L., Fop, M., Murphy, T. B., & Raftery, A. E. (2016). Mclust 5: Clustering, classification and density estimation using Gaussian finite mixture models. *R Journal*, 8(1). <https://doi.org/10.32614/rj-2016-021>
- Self-Determination Theory: Basic Psychological Needs in Motivation, Development, and Wellness. (2017). In *Self-Determination Theory: Basic Psychological Needs in Motivation, Development, and Wellness*. <https://doi.org/10.1521/978.14625/28806>
- Shaker, N., & Abou-Zleikha, M. (2016). Transfer learning for cross-game prediction of player experience. *IEEE Conference on Computational Intelligence and Games, CIG, 0*. <https://doi.org/10.1109/CIG.2016.7860415>
- Shih, J. L., Chiu, M. M., & Lin, C. H. (2022). Personalities, sequences of strategies and actions, and game attacks: A statistical discourse analysis of strategic board game play. *Computers in Human Behavior*, 133. <https://doi.org/10.1016/j.chb.2022.107271>
- Shin, D. H., Biocca, F., & Choo, H. (2013). Exploring the user experience of three-dimensional virtual learning environments. *Behaviour and Information Technology*, 32(2). <https://doi.org/10.1080/0144929X.2011.606334>
- Shu, Y., Huang, Y. Z., Chang, S. H., & Chen, M. Y. (2019). Do virtual reality head-mounted displays make a difference? A comparison of presence and self-efficacy between head-mounted displays and desktop computer-facilitated virtual environments. *Virtual Reality*, 23(4). <https://doi.org/10.1007/s10055-018-0376-x>
- Sienel, N., Münster, P., & Zimmermann, G. (2021). Player-type-based personalization of gamification in fitness apps. *HEALTHINF 2021 - 14th International Conference on Health Informatics; Part of the 14th International Joint Conference on Biomedical Engineering Systems and Technologies, BIOSTEC 2021*. <https://doi.org/10.5220/0010230603610368>
- Sifa, R., Drachen, A., & Bauckhage, C. (2018). Profiling in Games: Understanding Behavior from Telemetry. In *Social Interactions in Virtual Worlds: An Interdisciplinary Perspective* (pp. 337–374). <https://doi.org/10.1017/9781316422823.014>
- Silm, G., Pedaste, M., & Täht, K. (2020). The relationship between performance and test-taking effort when measured with self-report or time-based instruments: A meta-analytic review. In *Educational Research Review* (Vol. 31, p. 100335). <https://doi.org/10.1016/j.edurev.2020.100335>
- Simaremare, A., Wau, Y., Hutagalung, T., & Parluhutan Tambunan, H. (2022). *Development of Microlearning Model at High Class SDN 106813 Amplas*. 1–6. <https://doi.org/10.4108/eai.11-10-2022.2325468>
- Simpson, E. H. (1951). The Interpretation of Interaction in Contingency Tables. *Journal of the Royal Statistical Society Series B: Statistical Methodology*, 13(2). <https://doi.org/10.1111/j.2517-6161.1951.tb00088.x>
- Sipone, S., Abella, V., Rojo, M., & Moura, J. L. (2025). Gamification and player type: Relationships of the HEXAD model with the learning experience. *Journal of New Approaches in Educational Research*, 14(1), 1. <https://doi.org/10.1007/s44322-024-00021-w>
- Skalka, Ján. (2022). Microlearning and Automated Assessment -- A Framework Implementation of Dissimilar Elements to Achieve Better Educational Outcomes. In E. Smyrnova-Trybulska, P. Kommers, M. Drlik, & J. Skalka (Eds.), *Microlearning: New Approaches To A More Effective Higher Education* (pp. 1–26). Springer International Publishing. https://doi.org/10.1007/978-3-031-13359-6_1
- Skalka, Jan, & Drlik, M. (2018). Priscilla - Proposal of System Architecture for Programming Learning and Teaching Environment. *IEEE International Conference on Application of Information and Communication Technologies*. <https://publons.com/publon/27387754/>
- Skalka, Jan, & Drlik, M. (2020). Automated assessment and microlearning units as predictors of at-risk students and students' outcomes in the introductory programming courses. *Applied Sciences (Switzerland)*, 10(13). <https://doi.org/10.3390/app10134566>
- Skalka, Jan, & Drlik, M. (2023). Development of Automatic Source Code Evaluation Tests Using Grey-Box Methods: A Programming Education Case Study. *IEEE Access*, 11. <https://doi.org/10.1109/ACCESS.2023.3317694>
- Skalka, Jan, & Drlik, M. (2020). *Educational Model for Improving Programming Skills Based on Conceptual Microlearning Framework BT - The Challenges of the Digital Transformation in Education* (M. E. Auer & T. Tsiatsos (eds.); pp. 923–934). Springer International Publishing.
- Skalka, Ján, Drlik, M., Halvonik, D., Kuna, P., & Valko, M. (2026). Anchored Log-based User Personas: A Typology-guided Framework for Clustering Gameplay Behavior. *IEEE Access*, 1. <https://doi.org/10.1109/ACCESS.2026.3657676>
- Skalka, Jan, & Valko, M. (2024). Rapid Guessing Behavior Detection in Microlearning: Insights into Student Performance, Engagement, and Response Accuracy. *IEEE*

- Access, 12.
- Skalka, Jan, & Valko, M. (2025). *Motivation - Immersion Game Dataset*. <https://doi.org/10.6084/m9.figshare.30069718>
- Skalka, Ján, & Valko, M. (2025a). Beyond the Wow Effect: Prior Experience as a Predictor of VR User Acceptance. *ICL 2025*.
- Skalka, Ján, & Valko, M. (2025b). Comparison of Methods for Identifying Rapid Guessing Behavior in Microlearning Courses. In *E-Learning and Enhancing Soft Skills: Contemporary Models of Education in the Era of Artificial Intelligence*. https://doi.org/10.1007/978-3-031-82243-8_4
- Soland, J., Kuhfeld, M., & Rios, J. (2021). Comparing different response time threshold setting methods to detect low effort on a large-scale assessment. *Large-Scale Assessments in Education*, 9(1), 1–21. <https://doi.org/10.1186/s40536-021-00100-w>
- Somasundaram, M., Mohamed Junaid, K. A., & Mangadu, S. (2020). Artificial intelligence (AI) enabled intelligent quality management system (IQMS) for personalized learning path. *Procedia Computer Science*, 172. <https://doi.org/10.1016/j.procs.2020.05.096>
- Su, Y., Backlund, P., & Engström, H. (2021). Comprehensive review and classification of game analytics. *Service Oriented Computing and Applications*, 15(2), 141–156. <https://doi.org/10.1007/s11761-020-00303-z>
- Sukthankar, G., & Sycara, K. (2010). Analyzing team decision-making in tactical scenarios. *Computer Journal*, 53(5). <https://doi.org/10.1093/comjnl/bxp038>
- Sung, A., Leong, K., & Lee, C. (2023). A study of learners' interactive preference on multimedia microlearning. *Journal of Work-Applied Management*, 15(1), 96–119. <https://doi.org/10.1108/JWAM-01-2022-0007>
- Suriadi, S., Andrews, R., ter Hofstede, A. H. M., & Wynn, M. T. (2017). Event log imperfection patterns for process mining: Towards a systematic approach to cleaning event logs. *Information Systems*, 64. <https://doi.org/10.1016/j.is.2016.07.011>
- Svetina Valdivia, D., Rutkowski, L., Rutkowski, D., Canbolat, Y., & Underhill, S. (2023). Test engagement and rapid guessing: Evidence from a large-scale state assessment. *Frontiers in Education*, 8(1127644), 1–10. <https://doi.org/10.3389/feduc.2023.1127644>
- Tan, J., & Katchabaw, M. (2022). A Reusable Methodology for Player Clustering Using Wasserstein Autoencoders. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 13477 LNCS, 296–308. https://doi.org/10.1007/978-3-031-20212-4_24
- Tan, L. Y., Hu, S., Yeo, D. J., & Cheong, K. H. (2025). Artificial intelligence-enabled adaptive learning platforms: A review. *Computers and Education: Artificial Intelligence*, 9, 100429. <https://doi.org/https://doi.org/10.1016/j.caeai.2025.100429>
- Tan, T. Y., Jain, M., Obaid, T., & Nesbit, J. C. (2020). What can completion time of quizzes tell us about students' motivations and learning strategies? *Journal of Computing in Higher Education*, 32(2), 389–405. <https://doi.org/10.1007/s12528-019-09239-6>
- Tarekegn, A. N., Tessem, B., & Rabbi, F. (2025). A New Cluster Validation Index Based on Stability Analysis. *International Conference on Pattern Recognition Applications and Methods*, 1. <https://doi.org/10.5220/0013309100003905>
- Tavenard, R., Faouzi, J., Vandewiele, G., Divo, F., Androz, G., Holtz, C., Payne, M., Yurchak, R., Rußwurm, M., Kolar, K., & Woods, E. (2020). Tslern, a machine learning toolkit for time series data. *Journal of Machine Learning Research*, 21.
- Taylor, A. dung, & Hung, W. (2022). The Effects of Microlearning: A Scoping Review. *Educational Technology Research and Development*, 70(2), 363–395. <https://doi.org/10.1007/s11423-022-10084-1>
- Teng, Z., Holmes, J., Dominguez, F., Pfau, J., Junior, M. E., & El-Nasr, M. S. (2025). Identifying Player Strategies Through Segmentation: An Interactive Process Visualization Approach. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 15259 LNCS. https://doi.org/10.1007/978-3-031-74138-8_7
- Teng, Z., Pfau, J., Maram, S. S., & Seif El-Nasr, M. (2022). Player Segmentation with INSPECT: Revealing Systematic Behavior Differences within MMORPG and Educational Game Case Studies. *CHI PLAY 2022 - Extended Abstracts of the 2022 Annual Symposium on Computer-Human Interaction in Play*. <https://doi.org/10.1145/3505270.3558340>
- Tian, M., Blair, R. H., Mu, L., Bonner, M., Browne, R., & Yu, H. (2021). A framework for stability-based module detection in correlation graphs. *Statistical Analysis and Data Mining*, 14(2). <https://doi.org/10.1002/sam.11495>
- Tibshirani, R., & Walther, G. (2005). Cluster validation by prediction strength. *Journal of Computational and Graphical Statistics*, 14(3). <https://doi.org/10.1198/106186005X59243>
- Tiukhova, E., Vemuri, P., Flores, N. L., Islind, A. S., Óskarsdóttir, M., Poelmans, S., Baesens, B., & Snoeck, M. (2024). Explainable Learning Analytics: Assessing the stability of student success prediction models by means of explainable AI. *Decision Support Systems*, 182, 114229. <https://doi.org/https://doi.org/10.1016/j.dss.2024.114229>
- Tlili, A., Chang, M., Moon, J., Liu, Z., Burgos, D., Chen, N. S., & Kinshuk. (2021). A systematic literature review of empirical studies on learning analytics in educational games. *International Journal of Interactive Multimedia and Artificial Intelligence*, 7(2), 250–261. <https://doi.org/10.9781/ijimai.2021.03.003>
- Toda, A., Klock, A. C. T., Pereira, F. D., Rodrigues, L. A., Palomino, P. T., & Lopes, V. (2022). Towards the understanding of cultural differences in between gamification preferences: A data-driven comparison between the US and Brazil. *Proceedings of the 15th International Conference on Educational Data Mining, EDM 2022*. <https://doi.org/10.5281/zenodo.6853030>
- Tondello, G. F., Mora, A., Marczewski, A., & Nacke, L. E. (2019). Empirical validation of the Gamification User Types Hexad scale in English and Spanish. *International Journal of Human Computer Studies*, 127, 95–111. <https://doi.org/10.1016/j.ijhcs.2018.10.002>
- Tondello, G. F., & Nacke, L. E. (2020). Validation of User Preferences and Effects of Personalized Gamification on Task Performance. *Frontiers in Computer Science*, 2. <https://doi.org/10.3389/fcomp.2020.00029>
- Tondello, G. F., Wehbe, R. R., Diamond, L., Busch, M., Marczewski, A., & Nacke, L. E. (2016). The gamification user types Hexad scale. *CHI PLAY 2016 - Proceedings of the 2016 Annual Symposium on Computer-Human Interaction in Play*, 229–243. <https://doi.org/10.1145/2967934.2968082>
- Tori, A. A., Tori, R., & Nunes, F. D. L. D. S. (2022). Serious Game Design in Health Education: A Systematic Review. In *IEEE Transactions on Learning Technologies* (Vol. 15, Issue 6). <https://doi.org/10.1109/TLT.2022.3200583>
- Tricomi, P. P., Nenna, F., Pajola, L., Conti, M., & Gamberi, L. (2023). You Can't Hide Behind Your Headset: User Profiling in Augmented and Virtual Reality. *IEEE Access*, 11, 9859–

9875. <https://doi.org/10.1109/ACCESS.2023.3240071>
- Trosten, D. J., Løkse, S., Jenssen, R., & Kampffmeyer, M. (2021). Reconsidering Representation Alignment for Multi-view Clustering. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. <https://doi.org/10.1109/CVPR46437.2021.00131>
- Truong, C., Oudre, L., & Vayatis, N. (2020). Selective review of offline change point detection methods. In *Signal Processing* (Vol. 167). <https://doi.org/10.1016/j.sigpro.2019.107299>
- Tuunanen, J., & Hamari, J. (2012). *Meta-synthesis of player typologies*. 29–53. <https://doi.org/10.26503/dl.v2012i1.604>
- Tyack, A., & Mekler, E. D. (2020). Self-Determination Theory in HCI Games Research: Current Uses and Open Questions. *Conference on Human Factors in Computing Systems - Proceedings, 2020-January*. <https://doi.org/10.1145/3313831.3376723>
- Ullmann, T., Hennig, C., & Boulesteix, A. L. (2022). Validation of cluster analysis results on validation data: A systematic framework. In *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery* (Vol. 12, Issue 3). <https://doi.org/10.1002/widm.1444>
- Uludağlı, M. Ç., & Oğuz, K. (2023). Non-player character decision-making in computer games. *Artificial Intelligence Review*, 56(12). <https://doi.org/10.1007/s10462-023-10491-7>
- Ustun, A. B., Karaoglan-Yilmaz, F. G., & Yilmaz, R. (2023). Educational UTAUT-based virtual reality acceptance scale: a validity and reliability study. *Virtual Reality*, 27(2). <https://doi.org/10.1007/s10055-022-00717-4>
- Ustun, A. B., Karaoglan-Yilmaz, F. G., Yilmaz, R., Ceylan, M., & Uzun, O. (2024). Development of UTAUT-based augmented reality acceptance scale: a validity and reliability study. *Education and Information Technologies*, 29(9). <https://doi.org/10.1007/s10639-023-12321-3>
- Vahlo, J., & Tuuri, K. (2025). Validating Motives of Autonomous Players (MAP) inventory: a bottom-up model of general motivational factors to videogame play. *User Modeling and User-Adapted Interaction*, 35(2), 10. <https://doi.org/10.1007/s11257-025-09431-7>
- Valencia, M. M. A. (2022). Principles, Scope, and Limitations of the Methodological Triangulation. *Investigacion y Educacion En Enfermeria*, 40(2). <https://doi.org/10.17533/udea.iee.v40n2e03>
- van Buuren, S., & Groothuis-Oudshoorn, K. (2011). mice: Multivariate imputation by chained equations in R. *Journal of Statistical Software*, 45(3). <https://doi.org/10.18637/jss.v045.i03>
- Van Der Maaten, L., & Hinton, G. (2008). Visualizing data using t-SNE. *Journal of Machine Learning Research*, 9.
- Van Laer, T., De Ruyter, K., Visconti, L. M., & Wetzels, M. (2014). The extended transportation-imagery model: A meta-analysis of the antecedents and consequences of consumers' narrative transportation. *Journal of Consumer Research*, 40(5). <https://doi.org/10.1086/673383>
- van Loon, W., Fokkema, M., de Vos, F., Koini, M., Schmidt, R., & de Rooij, M. (2024). Imputation of missing values in multi-view data. *Information Fusion*, 111. <https://doi.org/10.1016/j.inffus.2024.102524>
- van Loon, W., Fokkema, M., Szabo, B., & de Rooij, M. (2020). Stacked penalized logistic regression for selecting views in multi-view learning. *Information Fusion*, 61. <https://doi.org/10.1016/j.inffus.2020.03.007>
- van Raaij, E. M., & Schepers, J. J. L. (2008). The acceptance and use of a virtual learning environment in China. *Computers and Education*, 50(3). <https://doi.org/10.1016/j.compedu.2006.09.001>
- Venkatesh, V., & Bala, H. (2008). Technology acceptance model 3 and a research agenda on interventions. *Decision Sciences*, 39(2). <https://doi.org/10.1111/j.1540-5915.2008.00192.x>
- Venkatesh, V., & Davis, F. D. (2000). Theoretical extension of the Technology Acceptance Model: Four longitudinal field studies. *Management Science*, 46(2). <https://doi.org/10.1287/mnsc.46.2.186.11926>
- Venkatesh, V., Morris, M. G., Davis, G. B., & Davis, F. D. (2003). User acceptance of information technology: Toward a unified view. *MIS Quarterly: Management Information Systems*, 27(3). <https://doi.org/10.2307/30036540>
- Vera, J. F., & Angulo, J. M. (2023). An MDS-based unifying approach to time series K-means clustering: application in the dynamic time warping framework. *Stochastic Environmental Research and Risk Assessment*, 37(12). <https://doi.org/10.1007/s00477-023-02470-9>
- Vijayan, D., & Aziz, I. (2023). Adaptive Hierarchical Density-Based Spatial Clustering Algorithm for Streaming Applications. *Telecom*, 4(1). <https://doi.org/10.3390/telecom4010001>
- Villena-Taranilla, R., Cózar-Gutiérrez, R., González-Calero, J. A., & Diago, P. D. (2023). An extended technology acceptance model on immersive virtual reality use with primary school students. *Technology, Pedagogy and Education*, 32(3). <https://doi.org/10.1080/1475939X.2023.2196281>
- Von Luxburg, U. (2009). Clustering stability: An overview. *Foundations and Trends in Machine Learning*, 2(3). <https://doi.org/10.1561/22000000008>
- von Ziegler, L., Sturman, O., & Bohacek, J. (2021). Big behavior: challenges and opportunities in a new era of deep behavior profiling. In *Neuropsychopharmacology* (Vol. 46, Issue 1). <https://doi.org/10.1038/s41386-020-0751-7>
- Vorderer, P., Wirth, W., Gouveia, F. R., Biocca, F., Saari, T., Jäncke, L., Böcking, S., Schramm, H., Gysbers, A., Hartmann, T., & others. (2004). MEC Spatial Presence Questionnaire (MEC-SPQ). *Report to the European Community, Project Presence: MEC (IST-2001-37661)*, 18(June).
- Wan, X., Liu, X., Liu, J., Wang, S., Wen, Y., Liang, W., Zhu, E., Liu, Z., & Zhou, L. (2023). Auto-Weighted Multi-View Clustering for Large-Scale Data. *Proceedings of the 37th AAAI Conference on Artificial Intelligence, AAAI 2023*, 37. <https://doi.org/10.1609/aaai.v37i8.26201>
- Wang, Chengyu, Li, X., Zhou, T., & Cai, Z. (2024). Unsupervised Time Series Segmentation: A Survey on Recent Advances. In *Computers, Materials and Continua* (Vol. 80, Issue 2). <https://doi.org/10.32604/cmc.2024.054061>
- Wang, Chun, & Xu, G. (2015). A mixture hierarchical model for response times and response accuracy. *British Journal of Mathematical and Statistical Psychology*, 68(3), 456–477. <https://doi.org/10.1111/bmsp.12054>
- Wang, P., Yang, X., Ding, W., Zhan, J., & Yao, Y. (2024). Three-way clustering: Foundations, survey and challenges. *Applied Soft Computing*, 151. <https://doi.org/10.1016/j.asoc.2023.111131>
- Wang, S., Wang, F., Zhu, Z., Wang, J., Tran, T., & Du, Z. (2024). Artificial intelligence in education: A systematic literature review. *Expert Systems with Applications*, 252, 124167. <https://doi.org/https://doi.org/10.1016/j.eswa.2024.124167>
- Wang, X., Xie, L., Wang, H., Xing, X., Wan, W., Wu, Z., Ma, X., & Li, Q. (2025). Deciphering Explicit and Implicit Features for Reliable, Interpretable, and Actionable User Churn Prediction in Online Video Games. *IEEE Transactions on Visualization and Computer Graphics*, 31(9), 5990–6007.

- <https://doi.org/10.1109/TVCG.2024.3487974>
- Watfa, M. K., & Akili, A. (2023). Factors influencing elders' intention to use a housing community: a virtual reality approach extending the theory of planned behaviour. *International Journal of Construction Management*, 23(5). <https://doi.org/10.1080/15623599.2021.1931769>
- Weibel, D., & Wissmath, B. (2011). Immersion in computer games: The role of spatial presence and flow. *International Journal of Computer Games Technology*. <https://doi.org/10.1155/2011/282345>
- Wen, J., Zhang, Z., Xu, Y., & Zhong, Z. (2019). Incomplete multi-view clustering via graph regularized matrix factorization. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 11132 LNCS. https://doi.org/10.1007/978-3-030-11018-5_47
- Wen, Y., & Li, H. (2025). Cluster Complementarity and Consistency Mining for Multi-View Representation Learning. *Mathematics*, 13(15). <https://doi.org/10.3390/math13152521>
- Wirth, W., Hartmann, T., Böcking, S., Vorderer, P., Klimmt, C., Schramm, H., Saari, T., Laarni, J., Ravaja, N., Gouveia, F. R., Biocca, F., Sacau, A., Jäncke, L., Baumgartner, T., & Jäncke, P. (2007). A process model of the formation of spatial presence experiences. *Media Psychology*, 9(3). <https://doi.org/10.1080/15213260701283079>
- Wise, S. L. (2006). An investigation of the differential effort received by items on a low-stakes computer-based test. *Applied Measurement in Education*, 19(2), 95–114. https://doi.org/10.1207/s15324818ame1902_2
- Wise, S. L. (2017). Rapid-Guessing Behavior: Its Identification, Interpretation, and Implications. *Educational Measurement: Issues and Practice*, 36(4), 52–61. <https://doi.org/10.1111/emip.12165>
- Wise, S. L. (2019). An Information-Based Approach to Identifying Rapid-Guessing Thresholds. *Applied Measurement in Education*, 32(4), 325–336. <https://doi.org/10.1080/08957347.2019.1660350>
- Wise, S. L. (2020). The Impact of Test-Taking Disengagement on Item Content Representation. *Applied Measurement in Education*, 33(2), 83–94. <https://doi.org/10.1080/08957347.2020.1732386>
- Wise, S. L., & DeMars, C. E. (2005). Low examinee effort in low-stakes assessment: Problems and potential solutions. *Educational Assessment*, 10(1), 1–17. https://doi.org/10.1207/s15326977ea1001_1
- Wise, S. L., & Gao, L. (2017). A General Approach to Measuring Test-Taking Effort on Computer-Based Tests. *Applied Measurement in Education*, 30(4), 343–354. <https://doi.org/10.1080/08957347.2017.1353992>
- Wise, S. L., & Kong, X. (2005). Response time effort: A new measure of examinee motivation in computer-based tests. In *Applied Measurement in Education* (Vol. 18, Issue 2, pp. 163–183). https://doi.org/10.1207/s15324818ame1802_2
- Wise, S. L., & Kuhfeld, M. R. (2020). A cessation of measurement: Identifying test taker disengagement using response time. In *Integrating Timing Considerations to Improve Testing Practices* (pp. 150–164). <https://doi.org/10.4324/9781351064781-11>
- Wise, S. L., & Kuhfeld, M. R. (2021). Using Retest Data to Evaluate and Improve Effort-Moderated Scoring. *Journal of Educational Measurement*, 58(1), 130–149. <https://doi.org/10.1111/jedm.12275>
- Wise, S. L., & Ma, L. (2012). Setting response time thresholds for a CAT item pool: the normative threshold method. *Paper Presented at the 2012 Annual Meeting of the National Council on Measurement in Education*, 1–24.
- Wise, S. L., Pastor, D. A., & Kong, X. J. (2009). Correlates of rapid-guessing behavior in low-stakes testing: implications for test development and measurement practice. *Applied Measurement in Education*, 22(2), 185–205. <https://doi.org/10.1080/08957340902754650>
- Wise, S. L., & Smith, L. F. (2016). The validity of assessment when students don't give good effort. In *Handbook of Human and Social Conditions in Assessment* (pp. 204–220). <https://doi.org/10.4324/9781315749136-19>
- Witmer, B. G., & Singer, M. J. (1998). Measuring presence in virtual environments: A presence questionnaire. *Presence: Teleoperators and Virtual Environments*, 7(3). <https://doi.org/10.1162/105474698565686>
- Wong, E. Y. cheung, Hui, R. T. yin, & Kong, H. (2023). Perceived usefulness of, engagement with, and effectiveness of virtual reality environments in learning industrial operations: the moderating role of openness to experience. *Virtual Reality*, 27(3). <https://doi.org/10.1007/s10055-023-00793-0>
- Wongabut, T., Ninrutsirikun, U., Nukoolkit, C., Lavangnananda, P., Warasup, K., & Arpikanondt, C. (2025). A Feature Engineering Approach to Improve Clustering-Based Persona Generation. *2025 IEEE 5th International Conference on Software Engineering and Artificial Intelligence, SEAI 2025*. <https://doi.org/10.1109/SEAI65851.2025.11108775>
- Wu, T., Fan, J., & Wang, P. (2022). An Improved Three-Way Clustering Based on Ensemble Strategy. *Mathematics*, 10(9). <https://doi.org/10.3390/math10091457>
- Xiong, Z., & Cao, M. (2025). SLRL: Structured Latent Representation Learning for Multi-view Clustering. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 15031 LNCS. https://doi.org/10.1007/978-981-97-8487-5_38
- Yama Adi Putra, G. N., Junus, K., & Santoso, H. B. (2022). Gamification-Based Online Collaborative Learning Feature Design on SoloLearn Application with Mechanics-Dynamics-Aesthetics Framework and User-Centered Design Method. *Proceedings - ICACIS 2022: 14th International Conference on Advanced Computer Science and Information Systems*, 65–74. <https://doi.org/10.1109/ICACIS56558.2022.9922961>
- Yang, C., & Yue, H. (2025). Consensus Partition Guided Incomplete Multi-View Clustering. *IEEE Access*, 13. <https://doi.org/10.1109/ACCESS.2025.3543099>
- Yang, T. Y., Brinton, C. G., Joe-Wong, C., & Chiang, M. (2017). Behavior-Based Grade Prediction for MOOCs Via Time Series Neural Networks. *IEEE Journal on Selected Topics in Signal Processing*, 11(5), 716–728. <https://doi.org/10.1109/JSTSP.2017.2700227>
- Yannakakis, G. N., & Togelius, J. (2018a). *Artificial intelligence and games* (Vol. 2). Springer.
- Yannakakis, G. N., & Togelius, J. (2018b). *Artificial Intelligence and Games*. Springer Nature. <https://doi.org/10.1007/978-3-319-63519-4>
- Yannakakis, G. N., & Togelius, J. (2025). *Artificial Intelligence and Games* (G. N. Yannakakis & J. Togelius (eds.); pp. 337–375). Springer Nature Switzerland. https://doi.org/10.1007/978-3-031-83347-2_11
- Ye, Y., Liu, X., Liu, Q., Guo, X., & Yin, J. (2018). Incomplete Multiview Clustering via Late Fusion. *Computational Intelligence and Neuroscience*, 2018.

- <https://doi.org/10.1155/2018/6148456>
- Yee, N. (2016). *Gaming Motivations Align with Personality Traits*. Quantic Foundry.
- Yee, N. (2006a). Motivations for play in online games. *Cyberpsychology and Behavior*, 9(6), 772–775. <https://doi.org/10.1089/cpb.2006.9.772>
- Yee, N. (2006b). The demographics, motivations, and derived experiences of users of massively multi-user online graphical environments. *Presence: Teleoperators and Virtual Environments*, 15(3). <https://doi.org/10.1162/pres.15.3.309>
- Yee, N., Ducheneaut, N., & Nelson, L. (2012). Online gaming motivations scale: Development and validation. *Conference on Human Factors in Computing Systems - Proceedings*. <https://doi.org/10.1145/2207676.2208681>
- Yu, H., Chapman, B., Di Florio, A., Eischen, E., Gotz, D., Jacob, M., & Blair, R. H. (2019). Bootstrapping estimates of stability for clusters, observations and model selection. *Computational Statistics*, 34(1). <https://doi.org/10.1007/s00180-018-0830-y>
- Yu, J., Duan, Q., Huang, H., He, S., & Zou, T. (2023). Effective Incomplete Multi-View Clustering via Low-Rank Graph Tensor Completion. *Mathematics*, 11(3). <https://doi.org/10.3390/math11030652>
- Yu, K. K., Guzdial, M., & Sturtevant, N. R. (2024). The FarmQuest Player Telemetry Dataset: Playthrough Data of a Cozy Farming Game. *Proceedings of the AAAI Conference on Artificial Intelligence and Interactive Digital Entertainment*, 20(1), 263–268. <https://doi.org/10.1609/aiide.v20i1.31889>
- Yu, S. Z. (2010). Hidden semi-Markov models. In *Artificial Intelligence* (Vol. 174, Issue 2). <https://doi.org/10.1016/j.artint.2009.11.011>
- Zaki, M. J., & Meira, W. (2014). *Data mining and analysis: fundamental concepts and algorithms*. Cambridge University Press.
- Zamarro, G., Hitt, C., & Mendez, I. (2019). When students don't care: Reexamining international differences in achievement and student effort. *Journal of Human Capital*, 13(4), 519–552. <https://doi.org/10.1086/705799>
- Zhao, S., Xu, Y., Luo, Z., Tao, J., Li, S., Fan, C., & Pan, G. (2021). Player Behavior Modeling for Enhancing Role-Playing Game Engagement. *IEEE Transactions on Computational Social Systems*, 8(2). <https://doi.org/10.1109/TCSS.2021.3052261>
- Zhou, L., Du, G., Lü, K., Wang, L., & Du, J. (2024). A Survey and an Empirical Evaluation of Multi-View Clustering Approaches. *ACM Computing Surveys*, 56(7). <https://doi.org/10.1145/3645108>
- Zhou, R., & Shen, Y. D. (2020). End-to-end adversarial-attention network for multi-modal clustering. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. <https://doi.org/10.1109/CVPR42600.2020.01463>
- Zhu, X., & Melnykov, V. (2015). Probabilistic assessment of model-based clustering. *Advances in Data Analysis and Classification*, 9(4). <https://doi.org/10.1007/s11634-015-0215-9>
- Zhuang, F., Qi, Z., Duan, K., Xi, D., Zhu, Y., Zhu, H., Xiong, H., & He, Q. (2021). A Comprehensive Survey on Transfer Learning. In *Proceedings of the IEEE* (Vol. 109, Issue 1). <https://doi.org/10.1109/JPROC.2020.3004555>
- Zucchini, W., Macdonald, I. L., & Langrock, R. (2017). Hidden Markov models for time series: An introduction using R, second edition. In *Hidden Markov Models for Time Series: An Introduction Using R, Second Edition*.
- <https://doi.org/10.1201/b20790>
- Żuchowska, L., Kutt, K., & Nalepa, G. J. (2021). Bartle taxonomy-based game for affective and personality computing research. *CEUR Workshop Proceedings*, 2995, 51–55.

Prílohy

Zoznam schválených časopiseckých a konferenčných publikácií využitých v práci:

1. **Rapid Guessing Behavior Detection in Microlearning: Insights Into Student Performance, Engagement, and Response Accuracy.** J. Skalka, M. Valko. In: IEEE Access, vol. 12, pp. 157996-158024, 2024, doi: 10.1109/ACCESS.2024.3485505
2. **Anchored Log-Based User Personas: A Typology-Guided Framework for Clustering Gameplay Behavior.** J. Skalka, M. Drlík, D. Halvoník, P. Kuna, M. Valko. In: IEEE Access, vol. 14, pp. 14558-14578, 2026, doi: 10.1109/ACCESS.2026.3657676.
3. **Towards a Unified Model for Content Personalization in Virtual Environments.** J. Skalka, M. Valko, M. Drlík, M. Pappová. In: DLCC 2025. Theoretical and Practical Aspects of Distance Learning. E-learning & Interactive Learning. Generative Artificial Intelligence, Gamification and Immersive Technologies in Educational Practice and Research, Cieszyn, Poland, 2025
4. **Uncovering Common Dimensions in Player Typologies: A Statistical Analysis of User Models.** J. Skalka, M. Valko. In: DLCC 2025. Theoretical and Practical Aspects of Distance Learning. E-learning & Interactive Learning. Generative Artificial Intelligence, Gamification and Immersive Technologies in Educational Practice and Research, Cieszyn, Poland, 2025
5. **Beyond the Wow Effect: Prior Experience as a Predictor of VR User Acceptance.** J. Skalka, M. Valko. In: ICL International Conference on Interactive Collaborative Learning 2025, Budapest, Hungary, 2025