



TEZĂ DE DOCTORAT

Sisteme Inteligente de Învățare pentru Dezvoltarea Psihomotorie în Medii
Deschise

Autor: Ing. Laurențiu-Marian Neagu

Conducători de doctorat: Prof. Dr. Ing. Sébastien Travadel, Prof. Dr. Ing. Răzvan Rughiniș

COMISIE DOCTORAT

Președinte	Mihai Dascălu	de la	Universitatea Politehnica din București
Conducător de doctorat	Sébastien Travadel	de la	MINES Paris - PSL University
Conducător de doctorat	Răzvan Rughiniș	de la	Universitatea Politehnica din București
Membru	Elvira Popescu	de la	Universitatea din Craiova
Membru	Monica Iulia Stănescu	de la	Universitatea Națională de Educație Fizică și Sport, București
Membru	Liviu P. Dinu	de la	Universitatea din București

Rezumat

Tehnologia informației a produs schimbări semnificative în mare parte dintre industrii. În acest timp, cercetarea recentă privind tehnologia aplicată în educație arată potențialul de a genera un punct de inflexiune care să transforme complet modul în care oamenii învață. Potențiala revoluție educațională actuală este condusă, în principal, de trei componente: inteligența artificială, accesibilitatea internetului și progresele în științele educației. Sistemele inteligente de instruire (denumite prescurtat ITS, din eng. „Intelligent Tutoring Systems”), sunt considerate de experți unul dintre cei mai potriviți candidați pentru transformarea educațională.

Un ITS este un sistem tehnologic care produce instruire personalizată prin material educațional individualizat, solid din punct de vedere pedagogic și ușor de accesat. Un ITS implică studenții în mod independent sau în colaborare pentru a asigura o învățare eficientă. Grupurile de cercetare de Inteligență Artificială în Educație au explorat diverse ipoteze și metode pentru construirea unor sisteme de învățare eficiente în domeniul cognitiv, cu rezultate notabile în discipline precum fizica, matematica și informatica. În schimb, domeniul psihomotric a intrat recent într-un proces intens de digitalizare, și câteva abordări din ultimii ani introduc sisteme de instruire pentru acest domeniu.

Obiectivul general al acestei teze este de a oferi sesiuni de pregătire personalizate în domeniul psihomotric sub forma unui ITS, denumit *Selfit* – un sistem eficient și ușor de utilizat, care are ca obiectiv pe termen lung atât atragerea oamenilor înspre activități sportive, cât și îmbunătățirea sănătății generale a populației. Acest obiectiv are trei direcții mari de cercetare. În primul rând, introducem o ontologie pentru modelarea conceptelor cheie ale domeniului psihomotric – reprezentările și relațiile dintre concepte, date și entități. Ontologia pentru modelarea cunoștințelor introdusă în cadrul *Selfit*, numită *OntoStrength*, a fost construită folosind metodologia *Ontology Development 101*.

În al doilea rând, introducem un algoritm de tip bandit bazat pe context (eng. contextual bandits) pentru generarea de sesiuni personalizate. Procesul decizional al tutorelui digital în fața incertitudinii se dovedește dificil – timpul de pregătire este limitat, studentul nu poate testa toate activitățile sportive, iar personalizarea ar trebui să se întâmple în timp real, menținând în același timp utilizatorul motivat și implicat. Abordarea *Selfit* pentru instruirea automată s-a dovedit, în simulări, mai eficientă ca abordarea de antrenament cu reguli fixe.

În al treilea rând, evaluăm utilitatea și eficacitatea sistemului nostru într-un experiment, ce a implicat 42 de participanți, cu experiență redusă sau medie în antrenamente sportive. Aceștia au primit una dintre cele două versiuni ale sistemului *Selfit*, folosind strategii diferite de adaptabilitate – una restrânsă, iar cealaltă mai largă în dimensiune a explorării. Utilizatorii au perceput, în majoritate, *Selfit* ca fiind practic, previzibil, simplu, elegant, motivant, nou și captivant. Rezultatele sunt, de asemenea, în concordanță cu simulările noastre inițiale, demonstrând potențialul abordării propuse pentru antrenament personalizat.

Evaluarea sistemului *Selfit*, în ansamblu, a arătat rezultate promițătoare și a evidențiat utilitatea arhitecturii ITS în domeniul psihomotric. Teza actuală poate fi considerată la baza unei noi intersecții disciplinare, ce implică Inteligența Artificială în Educație și pregătirea psihomotorie, deschzând noi direcții de cercetare care vizează îmbunătățirea stării generale de sănătate a populației prin sisteme automatizate. Cercetări ulterioare pot urmări extinderea bazei de cunoștințe de la antrenamentul de forță la alte tipuri de antrenament, cum ar fi flexibilitatea și mobilitatea, îmbunătățirea experienței utilizatorului prin oferirea de suport vocal în timpul antrenamentului, precum și integrarea tehnicilor de Procesare în Limbaj Natural pentru a îmbunătăți interacțiunea tutore – student, respectiv computer vision pentru evaluare în timp real.

Cuprins

1	Introducere	5
1.1	Obiective și domenii de interes	5
1.2	Structura Tezei	7
2	Sistemele Inteligente de Instruire și Antrenamentul Psihomotric	9
2.1	Arhitectura și Caracteristicile Sistemului de Instruire Inteligentă	9
2.2	Dezvoltarea Psihomotorie în Sistemele Inteligente de Instruire	10
2.3	Provocări în Domeniul Digitalizării Psihomotorii	12
3	Modele ale Procesului de Cunoaștere și de Învățare	15
3.1	Teoriile Învățării	15
3.2	Modelarea Cunoștințelor și a Predării	15
3.3	Principiile Evaluării Modelelor	17
4	Sisteme Inteligente de Instruire în Medii Deschise. Învățare Automată în Practică	20
4.1	Prezentare Generală a Tehnicilor de Predare pentru Tutori Inteligenți	20
4.2	Tehnici de Învățare Automată în Dezvoltarea Psihomotorie	23
5	OntoStrength – Un Cadru de Reprezentare și Deducere a Cunoștințelor în Sisteme de Instruire Inteligente Psihomotorii	25
5.1	Metodologia de Proiectare a OntoStrength	25
5.2	Utilizarea OntoStrength	29
6	Strategii de Predare într-un Sistem de Instruire Psihomotorie	30
6.1	Considerarea Dimorfismului Sexual în Sistemele de Instruire Psihomotorie	30
6.2	Optimizarea Secvențelor de Predare folosind Învățarea Automată. Metoda Exercițiul Corect la Momentul Potrivit (RiERiT).	32
7	Selfit – Un Prototip de Sistem de Instruire Psihomotorie în Medii Deschise	34
7.1	Arhitectura <i>Selfit</i>	34
7.2	Generarea Antrenamentului și Monitorizarea Impactului Antrenamentului	37
7.3	Evaluarea Psihomotorie folosind Vederea Computerizată. Un Studiu privind Atenuarea Riscului de Rănire	38
8	Rezultate	40
8.1	Experiment bazat pe Simulare	40
8.2	Experiment cu Utilizatori Reali	41
8.3	Rezultatele Învățării Agentului	44
8.4	Rezultate privind Experiența Utilizatorului	45
9	Discuție	47
9.1	Avantaje ale Abordării noastre	47
9.2	Limitări	50
9.3	Aplicații preconizate	51
10	Concluzii	53
10.1	Contribuții Personale	53
10.2	Direcții pentru Cercetări Ulterioare	55
	Listă de Publicații	57
	Referințe	59

Figuri

Figura 1. Structura tezei.....	7
Figura 2. Revizuirea Sistematică a Literaturii - Prezentare Generală a Metodei.....	11
Figura 3. Scheme de Proiectare ale Evaluării.....	19
Figura 4. Cele patru faze ale planificării sportive.	24
Figura 5. Subdomeniul OntoStrength pentru Dezvoltarea Personalizată a Abilităților de Forță	27
Figura 6. Interogare OntoStrength – Mișcările asociate unui Micro-ciclu.....	28
Figura 7. Vedere GraphDB a instanței și clasei Feet Elevated Front Plank.....	28
Figura 8. Interfața <i>Selfit</i> – Parametrii pentru Generarea de Sesiuni	38
Figura 9. Procesul Modulului de Evaluare a Riscului de Accidentare ACL.....	38
Figura 10. Ilustrație a evoluției distanței dintre genunchii și gleznela elevului cu variații între stânga și dreapta.....	39
Figura 11. Compararea Algoritmilor de Antrenament Sportiv – Interval de Timp de 2 ani.....	41
Figura 12. Spațiu de Explorare al Bandiților pentru fiecare grup, bazat pe Provocarea de Calibrare.	43
Figura 13. Numărul de Sesiuni per Utilizator și Grupul de Instruire Corespunzător.....	44
Figura 14. Recompense medii și Moving Average (dimensiune fereastră = 6 pași≈ 1 sesiune) Recompense per pas de bandit pentru cei mai buni atleți din Grupul A (> 11).....	45

Tabele

Tabel 1. Exemple Comparative de Evaluare (Woolf, 2010).....	19
Tabel 2. Scopul aplicării tehnicilor de învățare automată în ITS-uri în perioada 2007-2017 (Mousavinasab et al., 2018).....	20
Tabel 3. Adaptarea sarcinii de antrenament la faza menstruală adaptată din Pitchers	31
Tabel 4. Exemple de Șabloane de Microcicluri pentru Adaptarea Anatomică.....	32
Tabel 5. Feedback despre Experiența Utilizatorului bazat pe Chestionarul AttrakDiff în <i>Selfit Version 2</i>	46

1 Introducere

1.1 Obiective și domenii de interes

Creșterea tehnologiilor informaționale, determinată în principal de inovarea din sfera computerelor, a revoluționat modul în care interacționăm și învățăm (Woolf, 2010). Confluența internetului, inteligenței artificiale și științelor cognitive a creat mai departe noi instrumente în educație, îmbunătățind modul în care este produs și livrat conținutul educațional și sporind eficiența educației în general. Un candidat important în acest domeniu este Sistemul Inteligent de Instruire (din eng. Intelligent Tutoring System, prescurtat ITS), care este un sistem informatic bazat pe Inteligența Artificială care oferă o experiență educațională adaptativă (Fenza & Orciuoli, 2016).

Un Sistem Inteligent de Instruire își propune să îmbunătățească experiențele de învățare ale elevilor prin crearea de instrucțiuni și feedback personalizate, în timp ce colectează informații cât mai detaliate despre aceștia. Majoritatea ITS-urilor sunt împărțite din punct de vedere arhitectural în patru componente (Nkambou, 2010), și anume: componenta *Domeniu* – definește reguli, concepte și strategii de rezolvare a problemelor (cunoștințe de specialitate), componenta *Student* – stările cognitive și afective ale cursantului, evoluția în timp ce acesta învață, componenta de *Îndrumare* – selectează cele mai bune strategii și acțiuni de îndrumare de întreprins și componenta de *Interfață* – responsabil pentru interacțiunea studenților cu sistemul.

Lucrarea curentă își propune să contribuie la dezvoltarea ITS-urilor în domeniul psihomotoric pentru comunități mari de utilizatori, cu accent pe îmbunătățirea forței și a sănătății generale. Dezvoltarea abilităților psihomotorii este un proces ce se desfășoară pe tot parcursul vieții. O competență de mișcare este o tranzacție între un individ și o sarcină de mișcare într-un mediu dinamic. Mișcările esențiale, cum ar fi împingerea, tragerea, exercițiile de bază, genunchi sau șold sunt cerințe preliminare pentru învățarea mișcărilor psihomotorii complexe și specializate, cerute de viața de zi cu zi, de activitățile profesionale sau de petrecere a timpului liber. A învăța să efectuezi o mișcare în siguranță și eficient necesită practicarea unui volum adecvat de exerciții pentru îmbunătățirea calităților fizice asociate, cum ar fi forța, flexibilitatea sau rezistența.

Cu toate acestea, una dintre principalele provocări pentru o astfel de dezvoltare este costul ridicat atunci când se creează o bază de cunoștințe avansată de la zero. După cum au afirmat Zouaq și Nkambou (2010), o problemă acută de cercetare este modul în care componenta de instruire a unui ITS poate fi modelată eficient și ce fel de reprezentări ale cunoștințelor sunt disponibile și totodată ce fel de tehnici de achiziție de cunoștințe pot fi aplicate.

Introducere

În procesul de construire a unui sistem de instruire inteligent, fiecare componentă este bine definită cu roluri și reguli de implementare. Componentele ITS lucrează împreună pentru a produce un sistem de instruire uniform capabil să recunoască tiparele de comportament ale elevului (Orey, 1993) și să răspundă la aceste tipare cu instrucțiuni adecvate. Cu toate acestea, atunci când vine vorba de aplicarea într-un mediu deschis (care reflectă mai realist mediul obișnuit de antrenament), de exemplu, mai imprevizibil și mai slab definit, ridică noi întrebări privind modelarea și eficiența.

O altă provocare atunci când se dezvoltă un astfel de sistem este de a defini instrumentele potrivite pentru a dobândi competențe precise la nivel de cunoștințe al elevilor și pentru a prezice progresul lor în timpul utilizării sistemului. ITS-urile recent construite pentru pregătirea militară sunt adesea limitate la setările de laborator pe PC-uri și laptop-uri standard, care se concentrează pe formarea abilităților cognitive (cum ar fi luarea deciziilor și rezolvarea problemelor) și pot limita învățarea și reținerea stăpânirii sarcinilor fizice (LaViola et al., 2015).

O altă provocare este optimizarea secvențelor de predare – în general, sistemul de instruire folosește o estimare a nivelurilor de competență și progresul elevilor pentru a alege activitățile care oferă cea mai bună experiență de învățare la un anumit moment. Un ITS accesibil pentru marea majoritate a oamenilor, care se adresează sănătății generale, ar trebui să ofere o experiență de învățare personalizată, bazându-se doar pe puține cunoștințe despre utilizatori.

Provocarea cu care se confruntă tutorele este de a găsi care este secvența optimă de activități care maximizează nivelul mediu de competență peste toate abilitățile vizate (Clement, Roy, Oudeyer, & Lopes, 2015). Această provocare, care a fost ridicată inițial în domeniul cognitiv și are echivalentul în dezvoltarea psihomotorie, este generată de trei factori principali: timp limitat pentru practicarea activităților – tutorele nu poate testa toate combinațiile de secvențe, sau toate activitățile; gestionarea motivației este dificilă – elevii vor învăța eficient doar dacă sunt angajați în activități; diferențele individuale între elevi fac ca o secvență optimă pentru un elev să fie ineficientă pentru altul.

În plus, se consideră că un ITS înlocuiește antrenorul uman și mediază cunoștințele abstracte cu cursanți reali. Astfel, performanța ITS nu este determinată doar de cunoștințele pe care le deține și prelucrează, ci și de calitatea experienței utilizatorului. Pe baza provocărilor prezentate mai sus, această teză abordează următoarele obiective majore de cercetare:

- OC1: Proiectarea unui model eficient de reprezentare a cunoștințelor pentru dezvoltarea abilităților psihomotorii într-un Sistem Intelligent de Instruire.

Introducere

- **OC2:** Oferirea de recomandări de exerciții sportive personalizate pentru populație atunci când se antrenează în medii deschise.
- **OC3:** Implementarea unui modul de comunicare intuitiv și eficient care facilitează evaluarea progresului sportiv în medii deschise.

1.2 Structura Tezei

Teza este structurată în trei părți principale, *Aspecte Teoretice*, *Experimente și Rezultate și Discuții și Concluzii*. Capitolele descrise în partea *Aspecte teoretice* susțin secțiunile din *Experimente și Rezultate*, așa cum se poate vedea în Figura 1. Capitolele din secțiunea de *Experimente* au un capitol corespunzător în *Aspecte teoretice*.

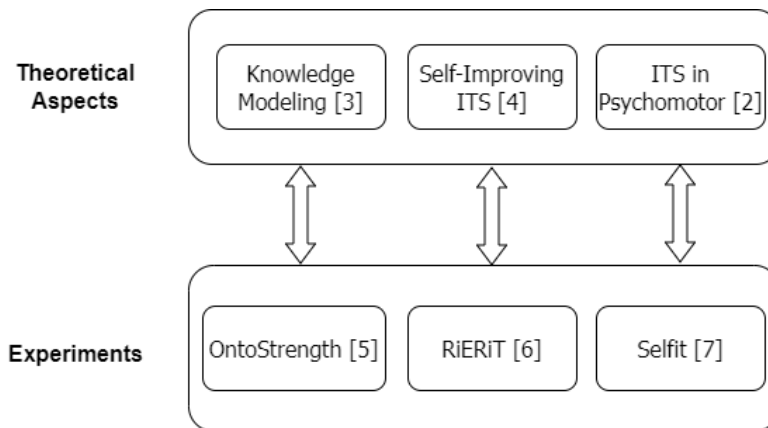


Figura 1. Structura tezei.

Structura *Aspectelor Teoretice* este următoarea – mai întâi sunt prezentate Sistemele inteligente de instruire, împreună cu utilizările lor în domeniul psihomotoric (Capitolul 2), apoi prezentăm modul în care cunoștințele sunt modelate în ITS (Capitolul 3) și care sunt metodele frecvent folosite pentru instruire în ITS-uri (Capitolul 4).

Apoi, în partea *Experimente și Rezultate*, propunem un nou model pentru domeniul psihomotoric, numit *OntoStrength* (Capitolul 5), care a fost construit pe baza constatărilor prezentate în Capitolul 3. În continuare, o metodă de personalizare a secvențelor de învățare în antrenamentul psihomotoric este introdus, denumit *RiERiT* – Capitolul 6, care a fost inspirat din constatățile din Capitolul 4, unde au fost propuse și utilizate metode similare în domeniul cognitiv. Sistemul *Selfit* este introdus în capitolul următor, ca prototip de antrenament psihomotor pentru ITS în medii deschise.

În această secțiune, lucrările prezentate pentru modelarea cunoștințelor și experimentele tutorilor psihomotori sunt îmbinate pentru a crea un sistem care prezintă potențialul descoperirilor noastre.

Introducere

Capitolul *Selfit* prezintă, de asemenea, componenta de Comunicare și modul în care aceasta a fost integrată pentru a face schimb de informații cu celelalte componente.

Ultimul capitol din această secțiune prezintă rezultatele experimentelor noastre, desfășurate în două direcții principale - pe de o parte, eficacitatea algoritmilor *RiARiT* - învățarea banditului și, pe de altă parte, experiența utilizatorului. Sistemul *Selfit* a fost testat cu utilizatori reali, care s-au antrenat în perioada 1 ianuarie 2022 – 31 mai 2022, scopul general fiind acela de a evalua dacă prototipul propus este valabil pentru antrenamentul psihomotor.

În continuare, secțiunea de *Discuții și Concluzii* descrie avantajele abordării noastre, problemele cu care ne-am confruntat și modul în care acestea au fost depășite, precum și limitările, împreună cu o listă de aplicații viitoare ce pot fi mai departe dezvoltate. Capitolul *Concluzii* prezintă rezumatul lucrării, contribuțiile noastre și direcțiile potențiale pentru cercetări viitoare.

2 Sistemele Inteligente de Instruire și Antrenamentul Psihomotric

Sistemele Inteligente de Instruire (ITS) se află la intersecția dintre educație și tehnologie (Paviotti, 2012). Un ITS este un sistem de instruire bazat pe computer, care vizează sprijinirea învățării prin diferite servicii de îndrumare, care specifică ce să predea, cum să predea, strategiile de predare și crează inferențe despre nivelul de cunoaștere al unui student asupra unui set de subiecte pentru adaptarea dinamică a conținutului sau instrucțiunilor (Murray, 1999).

Dezvoltarea unor astfel de sisteme este un proces multi-disciplinar, care implică atât experți în sfera didactică, cât și în tehnologiile cunoașterii. Dezvoltarea unui sistem inteligent de instruire necesită înțelegerea modului în care oamenii învață și predau.

2.1 Arhitectura și Caracteristicile Sistemului de Instruire Inteligentă

Cel mai cunoscut model arhitectural împrumutat la proiectarea unui ITS este Arhitectura cu patru componente, care este compusă dintr-un modul de domeniu, un modul de instruire, un modul student și interfața grafică cu utilizatorul (Nkambou, 2010).

Componenta *Domeniu* gestionează cunoștințele legate de subiectul ce trebuie învățat și conține concepte, reguli și strategii. ITS folosește cunoștințele domeniului pentru a raționa, a găsi soluții la probleme sau a răspunde la întrebările elevilor. O altă caracteristică a componentei *Domeniu* este că poate fi folosit pentru a detecta erorile elevilor și a propune soluții pentru a le corecta. Strategiile alternative de predare pot fi obținute prin dezvoltarea unor reprezentări distincte ale cunoștințelor din același domeniu.

Componenta de *Instruire* oferă cunoștințele necesare pentru atingerea obiectivelor didactice. Primește informații atât de la modulele *Domeniu*, cât și de la *Student* și este responsabil pentru selectarea conținutului subiectului pe care studentul îl va folosi, oferind mecanisme de răspuns pentru a răspunde la întrebările și tiparele elevului pentru a detecta când cursanții au nevoie de ajutor prin adoptarea diferitelor stiluri de livrare. Componenta de *Instruire* selectează scopurile didactice și decide care sunt cele mai potrivite strategii de predare pe baza modelului *Student* și a obiectivelor Studentului. Un modul de *Instruire* performant știe când este momentul potrivit pentru a actualiza procesul de învățare și cum poate face asta. Interacționează cu elevul prin feedback și sugestii.

Componenta *Student* descrie cunoștințele și abilitățile emergente ale cursantului și este considerat o componentă critică a unui ITS. Procesul de predare ar trebui să fie adaptat la caracteristicile fiecărui

elev și, pe baza acesteia, sistemul trebuie să colecteze cât mai multe informații despre preferințele cursanților, stările cognitive și afective, precum și progresul lor în timpul învățării. Un ITS este mai eficient cu cât reușește să colecteze mai multe date de la și despre cursant și să le folosească pentru a efectua o analiză a stării actuale a cunoștințelor sale.

Modulul de *Interfață*, cunoscut și sub denumirea de modulul de *Comunicare* sau modulul de Interfață Grafică cu utilizatorul, facilitează comunicarea dintre student și modulul de *Instruire*. Chiar și cu cele mai bune cunoștințe de predare și reprezentare a studenților, un tutore are o valoare limitată fără strategii de comunicare eficiente și, prin urmare, ar trebui să se depună o cantitate mare de muncă în dezvoltarea acestui modul (Woolf, 2010). În majoritatea cazurilor, modulul grafic este responsabil pentru furnizarea de lecții și ajutor în timpul învățării, rezultate și acțiuni pedagogice.

2.2 Dezvoltarea Psihomotorie în Sistemele Inteligente de Instruire

Domeniul psihomotric, denumit și psihomotor sau fizic, include mișcarea fizică, coordonarea și utilizarea zonelor de abilități motorii. Dezvoltarea abilităților în acest domeniu necesită practică, iar măsurătorile corespunzătoare ale performanței iau în considerare viteza, precizia, distanța, procedurile sau tehnicile de execuție.

O revizuire sistematică a literaturii de specialitate (Neagu, Rigaud, Travadel, Dascalu, & Rughinis, 2020) a fost efectuată în noiembrie 2019 asupra celor mai repute surse de date online pentru a evalua cantitatea și calitatea cercetărilor efectuate pentru a proiecta și dezvolta ITS-uri pentru formarea abilităților psihomotorii. Acest studiu a stat la baza experimentelor prezentate în continuare în această teză.

Metoda de identificare a tutorilor digitali existenți pentru dezvoltarea psihomotorie a implicat trei faze – Faza de identificare, Faza de definire a criteriilor de includere/excludere și Faza de evaluare a calității, așa cum se poate observa în Figura 2.

Interogarea de căutare aplicată pentru obținerea listei articolelor din bazele de date online este următoarea:

("Intelligent Tutoring System*" SAU "Intelligent Computer-Aided Instruction*" SAU "Intelligent Computer-Assisted Instruction*" SAU "Knowledge-Based Tutoring System*" SAU "Adaptive Tutoring System*" SAU "Computer-based Tutoring System*") ȘI (psycho-motor SAU psychomotor SAU "psycho motor" SAU physical)

Chiar dacă interogarea de mai sus a fost interogarea vizată pentru a fi aplicată tuturor surselor de date, au fost întâlnite diferite constrângeri în timpul utilizării fiecărui motor de căutare, cum ar fi

Sistemele Inteligente de Instruire și Antrenamentul Psihomotric

lungimea interogării furnizate a fost prea mare sau au fost aplicate prea multe măști (unde masca este considerată caracterul „*”).

Revizuirea literaturii de specialitate a fost efectuată în noiembrie 2019 folosind următoarele baze de date electronice internaționale: Scopus, Web of Science, ScienceDirect, IEEE Explore Digital Library, Springer, ACM și Journal of Education in Data Mining. Aceste surse de date sunt cele mai frecvente seturi online utilizate în cercetarea științifică (Dieste, Grimán, & Juristo, 2009).

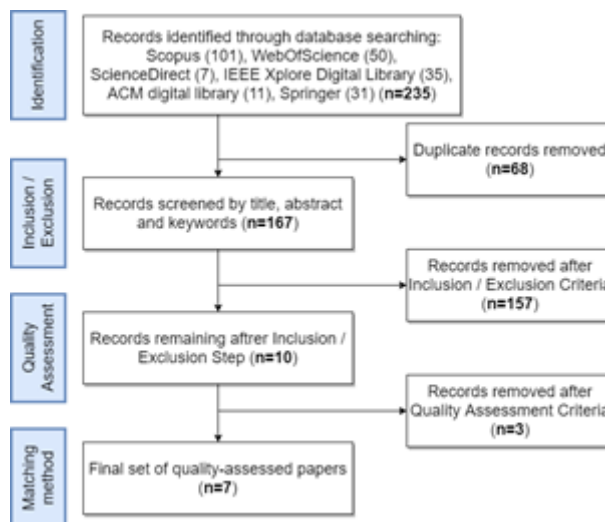


Figura 2. Revizuirea Sistematică a Literaturii - Prezentare Generală a Metodei

Procesul de revizuire a literaturii s-a concentrat pe găsirea unor lucrări adecvate cu cercetări originale pe diferite domenii în care ITS-urile au fost utilizate pentru antrenarea abilităților psihomotorii. Astfel, au fost elaborate următoarele criterii de includere: Lucrări complete și lucrări “peer-reviewed”; Lucrări cu cercetări empirice (calitative și cantitative); Lucrări care descriu arhitecturi sau variații ITS; și Lucrările explică clar domeniile domeniului psihomotric, unde a fost aplicat ITS.

Cercetările identificate, care sunt legate de antrenamentul psihomotor, variază de la foarte specifice (de exemplu, antrenament pentru tir, antrenament pentru trecerea mingii), până la activități mai ample (de exemplu, îmbunătățirea învățării motorii umane, antrenament de sarcini fizice). Lucrările care corespund criteriilor de includere/excludere au fost publicate la mai multe conferințe într-un interval de doisprezece ani, în timp ce majoritatea lucrărilor au fost publicate în ultimii doi ani.

Următorul pas a presupus citirea în detaliu a lucrărilor acceptate după filtrele de includere/excludere și evaluarea acestora. Verificarea a implicat dacă soluțiile prezintă vreun rezultat al arhitecturilor propuse și dacă au urmat taxonomii psihomotorii.

Sistemele Inteligente de Instruire și Antrenamentul Psihomotric

Din această trecere în revistă a literaturii, concluzionăm că, deși au fost dezvoltate inițial pentru formarea abilităților cognitive, ITS-urile au apărut și în pregătirea psihomotorie, cu utilizări în mai multe subdomenii, precum Medicină (Instruire în Chirurgie Laparoscopică, Radiologie), Militară (GIFT), Conducerea mașinilor (simulator de conducere adaptiv VR), sport (fotbal - antrenament de trecere a mingii, dans, reantrenare pentru sănătate) și proceduri manuale generice (TUMA).

2.3 Provocări în Domeniul Digitalizării Psihomotorii

Modelarea cunoștințelor. Una dintre cele mai dificile provocări la construirea ITS-urilor este crearea unei baze de cunoștințe puternice de la zero (Zouaq & Nkambou, 2010). Sarcinile de reprezentare a cunoștințelor, tehnicile de achiziție a cunoștințelor și modelarea eficientă a tutoratului necesită cercetări acute în domeniu.

Periodizarea antrenamentului sportiv este considerată un domeniu la început. Prima lucrare de cercetare privind descrierea regulilor de antrenament a fost realizată în urmă cu 5 ani de către Bompă (2017). Anterior, nu existau standarde clare pentru efectuarea antrenamentului sportiv și a periodizării, iar diferiți antrenori sportivi utilizau terminologii diferite atunci când se refereau la subiecte specifice.

Ontologiile sunt un candidat puternic pentru construirea cunoștințelor în sistemele inteligente de instruire și adaptările unor astfel de sisteme. După cum au afirmat Neagu, Guarnieri, et al. (2020), nu a fost dezvoltată o ontologie anterioară în domeniul psihomotric; lucrările existente se concentrează pe recunoașterea activităților sportive cu tehnologie sau sprijină luarea deciziilor pe baza datelor culese în timpul competițiilor sportive.

Strategii Inteligente de Instruire. Modulul de instruire al unui ITS este responsabil să aleagă secvențele optime de învățare pentru a oferi o experiență de învățare bună, bazată pe estimarea nivelurilor de competență și a evoluției elevilor, și puține cunoștințe despre modelele cognitive și ale studentului (Clement et al., 2015). Aceleași principii sunt aplicate și în domeniul psihomotric. Literatura de specialitate arată că pentru a învăța să conduci, Ropelato, Zund, Magnenat, Menozzi, and Sumner (2018) au creat un mediu de realitate virtuală în care cursanții primesc secvențe optime bazate pe algoritmul Zonei de dezvoltare proximală și succes empiric (ZPDES).

Instruirea tragerii cu pușca se concentrează pe învățarea elementelor funcționale și de bază pentru operarea eficientă a armei, iar instrucțiunile sunt axate pe lovirea constantă a țintelor statice la distanțe fixe (Goldberg, Amburn, Ragusa, & Chen, 2018). În mediul controlat, componentele antrenamentului: stabilitate, țintire, control și mișcare, sunt urmărite de tutore folosind tehnologii

Sistemele Inteligente de Instruire și Antrenamentul Psihomotric

de detectare. Modelul de personalizare a secvenței de antrenament a cursanților urmărește parametri precum poziția corpului, respirația, strângerea declanșatorului și clătinarea țevei puștii în timpul antrenamentului, dar algoritmi implementați pentru ajustarea personalizată a secvențelor nu au fost descriși în mod clar.

O mare provocare în instruirea în medii deschise este cauzată de lipsa informațiilor corecte ale cursanților în timpul antrenamentului. De asemenea, resursele de timp sunt limitate pentru cursanți, un cursant nu poate testa toate activitățile de instruire sau toate secvențele existente de instruire. Un tutor bazat pe reguli se poate dovedi inefficient atât în domeniul cognitiv, cât și în cel psihomotor. O secvență de învățare care este optimă pentru un cursant poate fi inefficientă pentru altul (Clement et al., 2015). Construirea unui tutor psihomotric într-un mediu deschis este o sarcină provocatoare, deoarece date minime despre cursant ar trebui să fie obținute în timpul antrenamentului, îndrumarea se bazează pe contribuția cursantului, datele parțial dobândite din mediu și cu prudență la sănătatea cursantului – noi secvențe generate de tutorele adaptativ ar trebui să protejeze cursantul de răni, probleme medicale sau epuizare fizică. Pe de altă parte, elevul ar trebui să fie implicat în învățare și să mențină motivația pe termen lung pentru formare. Învățarea ar trebui să fie furnizată în zona de dezvoltare proximă a stagiului.

Interacțiunea cu Atelul. Un tutor poate avea cele mai bune cunoștințe legate de elev și de predare, dar fără o componentă de interfață eficientă pentru a interacționa cu cursantul, aceasta va limita valoarea tutorelui (Woolf, 2010). Interfețele de utilizator ar trebui să fie clare și simple, atractive și rapide. Pe baza acestor considerații, construirea unui modul de comunicare adecvat implică, de obicei, un efort mare. Un tutor uman detectează cu ușurință reacțiile elevilor în sala de clasă, poate detecta cu ușurință problemele și oferă feedback și remediere. Tutorul tradițional poate urmări concentrarea atenției cursanților în timpul orelor, nivelul de oboseală și motivația. Clasificarea tipurilor de comunicare între tutori și cursanți în cadrul unui ITS include comunicarea grafică, inteligența socială, interfețele tip-componente și tehnicile limbajului natural (Woolf, 2010).

Într-un mediu deschis, interacțiunea cu elevul se dovedește a fi mai provocatoare decât în mediile închise, complet supravegheate. Configurația de pregătire a cursanților este necunoscută, iar evaluarea este greu de realizat. Pentru învățarea abilităților psihomotorii, elevul are nevoie de îndrumări pentru execuție, care pot fi în format video, imagine sau scris și feedback vocal sau vizual. De asemenea, evaluarea se poate dovedi critică atât pentru urmărirea progresului cursantului, cât și pentru evitarea riscului de rănire. Cu cât sistemul adună mai multe date, cu atât evaluarea și personalizarea ar trebui să fie mai bune.

Sistemele Inteligente de Instruire și Antrenamentul Psihomotric

Datele folosite pentru a măsura impactul antrenamentului, cum ar fi ritmul cardiac, caloriiile arse sau calitatea somnului, și care pot fi adunate cu precizie prin intermediul dispozitivelor IoT (ceasuri inteligente, benzi inteligente) nu ar trebui să fie obligatorii, ci doar să îmbunătățească modelul, dar nu ar trebui să se bazeze pe ele. Comunicarea dintre sistem și cursant trebuie să fie eficientă și simplă, cursantul nu ar trebui să fie forțat să fie legat de sistem în timpul antrenamentului. Proiectarea unui astfel de sistem este o provocare care, din constatările noastre, nu a fost abordată în literatură.

Revizuirea literaturii de specialitate a arătat un interes din ce în ce mai mare al comunităților de cercetare în proiectarea și dezvoltarea de tutori inteligenți pentru pregătirea psihomotorie. Cercetătorii au introdus în ultimii ani sisteme în mai multe subdomenii psihomotorii, inclusiv antrenamentul de pasare a mingii, domeniul medical (pentru intervenții chirurgicale), conducere auto sau militar (antrenament de tir). Scopul nostru este să construim un instructor automat psihomotor pentru atletism și să oferim sesiuni de antrenament sportiv optime pentru cursanții începători și intermediari.

3 Modele ale Procesului de Cunoaștere și de Învățare

3.1 Teoriile Învățării

Fiecare profesor de școală are o filozofie educațională, un set de idei și ipoteze declarate sau nedecarate despre cum să predea cel mai bine (Woolf, 2010). Pe de o parte, unii profesori văd responsabilitatea principală a meseriei lor de a oferi informații elevilor și apoi de a identifica cine a învățat. Ei sunt priviți ca tradiționaliști în filozofia de predare (Becker, 2000). Instructorul este sursa informată, iar studentul este novice, dornic să asculte și să învețe. Pe de altă parte, există profesorii moderni care sunt responsabili pentru crearea experiențelor pentru elevi.

ITS-urile sunt un tip particular de sistem inteligent de sprijinire a învățării, ale cărui componente reflectă valorile privind natura cunoașterii, învățării și predării (Self & Akhras, 2002). Arhitectura se concentrează pe reprezentarea cunoștințelor de învățat (modelul *Domeniului*), deducerea cunoștințelor cursantului (modelul *Studentului*) și planificarea pașilor de instruire pentru cursant (modelul de *Instruire*). Arhitectura ITS se potrivește cu filozofia tradițională de predare. Cu toate acestea, pentru teoria constructivistă, Self and Akhras (2002) contestă arhitectura clasică ITS, viziunea constructivistă subliniază diferite valori în nucleul său și, potențial, necesită o arhitectură diferită. Autorii au propus o nouă abordare a construirii ITS-urilor în care, în centrul procesului de învățare, există interacțiuni între cursanți și tutori. Ei își prezintă noua arhitectură cu două aplicații: SAMPLE – ITS pentru a sprijini învățarea conceptelor de preparare a salatei și INCENSE – ITS pentru învățarea ingineriei software. Chiar dacă explică pe scurt proiectarea sistemelor, nu a fost prezentată nicio validare pentru niciunul dintre ele.

Domeniul Inteligenței Artificiale în Educație își propune să folosească inteligența pentru a raționa despre predare și învățare. Aceasta nu este o sarcină simplă, deoarece a ști ce, când și cum să predai implică echipe multidisciplinare, din mai multe discipline, cum ar fi psihologia, educația și informatica.

3.2 Modelarea Cunoștințelor și a Predării

Tehnicile obișnuite pentru generarea modelelor de învățare includ rețele Bayesiene, rețele bazate pe încredere, raționament bazat pe caz (CBR) și maximizarea așteptărilor. Modelele de învățare pot fi clasificate după modul lor de funcționare (Sottolare, Graesser, Hu, & Holden, 2013). Ele sunt clasificate drept corective, elaborative, strategice, diagnostice, predictive sau evaluative.

Modele ale Procesului de Cunoaștere și de Învățare

Multe dezvoltări ITS consideră modelul *Student* ca o suprapunere sau un subset al modelului de *Domeniu* (Ma, Adesope, Nesbit, & Liu, 2014). Întrucât ITS urmărește să predea domeniul sau o parte a domeniului, munca inițială, înainte de a reprezenta cunoștințele studenților, ar trebui să fie definiția modelului de *Domeniu*. Într-un ITS tradițional, reprezentarea cunoștințelor de domeniu a fost implementată prin a) modele tip cutie-neagră (din eng. “black-box”), în care raționamentul nu este explicat clar, dar soluțiile sunt corecte; și b) modele de cutii de sticlă, unde raționamentul este explicat pas cu pas (Polson & Richardson, 1988).

Există două tipuri de cunoștințe în ambele modele: a) declarative, care sunt informații conceptuale; și b) procedurale, pentru secvențe de acțiuni și proceduri de rezolvare a problemelor. Scopul acestor reprezentări este de a se asigura că modulul de *Instruire* are acces la cunoștințe structurate și secvențe de învățare adecvate (Zouaq & Nkambou, 2010). Mai multe formalisme de reprezentare au fost propuse și utilizate în mod tradițional în ITS, cum ar fi reguli simple, raționament bazat pe cazuri, logica fuzzy, hărți conceptuale, hărți de topicuri sau grafice conceptuale (Zouaq & Nkambou, 2010).

O ontologie de domeniu este o alternativă puternică pentru reprezentarea cunoștințelor la construirea ITS-urilor pentru formalismul lor standard, ușurința de reutilizare a altor ontologii și modularitate. Proiectanții de sistem trebuie să integreze diferite ontologii pentru a impune reutilizarea și interconectarea diferitelor resurse relevante. O ontologie este un vocabular comun și o reprezentare a cunoștințelor utilizate pentru modelarea unui domeniu; ontologiile definesc descrieri explicite ale conceptelor și relațiilor lor și integrează semantica procesabilă de computer pentru datele de pe Web (Fensel, 2001).

O problemă acută de cercetare atunci când se dezvoltă un ITS este modul în care modulul de *Instruire* poate fi modelat eficient (Zouaq & Nkambou, 2010), ce fel de reprezentări ale cunoștințelor sunt disponibile și ce fel de tehnici de achiziție de cunoștințe pot fi aplicate. Tutorul trebuie să aibă o reprezentare explicită a cunoștințelor domeniului care face obiectul scopului de învățare.

Revizuirea amplă a literaturii arată că abordarea de urmărire a modelului/tutor cognitiv a fost folosită cel mai mult (21,21%), apoi urmărirea exemplilor (18,18%), bazată pe conținut și probleme (12,12%), bazată pe dialog (9,09%), bazate pe constrângeri (6,06%), pe mașini și pe oameni (6,06%), în timp ce celelalte nu au fost descrise clar sau nespecifice (27,27%). Studiile au inclus STI-uri prezentate fie ca scenariu ilustrativ (39,39%), experimente controlate (27,27%), studii de caz (15,15%), sondaj (3,03%) sau altele (15,15%).

Tutorii de tip urmărire a exemplilor (example-tracing tutors) sunt responsabili să interpreteze și să evalueze comportamentul elevului cu privire la exemplele generalizate de comportament de rezolvare

a problemelor (Alevan, McLaren, Sewall, & Koedinger, 2009). Această paradigmă a fost propusă de Alevan acum 13 ani și a fost adoptată foarte repede; 18% dintre studiile selectate în revizuirea literaturii au folosit exemplul de urmărire ca strategie de instruire. Această strategie permite experților și specialiștilor din domeniu să construiască un model cognitiv prin demonstrație, mai degrabă decât prin programarea unui model de reguli, reducând costurile de dezvoltare per total.

Strategia de predare tip ucenicie implică că expertul nu se angajează într-un mentorat explicit. Este prima strategie modelată direct pe mentorul fizic, real, în care elevul dobândește, dezvoltă și folosește instrumente cognitive autentice în învățare, atât în afara școlii, cât și în interiorul școlii (Brown, Collins, & Duguid 1989). Sistemul de instruire de tip ucenicie este responsabil să monitorizeze performanța elevilor, reflectând asupra abordărilor studenților, poate oferi sfaturi la cerere, iar calea către soluții ar trebui modelată prin mai multe căi. Instruirea tip ucenicie este uzuală în studiul de: cum să cânti la un instrument, antrenamentul pentru atletism sau învățarea să conduci. Pe baza strategiilor de predare și a abilităților dezvoltate în sistemele de mentorat existente construite folosind această abordare, predarea de tip ucenicie este unul dintre cei mai importanți candidați pentru dezvoltarea tutorilor psihomotorii.

Un sistem de instruire inteligent are o utilizare limitată dacă componenta de comunicare nu implementează strategii eficiente. Modelarea comunicării este un proces laborios. Interacțiunea profesor-învățător ar trebui să fie simplă, clară și eficientă. Au fost implementate mai multe tehnici pentru modelarea comunicării, inclusiv tutori animați, realitatea virtuală, recunoașterea vizuală a emoțiilor și procesarea limbajului natural.

Un modul eficient de comunicare al tutorelui automat îi face pe cursanți să se simtă autentici și sociali, implicând schimbul reciproc de informații cu sistemul. Tutorii inteligenți pot compune explicații, fie verbale, fie textuale, pentru a critica sau a menține un dialog cu cursantul prin tehnici de limbaj natural. Clasificarea modelării comunicării realizată de Woolf et al (Woolf, 2010) include 4 categorii principale: comunicare grafică, inteligență socială, interfețe de tip componente și comunicare în limbaj natural.

3.3 Principiile Evaluării Modelelor

Evaluarea este considerată procesul prin care datele relevante sunt colectate și transformate în informații semnificative utilizate pentru luarea deciziilor, conform unor scopuri specifice (Mark & Greer, 1993). Evaluarea este diferită între domenii. Evaluarea sistemelor inteligente de instruire

Modele ale Procesului de Cunoaștere și de Învățare

implică atât eficacitatea rezultatelor învățării, cât și utilizarea software-ului, dar și alți parametri de evaluare, cum ar fi experiența utilizatorului sau contribuția la teoria învățării.

O analiză sistematică recentă a literaturii despre metodele de evaluare utilizate în ITS (Mousavinasab et al., 2018) arată că evaluarea implică în principal măsurarea performanței sistemului, a performanței cursanților și a experiențelor de învățare. Majoritatea studiilor au fost utilizate în învățarea informaticii (55%), apoi în domeniul medical (15,09%), urmată de matematică (15,09%). Accentul în ITS-urile de sănătate/medicale este, de asemenea, în domeniul cognitiv, pentru cazuri de utilizare în educația teoretică, cum ar fi anatomie, boli ale copilăriei, fiziologie sau raționament clinic.

Procesul de evaluare include următoarele categorii: pre-test, intervenție, post-test, post-test întârziat, serii de timp întrerupte, crossover și parțial crossover. Pre-testul măsoară nivelul de cunoștințe al cursanților înainte de a începe experimentul. În plus, ar putea evalua caracteristicile elevilor, cum ar fi stilul de învățare sau motivația, pentru a ajuta la alocarea subiecților pe grupuri. Acest lucru poate fi necesar pentru o distribuție uniformă între grupuri. Intervenția tutorului este implicarea tutorelui în procesul de învățare cu obiective specifice de predare. Post-testul este efectuat la sfârșitul experimentului pentru a măsura cunoștințele dobândite ale cursanților. Un exemplu de proiect de evaluare cu pre-test și post-test poate fi văzut în Figura 3.a. Post-testul întârziat este utilizat în proiectarea evaluării pentru a măsura efectele pe termen lung ale învățării. Configurația de evaluare cu teste pre, post și întârziate poate fi vizualizată în Figura 3.b. Problema cu aceste abordări este că ele nu urmăresc momentele în care are loc învățarea, când cursanții își îmbunătățesc abilitățile și care sunt rădăcinile învățării – vezi Figura 3.c.

Evaluare tip serie temporală întreruptă implică măsurarea rezultatelor învățării prin post-teste repetate, care vor permite evaluarea diferențelor de învățare – vezi Figura 3.d. Chiar dacă există avantaje mari ale acestei metode, este foarte consumatoare de timp și implică mai multă muncă pentru a fi activată. Metoda crossover (Figura 3.e) presupune o configurație mai grea – patru grupuri de studenți, două forme de intervenție (care pot fi tutori inteligenți și sala de clasă tradițională) și două versiuni ale aceluiași test (testul A și testul B). Grupurile primesc mai întâi un tip de intervenție și efectuează mai întâi pre-testul A și apoi post-testul A. Apoi, intervenția grupului este comutată, efectuează pre-testul B și apoi post-testul B. Această metodă poate evalua efectele diferitelor metode de predare asupra populației selectate. Dezavantajele acestei metode sunt configurarea complicată și complexitatea celor patru condiții experimentale. Metoda încrucișării parțiale (Figura 3.f) este o simplificare a metodei încrucișării, cu doar două grupuri, dar urmând aceleași reguli.

Modele ale Procesului de Cunoaștere și de Învățare

Planificarea evaluării poate fi realizată pentru configurarea în lumea reală sau în laborator. Experimentele din lumea reală sunt preferabile mediilor de laborator, deoarece măresc argumentarea eficienței tutorelui. Dacă ipoteza făcută este valabilă pentru o populație și poate fi apoi extrapolată în lumea exterioară, înseamnă că evaluarea are validitate externă.

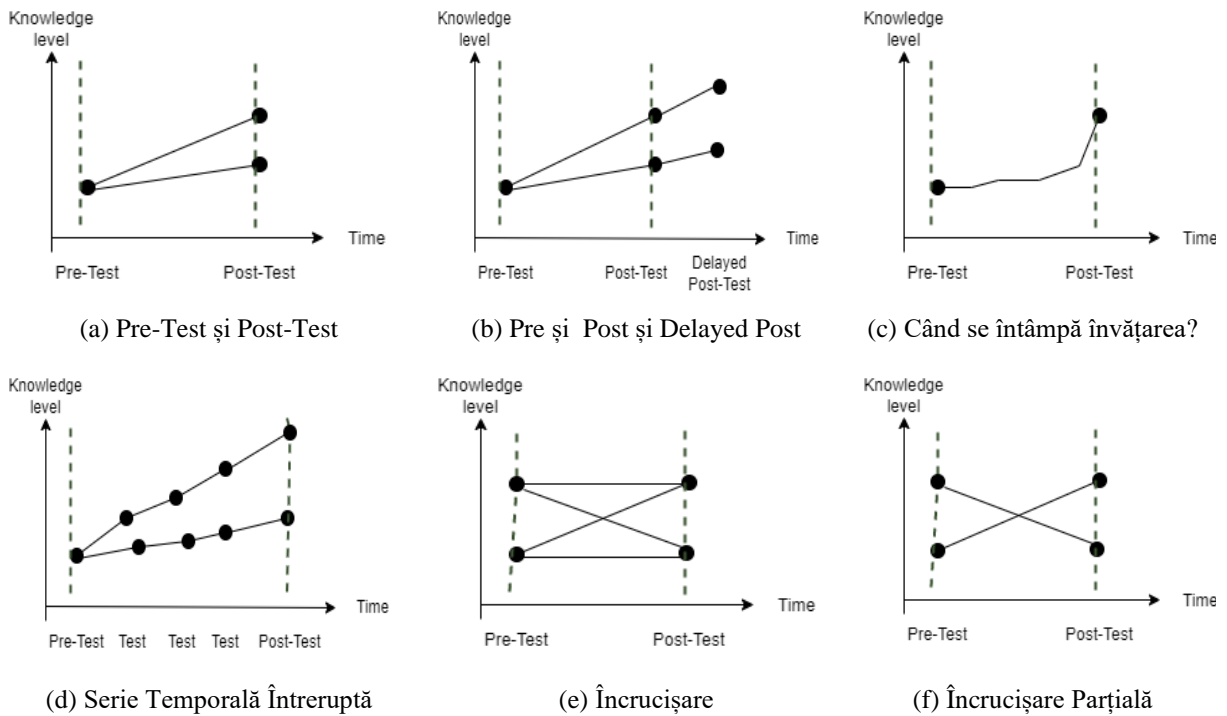


Figura 3. Scheme de Proiectare ale Evaluării

Eficiența evaluării trebuie efectuată folosind standarde (din eng. benchmarks). Woolf (Woolf, 2010) a propus șase exemple de comparații de evaluare, cu modelele de prototipare asociate, adaptate din teoriile designului de evaluare, care sunt rezumate în Tabel 1.

Tabel 1. Exemple Comparative de Evaluare (Woolf, 2010)

Tipuri de Evaluare	Metode de Evaluare
Tutore singur	Intervenție + Post-test
Tutor versus control non-intervențional	Pre-test + Intervenție + Post-test
Tutor versus clasă tradițională	Pre-test + Intervenție + Post-test + Post-test Întârziat
În interiorul sistemului: Tutore 1 versus Tutore 2	Serie Temporală Întreruptă
Tutore versus Tutore Incomplet	Încrucșare
Între sisteme: Tutore A versus Tutore B	Încrucșare Parțială

A patra fază a evaluării tutorelui este instanțierea procesului evaluării. Fazele anterioare au vizat crearea scheletului evaluării. Scopul acestei faze este de a descrie detaliile experimentului: definirea variabilelor dependente și independente, numărul de participanți, tipul de participanți, descrierea detaliată și justificarea grupurilor de control și utilizarea software-ului.

4 Sisteme Inteligente de Instruire în Medii Deschise. Învățare Automată în Practică

4.1 Prezentare Generală a Tehnicilor de Predare pentru Tutori Inteligenți

Într-un sistem de instruire inteligent, experiența poate fi obținută prin stocarea datelor istorice de îndrumare și utilizarea lor ca intrare de instruire pentru modelul de învățare automată (Dlamini & Leung, 2018). Învățarea de-a lungul timpului se numește învățare automată incrementală și aceasta poate fi realizată prin mai multe tehnici, care vor fi descrise pe scurt în continuare. Principalele beneficii ale tutorilor adaptabili sunt creșterea flexibilității tutorelui, costul redus de construire a tutorelui și adaptarea la noile populații de studenți (Woolf, 2010).

O analiză recentă a literaturii despre sistemele inteligente de tutorare care au implementat tehnici de învățare automată pentru diferite obiective a găsit 53 de studii relevante între 2007 și 2017, toate vizează dezvoltarea cognitivă (Mousavinasab et al., 2018). Revizuirea a inclus studii în educație, formare sau instrumente de asistență educațională, care au demonstrat utilizarea arhitecturii ITS în sistemele lor. Domeniul educațional major găsit în recenzie a fost programarea computerelor, cu o frecvență de 55%, urmată de domeniile medicale și matematice.

Analiza a găsit mai multe obiective pentru utilizarea tehnicilor de învățare automată în sistemul propus, de la modelarea adaptivă a tutorelui (feedback adaptiv, sugestii, calea de învățare), modelarea adaptivă a elevilor (definirea, clasificarea caracteristicilor cursantului) și modelarea adaptivă a domeniului. Lista detaliată a scopurilor tehnicilor de învățare automată cu frecvența asociată, găsită în analiza recentă, poate fi văzută Tabel 2.

Tabel 2. Scopul aplicării tehnicilor de învățare automată în ITS-uri în perioada 2007-2017 (Mousavinasab et al., 2018)

Tehnici ce Învățare Automata	Frecvență (%)
Definirea, clasificarea sau actualizarea caracteristicilor cursantului	56.60 %
Generare de feedback adaptiv, indicii sau recomandări	52.83 %
Evaluarea elevului	45.28 %
Prezentarea materialelor sau conținutului de învățare adaptiv	41.50 %
Navigare adaptivă în calea de învățare	28.30 %
Prezentarea de teste și exerciții adaptive	5.66 %

ITS-urile folosite pentru învățarea informaticii identificate în revizuirea literaturii de specialitate au folosit mai mulți algoritmi de învățare automată pentru a adapta instruirea: tehnici bazate pe fuzzy

(20%), raționament bazat pe reguli condiție-acțiune (20%), raționament bazat pe cazuri (13,33%), raționament multiplu inteligent. agent (13,33%) și data mining (13,33%). ITS de sănătate găsite în revizuire au folosit următorii algoritmi de învățare automată: tehnici bazate pe bayesian (50%), abordări bazate pe NLP și multi-agent inteligent. În matematică, majoritatea ITS-urilor au implementat raționamentul bazat pe reguli condiție-acțiune.

Progresele recente în tutoratul adaptiv se concentrează pe găsirea activităților care oferă cea mai bună experiență de învățare fiecărui cursant, pe baza unei estimări a nivelurilor de competență și a progresului elevilor și cu puține cunoștințe despre modelele cognitive și ale elevilor (Clement et al., 2015). Acest design se bazează pe următoarele principii:

- Dependență mai slabă de modelul cognitiv și studentesc.
- Metode eficiente de optimizare.
- Experiență mai motivantă.

Dezvoltarea unor astfel de tutori se bazează pe utilizarea algoritmilor de multi-armed bandits în modelarea tutorelor (Clement et al., 2015). Multi-armed bandits abordează o problemă în care un set limitat de resurse trebuie alocat între opțiuni într-un mod care maximizează câștigul așteptat. Proprietățile alegerii sunt cunoscute doar parțial în momentul în care este aleasă și devine mai bine înțeleasă pe măsură ce trece timpul. Algoritmii multi-armed bandits este o problemă clasică de învățare prin întărire care exemplifică problema compromisului de explorare-exploatare. În continuare, sunt enumerate tehnici comune pentru construirea de tutori inteligenți cu algoritmi de reinforcement learning.

Reinforcement Learning (sau RL) este una dintre cele mai bune abordări de învățare automată pentru luarea deciziilor în medii interactive, iar algoritmi RL sunt proiectați pentru a deduce politici eficiente care determină cea mai bună acțiune pe care o poate lua un agent în orice situație dată pentru a maximiza recompensa cumulativă (Ausin, Azizoltani, Barnes, & Chi, 2019).

Patru elemente de bază caracterizează definiția unei probleme de reinforcement learning: agentul, mediul, politica și funcția de recompensă. Mediul este definit ca sistemul extern în care agentul, care în acest caz este cel care învață, există, face acțiuni și trece de la o stare la alta. Agentul poate descrie un comportament de succes pe termen lung prin recompense, care sunt oferite la sfârșitul fiecărei acțiuni întreprinse. În cele mai multe cazuri, recompensa este o valoare scalară care este maximizată de agent și poate reprezenta gradul în care o acțiune sau o stare atinsă este de dorit. Funcția de recompensă definește scopul unei probleme RL (Woolf, 2010). Funcția mapează starea de acțiune a

mediului a fiecărei perechi la un număr, pozitiv sau negativ, numit recompensă, care indică dezirabilitatea acelei perechi. Politica este definită ca felul în care agentul se comportă la un moment dat. În unele cazuri, poate fi o funcție simplă sau un tabel de căutare, care verifică stările anterioare și acțiunile întreprinse în acele stări.

Există două categorii majore de algoritmi RL – online și offline. Metodele RL online învață politica în timp ce agentul interacționează cu mediul. În abordarea offline, politica este învățată dintr-un set de date de instruire precolectat (Ausin et al., 2019). RL online este mai potrivit pentru domeniile în care reprezentarea stării este clară, iar interacțiunea cu mediul simulat și mediul real este ieftină și fezabilă din punct de vedere computațional. RL offline este necesar pentru domenii mai complexe, cum ar fi e-learning, unde problema învățării umane este complexă, iar procesul nu este pe deplin înțeles.

O clasă specifică de probleme în domeniul reinforcement learning, într-un cadru simplificat, care implică învățarea cum să acționezi într-o singură situație este problema banditului cu mai multe brațe sau problema banditului k-armate. Problema bandiților multi-armate se întâlnește atunci când te confrunți în mod repetat cu o alegere între k opțiuni diferite, care pot fi definite ca acțiuni (Sutton & Barto, 2018). După fiecare acțiune, se acordă o recompensă numerică dintr-o distribuție de probabilitate staționară care depinde de alegerea selectată. Scopul este de a maximiza recompensa cumulativă într-o perioadă.

Dacă valorile per acțiune sunt cunoscute, problema este banală – veți selecta întotdeauna acțiunea care are cea mai mare recompensă. La un anumit pas, veți cunoaște recompensele pentru un set de acțiuni care au fost selectate anterior. O posibilă alegere viitoare ar fi să o alegem pe cea cu cea mai mare valoare, dintre acțiunile cunoscute. Aceasta se numește acțiune lacomă (*greedy action*), iar alegerea unei acțiuni pe care o cunoașteți deja se numește exploatarea cunoștințelor actuale. Exploatarea este ceea ce trebuie făcut pentru a maximiza recompensa într-un singur pas, dar explorarea – a unor noi alegeri, încă necunoscute – poate produce o recompensă totală mai mare pe termen lung.

Abordarea ϵ -Greedy forțează acțiunile non-lacome (non-greedy) să fie încercate, în cadrul factorului ϵ , dar fără discriminare, fără preferință pentru acțiunile care sunt aproape lacome sau deosebit de incerte. Aici este cazul în care abordarea Upper-Confidence-Bound poate fi mai eficientă. Este mai bine să selectați dintre acțiunile care nu sunt lacome în funcție de potențialul lor de a fi efectiv optime, în funcție de cât de aproape sunt estimările lor de a fi maxime și de incertitudinea din estimări (Sutton & Barto, 2018). În termeni mai simpli, acțiunile cu o valoare estimată mai mică

sau acțiunile care au fost selectate de multe ori vor fi mai puțin selectate de bandit. Cu cât banditul este mai incert cu privire la un anumit braț, cu atât sunt mai mari șansele să fie selectat. UCB nu este potrivit pentru probleme nestaționare sau probleme care au un spațiu mare de stare.

Într-o arhitectură ITS clasică, modulul de tutorat folosește o estimare a nivelurilor de competență și a progresului stagiului pentru a alege activitățile care oferă cea mai bună experiență de învățare la un anumit moment. Provocarea cu care se confruntă tutorele este să găsească care este secvența optimă de activități care maximizează nivelul mediu de competență, pentru toate abilitățile vizate (Clement et al., 2015). Această provocare este determinată de trei factori principali, care au fost abordați de Clement (Clement et al., 2015):

- Timp limitat pentru exersarea activităților – tutorul nu poate testa toate combinațiile de secvențe, nici toate activitățile;
- Gestionarea motivației este dificilă – elevii vor învăța eficient doar dacă sunt implicați în activități;
- Diferențele individuale dintre cursanți fac ca o secvență optimă pentru un anumit cursant să fie ineficientă pentru altul.

Clement (Clement et al., 2015) au propus o abordare a multi-armed bandits, utilizată împreună cu Zona de Dezvoltare Proximală. ZPD a fost definit de un expert, componentele cunoștințelor sunt în domeniul matematicii, mai precis descompunerea numerelor. ZPD va fi ajustat pe baza algoritmilor de optimizare, pe baza răspunsurilor, și a progresului de învățare al elevilor. Rezultatele obținute cu ajutorul algoritmilor de tip multi-armed bandits sunt comparabile și chiar depășesc, în anumite condiții, secvențele create de profesori experți.

4.2 Tehnici de Învățare Automată în Dezvoltarea Psihomotorie

Literatura și metodele legate de ITS-urile adaptive sunt vaste și, în această secțiune, accentul este pus pe implementările legate de sarcinile non-cognitive, și anume, abilitățile psihomotorii.

Individualizarea antrenamentului este condiția principală pentru optimizarea acestuia. Literatura de antrenament sportiv expune metodele clasice de individualizare, folosite de antrenori, cum ar fi „modelul maestrului” – un cadru teoretic care utilizează volumul și intensitatea antrenamentului pentru a calcula sarcina, sau prin antrenament real – calculând valorile medii ale mijloace de antrenament realizate într-un ciclu dat de către un grup de sportivi (Rygula, 2005). Punctele slabe ale acestor demersuri sunt lipsa individualizării, prin utilizarea tabelor de standarde, și imposibilitatea de a genera noi conținuturi de instruire, din cel existent.

Într-o revizuire recentă a literaturii despre metodele inteligente de analiză a datelor pentru antrenament sportiv inteligent (Rajšp & Fister, 2020), autorii contestă modul în care tehnologia modernă revoluționează modul în care sportivii își maximizează performanța și concurează la un nivel mai înalt decât oricând înainte. Ei definesc antrenamentul sportiv ca un proces pedagogic în care rolul antrenorului este unul de profesor și organizator, îndrumarea activităților sportivului și organizarea sesiunilor de antrenament. Exercițiile sunt definite ca sarcini care necesită efort fizic și ar trebui într-un fel să îmbunătățească rezultatele sportive ale cursantului. Ele despart procesul de planificare a sportului în patru faze: planificare (prescrierea unităților de exerciții adecvate), realizarea (faza de execuție), controlul (comparația între exercițiile efectuate de sportiv față de exercițiile planificate) și evaluarea (măsurarea performanței sportivului). Fazele sunt interconectate și au o tranziție continuă, așa cum se poate observa în Figura 4.

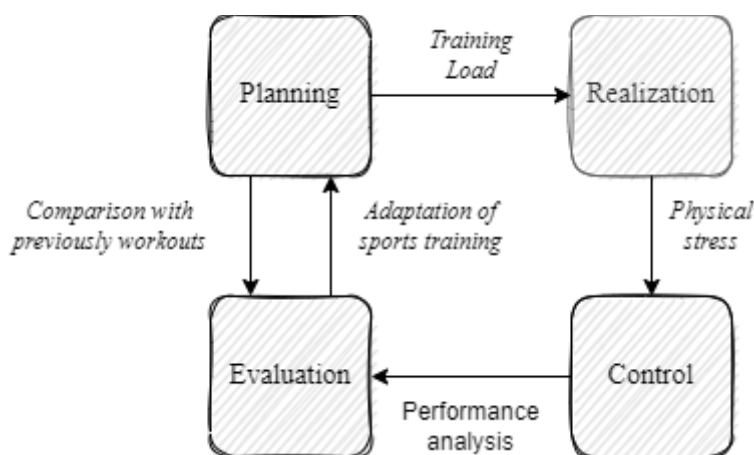


Figura 4. Cele patru faze ale planificării sportive.

Analiza literaturii de specialitate arată că domeniul antrenamentului sportiv inteligent a crescut în popularitate în ultimii 5 ani, începând cu 2016, unde studiile găsite au fost grupate într-o taxonomie împărțită în patru grupuri principale.:

- Metode de Inteligență Computațională
- Exploatarea Datelor (Data Mining)
- Deep Learning
- Altele (Case-Based Reasoning, Dynamic Time Warping, Bayesian Networks, Naïve Bayes, Markov chain, generalized additive models, Gaussian process, Linear Regression, regularized logistic regression, linear discriminant analysis, spline interpolation)

5 OntoStrength – Un Cadru de Reprezentare și Deducere a Cunoștințelor în Sisteme de Instruire Inteligente Psihomotorii

5.1 Metodologia de Proiectare a OntoStrength

Ontologia OntoStrength își propune să sprijine dezvoltarea unui ITS psihomotoriu dedicat îmbunătățirii abilităților psihomotorii și abilităților bio-motorii asociate, cum ar fi forța. O echipă multidisciplinară formată din informaticieni și oameni de știință din sport a dezvoltat OntoStrength. Metodologia Ontology 101, cunoscută și sub numele de OD101, (Noy & McGuinness, 2001) a fost folosită pentru a dezvolta ontologia.

Am folosit software-ul Protégé pentru a edita și rafina clase, relații, sloturi și fațete. GraphDB a fost considerată baza de date cu grafice semantice pentru stocarea și interogarea ontologiei, precum și pentru generarea de diagrame de date interactive. Limbajul de interogare SPARQL (Prud'hommeaux & Seaborne, 2008) a fost folosit pentru a testa diferite scenarii de antrenament prin interogări.

Dezvoltarea forței este domeniul acoperit de OntoStrength. Forța este definită ca forța maximă sau cuplul (forța de rotație) pe care o poate genera un mușchi sau un grup muscular sau ca capacitatea sistemului neuromuscular de a produce forță împotriva unei rezistențe externe (Bompa, 2017).

În primul rând, OntoStrength sprijină modulul domeniului ITS oferind cursuri care descriu diversitatea abilităților de forță. În al doilea rând, cursurile despre procesele de dezvoltare a forței sprijină modulul de îndrumare. În cele din urmă, OntoStrength sprijină modulul de studenți ITS cu cunoștințe despre diferitele caracteristici individuale de luat în considerare pentru personalizarea sarcinilor programului de forță. Primul subdomeniu OntoStrength își propune să descrie abilitățile de forță. Modulul de domeniu folosește abilitățile de forță pentru a oferi obiective de dezvoltare, modulul de student îl folosește pentru a proiecta o amprentă de putere a elevului, în timp ce modulul de tutorare generează și monitorizează antrenamentele de antrenament ca intrare.

Prin urmare, o abilitate de forță combină o abilitate de mișcare și un tip de forță în ontologia OntoStrength. OntoStrength ia în considerare patru tipuri de mișcare: musculară, funcțională, fundamentală și specializată. Primele două mișcări susțin abilitățile generale de forță. Musculară descrie diferitele tipuri de contracții posibile pentru fiecare mușchi implicat în mișcarea corpului uman. OntoStrength descrie douăzeci și patru de mușchi și patru moduri de contracție: excentric,

OntoStrength – Un Cadru de Reprezentare și Deducere a Cunoștințelor în Sisteme de Instruire Inteligente Psihomotorii

concentric, izometric și pliometric. *Funcțional* este legat de acțiunile efectuate de articulațiile corpului uman în timpul mișcării.

Subdomeniul abilități de forță OntoStrength include trei ierarhii de clase care pot fi utilizate pentru a descrie abilități precum „Forța maximă excentrică a bicepsului”, „Rezistența forței de flexie a șoldului”, „Forța maximă de aruncare” sau „Puterea de fandare”. Clasele folosite pentru a reprezenta principalele concepte ale acestui domeniu sunt următoarele: „Abilitatea Forță”, „Abilitatea de Mișcare” și „Proprietatea Forței”.

Al doilea subdomeniu OntoStrength acceptă descrierea unui program de dezvoltare a puterii. Modulul de domeniu pentru un ITS psihomotric poate folosi aceste cunoștințe pentru a oferi conținut relevant pentru a genera și programa antrenamente de antrenament. Modulul *Student* folosește aceste cunoștințe pentru a actualiza componentele de formare a elevilor atunci când efectuează antrenamente. În final, clasele definite structurează comportamentul modulului de tutorat. Acest subdomeniu centrat pe dezvoltarea abilităților de forță include două ierarhii de clase: una pentru a descrie diferite perioade și alta pentru a reprezenta modalitățile de dezvoltare a forței.

Al treilea subdomeniu OntoStrength sprijină descrierea variabilelor utilizate la definirea programelor de dezvoltare a antrenamentului de forță ajustate la caracteristicile elevilor. Modulul *Student* dintr-un ITS psihomotric folosește aceste cunoștințe pentru a oferi modulului de tutorat cunoștințe specifice despre fiecare student. În plus, modulul de *Instruire* folosește aceste cunoștințe atunci când definește conținutul antrenamentului și îl actualizează pe baza feedback-ului primit de la student. O tipologie a amprentelor de rezistență structurează aceste variabile.

Clasa „Semnătură generală” conține atribute generice, cum ar fi numele, vârsta, sexul, mărimea sau greutatea elevului. O semnătură specifică este asociată cu fiecare abilitate bio-motorie. „Semnătura antropometrică” se referă la mărimea corpului, greutatea și compoziția corpului. „Semnătura accidentării” include istoricul fiecărui elev cu privire la leziuni relevante care trebuie luate în considerare atunci când se efectuează un program de dezvoltare a forței. „Semnătura motorului” asociază elevului niveluri specifice, pentru fiecare abilitate de mișcare. Mai mult, ontologia include nivelul fiecărui tip de mișcare a forței pentru dezvoltarea forței.

„Semnătura antrenamentului de forță” descrie istoricul antrenamentului elevilor pentru fiecare antrenament efectuat, conținutul, evaluarea succesului și feedbackul asociat al elevilor. Prin urmare, „variabilele de dezvoltare biomotorie personalizate” organizează toate semnăturile diferite în ontologia OntoStrength, așa cum se poate vedea în Figura 5.

OntoStrength – Un Cadru de Reprezentare și Deducere a Cunoștințelor în Sisteme de Instruire Inteligente Psihomotorii

Terarhiile principale de clasă descrise anterior susțin instanțierea programelor de dezvoltare a forței, de la nivelul macrociclului până la nivelul exercițiului. În plus, interogările SPARQL au fost implementate pentru a rezolva sarcini specifice de antrenament – de exemplu, pentru a obține exerciții asociate cu o anumită parte a corpului (împingere lată a tricepsului, tragere laterală, împingere cu picioarele ridicate) sau pentru a obține șabloane de instruire generice pentru un obiectiv de formare, bazate pe caracteristicile cursantului. GraphDB a fost folosit pentru a testa interogările și a interacționa cu ontologia. Prin SPARQL, se pot adăuga date noi la ontologie.

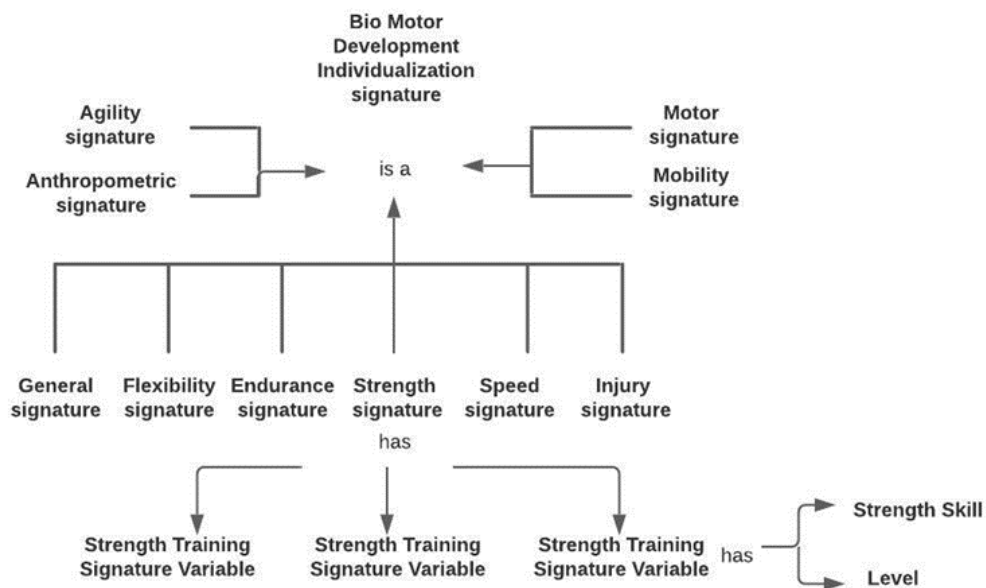


Figura 5. Subdomeniul OntoStrength pentru Dezvoltarea Personalizată a Abilităților de Forță

OntoStrength prezintă instanțierea unei entități Macro-ciclu, care are o entitate Mezo-ciclu ca proprietate a obiectului, numită `hasMesoCycle`. Entitatea Mezo-ciclu are o entitate Micro-ciclu, ca proprietate a obiectului, numită `hasMicroCycle`. Microciclul are două proprietăți ale obiectului (`hasWorkout` și `hasObjective`), în timp ce Microciclul este definit ca un antrenament tip Push și un antrenament ce include întreg corpul (Full-Body Workout).

Antrenamentele sunt inițializate cu exerciții care respectă regulile definite de Bompa (Bompa, 2017), pentru o încărcare de nivel începător. Fiecare exemplu de exercițiu descrie o listă de mișcări funcționale și fundamentale, împreună cu contracțiile musculare implicate în execuție. Interogarea SPARQL din Figura 6 preia toate mișcările implicate într-un microciclu specific definit în OntoStrength („os” denotă prefixul specific ontologiei OntoStrength).

OntoStrength – Un Cadru de Reprezentare și Deducere a Cunoștințelor în Sisteme de Instruire Inteligente Psihomotorii

```

SELECT DISTINCT ?movement ?microCycle
WHERE
?microC os:hasMicroCycle ?microCycle.
?wkout os:hasWorkout ?workout.
?cntBlck os:hasContentBlock ?contentBlock.
?ex os:hasExercise ?exercise.
?ld os:hasLoad ?load.
?mvmnt os:hasMovement ?movement.

```

Figura 6. Interogare OntoStrength – Mișcările asociate unui Micro-ciclu.

Ierarhia moștenirii poate fi vizualizată și în GraphDB. OntoStrength se bazează pe moștenirea proprietăților între clase. Fiecare exercițiu este reprezentat ca o clasă, care are clase de bază specifice reprezentând tipul de mișcare implicat, în timp ce cea mai generică este clasa „Abilitate de mișcare”. Clasa „Exercițiu” este moștenită din clasa „Mișcare specializată”, care include o listă de „Mișcări funcționale” de executat (cum ar fi „Extensia cotului” sau „Aducția umărului”). Mai mult decât atât, „Mișcările funcționale” sunt compuse dintr-o listă de „Contractii musculare”, cum ar fi „Contractie concentrică a tendoanelor” sau „Contractie excentrică a cvadricepsului”.

O instanțiere a unei clase de „Exercițiu” este exercițiul în sine, cu nivelul și descrierea sa specifice. „Feet Elevated Front Plank” din Figura 7 este un exemplu de instanță a clasei cu același nume, descris ca un exercițiu de Nivel 1, pentru Mișcarea Anti-Extensie.

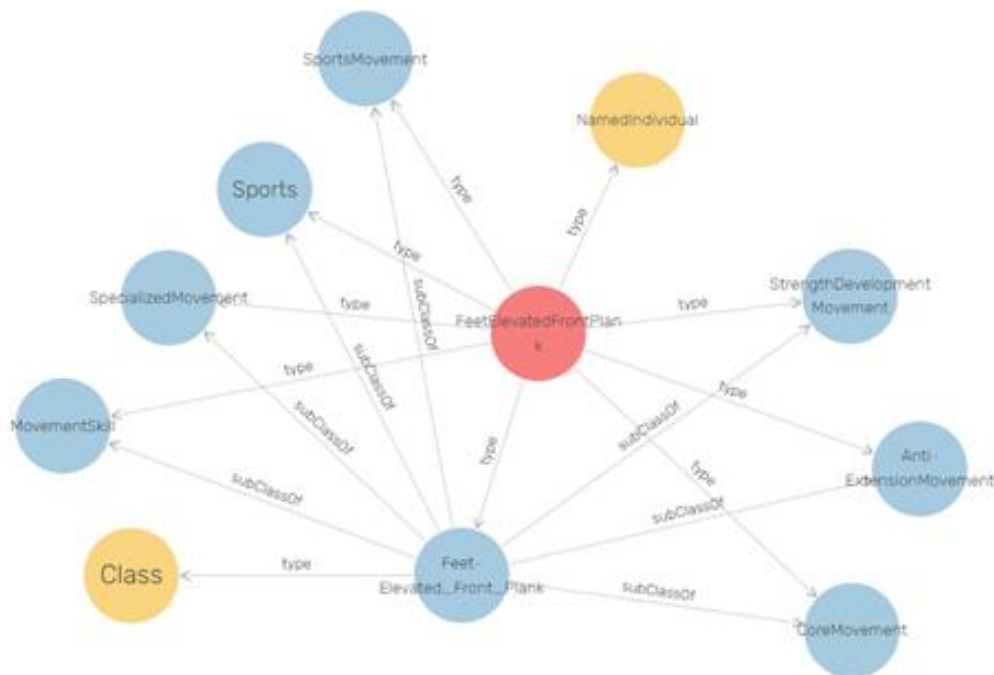


Figura 7. Vedere GraphDB a instanței și clasei Feet Elevated Front Plank.

5.2 Utilizarea OntoStrength

Ontologia OntoStrength susține orice ITS pentru dezvoltarea psihomotorie oferind cunoștințe și relații utile diferitelor module ale sistemului. În acest scop, un API RESTful poate interacționa cu ITS pentru a furniza microservicii specifice domeniului, studenților și funcționalităților sistemului de îndrumare. Următoarele subsecțiuni ilustrează interacțiunile OntoStrength cu un ITS psihomotoriu prin intermediul API-ului RESTful.

Funcționalitățile de profilare a studenților ITS elaborează și perfecționează profilurile de semnătură ale studenților utilizate pentru a personaliza definiția antrenamentelor de dezvoltare a forței. API-ul OntoStrength RESTful oferă interogări pentru a sprijini selecția variabilelor de semnătură utilizate de ITS, de a actualiza variabile de semnătură și de a obține valorile variabilelor de semnătură.

Semnătura de individualizare a forței constă într-un nivel care variază între 1-4 pentru a se potrivi cu nivelul la care exercițiile pot fi efectuate în siguranță, pentru toate abilitățile de mișcare a forței. Evaluarea acestor parametri se realizează printr-o sesiune inițială de antrenament de calibrare, care are o complexitate incrementală, până la eșec. Odată ce este efectuată o calibrare inițială a atletului, este generat un program de antrenament pentru dezvoltarea forței și este actualizat continuu după fiecare antrenament.

Am luat în considerare Ontology Development 101 (OD101) pentru construirea OntoStrength, o metodologie la nivel micro care propune un ghid practic și explicit pentru dezvoltarea ontologiilor. Procesul, bazat pe munca în echipă interdisciplinară, a implicat o definire clară a domeniului și domeniului de aplicare, reutilizarea ontologiilor existente, definirea claselor și proprietăților și, în final, crearea instanțelor pentru a completa baza de cunoștințe.

Ontologia poate fi accesată folosind o arhitectură de microservicii, în care punctele finale specifice sunt disponibile pentru a servi mai multe interogări în scopuri de antrenament sportiv, cum ar fi exerciții care vizează un model de mișcare, în funcție de dificultate, generarea de sesiuni de încălzire, planuri generice de antrenament săptămânal, bazate pe obiective, și alții. Microserviciile pot fi integrate în orice ITS pentru dezvoltarea psihomotorie. Secțiunea actuală este fundația pentru a genera lanțuri întregi de antrenament, inclusiv antrenamente, microcicluri, mezocicluri și macrocicluri. Îmbunătățirile în ceea ce privește proiectarea ontologiei includ dimensiuni suplimentare de gen și evaluări ale leziunilor în timpul practicării activităților de antrenament. OntoStrength va fi publicat sub o licență open-source și va fi extins în continuare pentru a include alte abilități psihomotorii, cum ar fi abilitățile de flexibilitate, mobilitate sau rezistență.

6 Strategii de Predare într-un Sistem de Instruire Psihomotorie

6.1 Considerarea Dimorfismului Sexual în Sistemele de Instruire Psihomotorie

Diferențele morfologice, cognitive și fiziologice dintre bărbați și femei influențează dezvoltarea conținutului sesiunilor de antrenament, împreună cu riscurile asociate de răni și tulburări psihologice. Această secțiune descrie pe scurt aceste diferențe.

Diferența dintre dimensiunea scheletului și compoziția corporală a femeilor și bărbaților (adică, densitatea, masa relativă de grăsime și masa corporală slabă ajustată în funcție de înălțime) variază la diferite perioade de vârstă (Kirchengast, 2010) (Joyce & Lewindon, 2016) (Shephard, 2000). Aceste diferențe cresc la pubertate datorită diferențierii hormonale. Bărbații umani adulți sunt cu 7% mai înalți decât femeile și există o cantitate substanțial mai mare de grăsime corporală și o cantitate substanțial mai mică de masă corporală slabă în rândul femeilor. Femeile au un torace mai mic, un abdomen mai mare, un pelvis mai larg și mai puțin adânc, picioare mai scurte și un centru de greutate relativ mai scăzut decât bărbații. Distribuția masei musculare inferioare a corpului este destul de similară între sexe, în timp ce femeile au mai puțină masă musculară în partea superioară a corpului decât bărbații.

Diverse teorii (Baron-Cohen, Knickmeyer, & Belmonte, 2005) (Liutsko, Muiños, Tous Ral, & Contreras, 2020) (Li, 2014) enunță diferența dintre abilitățile cognitive ale femeilor și ale bărbaților care influențează abilitățile psihomotorii. În general, femeile tind să-și adapteze comportamentul la percepția lor asupra emoțiilor și gândurilor altei persoane. Pentru navigare, ei favorizează o strategie egocentrică în timp ce folosesc numele străzilor și formele clădirilor ca repere. Ei depășesc bărbații în ceea ce privește precizia și abilitățile mâinii fine, locația obiectelor și memoria verbală, recunoașterea verbală și sarcinile de fluentă semantică.

În schimb, bărbații tind să analizeze și să exploreze regulile care guvernează un sistem. În general, au rezultate mai bune la sarcinile de rotație mentală și navigație spațială decât femeile. Pentru navigație, ei tind să favorizeze o strategie alocentrică care ia în considerare judecățile precise ale distanței. Bărbații integrează viteza și precizia mai repede decât femeile și tind să fie mai buni la sarcini senzoriomotorii, inclusiv țintirea, prinderea și aruncarea.

Strategii de Predare într-un Sistem de Instruire Psihomotorie

Diferențele morfologice ale femeilor și variabilitatea hormonală în timpul ciclului menstrual induc un risc mai mare de rănire și, în special, de leziune a ligamentului încrucișat anterior (ACL). Prevalența leziunii LCA la femei este de 2-10 ori mai mare decât la bărbați, pentru aceleași activități psihomotorii. Această prevalență determină o rată mai scăzută de dezvoltare a forței, deficite de activare a ischio-coarbei și o mai mare flexie dorsală a gleznei, combinată cu poziția valgus a genunchilor și rotația externă a șoldului hip (Joyce & Lewindon, 2016) (Somerson, Isby, Hagen, Kweon, & Gee, 2019).

În mod tradițional, programul și proiectarea sesiunilor de formare a abilităților psihomotorii se bazează pe variabile temporale fiziologice. Întârzierea dintre două ședințe trebuie să fie suficient de mare pentru a nu induce excesul de oboseală și nici prea lungă pentru a nu induce deantrenarea. Evoluția încărcării sesiunii, care este calculată folosind Ecuația 1, urmează modele temporale cu dezvoltare progresivă de la o săptămână la alta.

Ecuația 1. Formula de Calcul a Încărcăturii a unei Sesiuni

$$SessionLoad = \sum NoRepsEx_k * IntensityEx_k * RestTimeEx_k * NoJointsEx_k$$

Cea mai ușoară săptămână este stabilită la fiecare trei săptămâni pentru a facilita asimilarea învățării – de exemplu, o săptămână cu sesiuni ușoare, o săptămână cu sesiuni medii, o săptămână cu sesiuni grele, urmată din nou de sesiuni ușoare.

Monitorizarea performanței cursantului și feedbackul sprijină ajustarea sarcinii. Atunci când programează sesiuni de învățare pentru femei, tutorele trebuie să urmeze aceleași variabile temporale fiziologice. Cu toate acestea, la proiectarea sesiunilor, acestea trebuie să se sincronizeze cu ciclul menstrual pentru a defini conținutul sesiunii. Tabel 3 descrie relația dintre încărcarea sesiunii și diferitele faze ale ciclului menstrual conform Pitchers (Pitchers & K., 2019).

Tabel 3. Adaptarea sarcinii de antrenament la faza menstruală adaptată din Pitchers

Fază menstruală	Early follicular	Mid follicular	Late follicular	Early luteal	Mid luteal	Late luteal
Încărcătură a antrenamentului	Ușor	Mediu	Mediu / Greu	Foarte Greu	Mediu	Ușor

Profilul celui antrenat înainte de începerea și în timpul unui program de dezvoltare a abilităților psihomotorii constă în general în evaluarea capacităților fizice și identificarea zonelor de slăbiciune sau durere asociate cu performanța (Joyce & Lewindon, 2016). Luarea în considerare a riscurilor de leziuni specifice femeilor, în special ACL și triada sportivă de sex feminin, necesită integrarea unor

teste adecvate de evaluare a susceptibilității la rănire. Rezultatele acestor teste sunt utilizate ulterior pentru a oferi sesiuni de profilaxie dedicate și pentru a ajusta sesiunile de învățare în consecință.

6.2 Optimizarea Secvențelor de Predare folosind Învățarea Automată. Metoda Exercițiul Corect la Momentul Potrivit (RiERiT).

Procesul de îndrumare pentru un ITS psihomotoric a fost structurat pe o scară de maturitate pe patru niveluri, care include formatori începători, intermediari, avansați și experți. Temporalități suplimentare sunt luate în considerare în procesul de adaptare la trecerea de la un nivel la altul.

Novice Trainer implementează algoritmul bandiților Multi-Armed pentru personalizarea secvențelor de antrenament într-o sesiune. Trainerul intermediar poate personaliza conținutul unei sesiuni; Trainerul Avansat personalizează microciclul, în timp ce antrenorul Expert poate crea conținut personalizat de mezociclu și macrociclu pentru fiecare individ.

Modelul de bază se bazează pe șabloane de secvențe de antrenament pentru generarea de microcicluri și sesiuni bazate pe intrarea cursanților, inclusiv numărul de sesiuni de antrenat în săptămâna curentă (microciclu asociat), timpul de antrenament pentru o sesiune și microciclul. obiective sau concentrare. O sub-listă de șabloane utilizate pentru generarea de microcicluri în adaptarea anatomică este prezentată în Tabel 4.

Tabel 4. Exemple de Șabloane de Microcicluri pentru Adaptarea Anatomică

Nume Șablon Microclu	# de Sesiuni Antrenamente	Sportiv Recomandat
Push / Pull / Lower / Upper / Lower	5	Bărbat
Hip Dominant / Knee Dominant / Upper / Lower / Upper	5	Femeie
Upper / Lower / Full / Full / Full	5	Ambii

Nivelul de încărcare este reprezentat de numărul de repetări (de la 8 la 15) și de seturi (de la 1 la 5). Zonele vizate pentru exerciții sunt reprezentate fie de mișcări fundamentale, fie complementare, iar modulul de domeniu mapează exerciții reale cu tipuri de mișcare și niveluri de dificultate (de la 1 la 5). Nivelul de stagiar pentru fiecare mișcare fundamentală este estimat prin provocări de calibrare, care au fost introduse anterior. Ca atare, provocarea antrenorului începător este să aleagă exercițiul potrivit din lista de exerciții disponibile (numit Exercițiul potrivit la momentul potrivit - *RiEaRiT*).

O metodă online eficientă, și anume multi-armed bandits contextuali (Lu & Pal, 2010) a fost folosită pentru a explora și optimiza diferite exerciții și pentru a estima progresul stagiatarului. Astfel de algoritmi modelează o situație în care o decizie este luată într-o succesiune de încercări independente bazate pe un context dat, care conține informații secundare.

Strategii de Predare într-un Sistem de Instruire Psihomotorie

Contextul în cadrul sistemului *Selfit* este reprezentat de forma zilei a sportivului, care este calculată folosind o scală Borg (Spielholz, 2006), adică o scară CR-10 (Category Ration-10) pentru a măsura diferiți parametri de formă a corpului. Algoritmii selectați asigură crearea unei experiențe de învățare personalizate, bazându-se doar pe cunoștințe limitate ale domeniului. Scopul modelului este de a maximiza profitul total, sau recompensa, a acțiunilor alese.

Recompensa în cadrul algoritmului multi-armed bandit, după alegerea unui exercițiu, este calculată ca diferență între sarcina externă (EL) – taxa de exercițiu considerată: numărul de repetări și numărul de seturi și sarcina internă (IL) – calculată din forma estimată a utilizatorului, valoare subiectivă. Această diferență este definită și ca numărul de Repetări în Rezervă (RiR) (Hackett, Johnson, Halaki, & Chow, 2012) și, pentru antrenamentul de adaptare anatomică, cele mai bune valori sunt pozitive, cât mai aproape de 0.

RiR indică câte repetări mai multe ar fi putut efectua un cursant la sfârșitul unui set. 0 înseamnă că numărul de repetări furnizat este numărul maxim de repetări pe care utilizatorul le-ar fi putut efectua. O valoare pozitivă reflectă numărul de repetări potențiale care ar fi putut fi efectuate; cu toate acestea, această valoare este subiectivă. O valoare negativă înseamnă că cursantul a eșuat la acel set; dacă, de exemplu, setul avea 12 repetări și RiR era -2, cursantul putea efectua doar 10 repetări. În timpul unui program de antrenament, există sesiuni specifice care necesită ca cursantul să ajungă la eșec (RiR negativ).

Recompensa este calculată pe baza formulei din Ecuația 2. Valorile valide ale RiR sunt valori întregi în intervalul [-10,10]. Dacă RiR raportat este fie 0, fie 1, recompensa este 1, cea mai mare valoare. Aceasta înseamnă că utilizatorul a putut să execute numărul de repetări ale aceluși exercițiu și, de asemenea, a fost foarte dificil. Dacă RiR raportat este mai mare de 1, recompensa este pozitivă, în intervalul [0,1, 0,5]. Cu cât valoarea RiR este mai mare, cu atât recompensa este mai mică.

Ecuația 2. Formula de Recomensă în cadrul Algoritmilor Multi-Armed Bandit Contextuali.

$$rew(RiR) = \begin{cases} 1 & , unde RiR \in \{0,1\} \\ \frac{1}{RiR} & , unde RiR > 1 \\ \frac{1}{|RiR|} - 1 & , unde RiR < 0 \end{cases}$$

Dacă RiR raportat este mai mic de 0, înseamnă că utilizatorul a eșuat exercițiul curent. Recompensa este proporțională cu variabilitatea RiR. Cu cât valoarea RiR este mai mare, cu atât recompensa este mai mare. Pentru această ramură, recompensa este negativă, cu valori în intervalul [-0,9, 0].

7 Selfit – Un Prototip de Sistem de Instruire Psihomotorie în Medii Deschise

7.1 Arhitectura Selfit

Modelul Selfit Domain susține procesul de învățare oferind răspunsuri la a) solicitări legate de definirea obiectivelor de învățare, b) evaluarea cursanților, c) definirea programului de învățare și d) adaptarea prin răspunsul la solicitări. Ontologia OntoStrength structurează modelul domeniului Selfit. Nucleul său constă din clasa de abilități de mișcare, cu profilul psihomotoriu asociat, modelele de mișcare și modalitățile programului de antrenament. Ontologia descrie relațiile dintre lanțurile musculare ale corpului, mișcările articulațiilor, mușchii agonist, antagonist și sinergic pentru dezvoltarea calităților de forță. De asemenea, descrie diferite modalități de dezvoltare cu modele de încărcare asociate.

Domeniul Selfit încapsulează logica sesiunii de calibrare, folosită pentru a evalua nivelul stagiaryului. Au fost descrise 24 de exerciții, câte 4 pentru fiecare zonă de mișcare, cu dificultate incrementală și un protocol de execuție. Domeniul are, de asemenea, o mapare completă a mișcărilor cu mușchii corpului. Stagiaryul are opțiunea de a configura o sesiune specificând mușchii pe care doriți să îi antrenați. Lista mușchilor selectați este mapată în continuare la mișcările corespunzătoare și, pe baza nivelului stagiaryului și a obiectivului sesiunii curente, sunt propuse exercițiile dorite.

Modelul Selfit Student conține informații despre capacitățile psihomotorii ale cursanților, în special cele legate de starea ciclului de supercompensare. În plus, include statistici de utilizare. Modulul de monitorizare accesează informații despre modul în care elevii folosesc sistemul și despre modul în care progresează în formarea lor. Modulul folosește aceste informații pentru a modifica parametrii de antrenament. Modelul Selfit Student sprijină generarea de sesiuni de antrenament și monitorizarea eficienței cursanților pentru a optimiza progresul, asigurând în același timp motivația de a practica și de a progresa.

Modulul Selfit Student cartografiază informații despre starea mecanică a stagiaryului. Aceasta include evenimente specifice raportate de utilizator – durere, rănire, intervenții chirurgicale sau altele, pe una sau mai multe regiuni ale corpului: spate, trunchi, extremitate superioară, extremitate inferioară și cap și gât. Aceste date, care pot fi actualizate de orice tip de către cursant, sunt reflectate în planificarea instruirii. Evenimentele raportate acționează ca restricții asupra mișcărilor și mușchilor specifici care trebuie utilizați în timpul antrenamentului.

Modulul Selfit Student cartografiază o listă de probleme fiziologice, cu potențiale riscuri medicale, care sunt raportate și de către cursant. Acesta include un formular pe care cursantul poate opta să îl completeze, care include următoarele riscuri pentru sănătate – hipertensiune arterială, diabet, post-cancer și obezitate. Starea fiziologică a stabilit o listă de restricții privind generarea programului de antrenament. Alte date specifice utilizatorului sunt o listă de exerciții preferate, care sunt marcate de utilizator în timpul antrenamentului și vor crește șansele de a fi recomandate în continuare. Fiecare utilizator are o listă cu alți cursanți pe care îi urmează și care îi urmăresc în aplicația Selfit.

Modelul Selfit Tutoring susține procesul de învățare prin furnizarea de mecanisme ML pentru a sprijini adaptarea programului de învățare la caracteristicile cursantului. Modulul de tutorat a necesitat integrarea în domeniul dezvoltării psihomotorii. Antrenamentul sportiv este un proces complex, care sprijină adaptarea și personalizarea, luând în considerare diferite temporalități (de exemplu, exercițiu, sesiune, săptămână, lună).

Un algoritm de bandit cu mai multe brațe sprijină definirea antrenamentelor de antrenament prin ajustarea conținutului șablonului cu intrări legate de pregătirea pentru antrenament, realizarea efectivă a sarcinilor de antrenament și evaluarea subiectivă a efectelor sarcinii furnizate de utilizator. Dimensiunea dimorfismului sexual este, de asemenea, luată în considerare din cauza diferențelor morfologice, cognitive și fiziologice dintre bărbați și femei. Proiectarea sesiunilor de antrenament se bazează pe variabile temporale fiziologice. Întârzierea dintre două ședințe trebuie să fie suficient de mare pentru a nu induce oboseală excesivă și nici prea lungă pentru a nu induce deantrenamentul. Pentru femei, evoluția sarcinilor de sesiune le urmărește ciclurile menstruale folosind un șablon specific.

Selfit a implementat metoda Right Exercise at the Right Time (*RiERiT*), care s-a dovedit eficientă pentru adaptare în domeniul psihomotric, așa cum se arată în II.6. Tutorul implementează algoritmul de bandiți multi-armate pentru personalizarea secvențelor de antrenament într-o sesiune, pe baza șabloanelor de sesiune. Un șablon de sesiune are o listă de exerciții generice, fiecare dintre ele având o zonă vizată, un nivel de încărcare și un timp de odihnă. Selfit propune exerciții cu cea mai mare probabilitate de a crește nivelul mediu de competență pentru toate componentele psihomotorii folosind performanța anterioară a sportivului.

Interfața grafică cu utilizatorul Selfit acceptă schimbul de informații între cursant și Selfit pentru a facilita procesul de învățare. Elevii accesează modulul de interfață printr-o aplicație web progresivă,

disponibilă pentru telefoane mobile, tablete sau computere personale. Selfit este accesibil în cele mai populare magazine mobile – Google Play¹ și App Store².

Dezvoltarea Progressive Web Application (PWA) este o platformă nouă care combină capacitățile și experiențele aplicațiilor native cu acoperirea web (Biørn-Hansen, Majchrzak, & Grønli, 2017). PWA-urile sunt recunoscute pentru un set de caracteristici cheie, cum ar fi receptivitate, independente de conectivitate, asemănătoare aplicației, sigure sau instalabile. Aplicația acționează ca Modul de interfață cu utilizatorul și este responsabilă pentru actualizarea Modulului Student, prin feedback continuu al utilizatorului.

Modulul de interfață este compus din componenta de autentificare, componenta de calibrare sau evaluare, feedback și sesiunea de instruire. Selfit nu urmărește și nu stochează date personale ale utilizatorului; profilurile de utilizator constau dintr-un pseudonim, o parolă și o întrebare de securitate gestionată de subcomponenta Autentificare. Subcomponenta Calibrare sprijină definirea motivației de învățare a fiecărui elev prin selectarea calităților fizice de dezvoltat.

Pentru fiecare calitate fizică, componenta oferă un protocol de testare. De exemplu, evaluarea pentru dezvoltarea calităților de forță constă într-o provocare care urmărește efectuarea a patru din cele șase categorii de mișcări esențiale (împingere pe partea superioară a corpului pe orizontală, împingere pe partea superioară a corpului pe verticală, împingere pe partea superioară a corpului pe orizontală, trage pe partea superioară a corpului pe verticală, șoldul inferior dominant, partea inferioară a șoldului). genunchi dominant), un exercițiu pentru fiecare patru niveluri de dificultate. Sesiunile de calibrare trebuie efectuate în mod regulat pentru a ajusta progresul utilizatorului în timpul antrenamentului.

Feedback-ul este esențial pentru a performa abilitățile motorii (Bilodeau & Bilodeau, 1961). Subcomponenta Dialog sprijină studenții în furnizarea de informații înainte și după sesiunile de formare pentru a ajuta la adaptarea sesiunilor de formare la forma și disponibilitatea elevilor. Înainte de a începe o sesiune, Selfit le cere elevilor să-și auto-evalueze nivelul de oboseală, motivația de a se antrena, calitatea somnului și nivelul de stres pe o scară de la unu la zece.

În timpul sesiunilor de antrenament, Selfit le cere elevilor să se autoevalueze la sfârșitul fiecărui exercițiu de conținut și să răspundă dacă ar putea efectua repetări suplimentare și, dacă da, câte. După sesiunea de antrenament, Selfit le cere utilizatorilor să introducă dificultatea sesiunii pe care au perceput-o pe o scară de la unu (foarte greu) la zece (foarte ușor). Atleții pot selecta locația trenului

¹ <https://play.google.com>

² <https://www.apple.com/app-store>


(acasă sau sală de sport), cu multe șabloane de sesiune disponibile, materialele de antrenament disponibile (mreană, bandă elastică, mașină etc.) și mușchii complementari pe care să îi vizeze în timpul antrenamentului (umăr anterior, bicepși, antebrațe, coapse, etc.). În timpul antrenamentului, pentru fiecare exercițiu este afișat un videoclip care demonstrează mișcarea și detaliile necesare pentru a realiza sarcina corectă (adică, numărul de seturi, numărul de repetări, odihnă între repetări și între seturi).

7.2 Generarea Antrenamentului și Monitorizarea Impactului Antrenamentului

Motorul de generare a antrenamentului Selfit definește conținutul următoarei sesiuni de antrenament folosind informații despre caracteristicile elevilor, performanțele anterioare și nivelurile actuale de oboseală. Modulul de îndrumare identifică mai întâi ținta antrenamentului prin prezicerea șablonului cel mai precis, pe baza istoricului de antrenament al elevului și a semnăturii reale a oboselii. Odată selectat, modulul generează conținut adecvat folosind strategii de instruire și semnăturile de personalizare ale studenților. De asemenea, utilizatorul poate personaliza conținutul antrenamentului modificându-și preferințele cu privire la dezvoltarea mușchilor, înainte de a începe un antrenament. La sfârșitul fiecărui exercițiu, faza de sesiune și antrenament, Selfit evaluează succesul sau eșecul și îi întreabă pe atleți despre percepțiile lor despre efort.

Modulul de interfață cu utilizatorul Selfit actualizează ontologia cu actualizările informațiilor de antrenament transmise de utilizatori, cum ar fi profilul de oboseală zilnică sau percepția efortului după realizarea unei sarcini de antrenament. Un exemplu de interfață grafică din interiorul sesiunii de antrenament poate fi văzut în Figura 8 (a), unde utilizatorul își evaluează subiectiv forma fizică înainte de a începe o sesiune de antrenament; preferințele de dezvoltare musculară sunt descrise în Figura 8 (b).

Feedback-ul utilizatorului după fiecare exercițiu este stocat, iar modulul de îndrumare îmbunătățește recomandările pe baza repetărilor raportate în rezervă. Personalizarea este percepută la nivel de sesiune. Înainte de a începe fiecare antrenament, utilizatorul configurează parametrii sesiunii curente și apoi sunt generate toate exercițiile. Ulterior, rezumatul sesiunii generate este afișat utilizatorului și apoi antrenamentul poate fi început.



(a) Monitorizare zilnică a obosealii

(b) Preferințe de dezvoltare musculară

Figura 8. Interfața *Selfit*– Parametrii pentru Generarea de Sesiuni

7.3 Evaluarea Psihomotorie folosind Vederea Computerizată. Un Studiu privind Atenuarea Riscului de Rănire

În această etapă, a fost dezvoltat un modul de evaluare a riscului de accidentare ACL pentru femei pentru a sprijini screeningul inițial al elevilor și monitorizarea riscurilor de accidentare. Procesul de evaluare este structurat în patru faze, vezi Figura 9. Prima fază constă în captarea unui videoclip frontal și unul sagittal al elevului care efectuează o ghemuire pe spate. În a doua fază, un modul de recunoaștere a mișcării umane oferă o discretizare a traiectoriei fiecărei articulații a corpului în timpul efectuării genuflexiunii pe spate. Apoi, modulul de evaluare a riscului analizează acest model pentru calcularea factorului de risc de accidentare ACL. În cele din urmă, dacă sunt detectate riscuri, modulul oferă instrucțiuni către ITS.




Figura 9. Procesul Modulului de Evaluare a Riscului de Accidentare ACL

Cele două videoclipuri permit o perspectivă completă a mișcării efectuate și apoi oferă informații pentru evaluarea valgusului genunchiului și flexibilității gleznei, doi dintre factorii esențiali implicați în riscul de accidentare ACL.

.În a doua fază, un modul de recunoaștere a mișcării umane oferă o discretizare a traiectoriei fiecărei articulații ale corpului care efectuează ghemuitul pe spate. Biblioteca de estimare a poziției OpenPose 2D library (Cao, Simon, Wei, & Sheikh, 2018; Simon, Joo, Matthews, & Sheikh, 2017) permite obținerea de videoclipuri cu o suprapunere adăugată care conține punctele cheie și liniile corpului și o colecție de fișiere JSON, câte unul pentru fiecare cadru, care conține poziția punctelor esențiale, în pixeli.

Modulul de evaluare a riscurilor analizează acest model pentru calcularea factorului de risc de accidentare ACL. Monitorizarea aspectului medial al oricărui genunchi care trece de maleola medială din perspectiva anterioară în timpul oricărei faze a ghemuitului ajută la identificarea unui valgus (Somerson et al., 2019). Modulul evaluează distanța dintre „Genunchiul R sau L” și „Glezna R sau L” atunci când elevul efectuează ghemuitul pe spate.

Mișcarea începe în cadrul 30 și se termină în cadrul 150 din Figura 10. La poziția inițială, distanța dintre genunchi și glezne este negativă, iar distanța dintre genunchi și glezne este superioară de 5 cm, demonstrând prezența unui valg. poziție înainte de începerea mișcării. În timpul mișcării, distanța negativă dintre genunchiul stâng și glezna stângă crește, demonstrând creșterea poziției valgus.

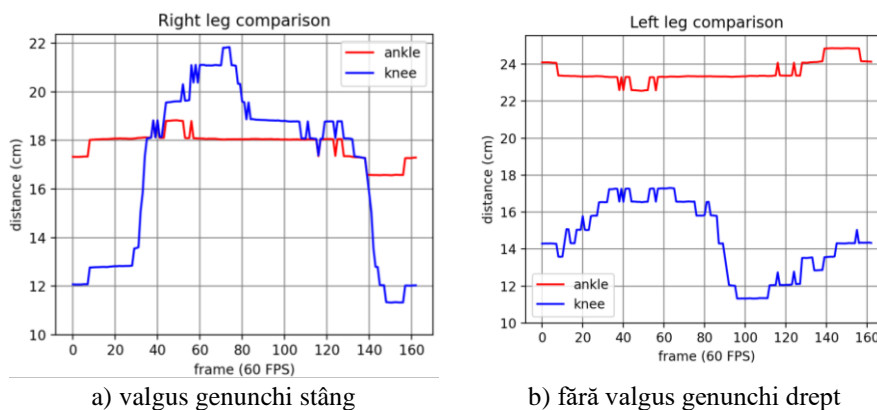


Figura 10. Ilustrație a evoluției distanței dintre genunchii și gleznelor elevului cu variații între stânga și dreapta

Riscul de leziune ACL crește dacă sunt detectate atât gleznelor valgus, cât și flexibile. În timpul perioadei de ovulație a ciclului menstrual, hormonii maximizează riscul. Dacă modulul de evaluare a riscurilor detectează un risc de ACL, comunică cu Selfit ITS furnizând reguli de atenuare pentru a reprograma sesiunile de învățare planificate și viitoare pentru luarea în considerare a sarcinilor cu risc scăzut. Capitolul actual introduce o descriere cuprinzătoare a Selfit, un ITS pentru dezvoltarea psihomotorie, alături de provocările de proiectare și implementare întâlnite și considerații arhitecturale pentru dimensiunea dimorfismului sexual.

8 Rezultate

8.1 Experiment bazat pe Simulare

Eficiența modulului de *Instruire* a fost simulată cu diferite implementări contextuale ale bandiților multi-armate. Experimentele au fost realizate în medii complet virtuale, iar scopul a fost de a determina, pe baza metodologiei generale de antrenament sportiv, care algoritm converge primul și câte sesiuni de antrenament sunt necesare.

Experimentul a fost realizat într-un mediu configurat cu 1800 de exerciții, câte 300 pentru fiecare familie de mișcări, cu 10 exerciții pe nivel de dificultate. Nivelurile de dificultate au variat de la 1 la 5. Următoarele strategii au fost implementate pentru a evalua performanța: (a) agent aleatoriu – alege un exercițiu aleatoriu pentru acel tip și nivel de mișcare; (b) limită superioară de încredere a banditului multi-armate (MaB UCB1) – principiul optimismului în fața incertitudinii, ceea ce înseamnă că, cu cât sunteți mai nesigur de un braț, cu atât este mai important să explorați; (c) bandit multi-armate ϵ -Greedy (0.1) – explore (alege o acțiune aleatorie) cu probabilitate ϵ și exploatează (alege o acțiune cu valoare maximă) cu probabilitate $1 - \epsilon$; și (d) bandit bayesian multi-armate UCB1 – folosește aceleași principii ale UCB1, dar încorporează informații prelabile despre distribuirea recompenselor unui braț pentru a explora mai eficient.

Pentru abordarea ϵ -Greedy, valoarea de 0,1 pentru ϵ a prezentat cele mai bune rezultate pentru toate simulările. Nivelurile inițiale de competență au fost configurate aleatoriu pentru fiecare tip de mișcare al cursanților simulați. Răspunsul elevilor după aplicarea unui exercițiu urmează teoria standard a răspunsului la item (Hambleton, Swaminathan, & Rogers, 1991), unde probabilitatea de a putea efectua un exercițiu este dată de Ecuația 3.

Ecuația 3. Item Response Theory (Hambleton et al., 1991)

$$p(\text{success}) = \frac{\gamma(a)}{1 + e^{-(\beta(c^Q - c(a) + \alpha)}}$$

Parametrii β și α sunt constante pentru a simula diferite rate de învățare ale populației; $\gamma(a)$ a fost generat aleatoriu pentru fiecare nivel de competență al stagiaryului între 0 și 1, unde 0 înseamnă că stagiaryul nu poate efectua exercițiul. De asemenea, s-a considerat că după fiecare 30 de exerciții aplicate unei familii de mușchi va crește numărul de repetări în rezervă pentru toate exercițiile pentru familia musculară vizată. Scopul experimentului a fost de a înțelege cât de rapid și eficient algoritmi propuși estimează și oferă exerciții de antrenament, folosind starea curentă a cursantului. În cadrul

Rezultate

experimentului a fost generată o populație de 1000 de cursanți, fiecare cu un anumit nivel de competență, generat aleatoriu pe exercițiu; Valorile RIR au fost inițial estimate pe exercițiu și pe cursant.

Populația anterioară a fost antrenată timp de 2 ani, inclusiv 384 de ședințe, folosind cele patru condiții date de algoritmi selectați. Aceleași exerciții au fost aplicate unui stagiar la un moment dat, având în vedere cele patru strategii. Rezultatele pot fi văzute în Figura 11. Un punct de date de pe axa Ox reprezintă numărul curent al sesiunii de antrenament, iar axa Oy încapsulează recompensa de antrenament cumulată.

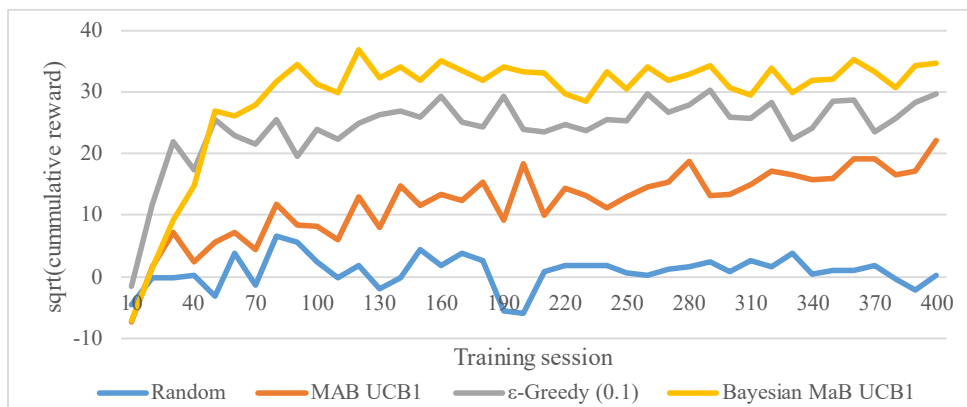


Figura 11. Compararea Algoritmilor de Antrenament Sportiv – Interval de Timp de 2 ani

Algoritmul care oferă cea mai bună recompensă cumulată în timpul antrenamentului este Bayesian Multi-Armed Bandits UCB1: 1175; următoarea a fost strategia ϵ -Greedy (975,8), urmată de MaB simplu UCB1 (483,3) și aleatoare (33,1). Modelul Selfit Tutoring sprijină procesul de învățare prin furnizarea de mecanisme de învățare automată pentru a sprijini adaptarea programului de învățare la caracteristicile cursantului. Pentru antrenorul începător, sesiunile au fost generate folosind un plan calendaristic standard, utilizat de formatori în activitatea lor zilnică.

8.2 Experiment cu Utilizatori Reali

Scopul unui sistem inteligent de îndrumare este de a oferi studenților experiențe de predare mai eficiente (Clement et al., 2015). Experimentul actual și-a propus să evalueze atât îmbunătățirea învățării Selfit, cât și experiența generală a utilizatorului. Experimentul a fost împărțit în două faze. Versiunea 1 Selfit a fost testată inițial în perioada ianuarie-februarie 2021, de 18 cursanți din Franța și România. Puține erori ale interfeței utilizatorului și ale selecției exercițiilor de sesiune au fost raportate de utilizatori și mai multe caracteristici de îmbunătățire au fost propuse în acest feedback preliminar.

Rezultate

Faza inițială de testare a fost urmată de o nouă fază de dezvoltare, între februarie 2021 și decembrie 2021, pentru o versiune îmbunătățită a Selfit, care a fost lansată în producție la sfârșitul anului 2021. Versiunea 2 Selfit a inclus câteva remedieri de erori, îmbunătățiri de performanță și un set de funcții noi, bazate pe feedback-ul utilizatorilor. Caracteristicile includ posibilitatea de a vă personaliza profilul (configurați o fotografie de profil, setați un motto, data nașterii etc.), o opțiune de a întrerupe și a relua exercițiile bazate pe timp, o interfață îmbunătățită pentru introducerea RIR pe exercițiu, o adaptare mai bună a unei sesiuni prin introducerea unei liste de materiale disponibile pentru antrenament, a adăugat diagrame statistice antrenate pentru zonele corpului, a integrat Google Analytics, a creat un nou protocol pentru teste pre- și post-test și altele.

Selfit Versiunea 2 a fost testată în a doua fază a experimentului, în perioada ianuarie-mai 2022, de 42 de stagiaari din Franța și România, care s-au introdus în aplicație la date diferite. Scopul a fost de a valida arhitectura software și interfața și de a evalua dacă este posibil să înveți cea mai bună sarcină în fiecare exercițiu, astfel încât cursanții să fie la nivelul lor optim pe parcursul unui program de antrenament.

Chiar dacă prima fază a experimentului ar fi trebuit să dureze 3 luni, pentru a colecta și date despre modul în care modulul de tutorat se comportă în practică, pe baza feedback-ului utilizatorului și a erorilor raportate, această fază a fost întreruptă și problemele au fost rezolvate. Versiunea 2 Selfit, cu mai multe upgrade-uri de interfață și performanță, a fost lansată intern, în grupul nostru de cercetare, în noiembrie 2021, și lansată public, în magazinele mobile, în ianuarie 2022.

Versiunea actualizată a împărțit populația de cursanți în două, ambii folosind algoritmul Contextual Multi-Armed Bandits ϵ -Greedy (0.1):

- primul grup a folosit Selfit Tutor A – tutorul folosește un spațiu de explorare mai larg (brațele bandiților pentru un exercițiu de zonă de mișcare includ toate nivelurile disponibile, filtrate de materialele disponibile);
- al doilea grup a folosit Selfit Tutor B – tutorul folosește un spațiu de explorare îngust (brațele de bandit pentru un exercițiu de zonă de mișcare includ doar nivelul estimat al utilizatorului, filtrat de materialele disponibile).

Ne așteptam ca Selfit Tutor B să ofere un conținut de instruire mai personalizat în general, datorită dimensiunii mai mici a spațiului de explorare. Chiar și luând în considerare contextul actual al stagiului, despre care am presupus că ar trebui să afecteze încărcătura de antrenament – dificultatea exercițiilor oferite, ne-am așteptat la mai multă implicare și un progres mai bun pentru participanții din Grupa B.

Rezultate

Utilizatorii înscriși în experiment au fost expuși la una dintre cele două versiuni ale componentei de tutorare, ambele implementate folosind generarea de sesiuni Contextual Multi-Armed Bandits ϵ -Greedy 0.1 (Contextual MaB) – una cu un spațiu de explorare mai mare (numit în continuare Grup A), și încă unul, cu un spațiu de explorare inferior (numit în continuare Grupa B).

Primii 5 performeri din Grupa A au următorul număr de sesiuni finalizate: 30, 27, 25, 23 și 16, în timp ce din Grupa B primii 5 performeri au: 11, 6, 6, 5 și, respectiv, 5 sesiuni. Grupa A a efectuat 254 de sesiuni de antrenament, în timp ce Grupa B a efectuat 61 de sesiuni de antrenament.

Scopul provocărilor de calibrare a fost de a clasifica utilizatorul într-una din categoriile de patru nivele (începător, intermediar, avansat sau expert), pentru fiecare tip de mișcare: Upper Body (Push orizontal, Push vertical, Pull Horizontal, Pull Vertical) și Partea inferioară a corpului (dominantă la șold, la genunchi). Utilizatorii își pot actualiza nivelurile pe tip de mișcare doar executând din nou provocările, în orice moment. Pe baza testului de calibrare, utilizatorii sunt alocați la nivelul corespunzător pe tip de mișcare și exercițiile viitoare vor fi furnizate urmând valorile curente.

Recomandările Banditului sunt diferite între cele două grupuri. Grupul A, care folosește spațiul de explorare înalt, va avea mai multe arme disponibile din care să aleagă – banditul va alege din toate nivelurile acelei zone de mișcare și va fi filtrat de restricțiile și preferințele utilizatorilor. Grupul B, care folosește spațiul îngust de explorare, va avea mai puține brațe disponibile din care să aleagă decât Grupul A. Un exemplu despre modul în care algoritmul se comportă pentru doi utilizatori, cu aceleași profiluri de antrenament, care folosesc Tutor A și Tutor B, după provocare de calibrare, poate fi văzută într-un scenariu simulat în Figura 12.

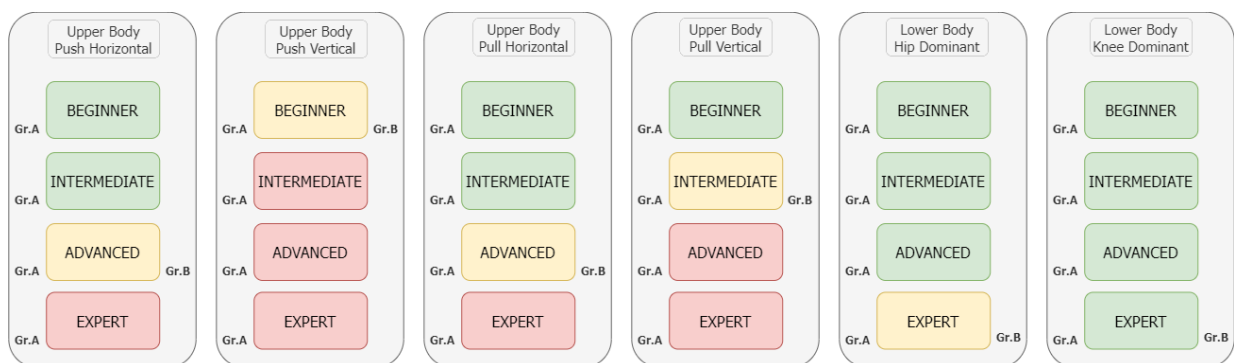


Figura 12. Spațiu de Explorare al Bandiților pentru fiecare grup, bazat pe Provocarea de Calibrare.

Pentru tipul de mișcare Upper-Body-Push-Horizontal, nivelul actual este Avansat. În Grupa A (Gr. A), exercițiile oferite pot fi fie Începător, Intermediar, Avansat sau Expert, în timp ce în Grupa B (Gr. B), exercițiile vor fi doar din categoria Avansat.

Rezultate

Chiar dacă cel mai activ cursant din Grupa A s-a antrenat pentru 169 de pași, în analiza actuală am luat în considerare mediile a cel puțin trei cursanți la fiecare punct de date. Acesta este motivul pentru care numărul de pași de bandit din Figura 14 se oprește la 144, ultimul pas când erau trei utilizatori cu predicții. Putem afirma că, la fiecare User ID, numărul de cursanți la acel pas de bandit este egal cu valoarea acelui identificator (valoarea User ID). De exemplu, la pasul 153, 2 cursanți foloseau sistemul și, începând cu pasul 154, a rămas doar unul.




Figura 14. Recompense medii și Moving Average (dimensiune fereastră = 6 pași \approx 1 sesiune) Recompense per pas de bandit pentru cei mai buni atleți din Grupul A (> 11)

La fel și pentru pasul 78 de bandit, 8 cursanți foloseau sistemul, iar de la pasul 79 până la pasul 81 erau 7 cursanți și așa mai departe. În mod similar, pentru grupul B am calculat recompensa medie pentru toți cursanții la fiecare pas de predicție, dar, din cauza datelor limitate, am analizat între 3 și 11 sesiuni, care au acoperit un număr de 6 cursanți și am luat în considerare în analiză pașii în care cel puțin 2 atleți sunt implicați. Datele adunate din Grupul B nu sunt suficiente pentru a trage o concluzie asupra învățării bandiților din explorarea spațială mai mică, chiar dacă vedem o tendință generală de creștere. Ar fi necesare mai multe date pentru a justifica învățarea algoritmului bandit pentru acest grup. Tutorul A arată, totuși, rezultate promițătoare pentru cursanții care au urmat programul de formare pentru mai mult de 12 sesiuni.

8.4 Rezultate privind Experiența Utilizatorului

Testarea Selfit Versiunea 2 a durat 5 luni, între ianuarie și mai 2022, și a implicat 42 de stagiați, din Franța și România. S-au înscris în sistem la date diferite și s-au antrenat între 1 și 30 de ședințe, valoarea mediană a fost de 5 ședințe. Selfit Versiunea 2 nu a stocat date personale despre utilizator. S-au înscris în sistem cu un pseudonim, o parolă și o întrebare de securitate, ca o rezervă pentru uitarea parolei. După fiecare conectare în sistem, utilizatorii își puteau configura profilul, completând informații generale despre sexul, anul nașterii, biografia sau configurarea unei imagini de profil. Din cei 42 de utilizatori, doar 10 utilizatori au completat informațiile opționale din profilurile lor. Doar

Rezultate

biografia și câmpurile de imagine de profil au fost publice și vizibile pentru ceilalți membri înscriși în sistem. Toți utilizatorii au fost implicați în pre-test - provocarea de calibrare efectuată atunci când au început să se antreneze folosind Selfit. 10 dintre ei au finalizat și post-testul.

La sfârșitul lunii mai 2022, cursanții au primit un sondaj privind experiența utilizatorului de completat. Structura sondajului a fost aceeași cu cea descrisă în secțiunea anterioară, pentru Selfit Versiunea 1, bazată pe chestionarul AttrakDiff, și a inclus 9 noi întrebări, în care am urmărit să evaluăm forma de antrenament a utilizatorului, implicarea în experiment și câteva întrebări deschise privind percepția generală a utilizatorului. 21 de cursanți din cei 42 inițiali (50%) au completat chestionarul. Pe baza cunoștințelor noastre, cei mai mulți dintre cursanții implicați în experimentul Selfit Versiunea 1 au folosit și noua versiune și s-au instruit în perioada ianuarie-mai 2022.

Valorile chestionarului AttrakDiff pentru versiunea 2 Selfit pot fi văzute în Tabel 5. Valorile îngroșate marchează o diferență mai mare de 0,5 pe scara Liker cu 7 puncte între cele două evaluări. Putem afirma că experiența generală a utilizatorului s-a îmbunătățit în versiunea 2 a Selfit, deoarece mulți hedoniști și valori pragmatice ale calității sunt mai bune. Diferențele negative dintre cele două versiuni indică faptul că utilizatorii percep noul sistem ca un pic mai tehnic în ansamblu și simt că sistemul nu le îndeplinește nevoia de a reuni oamenii, componenta socială.

Tabel 5. Feedback despre Experiența Utilizatorului bazat pe Chestionarul AttrakDiff în *Selfit Version 2*.

UX Quality	M (SD)	UX Quality	M (SD)	UX Quality	M (SD)
Pleasant	5.90 (1.26)	Connective	4.14 (1.64)	Human	3.85 (1.38)
Inventive	5.76 (1.71)	Simple	5.66 (1.65)	Professional	6.0 (0.83)
Attractive	5.19 (1.56)	Practical	5.66 (1.42)	Likeable	5.95 (1.21)
Straightforward	5.52 (1.36)	Stylish	4.90 (1.44)	Predictable	4.66 (1.49)
Premium	4.76 (1.54)	Integrating	4.95 (1.29)	Brings people closer	4.05 (1.30)
Novel	5.47 (1.49)	Motivating	5.90 (0.74)	Captivating	5.40 (1.39)

Utilizatorii implicați în sondajul de experiență au fost rugați, de asemenea, să completeze câte antrenamente au efectuat în medie până în săptămâna anterioară și în timpul experimentului. 5 utilizatori implicați în testarea Selfit Versiunea 2 nu se antrenau deloc înainte de experiment (23,81%) și, de exemplu, 1 utilizator se antrena în fiecare zi a săptămânii (4,76%). În timpul experimentului, majoritatea utilizatorilor s-au antrenat fie de 2, fie de 3 ori pe săptămână, 5 utilizatori din fiecare categorie, 3 utilizatori s-au antrenat o singură dată pe săptămână, în timp ce același utilizator ca înainte de experiment a continuat să se antreneze de 7 ori pe săptămână.

9 Discuție

9.1 Avantaje ale Abordării noastre

OC1: Proiectați un model eficient de reprezentare a cunoștințelor pentru dezvoltarea abilităților psihomotorii într-un sistem inteligent de instruire.

Teza actuală introduce o ontologie pentru modelarea învățării în domeniul psihomotric, numită OntoStrength. Modelarea propusă este dedicată îmbunătățirii abilităților psihomotorii și abilităților bio-motorii asociate, cu o descriere mai cuprinzătoare a abilității de forță. OntoStrength a fost construit de echipa noastră cu expertiză interdisciplinară, cu experiență în domeniile musculare, biomecanice, antrenament sportiv și informatică.

A fost dezvoltat folosind Ontology 101 Methodology (OD101), SPARQL a fost folosit pentru interogări, iar vizualizările au fost implementate folosind baza de date cu grafice semantice GraphDB. OWL este limbajul formal de reprezentare, iar software-ul folosit pentru dezvoltare a fost Protégé.

OntoStrength a fost integrat și utilizat în continuare într-un sistem inteligent de îndrumare pentru dezvoltarea psihomotorie, numit Selfit. Cunoștințele descrise au fost mapate la componentele ITS. Modulul domeniul se adresează domeniului mișcării, luând în considerare mai întâi diversitatea activităților mișcării umane – viața de zi cu zi, petrecerea timpului liber sau profesională – și descrierea acestora – contracția musculară, mișcările articulațiilor corpului uman sau mișcările fundamentale. În al doilea rând, include profilul metabolic al mișcării cu durata și intensitatea acestuia. Mai mult, domeniul este legat și de regulile și constrângerile specifice de dezvoltare ale diferitelor subcompetențe utilizate de programul de dezvoltare.

Modulul de student are în vedere domeniul de evaluare a abilităților psihomotorii. Din această perspectivă, OntoStrength include indicatori de performanță și reguli de evaluare asociate pentru fiecare sub-competență luată în considerare de programul de dezvoltare. De asemenea, ontologia se adresează indicatorilor de performanță utilizați pentru a monitoriza răspunsurile cursanților la antrenamentul și pentru a ajusta programul planificat la realitatea efectelor aplicării acestuia.

Ontologia a fost dezvoltată în principal pe baza teoriei antrenamentului sportiv descrisă de Bompa (2017) și a lucrărilor recente din domeniul psihomotoriei, inclusiv a actualizărilor taxonomiei psihomotorii (Hoque, 2016), și a unor lucrări similare dezvoltate pentru alte cazuri de utilizare: Goldberg și colab. . (2018) – pentru pregătirea militară, sau PRB de Campos (2018) – pentru

Discuție

învățarea ingineriei. Cu toate acestea, OntoStrength are un rol central în teza actuală, deoarece a fundamentat dezvoltarea unui tutorat eficient și a elementelor redactate în interfața grafică cu utilizatorul.

OC2: Oferirea de recomandări personalizate de exerciții sportive pentru populația de masă atunci când se antrenează în medii deschise.

Numeroși factori externi ar putea influența fitnessul, oboseala și dorința de a se antrena, cum ar fi viața de zi cu zi, profesionale sau alte activități psihomotorii. Factorii externi care influențează conținutul instruirii sunt al patrulea set de caracteristici. Consecința este că fitness-ul și nivelul de oboseală al stagiului ar putea fi superioare sau inferioare stării asumate de sistemul de tutorat. În plus, atunci când încep o nouă sesiune de antrenament, utilizatorii pot fi răniți și incapabili să efectueze o parte din sarcinile de antrenament psihomotorie.

Pe lângă aceste caracteristici ale câmpului psihomotoric, tutorele ar trebui să decidă care este secvența optimă de activități care maximizează abilitățile generale ale nivelului mediu de competență pentru fiecare cursant. Acest lucru este dificil de abordat, deoarece utilizatorii au un timp limitat pentru a practica activitățile de formare – nu pot testa toate exercițiile disponibile pentru a vedea care sunt cele mai bune pentru ei și există diferențe individuale între cursanți – o sarcină de învățare care este optimă pentru un utilizator. poate fi inefficient pentru un alt utilizator cu un profil similar.

Implementarea noastră inițială într-un mediu simulat a arătat că această abordare de personalizare este eficientă și oferă secvențe de învățare de înaltă performanță după șase luni de pregătire continuă. Am evaluat efectul MaB contextual într-un experiment cu utilizatori reali, care a implicat 42 de utilizatori care s-au antrenat timp de 6 luni. Participanții au folosit una dintre cele două versiuni ale sistemului Selfit, cu două strategii adaptative – Tutor A cu un spațiu de explorare mai larg (exerciții simple și dificile prezentate utilizatorilor din Grupa A) și Tutor B, cu un spațiu de explorare îngust (doar curent exerciții la nivel de utilizator afișate utilizatorilor din Grupa B). Participanții au fost rugați să efectueze 12 sesiuni de antrenament, precum și o sesiune inițială și finală de calibrare.

Am observat că participanții din Grupa B au renunțat mult mai repede la antrenamente – niciun utilizator nu a efectuat programul complet de antrenament (11 sesiuni de antrenament pentru antrenorul de top din acest grup), în timp ce în Grupa A au fost 12 participanți care au urmat programul complet de antrenament și de asemenea, câțiva cursanți de top – primii trei au efectuat 30, 27 și 25 de sesiuni. Aceasta a fost o surpriză pentru noi, deoarece configurația inițială a experimentului presupunea o implicare similară în general și chiar și Grupul B a depășit timpul de antrenament al Grupului A.

Discuție

Constatările noastre evidențiază importanța diversității exercițiilor, printr-o explorare amplă, pentru a menține motivația de a antrena și a menține utilizatorul implicat. Rezultatele pentru cursanții de top au arătat o creștere a recompensei medii în timp și, deși nu au urmat planificarea exactă a antrenamentului ca pentru simulare, rezultatele experimentelor converg încet către simulări, ceea ce a fost în conformitate cu așteptările noastre. . Metoda Contextual MaB pentru personalizarea învățării în pregătirea psihomotorie a arătat rezultate promițătoare în ansamblu.

OC3: Implementarea unui modul de comunicare intuitiv și eficient care facilitează evaluarea progresului sportiv în medii deschise.

Abilitățile bune de comunicare sunt esențiale pentru oamenii care lucrează cu alți oameni și cu siguranță pentru profesori (Woolf, 2010). Lucrarea curentă introduce un modul de comunicare pentru a sprijini schimbul de informații între utilizatori și tutore, pentru a sprijini dezvoltarea abilităților psihomotorii. Modulul de comunicare interacționează cu celelalte trei componente ITS – module de domeniu, student și tutorat.

Modulul de comunicare propus are următoarele componente: (a) componentă de autentificare, (b) componentă de calibrare a stagiului, (c) componentă de feedback (autoevaluare – înainte și după sesiune, feedback la nivel de exercițiu, pentru fiecare set – feedback acut), și (d) componenta antrenamentului de antrenament (video care demonstrează mișcarea, configurarea antrenamentului, rezumatul antrenamentului, antrenamentele anterioare). Cursanților li se cere să creeze un cont la prima interacțiune cu sistemul Selfit. Nu sunt stocate date personale în profilul lor de utilizator.

Sub-modulul Calibrare Trainee este un set de interfețe componente care au rolul de a face schimb de informații cu utilizatorul pentru a-și estima nivelul actual în principalele zone de mișcare. Modulul de Calibrare include maximum 24 de exerciții de executat, câte 4 pentru fiecare zonă de mișcare, clasificate în funcție de dificultate (de la nivelul 1 la nivelul 4). Dacă un anumit nivel nu este promovat, exercițiile mai dificile din categoria respectivă – niveluri superioare – nu vor fi afișate. Pentru a trece de un anumit nivel, utilizatorul trebuie să vizioneze videoclipul cu acele exerciții specifice, să execute numărul de repetări afișat și apoi să introducă numărul de execuții pe care a putut să le execute. Calibrarea cursanților este necesară înainte de prima sesiune folosind Selfit și va fi disponibilă în orice moment pentru utilizatori pe pagina de pornire. Este recomandat să refaceți provocarea de calibrare după terminarea unui meci și să fiți într-o formă bună atunci când îl efectuați.

Discuție

Componenta antrenamentului de antrenament face schimb de informații cu cursantul despre programul de antrenament și include configurarea antrenamentului (locația de antrenament, timpul de antrenament, materialele disponibile, mușchii preferați să țintiți), pagina cu rezumatul antrenamentului, părțile anterioare ale listei de antrenament și fluxul de antrenament. În timpul antrenamentului, pentru fiecare exercițiu este afișat un videoclip care demonstrează mișcarea și detaliile necesare pentru a realiza sarcina corectă (adică, numărul de seturi, numărul de repetări, odihnă între repetări și între seturi).

Modulul de Comunicare implementat în cadrul sistemului Selfit a fost testat cu utilizatori reali și a fost realizat un sondaj privind experiența utilizatorilor folosind chestionarul AttrakDiff. 21 de utilizatori au completat chestionarul, iar feedbackul general a fost că Selfit a fost perceput ca fiind plăcut, inventiv, simplu și profesionist.

9.2 Limitări

Setul de date obținut în timpul colectării datelor nu se potrivește pe deplin cu dimensiunea simulărilor. Simulările efectuate în mediul virtual au demonstrat învățarea algoritmilor contextuali ai bandiților multi-armate. Acestea au arătat că utilizatorii ar trebui să se antreneze pentru cel puțin 48 de sesiuni pentru a avea o creștere vizibilă a recompensei medii între sesiuni, în timp ce în experimentul real, cel mai performant s-a antrenat de 30 de ori.

Chiar dacă am publicat sistemul pe magazinele mobile și pe internet și l-am pus la dispoziție în întreaga lume, gratuit, am avut un buget limitat pentru a-l promova și pentru a ajunge la un număr mare de persoane (42 de stagiați angajați). Teoria individualizării sportive aplică aceleași reguli în funcție de diferențele de vârstă și profesii, având în vedere descrierea profilului stagiatarului – gen, profil accidentări, boli. Descoperirile noastre susțin generalizarea sistemului până la un anumit grad.

În ceea ce privește colectarea datelor în timpul antrenamentului, măsurarea efortului perceput pentru fiecare exercițiu – repetări în rezervă (RIR) a fost evaluată folosind input-ul subiectiv din partea cursantului, care poate fi zgomotos. O măsurare mai precisă a efortului perceput este monitorizarea ritmului cardiac în timpul antrenamentului și corelarea cu intrarea RIR. Variabilitatea ritmului cardiac indică dacă utilizatorul se antrenează sau nu și care este oboseala aproximativă. Poate fi, de asemenea, un bun indicator al numărării repetărilor executate. Măsurarea ritmului cardiac necesită un dispozitiv inteligent extern, cum ar fi o bandă inteligentă, un ceas inteligent sau o curea pentru piept, pe care utilizatorii implicați în experiment l-au cerut în timpul antrenamentului.

Discuție

O altă limitare pe care o menționăm este complexitatea domeniului antrenamentului psihomotric de forță. Deși putem concluziona că am obținut o bună modelare a câmpului de forță, prin OntoStrength, care a fost evidențiată de rezultatele noastre, nu am mapat toți parametrii care influențează individualizarea antrenamentului sportiv. Acest lucru s-a datorat atât constrângerilor de timp, cât și cunoștințelor limitate despre expertiza interdisciplinară, cum ar fi dimensiunea alimentară, unde ne lipseau cunoștințele necesare.

De asemenea, o altă limitare este generată de dezvoltarea globală a sistemului Selfit, în ultimii 4 ani, care nu a fost testat intens și poate arunca bug-uri în unele cazuri marginale. Echipa noastră nu avea un inginer de asigurare a calității (QA) desemnat să dezvolte cazuri de testare și să le execute periodic. Acest lucru expune o vulnerabilitate a sistemului Selfit în general. O privire de ansamblu asupra tuturor fluxurilor disponibile și cazurilor marginale trebuie descrisă pentru orice software, pentru a avea o vedere mai bună a erorilor potențiale care pot apărea. Pe baza analizei Visual Studio folosind Calculatorul de metrice de cod, versiunea actuală a sistemului Selfit are 221.873 de linii de cod.

9.3 Aplicații preconizate

Prima parte a tezei are o natură mai teoretică, obiectivul fiind construirea bazei OntoStrength are o descriere cuprinzătoare a profilului psihomotric și planificarea programelor de antrenament, pentru fiecare fază – sesiune, microciclu, mezociclu și macrociclu. . Împreună cu o bază de date de peste 1.000 de exerciții care sunt etichetate în funcție de mușchii implicați, mișcări, articulații, materiale necesare, videoclipuri și dificultate, OntoStrength va fi publicat în curând sub o licență deschisă, iar baza de cunoștințe va fi disponibilă gratuit.

Lucrarea prezentată pentru OntoStrength poate fi folosită pentru a îmbunătăți anumite scenarii de învățare. Alte sisteme care vizează antrenamentul de forță pot reutiliza modelarea OntoStrength și pot extinde munca la alte domenii psihomotorii - cum ar fi rezistența sau flexibilitatea.

Abordarea noastră a introdus un algoritm care se bazează pe estimarea empirică a progresului de învățare, numit RiERiT – Right Exercise at the Right Time, implementat în Python. Această lucrare poate fi utilizată în alte scenarii de îndrumare adaptivă. Alte sisteme care implică o componentă adaptivă, în pregătirea psihomotorie, pot folosi abordarea actuală ca punct de plecare.

Modelul de interfață cu utilizatorul a fost construit ca un sistem monolitic, folosind stiva de tehnologie Microsoft – ASP.NET MVC. Sursa codului va fi publicată în curând public pe platforma GitLab. Caracteristicile specifice, cum ar fi provocările de calibrare, integrarea dispozitivelor

Discuție

portabile cu cei mai cunoscuți furnizori (Garmin, Fitbit), fluxul de sesiune și configurarea profilului de către utilizatori pot fi reutilizate de alți cercetători în sistemele lor.

În general, întrucât guvernele sunt din ce în ce mai interesate de sănătatea populației în masă, iar lipsa activității fizice este o preocupare mare pentru țările mai dezvoltate, ne imaginăm lucrările actuale ca fundament al unui proiect de cercetare la scară mai mare, pe parcursul anii următori, cu accent pe digitalizarea domeniului antrenamentului sportiv și dezvoltarea mai multor soluții care au ca scop îmbunătățirea stilului de viață atât al începătorilor, cât și al cursanților intermediari. Considerăm că momentul este potrivit pentru un astfel de proiect de cercetare, progresele tehnologice susțin dezvoltările necesare, iar echipa noastră de bază poate oferi expertiza pentru a conduce dezvoltarea soluțiilor relevante în continuare.

10 Concluzii

Activitatea fizică insuficientă este o problemă de sănătate publică globală, care afectează milioane de oameni din țările dezvoltate și în curs de dezvoltare (Guthold, Stevens, Riley, & Bull, 2018). Tranzițiile sociale, economice și de mediu au dus la inactivitate fizică și la cantități mari de timp petrecut stând pe scaun (Owen et al., 2020), care este asociat cu un risc crescut de boli comune netransmisibile, cum ar fi diabetul de tip 2, cardiovasculare. boli, dizabilități musculo-scheletice sau cancere majore.

Într-o societate care este din ce în ce mai interesată de sănătatea publică globală (McCuaig & Quennerstedt, 2018), scopul actualei teze a fost de a studia cum și dacă ITS-urile pot fi construite și utilizate pentru formarea abilităților psihomotorii. Lucrarea prezentată se află la intersecția a două domenii principale, Inteligența Artificială în Educație (AIED) și antrenamentul sportiv. Abordarea noastră a introdus o ontologie în domeniul psihomotric, numită OntoStrength, utilizată de ITS pentru modelarea cunoștințelor.

De asemenea, pe baza constrângerilor de antrenament ale utilizatorului – timp limitat, oboseală și motivație volatilă, am introdus o abordare de personalizare a îndrumării bazată pe bandiți multi-armate contextuali RL, care sa dovedit anterior a fi eficientă în scenarii educaționale. Simulările noastre au arătat rezultate promițătoare pentru utilizarea acestei abordări în antrenamentul psihomotorie, iar între ianuarie și iunie 2022 a fost efectuat un experiment cu utilizatori reali care a arătat potențialul metodei propuse, dar sunt încă necesare experimente suplimentare în acest domeniu. Următoarea secțiune descrie contribuțiile personale pe baza celor trei întrebări de cercetare formulate inițial. În continuare, sunt prezentate câteva direcții pentru cercetările viitoare.

10.1 Contribuții Personale

Dezvoltarea mai multor sisteme și contribuțiile în diverse domenii de cercetare – inclusiv informatica, modelarea cunoștințelor sau știința datelor, toate convergând într-o abordare unificată la intersecția dintre informatică, știința educației și știința sportului, sunt doar punctele de evidențiere ale teza actuală. Scopul cercetării noastre a fost să înțelegem care sunt principalele cerințe și implicații pentru digitizarea antrenamentului psihomotoriu folosind sisteme inteligente de îndrumare. Munca noastră oferă o abordare interdisciplinară, acoperind:

- *informatică*, cu accent pe învățare prin consolidare ca suport pentru tutoratul adaptiv și inginerie informatică pentru dezvoltarea interfeței și modelarea comunicării;

Concluzii

- *științe educaționale*, pentru sistemele inteligente de îndrumare-cazuri de studiu, pentru a discuta transferabilitatea și implicațiile asupra domeniului psihomotric;
- *știința sportului*, pentru fundamentarea bazei de cunoștințe și dezvoltarea modelării folosind abordarea ontologică.

Lucrarea preliminară a acestei cercetări a fost o revizuire sistematică a literaturii despre sistemele inteligente de îndrumare pentru formarea psihomotorie, care a fost publicată la Conferința Intelligent Tutoring Systems la începutul anului 2020, iar lucrarea a fost citată și utilizată de alți cercetători din întreaga lume în proiecte similare. Teza a propus alte trei sisteme, OntoStrength, RiARiT și Selfit, care au fost dezvoltate de autor, sub îndrumarea directă a ambilor conducători de teză: Sébastien Travadel și Răzvan Rughiniș. În ceea ce privește baza de cunoștințe, cunoștințele din domeniul antrenamentului de forță au fost dezvoltate împreună cu trei membri ai centrului de cercetare MINES ParisTech – Vincent Guarnieri, care deține un master în științe ale sportului și antrenor de antrenament sportiv, și Eric Rigaud, cercetător, deținând un doctorat. antrenor în informatică și atletism, și Didier Delaitre – cercetător, doctor în medicină legală.

Cunoștințele dezvoltate de specialiștii în sport au fost ulterior modelate și integrate în software-ul Protégé de Laurențiu Neagu și Eric Rigaud. Ontologia a fost exportată în continuare în format .owl, distribuită echipei noastre și vizualizată inițial utilizând WebVOWL - Vizualizarea Ontologiilor bazată pe web, apoi folosind GraphDB. Versiunea inițială a ontologiei a fost publicată și acceptată ca lucrare completă la Simpozionul GIFT din 2020. În anii următori a fost dezvoltată o versiune actualizată, de asemenea, a fost dezvoltat un strat de integrare REST în tehnologia .NET Core, folosind limbajul de programare C#, care permite OntoStrength să interacționeze cu alte sisteme.

A doua contribuție, RiARiT, a fost o metodă propusă de personalizare a secvenței de învățare în pregătirea psihomotorie. Această metodă a implicat utilizarea algoritmilor contextuali ai bandiților cu arme multiple pentru a oferi recomandări de exerciții sportive în timpul antrenamentului. Acesta este primul nivel de adaptare pe care l-am imaginat – numit Novice Trainer – și folosește șabloane de sesiuni de antrenament care sunt completate de recomandări de exerciții. RiARiT a fost inițial simulat cu populații de cursanți virtuali și a arătat potențialul abordării. Această metodă a fost publicată la Conferința Intelligent Tutoring Systems din 2021. RiARiT a fost integrat în continuare în componenta de tutorare a unui sistem de dezvoltare psihomotorie și testat cu utilizatori reali.

A treia contribuție, Selfit, a fost construită peste cele două anterioare. Selfit este un prototip de sistem de tutorat inteligent care folosește modelul de cunoștințe OntoStrength și modulul de personalizare RiARiT pentru a prezenta potențialul unui astfel de sistem în dezvoltarea psihomotorie. Modulul de

Concluzii

interfață cu utilizatorul a fost dezvoltat în întregime de autorul tezei și, folosind framework-ul ASP.NET MVC și limbajul de programare C#.

Echipa de oameni de știință din sport a dezvoltat în continuare un protocol de calibrare personalizat, mai specific decât testul FMS, care a fost implementat în următoarea versiune a sistemului Selfit. De asemenea, în această versiune, utilizatorii nu au fost obligați să se înregistreze pe ei înșiși în timpul efectuării calibrării, ci doar puteau introduce manual efortul perceput. De asemenea, a fost implementat un modul de viziune computerizată, separat de sistemul Selfit, pentru a evalua riscul de accidentare pentru sportivele de sex feminin. Acest experiment a folosit OpenCV³ pentru a urmări unghiurile de mișcare și pentru a evalua riscul de răni. Această implementare nu a fost integrată în Selfit, deoarece OpenCV nu poate fi adăugat direct la aplicația mobilă și nu funcționează în timp real. Este nevoie de videoclipuri înregistrate, offline pentru a face o analiză. Pentru scopul experimentului, am explorat potențialul vederii computerizate asupra evaluării psihomotorii și am publicat munca noastră ca o lucrare completă la conferința Smart Learning Ecosystems and Regional Development (SLERD) din 2021⁴.

Versiunea finală rafinată a Selfit, care a fost testată cu utilizatori reali în perioada ianuarie-mai 2022, cu mai multe caracteristici care îmbogățesc experiența generală a utilizatorului (mod automat, o diagramă cu progresul zonei corpului, configurația antrenamentului specific acasă și la sală, exerciții preferate, rulare). /schimbați un exercițiu și altele) a fost publicat pentru al treilea an consecutiv la Conferința Intelligent Tutoring Systems din 2022. În concluzie, considerăm că obiectivul inițial de a evalua cerințele și implicațiile construirii unui sistem de tutorat inteligent pentru dezvoltarea psihomotorie a fost abordat prin multitudinea de sarcini de învățare implementate și un astfel de sistem are un mare potențial în domeniu.

10.2 Direcții pentru Cercetări Ulterioare

O direcție care necesită îmbunătățiri suplimentare este acuratețea evaluării utilizatorilor. Metoda implementată în teza actuală pentru evaluarea progresului utilizatorului se bazează pe introducerea manuală a utilizatorului a efortului perceput. Numărul de repetări în rezervă este raportat direct de fiecare utilizator. O metodă care are potențialul de a fi mai precisă pentru evaluarea efortului utilizatorului pe exercițiu este prin corelarea ecranului curent Selfit afișat și valoarea raportată a

³ <https://opencv.org>

⁴ <http://slerd2019.uniroma2.it>

Concluzii

ritmului cardiac printr-un purtabil. Ar fi necesară integrarea cu principalii producători de purtabile și sincronizarea în cadrul sesiunii de instruire.

Variabilitatea ritmului cardiac este un bun indicator al efortului perceput, atât acut cât și cronic (efecte pe termen scurt și pe termen lung). Această metodă poate fi utilizată împreună cu introducerea utilizatorului. Am inițiat dezvoltarea acestui modul care permite în prezent integrarea datelor Garmin și Fitbit, dar nu face corelarea cu exercițiile efective din sesiune. De asemenea, acest modul ar trebui să fie opțional și să acționeze doar ca o îmbunătățire a preciziei evaluării pentru utilizatorii care au astfel de dispozitive portabile și sunt de acord să partajeze aceste date sensibile.

O altă metodă de evaluare a utilizatorului și, de asemenea, o îmbunătățire a experienței generale a utilizatorului este integrarea unui modul de viziune computerizată. Acest modul își propune să măsoare numărul de repetări corecte executate și să pornească automat cronometrul timpului de odihnă și să treacă la următorul exercițiu când este finalizat numărul necesar de execuții. Funcția de viziune computerizată este utilă pentru a calcula numărul de repetări atunci când cursantul efectuează mai puțin decât numărul de repetări necesar.

Un alt domeniu pe care să se concentreze în continuare este extinderea personalizării îndrumării de la formatorul începător la antrenorul intermediar și avansat. Versiunea actuală a tutorelui adaptiv poate personaliza secvența de învățare la nivel de exercițiu, folosind șabloane de sesiune predefinite. Trainerul Intermediar ar trebui să poată descoperi sesiuni optime (mișcări de antrenat și ordinea exercițiilor de antrenat), generate de diferite seturi de reguli, dar nepredefinite, și ar trebui să fie folosit împreună cu antrenorul Novice. Trainerul avansat ar trebui să poată genera microcicluri, mezocicluri și macrocicluri pentru fiecare utilizator și să nu folosească șabloane predefinite.

O îmbunătățire a sistemului propus este integrarea dimensiunii alimentare. Programele de formare ar trebui să ia în considerare ceea ce mănâncă și bea oamenii. Recomandările privind planurile de masă și nutriție, bazate pe profilul cursantului, vor îmbunătăți eficacitatea generală a antrenamentului. Dimensiunea alimentară va necesita actualizări privind modelarea cunoștințelor și modulul de interfață cu utilizatorul.

Selfit este folosit în prezent pentru antrenamentul de forță. Alte direcții de antrenament, cum ar fi flexibilitatea sau rezistența, sunt, de asemenea, de mare interes, în special pentru persoanele cu probleme medicale care îi împiedică să urmeze un program de antrenament de forță. Dezvoltarea noilor direcții de formare este deja punctul nostru de interes în cercetările viitoare. Modulul de flexibilitate este în prezent în curs de dezvoltare și va fi lansat în lunile următoare.

Listă de Publicații

ISI Proceedings

1. Neagu, L.-M., Cotet, T.-M., Dascalu, M., Trausan-Matu, S., Badescu, L., & Simion, E. (2019a). Semantic Author Recommendations based on their Biography from the General Romanian Dictionary of Literature. In 7th Int. Workshop on Semantic and Collaborative Technologies for the Web, in conjunction with the 15th Int. Conf. on eLearning and Software for Education (eLSE 2019) (pp. 165–172). Bucharest, Romania: “CAROL I” National Defence University Publishing House. (WOS: 000473322400022) *
2. Neagu, L.-M., Rigaud, E., Travadel, S., Dascalu, M., Rughinis, R.-V. (2020). Intelligent Tutoring Systems for Psychomotor Training – A Systematic Literature Review. In: 16h Int. Conf. on Intelligent Tutoring Systems (ITS 2020) (pp. 335-341). Springer, Online. (WOS: 000720068400040)
3. Neagu, L.-M., Toma, I., Dascalu, M., Trausan-Matu, S., Hanganu, L., & Simion, E. (2020). A Quantitative Analysis of Romanian Writers’ Demography Based on the General Dictionary of Romanian Literature. In 5th Int. Conf. on Smart Learning Ecosystems and Regional Development (SLERD 2020) (pp. 253–261). Bucharest, Romania (Online): Springer. (WOS: 000783452900022) *
4. Neagu, L.-M., Rigaud, E., Guarnieri, V., Travadel, S., Dascalu, M. (2021). Selfit – An Intelligent Tutoring System for Psychomotor Development. In: 17th Int. Conf. on Intelligent Tutoring Systems (ITS 2021). Springer, Athens, Greece (Online). (WOS: 000718916000032)

BDI Proceedings

1. Neagu, L.-M., Cotet, T.-M., Dascalu, M., Trausan-Matu, S., Chisu, L., & Simion, E. (2019). Semantic Recommendations and Topic Modeling based on the Chronology of Romanian Literary Life. In 12th Int. Workshop on Social and Personal Computing for Web-Supported Learning Communities (SPeL 2019) held in conjunction with the 18th Int. Conf. on Web-based Learning (ICWL 2019) (pp. 164–174). Magdeburg, Germany: Springer *
2. Neagu, L.-M., Dascalu, M., Trausan-Matu, S., Chisu, L., & Simion, E. (2020). Automated Modeling of Romanian Literary Trends in History using Topics over Time and Co-Occurrences. In 8th Int. Workshop on Semantic and Collaborative Technologies for the Web, in conjunction with the 16th Int. Conf. on eLearning and Software for Education (eLSE 2020) (pp. 151–158). Online: “CAROL I” National Defence University Publishing House. *
3. Neagu, L.-M., Guarnieri, V., Rigaud, E., Travadel, S., Dascalu, M., Rughinis, R.-V. (2020). An Ontology for Motor Skill Acquisition Designed for GIFT. Proceedings of the 8th Annual Generalized Intelligent Framework for Tutoring (GIFT) Users Symposium (GIFTSym8). Online.
4. Toma, I., Neagu, L.-M., Dascalu, M., Trausan-Matu, S., Hanganu, L., Simion, E.. (2020). Emerging Patterns in Romanian Literature and Interactive Visualizations based on the General Dictionary of

Listă de Publicații

- Romanian Literature. In International Conference on Human-Computer Interaction (RoCHI2020): 91-103. Online: MatrixRom. *
5. Neagu, L.-M., Rigaud, E., Guarnieri, V., Matei, G.-D., Travadel, S., Dascalu, M.: Selfit – Accounting for Gender Differences in Personalized Motor Skills Learning. In: 6th Int. Conf. on Smart Learning Ecosystems and Regional Development (SLERD 2021). Springer, Bucharest, Romania (Online) (2021)
 6. Neagu, L.-M., Rigaud, E., Guarnieri, V., Dascalu, M., Travadel, S.: Selfit v2 – Challenges Encountered in Building a Psychomotor Intelligent Tutoring System. In: 18th Int. Conf. on Intelligent Tutoring Systems (ITS 2022). Springer, Bucharest, Romania (Online)
 7. Scheibenzuber, C., Neagu, L.-M., Ruseti, S., Artmann, B., Bartsch, C., Kubik, M., Dascalu, M., Trausan-Matu, S., Nistor, N.: Fake News Framing, Emotion, Argumentation, and Dialogic Social Knowledge Building in Online Discussions: An Exploration Including Natural Language Processing Data. In: 15th International Conference on Computer-Supported Collaborative Learning (CSCL) 2022. Hiroshima, Japan (Online)

Jurnale

Jurnale ISI

1. V. Pojoga, Neagu, L.-M., M. Dascalu (2020). The Character Network in Liviu Rebreanu's Ion: A Quantitative Analysis of Dialogue. *Metacritic Journal for Comparative Studies and Theory*, 6, 2, 23–47. *
2. Neagu, L.-M., Rigaud, E., Guarnieri, V., Radu, E.I., Travadel, S., Dascalu, M., Rughinis, R. (2022). *OntoStrength: An Ontology for Psychomotor Strength Development*. *IxD&A (Interaction Design and Architecture (s)) Journal*, 52, 101-118.

Patente

1. Ruseti, S., Neagu, L.-M., Toma, I., & Dascalu, M. (2021). *Metodă de Învățare Automată de Reprezentări Vectoriale în Grafuri de Cunoștințe pornind de la Modele de Limbă*. Romania. Cererea A/100184 / 19.04.2021. OSIM. *

Publicațiile marcate cu * sunt studii realizate în cadrul mai multor proiecte de cercetare la Universitatea Politehnică din București, care nu sunt direct legate de teza actuală.

Referințe

- Aleven, V., McLaren, B. M., Sewall, J., & Koedinger, K. R. (2009). A new paradigm for intelligent tutoring systems: example-tracing tutors. *International Journal of Artificial Intelligence in Education*, 19(2), 105-154.
- Ausin, M. S., Azizsoltani, H., Barnes, T., & Chi, M. (2019). Leveraging deep reinforcement learning for pedagogical policy induction in an intelligent tutoring system. *Proceedings of the Twelfth International Conference on educational data mining*, 168-177.
- Baron-Cohen, S., Knickmeyer, R. C., & Belmonte, M. K. (2005). Sex differences in the brain: implications for explaining autism. *Science*, 310(5749), 819-823.
- Becker, H. J. (2000). Findings from the Teaching, Learning, and Computing Survey: Is Larry Cuban Right? *Education Policy Analysis Archives*, 8(51).
- Bilodeau, E., & Bilodeau, I. (1961). Motor-skills learning. *Annual Reviews of Psychology*, 12, 243–280.
- Biørn-Hansen, A., Majchrzak, T. A., & Grønli, T.-M. (2017). Progressive web apps: The possible web-native unifier for mobile development. *Proceedings of the 13th International Conference on Web Information Systems and Technologies*, 1, 344–351.
- Bompa, T., & Buzzichelli, C. (2017). Periodization: Theory and Methodology of Training. *Human Kinetics Publishers, Sixth édition*.
- Brown, A. L., Collins, A., & Duguid, S. (1989). Situated cognition and the culture of learning. *Educational Researcher*, 18(1), 32–42.
- Cao, Z. H., G., Simon, T., Wei, S.-E., & Sheikh, Y. (2018). OpenPose: realtime multi-person 3D pose estimation using Part Affinity Fields. *arXiv preprint arXiv:1812.08008*.
- Clement, B., Roy, D., Oudeyer, P.-Y., & Lopes, M. (2015). Multi-Armed Bandits for Intelligent Tutoring Systems. *Journal of Educational Data Mining (JEDM)*, 7.
- Dieste, O., Grimán, A., & Juristo, N. (2009). Developing search strategies for detecting relevant experiments. *Empirical Software Engineering*, 14(5), 513-539.
- Dlamini, M., & Leung, W. S. (2018). Evaluating Machine Learning Techniques for Improved Adaptive Pedagogy. *IST-Africa Week Conference, IST-Africa, IEEE*, 1.
- Fensel, D. (2001). Ontologies. *Springer, Heidelberg*, 11-18.
- Fenza, G., & Orciuoli, F. (2016). Building pedagogical models by formal concepts analysis. *Proc 13th Int. Conf. Intelligent Tutoring Systems (ITS)*, 9684, 144-153.

Referințe

- Goldberg, B., Amburn, C., Ragusa, C., & Chen, D.-W. (2018). Modeling expert behavior in support of an adaptive psychomotor training environment: A marksmanship use case. *International Journal of Artificial Intelligence in Education, 28*(2), 194–224.
- Guthold, R., Stevens, G. A., Riley, L. M., & Bull, F. C. (2018). Worldwide trends in insufficient physical activity from 2001 to 2016: a pooled analysis of 358 population-based surveys with 1.9 million participants. *Lancet Glob Health, 6*(10).
- Hackett, D. A., Johnson, N. A., Halaki, M., & Chow, C.-M. (2012). A novel scale to assess resistance-exercise effort. *Journal of Sports Sciences, 30*:13, 1405-1413. doi:10.1080/02640414.2012.710757
- Hambleton, R. K., Swaminathan, H., & Rogers, H. J. (1991). Fundamentals of item response theory. *Sage, 2*.
- Hoque, M. E. (2016). Three Domains of Learning: Cognitive, Affective and Psychomotor. *The Journal of EFL Education and Research (JEFLER), 2*.
- Joyce, D., & Lewindon, D. (2016). Sports Injury Prevention and Rehabilitation. Integrating medicine and science for performance solutions. *Taylor and Francis*.
- Kirchengast, S. (2010). Gender Differences in Body Composition from Childhood to Old Age: An Evolutionary Point of View. *Journal of Life Sciences, 2*(1), 1-10. doi:10.1080/09751270.2010.11885146
- LaViola, J., Williamson, B., Brooks, C., Veazanchin, S., Garrity, P., & Sottolare, R. (2015). Using Augmented Reality to Tutor Military Tasks in the Wild. *Interservice/Industry Training, Simulation, and Education Conference (I/ITSEC)*, 1–10.
- Li, R. (2014). Why women see differently from the way men see? A review of sex differences in cognition and sports. *Journal of sport and health science, 3*(3), 155-162.
- Liutsko, L., Muiños, R., Tous Ral, J. M., & Contreras, M. J. (2020). Fine Motor Precision Tasks: Sex Differences in Performance with and without Visual Guidance across Different Age Groups. *Behavioral Sciences, 10*(1), 36.
- Lu, T. P., D., & Pal, M. (2010). Contextual Multi-Armed Bandits. *Proceedings of the 13th international conference on Artificial Intelligence and Statistics, 9*, 485–492.
- Ma, W., Adesope, O. O., Nesbit, J. C., & Liu, Q. (2014). Intelligent tutoring systems and learning outcomes: A meta-analysis. *Journal of Educational Psychology, 106*(4), 901.
- Mark, M. A., & Greer, J. E. (1993). Evaluation methodologies for intelligent tutoring systems. *Journal of Artificial Intelligence In Education, 4*, 129–153.
- McCuaig, L., & Quennerstedt, M. (2018). Health by stealth—exploring the sociocultural dimensions of salutogenesis for sport, health and physical education research. *Sport, education and society*.
- Mousavinasab, E., Zarifsanaiy, N., Niakan Kalhori, S. R., Rakhshan, M., Keikha, L., & Ghazi Saeed, M. (2018). Intelligent tutoring systems: A systematic review of characteristics, applications, and evaluation methods. *Interact. Learn. Environ.*, 1-22.

Referințe

- Murray, T. (1999). Authoring Intelligent Tutoring Systems: An analysis of the state of the art. *International Journal of Artificial Intelligence in Education (IJAIED)*, 98-129.
- Neagu, L.-M., Rigaud, E., Travadel, S., Dascalu, M., & Rughinis, R.-V. (2020). *Intelligent Tutoring Systems for Psychomotor Training – A Systematic Literature Review*. Paper presented at the 16h Int. Conf. on Intelligent Tutoring Systems (ITS 2020), Online.
- Nkambou, R., Bourdeau, J., Mizoguchi, R. (2010). Introduction: What Are Intelligent Tutoring Systems, and Why This Book. *Advances in Intelligent Tutoring Systems*, 1-12.
- Noy, N. F., & McGuinness, D. L. (2001). *Ontology Development 101: A Guide to Creating Your First Ontology*. Retrieved from Stanford, CA, USA:
- Orey, M. A., Nelson, W.A. (1993). Development Principles for Intelligent Tutoring Systems: Integrating Cognitive Theory into the Development of Computer-Based Instruction. *Association for Educational Communications and Technology*, 41.
- Owen, N., Healy, G. N., Dempsey, P. C., Salmon, J., Timpero, A., Clark, B. K., . . . Lambert, G. (2020). Sedentary behavior and public health: integrating the evidence and identifying potential solutions. *Annu. Rev. Public Health*, 41 265-287.
- Paviotti, G., Rossi, P.G., Zarka, D. (2012). Intelligent tutoring systems: an overview. *Pensa Multimedia*.
- Pitchers, G., & K., E.-S. (2019). Considerations for coaches training female athletes. *PROFESSIONAL STRENGTH & CONDITIONING, Training Female Athletes*, 19-30.
- Polson, M. C., & Richardson, J. J. (1988). Foundations of Intelligent Tutoring Systems. *Lawrence Erlbaum Associates, Hillsdale*, 79-108.
- Prud'hommeaux, E., & Seaborne, A. (2008). SPARQL query language for RDF. W3C Recommendation. In: World Wide Web Consortium.
- Rajšp, A., & Fister, I. (2020). A systematic literature review of intelligent data analysis methods for smart sport training. *Appl. Sci.*, 10, 3013.
- Ropelato, S., Zund, F., Magnenat, S., Menozzi, M., & Sumner, R. (2018). Adaptive tutoring on a virtual reality driving simulator. *1st Workshop on Artificial Intelligence Meets Virtual and Augmented Worlds (AIVRAR) in Conjunction with SIGGRAPH Asia*.
- Rygula, I. (2005). Artificial neural networks as a tool of modeling of training loads. *Proceedings of the 2005 IEEE engineering in medicine and biology 27th annual conference*, 1-4.
- Self, J., & Akhras, F. (2002). Beyond intelligent tutoring systems: situations, interactions, processes and affordances. *Instructional Science*, 30, 1-30.
- Shephard, R. J. (2000). Exercise and training in women, Part I: Influence of gender on exercise and training responses. *Can J Appl Physiol*, 25(1), 19-34. doi:10.1139/h00-002

Referințe

- Simon, T., Joo, H., Matthews, I., & Sheikh, Y. (2017). Hand Keypoint Detection in Single Images Using Multiview Bootstrapping. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 1145-1153.
- Somerson, J. S., Isby, I. J., Hagen, M. S., Kweon, C. Y., & Gee, A. O. (2019). The Menstrual Cycle May Affect Anterior Knee Laxity and the Rate of Anterior Cruciate Ligament Rupture: A Systematic Review and Meta-Analysis. *JBJS Rev.*, 7(9). doi:10.2106/JBJS.RVW.18.00198
- Sottolare, R., Graesser, A., Hu, X., & Holden, H. (2013). Design recommendations for Intelligent Tutoring Systems: learner modeling (vol. 1). *Orlando, FL: U.S. Army Research Laboratory*.
- Spielholz, P. (2006). Calibrating Borg scale ratings of hand force exertion. *Applied Ergonomics*, 37, 615-618.
- Sutton, R. S., & Barto, A. G. (2018). Reinforcement Learning: An Introduction. *MIT Press*, 398.
- Woolf, B. P. (2010). Building Intelligent Interactive Tutors: Student-centered Strategies for Revolutionizing e-Learning. *Morgan Kaufmann Publishers*.
- Zouaq, A., & Nkambou, R. (2010). A survey of domain ontology engineering: Methods and tools. *Advances in Intelligent Tutoring Systems, Springer-Verlag, Berlin Heidelberg*, 103–119.