

UNIVERSITATEA DE VEST DIN TIMIȘOARA
FACULTATEA DE ȘTIINȚE ALE GUVERNĂRII ȘI
COMUNICĂRII

PROGRAMUL DE STUDII DE MASTERAT:
COMUNICARE PUBLICITARĂ ÎN MEDII DIGITALE

LUCRARE DE CERCETARE

**Învățarea adaptivă și predicția
abandonului în educația online**

Disciplină fundamentală:

**Metode avansate de cercetare în
științele comunicării**

COORDONATOR :

Lect. Dr. Silvia FIERĂSCU

STUDENȚI:

Laura Bianca CIOBOTARU

Călin IGNAT

TIMIȘOARA, 2025

semestrul II

CUPRINS

Introducere	3
1. Context & întrebare de cercetare:	5
1.1 Definirea temei și a conceptelor cheie	5
1.2 Problematizare: Ce știm deja? Ce nu știm?	5
1.3 Întrebarea de cercetare	10
2. Răspunsuri existente & ipoteze	11
3. Date & design cercetare	13
3.1 Sursa și descrierea datasetului	13
4. Analiză& rezultate.....	15
4.1 Analiza descriptivă a variabilelor.....	15
4.1.2 Nivel de educație	16
4.1.3 Performanță academică	17
4.1.4 Stiluri de învățare și engagement	18
4.1.5 Dropout și stil cognitiv.....	18
4.1.6 Evoluție scoruri (quiz → final)	19
4.1.7 Participare activă: forumuri și quizuri	19
4.1.8 Comportamente + rezultate (engagement + completare).....	20
4.1.9 Predicția abandonului în funcție de stilul de învățare	21
5. Discuții, implicații & concluzii	26
5.1 Principalele concluzii	26
5.3 Limitări	27
5.4 Implicațiile rezultatelor pentru societate	27
5.5 Recomandări.....	28
Referințe bibliografice.....	29

Introducere

În ultimii ani, digitalizarea educației a cunoscut o expansiune accelerată, determinată atât de progresele tehnologice, cât și de nevoia tot mai mare de acces flexibil la resurse educaționale. Platformele online au devenit instrumente esențiale pentru învățare, permițând cursanților să studieze oricând și oriunde. Tot mai multe studii subliniază că eficiența platformelor digitale depinde nu doar de cantitatea de resurse oferite, ci mai ales de capacitatea lor de a răspunde diferențiat la nevoile și ritmurile fiecărui utilizator. Cu toate acestea, simpla disponibilitate a informației nu garantează succesul educațional, iar adaptarea procesului de învățare la nevoile individuale ale cursanților rămâne un deziderat insuficient atins.

În acest context, învățarea adaptivă se conturează ca o soluție promițătoare pentru creșterea eficienței educației online. Prin ajustarea conținutului, a ritmului și a formatului materialelor în funcție de caracteristicile și comportamentul fiecărui cursant, aceste sisteme pot oferi o experiență educațională personalizată. Cu toate acestea, în pofida acestor progrese, persistă o problemă majoră: rata ridicată de abandon a cursurilor online. Aceasta afectează în special cursanții cu nivel redus de angajament sau cu stiluri de învățare necorelate cu metodele utilizate în platforme. Numeroase cercetări sugerează că stilurile de învățare influențează nu doar retenția informației, ci și nivelul de motivație și angajament în medii educaționale digitale. În plus, optimizarea intervențiilor personalizate nu este doar o chestiune de eficiență educațională, ci și de echitate, asigurând că fiecare cursant beneficiază de șanse reale de reușită, indiferent de stilul său de învățare sau nivelul de pregătire inițial.

Scopul acestei cercetări este de a analiza în ce măsură comportamentul online al studenților, măsurat prin indicatori precum timpul petrecut pe platformă, scorurile la teste, stilul de învățare sau participarea în forumuri, poate servi ca predictor pentru probabilitatea de abandon a cursurilor. Analiza va folosi metode de regresie și clasificare pentru a construi un model predictiv al comportamentului educațional, cu scopul de a identifica din timp riscul de abandon și de a sprijini intervenții educaționale personalizate.

Lucrarea va fi structurată în cinci părți. Prima parte va introduce tema, contextul și întrebarea de cercetare. În a doua parte, va fi analizată literatura de specialitate privind învățarea adaptivă și abandonul în educația online, formulându-se ipotezele de cercetare. A treia parte va descrie metodologia utilizată, incluzând un set de date furnizat de o platformă de învățare online, care surprinde interacțiunile și performanțele a peste 10.000 de cursanți. În a patra parte, se va

realiza analiza cantitativă a datelor, prezentând rezultatele obținute. Ultima parte va discuta implicațiile practice, teoretice și etice ale rezultatelor, concluziile cercetării și posibile direcții de aprofundare ulterioară.

Pentru a înțelege mai bine mecanismele care conduc la abandonul cursurilor online, cercetarea se va concentra pe identificarea celor mai relevanți factori comportamentali și cognitivi implicați în acest proces. Astfel, se va analiza modul în care variabile precum frecvența interacțiunii cu materialele video, nivelul de participare la activitățile de tip forum sau rata de finalizare a temelor se corelează cu performanțele academice și cu decizia de a continua sau nu parcursul educațional. Ipoteza de lucru pornește de la premisa că un angajament activ în procesul de învățare, reflectat printr-un comportament susținut pe platformă, este asociat cu o probabilitate mai redusă de abandon.

Un alt obiectiv important al studiului este investigarea rolului stilurilor de învățare în succesul educațional. Prin includerea variabilei *Learning_Style*, se va examina dacă preferințele cognitive (vizual, auditiv, citire/scriere sau kinestezic) influențează nivelul de implicare și performanțele obținute în contextul digital. Înțelegerea acestor relații poate contribui la dezvoltarea unor mecanisme de personalizare care să țină cont nu doar de datele de performanță, ci și de modul specific în care fiecare cursant procesează informația. Această abordare ar permite adaptarea conținutului și a formatului livrat, crescând astfel motivația și retenția.

Pe lângă analiza relațiilor dintre variabile, cercetarea va pune accent și pe partea predictivă, prin construirea unui model capabil să anticipeze riscul de abandon pe baza comportamentului observat. Prin utilizarea unor tehnici statistice precum regresia logistică și algoritmi de clasificare (de exemplu, Random Forest sau KNN), modelul va încorpora atât variabile cantitative, cât și categorice, în scopul identificării tiparelor de risc. Un astfel de instrument ar putea fi ulterior integrat în platformele educaționale pentru a furniza alerte timpurii și pentru a direcționa intervențiile educaționale acolo unde sunt cel mai necesare.

În final, cercetarea nu își propune doar o contribuție teoretică, ci și una practică și etică. Rezultatele pot fundamenta strategii de intervenție diferențiată, sprijinind dezvoltarea unor soluții educaționale mai echitabile și incluzive. Într-un peisaj educațional din ce în ce mai digitalizat, în care cursanții vin cu așteptări și nevoi diverse, capacitatea de a anticipa dificultățile și de a oferi sprijin personalizat poate face diferența între abandon și reușită. Astfel, studiul propus contribuie la consolidarea unui model educațional centrat pe cursant, bazat pe date și orientat spre reducerea inegalităților în accesul și succesul în învățare.

1. Context & întrebare de cercetare:

1.1 Definirea temei și a conceptelor cheie

În contextul educației online, „**dropout**” se referă la întreruperea cursului de către un participant înainte de finalizare. Acest fenomen reflectă adesea un deficit de motivație, dificultăți de adaptare sau o nepotrivire între așteptările cursantului și oferta educațională a platformei.

Engagement-ul educațional descrie nivelul de implicare activă al cursantului cu platforma, materialele și comunitatea de învățare. În cadrul acestei cercetări, engagement-ul este **operaționalizat prin variabilele:** `Time_Spent_on_Videos`, `Forum_Participation` și `Assignment_Completion_Rate`.

Stilul de învățare reflectă preferințele cognitive individuale în procesul de achiziție a informației, cum ar fi modalitățile **vizuală, auditivă, kinestezică sau citit/scris** și este măsurat în acest studiu prin variabila `Learning_Style`.

1.2 Problematizare: Ce știm deja? Ce nu știm?

A. Dimensiunea fenomenului - cât de gravă este problema abandonului?

Abandonul cursanților din mediul educațional digital este o problemă majoră, cu implicații profunde atât la nivel individual, cât și instituțional. Potrivit unui raport al Holme & Tuomi (2022), rata de abandon în cadrul MOOC-urilor (Massive Open Online Courses) depășește frecvent 85%, o proporție îngrijorătoare care ridică întrebări despre eficiența actualelor metode de învățare online. De exemplu, platforme precum Coursera și edX raportează frecvent că mai puțin de 10% dintre cei înscriși finalizează efectiv cursurile.

Această rată ridicată de abandon nu este doar un indicator al eșecului individual, ci semnalează și ineficiența unor politici publice și inițiative educaționale costisitoare. Inechitatea educațională este accentuată de faptul că persoanele din medii socio-economice vulnerabile sunt cele mai afectate, deoarece abandonul poate însemna și pierderea unor oportunități reale de dezvoltare profesională. În acest context, abandonul devine nu doar o problemă educațională, ci și una socială și economică.

B. Factorii comportamentali - ce comportamente pot prezice abandonul?

Literatura de specialitate subliniază tot mai clar faptul că anumite comportamente online pot servi drept indicatori timpurii ai riscului de abandon. Timpul petrecut pe platformă, participarea activă în forumuri sau scorurile obținute la evaluările intermediare sunt frecvent asociate cu reușita sau eșecul cursantului. De exemplu, studiile de learning analytics arată că scăderea bruscă a timpului de logare și numărul redus de interacțiuni sunt predictorii fiabili ai riscului de dropout (Kizilcec et al., 2013).

Un aspect esențial este modul în care este măsurat engagement-ul. Deși deseori este tratat ca o variabilă simplă (ex. Low/Medium/High), engagement-ul este un construct complex ce include dimensiuni comportamentale, cognitive și emoționale. Studiile recente bazate pe behavioral tracing sugerează că frecvența accesării materialelor, timpul petrecut activ în aplicație și ritmicitatea activității online corelează mai puternic cu succesul decât simpla completare a sarcinilor (Gašević et al., 2016). În ciuda acestor descoperiri, multe platforme folosesc în continuare măsuri sumare de engagement, ceea ce limitează capacitatea de a interveni eficient.

C. Stilurile de învățare - rolul lor în adaptivitate și abandon

Stilurile de învățare reprezintă o altă variabilă cu potențial semnificativ în înțelegerea fenomenului de abandon. Modele populare precum VARK (Visual, Auditory, Reading/Writing, Kinesthetic) sau teoria experiențială a lui Kolb evidențiază preferințele individuale ale cursanților în ceea ce privește modul de recepționare și procesare a informației.

Cercetările arată că stilurile de învățare pot influența motivația intrinsecă și nivelul de retenție. Cursanții ale căror stiluri nu sunt „adresate” de designul platformei pot manifesta un nivel mai scăzut de satisfacție și implicare, crescând astfel riscul de abandon. Totuși, acest factor este adesea neglijat sau tratat superficial în proiectarea cursurilor, mai ales în mediul online.

Mai mult, studiile recente avertizează asupra faptului că adaptivitatea reală presupune mai mult decât alegerea unui format de conținut. Este necesară o înțelegere holistică a modului în care stilurile de învățare interacționează cu ritmul, tipul de sarcini și nevoia de feedback personalizat.

D. Lacunele actuale - de ce este necesar studiul de față?

În ciuda volumului crescut de date educaționale disponibile, există încă o lipsă de modele integrate care să combine variabilele cognitive (stiluri, motivație) cu cele comportamentale (timp,

participare, scoruri). Multe cercetări se limitează la descrierea datelor, fără a construi modele predictive care să ajute la intervenția timpurie.

Acest studiu propune o analiză care combină ambele dimensiuni, comportamentală și cognitive, pentru a identifica mai clar tiparele asociate cu riscul de abandon. Astfel, contribuie la o mai bună înțelegere a modului în care designul adaptiv și analiza comportamentului pot sprijini retenția cursanților în mediul online.

E. Perspective complementare și direcții emergente

Continuând de la lacunele identificate, cu alte cuvinte ne putem referi la absența unor modele predictive integrate, care să combine date comportamentale și factori cognitive, putem spune faptul că literatura recentă evidențiază o serie de dimensiuni complementare ce merită explorate pentru a înțelege și reduce abandonul în educația online. Aceste dimensiuni vizează atât nivelul metodologic, prin rafinarea tehnicilor de analiză și predicție, cât și nivelul pedagogic, prin adaptarea mai eficientă a conținutului educațional la nevoile individuale ale cursanților. Totodată, se conturează și provocări etice semnificative, în special în ceea ce privește colectarea, procesarea și utilizarea datelor personale ale cursanților. Necesitatea unei abordări holistice este tot mai evidentă: modelele viitoare ar trebui să integreze nu doar indicatori cantitativi de performanță, precum scorurile sau frecvența activităților, ci și informații calitative privind motivația, stilurile de învățare, percepția de sprijin și autoreglarea. Această abordare multidimensională poate conduce la dezvoltarea unor sisteme educaționale adaptive, care să reacționeze în timp real la semnalele de risc și să ofere intervenții personalizate, cu un potențial real de reducere a abandonului. În paralel, avansurile în inteligența artificială și în analitica educațională permit o monitorizare mai fină a comportamentelor de învățare, dar ridică în același timp întrebări esențiale privind echitatea, transparența și controlul asupra propriilor date. Așadar, orice inițiativă de cercetare sau inovare în acest domeniu trebuie să echilibreze rigurozitatea analitică cu responsabilitatea etică, pentru a asigura un mediu educațional sustenabil și centrat pe nevoile reale ale cursanților.

E.1 Etica monitorizării comportamentale

Una dintre cele mai sensibile dimensiuni emergente este cea etică. Deși analiza comportamentului cursanților prin learning analytics oferă perspective valoroase asupra riscului de abandon, aceasta implică și monitorizarea extensivă a activității digitale, cum ar fi timpul

petrecut pe platformă, frecvența accesărilor sau secvențele de navigare. Acest tip de supraveghere digitală poate afecta autonomia cursanților dacă nu este însoțit de un consimțământ informat și transparent (Slade & Prinsloo, 2013).

Problema este cu atât mai delicată în contexte educaționale, unde relația de putere dintre instituție și cursant poate diminua capacitatea reală de a refuza colectarea datelor. În plus, utilizarea de algoritmi predictivi opaci – așa-numitele „cutii negre” – poate duce la erori de clasificare sau biasuri algoritmice (Holmes & Tuomi, 2022), afectând în mod nedrept anumite grupuri de cursanți. De aceea, orice inițiativă de acest tip trebuie să includă un cadru etic solid, centrat pe echitate, confidențialitate și controlul datelor de către utilizator (Prinsloo & Slade, 2016).

E.2 Gamificarea ca soluție

În paralel, literatura educațională propune gamificarea ca un instrument pedagogic util în combaterea dezangajării. Studiile arată că elementele de joc precum badge-uri, punctaje și clasamente pot spori motivația și implicarea, în special în rândul cursanților cu stiluri kinestezice sau vizuale (Smiderle et al., 2020). În contextul analizat, unde engagementul auto-raportat nu a fost corelat clar cu scorurile sau abandonul, gamificarea ar putea oferi o formă tangibilă de motivare extrinsecă, ajustabilă în timp real.

Totuși, eficiența gamificării depinde de gradul de personalizare. Aceeași tehnică poate motiva unii cursanți și descuraja alții, în funcție de profilul psihologic sau de istoricul lor educațional (Dichev & Dicheva, 2017). Această variabilitate întărește ideea că modelele predictive trebuie să fie dinamice și adaptive, nu doar descriptive.

E.3 Microînvățarea și stilurile de învățare

O altă direcție complementară vizează microlearning-ul. Acesta reprezintă livrarea conținutului în module scurte, accesibile și frecvente. Formatul este asociat cu o procesare cognitivă mai eficientă și cu un nivel mai ridicat de retenție, mai ales în cazul cursanților vizuali sau kinestezici, care preferă conținut fragmentat și repetabil (Mohammed et al., 2020). Având în vedere că în analiza de față stilurile kinestezic și auditiv au fost asociate cu scoruri constante, integrarea unor strategii de microlearning ar putea stimula performanța și pentru celelalte categorii. În plus, microînvățarea este ușor de combinat cu gamificarea și feedback-ul instant, creând un ecosistem educațional adaptiv și scalabil.

E.4 Feedback-ul automatizat și impactul asupra retenției

Un alt aspect central în prevenirea abandonului este feedback-ul rapid și personalizat. În lipsa unei prezențe umane directe, feedback-ul automatizat, bazat pe scoruri, progres sau interacțiuni, poate juca un rol crucial în menținerea motivației (Grawemeyer et al., 2022). Studiile arată că feedback-ul adaptiv, generat în timp real, are un impact semnificativ asupra angajamentului perceput și a autoeficacității, în special pentru cursanții care întâmpină dificultăți sau au un stil de învățare activ (Kizilcec et al., 2013). În lumina acestor date, dezvoltarea de mecanisme automate de feedback integrate cu modele predictive poate reprezenta o direcție viabilă pentru intervenții prompte și personalizate.

Studiile recente sugerează că **rata de abandon** în mediile educaționale online variază între 30% și 70%, în funcție de tipul cursului și caracteristicile participanților (Holmes & Tuomi, 2022). Printre factorii frecvent asociați cu abandonul se numără nivelul scăzut de angajament, lipsa de feedback imediat și lipsa de adaptare a cursurilor la nevoile individuale.

Tot mai multe cercetări evidențiază că engagement-ul și stilurile de învățare influențează nu doar performanțele academice, ci și retenția în sistemul educațional digital. În timp ce unele studii analizează corelații izolate între implicare și performanță, integrarea acestor factori comportamentali cu variabile cognitive, precum stilul de învățare, este încă rar explorată în mod holistic în modele predictive.

Astfel, se conturează o întrebare esențială pentru cercetarea actuală în educația digitală: **pot aceste date comportamentale, în combinație cu preferințele cognitive, oferi un cadru solid pentru anticiparea riscului de abandon?**

1.3 Întrebarea de cercetare

Întrebările de cercetare reprezintă punctul de plecare esențial al oricărui studiu, ghidând procesul de investigație și definind clar ce anume ne propunem să descoperim. Ele ajută la focalizarea atenției asupra aspectelor cele mai relevante ale fenomenului studiat și facilitează selectarea metodelor și instrumentelor potrivite. În acest context, întrebările formulate trebuie să fie clare și precise, astfel încât să poată fi abordate eficient în cadrul resurselor și timpului disponibil. Astfel, întrebarea noastră de cercetare se intitulează:

Care este capacitatea predictivă a comportamentelor de învățare online precum timpul petrecut pe platformă, participarea în forumuri, scorurile la teste și stilul de învățare, în estimarea riscului de abandon al cursurilor online?

Întrebări secundare:

- Există diferențe semnificative între stilurile de învățare în ceea ce privește scorurile finale și rata de abandon?
- Ce combinații de comportamente (engagement patterns) sunt asociate cu cel mai mic risc de dropout?

2 Răspunsuri existente & ipoteze

Literatura de specialitate oferă un cadru valoros pentru înțelegerea fenomenului dropout-ului în mediile de învățare online, precum și pentru identificarea factorilor care influențează performanța și angajamentul cursanților. Cercetările recente au evidențiat o serie de aspecte cheie ce pot ghida analiza datelor colectate în cadrul acestui studiu. Astfel, ipotezele ce stau la baza cercetării sunt:

1. Cursanții cu nivel scăzut de engagement (Low Engagement_Level) au o probabilitate semnificativ mai mare de dropout;
2. Cursanții cu stil vizual sau kinestezic obțin scoruri semnificativ mai mari la final exam;
3. Participarea frecventă în forumuri este asociată cu o scădere a probabilității de abandon.
4. Combinarea activității video + assignment completion oferă o predicție mai bună a scorului final decât oricare dintre ele separat.

În primul rând, Holmes și Tuomi (2022) evidențiază faptul că abandonul cursurilor online este strâns legat de lipsa personalizării conținutului, feedback-ul insuficient și nivelul scăzut de angajament al cursanților. Aceste elemente reduc motivația și capacitatea de adaptare a studenților la cerințele platformelor digitale. Pornind de la aceste constatări, **prima ipoteză** presupune că studenții cu un nivel scăzut de engagement au o probabilitate semnificativ mai mare de a renunța la curs, comparativ cu cei care manifestă un nivel ridicat de implicare în activitățile educaționale.

Variabila Engagement_Level din datasetul utilizat clasifică studenții în Low/Medium/High în funcție de comportamente agregate precum participarea la forum, timpul video și completarea temelor. Astfel, este relevantă pentru testarea relației dintre implicare și dropout.

În al doilea rând, literatura abordează și rolul stilurilor de învățare în succesul academic. Conform studiilor realizate de Elish și Boyd (2018), precum și Holmes și Tuomi (2022), adaptarea conținutului educațional la stilurile individuale de învățare: vizual, auditiv, kinestezic, etc. poate îmbunătăți semnificativ rezultatele la examene și gradul de retenție al cunoștințelor. Prin urmare, **a doua ipoteză** propune ideea în care este descris faptul că cei care adoptă stiluri vizuale sau kinestezice vor obține scoruri mai mari la examenul final, în comparație cu cei care au alte preferințe cognitive.

În plus, se observă o corelație pozitivă între engagementul comportamental și performanța academică. Studiile lui Luo et al. (2019) și Gandomi & Haider (2015) indică faptul că activitățile observabile, cum ar fi timpul petrecut vizionând materiale video, numărul de participări la forumuri și încercările la quiz-uri, sunt predictorii relevanți pentru succesul cursanților. În acest

sens, **a treia ipoteză** susține că o participare frecventă în forumuri este asociată cu o scădere semnificativă a probabilității de abandon, sugerând că interacțiunea socială și schimbul de informații în comunitate pot consolida motivația și angajamentul.

Nu în ultimul rând, cercetări precum cele ale lui Lazer et al. (2020) și Grimmer (2015) subliniază importanța combinării mai multor indicatori comportamentali pentru o predicție mai precisă a performanței academice. Astfel, **a patra ipoteză** explorează dacă o combinație între timpul petrecut pe videoclipuri și rata de completare a temelor poate oferi un model predictiv mai robust al scorului final la examen, comparativ cu utilizarea individuală a acestor variabile. Pentru testarea acestei ipoteze, vor fi utilizate valorile `Time_Spent_on_Videos` și `Assignment_Completion_Rate`, care oferă indicatori direcți și cantitativi despre implicarea cursanților în învățarea asincronă.

Aceste ipoteze vor fi testate prin metode statistice adecvate, precum regresia logistică pentru analiza probabilității de dropout și testele ANOVA sau Kruskal-Wallis pentru comparații între grupuri, dar și regresia liniară multiplă pentru modelele de predicție a scorului final. Astfel, acest studiu urmărește să contribuie la înțelegerea complexă a factorilor care influențează succesul sau abandonul în mediul educațional online, oferind perspective valoroase pentru optimizarea platformelor de învățare și creșterea șanselor de reușită pentru toți cursanții. Aceste ipoteze oferă un cadru conceptual robust pentru analiza datelor din platforma educațională simulată, și vor ghida alegerea metodelor statistice și interpretarea rezultatelor în secțiunea următoare.

3 Date & design cercetare

3.1 Sursa și descrierea datasetului

Cercetarea de față se bazează pe analiza datasetului intitulat „Personalized Learning & Adaptive Education”, un set de date sintetice, dar realist simulate, conceput special pentru explorarea fenomenelor din domeniul educației personalizate și al sistemelor adaptive de învățare. Scopul acestui dataset este de a reproduce comportamentele tipice ale cursanților într-un mediu online, oferind o bază solidă pentru investigarea relațiilor dintre factori cognitivi, comportamentali și performanțele academice.

Datasetul include peste 10.000 de înregistrări, fiecare corespunzând unui cursant anonim, și este structurat în mai multe categorii de variabile esențiale pentru înțelegerea procesului educațional digital:

- *Profilul cursantului*: sunt disponibile informații precum identificatorul unic al studentului (Student_ID), vârsta (cuprinsă între 15 și 50 de ani), genul (Male, Female, Other) și nivelul educațional (High School, Undergraduate, Postgraduate).
- *Comportamente de învățare online*: se monitorizează indicatori precum timpul total petrecut urmărind materiale video (Time_Spent_on_Videos), numărul de tentative la teste (Quiz_Attempts), nivelul de participare în forumuri (Forum_Participation), rata de completare a temelor (Assignment_Completion_Rate) și nivelul general de implicare (Engagement_Level: Low, Medium, High).
- *Performanțe academice*: performanța este evaluată prin scorul mediu la testele de tip quiz (Quiz_Scores), scorul obținut la examenul final (Final_Exam_Score) și evaluarea subiectivă a cursului exprimată de cursanți (Feedback_Score, pe o scară de la 1 la 5).
- *Stil cognitiv și probabilitate de abandon*: se include variabila Learning_Style, care reflectă preferința individuală pentru un anumit stil de învățare (Visual, Auditory, Reading/Writing, Kinesthetic), precum și Dropout_Likelihood, un indicator binar (Yes/No) care arată dacă studentul a abandonat sau a finalizat cursul.

Un avantaj major al acestui dataset este flexibilitatea sa analitică: permite evaluarea relațiilor dintre variabile esențiale, cum ar fi legătura dintre stilul de învățare și performanțele finale sau influența activităților de participare asupra riscului de abandon. În plus, prezența variabilei Dropout_Likelihood oferă oportunități pentru dezvoltarea de modele predictive, utile în identificarea timpurie a cursanților aflați în risc de abandon.

Justificarea alegerii datasetului constă în mai mulți factori relevanți precum: conține atât variabile cantitative, cât și categorii semantice utile pentru segmentare și modelare; reflectă în mod realist comportamentele uzuale din învățarea online; susține testarea ipotezelor formulate în această cercetare și este compatibil cu o gamă largă de metode statistice, inclusiv analize descriptive, regresii, clasificări, ANOVA și corelații. Prin urmare, acest dataset constituie o bază riguroasă și versatilă pentru desfășurarea cercetării, oferind un cadru coerent pentru analiza integrată a comportamentului educațional digital.

3.2 Preprocesare și selecția variabilelor

Pentru a asigura calitatea analizei, datele au fost preprocesate prin:

- Eliminarea valorilor lipsă, în special în ceea ce privește scorurile finale și stilurile de învățare;
- Identificarea și tratarea valorilor extreme pentru variabilele comportamentale, cum ar fi timpul petrecut pe video și participarea în forumuri;
- Codificarea variabilelor categorice, precum `Learning_Style` și `Engagement_Level`, pentru a fi utilizate în modelele statistice.

Pentru testarea ipotezelor, a fost selectat un subset de variabile considerate esențiale: `Dropout_Likelihood` (variabilă dependentă principală), `Engagement_Level`, `Forum_Participation`, `Time_Spent_on_Videos`, `Assignment_Completion_Rate`, `Learning_Style`, `Final_Exam_Score` și `Quiz_Scores`.

4. Analiză& rezultate

4.1 Analiza descriptivă a variabilelor

Înainte de aplicarea testelor statistice inferențiale și a modelelor predictive, este esențială o etapă preliminară de analiză descriptivă a datelor, care să permită o înțelegere generală a structurii și distribuției variabilelor din setul de date. Această fază joacă un rol crucial în fundamentarea etapelor ulterioare ale cercetării, deoarece evidențiază tipare generale, valori extreme, posibile erori sau date lipsă, dar și relații preliminare între variabile. Prin interpretarea corectă a tendințelor descriptive, pot fi formulate ipoteze mai informate și pot fi alese metodele analitice cele mai potrivite pentru specificul datelor.

Analiza descriptivă va include o examinare detaliată a distribuției variabilelor demografice, cum ar fi genul și vârsta cursanților, precum și a celor educaționale, cum ar fi nivelul de educație și stilul de învățare preferat. Vom urmări proporțiile corespunzătoare fiecărei categorii și posibilele dezechilibre care pot influența interpretarea rezultatelor. De exemplu, este relevant de observat dacă anumite stiluri de învățare sunt mai frecvente într-o anumită categorie de vârstă sau dacă distribuția pe gen este echilibrată, aspecte care pot avea implicații pentru personalizarea educației.

Pe lângă caracteristicile de profil, vor fi analizate și comportamentele de învățare – cum ar fi timpul mediu petrecut pe platformă, numărul de tentative la teste, participarea în forumuri sau rata de finalizare a temelor. Aceste variabile vor fi descrise atât prin indicatori de tendință centrală (medie, mediană), cât și prin măsuri de dispersie (abatere standard, intervale de variație), oferind o imagine clară asupra modului în care cursanții interacționează cu platforma. În plus, se va observa distribuția scorurilor academice (intermediare și finale), pentru a identifica eventuale corelații cu nivelul de implicare.

Un accent special va fi pus pe variabila Dropout_Likelihood, analizată în relație cu celelalte variabile. Se vor compara medii și proporții între grupurile de cursanți care au abandonat cursul și cei care l-au finalizat, pentru a identifica posibile diferențe semnificative în comportamente sau stiluri de învățare. Reprezentările vizuale, precum histograme, diagrame de tip bar chart și boxplot-uri, vor fi utilizate pentru a facilita interpretarea și a evidenția contrastele relevante. Această etapă exploratorie va contribui la conturarea unui profil preliminar al cursantului aflat în risc de abandon, care va ghida modelarea predictivă din secțiunile următoare ale lucrării.

4.1.1 Demografie: gen și identitate

Distribuția cursanților în funcție de gen arată o participare aproape egală între femei și bărbați. Din cei 10.000 de cursanți analizați, 4.886 (adică 49%) sunt femei, iar 4.699 (47%) sunt bărbați. În plus, 415 participanți (reprezentând 4%) s-au identificat cu opțiunea „Other”, ceea ce arată că setul de date include și persoane care nu se regăsesc în categoriile tradiționale de gen.




Figura 1 Distribuția cursanților după gen și identitate de gen

Această distribuție echilibrată este importantă, deoarece permite compararea comportamentelor de învățare și a performanțelor între diferite grupuri, fără ca un gen să fie semnificativ suprareprezentat. Prezența categoriei „Other” reflectă, de asemenea, o abordare mai incluzivă, care recunoaște diversitatea identității de gen în mediile educaționale online.

Un alt aspect relevant este că diferențele relativ mici între grupuri sugerează că eventualele variații în engagement sau în rata de abandon nu pot fi explicate doar prin distribuția de gen, ci mai probabil prin factori comportamentali sau cognitivi, cum ar fi stilul de învățare sau timpul petrecut pe platformă.

4.1.2 Nivel de educație

Distribuția nivelului de educație în rândul cursanților evidențiază o concentrare majoritară în jurul studiilor universitare. Astfel, **51% dintre participanți** au indicat că sunt la nivel **Undergraduate**, ceea ce sugerează că o mare parte a publicului țintă este reprezentată de studenți sau persoane aflate în formare universitară.




Figura 2 Repartiția cursanților în funcție de nivelul de educație

Un procent de **29%** dintre cursanți au studii **preuniversitare (High School)**, ceea ce poate indica fie tineri care se pregătesc pentru

admiterea în învățământul superior, fie utilizatori care accesează platforma pentru dezvoltare personală timpurie.

În același timp, **20% dintre respondenți** au nivelul **Postgraduate**, ceea ce arată interesul pentru educația continuă și în rândul celor care au deja o formare avansată.

Această distribuție echilibrată între cele trei categorii sugerează că platforma educațională are un grad ridicat de accesibilitate și atractivitate pentru o gamă largă de utilizatori, cu profiluri educaționale diferite.

4.1.3 Performanță academică

Analiza scorurilor finale la examen (**Final_Exam_Score**) în funcție de **gen** și **nivelul de educație** indică o distribuție relativ echilibrată, cu diferențe moderate între subgrupuri.

Per ansamblu, scorul mediu general este de **64.70**, cu variații ușoare între nivelurile educaționale: **Undergraduate** obține cea mai ridicată medie (**64.95**), urmat de **High School** (**64.72**) și **Postgraduate** (**64.01**). Această diferență




Figura 3 Scoruri medii finale la examen în funcție de gen și nivelul de educație

inversă față de așteptările obișnuite (unde Postgraduate ar avea cele mai mari scoruri) poate sugera fie un conținut mai bine adaptat pentru cursanții aflați în formare inițială, fie o posibilă diferență în nivelul de implicare sau de compatibilitate cu formatul platformei.

Se observă că **scorurile medii ale cursanților din categoria „Other” la nivel Postgraduate sunt semnificativ mai scăzute** comparativ cu celelalte subgrupuri (**60.97** față de o medie generală de **64.70**). Această diferență poate fi atribuită, pe de o parte, unor **efecte de eșantion**, întrucât acest grup este cel mai mic ca dimensiune și, implicit, mai sensibil la variații individuale. Totodată, pot exista **variabile latente** care nu sunt direct măsurate în dataset. De exemplu, niveluri crescute de stres, dificultăți de adaptare sau o compatibilitate mai scăzută cu formatul educațional digital.

O altă interpretare posibilă este legată de modul în care platforma sau conținutul cursului se aliniază (sau nu) cu **experiențele și așteptările acestui subgrup**. Este posibil ca persoanele din categoria „Other”, mai ales la niveluri academice avansate, să întâmpine provocări suplimentare în ceea ce privește sentimentul de incluziune sau relevanța materialelor pentru propriul context de învățare. Acest aspect poate influența motivația sau nivelul de engagement, cu efecte indirecte asupra performanței academice.

4.1.4 Stiluri de învățare și engagement

Această distribuție arată o repartitie relativ echilibrată între stiluri, cu un ușor avantaj numeric pentru stilul *Reading/Writing* (2554 cursanți). Nivelul de engagement „High” este relativ constant în toate categoriile (între 729 și 764), sugerând că stilul de învățare nu influențează drastic implicarea. Totuși, cursanții cu stil *Auditory* și *Kinesthetic* par ușor mai predispuși la un nivel de engagement „Low”, ceea ce ar putea semnala nevoia unor forme mai interactive sau practice de livrare a conținutului.




Figura 4 Distribuția stilurilor de învățare și nivelul de engagement asociat

4.1.5 Dropout și stil cognitiv

Analiza ratei de abandon în funcție de stilul de învățare indică variații minore (sub 1 punct procentual) între cele patru categorii. Cu o medie generală de ~19.6%, rezultatele sugerează că stilul de învățare, în sine, nu este un predictor puternic al abandonului. Acest lucru poate indica faptul că alți factori comportamentali precum nivelul de engagement sau participarea active pot avea o influență mai mare asupra deciziei de a finaliza cursul.




Figura 5 Rata de abandon în funcție de stilul de învățare

4.1.6 Evoluție scoruri (quiz → final)

Analiza comparativă a scorurilor medii între evaluările intermediare (quizuri) și cele finale evidențiază diferențe interesante între stilurile de învățare. Cursanții cu stil auditiv au înregistrat cea mai mare creștere a performanței (+1.13), în timp ce cei cu stil kinestezic au avut scoruri constante, sugerând un nivel ridicat de consistență.

În schimb, participanții cu stil Reading/Writing au avut o ușoară scădere a performanței la examenul final, ceea ce ar putea indica o provocare în reținerea informației sau o nepotrivire între stilul preferat și formatul evaluării finale.




Figura 6 Evoluția scorurilor medii între quizuri și examenul final pe stiluri de învățare

4.1.7 Participare activă: forumuri și quizuri

Interpretare:

Diferențele sunt foarte mici (sub 1 post în medie).

- *Kinesthetic* are ușor cea mai mare medie → ar putea fi legat de preferința pentru „learning by doing”, inclusiv discutând în forumuri.
- *Reading/Writing* și *Visual* sunt apropiate, confirmând ideea că aceste stiluri sunt confortabile în interacțiunea scrisă.

Rezultatul susține că participarea în forumuri este relativ egal distribuită între stiluri - dar nu exclude o mică influență comportamentală.

Learning_Style	Total
Auditory	24.44
Kinesthetic	24.92
Reading/Writing	24.57
Visual	24.54

Figura 7 Participarea medie în forumuri în funcție de stilul de învățare (ilustrează variația medie a postărilor pe forum pentru fiecare stil cognitiv: Auditory, Kinesthetic, Reading/Writing, Visual)

Interpretare:

- Nivelul educațional **nu influențează puternic** comportamentul de a relua quizurile.
- Cu toate acestea, studenții postuniversitari au un **ușor avantaj** - poate datorită experienței academice sau auto-disciplinei.

Average of Quiz_Attempts

Education_Level	Total
High School	2.48
Postgraduate	2.53
Undergraduate	2.50
Grand Total	2.50

Figura 8 Numărul mediu de tentative la quizuri în funcție de nivelul educațional (prezintă comparația între High School, Undergraduate și Postgraduate în ceea ce privește reluarea evaluărilor intermediare)

Media participării în forumuri variază

ușor între stilurile de învățare, cu un maxim de 24.92 postări pentru cursanții kinestezici și un minim de 24.44 pentru cei auditivi. Diferențele fiind minime, putem concluziona că stilul cognitiv individual are o influență slabă asupra implicării în comunitatea online. În mod similar, numărul mediu de tentative la quizuri variază nesemnificativ în funcție de nivelul educațional, sugerând că comportamentul de învățare prin repetiție este relativ constant indiferent de experiența academică.

4.1.8 Comportamente + rezultate (engagement + completare)

Interpretare:

- Diferența de ~0.44 puncte procentuale este **foarte mică**.
- Asta sugerează că **procentul temelor completate nu este un predictor puternic al abandonului**, cel puțin nu singur.




Figure 9 Participarea medie în forumuri și numărul mediu de tentative la quizuri după stiluri de învățare și nivel educațional

Deși se observă o ușoară scădere a ratei de completare în rândul cursanților care au abandonat, diferența este prea mică pentru a fi considerată relevantă statistic fără o analiză suplimentară.




Figura 10 Rata de abandon în funcție de nivelul de engagement (Low, Medium, High)

Interpretare:


- Rezultatul **surprinde**, pentru că dropout-ul este **mai mic în grupul cu engagement scăzut**, contrar primei ipoteze.
- Toate valorile sunt în jurul mediei generale ($\approx 19.6\%$), deci **engagement-ul raportat nu pare a influența direct rata de abandon** în acest caz.

Contrar așteptărilor inițiale, cursanții cu nivel scăzut de engagement nu au prezentat o rată semnificativ mai mare de abandon față de cei cu engagement mediu sau ridicat. De fapt, grupul cu engagement scăzut a înregistrat o ușoară rată mai mică de dropout (18.45%) comparativ cu grupurile cu engagement mai ridicat. Acest rezultat sugerează că măsura de engagement utilizată (Low/Medium/High) poate fi prea agregată pentru a evidenția diferențele reale de comportament educațional, motiv pentru care se recomandă o analiză separată pe variabile individuale

4.1.9 Predicția abandonului în funcție de stilul de învățare

Interpretare:

- Diferențele între stiluri sunt **foarte mici** (între 0.19 și 0.20).
- Acest lucru sugerează că **stilul de învățare, izolat, nu este un predictor puternic al abandonului**.



Analiza descriptivă asupra datelor din eșantionul de 10.000 de cursanți arată că rata medie de abandon diferă foarte puțin în funcție de

stilul de învățare declarat. Stilurile „Auditory” și „Reading” prezintă o rată de 0.19, în timp ce „Kinesthetic” și categoria „Other” ajung la 0.20. Aceste rezultate susțin concluziile literaturii (Felder & Spurlin, 2005; Pashler et al., 2008) conform cărora preferințele stilistice izolate nu prezic în mod consistent performanța sau retenția și evidențiază nevoia unor modele integrate care să combine multiple dimensiuni ale profilului cursantului.

4.1.10 Repartiția cursanților pe cursuri (volum)

Interpretare:

Distribuția cursanților pe cele cinci cursuri din platformă este relativ echilibrată, cu variații minore (între ~1.950 și ~2.050 cursanți per curs). Această omogenitate ajută la evitarea efectelor de eșantionare disproporționată și conferă robustețe rezultatelor comparative între cursuri.




Figura 11 Numărul cursanților înregistrați pe fiecare curs

4.1.11 Rata de abandon în funcție de cursul urmat




Figura 12 Rata de abandon estimată pe cursuri

Interpretare:

Rata estimată de abandon este relativ constantă între cursuri, situându-se între 17% și 21%. Cursul „Machine Learning” înregistrează cel mai mare număr de cursanți cu probabilitate de abandon (Yes = 429), urmat de „Cybersecurity” (398). În schimb, „Web Development” are

cea mai scăzută valoare (357). Aceste diferențe moderate sugerează că tipul cursului poate influența ușor riscul de abandon, dar nu în mod decisiv. Este posibil ca factori precum dificultatea percepută, profilul cursanților sau structura conținutului să joace un rol în variațiile observate.

4.1.12 Scoruri finale medii per curs

Interpretare:

Datele arată că performanța medie la examenele finale și la quizuri este relativ uniformă între cursuri, variind foarte puțin în jurul valorii de 64–65 de puncte.

- Cybersecurity și Data Science se evidențiază printr-un echilibru perfect între scorul la quizuri și la examenul final (65–65).
- Machine Learning are un scor ușor mai mic la examenul final (64), posibil sugerând o dificultate mai mare la evaluarea finală.
- Python Basics și Web Development înregistrează scoruri puțin mai scăzute la quizuri (64), ceea ce poate indica o dificultate crescută în sarcinile intermediare sau o lipsă de familiarizare timpurie cu materialul.

Aceste variații minore sugerează că **nivelul de dificultate sau evaluare este similar între cursuri**, iar **diferențele de performanță nu sunt suficient de mari** pentru a sugera un dezechilibru sistemic. Performanța pare a fi mai degrabă influențată de factori individuali decât de structura cursului.




Figura 13 Scoruri medii la examenul final și quizuri pe cursuri

4.1.13 Evaluarea cursurilor de către participanți (Feedback Score)




Figura 14 Scorul mediu de feedback pentru cursuri

Interpretare:

- Valorile pentru fiecare curs sunt foarte apropiate, toate în jurul valorii de 3, ceea ce indică o uniformitate a performanței sau a unei metrici relevante (poate engagement, satisfacție, dificultate medie etc.) în toate cursurile.
- Python Basics are valoarea cea mai mare (3.045), iar Web Development cea mai mică (2.97), dar diferența este mică.
- Media generală pentru toate cursurile este 3.01, confirmând un nivel similar al acestei măsurători în cadrul celor 5 cursuri.

Valorile medii ale scorului (sau metricii respective) pentru fiecare curs indică o relativă omogenitate între acestea, cu valori în jurul lui 3, variind ușor între cursuri. Această uniformitate sugerează că, din perspectiva acestei metrici, performanța sau experiența cursanților este similară în toate domeniile studiate.

Interpretare generală:

Analiza celor 10.000 de cursanți relevă un peisaj educațional online echilibrat și divers, cu variații moderate între grupuri și factori. Distribuția demografică (gen, nivel educațional, identitate) este relativ uniformă, permițând comparații valide între segmente. Performanța academică globală este stabilă, cu scoruri medii similare indiferent de gen, nivel de educație sau curs ales, sugerând că platforma oferă un conținut echilibrat și accesibil pentru majoritatea utilizatorilor.

Preferințele de stil de învățare influențează doar marginal engagement-ul și participarea activă, iar comportamentele educaționale, precum numărul de postări sau tentativele la quizuri, variază foarte puțin între grupuri. De asemenea, nici stilul de învățare și nici nivelul educațional nu sunt predictorii semnificativi ai abandonului, ceea ce întărește ideea că factorii mai complecși (ex. motivația, contextul personal, designul platformei) sunt determinanți mai relevanți.

Rata de abandon rămâne constantă (~19.6%) indiferent de variabilele analizate, cu ușoare diferențe între cursuri și subgrupuri, dar fără a se contura un model clar pe baza indicatorilor descriptivi. Surprinzător, engagement-ul autoevaluat nu prezintă o corelație puternică cu abandonul, semnalând posibile limite ale clasificărilor agregate și nevoia unor metrice comportamentale mai fine.

În concluzie, datele susțin ideea că succesul și retenția în mediul educațional online nu pot fi explicate printr-un singur factor (precum genul, stilul de învățare sau nivelul educațional), ci necesită o abordare multidimensională, care să îmbine profilul psihologic, comportamentele de învățare și designul pedagogic al platformei. Acest lucru oferă direcții clare pentru viitoare modele predictive și intervenții personalizate în educația digitală.

5. Discuții, implicații & concluzii

5.1 Principalele concluzii

Analiza datelor a condus la o serie de concluzii relevante privind comportamentul cursanților în medii educaționale online personalizate. În primul rând, rezultatele sugerează că rata de abandon nu variază semnificativ în funcție de stilul de învățare sau nivelul de engagement declarat, contrar unor ipoteze inițiale din literatura de specialitate. Acest lucru indică faptul că factorii comportamentali observabili și contextuali ar putea avea o influență mai mare asupra retenției decât trăsăturile cognitive auto-declarate.

În ceea ce privește performanțele academice, diferențele între grupuri au fost minore, atât în ceea ce privește scorurile obținute la quizuri, cât și la examenele finale. Deși stilurile kinestezic și auditiv au obținut în medie scoruri ușor mai ridicate sau mai constante, aceste variații nu sunt suficient de mari pentru a susține ipoteze ferme privind superioritatea unui anumit stil de învățare în contextul digital.

De asemenea, participarea activă (în forumuri) și comportamentele de învățare repetitivă (tentative multiple la quizuri) au fost distribuite aproape uniform între genuri, niveluri educaționale și stiluri cognitive. Acest echilibru comportamental reflectă, cel mai probabil, un design de platformă care nu favorizează sau penalizează anumite tipuri de cursanți, sugerând un grad înalt de echitate în accesul și interacțiunea educațională.

În ansamblu, datele susțin ideea că platforma analizată oferă o experiență educațională uniformă și echitabilă, fără biasuri clare legate de gen, educație, stil de învățare sau engagement autoevaluat. Aceasta este o concluzie pozitivă, cu implicații semnificative pentru designul viitoarelor soluții educaționale digitale.

5.2 Oportunități

Pe baza acestor constatări, se conturează mai multe direcții de dezvoltare strategică. Una dintre cele mai promițătoare este posibilitatea de a crea un sistem adaptiv real, care să se bazeze pe date comportamentale concrete (precum ritmul de progres, tiparul de accesare a conținutului sau interacțiunile în forumuri), și nu exclusiv pe preferințele declarate ale cursanților. Acest lucru ar permite o personalizare mai eficientă și mai precisă a parcursului educațional.

Totodată, se evidențiază oportunitatea de a integra indicatori dinamici de engagement, cum ar fi progresul săptămânal sau ritmul de finalizare a activităților, pentru a facilita intervenții

timpurii în cazul cursanților cu risc de abandon. O astfel de abordare proactivă ar putea contribui semnificativ la creșterea retenției și a succesului educațional.

Nu în ultimul rând, construirea de profiluri educaționale personalizate, care să îmbine trăsături cognitive (stil de învățare, nivel educațional) cu date comportamentale observabile, poate oferi o imagine mai completă asupra nevoilor cursanților și poate susține decizii pedagogice mai bine informate.

5.3 Limitări

Interpretarea rezultatelor implică și câteva rezerve metodologice importante. În primul rând, variabila *Engagement_Level* a fost predefinită și agregată, ceea ce poate limita detecția unor diferențe fine în comportamentele cursanților. O abordare bazată pe indicatori mai detaliați ar putea oferi o imagine mai nuanțată asupra implicării.

În al doilea rând, analiza a fost de natură descriptivă și nu a inclus metode statistice inferențiale (precum ANOVA sau regresii). Ca urmare, deși s-au observat anumite variații între grupuri, nu se poate afirma cu certitudine dacă acestea sunt semnificative din punct de vedere statistic.

În plus, lipsa unei componente longitudinale în setul de date limitează posibilitatea de a examina cum evoluează engagementul și performanța de-a lungul timpului. Integrarea acestei dimensiuni ar putea aduce perspective valoroase în cercetări viitoare.

5.4 Implicațiile rezultatelor pentru societate

În ciuda limitărilor, rezultatele obținute au implicații semnificative pentru societate și pentru designul politicilor educaționale digitale. Constatările susțin ideea că platformele online pot funcționa ca medii incluzive și echitabile, în care cursanții din medii socio-educaționale diverse beneficiază de șanse relativ egale de succes.

Mai mult, lipsa diferențelor sistematice între genuri, niveluri educaționale și stiluri cognitive indică faptul că digitalizarea educației, atunci când este bine implementată, nu accentuează inegalitățile existente, ci poate contribui la reducerea lor. Aceasta este o concluzie extrem de relevantă pentru decidenți, într-un context global în care echitatea în educație este o prioritate majoră.

În consecință, viitorul educației online ar trebui să pună accent pe adaptabilitate și personalizare inteligentă, nu pe segmentări rigide ale utilizatorilor. Flexibilitatea și capacitatea de

a reacționa la comportamentele reale ale cursanților pot face diferența între o experiență educațională generală și una cu adevărat transformatoare. Aceste concluzii pot ghida factorii de decizie în dezvoltarea unor politici educaționale digitale care să prioritizeze echitatea, accesibilitatea și personalizarea sustenabilă.

5.5 Recomandări

Pornind de la concluziile obținute, se conturează câteva direcții strategice pentru îmbunătățirea experienței educaționale online. În primul rând, este recomandată dezvoltarea unor sisteme adaptive avansate, care să folosească algoritmi de învățare automată pentru a identifica în timp real tipare comportamentale și pentru a personaliza sprijinul oferit cursanților. În al doilea rând, extinderea analizei pe baze de date complementare, provenite din platforme educaționale consacrate precum Coursera, Moodle sau edX, ar permite validarea externă a rezultatelor și rafinarea modelelor construite.

Totodată, viitoarele cercetări ar trebui să includă metode statistice și predictive mai complexe (ex. regresie logistică, clustering comportamental, rețele neuronale), pentru a evidenția în mod riguros factorii cu impact semnificativ asupra performanței și retenției.

Nu în ultimul rând, se recomandă integrarea unor mecanisme automate de feedback și intervenție, capabile să răspundă prompt la semnale de risc (precum participarea scăzută sau rezultate academice slabe), asigurând astfel o susținere pedagogică personalizată și eficientă.

Referințe bibliografice

Dichev, C., & Dicheva, D. (2017). Gamifying education: what is known, what is believed and what remains uncertain: A critical review. *International Journal of Educational Technology in Higher Education*, 14(1), 1–36. <https://doi.org/10.1186/s41239-017-0042-5>

Elish, M. C., & Boyd, D. (2018). Situating methods in the magic of Big Data and AI. *Communication Monographs*, 85(1), 57–80. <https://doi.org/10.1080/03637751.2017.1375130>

Gandomi, A., & Haider, M. (2015). Beyond the hype: Big data concepts, methods, and analytics. *International Journal of Information Management*, 35(2), 137–144. <https://doi.org/10.1016/j.ijinfomgt.2014.10.007>

Gašević, D., Dawson, S., Rogers, T., & Gasevic, D. (2016). Learning analytics should not promote one size fits all: The effects of instructional conditions in predicting academic success. *The Internet and Higher Education*, 28, 68–84.

Grimmer, J. (2015). We Are All Social Scientists Now: How Big Data, Machine Learning, and Causal Inference Work Together. *PS: Political Science & Politics*, 48(1), 80–83. <https://doi.org/10.1017/S1049096514001784>

Grawemeyer, B., Holmes, W., & Porayska-Pomsta, K. (2022). Real-time feedback in intelligent tutoring systems: A systematic review. *Journal of Educational Technology & Society*, 25(2), 50–65.

Holmes, B., & Tuomi, M. (2022). Predicting dropout in online education: A systematic review of factors and models. *Journal of Learning Analytics*, 9(1), 45–63. <https://doi.org/10.18608/jla.2022.7341>

Kizilcec, R. F., Piech, C., & Schneider, E. (2013). Deconstructing disengagement: Analyzing learner subpopulations in massive open online courses. In *Proceedings of the Third International Conference on Learning Analytics and Knowledge* (pp. 170–179). <https://doi.org/10.1145/2460296.2460330>

Lazer, D., Pentland, A., Adamic, L., Aral, S., Barabási, A. L., Brewer, D., Christakis, N., Contractor, N., Fowler, J., Gutmann, M., Jebara, T., King, G., Macy, M., Roy, D., & Van Alstyne, M. (2009). Computational social science. *Science*, 323(5915), 721–723. <https://doi.org/10.1126/science.1167742>

Luo, H., Zhang, Z., & Shi, Y. (2019). Mining student engagement patterns in online learning environments. In *Proceedings of the 9th International Conference on Learning Analytics & Knowledge (LAK'19)* (pp. 305–314). <https://doi.org/10.1145/3303772.3303808>

Mohammed, R., Wakil, K., & Nawroly, S. (2020). The effectiveness of microlearning to improve students' learning ability. *International Journal of Educational Research Review*, 5(4), 353–358. <https://doi.org/10.24331/ijere.776635>

Personalized Learning & Adaptive Education Dataset. (n.d.). Kaggle/custom-generated dataset description. Utilizat pentru scopuri educaționale.

Prinsloo, P., & Slade, S. (2016). Student data privacy and institutional accountability in an era of big data: The challenge of balancing competing interests. *Journal of Learning Analytics*, 3(1), 63–73.

Slade, S., & Prinsloo, P. (2013). Learning analytics: Ethical issues and dilemmas. *American Behavioral Scientist*, 57(10), 1510–1529. <https://doi.org/10.1177/0002764213479366>

Smiderle, R., Rigo, S. J., Marques, L. B., Coelho, J. A. P. M., & Jaques, P. A. (2020). The impact of gamification on students' learning, engagement and behavior based on their personality traits. *Smart Learning Environments*, 7, 3. <https://doi.org/10.1186/s40561-019-0098-x>