



PREVENTING AND FIGHTING EARLY LEAVING
FROM EDUCATION & TRAINING WITH AI

stAI

Acționează înainte să se întâmple: Prevenirea și
combaterea părăsirii timpurii educației și formării cu
ajutorul Inteligenței Artificiale

T3.2 Data-driven decision support in Education: guidelines outlining opportunities, recommendations and concerns

Work Package 3

Autor: STAI Consorțiu

INFORMAȚII PROIECT

Acronim proiect:

stAI

Titlu proiect: Acționează înainte să se întâmple: Prevenirea și combaterea părăsirii timpurii a educației și formării cu ajutorul Inteligenței Artificiale

Proiect N°:2023-1-IS01-KA220-SCH-000157308

Sub-programm sau KA:

KA220-SCH – Parteneriate de cooperare în educația școlară

Website: www.stai-edu.eu

Consorțiu:



SCHOOL OF EDUCATION



Tabelă de conținuturi

Introducere.....	5
Opportunități.....	6
1. Învățare personalizată.....	6
Abordări ale învățării centrate pe elev.....	6
Adaptarea conținutului învățării pe bază de date.....	6
Traseele personalizate reduc dezangajarea.....	6
Sprijinirea obiectivelor și a definițiilor de succes diferențiate.....	7
Promovarea flexibilității și a învățării continuu.....	7
Susținerea conștientizării de sine în învățare.....	7
Condiții pentru implementarea cu succes.....	8
2. Intervenția timpurie.....	8
Introducere.....	8
Context și definiții europene.....	8
Cadrul strategic și politicile europene.....	9
Intervenția timpurie – concept și mecanisme.....	9
Impactul și beneficiile intervenției timpurii.....	10
Concluzii.....	10
3. Strategii de predare îmbunătățite.....	10
Strategii de predare îmbunătățite.....	10
De la intuiție la pedagogie bazată pe dovezi.....	11
Învățarea mixtă și cea activă ca pedagogii strategice.....	11
Împuternicire profesională și practică de reflexie.....	11
Rolul AI în evoluția pedagogiei.....	12
Implicații strategice și un viitor bazat pe om.....	12
Preocupări.....	13
1. Confidențialitatea și securitatea datelor.....	13
Colectarea și prelucrarea datelor cu caracter personal.....	13
Baza juridică și consimțământul părinților.....	14
Stocarea, păstrarea și securitatea datelor.....	14
Preocupări specifice AI în instrumentele educaționale.....	14
Partajarea datelor cu terți și conformitatea cu reglementările.....	15
Transparență în evaluarea riscurilor.....	15
Protecția datelor prin proiectarea și controlul utilizatorilor.....	15

Măsuri de asigurare a vârstei și siguranța copiilor.....	16
2. Dependența excesivă de date.....	16
Echilibrarea cantității și calității datelor.....	17
Îmbunătățirea calității datelor.....	17
Permiterea modelelor să învețe și să se adapteze în timp.....	19
Integrarea datelor cu experiența anterioară, expertiza umană și cunoștințele din domeniu.....	20
Îmbunătățirea transparenței, ghidarea procesului decizional și construirea încrederii și înțelegerii.....	21
3. Considerente etice.....	22
Concluzii.....	25
Referințe.....	27

Introducere

Educația intră într-o nouă eră în care datele și Inteligența Artificială (IA) devin instrumente puternice pentru a sprijini elevii și educatorii. Acest document se concentrează pe crearea de linii directoare practice și accesibile pentru a ajuta școlile și sistemele de învățământ să utilizeze eficient instrumentele bazate pe IA pentru a aborda provocările Părăsirii Timpurii a Școlii și Formării (PTSF). Aceste instrumente pot ajuta la identificarea elevilor aflați în pericol, la recomandarea de strategii de sprijin și la eficientizarea și proactivitatea proceselor de luare a deciziilor. Acest document se bazează pe perspectivele adunate din munca anterioară, urmărind să exploreze modul în care sistemele bazate pe IA pot fi integrate în medii educaționale reale. Obiectivul este de a asigura că aceste tehnologii nu sunt doar eficiente, ci și etice, transparente și incluzive. Prin examinarea beneficiilor lor potențiale, cum ar fi o mai bună monitorizare a elevilor și intervențiile personalizate, alături de preocupările pe care le ridică, inclusiv problemele de confidențialitate, erorile din date și echitatea deciziilor IA, ne propunem să creăm o abordare echilibrată în care școlile să poată avea încredere. În cele din urmă, acest document urmărește să ajute educatorii și factorii de decizie să navigheze în acest peisaj complex, dar incitant. Liniile directoare pe care le dezvoltăm vor oferi sfaturi clare, concrete, pentru utilizarea IA în moduri care sprijină elevii și promovează egalitatea, incluziunea și transparența. Prin colaborarea cu partenerii de proiect și contribuția din contexte educaționale din lumea reală, aceste linii directoare vor deschide calea către instrumente mai sigure, mai inteligente și mai eficiente pentru a reduce ratele de abandon școlar și pentru a oferi fiecărui elev o șansă mai bună de a reuși.

Oportunități

1. Învățare personalizată

Abordări de învățare centrate pe elev


Învățarea personalizată reprezintă o schimbare transformatoare în educație, îndepărtându-se de curriculum-urile standardizate către abordări centrate pe student care se adaptează călătoriei unice a fiecărui elev. În loc să grupeze elevii după vârstă sau niveluri predefinite, sistemele personalizate se adaptează continuu la nevoile, preferințele și ritmul cursanților. Această schimbare de accent le dă putere elevilor să preia un rol activ în călătoria lor de învățare, stimulând o mai mare implicare și responsabilitate asupra traseului lor educațional.

Adaptarea conținutului de învățare pe bază de date

Inteligența artificială joacă un rol central în susținerea învățării personalizate. Prin analiza datelor structurate, cum ar fi scorurile evaluărilor și tiparele de prezență, precum și a inputurilor nestructurate, cum ar fi timpul petrecut pe sarcini și tiparele de interacțiune, IA poate construi profiluri detaliate de învățare. Aceste profiluri informează adaptarea dinamică a materialelor, formatelor și nivelurilor de complexitate, asigurând că fiecărui cursant i se prezintă sarcini care nu sunt nici prea simple, nici prea provocatoare. Adaptabilitatea în timp real a sistemului creează un mediu de învățare în evoluție care răspunde progresului și nevoilor elevilor, contribuind astfel la menținerea motivației și la reducerea frustrării.

Traseele personalizate reduc dezangajarea.


Un avantaj cheie al învățării personalizate este capacitatea sa de a aborda cauzele subiacente ale dezangajării școlare înainte ca acestea să escaladeze. Atunci când



elevii nu se pot identifica cu conținutul, simt că sunt în mod constant în urmă față de colegii lor sau percep școala ca fiind irelevantă, motivația lor are de suferit. Totuși, oferind multiple trasee de învățare care sunt aliniate cu interesele și capacitățile individuale, învățarea personalizată poate restabili relevanța și scopul experienței educaționale a elevilor. Acest lucru este deosebit de important pentru cursanții care nu se încadrează în modelele educaționale tradiționale sau care au întâmpinat dificultăți.

Sprijinirea obiectivelor și definițiilor de succes diferențiate

Sistemele tradiționale se bazează adesea pe definiții înguste ale realizării. În schimb, învățarea personalizată adoptă o viziune mai largă asupra succesului, incluzând nu doar competența academică, ci și progresul în abilități precum colaborarea, rezolvarea de probleme și autoreglarea emoțională. Instrumentele IA pot urmări aceste dimensiuni și pot oferi feedback care recunoaște îmbunătățirea incrementală. Acest lucru încurajează perseverența și încrederea în sine – două elemente critice în prevenirea părăsirii timpurii a școlii.



Promovarea flexibilității și învățării continue

Învățarea personalizată permite o flexibilitate mai mare în ceea ce privește momentul, locul și modul în care elevii învață. Acest lucru este deosebit de benefic pentru cursanții care se confruntă cu provocări externe, cum ar fi probleme de sănătate, responsabilități de îngrijire sau bariere socio-economice. Prin decuplarea învățării de orarele rigide și locațiile fizice, sistemele activate de IA ajută la asigurarea continuității și accesului, reducând astfel probabilitatea ca dificultățile temporare să ducă la o dezangajare permanentă.

Sustținerea conștientizării de sine în învățare

O altă caracteristică cheie a învățării personalizate este capacitatea sa de a încuraja metacogniția. Tablourile de bord în timp real, instrumentele de urmărire a progresului și feedback-ul inteligent ghidează elevii prin conținut și îi încurajează să reflecte asupra

procesului lor de învățare. Abilitatea de a înțelege cum învață, de a identifica strategii eficiente și de a se adapta în consecință le dă putere elevilor să devină mai autonomi și mai rezilienți.

Condiții pentru implementarea cu succes

Pentru a realiza beneficiile complete ale învățării personalizate, aceasta trebuie integrată cu atenție în ecosistemul educațional mai larg. Acest lucru implică asigurarea accesului echitabil la tehnologie, infrastructură digitală și platforme de învățare ușor de utilizat, incluzive. Este esențial ca profesorii să fie instruiți nu doar în utilizarea instrumentelor IA, ci și în înțelegerea modului de interpretare a rezultatelor acestora, de menținere a autonomiei pedagogice și de gestionare a implicațiilor etice ale utilizării datelor.

2. Intervenție timpurie

Introducere

Părăsirea timpurie a școlii este o provocare majoră pentru toate statele membre ale Uniunii Europene. Aceasta afectează nu doar parcursul individual al tinerilor, ci și coeziunea socială, productivitatea economică și competitivitatea pe termen lung a societăților europene. Un tânăr care părăsește școala înainte de a dobândi abilități de bază este expus unui risc ridicat de șomaj, excluziune socială și oportunități limitate de dezvoltare personală. Uniunea Europeană a recunoscut gravitatea acestui fenomen și a stabilit obiective ambițioase pentru reducerea sa. Intervenția timpurie este considerată cea mai eficientă strategie de prevenire a abandonului școlar, deoarece abordează factorii de risc la timp și oferă sprijin personalizat elevilor vulnerabili.

Context și definiții europene

Părăsirea timpurie a școlii și formării (PTSF) este definită ca procentul tinerilor cu vârste cuprinse între 18 și 24 de ani care au absolvit cel mult învățământul secundar inferior și care nu sunt implicați în educație sau formare. În 2023, rata medie a UE a fost de 9,5%, apropiată de obiectivul pentru 2030 de sub 9%. Cu toate acestea, diferențele între state sunt semnificative. În unele țări nordice și central-europene, rata este sub 5%, în timp ce în statele din sud și est depășește adesea 12–14%. Motivele pentru care tinerii părăsesc prematur educația nu sunt singulare. Ele reflectă un set întrețesut de influențe: dificultăți personale, circumstanțe familiale, deficiențe instituționale și mediul comunitar mai larg. Niciun factor singur nu explică abandonul școlar; mai degrabă, interacțiunea acestor condiții duce la dezangajare. Secțiunile următoare examinează aceste dimensiuni în detaliu.

Factori de risc principali:

Factori individuali

Experiențele și capacitățile cursantului sunt centrale pentru înțelegerea părăsirii timpurii.

Absenteism cronic este unul dintre cei mai puternici predictorii. Când elevii absentează frecvent, aceștia rămân în urmă din punct de vedere academic, pierd legături sociale și încep să considere școala ca fiind periferică vieții lor de zi cu zi.


Performanță academic scăzută adâncește acest risc.

Eșecurile repetate erodează încrederea, făcându-i pe elevi să se simtă incapabili să îndeplinească așteptările. În sistemele în care repetarea clasei este frecventă, elevii se pot descuraja atunci când progresul lor pare blocat

Lipsa de motivație apare adesea atunci când elevii nu văd relevanța educației pentru viitorul lor. Dacă programele de învățământ par abstracte, deconectate de viața reală sau de perspectivele de angajare, implicarea scade.

Provocările de sănătate mintală Probleme precum anxietatea, depresia sau dificultățile de comportament adaugă un alt nivel de vulnerabilitate. Fără un sprijin adecvat, aceste probleme pot submina prezența, concentrarea și performanța.

Răspunsuri politice: Sistemele de avertizare timpurie care urmăresc prezența și performanța pot identifica riscurile înainte ca acestea să se înrădăcineze. Școlile trebuie să ofere meditații specifice, îndrumare personalizată și acces la consiliere în



cadrul școlii. Reformele curriculare care evidențiază relevanța - prin învățare bazată pe proiecte, opțiuni vocaționale și orientare în carieră - pot consolida motivația.

Factori legați de familie

Contextul familial exercită o influență puternică asupra rezultatelor educaționale.

Educație parentală este un determinant cheie. Atunci când părinții înșiși au o educație limitată, este posibil să nu aibă cunoștințele sau încrederea necesare pentru a sprijini studiile copiilor lor sau pentru a se implica activ cu profesorii și școlile.

Sărăcia și privarea materială creează obstacole practice: incapacitatea de a-și permite rechizite școlare, internet fiabil sau transport sigur poate reduce participarea. Presiunile economice pot, de asemenea, să-i împingă pe tineri spre angajare timpurie, în special în familiile care se confruntă cu șomaj sau cu locuri de muncă precare.

Sprijin familial limitat – fie din cauza orelor lungi de lucru, a barierelor lingvistice sau a marginalizării sociale – poate slăbi încurajarea de care elevii au nevoie pentru a persevera. În unele gospodării, instabilitatea sau conflictul familial erodează și mai mult condițiile de învățare.

Răspunsuri politice: Reducerea influenței mediului socio-economic necesită un sprijin specific. Acesta include măsuri financiare, cum ar fi mesele gratuite în școli, subvențiile pentru transport și sprijinul financiar pentru familiile defavorizate. Programele care consolidează implicarea părinților - prin ateliere, vizite la domiciliu sau mediatori comunitari - contribuie la consolidarea legăturii dintre casă și școală. Politicile sociale mai ample care atenuează sărăcia infantilă sprijină, de asemenea, în mod direct nivelul de educație.

Factori legați de școală

Mediul școlar poate fie proteja împotriva, fie contribui la abandonul timpuriu.

Un climat educational slab, marcat de așteptări scăzute, disciplină limitată sau relații negative cu colegii, diminuează sentimentul de apartenență. Agresivitatea și excluderea, dacă nu sunt abordate, îi înstrăinează adesea pe elevii vulnerabili.

Resurse insuficiente împiedică școlile să ofere sprijinul specific de care au nevoie elevii cu dificultăți. Sălile de clasă supraaglomerate, lipsa personalului specializat și accesul limitat la activități extracurriculare reduc oportunitățile de implicare.

Metode de predare care nu sunt adaptate la nevoi diverse creează riscuri suplimentare. Abordările tradiționale, bazate pe prelegeri, pot înstrăina elevii cu stiluri de învățare diferite, în timp ce diferențierea limitată îi lasă pe unii în urmă. Programele de învățământ prea rigide sau bazate pe examene pot să nu reușească să capteze interesul celor care caută învățare practică sau aplicată.

Răspunsuri politice: Consolidarea climatului școlar necesită strategii la nivelul întregii școli pentru a promova incluziunea, programe anti-bullying și participarea elevilor la luarea deciziilor. Investițiile în formarea profesorilor pot dota educatorii cu pedagogii incluzive și abilități de instruire diferențiate. Finanțarea adecvată pentru școlile subdeservite asigură că acestea pot oferi meditații, activități extracurriculare și clase mai mici. Extinderea opțiunilor de învățare profesională și bazată pe proiecte face ca școala să fie mai relevantă și mai atractivă pentru o gamă mai largă de elevi.

Factori legați de comunitate

Contextul comunitar mai larg determină accesibilitatea și valoarea educației.

Lipsa oportunităților locale – fie în formare, ucenicie sau angajare - poate slăbi valoarea percepută a finalizării educației. Dacă traseele de la școală la muncă sunt neclare, elevii își pot pierde motivația.

Dificultăți de transport creează bariere concrete, în special în regiunile rurale sau periferice. Navetele lungi, costisitoare sau nesigure descurajează participarea regulată la cursuri.

Presiunea de a lucra la o vârstă fragedă apare în comunitățile în care sunt disponibile locuri de muncă slab calificate sau în care normele culturale pun accentul pe contribuția economică timpurie. Pentru unele familii, venitul imediat depășește promisiunea beneficiilor pe termen lung din continuarea școlarizării.

Răspunsuri politice: Investițiile în rețele de transport fiabile și accesibile sunt cruciale pentru a asigura accesul elevilor din mediul rural. Parteneriatele dintre școli, angajatori și furnizorii de formare pot ajuta la alinierea educației cu piețele locale ale muncii și la vizibilitatea traseelor. Centrele de tineret comunitare, programele de mentorat și

inițiativele extracurriculare oferă spații alternative pentru implicare. Măsurile de reglementare a muncii copiilor și de promovare a oportunităților de angajare a tinerilor legate de formare pot reduce, de asemenea, tranzițiile premature de la școală la muncă.

Concluzii

Părăsirea timpurie a școlii nu este rezultatul unei singure cauze, ci al unei rețele de factori interconectați care cuprind individul, familia, școala și comunitatea. Abordarea acestora necesită o abordare politică holistică. Eforturile trebuie să înceapă cu prevenirea: monitorizarea prezenței, sprijinirea elevilor aflați în situații de risc și transformarea educației într-una relevantă și captivantă. Familiile trebuie să fie împuternicite ca parteneri, cu sprijin financiar și social pentru a depăși barierele materiale. Școlile trebuie să fie dotate cu resursele, personalul și pedagogiile necesare pentru a-i include pe toți elevii. Comunitățile trebuie să se asigure că educația este accesibilă și legată în mod clar de oportunități semnificative.

Abordând aceste dimensiuni într-un mod integrat, UE și statele sale membre se pot apropia de obiectivul pentru 2030 și, mai important, se pot asigura că fiecare tânăr are șansa de a-și finaliza educația și de a intra în viața adultă cu încredere, oportunități și speranță.

Cadrul strategic și politicile europene

Uniunea Europeană a dezvoltat mai multe instrumente pentru a sprijini statele membre:

- Recomandarea Consiliului „Căi către succesul școlar” (2022) – stabilește un cadru integrat bazat pe prevenire, intervenție timpurie și măsuri compensatorii.
- Spațiul European al Educației 2030 – stabilește obiective clare: reducerea abandonului școlar timpuriu la sub 9%, asigurarea unei participări de cel puțin 96% la educația timpurie a copiilor și reducerea ponderii elevilor cu performanțe scăzute la citire, matematică și științe la sub 15%.
- Planul de acțiune pentru educația digitală 2021–2027 – sprijină incluziunea digitală, oferă resurse pentru profesori și elevi și combate inegalitățile în accesul la educația online.
- Garanția europeană pentru copii (2021) – asigură accesul la educație de calitate, asistență medicală, mese sănătoase și condiții de viață decente.
- Fonduri UE: prin intermediul FSE+, Erasmus+ și RRF, statele membre primesc resurse pentru infrastructura școlară, sprijinirea cadrelor didactice și implementarea programelor de reducere a abandonului școlar.

Intervenția timpurie – concept și mecanisme

Intervenția timpurie este esențială și implică acțiuni coordonate atunci când un elev prezintă semne de risc. Mecanismele includ:

- Sisteme de avertizare timpurie (SAT).
- Planuri de sprijin individualizate (mentorat, meditații).
- Consiliere psihologică și sprijin emoțional.
- Implicarea parentală și comunitară.
- Tranziții asistate.

Impactul și beneficiile intervenției timpurii

Intervenția timpurie aduce multiple beneficii:

- Crește șansele de finalizare a studiilor și de integrare pe piața muncii.
- Reduce riscul de sărăcie și excluziune socială.
- Îmbunătățește bunăstarea elevilor și a familiilor.
- Adaugă valoare economică printr-o forță de muncă mai bine calificată.

Studiile arată că investițiile în prevenire și intervenție timpurie sunt mai eficiente și mai puțin costisitoare decât măsurile compensatorii luate după ce un elev a părăsit deja școala.

Concluzii

Abandonul școlar timpuriu rămâne o problemă complexă, dar intervenția timpurie este una dintre cele mai eficiente soluții. Uniunea Europeană oferă cadrul strategic și resursele, dar succesul depinde de modul în care fiecare stat membru, inclusiv România, reușește să implementeze măsuri adaptate propriului context. Prin cooperarea dintre școli, familii, comunități și instituții europene, se poate atinge obiectivul de reducere a abandonului școlar timpuriu sub 9% până în 2030.

3. Strategii didactice îmbunătățite

Strategii didactice îmbunătățite

Îmbunătățirea strategiilor didactice este esențială pentru crearea unor medii de învățare incluzive, captivante și echitabile, în special pentru elevii cu risc de părăsire timpurie a sistemului de educație și formare profesională (ELET). În timp ce învățarea personalizată și intervenția timpurie se concentrează pe elev, strategiile de predare îmbunătățite abordează metodele și sistemele utilizate de educatori pentru a oferi o instruire eficientă. Integrarea instrumentelor de asistență a deciziilor bazate pe date permite o trecere de la predarea reactivă la cea proactivă, susținând practici pedagogice mai receptive, informate și inovatoare.

De la intuiție la pedagogia bazată pe dovezi

Traditional teaching often relies on educator's intuition and experience. While valuable, this approach may not always identify or address early signs of disengagement. Data analytics and AI technologies offer tools to systematically analyse student engagement, behaviour, and outcomes, supporting educators in making timely instructional decisions. For example, AI-based systems can assist teachers in adapting their strategies by offering real-time dashboards and smart alerts that prompt timely pedagogical adjustments. The RADAR system (Embarak & Hawarna, 2024) and the PDAR/LIS tools (Baneres, Rodriguez-Gonzalez, & Guerrero-Roldan, 2023) exemplify how real-time data feedback loops allow educators to spot and respond to learning problems early, often before traditional assessments would flag a concern. Though these systems were developed for tertiary education, the underlying principles of predictive analytics and continuous monitoring are equally relevant in school settings.

Învățarea mixtă și activă ca pedagogii strategice

Strategiile de predare care combină instrumentele digitale cu metode colaborative, bazate pe proiecte, pot fi extrem de eficiente în prevenirea ELET (Educația Electronică Tradițională în Învățare). Inițiativele islandeze Austur-Vestur Sköpunarsmiðjur (Austur-Vestur Sköpunarsmiðjur, fără date) și Mixtúra (Mixtúra, fără date) ilustrează modul în care tehnologiile creative și spațiile de producție pot re-implica elevii, punând accentul pe învățarea practică, rezolvarea problemelor și capacitatea de a acționa. Aceste medii oferă elevilor noi modalități de a demonstra învățarea și de a promova abilități precum perseverența, munca în echipă și creativitatea. De asemenea, programul italian Classe AI (Classe AI, 2025) integrează educația bazată pe IA în activitățile din clasă, încurajând atât profesorii, cât și elevii să exploreze IA în mod critic și creativ. Acest lucru susține dezvoltarea alfabetizării digitale și demitizează tehnologiile care sunt adesea văzute ca fiind distante sau opace.

Împuternicire profesională și practică refelexivă

Strategiile de predare îmbunătățite sunt sustenabile doar atunci când educatorii sunt sprijiniți în dezvoltarea lor profesională. După cum se observă în centrul Mixtúra din Reykjavík, integrarea învățării profesionale continue în politica educațională locală creează o cultură în care inovația este o practică sistemică, nu o inițiativă singulară. Programul Național pentru Succesul Școlar din Portugalia pune accentul pe planificarea acțiunilor localizate, condusă de profesori, în cadrul căreia școlile dezvoltă strategii specifice contextului, bazate pe date de autoevaluare. Acest lucru consolidează capacitatea profesorilor de a acționa și încurajează asumarea responsabilității asupra schimbării, încurajând educatorii să reflecteze asupra practicilor lor și să monitorizeze impactul acestora, creând un ciclu de îmbunătățire iterativă. IA

poate sprijini în continuare acest lucru prin crearea de căi de dezvoltare profesională extrem de personalizate pentru profesori, sugerând cercetări relevante, module de formare sau chiar oferind îndrumare bazată pe inteligență artificială, bazată pe provocările specifice din clasă.

Rolul AI în evoluția pedagogiei

Looking forward, the role of AI can expand beyond current applications to become a true "cognitive partner" for both teachers and students. Advanced AI teaching assistants could act as a sophisticated co-pilot for teachers, not just flagging at-risk students but also suggesting pedagogical approaches for difficult topics, automating the creation of diverse assessment tools, and handling routine administrative tasks. This would free up teachers to focus on direct student interaction and complex pedagogical planning. For students, AI tutors could engage them in Socratic dialogues to prompt critical thinking or help them visualise their own learning journeys to develop metacognitive skills and self-regulation.

Implicații strategice și un viitor centrat pe om

Aceste strategii de predare îmbunătățite contribuie direct la reducerea riscului de abandon școlar prin creșterea implicării elevilor, oferind căi diverse către succes și creând medii de învățare suportive în care elevii se simt văzuți și motivați. Cu toate acestea, pentru a valorifica aceste posibilități viitoare, sunt esențiale câteva considerații strategice. Pe măsură ce IA devine mai integrată, cadrele etice robuste, protecțiile puternice ale confidențialității (cum ar fi GDPR) și atenuarea activă a prejudecăților algoritmice nu sunt negociabile. Tehnologia ar trebui să fie întotdeauna poziționată ca un instrument care să contribuie și să împuternicească profesorii, nu să înlocuiască judecata lor profesională sau conexiunea umană. Pentru orice decizie critică, o persoană trebuie să rămână la curent. În cele din urmă, asigurarea echității digitale - în care toți elevii și profesorii au acces la tehnologia și competențele necesare - va fi primordială pentru a împiedica IA să amplifice inegalitățile existente.

Preocupări

1. Confidențialitatea și securitatea datelor

Pe măsură ce instituțiile de învățământ se bazează din ce în ce mai mult pe inteligența artificială (IA) și pe luarea deciziilor bazate pe date pentru a personaliza experiențele de învățare, a optimiza performanța elevilor și a spori eficiența administrativă, preocupările legate de confidențialitate, securitate și conformitate cu reglementările Uniunii Europene (UE) au devenit mai presante. Implementarea IA în educație trebuie evaluată cu atenție pentru a asigura utilizarea etică, conformitatea legală și protejarea drepturilor fundamentale ale elevilor.

Una dintre principalele preocupări legate de instrumentele educaționale bazate pe inteligență artificială este accesibilitatea acestor sisteme pentru minori. Conform articolului 8 din GDPR, prelucrarea datelor cu caracter personal ale copiilor sub 16 ani (sau 13 ani în unele țări ale UE) necesită consimțământul verificabil al părinților. Dacă sistemul de inteligență artificială este conceput pentru grupuri vulnerabile, cum ar fi studenții neurodivergenți sau persoanele cu dizabilități, trebuie să existe garanții suplimentare pentru a evita părtinirea și a asigura transparența.



Multe aplicații educaționale bazate pe inteligență artificială necesită acces la dispozitivele utilizatorilor, colectând adesea date din liste de contacte, fișiere media, microfoane, camere, geolocalizare și chiar senzori biometrici. Un astfel de acces extins la date ridică semnale de alarmă cu privire la principiile de minimizare a datelor în temeiul articolului 5 din GDPR. Instituțiile și furnizorii de tehnologie trebuie să evalueze dacă permisiunile solicitate sunt strict necesare pentru funcționalitatea instrumentului și dacă utilizatorii își pot oferi consimțământul informat înainte de a acorda accesul.

Colectarea și prelucrarea datelor cu caracter personal

Tipul și amploarea datelor cu caracter personal colectate de sistemele de inteligență artificială trebuie justificate în temeiul articolului 9 din GDPR, care impune condiții stricte privind prelucrarea unor categorii speciale de date, cum ar fi informațiile biometrice, dosarele medicale sau analiza comportamentală. Sistemele de inteligență artificială

utilizate în educație colectează adesea cantități uriașe de date, inclusiv dosarele academice ale studenților, modele de interacțiune și chiar răspunsuri emoționale.

Dacă colectarea datelor este disproporționată față de scopul propus, aceasta încalcă principiul proporționalității datelor și ar putea duce la expunerea inutilă a informațiilor sensibile.

Temeiul juridic și consimțământul juridic

Instituțiile de învățământ și furnizorii de IA trebuie să stabilească un temei juridic pentru prelucrarea datelor cu caracter personal. În funcție de cazul de utilizare, acesta poate fi consimțământul explicit, necesitatea contractuală sau interesul legitim. Cu toate acestea, dacă sistemul de IA implică profilare, luarea automată a deciziilor sau urmărirea comportamentală, articolul 22 din GDPR acordă persoanelor dreptul de a contesta și de a renunța la o astfel de prelucrare. În plus, instituțiile trebuie să se asigure că mecanismele de consimțământ parental pentru minori sunt robuste, prevenind colectarea neautorizată de date de la copii fără garanții adecvate.

Stocarea, păstrarea și securitatea datelor

Un aspect crucial al guvernantei inteligenței artificiale în educație este locația de stocare și durata datelor colectate. Dacă datele elevilor sunt stocate în afara UE, trebuie să existe clauze contractuale standard (CSC) pentru a asigura conformitatea cu GDPR. În plus, principiul limitării stocării (articolul 5 din GDPR) prevede că datele ar trebui păstrate doar atât timp cât este necesar pentru îndeplinirea scopului propus.



Riscurile de securitate cibernetică reprezintă, de asemenea, o provocare semnificativă, deoarece accesul neautorizat la datele educaționale poate duce la furtul de identitate, publicitate direcționată sau chiar manipularea dosarelor studenților. Instituțiile trebuie să implementeze criptare, controale stricte ale accesului și tehnici de anonimizare pentru a atenua aceste riscuri și a preveni încălcările.

Preocupări specific AI în instrumentele educaționale

Dincolo de preocupările standard legate de confidențialitate, platformele educaționale bazate pe inteligență artificială introduc riscuri unice care necesită o supraveghere specializată:



- **Învățare adaptivă și urmărire comportamentală:** Sistemele de inteligență artificială care analizează interacțiunile elevilor și adaptează conținutul în consecință trebuie să fie transparente în ceea ce privește utilizarea datelor.
- **Realitate augmentată (RA) și scanare a mediului:** Funcțiile RA bazate pe inteligență artificială care scanează împrejurimile utilizatorului pot capta în mod accidental date de la terți, fără consimțământul acestuia.
- **Inteligență artificială generativă și asistenți virtuali:** Dacă chatboții sau agenții de meditații bazați pe inteligență artificială interacționează dinamic cu elevii, trebuie să existe mecanisme pentru a preveni dezinformarea, prejudecățile sau stocarea neautorizată a datelor.

Partajarea datelor cu terți și conformitatea cu reglementările

Implicarea furnizorilor terți în educația bazată pe inteligență artificială ridică preocupări suplimentare cu privire la partajarea datelor. Dacă datele studenților sunt transferate către terți în scopuri de analiză, marketing sau instruire privind modelele de inteligență artificială, Acordurile de prelucrare a datelor (DPA) în temeiul articolului 28 din GDPR sunt obligatorii. Instituțiile trebuie să asigure transparență deplină cu privire la entitățile care au acces la date și în ce scopuri.

Transparență în evaluarea riscurilor

Pentru a atenua riscurile asociate cu IA în educație, instituțiile ar trebui să efectueze evaluări ale impactului asupra protecției datelor (DPIA), așa cum prevede articolul

7 PRINCIPLES OF PRIVACY BY DESIGN

1



Proactive not reactive; preventative not remedial

Take a proactive rather than reactive approach to privacy. Identify and mitigate privacy risks before they happen.

2



Privacy as the default setting

Design privacy-by-default features to ensure that consumers don't have to take extra measures to protect privacy.

3



Privacy embedded into design

Take a privacy-first approach right from the initial stages of a product's development and design.

4



Full functionality – positive-sum, not zero-sum

Privacy is a positive-sum goal, not a zero-sum goal. Avoid the false idea of trade-offs between privacy and other functionalities.

5



End-to-end security – lifecycle protection

Prioritise the security of user data throughout its lifecycle, from data collecting to its deletion.

6



Visibility and transparency

Implement transparency by documenting and communicating actions clearly, through privacy and data-sharing policies.

7



Respect for user privacy

Keep the interests of your users at the core by building strong privacy safeguards and user-friendly systems.

Source:
www.cookieyes.com/blog/privacy-by-design

CookieYes
f t in /CookieYesHQ

35 din GDPR. DPIA ajută la identificarea riscurilor potențiale, la evaluarea strategiilor de atenuare și la asigurarea conformității cu standardele legale și etice. În plus, instituțiile de învățământ trebuie să ofere elevilor și părinților politici de confidențialitate clare și adecvate vârstei, asigurându-se că aceștia își înțeleg drepturile și implicațiile deciziilor bazate pe IA.

Protecția datelor și controlul utilizatorilor

Conform principiului privind **confidențialitatea prin proiectare (articolul 25 din GDPR)**, instrumentele de inteligență artificială ar trebui configurate pentru a colecta în mod implicit **minimul de date necesar**. Elevii și părinții trebuie să aibă acces facil la **setările de confidențialitate, mecanismele de dezabonare și opțiunile de ștergere a datelor**. Mai mult, instituțiile trebuie să asigure respectarea **drepturilor persoanelor vizate** (articolele 15-22), permițând utilizatorilor să acceseze, **să corecteze, să șteargă sau să își poarteze datele** atunci când este necesar.

Măsuri de asigurare a vârstei și siguranța copiilor

Având în vedere preocupările tot mai mari legate de **verificarea vârstei**, platformele educaționale bazate pe inteligență artificială trebuie să echilibreze securitatea cu confidențialitatea. Deși mecanismele de asigurare a vârstei pot ajuta la protejarea minorilor, soluțiile implementate defectuos pot introduce **noi riscuri**, cum ar fi colectarea excesivă de date sau metodele de identificare eronate. Instituțiile ar trebui să acorde prioritate soluțiilor care oferă **garanții eficiente fără a încălca drepturile la confidențialitate**.

Suportul decizional bazat pe date în educație are un potențial imens de a revoluționa experiențele de învățare, oferind **educație personalizată, accesibilitate îmbunătățită și procese administrative eficiente**.

Totuși, aceste beneficii vin la pachet cu provocări semnificative în materie de **confidențialitate, securitate și etică**. Prin respectarea reglementărilor UE, implementarea **unor măsuri solide de protecție a datelor, efectuarea de evaluări ale riscurilor și asigurarea transparenței**, instituțiile de învățământ pot valorifica potențialul IA, protejând în același timp drepturile și interesele studenților.

Pe măsură ce IA în educație continuă să evolueze, **echilibrul dintre inovație și responsabilitate** va rămâne esențial. Factorii de decizie politică, educatorii și dezvoltatorii de IA trebuie să colaboreze pentru a crea **sisteme de IA de încredere, echitabile și conforme cu reglementările** privind confidențialitatea, care să îmbunătățească cu adevărat educația fără a compromite drepturile fundamentale.

2. Dependența excesivă de date

Vastul volum de date din societate a dus la utilizarea tehnologiilor bazate pe algoritmi, cum ar fi inteligența artificială (IA) și învățarea automată (ML), pentru a organiza și interpreta informațiile. Cu toate acestea, dependența excesivă de date poate fi problematică dacă aceste sisteme nu sunt proiectate corespunzător. IA depinde de informații cuantificabile, ceea ce ridică îngrijorări cu privire la faptul dacă realitățile complexe pot fi cu adevărat reduse la date. În cele din urmă, prejudecățile, percepțiile și viziunile umane asupra lumii modelează proiectarea și evaluarea acestor sisteme, impunând limitări mai mari decât tehnologia în sine. Chiar și pe măsură ce mașinile învață, oamenii își definesc punctul de plecare și cadrul de învățare (Kallberg, 2022).

Dependența excesivă de date se referă la o dependență excesivă de modelele bazate pe date pentru luarea deciziilor, fără a lua în considerare contextul, judecata umană sau factorii externi, mai ales atunci când datele utilizate sunt eronate, limitate sau lipsite de diversitate

Echilibrarea cantității și calității datelor

Modelele de învățare automată, în special algoritmi de învățare profundă, necesită adesea cantități substanțiale de date pentru a identifica modele complexe. Cu toate acestea, calitatea nu ar trebui niciodată sacrificată în favoarea cantității (Pagadala, 2023). În domeniul complex al învățării automate, găsirea echilibrului perfect între cantitatea și calitatea datelor este similară cu echilibrul pe o sârmă întinsă. Pe de o parte, mai multe date oferă modelului o perspectivă mai largă, permițându-i să generalizeze mai bine datele nevăzute. Pe de altă parte, datele de înaltă calitate asigură că modelul învață din modele fiabile, rezultând predicții precise. În timp ce cantitatea asigură exhaustivitatea, calitatea garantează acuratețea.

- **Cantitate în detrimentul calității:** Dacă datele sunt abundente, dar o mare parte din ele sunt de calitate scăzută, modelul ar putea învăța modele incorecte, ducând la predicții nesigure.
- **Calitate în detrimentul cantității:** În schimb, existența unor date de înaltă calitate, dar insuficiente, poate limita capacitatea modelului de a generaliza la diverse scenarii.

Îmbunătățirea calității datelor

Datele, așa cum sunt definite de Andrea Jones-Rooy, reprezintă o aproximare imperfectă a unui aspect al lumii la un anumit moment și loc (Jones-Rooy, 2019). Atâta timp cât datele sunt considerate adevăr rece, dur și infailibil, riscăm să generăm și să consolidăm o mulțime de înțelegeri inexacte ale lumii din jurul nostru. Din acest motiv, calitatea datelor are un impact direct asupra performanței, preciziei și fiabilității

modelelor de IA (Redman, 2018). Datele de înaltă calitate permit modelelor să facă predicții mai bune și să producă rezultate mai fiabile, promovând încrederea în rândul utilizatorilor (Ataman, 2024).

Asigurarea calității datelor înseamnă, de asemenea, abordarea prejudecăților prezente în date, ceea ce este esențial pentru a evita perpetuarea și amplificarea acestor prejudecăți în rezultatele generate de IA. În plus, un set de date divers și reprezentativ îmbunătățește capacitatea unui model de IA de a generaliza bine în diferite situații și intrări, asigurându-i performanța și relevanța în diverse contexte și grupuri de utilizatori. În cele din urmă, menținerea calității datelor este esențială pentru realizarea întregului potențial al sistemelor de IA în furnizarea de valoare, stimularea inovației și asigurarea rezultatelor etice.

Componentele cheie ale datelor de calitate în domeniul inteligenței artificiale sunt acuratețea, consecvența, caracterul complet, actualitatea, relevanța, integritatea, diversitatea și reprezentativitatea.

- **Acuratețe:** Datele precise și fără erori asigură că modelele de IA învață din informații corecte, reducând riscul unor predicții înșelătoare și al unor decizii deficitare. În schimb, erorile în introducerea datelor pot duce la decizii incorecte sau la perspective eronate, putând cauza daune semnificative atât organizațiilor, cât și indivizilor.

- **Completitudine:** Seturile de date complete care captează toate variabilele relevante previn lacunele informaționale, permițând modelului să identifice tipare și relații semnificative. Dimpotrivă, incompletitudinea datelor se referă la situația în care setul de date utilizat pentru antrenarea unui model de învățare automată duce lipsă de anumite informații sau are valori lipsă pentru unele dintre caracteristicile sale. Seturile de date incomplete pot împiedica algoritmi de IA să detecteze tipare și corelații critice, compromițând capacitatea modelului de a generaliza eficient la date noi, nevăzute.

- **Consistență:** Datele uniforme în diferite surse și intervale de timp evită contradicțiile și asigură că modelul primește informații coerente, îmbunătățind stabilitatea și fiabilitatea, în timp ce datele inconsistente pot duce la confuzie și interpretări greșite, afectând performanța sistemelor de IA.

- **Relevanță:** Datele trebuie să fie direct legate de problema abordată. Datele relevante contribuie direct la problema în cauză, ajutând sistemele de inteligență artificială să se concentreze asupra celor mai importante variabile și relații. Datele irelevante pot aglomera modelele și pot introduce zgomot, reducând eficacitatea modelului.

- **Actualitate:** Datele actualizate asigură că modelul reflectă tendințele și comportamentele actuale, ceea ce este esențial pentru adaptarea la medii în schimbare, în timp ce datele învechite au ca rezultat rezultate irelevante sau înșelătoare. De aici, importanța sistemelor de antrenament cu date actuale pentru a asigura performanțe ridicate ale inteligenței artificiale.
- **Diversitate și reprezentativitate:** Seturi de date diverse și imparțiale ajută modelele să se generalizeze bine în diferite populații și scenarii, reducând la minimum riscul unor rezultate părtinitoare. Dacă datele colectate nu sunt reprezentative pentru întreaga populație, acestea pot duce la concluzii părtinitoare. Predicțiile modelului vor fi o reflectare directă a acelor date.
- **Integritate:** Datele securizate și nealterate protejează împotriva corupției sau manipulării, asigurând rezultate demne de încredere.

Pentru a ilustra impactul problemelor legate de calitatea datelor, în special al datelor incomplete, să luăm în considerare un sistem de predicție a abandonului școlar care se bazează exclusiv pe date istorice despre elevi, cum ar fi notele, prezența și indicatorii de implicare. Cu toate acestea, modelul trece cu vederea factorii necuantificabili, cum ar fi problemele de sănătate mintală sau provocările personale. Prin urmare, elevii care se confruntă cu dificultăți emoționale, dar care mențin performanțe academice solide, pot trece neobservați și nu pot primi sprijinul necesar, reducând în cele din urmă eficacitatea modelului în identificarea elevilor aflați în situații de risc.

Permiterea modelelor să învețe și să se adapteze în timp

Mediul în care funcționează învățarea automată poate evolua sau diferi de ceea ce au fost dezvoltate algoritmi. Deși acest lucru se poate întâmpla în multe feluri, două dintre cele mai frecvente sunt deriva conceptelor și schimbarea covariatelor. În cazul primelor cazuri, relația dintre intrările pe care le utilizează sistemul și ieșirile sale nu este stabilă în timp sau poate fi specificată greșit (Babic, Cohen, Evgeniou și Gerke, 2021).

Să presupunem că o universitate folosește un model de învățare automată antrenat pe date pre-pandemice pentru a prezice riscul de abandon școlar al studenților. Modelul se bazează pe factori precum prezența la cursuri, participarea la activitățile din campus și utilizarea suportului academic față în față. Cu toate acestea, în timpul și după pandemia de COVID-19, universitatea a trecut la învățarea online și hibridă. Comportamentele și modelele de implicare ale studenților se schimbă - prezența este acum virtuală, activitățile din campus sunt limitate, iar studenții se bazează mai mult pe resurse digitale.

Modelul, antrenat pe date de învățare față în față, nu reușește să țină cont de aceste schimbări comportamentale. Acesta marchează în mod inexact studenții ca fiind cu risc ridicat, deoarece indicatorii tradiționali (cum ar fi prezența fizică) nu se mai aplică. În schimb, ar putea trece cu vederea elevii aflați în situații de risc care se confruntă cu dificultăți în învățarea online din cauza accesului deficitar la internet, a izolării sau a problemelor de sănătate mintală.

Precizia predictivă a modelului scade deoarece relația dintre datele de intrare și riscul de abandon școlar s-a modificat. Această modificare a tiparelor de date reflectă deviația conceptelor, subliniind necesitatea reantrenării modelului cu date actualizate pentru a se adapta la noul mediu de învățare.

Este crucial să se ofere modelelor posibilitatea de a învăța și de a se adapta continuu în timp, fără a fi necesară reantrenarea completă. Implementarea învățării continue și prin transfer permite modelelor să utilizeze eficient cunoștințele din sarcinile conexe, sporind adaptabilitatea și performanța.

Deplasările covariabile apar atunci când datele introduse într-un algoritm în timpul utilizării sale diferă de datele care l-au antrenat. Acest lucru se poate întâmpla chiar dacă tiparele învățate de algoritm sunt stabile și nu există deviație a conceptelor (Babic et al., 2021). Deplasarea covariabile este un tip specific de deplasare a setului de date întâlnit adesea în învățarea automată. Este vorba despre schimbarea distribuției datelor de intrare între mediul de instruire și mediul real.

O universitate dezvoltă un model de învățare automată pentru a prezice riscul de abandon școlar al studenților pe baza datelor istorice. Modelul utilizează caracteristici precum scorurile la testele standardizate, înregistrările de prezență și participarea la activități extracurriculare pentru a evalua riscul.

Universitatea a adoptat ulterior o politică de admitere cu teste opționale, reducând semnificativ numărul de studenți care prezintă rezultate la teste standardizate. În plus, învățământul online a devenit mai răspândit, schimbând metodele de urmărire a prezenței.

Deși relația dintre predictorii și riscul de abandon școlar (distribuția condiționată) rămâne aceeași, distribuția caracteristicilor de intrare (covariabile) s-a modificat. De exemplu, modelul primește acum mai puține scoruri la testele standardizate, ceea ce face ca această caracteristică să fie mai puțin informativă. În plus, datele de prezență colectate de pe platformele online diferă de înregistrările tradiționale față în față. Drept urmare, performanța modelului se deteriorează deoarece a fost antrenat pe date în care scorurile la testele standardizate și prezența față în față erau predictorii fiabili.

Această modificare a distribuției datelor de intrare, fără a altera relația rezultatului, exemplifică o modificare a covariabilelor. Pentru a remedia acest lucru, modelul trebuie reantrenat sau ajustat pentru a ține cont de noile distribuții de caracteristici.

Pentru a atenua modificările covariabilelor - modificările distribuției datelor de intrare între antrenament și testare - pot fi utilizate diverse strategii. Adaptarea domeniului aliniază distribuțiile datelor de antrenament și testare prin tehnici precum normalizarea caracteristicilor și învățarea adversă. Ponderarea importanței ajustează influența eșantionului de antrenament pe baza diferențelor de distribuție, în timp ce selecția robustă a caracteristicilor se concentrează pe caracteristici stabile pentru a minimiza sensibilitatea la modificări. Metodele de regularizare îmbunătățesc generalizarea, iar augmentarea datelor introduce diverse scenarii în model. Metodele de ansamblu combină mai multe modele pentru a echilibra varianțele distribuționale, iar învățarea online permite actualizări continue ale modelului cu date noi. În plus, adaptarea statisticilor de normalizare în loturi la domeniul țintă îmbunătățește și mai mult robustețea. Împreună, aceste abordări ajută la menținerea unei performanțe consecvente a modelului în diferite distribuții de date.

Integritatea datelor cu experiența anterioară, expertiză umană și cunoștințele din domeniu

Așa cum scrie Andrea Jones-Rooy în Quartz (Jones-Rooy, 2019), datele există în primul rând doar pentru că oamenii au ales să le colecteze și le-au colectat folosind instrumente create de om. Prin urmare, datele sunt la fel de falibile ca oamenii. Datele sunt esențiale pentru descoperire, dar necesită judecata umană pentru a le selecta, rafina și transforma în informații semnificative. În cele din urmă, valoarea datelor depinde de calitatea lor și de expertiza și abilitățile individului care le interpretează și le utilizează (Jones-Rooy, 2019; Taylor, 2020). Pe lângă gestionarea corectă a datelor, luarea în considerare a cunoștințelor din domeniu, înțelegerea procesului din spatele datelor și luarea în considerare a informațiilor contextuale sunt cruciale pentru performanța eficientă a modelelor de învățare automată. Aceste elemente contribuie la rezultate mai precise, fiabile și semnificative.

Atunci când datele sunt utilizate alături de alți factori decizionali, cum ar fi judecata experților și înțelegerea contextuală, impactul analizelor eronate este redus la minimum, deoarece acești factori suplimentari pot compensa potențialele inexactități. Totuși, atunci când datele servesc drept bază principală pentru luarea deciziilor, analizele eronate pot duce la erori semnificative și rezultate slabe. Concluzia cheie nu este de a respinge valoarea datelor, ci de a sublinia importanța integrării datelor și a informațiilor analitice cu instrumente complementare de luare a deciziilor, cum ar fi experiența anterioară și expertiza în domeniu. Bazarea exclusivă pe date ca sursă

supremă de adevăr poate submina procesul decizional și poate crește riscul de eroare (Nolis, 2018).

De exemplu, în prezicerea riscului de abandon școlar timpuriu, poate fi valoroasă încorporarea potențialelor relații cauzale identificate de profesori pentru a completa informațiile derivate din analiza datelor. Observațiile și experiențele directe ale profesorilor pot oferi factori specifici contextului pe care datele singure îi pot trece cu vederea, ducând la o evaluare a riscurilor mai cuprinzătoare și mai precisă.

Integrarea cunoștințelor din domeniu este esențială pentru îmbunătățirea performanței modelului, cum ar fi încorporarea perspectivei experților în selecția caracteristicilor, constrângerile modelului și logica decizională. În plus, combinarea modelelor bazate pe date cu sisteme de raționament bazate pe reguli sau simbolice poate îmbunătăți interpretabilitatea și fiabilitatea. Proiectarea sistemelor „human-in-the-loop” este la fel de importantă, permițând supravegherea umană în procesele decizionale critice și permițând intervenția și feedback-ul în timp util pentru a asigura rezultate mai precise și mai responsabile. În plus, inferența și raționamentul cauzal îmbunătățesc modelele predictive prin identificarea relațiilor adevărate cauză-efect, mai degrabă decât să se bazeze exclusiv pe corelații. Acest lucru duce la predicții mai robuste și mai generalizabile, deoarece modelele pot înțelege mai bine modul în care schimbările variabilelor de intrare influențează rezultatele. Drept urmare, modelele devin mai ușor de interpretat și mai fiabile, în special în medii complexe sau dinamice în care înțelegerea mecanismelor cauzale este crucială pentru predicții precise și acționabile.

Îmbunătățirea transparenței, ghidarea luării deciziilor și construirea încrederii și a înțelegerii

Oamenii aleg strategic dacă să se implice sau nu într-o explicație bazată pe IA, demonstrând empiric că există scenarii în care explicațiile bazate pe IA reduc dependența excesivă (Vasconcelos și colab., 2023). Utilizarea modelelor interpretabile sau a instrumentelor de explicabilitate face ca deciziile bazate pe IA să fie transparente și ușor de înțeles pentru părțile interesate. Explicațiile clarifică procesul decizional, ajutând utilizatorii să identifice când modelele depind prea mult de date sau de modele părtinitoare. Explicațiile oferă, de asemenea, puterea de a interveni experților în domeniu, asigurându-se că informațiile bazate pe date sunt echilibrate cu expertiza din lumea reală.

3. Considerente etice

Deși IA și instrumentele bazate pe date au un potențial semnificativ de a îmbunătăți educația și de a reduce părăsirea timpurie a sistemului de învățământ și formare profesională (ELET), utilizarea lor ridică și întrebări etice importante. Pentru a ne asigura

că aceste tehnologii sunt utilizate în mod responsabil, este esențial să abordăm preocupările legate de echitate, transparență, confidențialitate și impactul lor general asupra elevilor și educatorilor. Mai jos sunt câteva considerații etice cheie de care trebuie să ții cont:

1. Evitarea prejudecăților și asigurarea echității


Sistemele de IA se bazează pe date pentru a lua decizii, dar dacă aceste date reflectă inegalitățile existente, ar putea duce la rezultate nedrepte. De exemplu, elevii din medii defavorizate ar putea fi marcați incorect ca fiind „la risc” pur și simplu din cauza tiparelor din datele istorice. Acest lucru poate consolida stereotipurile și poate agrava inegalitățile. Pentru a preveni acest lucru, trebuie să examinăm cu atenție datele utilizate și să ne asigurăm că reprezintă toate grupurile în mod echitabil. Instrumentele de IA ar trebui concepute pentru a promova incluziunea, nu discriminarea, și pentru a trata fiecare elev ca individ.

2. Luarea deciziilor clare și ușor de înțeles

Sistemele de IA funcționează adesea ca niște cutii negre, luând decizii dificil de explicat sau de înțeles. Pentru profesori, părinți și elevi, această lipsă de claritate poate fi frustrantă și poate reduce încrederea în sistem. Pentru a aborda această problemă, instrumentele de inteligență artificială trebuie să ofere explicații clare și ușor de înțeles pentru recomandările lor. Educatorii ar trebui să poată înțelege de ce un elev este marcat ca fiind „la risc” și cum a ajuns sistemul la această concluzie.

3. Sprijinirea elevilor fără a-i stigmatiza

Etichetarea elevilor drept „la risc” le poate afecta în mod neintenționat încrederea sau poate duce la așteptări mai mici din partea profesorilor. Este important să se utilizeze informațiile oferite de inteligența artificială pentru a sprijini elevii într-un mod pozitiv, concentrându-se pe potențialul lor și oferindu-le oportunități de creștere. Aceste instrumente ar trebui să ajute la responsabilizarea elevilor și la consolidarea relației dintre educatori și cursanți, nu să definească sau să limiteze viitorul lor.



4. Protejarea confidențialității și obținerea consimțământului

Datele personale ale elevilor trebuie gestionate cu grijă și respect. Școlile și organizațiile trebuie să respecte reglementări stricte privind confidențialitatea, cum ar fi GDPR, asigurându-se că toate datele sunt stocate în siguranță și utilizate numai în scopuri educaționale. Elevii și familiile acestora ar trebui să înțeleagă modul în care datele lor vor fi utilizate și au dreptul de a da sau de a refuza consimțământul.

5. Menținerea responsabilității și a supravegherii

Instrumentele de inteligență artificială ar trebui să completeze, nu să înlocuiască, judecata umană. Dacă un sistem face o predicție incorectă, trebuie să existe o modalitate de a o revizui și remedia. Educatorii ar trebui să dețină controlul asupra modului în care sunt aplicate recomandările de inteligență artificială și ar trebui să existe procese clare de responsabilitate pentru a remedia orice greșeli.

6. Implicarea persoanelor potrivite în proiectare

Instrumentele de inteligență artificială ar trebui să fie proiectate cu contribuții din partea persoanelor pe care le afectează - profesori, elevi, părinți și factori de decizie politică. Includerea acestor perspective ajută la asigurarea că instrumentele răspund nevoilor reale și sunt etice și practice de utilizat în mediile educaționale de zi cu zi.

7. Echilibrarea tehnologiei cu conexiunea umană

În cele din urmă, deși inteligența artificială poate fi un instrument util, educația se referă fundamental la relațiile umane. Profesorii, nu algoritmi, înțeleg nevoile și emoțiile unice ale elevilor lor. Orice sistem de inteligență artificială ar trebui folosit pentru a îmbunătăți, nu a înlocui, conexiunile personale care sunt atât de vitale în educație.

Concluzii

Integrarea Inteligenței Artificiale (IA) și a instrumentelor bazate pe date în domeniul educației reprezintă o schimbare de paradigmă în modul în care școlile înțeleg, sprijină și răspund nevoilor elevilor. Așa cum este explorat în acest document, utilizarea tehnologiilor IA oferă oportunități promițătoare pentru personalizarea învățării, anticiparea riscurilor precum părăsirea timpurie a sistemului de învățământ și formare profesională (ELET) și îmbunătățirea proceselor didactice și administrative. Aceste tehnologii nu sunt noutăți futuriste - ele devin integrate în peisajul educațional actual.

Una dintre cele mai puternice contribuții ale IA este capacitatea sa de a sprijini învățarea personalizată și centrată pe elev. Prin ajustarea dinamică a conținutului, ritmului și feedback-ului pe baza datelor în timp real, sistemele IA permit elevilor să urmeze căi de învățare individualizate. Această capacitate de răspuns ajută la creșterea implicării, la reducerea frustrării și la prevenirea rămânerii în urmă a elevilor. Astfel de sisteme adaptive sunt deosebit de valoroase în sălile de clasă diverse, unde elevii pot avea medii, stiluri de învățare sau nevoi de sprijin variate.

În plus, IA sporește capacitatea educatorilor și a sistemelor școlare de a detecta semnele de avertizare timpurie ale dezangajării. Prin analize predictive și analiză a modelelor comportamentale, devine posibilă semnalarea elevilor care ar putea fi expuși riscului de a părăsi prematur sistemul de învățământ. Este important de menționat că aceste perspective permit școlilor să ia măsuri proactive și specifice - de la sprijin academic la intervenții socio-emoționale - mutând astfel accentul de la reacție la prevenție.

Cu toate acestea, adoptarea IA în educație nu poate continua fără o bază solidă în conștientizarea etică și respectarea reglementărilor. Preocupările legate de confidențialitatea datelor, în special atunci când se lucrează cu minori, sunt serioase și multiple. Instituțiile trebuie să se asigure că practicile de colectare, stocare și prelucrare a datelor sunt pe deplin aliniate cu Regulamentul general privind protecția datelor (GDPR), oferind transparență și consimțământ semnificativ elevilor și familiilor acestora. În plus, trebuie să existe măsuri de siguranță pentru a preveni utilizarea abuzivă a informațiilor sensibile și pentru a respecta drepturile și demnitatea tuturor utilizatorilor.

La fel de importantă este problema dependenței excesive de date. Deși datele cantitative pot oferi informații valoroase, acestea trebuie contextualizate în cadrul realităților mai largi ale vieții elevilor și al judecății educatorilor. Modelele antrenate exclusiv pe baza performanțelor anterioare sau a indicatorilor restrânși riscă să treacă

cu vederea dimensiunilor umane, sociale și emoționale ale învățării. Integrarea datelor cu expertiza profesorilor, cunoștințele școlii și experiențele trăite de elevi creează un proces decizional mai echilibrat și mai precis. Pe măsură ce tehnologiile IA evoluează, modelele trebuie să fie capabile să învețe și să se adapteze la mediile educaționale în schimbare. Conceptul de derivă a conceptelor și schimbare a covariatelor ne amintește că comportamentul elevilor, contextele de învățare și realitățile sociale sunt dinamice. Sistemele concepute pentru medii statice riscă să devină învechite sau să producă rezultate înșelătoare dacă nu sunt reînstruite periodic cu date actuale. Astfel, evaluarea continuă, supravegherea umană și adaptarea flexibilă sunt caracteristici esențiale ale sistemelor IA educaționale de încredere.

O altă considerație critică este corectitudinea și incluziunea. Sistemele IA trebuie proiectate cu atenție pentru a evita perpetuarea prejudecăților încorporate în datele istorice. De exemplu, dacă datele școlare anterioare subreprezintă grupurile dezavantajate, algoritmiile pot penaliza în mod neintenționat aceiași elevi. IA etică în educație ar trebui să promoveze activ echitatea prin corectarea dezechilibrelor sistemice, asigurându-se că toți elevii sunt tratați în mod echitabil, indiferent de origine, abilități sau context.

În cele din urmă, integrarea cu succes a IA în educație depinde de participarea activă a tuturor părților interesate. Profesorii, elevii, părinții, liderii școlilor și factorii de decizie politică trebuie să fie implicați în proiectarea, implementarea și evaluarea instrumentelor IA. Feedback-ul lor asigură că tehnologiile rămân aliniate cu valorile educaționale, realitățile din clasă și interesele superioare ale elevilor. Implicarea de jos în sus este deosebit de importantă pentru a crea sisteme adaptabile, incluzive și receptive la provocările lumii reale.

În concluzie, IA nu este o soluție miraculoasă, ci un instrument puternic - unul care trebuie utilizat cu înțelepciune, etică și colaborativ. Atunci când este proiectată și implementată corespunzător, IA poate sprijini medii de învățare mai receptive, echitabile și captivante. Prin responsabilitate comună, reflecție continuă și angajament față de bunăstarea elevilor, putem asigura că inovația tehnologică servește obiectivului unei educații incluzive și de calitate pentru toți.

Referințe

1. Austur-Vestur sköpunarsmiðjur. (n.d). <https://sites.google.com/rvkskolar.is/austurvestur/>
2. Ataman, A. (2024). Data Quality in AI: Challenges, Importance & Best Practices. Retrieved from AIMultiple RESEARCH website: <https://research.aimultiple.com/data-quality-ai/>
3. Babic, B., Cohen, I. G., Evgeniou, T., & Gerke, S. (2021). When Machine Learning Goes Off the Rails: A guide to managing the risks. Retrieved from <https://hbr.org/2021/01/when-machine-learning-goes-off-the-rails>
4. Bañeres, D., Rodríguez-González, M. E., Guerrero-Roldán, A. E., & Cortadas, P. (2023). An early warning system to identify and intervene online dropout learners. *International Journal of Educational Technology in Higher Education*, 20(1). <https://doi.org/10.1186/s41239-022-00371-5>
5. Embarak, O. H., & Hawarna, S. (2024). Enhancing Student Success with XAI-Powered RADAR: An Automated AI-driven System for Early Detection of At-risk Students. *Procedia Computer Science*, 231(2023), 151–160. <https://doi.org/10.1016/j.procs.2023.12.187>
6. Jones-Rooy, A. (2019). I'm a data scientist who is skeptical about data. Retrieved from <https://qz.com/1664575/is-data-science-legit>
7. Kallberg, J. (2022). The risks of over-reliance on quantifiable data. Retrieved from <https://www.linkedin.com/pulse/risks-over-reliance-quantifiable-data-kallberg-ph-d-cism-cissp/>
8. Mixtúra. (n.d.). <https://reykjavik.is/en/residents-children-youth/mixtura>
9. Nolis, J. (2018). You're relying on data too much: Making decisions worse, not better. Retrieved from <https://towardsdatascience.com/youre-relying-on-data-too-much-250d4edc70c3>
10. Pagadala, S. (2023). Maximizing Machine Learning Success: The Data Dilemma Unraveled. Retrieved from <https://pagadala-saiteja.medium.com/maximizing-machine-learning-success-the-data-dilemma-unraveled-87b941236cf8>
11. Redman, T. C. (2018). If Your Data Is Bad, Your Machine Learning Tools Are Useless. Retrieved from <https://hbr.org/2018/04/if-your-data-is-bad-your-machine-learning-tools-are-useless>
12. Taylor, P. (2020). The Problem With An Over-Reliance On Data. Retrieved from <https://paulitaylor.com/2020/11/08/the-problem-with-an-over-reliance-on-data/>
13. Vasconcelos, H., Jörke, M., Grunde-Mclaughlin, M., Gerstenberg, T., Bernstein, M. S., & Krishna, R. (2023). Explanations Can Reduce Overreliance on AI Systems During Decision-Making. *Proceedings of the ACM on Human-Computer Interaction*, 7(CSCW1), 1–38. <https://doi.org/10.1145/3579605>
14. European Commission. (2016). General Data Protection Regulation (GDPR) (Regulation (EU) 2016/679). Official Journal of the European Union. Retrieved from <https://eur-lex.europa.eu>
15. European Data Protection Board (EDPB). (2020). Guidelines on Data Protection by Design and by Default. Retrieved from <https://edpb.europa.eu>
16. Council of Europe. (2021). Artificial Intelligence, Education, and Human Rights: A Policy Brief. Strasbourg, France: Council of Europe.
17. Floridi, L., & Cows, J. (2019). A Unified Framework of Five Principles for AI in Society. *Harvard Data Science Review*, 1(1). <https://doi.org/10.1162/99608f92.8cd550d1>

18. Luckin, R., Holmes, W., Griffiths, M., & Forcier, L. B. (2016). Intelligence Unleashed: An Argument for AI in Education. Pearson Education.
19. Selwyn, N. (2022). Should Robots Replace Teachers? AI and the Future of Education. Polity Press.
20. UNESCO. (2023). AI and Education: Guidance for Policy-Makers. United Nations Educational, Scientific and Cultural Organization. Retrieved from <https://unesdoc.unesco.org>
21. West, S. M., Whittaker, M., & Crawford, K. (2019). Discriminating Systems: Gender, Race, and Power in AI. AI Now Institute. Retrieved from <https://ainowinstitute.org>