

SISTEM INTELIGENT DE INSTRUIRE BAZAT PE MODELUL DE STARE A FLUXULUI CONDUS DE INTELIGENȚA ARTIFICIALĂ

Sergiu SCROB*, Inga LISNIC

Departamentul Ingineria Software și Automatică, doctorand școala doctorală UTM, Facultatea Calculatoare Informatică și Microelectronică, Universitatea Tehnică a Moldovei, Chișinău, Republica Moldova

*Autorul corespondent: Sergiu Scrob, sergiu.scrob@ati.utm.md

Rezumat. În domeniul educației care evoluează rapid, inteligența artificială joacă un rol cheie în schimbarea experienței de învățare. O aplicație notabilă este dezvoltarea sistemelor inteligente de învățare, în special învățarea adaptivă bazată pe chestionare, care vizează furnizarea de căi de învățare personalizate și eficiente pentru studenți. În acest articol ne propunem să relatăm despre o nouă abordare inovatoare care valorifică puterea inteligenței artificiale pentru a crea experiențe educaționale dinamice și personalizate folosind modelul stării fluxului propus de Mihalyi Csikszentmihalyi. Sistemul folosește un model cu mai multe fațete care include recunoașterea emoțiilor, analiza stării fluxului și o rețea neuronală pentru a adapta experiența de învățare pentru fiecare student. Detectarea emoțiilor folosind modele precum MobileNetV2, ResNet-50, EfficientNetB3 permite sistemului să măsoare starea emoțională a unui elev în timp real. Aceste date, combinate cu un calcul cuprinzător al indicelui fluxului, asigură că materialul de învățare este adaptat nevoilor emoționale și cognitive ale cursantului. Scopul final este menținerea unei stări de flux pozitiv pentru o perioadă de timp cât mai mare, sporind angajamentul și prevenind plictiseala sau frustrarea.

Cuvinte cheie: învățarea adaptivă, inteligența artificială, sisteme inteligente de învățare, modelul stării fluxului.

Introducere

Nevoia de învățare personalizată a devenit primordială în contextul în care elevii cu stiluri și ritmuri de învățare diferite au nevoie de abordări personalizate care să răspundă nevoilor lor individuale [1]. Învățarea adaptivă face învățarea mai eficientă și mai captivantă, și trece dincolo de o singură paradigmă, recunoscând punctele forte, punctele slabe și preferințele unice ale fiecărui cursant. Această recunoaștere a dus la integrarea tehnologiilor avansate, în special a inteligenței artificiale, pentru a schimba peisajul educațional.

Învățarea prin test adaptiv bazată pe Inteligență Artificială (IA) reprezintă o abordare inovatoare care valorifică puterea IA pentru a oferi nu doar conținut educațional static, ci și învățare interactivă și dinamică. Acesta adaptează traseul educațional pentru fiecare elev, recunoscând importanța luării în considerare a competențelor individuale și a stărilor emoționale. Scopul final fiind menținerea unei stări de flux pozitive pentru o perioadă de timp cât mai mare, sporind angajamentul și prevenind plictiseala sau frustrarea elevului.

Pe măsură ce ne aprofundăm în complexitatea îndrumării cu chestionare adaptive bazate pe inteligență artificială, pornim într-o călătorie care face legătura între domeniile educației și tehnologiei, într-un efort de a redefini modul în care predarea și învățarea au loc. Această introducere pune bazele pentru explorarea unui viitor în care educația nu este doar informativă, ci și profund adaptivă și personalizată, iar inteligența artificială devine un catalizator al schimbărilor transformatoare în educație.

Fundamentul învățării adaptive

Învățarea adaptivă este o metodă de predare care utilizează computerele și diverse tehnologii pentru a facilita înțelegerea și reținerea materialului pe baza nevoilor unice ale cursantului [2]. Conceptul de învățare adaptivă a fost creat de B.F. Skinner, care a proiectat o

mașină de învățare care sa concentrat pe învățarea eficientă, mai degrabă decât pe memorarea noilor concepte. Învățarea adaptivă se bazează pe următoarele principii:

- **Individualizare**, sistemul este conceput pentru a satisface nevoile, abilitățile și preferințele unice ale fiecărui elev.
- **Analitica datelor și inteligența artificială**, aceste tehnologii sunt folosite pentru a procesa datele elevilor și pentru a crea căi de învățare personalizate.
- **Evaluare continuă**, evaluările regulate oferă feedback în timp real și servesc drept bază pentru procesul de adaptare a sistemului.
- **Setări de conținut**, materialul educațional este adaptat nivelului de cunoștințe, ritmului de învățare și preferințelor fiecărui elev.
- **Feedback adaptiv și corecție**, sistemul oferă feedback bazat pe performanța elevului și sugerează conținut corectiv atunci când este necesar.
- **Flexibilitate, interactivitate, scalabilitate și accesibilitate**, sistemul este conceput pentru a fi flexibil, interactiv, scalabil și accesibil pentru o gamă largă de studenți.
- **Cercetare și practică bazată pe dovezi**, dezvoltarea și implementarea sistemului se bazează pe cercetări educaționale și pe practici dovedite.

Sistem inteligent de predare

Un sistem inteligent de predare, din engleză Intelligent Tutoring Systems (ITS), este cel mai avansat tip de sistem din această categorie care folosește algoritmi de inteligență artificială pentru a evalua, monitoriza și răspunde la performanța elevilor, creând o metodologie educațională personalizată [3]. Ele pot oferi studenților asistență imediată, resurse adaptate nevoilor lor de învățare și feedback relevant de care ar putea avea nevoie studenții. Învățarea adaptivă are loc de obicei pe o platformă web. Platforma poate fi sub forma unei interfețe, a unui program interactiv sau a unui proces de învățare. Software-ul conține toate informațiile importante legate de clasă și poate ajuta elevii în procesul lor de învățare. Odată ce un student își încheie munca pe platformă, software-ul poate lua decizii informate cu privire la cel mai bun plan de acțiune pentru student.

Fiecare sistem de învățare adaptiv este unic în ceea ce privește detaliile și designul. Cu toate acestea, majoritatea acestor sisteme constau de obicei din trei componente principale:

- modelul de conținut
- modelul de învățare
- modelul de instruire

Acest sistem de învățare asigură că materialul de învățare nu este doar informativ, ci și adaptat nevoilor în schimbare ale fiecărui elev. Acest lucru oferă un nivel de adaptabilitate și personalizare pe care metodele tradiționale se străduiesc să-l atingă. Îndrumarea prin chestionare adaptive, ca parte a unei game mai largi de ITS, urmărește să atingă câteva obiective educaționale cheie:

- personalizare, pentru a oferi o experiență de învățare personalizată care se adaptează la stilurile și abilitățile unice de învățare ale elevilor individuali.
- implicare, promovarea implicării prin ajustarea dinamică a dificultății întrebărilor din test în funcție de nivelul de cunoștințe al elevului, prevenind plictiseala și frustrarea.
- conștientizarea emoțională, integrarea capacităților de detectare a emoțiilor, creând o platformă care recunoaște și răspunde stărilor emoționale ale elevilor, îmbunătățind experiența educațională generală.
- cale eficientă de învățare, optimizarea experienței de învățare prin anticiparea și furnizarea de conținut care se potrivește cu nivelul de abilități și preferințele curente ale cursantului.

Componentele cheie din ITS

A. Interfață interactivă. O experiență de utilizator fluidă și intuitivă este de cea mai mare importanță în orice aplicație de tip chestionar, care include multe elemente web interactive prin Document Object Model (DOM). Aplicația afișează întrebarea și câteva opțiuni de răspuns, iar în caz că utilizatorul răspunde greșit, îi oferă posibilitatea de a studia materialul didactic relevant cu întrebarea adresată. A se vedea figura 1.

Figura 1. Interfața web pentru chestionar și feedback

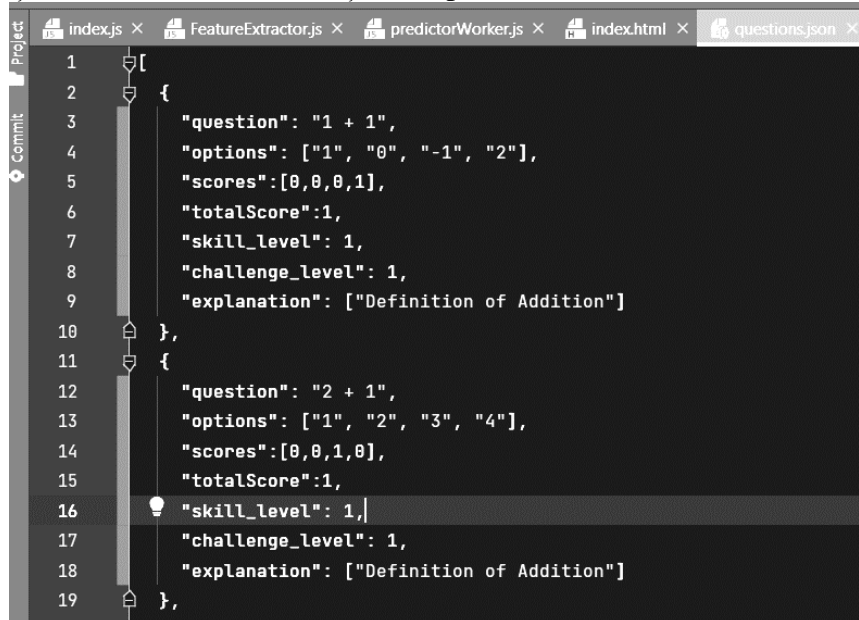
B. Gestionarea și colectarea datelor. Aplicația excelează în gestionarea unei game variate de întrebări care formează conținut testului. Încărcând întrebări dintr-un fișier JSON, sistemul populează o matrice cu diferite tipuri de întrebări, opțiuni și scoruri asociate. Capacitatea de a salva și încărca întrebări oferă flexibilitate la crearea conținutului, creând un mediu ușor de utilizat. Această versatilitate permite includerea diferitelor formate de întrebări, făcând sistemul adaptabil la diferite scenarii de chestionare. Aplicația colectează datele utilizatorului precum: opțiunea aleasă, timpul de răspuns, scorul testului, nivelul de aptitudine și provocare, capturi de imagini prin camera video.

C. Extragerea emoțiilor. Emoțiile joacă un rol esențial în procesul de învățare, influențând angajamentul cognitiv și receptivitatea la materialul educațional. Aplicația utilizează biblioteca TensorFlow.js și modelul MobileNetV2, pentru a prelucra imaginile colectate extragerea caracteristicilor din fiecare cadru la intervale specificate asigurând că sistemul poate capta în mod dinamic informații în timpul testului, contribuind la experiența generală de învățare. Pentru o gestionare optimă a memorie și timpul de procesare a imaginilor, aplicația folosește în mod implicit dimensiunea imaginilor de 96x96 pixeli, limita de cadre este de 120 cadre per secundă. MobileNetV2 va returna un vector de 1280.

D. Modelul asociat cu starea de flux. Scopul acestui model este de a corela emoțiile cu indicii actuali și precedenți de flux, aptitudine și provocare. Indicele de flux joacă rol de controlor care determină sensul, pasul și viteza fluxului, astfel după etapa de antrenare a modelului acest parametru va fi utilizat pentru a manipula modelul. Datele de intrare sunt constituite în mod implicit din 120 vectori, fiecare cu lungimea 1280, obținuți la extragerea caracteristicilor folosind modelul MobileNetV2. Tot aici se adaugă indicele de flux actual, nivelurile precedente de aptitudine și provocare. Datele de ieșire sunt constituite din nivelurile actuale de aptitudine și provocare.

Modelul de conținut

Model de conținut reprezintă un set de întrebări și răspunsuri pentru a evalua cunoștințele și înțelegerea elevilor în ceea ce privește diverse subiecte dintr-un domeniu precum matematică. Acest model poate fi utilizat în sistemele inteligente de predare pentru a oferi întrebări adaptative și feedback adecvat în funcție de performanța elevilor în adunarea simplă. Algoritmul adaptiv ar putea selecta întrebări în funcție de nivelul de competență al elevului și ar putea oferi explicații suplimentare sau resurse de învățare în funcție de răspunsurile date. În figura 2 este ilustrat modelul de conținut al sistemului de învățare adaptiv.



```
1  [
2  {
3    "question": "1 + 1",
4    "options": ["1", "0", "-1", "2"],
5    "scores": [0, 0, 0, 1],
6    "totalScore": 1,
7    "skill_level": 1,
8    "challenge_level": 1,
9    "explanation": ["Definition of Addition"]
10 } ,
11 {
12   "question": "2 + 1",
13   "options": ["1", "2", "3", "4"],
14   "scores": [0, 0, 1, 0],
15   "totalScore": 1,
16   "skill_level": 1,
17   "challenge_level": 1,
18   "explanation": ["Definition of Addition"]
19 } ,
```

Figura 2. Model de conținut pentru sistemul de învățare

Modelul de conținut are următoarele elementele:

- Întrebare (question), fiecare întrebare reprezintă o problemă de operație matematică, cum ar fi "1 + 1" sau "2 + 1".
- Opțiuni (options), pentru fiecare întrebare, există mai multe opțiuni de răspuns, dintre care una este corectă și celelalte sunt greșite. De exemplu, pentru "2 + 1", opțiunile sunt ["1", "2", "3", "4"].
- Scoruri (scores), acesta indică punctajele asociate cu fiecare opțiune de răspuns. De exemplu, pentru "2 + 1", opțiunea corectă ("3") are un scor de 1, iar celelalte opțiuni au scoruri de 0.
- Scor total (totalScore), acesta reprezintă scorul total disponibil pentru fiecare întrebare. În acest caz, fiecare întrebare are un scor total de 1.
- Nivelul de aptitudine (skill_level), acesta indică nivelul de dificultate al întrebării. În acest model, toate întrebările au același nivel de competență (skill_level: 1), ceea ce sugerează că sunt concepute pentru începători sau pentru a evalua cunoștințe de bază.
- Nivelul de provocare (challenge_level), acesta poate indica gradul de dificultate sau de provocare al întrebării. În acest caz, toate întrebările au același nivel de provocare (challenge_level: 1).
- Explicație (explanation), aceasta furnizează o explicație asociată cu întrebarea și răspunsul corect. În acest caz, toate întrebările au aceeași explicație, care este "Definiția adunării".

Modelul de învățare

În contextul învățării prin test adaptiv, inteligența artificială servește drept creier al sistemului. Capacitatea IA de a procesa cantități masive de date în timp real despre emoțiile, performanța și preferințele elevilor, de a recunoaște tipare și de a face predicții informate se aliniază perfect cu nevoile diverse ale studenților, permițând platformei să ajusteze dinamic conținutul și sarcinile. În figura 3 este prezentată diagrama de componente a modelului de învățare.




Figura 3. Modelul de învățare bazat pe inteligența artificială

Rețeaua neuronală artificială utilizată pentru modelul de învățare este de tip perceptron având un strat de intrare, două straturi ascunse complet conectate și un strat de ieșire. După cum se vede în figura 4, este un model cu o arhitectură simplă și minimalistă, deoarece scopul este de a înțelege și testa dacă datele de intrare din setul de antrenare sunt relevante pentru a forma tipare cu datele de ieșire. Forma și dimensiunea datelor de intrare depinde de:

- limita de cadre (nr. emoții), numărul de imagini din care se extrage lista de emoții faciale
- intervalul de captare a cadrelor, frecvența cu care se captează cadrele de camera web
- lungimea ferestrei de context, lungimea maximală constantă de cadre(emoții) pentru fiecare întrebare multiplicat la un număr maximal de întrebări care formează o serie de emoții poziționate și corelate prin relația: precedent-curent-următor.

Layer (type)	Input Shape	Output shape	Param #
dense_Dense1 (Dense)	[[null,153603]]	[null,10]	1536040
dense_Dense2 (Dense)	[[null,10]]	[null,100]	1100
dense_Dense3 (Dense)	[[null,100]]	[null,2]	202
Total params: 1537342			
Trainable params: 1537342			
Non-trainable params: 0			

Figura 4. Modelul rețelei neurale artificiale

Starea de flux

Înțelegerea și menținerea stării de flux a unui cursant este esențială pentru un angajament susținut și o învățare eficientă. Starea de flux, așa cum este conceptualizată de Csikszentmihalyi, reprezintă echilibrul optim între provocare și abilitate, ceea ce duce la o concentrare sporită și captivantă. Analiza stării fluxului implică evaluarea performanței, satisfacției și angajării cursantului cu fiecare întrebare. Prin calcularea unui indice de flux care ia în considerare factori precum corectitudinea, timpul de răspuns și stările istorice ale fluxului, sistemul asigură că

experiența de învățare este adaptată continuu pentru a se potrivi nevoilor și abilităților în evoluție ale elevului. Pentru a ilustra cele menționate, a se vedea figura 5.

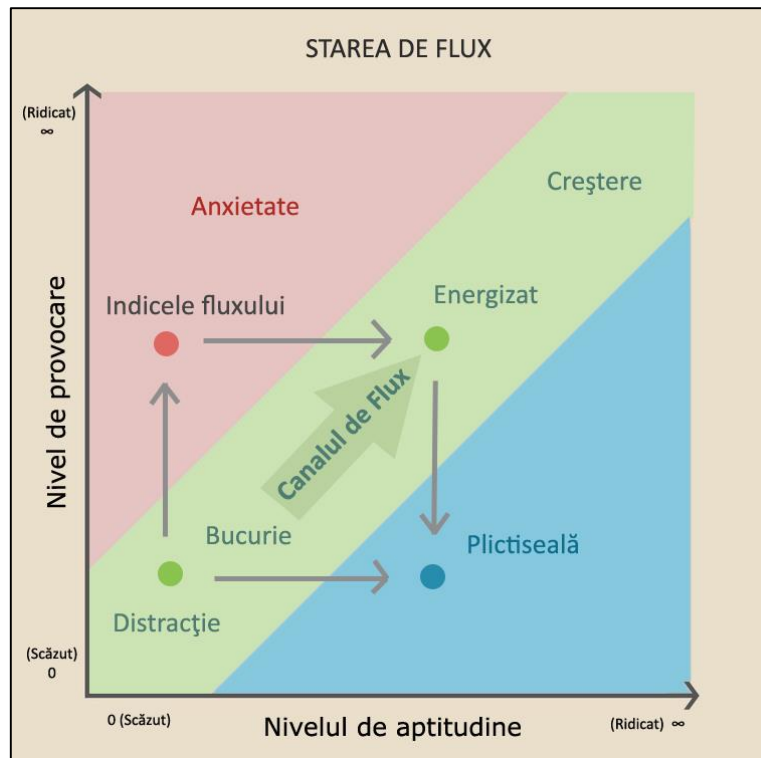


Figura 5. Starea de flux

În contextul nostru, nivelul de aptitudine și provocare pot fi utilizate ca identificatori pentru următoarea întrebare din chestionar. Starea de flux ne va ajuta să înțelegem cum asociem tensorii pentru antrenarea modelului neuronal artificial, suficient pentru identificare tiparelor. Astfel indicele de flux în creștere în raport cu emoțiile actuale ale elevului determină sensul și direcția fluxului. Sensul poate fi pozitiv sau negativ, iar direcția este descrisă de vectorul rezultat al sumei dintre vectorul de aptitudine și promovare. La etapa de inferență, indicele de flux ne va permite să identifică nivelurile de aptitudine și provocare optime pentru identificare următoarei întrebări.

Modele de convoluție

Modele de convoluție disponibile împreună cu ponderi pre-antrenate pot fi utilizate pentru antrenare și inferență în probleme de clasificare a imaginilor, detectare a obiectelor din imagini, extragerea de caracteristici și reglarea fină, dar și pentru detectarea emoțiilor umane. În tabelul 1 sunt prezentate performanțele diferitor modele de convoluție pe setul de date ImageNet.

Precizia top-1 și top-5 se referă la performanța modelului pe setul de date de validare ImageNet. Adâncimea se referă la adâncimea topologică a rețelei. Aceasta include straturi de activare, straturi de normalizare a loturilor etc. Timpul per pas de inferență este media a 30 de loturi și 10 repetări. Adâncimea numără numărul de straturi cu parametri.

Tabelul 1

Performanța modelelor de convoluție pe setul de date ImageNet [1-8].

Modelul	Size (MB)	Top-1 Accuracy	Top-5 Accuracy	Parameters	Depth	Time (ms) per inference step (CPU)	Time (ms) per inference step (GPU)
Xception	88	79.0%	94.5%	22.9M	81	109.4	8.1
VGG16	528	71.3%	90.1%	138.4M	16	69.5	4.2
VGG19	549	71.3%	90.0%	143.7M	19	84.8	4.4
ResNet50	98	74.9%	92.1%	25.6M	107	58.2	4.6
ResNet50V2	98	76.0%	93.0%	25.6M	103	45.6	4.4
ResNet101	171	76.4%	92.8%	44.7M	209	89.6	5.2
ResNet101V2	171	77.2%	93.8%	44.7M	205	72.7	5.4
ResNet152	232	76.6%	93.1%	60.4M	311	127.4	6.5
ResNet152V2	232	78.0%	94.2%	60.4M	307	107.5	6.6
InceptionV3	92	77.9%	93.7%	23.9M	189	42.2	6.9
InceptionResNetV2	215	80.3%	95.3%	55.9M	449	130.2	10.0
MobileNet	16	70.4%	89.5%	4.3M	55	22.6	3.4
MobileNetV2	14	71.3%	90.1%	3.5M	105	25.9	3.8
DenseNet121	33	75.0%	92.3%	8.1M	242	77.1	5.4
DenseNet169	57	76.2%	93.2%	14.3M	338	96.4	6.3
DenseNet201	80	77.3%	93.6%	20.2M	402	127.2	6.7
NASNetMobile	23	74.4%	91.9%	5.3M	389	27.0	6.7
NASNetLarge	343	82.5%	96.0%	88.9M	533	344.5	20.0
EfficientNetB0	29	77.1%	93.3%	5.3M	132	46.0	4.9
EfficientNetB1	31	79.1%	94.4%	7.9M	186	60.2	5.6
EfficientNetB2	36	80.1%	94.9%	9.2M	186	80.8	6.5
EfficientNetB3	48	81.6%	95.7%	12.3M	210	140.0	8.8
EfficientNetB4	75	82.9%	96.4%	19.5M	258	308.3	15.1
EfficientNetB5	118	83.6%	96.7%	30.6M	312	579.2	25.3
EfficientNetB6	166	84.0%	96.8%	43.3M	360	958.1	40.4
EfficientNetB7	256	84.3%	97.0%	66.7M	438	1578.9	61.6
EfficientNetV2B0	29	78.7%	94.3%	7.2M	-	-	-
EfficientNetV2B1	34	79.8%	95.0%	8.2M	-	-	-
EfficientNetV2B2	42	80.5%	95.1%	10.2M	-	-	-
EfficientNetV2B3	59	82.0%	95.8%	14.5M	-	-	-
EfficientNetV2S	88	83.9%	96.7%	21.6M	-	-	-

Rezultate Preliminare

Captarea emoțiilor în timp real prin ITS este o provocare pentru tehnica de calcul a unui utilizator obișnuit, deoarece prelucrarea imaginilor în timp real și utilizarea modelului de rețea neuronală necesită resurse de calcul semnificative în comparație cu specificația tehnicii de calcul. Din acest motiv sa optat pentru utilizarea modelelor mai mici dar cu performanțe bune care pot fi accesibile și simple de utilizat pe tehnica de calcul și în cadrul paginilor web. Aceste modele sunt: MobileNetV2, ResNet50, EfficientNetB3.

În contextul procesului de antrenare a modelelor selectate pentru sistemul nostru de învățare, modelele au fost antrenate pe un set de date propriu format din imagini alb-negru de dimensiunea 48x48 pixeli, 40011 imagini din 7 categorii de emoții. În figura 6 sunt prezentate un lot de imagini din setul de date cu diverse emoții.



Figura 6. Imagini cu emoții faciale din setul de date propriu

Aceste modele au arătat performanțe diferite față de cele menționate în tabelul 1. Acest fapt poate fi interpretat precum că setul de date este diferit, dimensiunea imaginilor este mult mai mică dar necesară pentru a economisi resursele de memorie, imaginile au un număr de canale mai mic, fiind în culori alb-negru. Rezultatele sunt reprezentate în tabelul 2.

Tabelul 2

Performanța modelelor selectate pe setul de date propriu

Model Neural	Acuratețe	Precizie	Recuperare	F1-score
ResNet-50	0.59	0.57	0.54	0.65
EfficientNetB3	0.52	0.48	0.99	0.65
MobileNetV2	0.74	0.70	0.79	0.65

În urma performanțelor obținute de fiecare model selectat pentru capturarea emoțiilor, cel mai eficient sa dovedit a fi MobileNetV2. Acest model are cea mai mică dimensiune și cel mai bun timp de inferență care a obținut cele mai bune scoruri pentru metricile din tabelul 2. Deși modelul EfficientNetB3 era mai bine clasat în tabelul 1, pentru setul de date propriu performanța acestui model sa dovedit diferită și mai slabă decât a fost anticipată.

În continuare modelul MobileNetV2 a fost re-antrenat, pentru a obține un indicator de acuratețe mai bun, a se vedea figura 7.

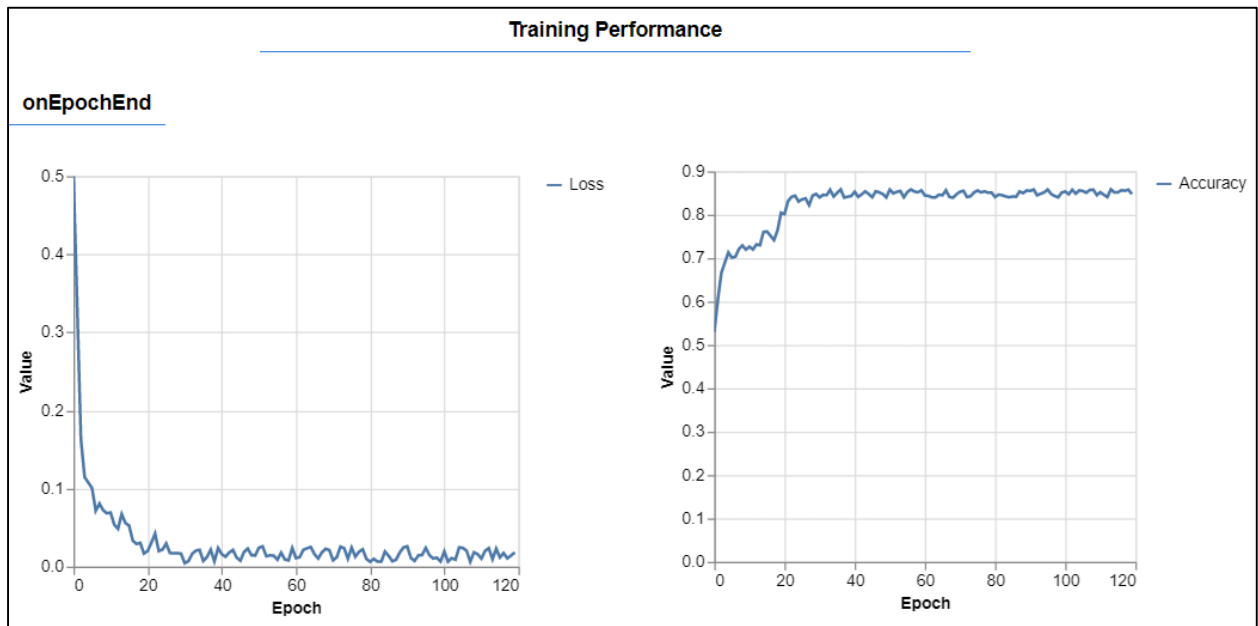


Figura 7. Re-antrenarea modelului MobileNetV2 pentru 120 de epoci

După re-antrenarea modelului MobileNetV2, acuratețea a ajuns la 0.84. Modelul final a fost utilizat pentru extragerea și identificarea emoțiilor în timp real pentru sistemul de învățare și colectarea datelor precum emoțiile pentru formarea setului de date pentru modelul de învățare.

Antrenarea modelului de învățare asociat cu modelul stării de flux este realizat după finisarea chestionarului și colectarea tuturor datelor aferente. Deoarece un singur chestionar are în total 164 de întrebări, a fost creat un mic set de date dintr-un singur chestionar pentru a observa dacă modelul poate recunoaște tiparele după antrenare. În figura 8 este reprezentat procesul de antrenare și graficele pentru metricile de antrenare și validare. Se poate observa precum că funcția de pierdere (Loss) a coborât de la valoarea 40 și 35 până la valoarea 4.21 pentru validare și 4.97 pentru antrenare. Acest progres demonstrează de fapt că modelul este capabil să generalizeze recunoscând tiparele din setul de date. Deoarece setul de date este foarte mic, iar setul de validare și mai mic, valorile de validare sunt mai bune față de cele de antrenare. Cu toate acestea modelul converge la valori relativ mari din cauză că nu există suficiente exemple pentru a face o diferențiere mai bună dintre tipare. Eroare medie absolută care reprezintă o metrică pentru a cuantifica eroarea dintre predicțiile modelului și valorile țintă reale, are valorile 1.85 pentru antrenare și 1.75 validare. Luând în considerare faptul că modelul a reușit să coboare de la valori cuprinse între 6 și 5, iar cu cât mai mică este eroarea cu atât mai bine este predicția, putem spune că performanța este triplă și dublă față de starea modelului de la început. Aceste valori ne demonstrează de asemenea că modelul poate să recunoască tipare și setul de date este corect format cu valori relevante în care datele de intrare corelează bine cu datele de ieșire.

Formarea unui set de date mai mare dar și identificare unei arhitecturi a rețelei neurale mai potrivite poate aduce rezultate mult mai bune.

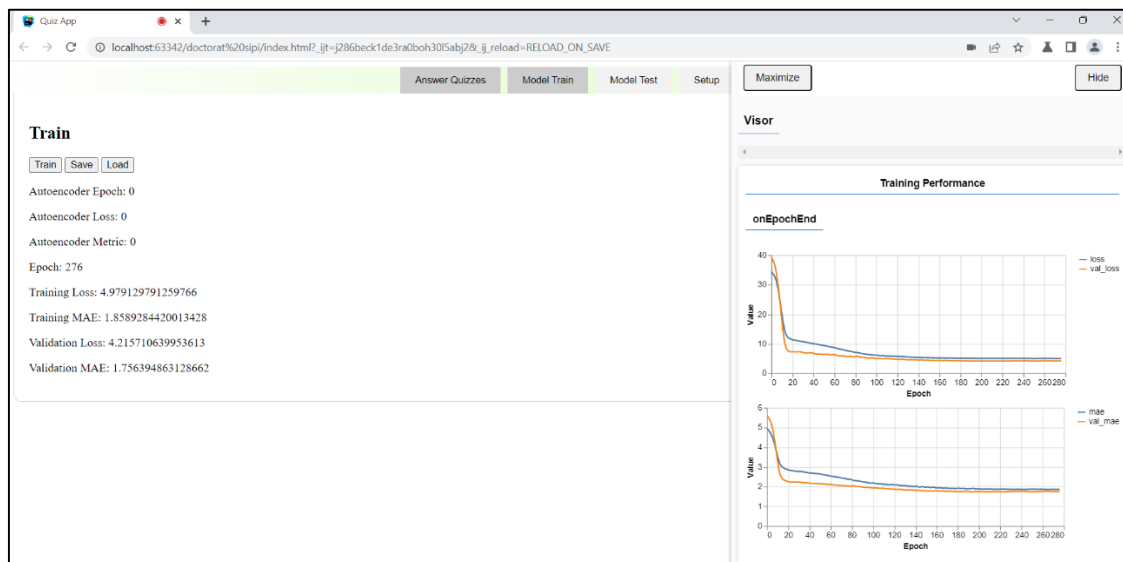


Figura 8. Antrenarea modelului de învățare

Pentru a observa diferența dintre valorile ținte (reale) și predicțiile obținute de la modelul de învățare pentru unele exemple, a se vedea tabelul 3 și 4, dar tot odată pentru a demonstra că modelul poate identifica tipare iar structura setul de date este relevantă într-o oarecare măsură și suficient pentru a ne convinge că noua abordare poate valorifica puterea inteligenței artificiale pentru a crea experiențe educaționale dinamice și personalizate folosind modelul stării de flux.

Tabelul 3

Date de Intrare și Ieșire din setul de date pentru antrenare

ID întrebare	Emoții	Nivel provocare	Nivel aptitudine	Flux de stare
1	Fericire, Uimit	5	7	2
2	Tristețe, Nervozitate	8	6	3
3	Stres, Neutru	3	9	1
95	Plictisit, Neutru	6	9	2
96	Tristețe, Uimit	5	10	1
97	Plictisit, Uimit	9	8	1

Tabelul 4

Date de Intrare și Ieșire precise de modelul de învățare

ID întrebare	Nivel aptitudine prezis	Nivel provocare prezis	Flux de stare actual	Întrebarea următoare (ID)
1	6	8	3	2
2	7	5	2	3
3	8	4	1	1
95	4	3	4	32
96	3	9	3	16
97	5	6	2	57

Din tabelele de mai sus putem observa că modelul de învățare sa adaptat relativ bine unor întrebări cu ID-ul 1,2,3 însă pentru alte întrebări modelul nu sa adaptat la fel de bine. Posibil sunt necesare mai multe exemple în setul de date, antrenarea mai îndelungată și parametrizarea corectă.

Concluzii

ITS excelează în recunoașterea ritmului unic de învățare al fiecărui student și a punctelor forte sau punctelor slabe. Adaptând conținutul și strategiile de învățare la cerințele individuale, îmbunătățește înțelegerea și implicarea, promovând o învățare mai eficientă. În domeniul educației care evoluează rapid, inteligența artificială joacă un rol cheie în schimbarea experienței de învățare. O aplicație notabilă este dezvoltarea sistemelor inteligente de învățare, în special învățarea adaptivă bazată pe chestionare, care vizează furnizarea de căi de învățare personalizate și eficiente pentru studenți. Învățarea prin test adaptiv bazată pe Inteligență Artificială (IA) reprezintă o abordare inovatoare care valorifică puterea IA pentru a oferi nu doar conținut educațional static, ci și învățare interactivă și dinamică. Acesta adaptează traseul educațional pentru fiecare elev, recunoscând importanța luării în considerare a competențelor individuale și a stărilor emoționale.

Bibliografie

- [1] Olga Russakovsky*, Jia Deng*, Hao Su, Jonathan Krause, Sanjeev Satheesh, Sean Ma, Zhiheng Huang, Andrej Karpathy, Aditya Khosla, Michael Bernstein, Alexander C. Berg and Li Fei-Fei. ImageNet Large Scale Visual Recognition Challenge. IJCV, 2015.
- [2] Chollet, F. (2017). Xception: Deep Learning with Depthwise Separable Convolutions. In 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR) (pp. 1251-1258). IEEE. DOI: 10.1109/CVPR.2017.195.
- [3] Simonyan, K., & Zisserman, A. (2015). Very Deep Convolutional Networks for Large-Scale Image Recognition. arXiv preprint arXiv:1409.1556.
- [4] He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep Residual Learning for Image Recognition. In 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR) (pp. 770-778). IEEE. DOI: 10.1109/CVPR.2016.90.
- [5] Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., & Wojna, Z. (2016). Rethinking the Inception Architecture for Computer Vision. In 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR) (pp. 2818-2826). IEEE. DOI: 10.1109/CVPR.2016.308.
- [6] Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M., & Adam, H. (2017). MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications. arXiv preprint arXiv:1704.04861.
- [7] Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., & Chen, L.-C. (2018). MobileNetV2: Inverted Residuals and Linear Bottlenecks. In 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR) (pp. 4510-4520). IEEE. DOI: 10.1109/CVPR.2018.00474.
- [8] Tan, M., & Le, Q. V. (2019). EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. arXiv preprint arXiv:1905.11946.