



Teză de abilitare

AFFECTIVE COMPUTING APPLIED TO VIRTUAL REALITY BASED-PHOBIA TREATMENT AND LEARNING PROCESS

Calcul Afectiv Aplicat în Tratarea Fobiilor prin Realitate Virtuală și în Procesul de Învățare

Conf. dr. Gabriela MOISE

Domeniul: Informatică

Brașov, 5 septembrie 2025



Universitatea
Transilvania
din Brașov



Agenda prezentării

01. Prezentare personală

O privire asupra
calcului afectiv

Date pentru
recunoașterea
automată a emoțiilor

02. Realizări științifice și profesionale (B-i)

Sisteme conștiente de emoții cu
realitate virtuală de terapie prin
expunere pentru tratatarea fobiilor

Construirea de grupuri creative în
învățarea colaborativă utilizând tehnici
de inteligență artificială

Recunoașterea automată a
emoțiilor în procesul de învățare

Explicabilitate în învățarea
automată

03. Evoluție și plan de dezvoltare a carierei (B-ii)

04. Bibliografie - selecție (B-iii)

05. Discuții



Prezentare personală

1992 – Facultatea de Matematică, Universitatea București, specializarea Informatică (licență 5 ani)

2008 – Universitatea Petrol-Gaze din Ploiești, doctor în Automatică

1992-2000 – industria IT (programator, șef oficiu calcul)

2000-prezent – Universitatea Petrol-Gaze din Ploiești (asistent, lector, conferențiar)

2009-2024 – management academic (Șef Catedra de Informatică, Director Departament Informatică, Tehnologia Informației, Matematică și Fizică)

2016-2024 – membru în senatul Universității Petrol-Gaze din Ploiești

2013-prezent – membru în consiliul centrului de cercetare CerTIMF

2019-prezent – coordonator al laboratorului Computer Science&Education

2012-prezent – coordonator al programului de licență Informatică

2016-prezent – evaluator ARACIS, comisia C1, domeniul Informatică



Prezentare personală

Proiecte de cercetare și dezvoltare (după 2008, selecție):

2023-2024, Affective Learning: Benefits and Ethical Risks in Superior Education (ALBER) – GO-GICS nr. 11061/08.06.2023, 40000 lei, competiție Universitatea Petrol-Gaze din Ploiești (<http://csed.upg-ploiesti.ro/alber/>) – coordonator

2020 CNFIS-FDI-2020-0034 - POLE4R&D – Suport pentru cercetare de excelență în disciplinele din aria STEM, director

2019 CNFIS-FDI-2019-0066 - UPG-HUB4.0 – UPG-HUB4.0 – Hub pentru cercetare, dezvoltare și inovare multidisciplinară în contextul revoluției industriale 4.0, director

2019 CNFIS-FDI-2019-0048 - Bază de practică pentru dezvoltarea creativității și inovării în demersul educațional multidisciplinar –informatică și inginerie mecanică, membru

2017, contract de cercetare nr. 8714/31.08.2017, INTELSEC - Sistem inteligent de monitorizare a portului echipamentului de protecție folosit pentru rețelele electrice de înaltă tensiune bazat pe tehnologii RFID și wireless, proiect UEFISCDI PN-III-P2-2.1-CI-2017-0262 contract PN-III-118CI/2017, membru

2017, contract de cercetare nr. 8715/31.08.2017, Sistem de senzori inteligenti conectati wireless pentru monitorizarea instalatiilor de tratament termic, proiect UEFISCDI PN-III-P2-2.1-CI-2017-0287 contract PN-III-93CI/2017, membru



Prezentare personală

Organizare evenimente științifice (selecție)

Simpozionul Computer Science&Education (2017, 2019, 2022, 2024)

Workshop-ul științific cu tema "Învățarea afectivă bazată pe recunoașterea automată a emoțiilor. Beneficii și riscuri etice în învățământul superior" - 30 mai 2024

Multimodal, Affective and Interactive eXplainable AI, 19th – 20th October 2024, part of the 27th European Conference on Artificial Intelligence, Santiago de Compostela, Spain

Workshop științific studentesc – TENDINȚE ALE CERCETĂRII INFORMATICE (2022-present)

Comitete științifice (selecție)

ITICSE, Annual Conference on Innovation and Technology in Computer Science Education, conferinta clasificata CORE A (2018-prezent)

SIGCSE, ACM Special Interest Group on Computer Science Education Conference, conferinta clasificata CORE A (2017-2022)

Conferința Națională „Tendințe în Știință și Tehnologie. Confluența Matematicii, Fizicii și Informaticii”, 26 iunie 2025



Prezentare personală

Publicații în calitate de autor sau co-autor (selecție)

58 articole științifice: 5 în jurnale A, 1 în jurnal B, 3 în jurnale C, 7 în volume conferințe A, 1 în workshop asociat conferință A*, 6 în conferințe C sau LNCS

1 capitol carte A conform SENSE

1 capitol carte B conform SENSE

1 capitol carte D conform SENSE

10 cărți nelistate SENSE

Parteneriate cu societăți comerciale – responsabil 7 acorduri de parteneriat

Lider echipă de cercetare pe teme de explicabilitate în învățare automată și problema dezacordului în tehnicile de explicare a ieșirilor modelelor de învățare automată

Colaborator la proiectul System for Ameliorating Phobias based on Exposure to Virtual Reality (SAFE-VR), Universitatea Politehnica București, 2018

Arii de cercetare: Detectare automată a emoțiilor, Computer Science&Education, Etică și explicabilitate



O privire asupra calcului (computing) afectiv

Calcul (computing) afectiv

Domeniu interdisciplinar - inteligența artificială, neuroștiința, psihologia, științele cognitive, robotică

Obiectiv – dezvoltarea de tehnologii capabile să recunoască, să înțeleagă, să genereze și să exprime emoțiile umane și reacții la acestea

Prof. Picard "computing care are legătură cu, apare din sau influențează emoții", 1995, [T1]

Aplicații – în procese de **învățare**, **medicină**, marketing, jocuri video, robotică, realitate virtuală, sisteme de recomandare, interacțiunea om-mașină

Învățare afectivă (affective learning)

Include tehnologii care „ajută la obținerea, detectare, măsurarea, comunicarea, înțelegerea, reflectarea asupra și răspunsul la emoții”, 2004, [T2]

Tehnologii care își dau seama de emoții în procesul de învățare - Affect-Aware Learning Technologies (AALTs)

**Detectare/recunoaștere
emoții**

**Generarea și
exprimarea emoțiilor**

Etică
Date, Cod,
Interacțiune om-
mașină, Utilizare,
Implicații,
Percepții.

Date pentru recunoașterea automată a emoțiilor



Modele ale emoțiilor

Modelul discret - Ekman, Izard

Ekman – 6 emoții de bază - „tristețe, fericire, dezgust, furie, frică și surpriză”

Ekman (1999) – 15 emoții de bază „amuzament, furie, dispreț, mulțumire, dezgust, jenă, entuziasm, frică, vinovăție, mândrie pentru realizări, ușurare, tristețe/suferință, satisfacție, plăcere senzorială și rușine” [T56]


Modelul dimensional

2 sau 3 dimensiuni: valență, intensitate și dominație

Mehrabian and Russel (1974, 1977) [T60], [T61]

Mehrabian (1995, 1996) [T62], [T63]

**Frica - valență scăzută,
intensitate/activare ridicată și dominanță scăzută**




Reprezentare valori medii emoții în trei dimensiuni [T61]
considerând date din [T25]

Date pentru recunoașterea automată a emoțiilor



Tipuri de date





Date pentru recunoașterea automată a emoțiilor

Seturi de date

2 seturi de date obținute din experimente [T5-T9], [T10-T12]

Setul de date 1 - semnale EEG (Electroencephalography), EDA (Electrodermal activity) și HR (Heart Rate) achiziționate de la 4 subiecți atât în mediu virtual cât și în mediul real.

Dispozitiv Acticap Xpress Bundle cu 16 electrozi uscați pentru achiziționarea semnalelor de la canalele: FP1, FP2, FC5, FC1, FC2, FC6, T7, C3, C4, T8, P3, P1, P2, P4, O1 și O2.

Semnalele EDA și HR au fost achiziționate cu ajutorul unității GSR a unui dispozitiv Shimmers Multi-Sensory.

Setul de date 2 - semnalele GSR (Galvanic Skin Response), HR și RR (Respiration Rate) achiziționate de la 5 subiecți în două situații. Situația 1 - GSR, HR și RR de referință în timp ce subiecții efectuau următoarele acțiuni: respirație adâncă, mișcări ale capului spre stânga, dreapta, sus, jos, clic cu mâna dreapta pe controlerul HTC Vive și ridicarea mâinii drepte. Situația 2 - GSR, HR și RR în timp ce subiecții au jucat un joc video cu realitate virtuală. Pentru măsurarea HR și GSR am utilizat dispozitivul Shimmer3 GSR+ Unit (<https://www.shimmersensing.com/product/shimmer3-gsr-unit/>). RR a fost calculată pe baza distanței dintre două dispozitive tracker HTC Vive.

Date pentru recunoașterea automată a emoțiilor



Setul de date DEAP (Database for Emotion Analysis using Physiological signals) [T13]

32 de subiecți

Semnale EEG - FP1, AF3, F3, F7, FC5, FC1, C3, T7, CP5, CP1, P3, P7, PO3, O1, Oz, Pz, FP2, AF4, Fz, F4, F8, FC6, FC2, Cz, C4, T8, CP6, CP2, P4, P8, PO4, O2

Semnale GSR, amplitudinea respirației, temperatura, activarea electrică a mușchilor, etc.

Valență, intensitate, dominanță în intervalul [1,9]

<https://www.eecs.qmul.ac.uk/mmv/datasets/deap/readme.html>

Semnale EEG:

Frecvența 1-100Hz

Tipuri de unde

Delta waves (0.5 – 4 Hz)

Theta waves (4 – 8 Hz)

Alpha waves (8 – 13 Hz)

Beta waves (13 – 30 Hz)


Gamma waves (>30 Hz)



Date pentru recunoașterea automată a emoțiilor



Galvanic Skin Response (GSR) – conductanța pielii (μS)



Skin Conductance Level (SCL) – background tonic – valori medii 2-20 μS .
Skin Conductance Response (SCR) cu SCR non-specific și SCR legat de evenimente – rapid phasic components – valori medii 0.1-1.3 μS

Sisteme conștiente de emoții cu realitate virtuală de terapie prin expunere pentru tratatarea fobiilor



Publicații: [T5-T12] [T14-T16]

Acrofobia – 1 din 20 de persoane este afectată

- Proiect "System for Ameliorating Phobias based on Exposure to Virtual Reality (SAFE-VR)"

Terapia prin expunere – 1990 – tehnologie cu realitate virtuală


Modele de recunoaștere automată a emoțiilor pe baza setului de date DEAP

- Detectarea fricii (valență scăzută, intensitate ridicată și dominanță scăzută)

2 modalități de evaluare a sentimentului de frică:

Label	Valence	Arousal	Dominance
0 - no fear	(5; 9]	[1; 5)	[5; 9]
1 - fear	[1; 5]	[5; 9]	[1; 5)

Label	Valence	Arousal	Dominance
0 - no fear	[7; 9]	[1; 3)	[7; 9]
1 - low Fear	[5; 7)	[3; 5)	[5; 7)
2 - medium fear	[3; 5)	[5; 7)	[3; 5)
3 - high fear	[1;3)	[7;9)	[1;3)



Setul 1 - Valorile EEG pentru 32 de canale și datele fiziologice hEOG, vEOG, zEMG, tEMG, GSR, Respirație, PPG și Temperatură – 40 de attribute

Setul 2 - valori Power Spectral Density (PSD) din 32 canale EEG în frecvențele alpha, beta and theta, după care am calculat valori medii pentru alpha, beta and theta PSD în pre-frontal (FP), AF (between FP and F), frontal (F), FC (între F și C), central (C), temporal (T), P (parietal), CP (între C și P), O (occipital) și PO (între P și O) părți ale creierului – 38 de attribute

Setul 3 - Petrosian Fractal Dimension din 32 canale EEG și datele fiziologice – 40 de attribute

Setul 4 - Higuchi Fractal Dimension din 32 canale EEG și datele fiziologice – 40 de attribute

Setul 5 - Approximate Entropy din 32 canale EEG și datele fiziologice – 40 de attribute

4 DNN-uri, Support Vector Machine (SVM), Linear Discriminant Analysis (LDA), Random Forest (RF), k-Nearest Neighbors (kNN)

Principal Component Analysis (PCA), Sequential Feature Selector (SFS), Fisher pentru fiecare set de date

Sisteme conștiente de emoții cu realitate virtuală de terapie prin expunere pentru tratatarea fobiilor

Modele de recunoaștere automată a emoțiilor pe baza setului de date DEAP

- Detectarea fricii (valență scăzută, intensitate ridicată și dominanță scăzută)

Setul 1

Classifier	2-level scale		4-level scale	
	F1 score (%)	Accuracy (%)	F1 score (%)	Accuracy (%)
No feature selection				
RF			83.85	84.01
kNN	86.81	87		

Setul 2

No feature selection				
RF	93.11	93.13	85.33	85.74

Setul 3

No feature selection				
RF	87.33	87.54		
Fisher selection				
RF	87.33	87.54		
PCA selection				
kNN			83.50	83.64

Setul 4

No feature selection				
RF	89.96	90.07	82.59	83.24
Setul 5				
No feature selection				
RF	89.65	89.78	80.78	81.70
Fisher selection				
RF	89.51	89.63	80.47	81.50

Sisteme conștiente de emoții cu realitate virtuală de terapie prin expunere pentru tratatarea fobiilor

Modele de recunoaștere automată a emoțiilor pe baza setului de date DEAP

- Detectare 6 emoții de bază - tristețe, fericire, dezgust, furie, frică și surpriză (Ekman)

Date de intrare - semnale EEG (brute și procesate - approximate entropy/Petrosian fractal dimension/Higuchi fractal dimension) și semnale periferice hEOG, vEOG, zEMG, tEMG, GSR, rata de respirație, PPG și temperatura

	Raw		Petrosian		Higuchi Fractal dimension		Approximate entropy	
Anger	RF 96.04	<u>kNN</u> Fisher 97.52%	SVM 98.02%	SVM Fisher 95.05%	SVM 98.02%	SVM Fisher 94.05%	RF 92.55%	RF Fisher 92.08%
Joy	<u>kNN</u> 91.22%	LDA SFS 100%	<u>kNN</u> 87.9%	<u>kNN</u> Fisher 85.76%	<u>kNN</u> 87.60%	<u>kNN</u> Fisher 83.75%	RF 86.40%	RF Fisher 80.37%
Surprise	<u>kNN</u> 85.01%	SVM SFS 96%	<u>kNN</u> 84.75%	<u>kNN</u> Fisher 80.59%	<u>kNN</u> 83.64%	RF Fisher 80.69%	<u>kNN</u> 81.30%	<u>kNN</u> Fisher 82.59%

Sisteme conștiente de emoții cu realitate virtuală de terapie prin expunere pentru tratatarea fobiilor



Modele de recunoaștere automată a emoțiilor pe baza setului de date DEAP

- Detectare 6 emoții de bază - tristețe, fericire, dezgust, furie, frică și surpriză (Ekman)


Date de intrare - semnale EEG (brute și procesate - approximate entropy/Petrosian fractal dimension/Higuchi fractal dimension) și semnale periferice hEOG, vEOG, zEMG, tEMG, GSR, rata de respirație, PPG și temperatura

Disgust	RF 93.63%	<u>kNN</u> Fisher 89.74%	<u>kNN</u> 95%	SVM Fisher 90%	SVM 91.59%	RF Fisher 90.23%	RF 83.14%	RF Fisher 75.26%
Fear	<u>kNN</u> 90.75%	RF Fisher 80.85%	<u>kNN</u> 89.72%	<u>kNN</u> Fisher 80.82%	<u>kNN</u> 89.04%	<u>kNN</u> Fisher 83.39%	<u>kNN</u> 80.66%	<u>kNN</u> Fisher 79.45%
Sadness	RF 87.49%	<u>kNN</u> Fisher 85.76%	<u>kNN</u> 90.17%	<u>kNN</u> Fisher 83.29%	SVM 90.8%	SVM Fisher 86.43%	RF 81.86%	<u>kNN</u> Fisher 76.45%

Sisteme conștiente de emoții cu realitate virtuală de terapie prin expunere pentru tratatarea fobiilor

Modele de recunoaștere automată a emoțiilor pe baza setului de date DEAP

- Detectare frică numai din semnale GSR și HRV



[T15]

Sisteme conștiente de emoții cu realitate virtuală de terapie prin expunere pentru tratatarea fobiilor

Modele de recunoaștere automată a emoțiilor pe baza setului de date DEAP

- Detectare frică numai din semnale GSR și HRV – 33 attribute din EDA și 7 attribute din HRV

Abordarea 1 – 3 ferestre care nu se suprapun (un segment de 60 de secunde este divizat în 3 ferestre de câte 20 de secunde). Set de date cu 1494 de înregistrări (830 etichetate non-fear; 664 etichetate fear)

Abordarea 2 – 5 ferestre cu suprapunere (un segment de 60 de secunde este divizat în 5 ferestre de câte 20 de secunde cu 10 secunde suprapunere). Set de date cu 7470 de înregistrări (4150 etichetate non-fear și 3320 etichetate fear).


Modele de învățare automată - Decision Trees – RF (Random Forest) and GBT (Gradient Boosting Tree), k-Nearest Neighbors (kNN), Support Vector Machine (SVM) și rețele neuronale shallow și profunde. Pentru ambele abordări, cele mai bune performanțe, peste 89%, au fost atinse cu algoritmi SVM (Support Vector Machine) și GBT (Gradient Boosting Tree). În ceea ce privește scorul ROC AUC, cele mai bune rezultate au fost obținute astfel:

- Pentru setul de date fără-suprapuneri: reducere PCA + SVM – **93.5%**.
- Pentru setul de date cu-suprapuneri: GBT – **91.7%**.

Sisteme conștiente de emoții cu realitate virtuală de terapie prin expunere pentru tratatarea fobiilor

Modele de recunoaștere automată a emoțiilor pe baza setului de date DEAP

- Detectare frică numai din semnale GSR și HRV



Interpretare LIME pentru o instanță cu predicția non-fear (setul de date cu suprapuneri)

Sisteme conștiente de emoții cu realitate virtuală de terapie prin expunere pentru tratatarea fobiilor


Dezvoltare de sisteme adaptive de terapie prin expunere cu realitate virtuală și recunoașterea emoțiilor

2018-2019

Semnale EEG, EDA, HR, RR

Experiment inițial – 4 subiecți (3 – succes)

Semnale EEG: FP1, FP2, FC5, FC1, FC2, FC6, T7, C3, C4, T8, P3, P1, P2, P4, O1 și O2
pre-frontal (Fp), frontal (F), temporal (T), parietal (P), occipital (O) și central (C)




Sisteme conștiente de emoții cu realitate virtuală de terapie prin expunere pentru tratatarea fobiilor

Dezvoltare de sisteme adaptive de terapie prin expunere cu realitate virtuală și recunoașterea emoțiilor

Arhitectură sistem

DNN1 – predicție nivel curent de frică

DNN2 – predicție următorul nivel de joc adecvat unui utilizator specific



Sisteme conștiente de emoții cu realitate virtuală de terapie prin expunere pentru tratatarea fobiilor

Dezvoltare de sisteme adaptive de terapie prin expunere cu realitate virtuală și recunoașterea emoțiilor

n – număr niveluri joc


$l_0, l_1, \dots, l_{n-1}$ – niveluri joc ordonate după gradul de expunere la înălțime

l_{cr} – nivel curent de joc

l_{pr} – nivel joc prezis

fl_{cr} – nivel frică curent


fl_d – nivel frică dorit



Sisteme conștiente de emoții cu realitate virtuală de terapie prin expunere pentru tratatarea fobiilor

Dezvoltare de sisteme adaptive de terapie prin expunere cu realitate virtuală și recunoașterea emoțiilor

Captură joc video



Sisteme conștiente de emoții cu realitate virtuală de terapie prin expunere pentru tratatarea fobiilor

Dezvoltare de sisteme adaptive de terapie prin expunere cu realitate virtuală și recunoașterea emoțiilor

DNN1 – recunoaștere emoție

Setul de date

71 de attribute

Valori alpha, beta, theta, theta/beta de la canalele: FP1, FP2, FC5, FC1, FC2, FC6, T7, C3, C4, T8, P3, P1, P2, P4, O1, O2

Valori pentru: $\text{Alpha FP2} - \text{Alpha FP1}; (\text{Alpha FC2} + \text{Alpha FC6}) - (\text{Alpha FC5} + \text{Alpha FC1}); (\text{Alpha FP2} + \text{Alpha FC2} + \text{Alpha FC6}) - (\text{Alpha FP1} + \text{Alpha FC5} + \text{Alpha FC1}); (\text{Beta FP2} + \text{Beta FC2} + \text{Beta FC6}) - (\text{baseline Beta FP2} + \text{baseline Beta FC2} + \text{baseline Beta FC6}); (\text{theta/beta FC6} + \text{theta/beta FC2} + \text{theta/beta FP2}) - (\text{baseline theta/beta FC6} + \text{baseline theta/beta FC2} + \text{baseline theta/beta FP2})$

Valori GSR și HR

Țintă – nivel de frică -scala cu 11 niveluri (0-10), scala cu 4 niveluri (0-3), scala cu 2 niveluri (0,1)

Sisteme conștiente de emoții cu realitate virtuală de terapie prin expunere pentru tratatarea fobiilor



Dezvoltare de sisteme adaptive de terapie prin expunere cu realitate virtuală și recunoașterea emoțiilor

DNN1 – recunoaștere emoție

Cele mai bune rezultate

- Scala cu 2 niveluri - **95.51%** utilizând un DNN cu 3 straturi ascunse – 300 de neuroni pe fiecare strat, activare RELU, stratul de ieșire – activare Sigmoid, funcția de pierdere Binary cross-entropy.
- Scala cu 4 niveluri - **90.49%** utilizând un DNN cu 3 straturi ascunse – 300 de neuroni pe fiecare strat, activare RELU, stratul de ieșire – funcția de activare Softmax, funcția de pierdere Logarithmical categorical cross-entropy.
- Scala cu 11 niveluri – **85.09%** utilizând un DNN cu 3 straturi ascunse – 150 de neuroni pe fiecare strat, activare RELU, stratul de ieșire – activare Softmax, funcția de pierdere Logarithmical categorical cross-entropy.

Sisteme conștiente de emoții cu realitate virtuală de terapie prin expunere pentru tratatarea fobiilor



Dezvoltare de sisteme adaptive de terapie prin expunere cu realitate virtuală și recunoașterea emoțiilor

DNN2 – predicție nivel de joc

Cele mai bune rezultate

- Scala cu 2 niveluri – **98.72%** utilizând un DNN cu 3 straturi ascunse – 300 de neuroni pe fiecare strat, activare RELU, stratul de ieșire cu 5 neuroni, activare Softmax, funcția de pierdere Logarithmical categorical cross-entropy.
- Scala cu 4 niveluri – **98.67%** utilizând un DNN cu 3 straturi ascunse – 150 de neuroni pe fiecare strat, activare RELU, stratul de ieșire cu 5 neuroni, activare Softmax, funcția de pierdere Logarithmical categorical cross-entropy.
- Scala cu 11 niveluri – **98.75%** utilizând un DNN cu 3 straturi ascunse – 150 de neuroni pe fiecare strat, activare RELU, stratul de ieșire cu 5 neuroni, activare Softmax, funcția de pierdere Logarithmical categorical cross-entropy.

Sisteme conștiente de emoții cu realitate virtuală de terapie prin expunere pentru tratatarea fobiilor

Dezvoltare de sisteme adaptive de terapie prin expunere cu realitate virtuală și recunoașterea emoțiilor

Extindere experiment – 8 subiecți

Modele pentru emoție și determinarea nivelului de joc - kNN, SVM, RF, LDA

2 modalități – user independent (antrenare pe datele altui subiect) și user dependent (antrenare și testare pe datele aceluiași subiect)

Rezultate

Pentru clasificatorul de predicție a nivelului de frică - cea mai mare acuratețe de peste **98%** cu validare încrucișată cu unul din algoritmi kNN sau RF, atât pentru modalitatea independent de jucător, cât și pentru modalitatea dependent de jucător

Pentru clasificatorul de predicție a nivelului următor de joc - cea mai mare acuratețe cu validare încrucișată a fost obținută cu RF, peste **99.75%**

Sisteme conștiente de emoții cu realitate virtuală de terapie prin expunere pentru tratatarea fobiilor

Dezvoltare de sisteme adaptive de terapie prin expunere cu realitate virtuală și recunoașterea emoțiilor

Extindere experiment – 8 subiecți

Rezultate

Importanța atributelor – user independent

2-choice scale		4-choice scale		11-choice scale	
Feature	Feature importance	Feature	Feature importance	Feature	Feature importance
GSR	0.41	GSR	0.45	GSR	0.49
HR	0.28	HR	0.28	HR	0.24

Sisteme conștiente de emoții cu realitate virtuală de terapie prin expunere pentru tratatarea fobiilor

Dezvoltare de sisteme adaptive de terapie prin expunere cu realitate virtuală și recunoașterea emoțiilor

Extindere experiment – 8 subiecți

Rezultate

Importanța atributelor – user dependent

2-choice scale		4-choice scale		11-choice scale	
Feature	Feature importance	Feature	Feature importance	Feature	Feature importance
GSR	0.40	GSR	0.46	GSR	0.48
HR	0.25	HR	0.32	HR	0.27

Sisteme conștiente de emoții cu realitate virtuală de terapie prin expunere pentru tratatarea fobiilor

Dezvoltare de sisteme adaptive de terapie prin expunere cu realitate virtuală și recunoașterea emoțiilor

Exemple date (condiții VR)

Floor / position	ALPHA															
	FP1	FP2	FC5	FC1	FC2	FC6	T7	C3	C4	T8	P3	P1	P2	P4	O1	O2
P--1	3.503892	2.896083	2.495974	2.275845	2.3931	2.550224	3.535742	2.070293	3.987501	2.083388	3.13693	2.527608	3.987501	2.540366	3.987501	3.090283
P--2	3.239585	2.996605	2.785175	2.22867	2.62501	2.70819	3.284469	2.115948	3.980763	2.138393	2.241442	2.10786	3.980763	2.363486	3.980763	2.50996
P--3	3.301529	2.662959	2.754192	2.274489	2.252268	2.50137	3.276848	2.118844	3.973349	2.152324	2.214148	1.976768	3.973349	2.487142	3.973349	2.42714
1--1	3.212697	2.863069	5.706423	2.115041	2.031369	2.226406	3.348228	1.762564	3.965235	1.695213	1.795213	2.037601	3.965235	2.338431	3.965235	2.331008
1--2	3.40892	2.893017	6.686761	2.594526	2.72538	2.750569	3.364398	2.185702	3.956601	2.203633	2.240396	1.935961	3.956601	2.612176	3.956601	2.346245
1--3	3.208121	2.622227	5.370759	2.388889	2.315563	2.457556	3.204464	2.00252	3.947659	2.193241	2.297086	2.288211	3.947659	2.574624	3.947659	2.511906
4--1	2.935946	2.509878	3.686198	2.388428	1.999771	2.067191	3.099483	1.699334	3.938778	1.902968	2.060691	2.758177	3.938778	2.360999	3.938778	2.729347
4--2	2.966746	2.107847	2.878077	1.822348	2.031287	2.113311	2.611677	1.969957	3.930074	1.659816	2.032511	2.482623	3.930074	2.147753	3.930074	2.597208
4--3	3.058292	2.727784	2.850501	2.197695	2.176509	2.261191	3.02155	1.867368	3.92135	1.953932	1.903344	2.904563	3.92135	2.343217	3.92135	2.207048
6--1	3.12524	2.558639	2.681191	2.036931	2.11049	2.343229	3.182617	1.764988	3.912493	1.892438	1.895786	2.239401	3.912493	2.171497	3.912493	2.29269
6--2	3.028642	2.536119	2.64066	2.123024	2.134253	2.103594	3.030362	2.025526	3.903561	2.242655	2.099304	2.56625	3.903561	2.353571	3.903561	2.669227
6--3	3.337986	3.111522	2.841108	2.123137	2.300009	2.375259	3.267446	1.914309	3.894857	2.0461	2.295186	2.284584	3.894857	2.32404	3.894857	2.334306
10--1	2.992564	2.794926	2.301249	2.197942	2.294971	2.368559	2.933374	2.013791	3.886676	2.118887	1.744859	3.038971	3.886676	2.446347	3.886676	3.146819
10--2	3.170476	2.709144	2.272261	2.203872	2.262553	2.366289	3.362912	2.046273	3.879698	2.147321	2.019485	2.438252	3.879698	2.446323	3.879698	2.61704
10--3	2.640202	2.695827	2.704718	2.097439	2.358461	2.299832	3.17162	2.004463	3.873938	1.82279	1.90073	2.221822	3.873938	2.262991	3.873938	2.424596

Sisteme conștiente de emoții cu realitate virtuală de terapie prin expunere pentru tratatarea fobiilor

Dezvoltare de sisteme adaptive de terapie prin expunere cu realitate virtuală și recunoașterea emoțiilor

Abordarea centrată pe om:

- Etapa I: Desfășurarea jocului și înregistrarea datelor biofizice supravegheate de terapeut.
- Etapa II: Prelucrarea datelor biofizice supravegheată de terapeut.
- Etapa III: Clasificarea nivelului de frică utilizând modele de învățare automată supravegheată de terapeut.
- Etapa IV: Selecția scenariilor VR utilizând modele de învățare automată supravegheată de terapeut.

Propunere utilizare **Interactive Machine Learning (iML)**:

Vederea de tip opaque-box pentru modele de învățare automată este înlocuită cu glass-box - experții umani sunt agenți implicați în toate etapele dezvoltării sistemelor: achiziție date, antrenare, testare, implementare.

Modelele de învățare automată interacționează cu agenții și își schimbă comportamentul de antrenare.

Sisteme conștiente de emoții cu realitate virtuală de terapie prin expunere pentru tratatarea fobiilor

Dezvoltare de sisteme adaptive de terapie prin expunere cu realitate virtuală și recunoașterea emoțiilor

Arhitectură cu holoni

Holon


Arthur Koestler (1967) cu scopul de a evidenția relația dintre întreg și părți [T80]

- componentă care poate acționa inteligent

Holon în sisteme de producție

- o entitate/bloc cu autonomie, cooperare, autoorganizare și reconfigurabilitate.


- o parte de procesare a informațiilor și o parte fizică [T81]



Sisteme conștiente de emoții cu realitate virtuală de terapie prin expunere pentru tratatarea fobiilor

Dezvoltare de sisteme adaptive de terapie prin expunere cu realitate virtuală și recunoașterea emoțiilor

Arhitectură cu holoni pentru sistemul de terapie pentru fobia de înălțime



Sisteme conștiente de emoții cu realitate virtuală de terapie prin expunere pentru tratatarea fobiilor

Dezvoltare de sisteme adaptive de terapie prin expunere cu realitate virtuală și recunoașterea emoțiilor

Probleme privind integrarea detectării automate a emoțiilor în sistemele de terapie a fobiilor

- achiziția datelor - artefacte
- consumul de resurse

Cum trebuie măsurate semnalele în medii de realitate virtuală?

Metodă pentru determinarea tiparelor artefactelor la achiziționarea de semnale în timpul unui joc VR: alinierea segmentelor de date corespunzătoare momentelor în care utilizatorii au efectuat mișcări ale capului/mâinii/corpului cu semnalele artefactelor înregistrate în timpul unei proceduri de referință [T8]:

- I Măsurare artefacte de referință
- II Măsurare artefacte în timpul unui joc video
- III Evaluare potrivire artefacte

Sisteme conștiente de emoții cu realitate virtuală de terapie prin expunere pentru tratatarea fobiilor



Dezvoltare de sisteme adaptive de terapie prin expunere cu realitate virtuală și recunoașterea emoțiilor

Recunoaștere artefacte - Experiment – 5 subiecți, Semnale – GSR, HR și RR, Valori – bias, Mean Absolute Error (MAE), Mean Absolute Percentage Error (MAPE) pentru GSR și HR
respirație profundă, mișcare a capului spre stânga, mișcare a capului spre dreapta, mișcare a capului în sus, mișcare a capului în jos, clic cu mâna dreaptă pe controlerul HTC Vive, ridicare mâna dreaptă

Artefact type	GSR MAPE (%)				
	GSR -2 steps	GSR -1 step	GSR aligned time stamps	GSR +1 step	GSR +2 steps
RESPIRATION	28.26856386	28.13125142	28.3442362	29.36369501	29.65567029
LEFT HEAD	27.58241056	28.18084292	29.2564398	29.19821758	29.06203135
RIGHT HEAD	28.29350035	28.32949923	28.3200534	28.35180869	28.03708074
DOWN HEAD	27.81568491	27.77749042	27.62714529	27.33337573	27.5452365
UP HEAD	27.92170684	27.57325531	27.79352328	27.58577201	27.03417432
CLICK	31.81846513	31.28737745	30.76154053	30.69721127	30.79128381
UP HAND	33.74056947	33.83259569	32.68694971	32.58406055	32.81968315

Construirea de grupuri creative în învățarea colaborativă utilizând tehnici de inteligență artificială



Publicații: [T20-T23] (2013-2018)

Algoritm bazat pe Q-learning, Watkins (1998) $Q(s, a) \leftarrow Q(s, a) + \alpha * (R(s, a) + \gamma * \max_{a'} Q(s', a') - Q(s, a))$

n – number of students

$c = (c_1, c_2, \dots, c_m)$ – creativity vector, c_i represents a characteristic of students influencing group creativity, m – number of individual characteristics

id_group – the group identification

k – the number of groups

$(c_1, c_2, \dots, c_m, id_group)$ – a state (s), composed by the creativity vector and the group identification for each student

action (a) – the action of moving a student to another group in which he would contribute the most to increasing the group creativity

Q – expresses the quality of association between a state and an action, in the sense of our goal, to build the most creative k groups

R – reward is the value of group's creativity, and it ranges between 1 and 5.

Construirea de grupuri creative în învățarea colaborativă utilizând tehnici de inteligență artificială



1. Build a bi-dimensional matrix Q for all possible pairs $\langle state, action \rangle$:
 $(c_1, c_2, \dots, c_m, id_group, action_number, q)$

A value of the *action_number* equals with j means that if a particular type of student (given by their creativity vector $(c_1, c_2, \dots, c_m)$) will be moved to the group having the value of *id_group* equal with j , then their contribution to group creativity is quantified by q (in this stage). All the elements in the q column may be initialized with 0 or with a randomly chosen low value. On each line of the matrix, the data that corresponds to each type of student involved in the grouping process is included, i.e. the values of their characteristics, the current group number, the action number, and the value computed for q (*that quantifies a potential for creativity*). One particular type of student could have more corresponding lines, one for each combination $\langle current\ id_group, action \rangle$

2. Initialize the optimal_policy with an initial policy. In our case, the optimal policy is an optimal grouping of students that maximizes group creativity. The initial grouping is set by the instructor and the students together and experience shows that they tend to group as cliques determined by their inter-personal affinities.



Construirea de grupuri creative în învățarea colaborativă utilizând tehnici de inteligență artificială

3. Group the students and have them carry out working sessions, in which each group's creativity is assessed, and its score is assigned to the reward $R(s, a)$. The values of $R(s, a)$ are obtained with help from human experts. The reward describes the potential of the groups' creativity. Then, the matrix Q is updated for each such working session. This procedure is presented below.

```
procedure working_session_computation
  select action of (optimal_policy) /* student grouping*/
  compute  $R(s, a)$ 
  compute table  $Q$ 
```

4. Analyse the group creativity for each group against the global objective (the optimal grouping policy), which is getting closer to the maximum value possible for R , for each group or for all the groups. Re-iterate from step 3, if necessary.



Construirea de grupuri creative în învățarea colaborativă utilizând tehnici de inteligență artificială

Publicații: [T20-T23]

Algoritm bazat pe **Q-learning** pentru construire de grupuri creative

Studiu experimental – 27 de studenți

Intrări – gradul de motivare (3 clase 0, 1, 2), nivel de creativitate (scor de creativitate între -12 și 18, 5 clase), ieșiri – id grup

Rezultate

creativity class	motivation level	id of the group	Q value
3	1	1	3.46875
3	1	5	2.6971875
3	1	6	3.29578125
3	1	7	3.79828125
3	1	9	2.5321875



Recunoașterea automată a emoțiilor în procesul de învățare

Publicații: [T24,T25]

Emoții des întâlnite în procesul de învățare – plictiseală; furie; anxietate; bucurie; surprindere; tristețe, frustrare; mândrie; speranță; lipsă de speranță, rușine; confuzie, fericire, fire, frică, bucurie; dezgust, interes; ușurare, entuziasm

Tipuri de date utilizate cu precădere – text, date fiziologice, expresii faciale, voce

6 roluri principale ale recunoașterii automată a emoțiilor în învățarea online:

1. dezvoltarea sistemelor inteligente de tutorat cu abilități emoționale, capabile să detecteze emoțiile și să reacționeze corespunzător
2. sprijinirea implicării și motivării cursanților și a profesorilor
3. evaluarea rezultatelor învățării (detectarea copierii de către elevi)
4. evaluarea predării (profesorii trebuie să fie conștienți de impactul emoțiilor asupra procesului de predare-învățare)
5. construirea unor medii de învățare confortabile (creșterea eficienței învățării și predării)
6. sprijinirea elevilor cu nevoi speciale (ADHD, anxietate etc.)


Recunoașterea automată a emoțiilor în procesul de învățare



Model 1D-CNN model pentru recunoaștere emoțiilor pe baza a valorilor a 5 canale EEG – setul de date DEAP

7 emoții: plictiseală, confuzie, frustrare, curiozitate, entuziasm, concentrare și anxietate

Akter et al. (2022) - un model 1D-CNN cu patru straturi convoluționale și trei straturi dense folosind 14 canale EEG (FP1, FP2, AF3, Fz, F3, F4, F7, F8, FC1, C4, P3, P4, PO3, PO4) [T113]: acuratețe valență - 99,89%, excitare - 99,83%



Recunoașterea automată a emoțiilor în procesul de învățare




Model 1D-CNN model pentru recunoaștere emoțiilor pe baza a valorilor a 5 canale EEG – setul de date DEAP

Topic et al. (2022) [T114]

ReliefF	FP1	AF3	F3	F7	T7
NCA	FP1	AF3	F7	T7	CP5
ReliefF	O1	Oz	FP2	F8	P8
NCA	P7	FP2	AF4	FC6	T8

FP1, AF3, F7, T7, FP2

Pentru extragerea caracteristicilor, am utilizat FFT (Fast Fourier Transform) cu canalele FP1, AF3, F7, T7, FP2 și sub-benzile theta 4-8Hz; alfa 8-13Hz; low beta 13-22Hz; high beta 22-30Hz, gamma 30-100Hz.



[T25]



Recunoașterea automată a emoțiilor în procesul de învățare

Model 1D-CNN model pentru recunoaștere emoțiilor pe baza a valorilor a 5 canale EEG – setul de date DEAP

Rezultate

Emotion	Performance (%)					Running time (seconds)
	Test loss	Test accuracy	Precision	Recall	F1_score	
Boredom	0.91	99.64	94.62	97.41	95.97	8281.34
Confusion	1.16	99.70	99.17	96.19	97.63	6004.65
Frustration	0.98	99.66	98.98	95.13	96.97	5690.35
Curiosity	0.97	99.80	99.74	96.83	98.24	8675.36
Excitement	0.41	99.91	98.74	97.75	98.24	5790.36
Concentration	1.14	99.70	99.16	98.98	99.07	9342.58
Anxiety	1.91	99.21	95.03	88.96	91.76	6655.65



Recunoașterea automată a emoțiilor în procesul de învățare

Model 1D-CNN model pentru recunoaștere emoțiilor pe baza a valorilor a 5 canale EEG – setul de date DEAP

Comparații F1-score

no channels	boredom	confusion	frustration	curiosity	excitement	concentration	anxiety
14	99.36	98.80	91.89	99.65	99.42	99.77	99.52
10 -ReliefF	97.81	99.03	97.41	98.77	94.79	99.42	97.53
10 -NCA	98.94	96.92	98.61	98.57	98.41	99.05	99.40
5 channels	95.97	97.63	96.97	98.24	98.24	99.07	91.76



Recunoașterea automată a emoțiilor în procesul de învățare

Model 1D-CNN model pentru recunoaștere emoțiilor pe baza a valorilor a 5 canale EEG – setul de date DEAP

Comparații timp de antrenare (secunde)

no channels	boredom	confusion	frustration	curiosity	excitement	concentration	anxiety
10- ReliefF	12487.59	10117.58	8421.99	10196.85	9333.75	16821.48	13403.73
10-NCA	14119.25	10057.39	12463.57	7011.58	7638.51	12405.46	9943.37
5	8281.34	6004.65	5690.35	8675.36	5790.36	9342.58	6655.65



Recunoașterea automată a emoțiilor în procesul de învățare

Model etic pentru recunoașterea automată a emoțiilor în procesul de învățarea online

16 clase de riscuri etice:

- Prejudecăți și discriminare,
- Rezultate nefiabile, incerte, nesigure sau slabe.
- Rezultate netransparente, inexplicabile, nejustificate sau total neprevizibile.
- Încălcarea vieții private prin (1) proprietatea și gestionarea incorectă a datelor cu caracter personal, (2) neacordarea și retragerea consimțământului și (3) supraveghere internă.
- Nedreptate și diviziune digitală.
- Înșelăciune.
- Manipularea și construirea de relații autoritare.
- Schimbări în percepția umană asupra realității, înțelegerii, expertizei și comportamentului natural.
- Portretizare eronată a ființelor umane și a emoțiilor.



Recunoașterea automată a emoțiilor în procesul de învățare

Model etic pentru recunoașterea automată a emoțiilor în procesul de învățare online

16 clase de riscuri etice:

Negarea sau ocolirea autonomiei și drepturilor individuale (restricționarea capacității utilizatorilor de a-și exercita voința sau libertatea de exprimare, decizii nelibere și neinformate cu privire la utilizatori).

Utilizare duală.

Izolarea indivizilor, dezintegrarea conexiunilor sociale și dezumanizarea relațiilor interumane prin interacțiunea emoțională și socială cu sisteme de inteligență artificială de înaltă performanță, dar lipsite de conștientizare de sine.

Dependență de o mașină.

Riscul de a pierde simțul identității individuale.

Înlocuirea profesorilor.

Lipsa sustenabilității energetice.

Model etic

Explicabilitate în învățarea automată



Publicații: [T30], [T25]


- Interpretabilitate – explicabilitate

“gradul în care un observator poate înțelege cauza deciziei/ieșirilor unui model” Miller (2019) [T118]

4 direcții: justificarea deciziei, control și corectarea erorilor posibile, îmbunătățirea modelelor, descoperire de cunoștințe noi Adadi&Berrada (2018) [T121] Fairness

AI Act (2024) & GDPR (2016)
beneficiari & dezvoltatori

Modelul FAT [T31]
industrie și mediul
academic



Problema dezacordului
între rezultatele
algoritmilor de generare
a explicațiilor

Explicabilitate în învățarea automată



O metodă de analiză cu LIME pentru explicații, LIME (Local Interpretable Model-agnostic Explanations), Ribeiro et al. (2016) [T125]

- LIME este executat de mai multe ori (în experimentele noastre, de 20 ori).
- La fiecare execuție se determină influența atributului asupra predicției (unele attribute sprijină prezența unei emoții specific, altele sprijină absența acelei emoții).
- Pentru fiecare atribut, este calculat numărul de apariții ale atributului în subsetul de attribute care sprijină prezența unei emoții specifice, precum și numărul de apariții ale atributului în subsetul de attribute care sprijină absența unei emoții specifice.
- Pentru fiecare atribut, se calculează valoarea absolută a diferenței dintre cele două frecvențe calculate anterior.
- Ulterior, attributele sunt sortate în ordine descendentă pe baza diferenței absolute. Atributul cu cea mai mare valoare contribuie cel mai mult la prezența sau absența emoției. Dacă numărul de apariții ale unui atribut în subsetul de attribute care sprijină prezența emoției este mai mare decât numărul de apariții ale aceluiaș atribut în subsetul de attribute care sprijină absența emoției, atunci se consideră că acel atribut sprijină prezența emoției, altfel invers. [T25]

Explicabilitate în învățarea automată



O metodă de analiză cu LIME pentru explicații, LIME (Local Interpretable Model-agnostic Explanations), Ribeiro et al. (2016) [T125]

Rezultate (obținute pe modelul 1D-CNN recunoaștere emoții – 5 canale EEG, 14 instanțe)

Într-un caz al predicției absenței plictiselii, sunt obținute următoarele rezultate pentru fiecare atribut rulând LIME de 20 de ori: culoarea orange marchează attributele care sprijină mai mult prezența emoției, culoarea albastră le marchează pe cele care sprijină absența emoției, iar attributele fără nicio culoare au diferența absolută egală cu 0.

19	6	23	7	4	11	12	2	5	13	20	24	
14	12	12	10	8	8	8	6	6	6	6	6	
1	9	14	18	21	0	8	15	16	17	22	3	10
4	4	4	4	4	2	2	2	2	2	2	0	0

Adunând diferențele absolute, putem concluziona că există mai multe attribute determină absența emoției (72) decât prezența acesteia (62).

Explicabilitate în învățarea automată



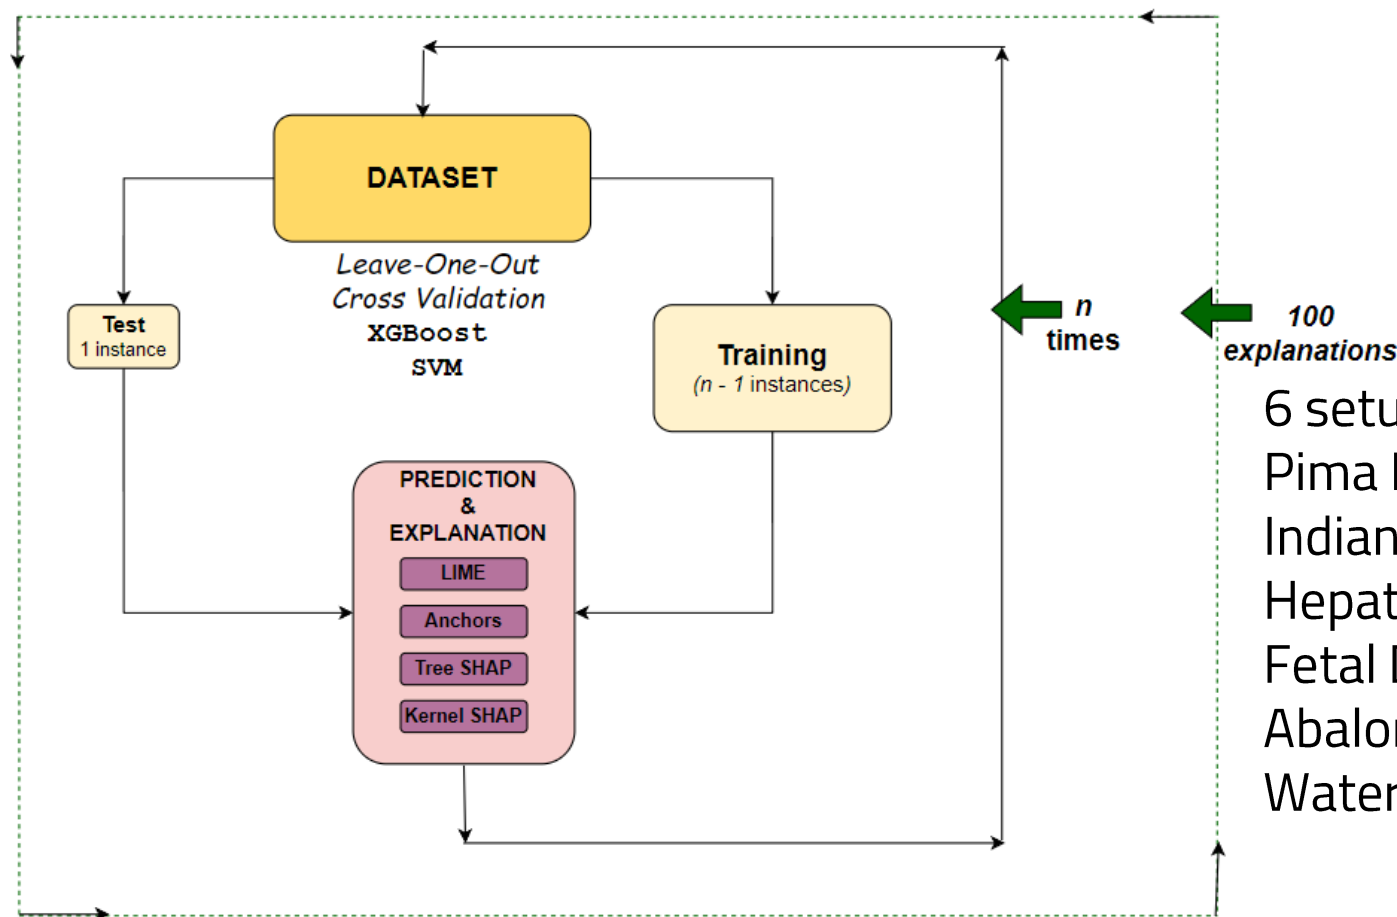
O metodă de agregare bazată pe clustere pentru alinierea explicațiilor

Pirie et al. (2023) - AGREE (AGgregation for Robust Explanations) – framework pentru agregarea explicatorilor și metrica Case Alignment Confidence

Etapa I

Generare explicații

scor și semn
pentru atribute



6 seturi de date:
Pima Indian Diabetes Dataset
Indian Liver Patient Dataset
Hepatitis Dataset
Fetal Dataset
Abalone Dataset
Water Quality Dataset

Explicabilitate în învățarea automată



O metodă de agregare bazată pe clustere pentru alinierea explicațiilor

Pirie et al. (2023) - AGREE (AGgregation for Robust Explanations) – framework pentru agregarea explicatorilor și metrica Case Alignment Confidence

Etapa II

Metodă de agregare bazată pe clustere

GAME (Global Alignment Measure) [T126] – între spațiul problemelor și soluțiilor

$$GAME = \frac{Sim(M_{sp})}{Sim(M_s)}$$

GAME score între exp. i și exp. j

GAME (Anchors-Anchors)=1

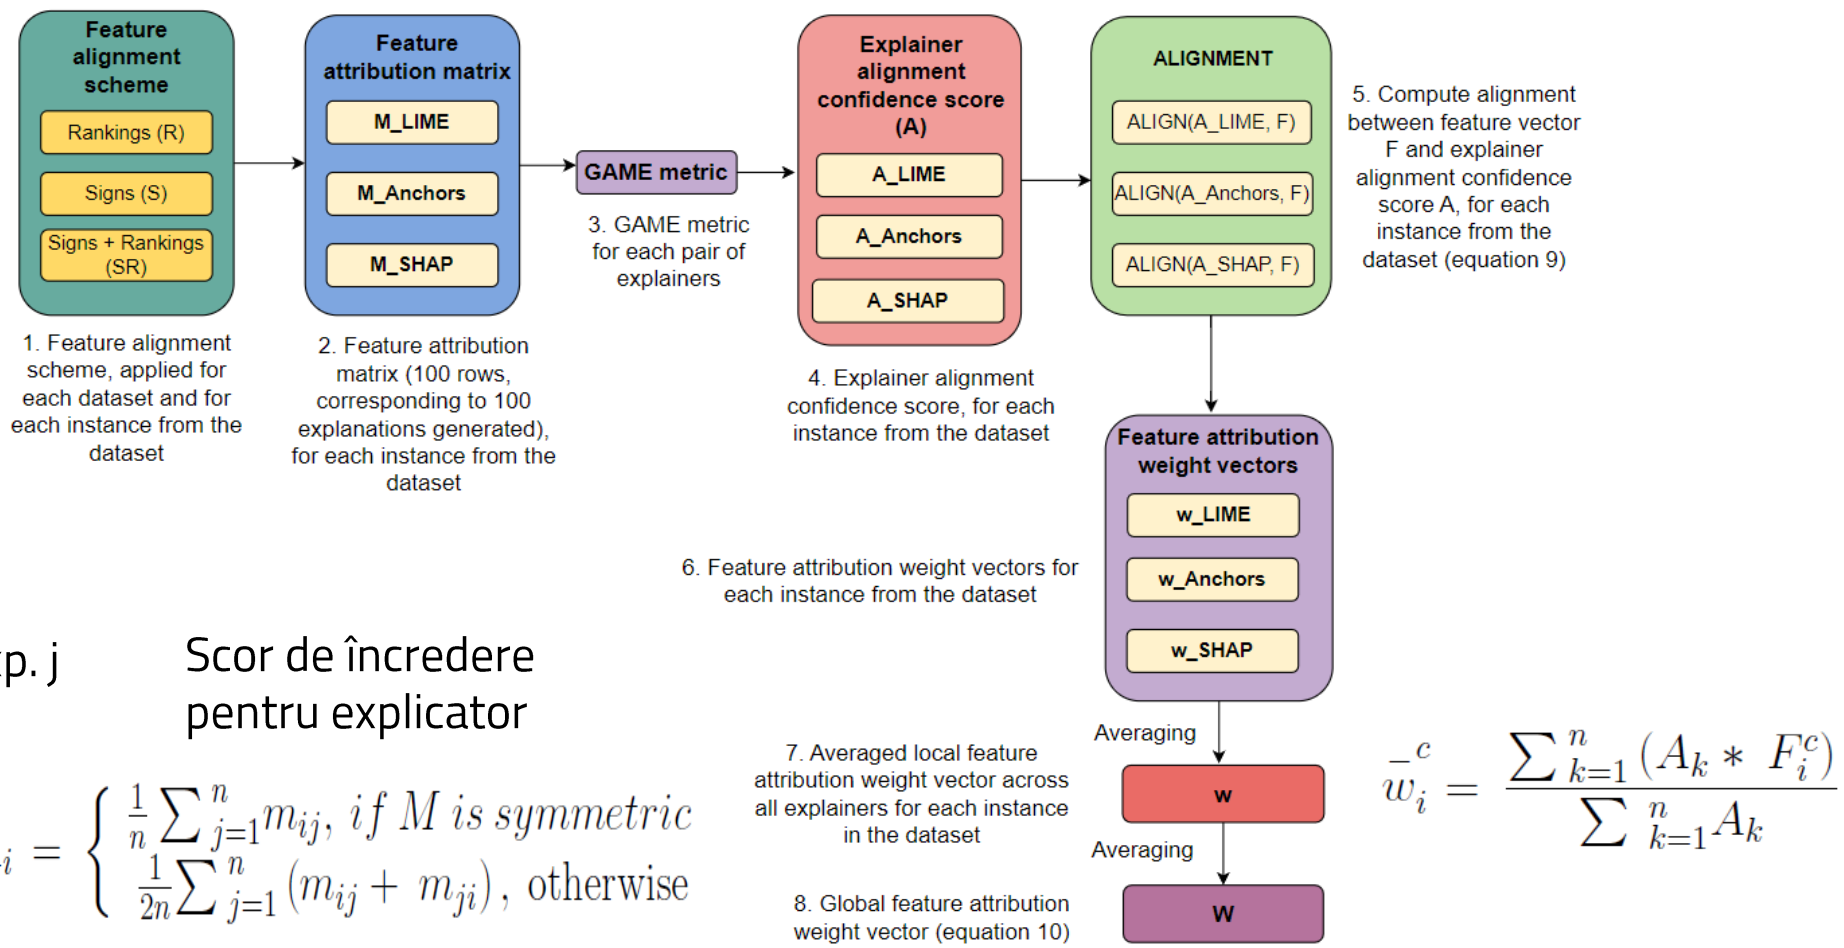
GAME (LIME-LIME)=1

GAME (SHAP-SHAP)=1

--

Scor de încredere pentru explicator

$$A_i = \begin{cases} \frac{1}{n} \sum_{j=1}^n m_{ij}, & \text{if } M \text{ is symmetric} \\ \frac{1}{2n} \sum_{j=1}^n (m_{ij} + m_{ji}), & \text{otherwise} \end{cases}$$



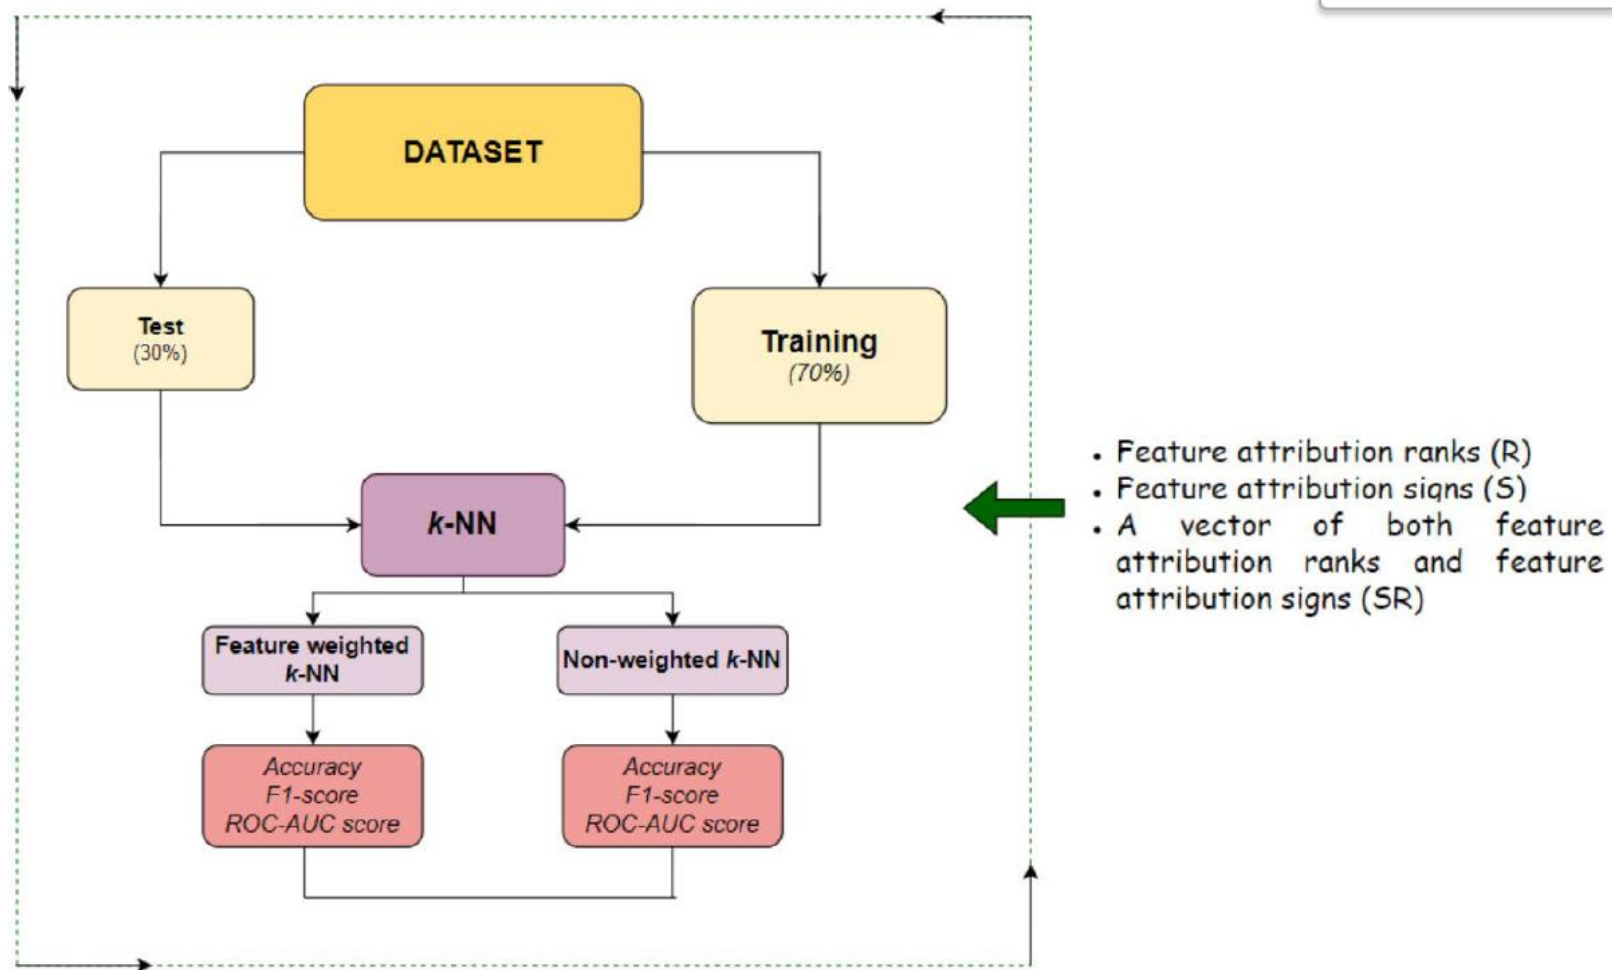
$$\bar{w}_i^c = \frac{\sum_{k=1}^n (A_k * F_i^c)}{\sum_{k=1}^n A_k}$$

Explicabilitate în învățarea automată



O metodă de agregare bazată pe clustere pentru alinierea explicațiilor

Evaluare



Explicabilitate în învățarea automată




O metodă de agregare bazată pe clustere pentru alinierea explicațiilor

Rezultate

Creșterea performanței k-NN ponderat cu w anterior calculat față de k-NN neponderat

- Clasificatorii non-weighted k-NN și weighted k-NN au fost rulați de 50 de ori, după care s-au calculat mediile metricilor de performanță

Scorurile de performanță pentru algoritmul k-NN ponderat au fost mai mari decât scorurile de performanță obținute cu clasificatorul k-NN neponderat pentru seturile de date Diabet, Liver, Hepatitis, Water și Fetal. Excepție a fost setul de date Abalone, pentru care am obținut scoruri de clasificare mai mici.



Evoluție și plan de dezvoltare a carierei (B-ii)



Cercetare

Direcții de cercetare

1. modele de învățare automată cu consum redus de energie

2025 - cererea de energie electrică pentru centrele de date bazate pe inteligență artificială va ajunge probabil la 21 GW

Networks of spiking neurons (SNN) :

Intrările neuronilor sunt spike-uri (creșteri foarte scurte de activitate electrică). Potențialul membranei neuronului crește prin acumulare de spike-uri. Când potențialul membranei neuronului atinge un prag, neuronul generează un spike către neuronii conectați la acesta. După ce neuronul emite un spike, potențialul membranei este resetat.

Modelele de SNN depind mecanismul de generare a spike-urilor.

Evoluție și plan de dezvoltare a carierei (B-ii)



Cercetare

Directii de cercetare

1. modele de învățare automată cu consum redus de energie și computing afectiv

Leaky Integrate and Fire (LIF) model, membrana neuronului este modelată conform ecuației

$$\tau \frac{du(t)}{dt} = u_{rest} - u(t) + RI(t), u < u_{th}$$

where u is the membrane potential, u_{rest} is the resting potential, τ is the membrane time constant, R the membrane resistance, I represent the input, the weighted sum of spikes, u_{th} is the firing threshold.

Evoluție și plan de dezvoltare a carierei (B-ii)



Cercetare

Directii de cercetare

**1. modele de învățare
automată cu consum redus
de energie și computing afectiv**

Rezultate

(recunoașterea emoțiilor)

Timpul max de
antrenare SNN
192.37 secunde,
timp min de
antrenare D-CNN
with 5 EEG este
5790.36 secunde

Emotion	SNN - Performance (%)		
	Training accuracy (%)	Test Accuracy (%)	Running time (seconds)
Boredom	97.656%	97.861%	153.5725
Confusion	100%	96.378%	142.9799
Frustration	95.312%	96.953%	192.3776
Curiosity	98.4375%	96.969%	128.8649
Excitement	98.437%	98.672%	110.2392
Concentration	93.75%	91.798%	122.2810
Anxiety	94.5312%	97.417%	121.9561

Multilabel classification pentru recunoașterea emoțiilor

Recunoașterea emoțiilor din expresii faciale

Evoluție și plan de dezvoltare a carierei (B-ii)



Cercetare

Directii de cercetare

2. Explicabilitate în învățarea automată

- Algoritm bazat pe LIME
- Algoritm pentru obținere de meta-rank-uri pentru attribute
- Echilibru între modelele de învățare automată de înaltă performanță și metodele de explicație consistente cu resurse reduse

3. Etică în învățarea automată

- Proiect de cercetare "Strategii pentru crearea unor locuri de muncă echitabile în societatea 5.0 "

Evoluție și plan de dezvoltare a carierei (B-ii)



Cercetare

Diseminare rezultatele cercetărilor

Implicare în depunere de proiecte de cercetare

2013 - Învățarea afectivă: beneficii și riscuri etice în învățământul superior (ALBER)

Colaborare cu cercetători din universități și companii

continuarea invitării de cercetători la cursul de Activități de cercetare în informatică

Organizare de evenimente științifice

Continuarea activității de membru în comitete științifice (ITICSE)

Dezvoltarea laboratorului Computer Science&Education

Evoluție și plan de dezvoltare a carierei (B-ii)



Didactic

Cursuri: învățare automată, analiza datelor, criptare și securitatea informației, algoritmica grafurilor, rețele de calculatoare, activități de cercetare în informatică

Introducere de cursuri opționale

Dezvoltare programe de studii - coordonator al programului de licență, Informatică

Mobilități Erasmus pe domeniul Informatică

Organizare de activități extracurriculare – elevi, studenți, angajatori

Dezvoltare de colaborări cu firme de profil

Organizare de workshop-uri științifice dedicate studenților



Bibliografie

[T1] Picard, R., Affective Computing, M.I.T Media Laboratory Perceptual Computing Section Technical Report No. 321, Cambridge, 1995.

[T2] Picard, R.W., Papert, S., Bender, W. Blumberg, B., Breazeal, C., Cavallo, D., Machover, T., Resnick, M., Roy D., and Strohecker, C.: Affective Learning – A Manifesto, BT Technology Journal, 22: 253, 2004.
<https://doi.org/10.1023/B:BTTJ.0000047603.37042.33>.

[T56] Ekman, P.: Basic emotions. In Handbook of Cognition and Emotion; Dalglish, T., Power, M., Eds.; John Wiley&Sons Ltd.: Hoboken, NJ, USA, 1999.

[T60] Mehrabian A., and Russel, J.A., An Approach to Environmental Psychology, The Massachusetts Institute of Technology: Cambridge, MA, USA, 1974.

[T61] Russel J., and Mehrabian, A., Evidence for a three-factor theory of emotions, J. Res. Personal, 11, p. 273–294, 1977.
[https://doi.org/10.1016/0092-6566\(77\)90037-X](https://doi.org/10.1016/0092-6566(77)90037-X)

[T62] Mehrabian, A., Pleasure-Arousal-Dominance: A general framework for describing and measuring individual differences in temperament, Curr. Psychol., 14, pp. 261-292, 1996. <https://doi.org/10.1007/BF02686918>.

[T63] Mehrabian, A., Framework for a comprehensive description and measurement of emotional states, Genet. Soc. Gen. Psychol. Monogr, 121, pp. 339-361, 1995. PMID: 7557355.



Bibliografie

- [T25] Moise, G., Dragomir, E.G., Șchiopu, D. et al. Towards Integrating Automatic Emotion Recognition in Education: A Deep Learning Model Based on 5 EEG Channels. Int J Comput Intell Syst 17, 230, 2024. <https://doi.org/10.1007/s44196-024-00638-x>
- [T5] Bălan, O., Moise, G., Moldoveanu, A., Moldoveanu, F. and Leordeanu. M., Does automatic game difficulty level adjustment improve acrophobia therapy? differences from baseline. In Proceedings of the 24th ACM Symposium on Virtual Reality Software and Technology (VRST '18). Association for Computing Machinery, New York, NY, USA, Article 78, 1–2. 2018., <https://doi.org/10.1145/3281505.3281583>.
- [T6] Bălan, O., Moise, G., Moldoveanu, A., Leordeanu, M., Moldoveanu. F., Challenges for ML-based Emotion Recognition Systems in Medicine. A Human-Centered Approach. CHI'19 Extended Abstracts, May 4-9, 2019, Glasgow, Scotland, UK. ACM CHI Conference on Human Factors in Computing Systems Workshop on Emerging Perspectives in Human-Centered Machine Learning.
- [T7] Bălan, O., Cristea, Ș., Moldoveanu, A., Moise, G., Leordeanu, M., Moldoveanu, F. (2020). Towards a Human-Centered Approach for VRET Systems: Case Study for Acrophobia. In: Siarheyeva, A., Barry, C., Lang, M., Linger, H., Schneider, C. (eds) Advances in Information Systems Development. ISD 2019. Lecture Notes in Information Systems and Organisation, vol 39. Springer, Cham. https://doi.org/10.1007/978-3-030-49644-9_11.



Bibliografie

[T9] Balan, O., Moise, G., Moldoveanu, A., Moldoveanu, F. and Leordeanu, M., Automatic Adaptation of Exposure Intensity in VR Acrophobia Therapy, Based on Deep Neural Networks. In Proceedings of the 27th European Conference on Information Systems (ECIS), Stockholm & Uppsala, Sweden, June 8-14, 2019. ISBN 978-1-7336325-0-8 Research Papers.
https://aisel.aisnet.org/ecis2019_rp/52.

[T10] Bălan, O.; Moise, G.; Moldoveanu, A.; Leordeanu, M.; Moldoveanu, F. An Investigation of Various Machine and Deep Learning Techniques Applied in Automatic Fear Level Detection and Acrophobia Virtual Therapy. Sensors 2020, 20, 496.
<https://doi.org/10.3390/s20020496>.

[T11] Bălan, O., Moise, G., Moldoveanu, A., Moldoveanu, F., Leordeanu, M., Classifying the Levels of Fear by Means of Machine Learning Techniques and VR in a Holonic-Based System for Treating Phobias. Experiments and Results. In: Chen, J.Y.C., Fragomeni, G. (eds) Virtual, Augmented and Mixed Reality. Industrial and Everyday Life Applications. HCII 2020. Lecture Notes in Computer Science, vol 12191. Springer, Cham. 2020. https://doi.org/10.1007/978-3-030-49698-2_24

[T12] Petrescu, L.; Petrescu, C.; Mitruț, O.; Moise, G.; Moldoveanu, A.; Moldoveanu, F.; Leordeanu, M. Integrating Biosignals Measurement in Virtual Reality Environments for Anxiety Detection. Sensors 2020, 20, 7088.
<https://doi.org/10.3390/s20247088>.



Bibliografie

- [T13] Koelstra, S.; Muehl, C.; Soleymani, M.; Lee, J.-S.; Yazdani, A.; Ebrahimi, T.; Pun, T.; Nijholt, A.; Patras, I. DEAP: A Database for Emotion Analysis using Physiological Signals. IEEE Trans. Affect. Comput. 2012, 3, 18–31, doi: 10.1109/T-AFFC.2011.15. ments for Anxiety Detection. Sensors 2020, 20, 7088. <https://doi.org/10.3390/s20247088>.
- [T8] Bălan, O., Moldoveanu, A., Petrescu, L., Moise, G., Cristea, Ș., Petrescu, C., Sensors system methodology for artefacts identification in Virtual Reality games, 2019 International Symposium on Advanced Electrical and Communication Technologies (ISAECT), Rome, Italy, 2019, pp. 1-6, doi: 10.1109/ISAECT47714.2019.9069719.
- [T14] Bălan, O.; Moise, G.; Moldoveanu, A.; Leordeanu, M.; Moldoveanu, F. Fear Level Classification Based on Emotional Dimensions and Machine Learning Techniques. Sensors 2019, 19, 1738. <https://doi.org/10.3390/s19071738>
- [T15] Petrescu, L.; Petrescu, C.; Oprea, A.; Mitruț, O.; Moise, G.; Moldoveanu, A.; Moldoveanu, F. Machine Learning Methods for Fear Classification Based on Physiological Features. Sensors 2021, 21, 4519. <https://doi.org/10.3390/s21134519>.
- [T16] Bălan, O.; Moise, G.; Petrescu, L.; Moldoveanu, A.; Leordeanu, M.; Moldoveanu, F. Emotion Classification Based on Biophysical Signals and Machine Learning Techniques. Symmetry 2020, 12, 21. <https://doi.org/10.3390/sym12010021>.



Bibliografie

[T80] Koestler, A.: The Ghost in The Machine. Arkana, New York, 1967.

[T81] Garcia-Herreros, E., Christensen, J., Prado, J.M., Tamura, S.: IMS - holonic manufacturing systems: System components of autonomous modules and their distributed control. Technical report, HMS Consortium, 1994.

[20] Moise, G., Vladoiu, M., Constantinescu, Z., GC-MAS – A Multiagent System for Building Creative Groups Used in Computer Supported Collaborative Learning. In: Jezic, G., Kusek, M., Lovrek, I., J. Howlett, R., Jain, L. (eds) Agent and Multi-Agent Systems: Technologies and Applications. Advances in Intelligent Systems and Computing, vol 296. Springer, Cham. 2014.
https://doi.org/10.1007/978-3-319-07650-8_31.

[21] Moise, G., Vladoiu, M., Constantinescu, Z., Building the Most Creative and Innovative Collaborative Groups Using Bayes Classifiers. In: Panetto, H., et al. On the Move to Meaningful Internet Systems. OTM 2017 Conferences. International Conference on Cooperative Information Systems (CoopIS) 2017, Lecture Notes in Computer Science(), vol 10573. Springer, Cham.
https://doi.org/10.1007/978-3-319-69462-7_17.

[22] Vladoiu, M., Moise, G., & Constantinescu, Z., Towards Building Creative Collaborative Learning Groups Using Reinforcement Learning. In B. Andersson, B. Johansson, S. Carlsson, C. Barry, M. Lang, H. Linger, & C. Schneider (Eds.), Designing Digitalization (ISD2018 Proceedings). Lund, Sweden: Lund University. ISBN: 978-91-7753-876-9. 2018.
<http://aisel.aisnet.org/isd2014/proceedings2018/Education/9>




Bibliografie

- [T23] Moise, G., Vladoiu, M., & Constantinescu, Z. (2018). Towards Construction of Creative Collaborative Teams Using Multiagent Systems. In B. Andersson, B. Johansson, S. Carlsson, C. Barry, M. Lang, H. Linger, & C. Schneider (Eds.), Designing Digitalization (ISD2018 Proceedings). Lund, Sweden: Lund University. ISBN: 978-91-7753-876-9. 2018.
<http://aisel.aisnet.org/isd2014/proceedings2018/Education/10>.
- [T24] Moise, G., Nicoară, E., S., Chapter 4 - Ethical aspects of automatic emotion recognition in online learning, Editor(s): Santi Caballé, Joan Casas-Roma, Jordi Conesa, In Intelligent Data-Centric Systems, Ethics in Online AI-based Systems, Academic Press, 2024, Pages 71-95, ISBN 9780443188510, <https://doi.org/10.1016/B978-0-443-18851-0.00003-2>.
- [T113] Akter, S., Prodhan, R.A., Pias, T.S., Eisenberg, D., Fresneda Fernandez, J.: M1M2: Deep-Learning-Based Real-Time Emotion Recognition from Neural Activity. Sensors. 22, 8467, 2022. <https://doi.org/10.3390/s22218467>.
- [T114] Topic, A., Russo, M., Stella, M., Saric, M.: Emotion Recognition Using a Reduced Set of EEG Channels Based on Holographic Feature Maps. Sensors 22, 3248, 2022. <https://doi.org/10.3390/s22093248>.
- [T31] Shin, D., Park, Y. J., Role of fairness, accountability, and transparency in algorithmic affordance, Computers in Human Behavior, Volume 98, 2019, Pages 277-284, ISSN 0747-5632, <https://doi.org/10.1016/j.chb.2019.04.019>.



Bibliografie

- [T125] Ribeiro, M.T., Singh, S., Guestrin, C.: "Why Should I Trust You?": Explaining the Predictions of Any Classifier. In: Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD '16), Association for Computing Machinery, New York, NY, USA, 1135–1144, 2016. <https://doi.org/10.1145/2939672.2939778>
- [T35] Pirie, C., Wiratunga, N., Wijekoon, A., Moreno-Garcia, C.F., AGREE: a feature attribution aggregation framework to address explainer disagreements with alignment metrics. In Proceedings of the Workshops at the 31st International Conference on Case-Based Reasoning (ICCBR-WS 2023), pp184–199. CEUR. 2023. https://ceur-ws.org/Vol-3438/paper_14.pdf Accessed April 2025.
- [T126] Chakraborti, S., Beresi, U., Wiratunga, N., Massie, S., Lothian, R., Watt, S., A Simple Approach towards Visualizing and Evaluating Complexity of Textual Case Bases. In: Proc. of the ICCBR 2007 Workshops. 2007.
- [T118] Miller, T., Explanation in artificial intelligence: Insights from the social sciences, Artificial Intelligence, Volume 267, 2019, Pages 1-38, ISSN 0004-3702, <https://doi.org/10.1016/j.artint.2018.07.007>
- [T121] Adadi A., M. Berrada, M., Peeking Inside the Black-Box: A Survey on Explainable Artificial Intelligence (XAI), in IEEE Access, vol. 6, pp. 52138-52160, 2018, doi: 10.1109/ACCESS.2018.2870052.



Mulțumesc

Sesiune de întrebări

Gabriela Moise

gmoise@upg-ploiesti.ro