



Universitatea
Transilvania
din Braşov

ŞCOALA DOCTORALĂ INTERDISCIPLINARĂ
Facultatea de Inginerie Electrică și Știința Calculatoarelor

Ing. Dragoș-Vasile BRATU

Inteligența artificială în sprijinul persoanelor cu nevoi speciale

REZUMAT

Conducător științific
Prof. dr. ing. Sorin-Aurel MORARU

BRAȘOV, 2023

Cuprins

Pagina rezumat
Pagina teză

Rezumat	iii	XXI
1 Introducere	1	1
1.1 Motivația utilizării inteligenței artificiale în sprijinul persoanelor cu nevoi speciale	1	1
1.2 Obstacolele inteligenței artificiale în sprijinul persoanelor cu nevoi speciale	2	3
1.3 Obiectivele cercetării doctorale	2	4
1.4 Structura și conținutul tezei	3	5
2 Stadiul actual al inteligenței artificiale și al persoanelor cu nevoi speciale	5	7
2.1 Stadiul actual al inteligenței artificiale	5	7
2.1.1 Învățarea supervizată	6	11
2.1.2 Învățarea nesupervizată	7	13
2.1.3 Învățarea prin consolidare	7	13
2.1.4 Elemente constitutive ale inteligenței artificiale	7	14
2.1.5 Obstacole semnificative ale învățării profunde	10	35
2.2 Stadiul actual al persoanelor cu nevoi speciale	10	35
2.2.1 Definiție și termeni folosiți	10	36
2.2.2 Tipuri de deficiențe	10	37
2.2.3 Encefalografia în studiul problemelor persoanelor cu nevoi speciale	11	41
3 Impactul inteligenței artificiale asupra vieții persoanelor cu nevoi speciale	13	45
3.1 Dificultățile cotidiene întâlnite de persoanele cu nevoi speciale	13	46
3.2 Tehnologii cu potențial în sprijinul persoanelor cu nevoi speciale	14	47
3.2.1 Interfețe creier-computer	14	47
3.2.2 Electrocardiografia	17	59
3.2.3 Considerații finale	18	63
4 Contribuții la aplicarea inteligenței artificiale pe dispozitive de putere redusă	19	65
4.1 Dezvoltarea unui sistem de procesare eficientă a seriilor temporale utilizând tehnici de inteligență artificială și <i>edge computing</i>	19	66
4.1.1 Prelucrarea și analiza descentralizată a datelor la marginea rețelei	20	66
4.1.2 Îmbunătățirea calității vieții persoanelor cu nevoi speciale prin procesarea eficientă a serii temporale pe dispozitivele <i>edge computing</i>	20	68

4.1.3	Implementarea unui sistem inteligent de detecție a anomaliilor din seriile tempore pe dispozitive de putere redusă	21	69
4.1.4	Considerații finale	25	78
4.2	Dezvoltarea unui robot autonom cu funcții multiple pentru îmbunătățirea calității vieții persoanelor cu nevoi speciale	26	79
4.2.1	Roboți de asistență	26	79
4.2.2	Îmbunătățirea calității vieții persoanelor cu nevoi speciale prin utilizarea unui robot autonom cu funcții multiple	26	80
4.2.3	Implementarea unui robot autonom pe dispozitive de consum redus pentru a răspunde nevoilor anumitor categorii vulnerabile	27	81
4.2.4	Considerații finale	36	98
5	Contribuții la aplicarea inteligenței artificiale în sprijinul persoanelor cu nevoi speciale	37	99
5.1	Aplicațiile inteligenței artificiale pentru detectarea și clasificarea aritmiei cardiace	37	100
5.1.1	Obstacole întâlnite în procesul electrocardiografiei	38	101
5.1.2	Colectarea și preprocesarea datelor	38	102
5.1.3	Arhitectura rețelei neuronale propuse	40	104
5.1.4	Aplicarea transformatei Wavelet	41	107
5.1.5	Evaluarea performanțelor obținute	42	109
5.1.6	Considerații finale	44	112
5.2	Aplicațiile inteligenței artificiale în clasificarea sarcinilor motorii	44	112
5.2.1	Obstacole întâlnite în cadrul interfețelor creier-computer	45	113
5.2.2	Arhitectura sistemului în aplicațiile interfeței creier-computer	45	114
5.2.3	Metode privind colectarea și preprocesarea seturilor de date experimentale	47	119
5.2.4	Extragerea caracteristicilor importante	55	139
5.2.5	Antrenarea, calibrarea și clasificarea datelor	56	142
5.2.6	Evaluarea performanțelor obținute	58	145
5.2.7	Considerații finale	60	153
6	Concluzii generale	61	155
6.1	Realizarea obiectivelor și contribuții originale	61	156
6.2	Direcții viitoare de cercetare	64	159
6.3	Diseminarea rezultatelor cercetării	65	160
6.3.1	Lista de publicații	66	160
6.3.2	Coordonator, concursuri și participarea la sesiuni științifice	66	161
6.3.3	Participarea la conferințe de domeniu	67	162
	Referințe	69	179

Rezumat

Teza intitulată „**Inteligența artificială în sprijinul persoanelor cu nevoi speciale**” reprezintă un studiu de mare importanță în contextul evoluției tehnologiei, ce evidențiază impactul pozitiv al inteligenței artificiale (IA) în viața persoanelor cu nevoi speciale.

Într-o lume tot mai digitalizată, accesul la tehnologii adecvate poate face diferența dintre limitări și posibilități, dintre izolare și incluziune. Prin această lucrare se urmărește dezvoltarea de soluții inovatoare sau îmbunătățirea celor deja existente, care să fie adaptate la cerințele specifice ale acestei categorii adesea neglijate în procesul de dezvoltare tehnologică.

Utilizarea IA în sprijinul persoanelor cu nevoi speciale reprezintă o direcție promițătoare, însă se confruntă cu numeroase obstacole ce variază de la costurile ridicate, nevoia personalizării soluțiilor și educația celor implicați, până la aspecte legate de infrastructura, accesibilitatea și confidențialitatea datelor. Prin aplicarea abordării interdisciplinare, IA poate îmbunătăți viața acestor persoane prin dezvoltarea sistemelor de asistență, eficientizarea comunicării, sprijinirea mobilității și independenței fizice, perfecționarea asistenței medicale și extinderea incluziunii sociale.

În primul rând, această lucrare analizează adaptarea tehnologiilor IA pentru a se potrivi cu cerințele specifice ale persoanelor cu nevoi speciale. Aceasta implică analiza atentă a tehnologiilor existente în IA, cu accent pe aplicabilitatea acestora în îmbunătățirea calității vieții categoriei anterior menționate. Prin explorarea acestui aspect, se urmărește dezvoltarea de soluții personalizate pentru anumite afecțiuni medicale și sisteme de asistență pentru persoanele cu nevoi speciale.

În al doilea rând, teza explorează aplicarea tehnologiilor de IA pe dispozitive de consum redus (*edge computing*). Aceste tehnologii pot crea soluții pentru procesarea eficientă a seriilor temporale ce sunt predominante în domeniul medical. De asemenea, se dezvoltă un robot de asistență multifuncțional, care utilizează IA și *edge computing* pentru a sprijini persoanele cu nevoi speciale în diverse aspecte ale vieții lor, ce se poate extinde și către alte servicii.

În ultimul rând, cercetarea se concentrează pe dezvoltarea și implementarea practică a sistemelor dedicate persoanelor cu nevoi speciale. Aceste sisteme vizează îmbunătățirea interacțiunii om-mașină, detectarea afecțiunilor medicale și adaptarea la nevoile individuale ale acestor persoane. De exemplu, soluțiile propuse includ detectarea și clasificarea aritmiilor cardiace, precum și clasificarea semnalelor encefalografice asociate cu sarcini motorii și propunerea de noi aplicații pentru îmbunătățirea vieții acestor categorii.

Capitolul 1

Introducere

1.1 Motivația utilizării inteligenței artificiale în sprijinul persoanelor cu nevoi speciale

Aplicațiile inteligenței artificiale (IA) pot avea un impact considerabil asupra vieții persoanelor cu nevoi speciale [1, 2, 3]. Îmbunătățirea calității vieții acestor persoane este un factor important de dezvoltare pentru multe sisteme de ultimă generație din domeniul IA. Exemplele includ instrumente de recunoaștere vocală ce adaugă subtitrări pentru persoanele cu deficiențe de auz și algoritmi de predicție a limbajului care sprijină comunicarea pentru cei cu dizabilități. Cu toate acestea, sistemele IA la scară largă pot prezenta probleme în adaptarea la nevoile specifice ale persoanelor cu dizabilități sau pot genera discriminare [4]. Organizația Mondială a Sănătății estimează că există peste un miliard de persoane cu nevoi speciale în întreaga lume [5]. Dezvoltarea de produse tehnologice accesibile pentru toate categoriile de utilizatori a fost un proces lung, dar tehnologiile de uz larg au adus beneficii semnificative pentru persoanele cu nevoi speciale [6, 7]. Un exemplu notabil este inventarea telefonului cu fir de către A. Graham Bell, care a încercat inițial să ajute persoanele cu deficiențe de auz, dar a creat un dispozitiv care a revoluționat comunicarea la nivel global. Cărțile audio și subtitrările vizuale reprezintă alte inovații importante care au făcut informația și cultura mai accesibile pentru persoanele cu diferite nevoi.

IA este tot mai folosită pentru a lua decizii cu impact direct asupra vieților oamenilor [8] însă există o tendință de discriminare către grupurile marginalizate, inclusiv persoanele cu dizabilități [4]. Condițiile de dizabilitate sunt diverse și sensibile, iar informațiile despre acestea nu sunt întotdeauna partajate din cauza riscului de discriminare [4, 7]. Utilizarea tehnologiilor avansate poate contribui la extinderea participării sociale și a oportunităților de angajare pentru persoanele cu dizabilități, având în vedere ratele semnificative de inactivitate pe piața muncii, cum ar fi cea de 32% în România, conform unui studiu Eurostat din 2018 [9]. IA nu poate oferi soluții suficiente pentru fiecare problemă, dar companiile deja investesc în proiecte de cercetare [10] ce pot depăși obstacolele existente.

1.2 Obstacolele inteligenței artificiale în sprijinul persoanelor cu nevoi speciale

Utilizarea IA în sprijinul persoanelor cu nevoi speciale reprezintă o direcție promițătoare, însă această aplicare se confruntă cu diferite obstacole. Aceste impedimente sunt atât tehnice, necesitând inovații complexe, cât și etice, având implicații sociale profunde dintre care se poate enumera:

- ▣ **Personalizare:** fiecare persoană cu nevoi speciale are un set unic de caracteristici, obstacole și aptitudini deci o soluție de IA generală este imposibil de realizat. Prin urmare este nevoie de soluții ce se pot adapta astfel încât să poată răspunde nevoilor specifice a cât mai multor indivizi;
- ▣ **Accesibilitate:** tehnologiile ce folosesc IA nu sunt accesibile/utilizabile de către această categorie;
- ▣ **Confidențialitatea datelor:** tehnologiile ce utilizează inteligența artificială necesită frecvent cantități mari (eng. *Big Data*) de informații personale pentru a funcționa în mod corespunzător. Persoanele cu nevoi speciale nu sunt întotdeauna în măsură să își acorde consimțământul pentru prelucrarea anumitor date, ceea ce face generalizarea soluțiilor cu atât mai dificilă;
- ▣ **Cost:** soluțiile deja existente fie consumă foarte multă energie, fie au nevoie de dispozitive scumpe ceea ce le face inaccesibile pentru unele persoane cu nevoi speciale, în special pentru cele cu venituri reduse;
- ▣ **Abordări interdisciplinare:** dezvoltarea tehnologiilor de IA pentru persoanele cu nevoi speciale necesită cunoștințe nu numai de informatică, ci și de educație specială despre anumite patologii, boli sau chiar psihologie;
- ▣ **Educație:** utilizatorii obișnuiți au nevoie de educație pentru a folosi IA), însă această nevoie este și mai pronunțată în cazul persoanelor cu deficiențe. Astfel, educația devine esențială pentru toată lumea, cu atât mai mult pentru categoria anterior menționată;
- ▣ **Antrenare:** de obicei antrenarea anumitor algoritmi se face pe anumite baze de date adnotate de medici, care pot diferi de semnalele indivizilor curenți. Acest lucru poate duce la rezultate divergente.

1.3 Obiectivele cercetării doctorale

În această teză, obiectivele acționează ca principii călăuzitoare, modelând direcția de cercetare, metodologia și concluziile tezei. Acestea reprezintă fundația pe care se construiește întregul studiu, definind cu precizie scopurile și obiectivele cercetării.

Obiectivul general al tezei este îmbunătățirea vieții persoanelor cu nevoi speciale prin utilizarea și implementarea tehnicilor de inteligență artificială. Prin aceasta se urmărește dezvoltarea de soluții

inovatoare sau îmbunătățirea celor actuale, care să fie adaptate la nevoile și cerințele specifice acestei categorii de persoane de cele mai multe ori ignorate.

OS1. Primul obiectiv specific constă în investigarea arhitecturilor de rețele neuronale și tehnologii IA adaptate nevoilor speciale ale anumitor categorii. Acesta se concentrează pe o explorare exhaustivă a arhitecturilor rețelelor neuronale, cu un accent deosebit pe aplicarea acestora în domeniul medical dar și pentru a se alinia la nevoile distincte ale persoanelor cu nevoi speciale. Se dorește obținerea de rezultate precise și relevante pentru îmbunătățirea calității vieții acestor persoane.

OS2. Al doilea obiectiv specific constă în analiza tehnicilor de IA aplicate dispozitivelor de consum redus – *edge computing*, în două cazuri concrete: unul legat de prelucrarea seriilor temporale și altul legat de realizarea unui sistem robotic multifuncțional, cu procesare cât mai aproape de sursa generatoare de date. Acestea sunt importante deoarece multe dintre sistemele utilizate pentru a răspunde cerințelor diverse ale anumitor categorii de persoane cu nevoi speciale necesită sisteme adaptabile cu procesarea locală a datelor, oferind sprijin într-un spectru de domenii, incluzând comunicarea, detecția anumitor anomalii medicale și chiar independența mobilității.

OS3. Al treilea și ultimul obiectiv specific constă în dezvoltarea și implementarea sistemelor dedicate persoanelor cu nevoi speciale, făcând referire la tehnologiile ce au fost menționate și în cadrul obiectivelor precedente. Acestea vor fi explorate practic, prin exemple din lumea reală, pentru a aborda aspecte legate de interacțiunea om-mașină, detectarea anumitor anomalii, afecțiuni medicale și interpretarea semnalelor vitale.

În concluzie, obiectivele descrise converg pentru a susține aspirația mai largă de a folosi inteligența artificială ca un catalizator pentru o schimbare pozitivă în viața persoanelor cu nevoi speciale și nu numai. Prin îndeplinirea acestor obiective se realizează îmbunătățiri tangibile și de durată în ceea ce privește bunăstarea, integrarea și autonomia acestui segment al societății noastre puțin avut în vedere.

1.4 Structura și conținutul tezei

Structura este organizată în șase capitole, fiecare capitol având un rol distinct în facilitarea unei examinări cuprinzătoare a obiectivelor anterior menționate.

Capitolul 1, intitulat „**Introducere**”, oferă o prezentare generală a subiectului tezei, introduce problema de cercetare și prezintă structura acestei lucrări. Totodată, în cadrul acestui capitol se prezintă obiectivele cercetării doctorale, scopurile specifice și importanța studiului. Obiectivele cercetării doctorale prezintă direcția de dezvoltare a acesteia. Acest capitol clarifică domeniul de aplicare al studiului, evidențiind principalele domenii de investigare.

Capitolul 2, denumit „**Stadiul actual al inteligenței artificiale și al persoanelor cu nevoi speciale**”, aprofundează aspectele fundamentale ale cercetării prin explorarea contextului actual al inteligenței artificiale. Sunt explicate diferitele tipuri de inteligență artificială, inclusiv învățarea supervizată și nesupervizată. Capitolul acoperă, de asemenea, componentele esențiale ale IA și obstacolele din învățarea profundă. În plus, în cadrul acestui capitol se prezintă o evaluare a situației actuale a persoanelor cu

nevoi speciale, inclusiv definirea termenilor și conceptelor relevante, identificarea diferitelor tipuri de deficiențe, precum și explorarea tehnologiilor adecvate ce pot fi aplicate problemelor acestui grup.

Capitolul 3, intitulat „**Impactul inteligenței artificiale asupra vieții persoanelor cu nevoi speciale**”, examinează implicațiile practice ale tehnologiei și ale inteligenței artificiale pentru persoanele cu nevoi speciale. Sunt prezentate obstacolele cu care se confruntă acest grup, după care este examinat potențialul diferitelor tehnologii. Sunt explorate interfețele creier-computer (BCI), dispozitivele de detectare a afecțiunilor cardiace și monitorizarea EKG concepute pentru a ajuta persoanele cu nevoi speciale, însoțite de exemple și dificultăți din lumea reală.

Capitolul 4, denumit „**Contribuții la aplicarea inteligenței artificiale pe dispozitive de putere redusă**”, se concentrează pe implementarea practică a soluțiilor *edge computing* și IA. Totodată se analizează impactul acestor soluții asupra îmbunătățirii calității vieții persoanelor cu nevoi speciale oferind sprijin într-un spectru de domenii, incluzând comunicarea, detecția anumitor anomalii medicale și chiar independența mobilității. În plus, este prezentată o nouă aplicație practică de inteligență artificială a unui dispozitiv de putere redusă prin proiectarea, dezvoltarea și implementarea unui robot de asistență autonom multifuncțional. Această aplicație utilizează inteligența artificială într-un sistem dual și redundant de detecție a persoanelor și poate descrie mediul în care se află, pentru a răspunde cerințelor anumitor categorii vulnerabile oferindu-le un mediu mai sigur. În cadrul acestui capitol se prezintă și impactul unui robot autonom cu funcții multiple asupra îmbunătățirii calității vieții persoanelor cu nevoi speciale.

Capitolul 5, intitulat „**Contribuții la aplicarea inteligenței artificiale în sprijinul persoanelor cu nevoi speciale**”, prezintă abordările practice ale IA pentru a răspunde obstacolelor cu care se confruntă persoanele cu nevoi speciale. Acesta descrie proiectarea, dezvoltarea și implementarea sistemelor dedicate persoanelor cu nevoi speciale, făcând referire la tehnologiile ce au fost menționate și în capitolele precedente. În prima parte sunt prezentate aplicațiile IA și abordările inedite pentru detectarea și clasificarea aritmiilor cardiace cu rezultate remarcabile de peste 98%. Sunt explicate colectarea de date, preprocesarea și arhitectura modelului, inclusiv rețelele neuronale convoluționale și soluțiile inedite aplicate. De asemenea, capitolul analizează aplicațiile inteligenței artificiale pentru clasificarea semnalelor encefalografice (EEG) asociate cu sarcini motorii ce se pot concretiza în soluții cu efect pozitiv asupra vieții persoanelor cu nevoi speciale. Sunt abordate impedimentele interfețelor creier-computer, achiziția de date, filtrarea, extragerea caracteristicilor, calibrarea și evaluarea datelor. În acest capitol se detaliază procesul de efectuare al unui experiment de colectare a datelor EEG de la diverși subiecți, conducând la rezultate remarcabile de clasificare a semnalelor temporale a sarcinilor motorii de peste 90%. Aceste rezultate sunt obținute prin intermediul unui sistem propriu implementat, capabil să utilizeze diverse arhitecturi neuronale convoluționale propuse dar și altele deja existente.

Capitolul 6, denumit „**Concluzii generale**”, rezumă principalele constatări și contribuții ale cercetării. Se evidențiază modul în care rezultatele cercetării au fost diseminate prin publicații, concursuri și conferințe. Capitolul prezintă implicațiile cercetării și contribuțiile sale în domeniu. Sunt explorate, de asemenea, potențialele căi de cercetare viitoare pe baza rezultatelor obținute.

Capitolul 2

Stadiul actual al inteligenței artificiale și al persoanelor cu nevoi speciale

2.1 Stadiul actual al inteligenței artificiale

Inteligența artificială (IA) este inteligența de care dau dovadă mașinile, utilizând metodologii din teoria probabilităților, statistică și informatică, matematică, psihologie și lingvistică pentru a dezvolta algoritmi capabili să emuleze funcțiile cognitive umane. IA este un domeniu în creștere rapidă care dezvoltă mașini inteligente capabile să îndeplinească sarcini care necesită abilități umane și să lucreze cu cantități mari de date fiind aplicată în domenii diverse. Acest domeniu cuprinde diverse subdomenii și tehnici, inclusiv învățarea automată, învățarea profundă, procesarea limbajului natural ilustrat în figura 2.1.

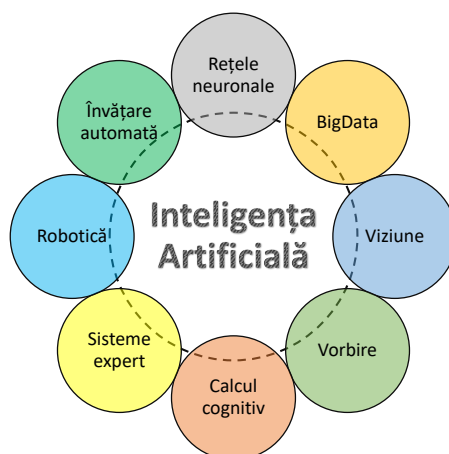


Figura 2.1: Ramuri ale inteligenței artificiale.

Un iceberg care plutește deasupra oceanului simbolizează vastitatea IA, așa cum se vede în figura 2.2. Deasupra liniei de plutire, se observă adesea titluri care atrag atenția, realizări și aplicații revoluționare, care prezintă capacitățile impresionante ale acestor sisteme. Sub linia de plutire se observă domeniile complexe de cercetare, algoritmi care implică modele matematice complexe, proceduri de formare extinse și o putere de calcul substanțială.

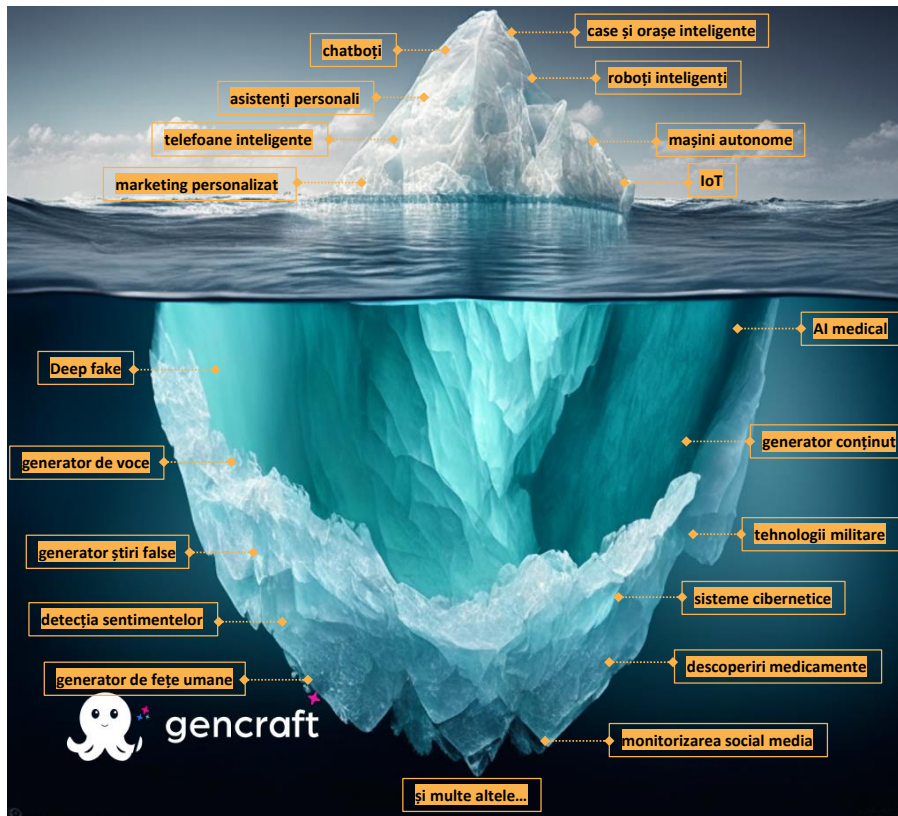


Figura 2.2: Analogie aisberg-inteligența artificială și domeniile vizibile și mai puțin vizibile¹.

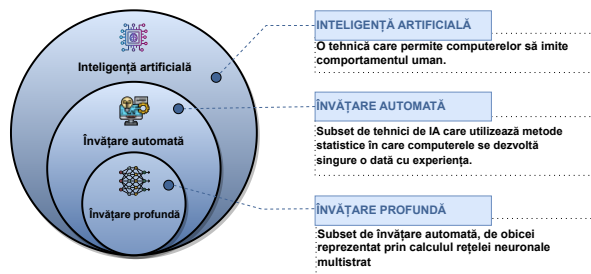


Figura 2.3: De la învățare profundă la inteligența artificială, adaptare după [11].

2.1.1 Învățarea supervizată

Utilizează un set de date etichetate pentru a prezice ieșirea, ajustând parametrii pe baza feedback-ului din erori. Se folosește în probleme de clasificare și regresie precum diagnosticul medical, detectarea fraudelor sau prezicerea temperaturii medii lunare. Alți algoritmi sunt regresia logistică, k-Nearest Neighbors, arborii de decizie, SVM, Naive Bayes [12, 13, 14, 15, 16].

¹Imagine artificială generată folosind textul „iceberg in the ocean with what is seen and what is not seen” www.gencraft.com, cu text adăugat peste.

2.1.2 Învățarea nesupervizată

Utilizează date fără etichetare, cu scopul de a descoperi modele și structuri necunoscute și este utilizată pentru detectarea modelelor și reducerea dimensionalității datelor.

2.1.3 Învățarea prin consolidare

Învățarea prin consolidare [17] este un proces de prin care modelul „învață” să atingă obiective în medii complexe. Se aseamănă cu un joc pe calculator, în care modelul învață prin încercări și erori, maximizând recompensele deci utilizează abordări bazate pe încercări cu o putere de calcul ridicată.




Figura 2.4: Concept consolidare a învățării, adaptare după [18].

2.1.4 Elemente constitutive ale inteligenței artificiale

Înțelegerea principiilor fundamentale ale învățării automate, inclusiv perceptronul, arhitectura rețelei și indicatorii de performanță, este esențială în acest domeniu.

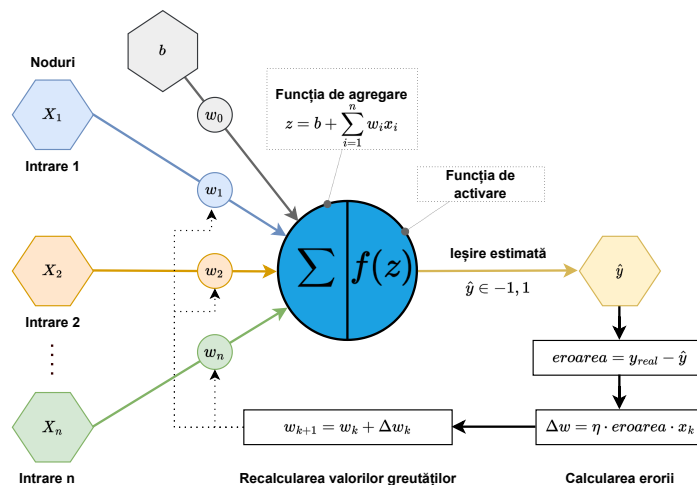


Figura 2.5: Perceptronul și funcția $f(z)$ de activare, cu o rată de învățare η , adaptare [19, 20, 21].

2.1.4.1 Perceptronul, funcțiile de activare și straturi arhitecturale

Perceptronul (figura 2.5) este nucleul rețelelor neuronale artificiale, care prin ponderile (w_i) și a funcției de activare ($f(x)$), procesează intrările (X_i) și *bias*-ul pentru a genera ieșiri (y_n). Funcția de activare introduce neliniaritate, permițând captarea relațiilor complexe dintre intrări și ieșiri.

Funcția de activare reprezintă o ecuație matematică care determină ieșirea fiecărui neuron în funcție de intrare (figura 2.5). Este eficientă din punct de vedere computațional și ajută la crearea unui interval între 0 și 1. Funcția de activare introduce neliniaritatea, permițând modelului să învețe modele complexe din date. Funcțiile de activare pot fi liniare sau neliniare și sunt esențiale pentru performanța și flexibilitatea rețelelor neuronale. Funcția de activare într-o rețea neuronală introduce non-linearitate în ieșirile neuronilor. Există trei tipuri principale de funcții de activare: binare, liniare și neliniare.

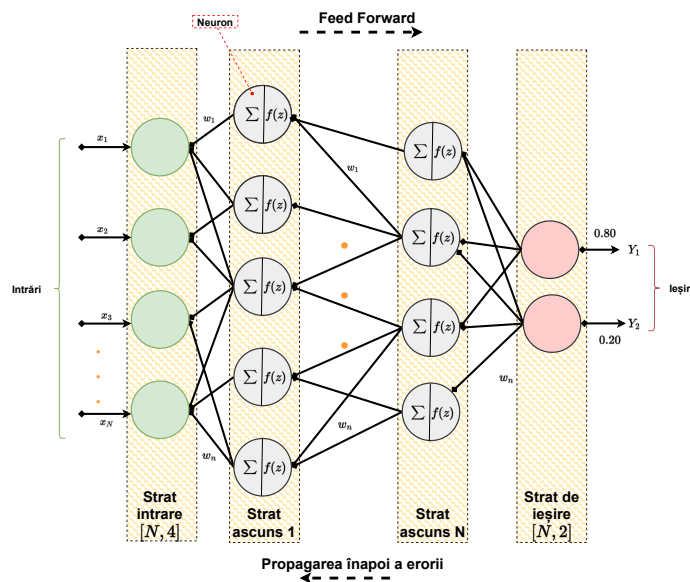


Figura 2.6: Arhitectura unei rețele neuronale: intrare, straturi ascunse și ieșire, adaptare [20].

Funcția de pas binar are la bază un prag ce trimite un semnal identic către stratul următor atunci când o valoare de intrare depășește sau scade sub un anumit prag. **Funcția de activare liniară** are performanțe mai bune decât cea binară cu dezavantaj în a folosi metoda *Backpropagation*. **Funcția de activare neliniară** este cea mai utilizată funcție de activare pentru a crea corespondențe complexe între intrări și ieșiri, esențiale pentru învățarea și modelarea datelor. Cele mai utilizate astfel de funcții sunt funcția de activare sigmoidă/logistică, a tangențelor hiperbolice, ReLU (eng. *Rectified Linear Unit*), *Leaky ReLU*, (PReLU), ELU (care rezolvă problemele ReLU) și Softmax [22] etc.

Straturi arhitecturale în rețele neuronale artificiale

Stratificarea rețelelor neuronale în straturi arhitecturale este un factor esențial în determinarea configurației și funcționării rețelei. Procesul implică transmiterea intrărilor în straturi succesive. Stratul anterior generează intrări pentru stratul următor. Straturile de intrare, straturile ascunse și straturile de ieșire, îndeplinesc fiecare sarcini specifice. Stratul inițial este responsabil pentru primirea datelor neprocesate, în timp ce straturile intermediare efectuează calcule pe date pentru a genera reprezentări intermediare, iar stratul final produce rezultatul predicției sau al clasificării. Dintre cele mai utilizate straturi menționăm stratul de convoluție, de *dropout* [23], de pooling maxim sau mediu [24, 25, 26, 27], de aplatizare și cel complet conectat.

2.1.4.2 Propagarea înapoi în rețea a erorilor, funcția de pierdere, hiperparametri, termenul de distorsiune și modelul unei rețele neuronale artificiale

Backpropagation este un algoritm esențial în antrenarea rețelelor neuronale. Are două faze: trecere înainte (propagarea datelor prin rețea) și trecere înapoi (calcularea erorii și ajustarea ponderilor). Scopul este minimizarea erorii prin actualizarea ponderilor iterativ cu ajutorul gradientului erorii [28]). Funcția de pierdere (sau funcția de cost) evaluează cât de bine se potrivesc predicțiile unui model cu datele de antrenare. Se folosesc funcții de cost diferite precum MSE *Cross-entropy Loss* [29, 30, 31]. Hiperparametri (eng. *Hyperparameters*) sunt parametrii ale căror valori controlează procedura de învățare și decid valorile parametrilor modelului pe care un algoritm de învățare le asimilează în cele din urmă. Prefixul „hiper” indică faptul că acești parametri controlează procesul de învățare și parametri modelului care rezultă din acesta (adaptare după [32]). Termenul de distorsiune (eng. *bias* [33, 34, 35]) reprezintă eroarea sistematică a algoritmilor în prezicerea valorilor reale sau preconizate, iar modelul unei rețele neuronale este o reprezentare matematică care învață și face predicții pe baza datelor de intrare.

2.1.4.3 Metrici pentru evaluarea performanței algoritmului de învățare automată, epoci, rata de învățare, supraadaptarea și subadaptarea

Metricile constă în diverse măsurători folosite în procesul de evaluare a performanței și stabilire a eficacității arhitecturilor rețelelor de învățare automată. Dintre cele mai utilizate astfel de metrice putem menționa acuratețea modelului, matricea de confuzie, precizie și rata adevăratului pozitiv, scorul F1, AUC-ROC, MAE etc. Epoca reprezintă o iterație asupra setului de date de instruire, în timpul căreia parametrii modelului sunt ajustați în funcție de eroarea calculată între valorile prezise și cele reale. Rata de învățare este un hiperparametru care determină cât de rapid sunt modificate parametrii în timpul instruirii, influențând convergența și evitarea supraadaptării sau subadaptării [28, 36].

2.1.4.4 Optimizatoare și metode de a gestiona seturile de date dezechilibrate

Optimizatoarele sunt esențiale în instruirea rețelelor neuronale, ajustând ponderile modelului pentru a obține predicții precise prin modificarea lor în funcție de funcția de pierdere. Exemple de optimizatoare includ Adadelta, AdaGrad, Adam etc.[37, 28, 38, 39], fiecare cu abordări diferite de ajustare a parametrilor modelului. Alegerea optimizatorului potrivit influențează performanța și viteza de convergență a modelului.

Pentru a gestiona seturile de date dezechilibrate în învățarea automată, se pot utiliza tehnici precum supraeșantionarea aleatorie (duplicarea eșantioanelor din clasa minoritară), subeșantionarea aleatorie (eliminarea aleatorie a eșantioanelor din clasa majoritară) sau tehnica SMOTE [40] (crearea de exemple sintetice ale clasei minoritare prin extrapolarea trăsăturilor). Aceste metode ajută la echilibrarea setului de date și îmbunătățesc performanța modelului.

2.1.5 Obstacole semnificative ale învățării profunde

Învățarea profundă, deși promițătoare, se confruntă cu numeroase provocări, precum **lipsa datelor de înaltă calitate, mediul în continuă schimbare** și necesitatea de **putere de procesare considerabilă**, cu implicații în consumul de energie, **confidențialitatea și securitatea datelor**. De asemenea, **specificitatea și complexitatea rețelelor neuronale** adâncesc dificultățile în dezvoltarea acestor algoritmi.

2.2 Stadiul actual al persoanelor cu nevoi speciale

Dizabilitatea este o problemă complexă care include dificultăți în îndeplinirea sarcinilor și restricții în participarea la viață, reflectând interacțiunea dintre caracteristicile individului și societatea în care trăiește, conform definiției OMS [5].

2.2.1 Definiție și termeni folosiți

În contextul persoanelor cu nevoi speciale, termenul de „dizabilitate” se referă la pierderi sau limitări ale funcțiilor fizice sau mentale, având un impact asupra abilității de a îndeplini sarcini zilnice și de a participa activ în societate, iar limbajul preferat se îndreaptă către expresii respectuoase precum „persoane cu handicap” sau „persoane cu nevoi speciale”, cuprinzând o varietate de subdiviziuni, de la probleme motorii la dizabilități senzoriale sau intelectuale. Această categorie diversificată de persoane cu nevoi speciale include vârstnici cu probleme motorii și cardiace, indivizi cu paralizii dobândite din accidente sau traume, persoane cu dizabilități senzoriale, traume psihice, dependențe de substanțe, copii din medii defavorizate sau marginalizate, precum și cei cu dizabilități intelectuale, afecțiuni medicale cronice sau dizabilități de învățare. În lucrarea curentă, termenul „persoane cu nevoi speciale” acoperă un grup divers de indivizi cu cerințe sau necesități particulare, care pot include deficiențe sau dizabilități, dar variază în funcție de factori precum vârsta, sănătatea mintală, dependențele, situația socio-economică și istoricul educațional, iar sprijinul adecvat este esențial pentru promovarea egalității de șanse și a drepturilor omului.

2.2.2 Tipuri de deficiențe

Cele mai comune deficiențe întâlnite în rândul persoanelor cu nevoi speciale pot fi grupate în trei categorii: deficiențe fizice și senzoriale, tulburări și afecțiuni cognitive și dizabilități fizice dobândite, inclusiv paralizii și dizabilități cauzate de leziuni cerebrale.

2.2.2.1 Deficiențe fizice și senzoriale

Deficiențele motorii și de comunicare pot limita independența și participarea socială a persoanelor în vârstă, putând fi cauzate de factori precum slăbirea musculară, declinul cognitiv sau probleme de auz și vorbire. Intervenții, reabilitare și tehnologii pot contribui la îmbunătățirea calității vieții acestor

persoane. Deficiența vizuală se referă afectarea vederii care nu poate fi corectată cu ochelari sau lentile de contact. Pe de altă parte, pierderea auzului este o afectare parțială sau totală a capacității de a auzi, care poate afecta limbajul la copii și interacțiunile sociale la adulți, cu potențialul de a izola persoanele din grupuri sociale. Ambii factori pot influența capacitatea fizică sau percepțiile senzoriale ale unei persoane.

2.2.2.2 Tulburări și afecțiuni cognitive

Aceste categorii includ o gamă largă de afecțiuni legate de sănătatea mintală, dizabilități intelectuale și leziuni cerebrale, care afectează funcțiile cognitive. Exemple includ tulburări de spectru autist, sindromul Tourette și epilepsia. Condițiile de sănătate mintală, precum depresia, anxietatea și schizofrenia, pot influența negativ viața de zi cu zi și pot fi gestionate prin terapie medicamentoasă și psihoterapie. Dizabilitatea intelectuală implică limitări semnificative în funcționarea intelectuală și adaptarea la viața de zi cu zi, iar cauzele pot fi variate, inclusiv factori genetici și de mediu. Leziunile cerebrale pot rezulta din evenimente după naștere și pot cauza tulburări cognitive, emoționale și fizice. Tulburarea din spectrul autist afectează interacțiunile sociale și comunicarea, în timp ce sindromul Tourette implică ticuri vocale și motorii. Epilepsia provoacă convulsii recurente datorită activității electrice anormale în creier și poate avea cauze diverse, de la leziuni cerebrale la factori genetici.

2.2.2.3 Dizabilități fizice dobândite

Această categorie include dizabilitățile fizice dobândite, cum ar fi leziunile cerebrale, paralizia cerebrală, distrofia musculară și leziunile măduvei spinării. Dizabilitatea fizică afectează mobilitatea și poate fi ereditară sau dobândită în urma unui accident sau afecțiunii medicale. Cauzele pot include traume, boli sau afecțiuni congenitale. Paralizia cerebrală se dezvoltă în timpul nașterii și poate provoca slăbiciune musculară și probleme de coordonare. Distrofia musculară este o afecțiune genetică care duce la pierderea progresivă a mușchilor, iar leziunile măduvei spinării pot cauza pierderea mobilității.

2.2.3 Encefalografia în studiul problemelor personalelor cu nevoi speciale

Electroencefalografia este o tehnică utilizată pentru a măsura activitatea electrică a creierului uman prin înregistrarea potențialelor electrice generate. Acest test este ușor accesibil și oferă date concrete despre starea de funcționare a creierului. Electroencefalograma (EEG) este un instrument utilizat în mod obișnuit în rândul medicilor și cercetătorilor în scopul investigării proceselor cerebrale și al identificării patologiilor neurologice. În plus, s-a constatat că este benefică în abordarea tulburărilor de comportament, cum ar fi autismul, a deficitelor de atenție, a dificultăților în dobândirea cunoștințelor și a întârzierilor în dezvoltarea limbajului [41]. Învățarea profundă cunoscută și sub numele de *Deep Learning* a demonstrat în ultima perioadă de timp o capacitate impresionantă în interpretarea semnalelor în serii temporale [42, 43] și poate avea un impact puternic în interpretarea semnalelor EEG prezent în anumite studii [44].

2.2.3.1 Tipuri de electroencefalogramă

Electroencefalograma este folosită pentru diagnosticarea anumitor afecțiuni neurologice. Există EEG de rutină pentru evaluarea stării creierului, EEG ambulatoriu pentru monitorizarea activității cerebrale în afara spitalului, EEG în timpul somnului pentru diagnosticarea tulburărilor de somn și EEG video (telemetria video) care combină înregistrarea activității cerebrale cu monitorizarea comportamentului pacientului pentru o evaluare mai detaliată a funcționării creierului.

2.2.3.2 Stocarea semnalelor medicale

Formatul european de date (EDF) reprezintă un standard gratuit pentru stocarea semnalelor biologice și fizice în electrofiziologie, fiind esențial în înregistrările EEG și PSG. EDF+ [45, 46] este o versiune îmbunătățită care permite adnotări text direct pe semnale, iar software-ul EDF Browser [47] facilitează vizualizarea și analiza acestor date, fiind util în cercetare și practica clinică.

Capitolul 3

Impactul inteligenței artificiale asupra vieții persoanelor cu nevoi speciale

În lumea modernă, tehnologia și inteligența artificială au schimbat în mod remarcabil multe aspecte ale vieții, în special pentru persoanele cu nevoi speciale [1, 2, 3]. Tehnologia a revoluționat abilitățile persoanelor cu nevoi speciale, inclusiv dezvoltarea comunicării, mobilității, asistența medicală și se întâlnește chiar și în deciziile cu impact major asupra oamenilor [8].

Cu toate acestea, există obstacole cum ar fi personalizarea soluțiilor, protecția datelor și costurile ridicate în domeniul IA. Interfața creier-computer (BCI) reprezintă un domeniu important, permițând controlul dispozitivelor cu semnale emise de creier, benefic pentru persoanele cu dizabilități, inclusiv în detectarea problemelor de sănătate.

Un alt aspect important constă în utilizarea dispozitivelor de detecție a afecțiunilor medicale ce sunt vitale pentru persoanele cu nevoi speciale care se confruntă cu afecțiuni precum cele cardiace.

3.1 Dificultățile cotidiene întâlnite de persoanele cu nevoi speciale

Persoanele cu nevoi speciale se confruntă zilnic cu provocări influențate de tipul și gravitatea acestora și de disponibilitatea asistenței după cum urmează:

- ❑ **traul independent** și anume că unele persoane cu dizabilități pot necesita asistență pentru sarcini cotidiene, precum igiena personală sau hrănirea;
- ❑ **Asistența medicală și serviciile de sprijin** care de cele mai multe ori sunt costisitoare, în plus necesitând anumite echipamente;
- ❑ **Comunicarea** cu cei din jur pentru exprimarea nevoilor fundamentale, cum ar fi mâncarea și apa, sau chiar controlul unui scaun cu roțile fiind strâns legată integrarea în societate a acestora pentru a nu fi marginalizați;
- ❑ **ocuparea forței de muncă;**

- ▣ obținerea unei **educații de calitate**, specifice nevoii lor;
- ▣ **incluziunea redusă** în societate ce rezultă în marginalizarea acestei categorii;
- ▣ **mobilitatea și accesibilitatea** sunt obstacole principale pentru persoanele cu dizabilități, influențându-le capacitatea de a se deplasa și de a participa în societate.

O strategie de dezvoltare cuprinzătoare este esențială pentru depășirea obstacolelor menționate și viitoare, inclusiv îmbunătățirea accesibilității, combaterea prejudecăților sociale și extinderea serviciilor de sănătate și de mobilitate pentru persoanele cu dificultăți.

3.2 Tehnologii cu potențial în sprijinul persoanelor cu nevoi speciale

Deși s-a discutat anterior despre contribuția IA la sprijinirea categoriilor vulnerabile, trebuie să explorăm modurile în care aceasta poate colabora cu alte tehnologii pentru a depăși obstacolele enumerate în secțiunea 3.1.

3.2.1 Interfețe creier-computer

Interfața creier-computer (BCI) permite comunicarea cu mediul înconjurător cu ajutorul semnalelor cerebrale, fără a fi necesară acțiunea musculară. Acest sistem are un impact semnificativ asupra calității vieții persoanelor cu dizabilități motorii severe, facilitând interacțiunea cu dispozitive externe precum computere, sintetizatoare de vorbire și proteze neuronale. Progresele în neurologie, prelucrarea semnalelor și tehnologia senzorilor au transformat BCI-urile din concepte în realitate, așa cum indică studii recente [48, 49, 50]. BCI-urile se pot folosi de IA, mai exact învățarea automată, și pot recunoaște un anumit set de modele în semnalele electrice produse de creier. Tot acest proces se desfășoară în mai multe etape consecutive: achiziția semnalului, preprocesarea și îmbunătățirea semnalului, extragerea caracteristicilor, clasificarea și antrenarea (cu ajutorul tehnicilor de IA) și interfața de control cu aplicațiile în timp real, etape descrise în secțiunea 5.2.2.

3.2.1.1 Activitatea electrică a creierului: funcții și localizări

Undele cerebrale, denumite și **oscilații neuronale**, sunt modele periodice de activitate electrică generate de creier, clasificate în intervale de frecvență distincte și legate de procesele cognitive, stările mentale și funcțiile fiziologice. Acestea se împart în mai multe categorii: delta (0,5-4 Hz) sunt observate în somnul profund, theta (4-8 Hz) asociate cu visarea, relaxarea profundă și creativitatea, alfa (8-12 Hz) pentru stare de relaxare și meditație cu ochii închiși, beta (12-30 Hz) asociate cu concentrare sporită, în timp ce gama (30-100 Hz) indică procese cognitive avansate, precum atenția și memoria. Tiparele undelor cerebrale variază de la o persoană la alta, fiind influențate de stările de spirit și de activitățile mentale. Neuro-știința, psihologia și știința cognitivă studiază aceste oscilații pentru a înțelege funcția neuronală și comportamentul uman.

Funcțiile și locațiile cerebrale, (cu lobul frontal, occipital, parietal, temporal), care desemnează funcții specifice, constituie aspecte esențiale în complexitatea creierului uman. Cercetări extinse au condus la progrese semnificative în identificarea zonelor cruciale responsabile pentru funcții precum percepția, controlul motor, procesarea limbajului și consolidarea memoriei [51]

Zonele Brodmann reprezintă un sistem de diviziuni anatomice în cortexul cerebral uman similare cu cele din figura 3.1. Ele au fost definite de neurologul K. Brodmann care a împărțit cortexul în 52 de zone. Există anumite cercetări ce au arătat că organizarea creierului este mult mai complexă [52, 53].




Figura 3.1: Locațiile creierului și funcțiile acestuia, sursă [54], după zonele Brodmann [55].

3.2.1.2 Utilitatea encefalogramii în diferite afecțiuni

Electroencefalografia ajută la diagnosticarea tulburărilor neurologice și psihiatrice prin analiza activității electrice cerebrale, contribuind la un diagnostic precis și la progresul pacientului, în special în sistemele nervoase centrale sau periferice [56, 57, 58, 59]. Acestea includ utilizarea EEG-ului pentru localizarea zonelor responsabile de crizele epileptice, evaluarea deteriorării funcției cerebrale și a complicațiilor post-AVC, identificarea zonelor funcționale în timpul intervențiilor chirurgicale pentru tumori cerebrale și detectarea modificărilor subtile ale undelor cerebrale în stadiile incipiente ale demenței Alzheimer. Pe de altă parte, afecțiunile psihiatrice afectează funcționarea mentală, emoțională și comportamentală a unei persoane iar EEG-ul poate fi folosit pentru ajustarea tratamentului și evaluarea eficacității acestuia. Dintre afecțiuni, cele mai comune includ tulburarea depresivă, schizofrenia, depresia și anxietatea, precum și tulburările de stres post-traumatic.

3.2.1.3 Electrozi, amplasarea acestora în montaje și posibile artefacte

Electrozii EEG se împart în două categorii: electrozi activi și pasivi. Cei activi au circuite de amplificare pentru îmbunătățirea semnalului și reducerea interferențelor, necesitând echipamente specializate și

alimentare suplimentară. Electrozii pasivi măsoară potențialele electrice direct, fără amplificare internă, și necesită un sistem de amplificare separat, având variate modele și materiale, precum electrozi cu gel Ag/AgCl, electrozi cu un singur ac de aur sau electrozi hibridi cu mai mulți pini, fiecare cu avantaje și dezavantaje specifice [60].

Amplasarea electrozilor se realizează prin intermediul montajelor, care sunt aranjamente logice și ordonate de canale utilizate pentru afișarea activității EEG pe scalp. Numărul de canale dintr-un montaj variază (de la 2 la peste 100) în funcție de numărul de electrozi disponibili și scopul înregistrării. Sistemul 10-20, cu 21 de locații pentru electrozi și 16 canale, este doar una dintre multele configurații posibile. Clasificarea montajelor include variante precum bipolar longitudinal, transversal sau referențial [61].

Numărul de canale sau numărul de electrozi utilizați pe scalp pentru înregistrare, influențează rezoluția spațială și capacitatea de detectare a afecțiunilor. Mai multe canale îmbunătățesc precizia localizării activității cerebrale și oferă date suficiente pentru algoritmi de învățare automată, evitând necesitatea generării de date sintetice (secțiunea 2.1.4.4).

Tipurile de artefacte reprezintă semnale nedorite care pot interfera cu interpretarea corectă a activității cerebrale. Cele mai des întâlnite artefacte sunt cele produse de clipire (figura 3.2), artefacte de transpirație, artefacte de mișcarea laterală a ochilor, artefacte EKG, artefacte generate de pulsația unei vene și artefacte de respirație.



Figura 3.2: Artefactul produs de clipire, sursa [62].

Analiza componentelor independente (ICA) [63, 64] este o metodologie de procesare a semnalelor folosită în EEG pentru a separa în mod eficient semnalele în componentele lor fundamentale, eliminând artefacte precum clipitul ochilor și zgomotele electrice.

3.2.1.4 Dispozitive pentru achiziția semnalelor cerebrale

Dispozitivele de achiziție a semnalelor cerebrale sunt instrumente non-invasive care capturează activitatea electrică a creierului de la nivelul scalpului, având multiple aplicații în cercetare, tratament medical și dezvoltarea tehnologiilor controlate de creier.

Sistemul Neuron Spectrum 65 este un dispozitiv medical dezvoltat de Neurosoft utilizat în instituții medicale din întreaga lume pentru achiziționarea semnalelor cerebrale. Acest sistem avansat oferă 39 de canale EEG, canale EKG pentru eliminarea artefactelor, precum și canale EMG și EOG, încorporând o unitate portabilă pentru conectarea și deconectarea senzorilor, asigurând o calitate excelentă a semnalului și reprezentând o soluție flexibilă. Sunt disponibile diverse dispozitive EEG pentru cercetare și



Figura 3.3: Dispozitiv Neuron Spectrum 65, sursă [65] (a), Complex QRS, adaptare după [66] (b).

aplicații clinice, precum Emotiv EPOC+ cu 14 canale și o rată de eșantionare de 2048 Hz, Muse cu șapte electrozi și funcții de filtrare, OpenBCI o platformă EEG programabilă și de costuri reduse, MindWave Mobile 2 pentru monitorizarea nivelului de atenție și relaxare, precum și sisteme EEG avansate de la g.tec, cum ar fi g.Nutilus.

Așadar, tehnologiile noninvazive, cum ar fi căștile EEG și interfețele creier-computer pot îmbunătăți semnificativ calitatea vieții persoanelor cu nevoi speciale. Aceste tehnologii avansate permit persoanelor să obțină autonomie, comunicare, mobilitate și să depășească limitări precum paralizia sau deficiențele motorii. De asemenea, ele promovează integrarea și incluziunea socială, contribuind la o societate mai incluzivă și mai pașnică.

3.2.2 Electrocardiografia

EKG-ul este un test noninvaziv care colectează activitatea electrică a inimii cu ajutorul unor electrozi pe piept și încheieturi. În unele cazuri, pentru a detecta evenimente rare sau neregulate în activitatea cardiacă există două opțiuni de monitorizare: **monitorizarea Holter** (24-48 de ore) și dispozitivele de **monitorizare a evenimentelor**. Figura 3.3b prezintă componentele principale ale unui semnal EKG: unda P (depolarizarea atrială), complexul QRS (depolarizarea ventriculară), și unda T (repolarizarea ventriculară). Componentele semnalului EKG sunt evaluate în ceea ce privește forma, amplitudinea și durata lor. Anomaliile în aceste caracteristici pot indica diferite afecțiuni cardiace.

3.2.2.1 Scopul și aplicațiile EKG în diagnosticul medical

Scopul principal al EKG constă în diagnosticarea diverselor afecțiuni cardiace, inclusiv aritmii, ischemie sau infarct miocardic și hipertrofie ventriculară [67, 68]. Aceasta se realizează prin identificarea anomaliilor în ritmul și activitatea electrică a inimii, ceea ce permite medicilor să detecteze și să evalueze aceste condiții și să stabilească planuri de tratament adecvate pentru pacienți.

3.2.2.2 Achiziționarea și prelucrarea semnalului EKG

Aceasta se realizează cu ajutorul unui aparat, care este format din mai multe componente principale: **electrozi, cabluri de conectare, amplificator și unitate de afișare** sau înregistrare. Electrozii sunt plasați pe pielea pacientului pentru a captura semnalele electrice generate de activitatea cardiacă. Un EKG cu 12 derivații utilizează 10 electrozi în locuri strategice pe picioare, umeri și piept pentru a crea o imagine completă a activității electrice a inimii din 12 unghiuri distincte. Semnalul EKG trebuie procesat pentru a elimina zgomotul și interferența, inclusiv filtrarea pentru frecvențe înalte și joase, iar apoi poate fi analizat pentru a identifica anomalii, ritmul cardiac sau alte informații.

3.2.2.3 Progrese tehnologice în EKG – dispozitive portabile și sisteme de monitorizare la distanță

Progresele tehnologice în acest domeniu au revoluționat colectarea și prelucrarea datelor EKG. Aceste dispozitive inteligente (ceasuri), oferă confort, accesibilitate monitorizare noninvazivă, în timp real. Cu toate acestea, aceste sisteme se află încă în stadii incipiente de dezvoltare și nu sunt încă valide d.p.d.v. medical. Așadar se poate discuta de o mai bună gestionare a sănătății cardiovasculare pentru persoanele cu nevoi speciale, inclusiv monitorizarea continuă, detectarea timpurie și terapia personalizată, îmbunătățind potențial sănătatea generală a acestora.

3.2.2.4 Resurse cu acces liber pentru semnale fiziologice

PhysioNet [69]¹ furnizează semnale fiziologice și date din seria temporală cercetătorilor din domeniul sănătății. De asemenea, oferă instrumente și tehnici software pentru prelucrarea și analiza datelor.

3.2.3 Considerații finale

În concluzie, tehnologia și IA au adus modificări semnificative în existența persoanelor cu cerințe speciale, furnizând posibilități de optimizare a comunicării, mobilității, autonomiei și îngrijirii medicale. Interfețele creier-computer sunt un domeniu emergent cu potențial promițător, care poate contribui la depășirea obstacolelor menționate anterior. Aceasta oferă oportunitatea de a controla dispozitivele în mod noninvaziv și de a detecta afecțiuni medicale. Prin utilizarea adecvată a acestor tehnologii, se pot deschide noi orizonturi pentru îmbunătățirea vieții persoanelor cu nevoi speciale dar și pentru facilitarea participării active a acestora în societate.

¹PhysioNet este o bază de date medicale disponibile în mod gratuit, gestionat de MIT Laboratory for Computational Physiology, disponibil la adresa <https://physionet.org/>.

Capitolul 4

Contribuții la aplicarea inteligenței artificiale pe dispozitive de putere redusă

Progresele semnificative în diverse industrii datorate soluțiilor de învățare automată se confruntă adesea cu costuri ridicate legate de dispozitivele de procesare precum plăcile grafice sau ASIC-urile [70]. O alternativă este rularea acestor soluții pe servere în *Cloud*, dar aceasta generează latență și dependență crescută de infrastructura de rețea, mai ales în zone cu conectivitate limitată sau inexistentă.

Aceste impedimente pot fi depășite și procesate, în mod eficient, mai aproape de sursă și anume la nivelul *edge* (la margine, de unde și denumirea de *edge computing*, EC) [71, 72, 73, 74] ceea ce este important pentru roboți asistenți și algoritmi de detectare a anomaliilor în semnalele vitale.

4.1 Dezvoltarea unui sistem de procesare eficientă a seriilor temporale utilizând tehnici de inteligență artificială și *edge computing*

În domeniul inteligenței artificiale, în special în domeniul medical, seriile temporale reprezintă un format predominant. Aceste serii constau dintr-o multitudine de observații rezultate din măsurători efectuate în perioade succesive de timp și găsesc aplicabilitatea nu numai în EKG și EEG, ci și în monitorizarea semnelor vitale (tensiunea arterială, nivelul de glucoză, frecvența respiratorie, etc). Acestea sunt esențiale și pentru îmbunătățirea vieții persoanelor cu nevoi speciale, monitorizând mișcările și semnele vitale, facilitând evaluarea medicală și detectarea problemelor.

Cu toate acestea, rularea acestor algoritmi IA eficient și economic este o provocare, deoarece aceștia necesită dispozitive costisitoare precum plăci grafice, servere la distanță sau controlere dedicate (*ASIC*-uri), implicând costuri suplimentare și consum crescut de energie. Astfel, există o tendință de migrare [75, 76, 77] de pe aceste dispozitive mari consumatoare de energie pe anumite dispozitive de putere redusă cât mai aproape de sursă (*edge computing*).

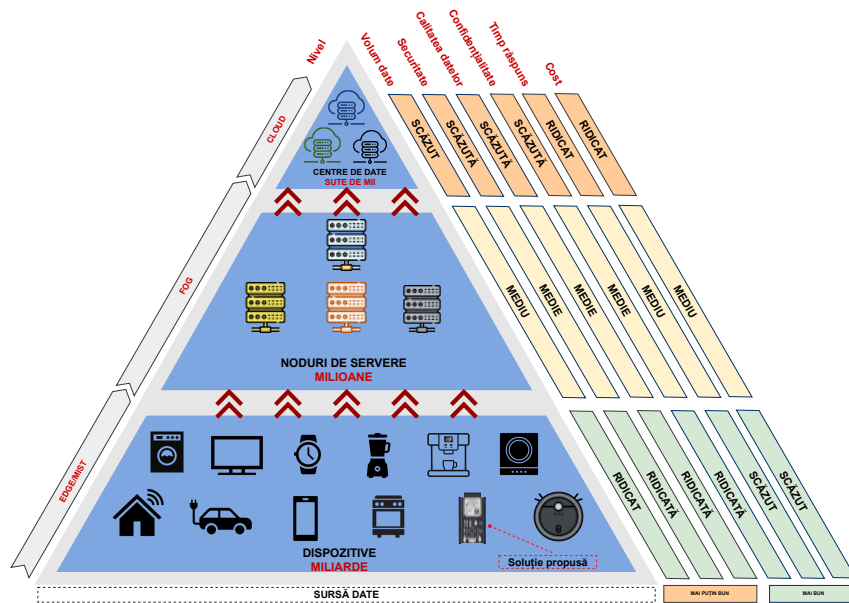


Figura 4.1: Arhitectura ierarhică a procesării datelor dispozitivelor inteligente (IoT) în *Cloud*, *fog* și *edge computing* dificultăți și limitări, adaptare și adăugare după sursa [78].

4.1.1 Prelucrarea și analiza descentralizată a datelor la marginea rețelei

Aceasta poartă numele de *edge computing*, oferind eficiență crescută și viteze mai rapide, contracarând dependența de infrastructura *Cloud* centralizată. Acest concept, s-a dezvoltat pentru a reduce costurile și pentru a permite analize în timp real, eliminând necesitatea conexiunii constante la internet pentru modelele de învățare automată voluminoase. Arhitecturi precum *fog* și *mist computing* (figura 4.1) au fost dezvoltate pentru a depăși limitările *Cloud*-ului, dar diferențele esențiale dintre ele le fac potrivite pentru contexte specifice, în funcție de nevoi și resurse disponibile.

Eurostat¹ [79] arată că în 2021, 41% din întreprinderile din UE au adoptat *Cloud Computing* (5% creștere față de 2020). În industrie, întreținerea predictivă este vitală pentru menținerea stării optime a echipamentelor, detectarea anticipată a defecțiunilor poate fi costisitoare și consumatoare de timp.

4.1.2 Îmbunătățirea calității vieții persoanelor cu nevoi speciale prin procesarea eficientă a serii temporale pe dispozitivele edge computing

Integrarea IA și EC pe dispozitive cu consum redus de energie îmbunătățește calitatea vieții persoanelor cu nevoi speciale, permițând prelucrarea eficientă a seriilor temporale, fiind un format de reprezentare a datelor des întâlnit.

Această abordare oferă beneficii semnificative, incluzând **crearea de soluții personalizate** pentru persoanele cu nevoi speciale, furnizarea de **asistență medicală permanentă** la costuri reduse, **extinderea accesibilității**, interpretarea datelor aproape sursă, și **autonomia sistemului**. Aceste aspecte contribuie la îmbunătățirea calității vieții și la asigurarea securității și confidențialității datelor.

¹Eurostat este biroul de statistică al Uniunii Europene, responsabil cu publicarea de statistici și indicatori de înaltă calitate la nivel european.

4.1.3 Implementarea unui sistem inteligent de detecție a anomaliilor din seriile temporale pe dispozitive de putere redusă

Seriile temporale reprezintă un format des utilizat în domeniul IA în sectorul medical și numai cu o provocare semnificativă de a migra soluțiile de pe infrastructuri extinse la dispozitive de consum redus. Astfel, deși această teză se concentrează pe îmbunătățirea vieții persoanele cu nevoi speciale, soluțiile EC bazate pe IA și procesarea eficientă a seriilor temporale, pot fi aplicate în mod universal. Aceleași tehnici care permit detectarea anomaliilor în seriile temporale din vibrațiilor rulmenților de motoare pot fi adaptate și pentru alte cazuri de utilizare pentru aplicații și senzori medicali prin valorificarea abilităților AI. Ca atare, este important să abordăm acest impediment în mod metodic și practic, pas cu pas, cu un scop clar: **demonstrarea capacității inteligenței artificiale de a procesa seriile temporale pe dispozitive cu consum redus de energie**, cum ar fi microcontrolerele, în cadrul *edge computing* cât mai aproape de sursa generatoare de date.




Figura 4.2: Arhitectura modelului rețelei neuronale artificiale propuse.

4.1.3.1 Prezentarea generală a abordării și proiectarea arhitecturii rețelei neuronale

Abordarea tradițională de a executa algoritmi de învățare automată pe servere ridică probleme legate de latență, confidențialitate, lățime de bandă și conectivitate la rețea (figura 4.1). Pentru a rezolva aceste limitări, partea de procesare trebuie mutată cât mai mult posibil către marginea infrastructurii, direct pe dispozitivele care achiziționează datele. Se propune o soluție eficientă pentru detectarea anomaliilor în seriile temporale, concentrându-se pe vibrațiile generate de motoare, cu un accent pe prelucrarea locală a datelor. Această soluție poate fi implementată pe microcontrolere fără a necesita infrastructură *Cloud* și este comparată cu alte abordări mai rapide care pun în pericol confidențialitatea și securitatea datelor. Detectarea anomaliilor în seriile temporale necesită definirea unui model de comportament normal și poate identifica devierile de la aceste tipare în datele monitorizate [80, 81].

Soluția propusă utilizează un Autoencoder, pentru detectarea anomaliilor în modelele de vibrații ale rulmenților motoarelor industriale folosind valorile mediane absolute (MAD) ale măsurătorilor de la

accelerometru. Pentru eficiență energetică algoritmul calculează constant, pe un ESP32, MAD și generează alerte pentru întreținerea predictivă și poate fi adaptat la alte aplicații cu serii temporale, cum ar fi bio-senzorii, având o importanță semnificativă în evaluarea și prevenirea defecțiunilor în echipamente. Pentru obținerea unui model precis, s-a aplicat filtrarea simplă trece-jos (FTI) pentru curățarea datelor. Modelul constă într-o rețea cu 5 straturi, inclusiv 3 straturi ascunse, având straturi de regularizare *dropout* pentru a evita supra-ajustarea. Plasat după primul strat ascuns, stratul de regularizare are o rată de *dropout* de 0,2. Se utilizează o dimensiune de intrare de 8 puncte de date, corespunzătoare celor 4 rulmenți măsurați pe 2 canale. Numărul de neuroni scade în straturile ascunse pentru a extrage informații esențiale și pentru eliminarea zgomotului. Procesul de codificare și decodificare este ilustrat în figura 4.2, iar funcția de activare ReLU este folosită în toate straturile ascunse [81].

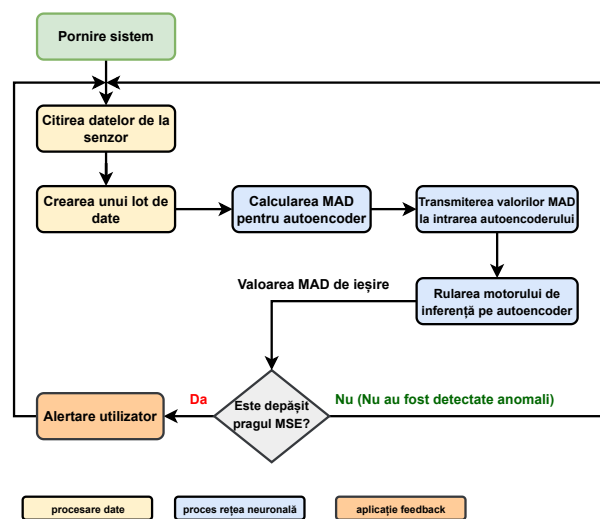
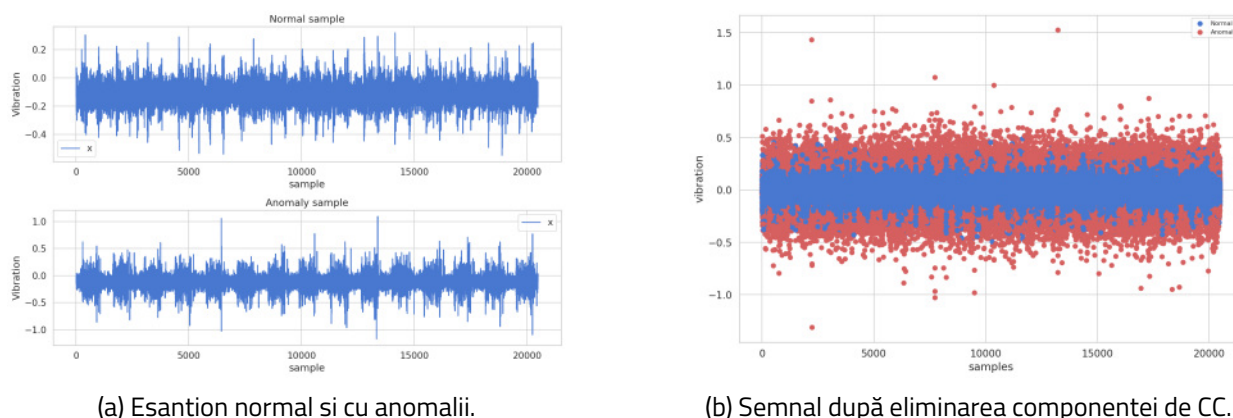


Figura 4.3: Diagrama fluxului de lucru a sistemului propus.

4.1.3.2 Prelucrarea prealabilă a datelor

În prima etapă a dezvoltării sistemului, s-a proiectat un model adecvat pentru analiza vibrațiilor, necesitând un set de date corespunzător și anume „Setul de date despre rulmenți NASA” [82] ce conține înregistrări de la rulmenții industriali care s-au defectat în timpul funcționării. Această abordare a fost aleasă datorită duratei semnificative necesare pentru ca astfel de echipamente industriale să sufere defecte [82]. Conform aceleiași surse, patru rulmenți au fost supuși unei sarcini radiale de aproximativ 2721 Kg la o viteză constantă de 2000 RPM. Setul de date constă din fișiere individuale, fiecare reprezentând o secundă de semnal de vibrație înregistrată la intervale specificate. Fiecare fișier conține 20480 de puncte și o rată de eșantionare de 20 kHz. Dezvoltarea unui model eficient necesită o cantitate semnificativă de date, care să includă atât comportamentul normal, cât și anomalii evidente (vezi figura 4.4a).

Pasul următor a constat în extragerea caracteristicilor și identificarea valorilor anormale. Deși datele brute pot fi suficiente pentru a dezvolta un model, este necesar să se determine caracteristicile specifice pe care rețeaua le va analiza. Pentru realizarea acestui obiectiv, componenta de CC a semnalului a



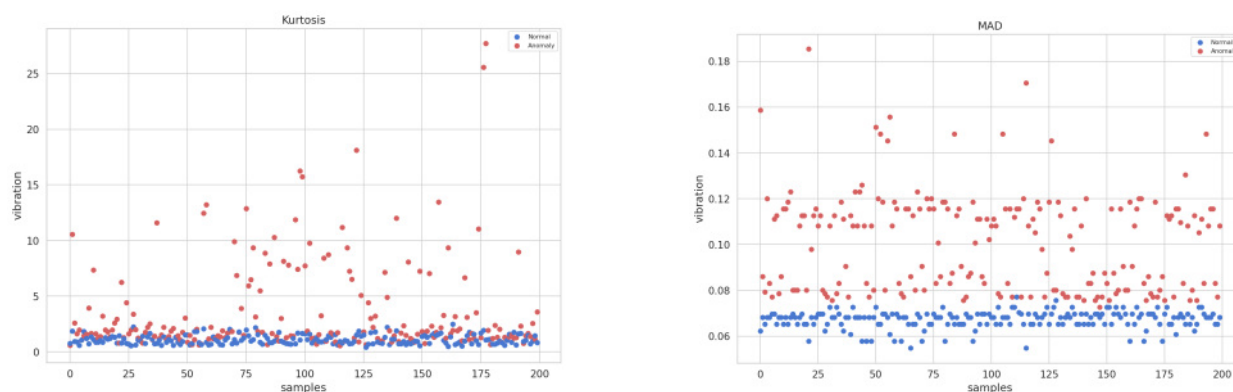
(a) Eșantion normal și cu anomalii.

(b) Semnal după eliminarea componentei de CC.

Figura 4.4: Vibrațiile din rulmenți observate în diverse situații sub forma seriilor temporale.

fost eliminată prin scăderea amplitudinii medii. Această metodă permite vizualizarea componentei de vibrație a semnalului și identificarea valorilor anormale, cum se poate observa în figura 4.4b.

Diferența semnificativă între proba de anomalie (roșu) și cea normală (albastru) este evidentă. Zona roșie este mult mai extinsă, în timp ce zona albastră este mai compactă. O analiză ulterioară a datelor relevă diferențe semnificative între cele două grupuri, evidențiate prin analiza varianței, asimetriei ($Skew^1$), Kurtosis², și deviația mediană absolută (MAD). Varianța este ilustrată în figura 4.5b și măsoară cât de departe sunt valorile individuale din setul de date față de media lor, facilitând separarea datelor. Boltirea ridicată într-un set de date indică prezența valorilor aberante și este folosit pentru a descrie valorile extreme în comparație cu o distribuție gaussiană, așa cum este ilustrat în figura 4.5a.

(a) Comparație între boltirea (*kurtosis*) unor eșantioane de vibrații normale și anormale.

(b) Comparație între componenta MAD a unui eșantion de vibrații normale și anormale.

Figura 4.5: Metode de înțelegere a datelor temporale rezultate din vibrațiile motorului.

Boltirea, evaluează gradul de concentrare și mai exact înălțimea „cocoșei” în comparație cu o distribuție normală. În contextul analizei datelor cu valori aberante sau non-normale, MAD este o măsură mai robustă [84], așa cum se poate observa în figura 4.5b. Aceasta facilitează separarea mai clară a datelor normale de cele cu anomalii, iar acest aspect a contribuit la alegerea sa în soluția propusă, așa cum se ilustrează în diagrama fluxului de lucru a sistemului din figura 4.3.

¹Skewness în statistică reprezintă gradul de asimetrie observat într-o distribuție de probabilitate.

²Kurtosis, indicele de aplatizare/boltirea („cocoșă”) se referă la înălțimea curbei, comparativ cu cea normală [83].

4.1.3.3 Instruirea modelului

Pentru antrenarea modelului, datele au fost împărțite în date de antrenare (~55% - 701 eșantioane), validare încrucișată *cross-validation* (~10% - 420 eșantioane) și seturi de testare (~35% - 280 eșantioane). Setul de antrenare se caracterizează prin faptul că conține exclusiv date ce nu conțin anomalii. Acest lucru se datorează faptului că *Autoencoder*-ul ar trebui să se antreneze să recunoască foarte bine funcționarea normală a unui motor, astfel încât tot ceea ce nu seamănă cu un comportament normal să fie clasificat drept anomalitate. În cadrul acestui experiment, datele anterioare defecțiunii rulmentului în motor sunt folosite ca set de date de antrenare. Setul de validare conține atât date normale, cât și date cu anomalii, și rețeaua este instruită pentru a le recunoaște cu precizie. Setul de testare conține date similare celor în timp real. Antrenamentul durează 50 de epoci (lotul este 55) folosind optimizatorul *Adam*, iar funcția de pierdere fiind MSE. Greutățile sunt generate aleatoriu la începutul antrenamentului.

Graficul pierderii în timpul antrenamentului, atât pentru setul de testare, cât și pentru cel de validare, arată că modelul converge în primele 15 epoci, menținând pierderile la valori mici în jurul lui 0,001 (figura 4.6a) iar histograma seturilor de antrenament, cu date normale comparate cu cele cu anomalii, ilustrează o clară separare a MSE a funcției de pierdere. Acest lucru confirmă eficacitatea metodei în detectarea anomaliilor.

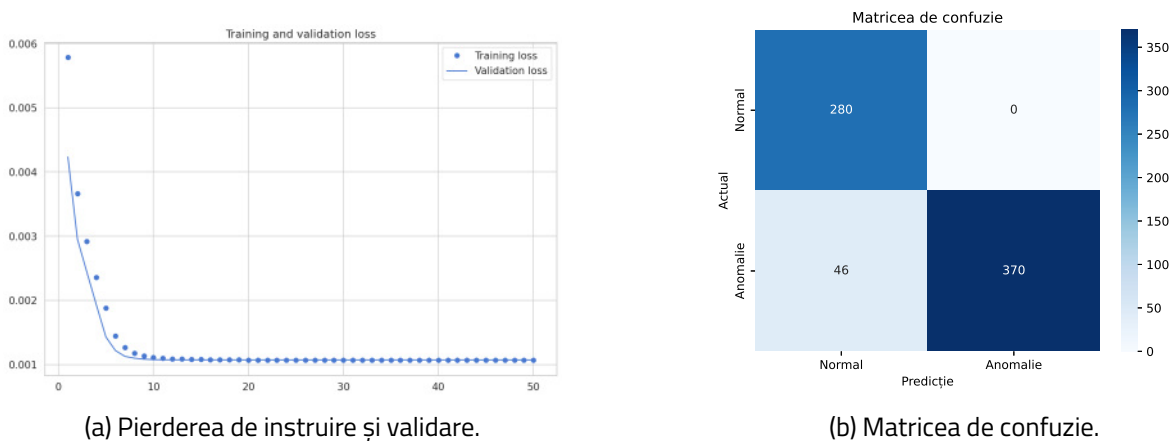


Figura 4.6: Comparații ale rezultatelor obținute în urma instruirii modelului rețelei neuronale.

Tabel 4.1: Comparație între testarea cu și fără inferență.

Testare	Eșantioane/fișier	Timp(μ s)	Anomalii	Eroare (%)
MAD	20000	2102	NU	6,57
MAD	20000	2153	DA	6,57
MSE + Inf.	20000	150	NU	6,57
MSE + Inf.	20000	45	DA	6,57

În această etapă, se construiește un clasificator cu două clase pentru a decide dacă datele analizate sunt normale sau anormale. Pragul de clasificare este setat la ultima valoare medie pătratică a erorii din setul de validare, care în acest caz este de $1,1001 \times 10^{-3}$. Matricea de confuzie (figura 4.6b) oferă indici de performanță a modelului cu o performanță înaltă, 280 de cazuri corect clasificate ca normal

și 370 ca anomalie. De asemenea, 46 de cazuri au fost clasificate incorect ca anomalie și 0 ca normal. Acuratețea modelului este calculată împărțind numărul total de cazuri clasificate corect la numărul total de cazuri. În acest caz, acuratețea modelului ajunge la o rată de clasificare de 85%.

În faza de testare, modelul implementat pe microcontrolerul ESP32 a obținut o performanță remarcabilă de 93,42% în detectarea datelor anormale, așa cum este prezentat în Tabelul 4.2. Pentru un eșantion de test normal folosit în calibrare, algoritmul a necesitat $6795\mu s$ pentru a calcula MAD, iar rezultatul inferenței pentru datele nevăzute anterior a fost finalizat în $161\mu s$.

Tabel 4.2: Rezultatele testării modelului implementat pe microcontrolerul ESP32.

Descriere	Valoare
Precizia modelului ESP32 în detectarea anomaliilor (validare)	93,42%
Timpul necesar pentru calculul MAD pe un eșantion normal	$6795\mu s$
Timpul de inferență pentru date nevăzute anterior	$161\mu s$
Timpul de execuție al inferenței și calculul MAD pe un eșantion de anomalie	$106\mu s$
Diferența dintre valorile prezise în faza de proiectare și rulare	$< 0,1$

Timpul de execuție al inferenței și cel pentru calcularea MAD pentru un eșantion de anomalie a fost de $106\mu s$. Comparând rezultatele obținute în mediul de testare, în faza de proiectare a modelului, cu cele obținute după rularea algoritmului pe datele de validare, s-a descoperit că eroarea dintre valorile prezise este mai mică de 0,1. Acest lucru indică faptul că algoritmul este sigur și fiabil pentru implementare în diverse scenarii.

4.1.4 Considerații finale

Așadar, proiectul a ajuns la o fază de operare sigură pentru detectarea anomaliilor, obținând performanțe ridicate ($\sim 93,42\%$) în faza de testare. Sistemul complet dezvoltat utilizează un *Autoencoder* pentru a calcula valorile MAD și le compară cu un prag pentru a alerta utilizatorul cu privire la eșantioanele anormale. Sistemul este versatil și adaptabil la diverse domenii în *edge computing*.

În domeniul IA, în special în domeniul persoanelor cu nevoi speciale, seriile temporale reprezintă un format des întâlnit în multe din aplicații. Aceleași tehnici care permit să detectăm anomalii în seriile temporale ale vibrațiilor rulmenților de motoare pot fi adaptate cu ușurință și pentru alte cazuri de utilizare pentru aplicații și senzori medicali prin valorificarea abilităților AI. Unul dintre cele mai mari impedimente este procesarea acestor serii temporale cu menținerea eficienței la un nivel ridicat și a costurilor la un nivel scăzut. Acești algoritmi inteligenți au la bază multitudinea datelor provenite de la anumite procese sau de la anumiți senzori și sunt proiectați să ia decizii complexe, asemenea inteligenței umane. Eficiența energetică a devenit un punct de interes și este necesară explorarea unor alternative. Aceste soluții vor fi rulate aproape de sursă (*edge computing*) pe dispozitive de putere redusă cu aplicații în robotică, dispozitive portabile medicale, îmbunătățirea procedurilor medicale actuale și crearea unor asistenți personalizați ce cu siguranță pot îmbunătăți viața anumitor categorii de persoane.

4.2 Dezvoltarea unui robot autonom cu funcții multiple pentru îmbunătățirea calității vieții persoanelor cu nevoi speciale

În ultimul timp, în domeniul roboticii și IA, s-au generat soluții inovatoare pentru persoanele cu cerințe specifice [85, 86, 87]. Se poate observa ca interesul crește pentru roboții autonomi multifuncționali, dezvoltați pentru a îmbunătăți calitatea vieții acestor persoane. Datorită îmbătrânirii populației, există o cerere crescută pentru servicii de sănătate la domiciliu, sugerând necesitatea dezvoltării roboților autonomi reprogramabili, capabili să ofere diverse servicii adaptate nevoilor actuale. Aceste sisteme robotice au potențialul de a îmbunătăți semnificativ viața celor cu dificultăți fizice, cognitive sau emoționale, oferindu-le autonomie, asistență și confort sporit.

4.2.1 Roboți de asistență

Aceștia constituie o categorie distinctă de roboți care au fost special concepuți pentru a oferi ajutor și consolidare celor care au dizabilități sau necesități unice.

În domeniul sistemelor robotice de asistență, se observă patru direcții principale, care includ înțelegerea mediului prin percepție senzorială, mobilitatea sistemelor și a persoanelor asistate, monitorizarea stării și sănătății persoanelor asistate, precum și comunicarea cu acestea și înțelegerea nevoilor lor. Aceste sisteme sunt dotate cu senzori avansați, inclusiv camere, LiDAR, senzori de distanță ultrasonici și senzori de temperatură, care permit roboților să obțină o înțelegere detaliată a mediului înconjurător. Aceasta facilitează o navigare și o interacțiune eficiente. Roboții de asistență utilizează diverse tehnologii, inclusiv exoschelete, scaune cu roțile și brațe robotice, pentru a oferi asistență celor care se confruntă cu limitări în ceea ce privește mișcarea, controlate prin diverse interfețe. În ceea ce privește starea de sănătate a persoanelor asistate, se pot implementa soluții care asigură curățenia, sterilizarea în cazul unor boli infecțioase și, în același timp, monitorizează starea pacientului de la distanță și pot comunica cu acesta. Prin aplicarea tehnologiilor de procesare a limbajului natural și de recunoaștere a vorbirii, se facilitează comunicarea și se creează oportunități pentru stabilirea unor legături sociale și relații de companie între indivizi și entitățile robotice, și nu numai.

4.2.2 Îmbunătățirea calității vieții persoanelor cu nevoi speciale prin utilizarea unui robot autonom cu funcții multiple

Soluțiile propuse în continuare servesc drept exemple pentru a evidenția multifuncționalitatea sistemelor robotice autonome de asistență. Prin utilizarea IA și a dispozitivelor cu consum redus de energie, acești roboți au capacitatea de a fi adaptați pentru a răspunde la o gamă variată de cerințe oferind un sprijin semnificativ prin diverse aplicații persoanelor cu nevoi speciale după cum urmează:

- ▣ **Asistenți personali** pentru a oferi persoanelor cu nevoi specifice asistență personalizată zilnică reducând astfel nevoia de personal medical și costurile asociate îngrijirii acestora;

- ▣ **Monitorizarea** spațiului de interes permițând robotului să supravegheze și să măsoare factori de mediu precum temperatură, umiditate și calitatea aerului, identificând potențiale riscuri precum scurgerile de gaze sau incendiile sau chiar în cazul unor boli contagioase (fără contact direct);
- ▣ **Livrare și logistică** pentru transportul sigur și eficient al consumabilelor medicale, medicamentelor sau a alimentelor în unități de sănătate;
- ▣ **Apartenența socială** poate fi facilitată prin utilizarea roboților pentru persoanele în vârstă, cu dizabilități, sau pentru cele care locuiesc în centre de îngrijire;
- ▣ **Educație** ce poate aduce beneficii elevilor cu dificultăți de învățare sau celor care necesită asistență suplimentară, facilitându-le participarea la sesiuni interactive de instruire;
- ▣ **Mijlocul de locomoție virtual** ar permite persoanelor cu probleme de mișcare, cum ar fi paralizia sau alte deficiențe, să rămână conectate la lumea exterioară.

4.2.3 Implementarea unui robot autonom pe dispozitive de consum redus pentru a răspunde nevoilor anumitor categorii vulnerabile

Importanța sistemelor autonome de asistență în medicină este evidențiată de creșterea incidenței bolilor infecțioase, inclusiv virusul SARS-CoV-2, și de limitările metodelor convenționale de sterilizare. Persoanele cu vârsta înaintată, în special, necesită soluții de sterilizare adaptate [88]. Studii arată că 20-30% dintre pacienții din unitățile de îngrijire intensivă dezvoltă infecții nosocomiale HAI (eng. *Healthcare Associated Infections*¹) [88, 89, 90], subliniind necesitatea de a aborda această problemă.

În cadrul acestei secțiuni, punctul de interes îl constituie implementarea unui serviciu al unui robot de asistență „RoboCoV Cleaner” și mai exact obținerea unui mediu sigur prin reducerea anumitor patogeni, de exemplu a virusilor (SARS-CoV-2) și a altor microorganisme de pe suprafețe care pot pune viața în pericol anumitor persoane contribuind astfel la o viață sănătoasă și normală. Acest robot mobil autonom (AMR) este echipat în principal cu cinci lămpi UV-C de 18W în combinație cu un sistem de control. Robotul este autonom și poate funcționa fără intervenția umană, dar poate fi, de asemenea, controlat de la distanță printr-o aplicație web dezvoltată în Python cu ajutorul cadru de dezvoltare Flask¹. Acest sistem are potențialul de a neutraliza bacterii și viruși în spații închise, îmbunătățind siguranța și protejând personalul din universități, centre de îngrijire și spitale. Robotul este versatil, putând fi adaptat cu ușurință pentru a sprijini diverse nevoi, de exemplu, asistență pentru persoane cu diferite cerințe, așa cum este prezentat în secțiunea 4.2.2.

4.2.3.1 Utilitatea folosirii unui robot de asistență în procesul de sterilizare

Situația pandemică precedentă cu răspândirea rapidă a virusului SARS-CoV-2 a subliniat importanța unei sterilizări eficiente pentru a preveni transmiterea bolilor, deoarece purtarea măștilor nu este sufi-

¹În traducere „infecții asociate asistenței medicale”.

¹Flask este un instrument web ușor și minimalist în Python, utilizat pentru crearea de aplicații web.

cientă pentru a proteja împotriva contaminării suprafețelor [91, 92]. Sterilizarea are ca obiectiv eliminarea microorganismelor de pe suprafețe pentru a preveni răspândirea agenților patogeni și a infecțiilor prin contact direct sau aerian. Lumina ultravioletă de tip C (UV-C) cu o lungime de undă între 200–280 nm s-a dovedit eficientă în distrugerea microorganismelor, inclusiv virusul SARS-CoV-2, și poate ajuta la prevenirea infecțiilor în locuri greu accesibile, cum ar fi spitalele [93].

În acest sens, propunerea de a utiliza un robot autonom pentru sterilizarea încăperilor folosind lămpi UV-C are avantaje multiple: elimină intervenția umană, evită substanțele chimice toxice, și are potențialul de a servi și alte scopuri, precum asistența medicală sau reprogramarea simplă.

Caracteristicile roboților de sterilizare existenți și potențiale direcții de dezvoltare

Progresele recente în tehnologie au permis dezvoltarea de sisteme robotice de sterilizare avansate care utilizează lumina UV-C pentru a elimina agenții patogeni, necesitând o evaluare a potențialului lor în diverse domenii (avantajele, dezavantajele și direcțiile de dezvoltare posibile).

Dispozitivele comerciale au costuri substanțiale (media 50 000\$) și o gamă largă de opțiuni de deplasare, care variază de la baze mobile [94, 95, 96] (deplasa în orice direcție pe podea), concentrând lumina oriunde este necesar, până la platforme staționare (sursa de lumină orientată vertical sau orizontal) așa cum sunt sistemele [97, 98, 99]. În domeniul acestor roboți, detecția prezenței umane a fost abordată diferit, cu unele sisteme având mecanisme de detectare iar altele rămânând limitate sau chiar absente. Aceste sisteme nu detectează obiecte în timp real și limitează componentele la o anumită generație ce poate împiedica viitoarele îmbunătățiri. Dintre acești roboți nu toți dispun de un mod de economisire a energiei și își procesează datele pe sisteme *Cloud*, pierzând din beneficiile procesării locale. În urma analizei literaturii științifice apare o tendință de inovație cu integrarea brațelor robotice cu diferite grade de libertate [100], dar și alte categorii de baze mobile [101, 102]. Nici acestea nu dispun de o metodă robustă de detectare a prezenței umane, ceea ce creează o vulnerabilitate în cazul unei comunicări eronate între subsisteme. Această omisiune a redundanței, un principiu fundamental de siguranță, necesită o evaluare amănunțită a rezilienței sistemului și a riscurilor asociate.

Așadar, aspecte care erau cândva limitate la domeniul comercial au devenit acum principii fundamentale în cercetarea academică. Conceptele de transmisiuni video în timp real dar și autonomia sporită ce au căpătat importanță în mediul comercial, continuă să fie subiecte de interes și în mediul academic. Cu toate acestea, aproape inexistent este domeniul de recunoașterea a obiectelor în fluxurile video, înțelegerea scenei și pe generarea de rapoarte la fel ca la sistemele comerciale. Mai mult de atât abordarea separării logicii dintre modulele de senzori și actuatori și logica de bază a robotului, economisirea energiei, procesarea locală lângă sursa generatoare, reprezintă alte îmbunătățiri ce pot fi aduse acestor sisteme.

Conform [103, 93, 104, 105], lumina UV-C distruge ADN-ul bacteriilor și virușilor. Zona UV este împărțită în trei secțiuni: UV-A (320–400 nm), UV-B (280–320 nm) și UV-C (200–280 nm) și se împarte în două categorii: ne-ionizantă (380–121,6 nm) și ionizantă (sub 121,6 nm). În momentul actual există trei tipuri de lămpi UV utilizate în scopuri germicide: lămpi cu mercur cu presiune joasă (LPM), lămpi

cu bliț cu xenon pulsant (PXF) și lămpile Far-UV-C. **Doza necesară pentru a inactiva un organism** poate

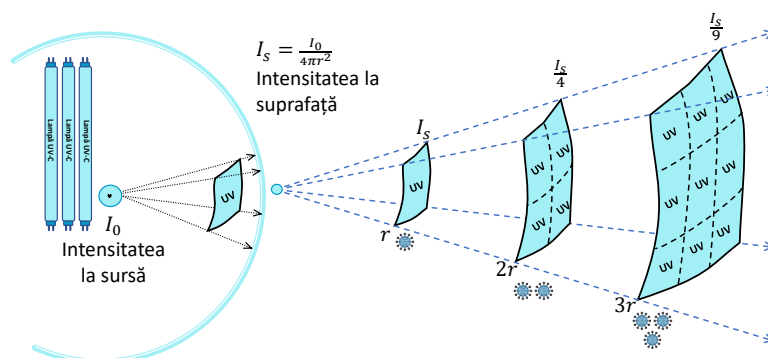


Figura 4.7: Legea pătratului invers de la un punct de sursă. I_s este intensitatea la suprafață și I_0 este intensitatea sursei în wați, iar r raza sferei, adaptare după sursa [106].

fi considerată ca nivelul de lumină UV pe care îl primește un organism. Aceasta se măsoară în miliJouli pe centimetru pătrat (mJ/cm^2). Aceasta poate fi determinată prin înmulțirea puterii de iradiere cu timpul de expunere (formula de dozare 4.1). Potrivit [107], corona-virusurile vor fi inactivate de lumina UV fără a schimba tehnologia acestui tip de lumini de sterilizare. Valoarea realistă este probabil doar $3,7mJ/cm^2$ (media) conform [107, 108, 109, 110, 111].

$$Dozaj(mJ/cm^2) = Iradiere(mW/cm^2) * Durata(sec) \quad (4.1)$$

Iradieră se măsoară în wați pe metru pătrat (W/m^2 sau miliwați pe centimetru pătrat (mW/cm^2) și variază în funcție de puterea lămpii, configurația robotului și distanța până la suprafața de dezinfectat, respectând legea inversului pătratului, așa cum se ilustrează în figura 4.7.

4.2.3.2 Implementare software a sistemului robotic

Acest robot reprezintă un sistem complex și complet. Implementarea acestuia a necesitat cunoștințe din domeniul mecanicii, electronicii, automaticii și dezvoltării software (utilizate pentru procesarea imaginilor, utilizarea sistemelor de operare în timp real și îmbinarea acestora cu diferite limbaje de programare) ce reprezintă în esență un sistem mecatronic. Utilizarea acestui tip de robot de sterilizare cu lumină UV-C oferă avantaje semnificative, fiind capabil să sterilizeze rapid diverse încăperi, inclusiv săli de clasă, laboratoare, băi și holuri, fiind eficient pe distanțe variate, și nu necesită consumabile, funcționând pe o durată extinsă (8000 de ore - perioada de funcționare a lămpilor UV). Poate fi controlat și de la distanță folosind o aplicație web, singurele implicații fiind o conexiune la internet și un browser. Aplicația permite pornirea, oprirea și controlul deplasării robotului atât în interior, cât și în exteriorul camerei, iar camera atașată asigură monitorizarea activității chiar și în întuneric, datorită unui filtru IR. De asemenea, display-ul robotului oferă informații utile, cum ar fi starea bateriei și mesaje de urgență.

Din punct de vedere conceptual, acest robot este alcătuit din două module separate, atât în ceea ce privește componentele hardware, cât și software-ul asociat. Datorită complexității hardware-ului, care



Figura 4.8: Robotul pe holul Corpului V, al Universității Transilvania din Brașov.

implică o multitudine de senzori și componente (figura 4.9), designul software-ului este, de asemenea, elaborat, fiind nevoie de două sisteme diferite cu arhitecturi și tehnologii distincte.

Modulul de control este denumit Unitatea Centrală de Control (UCC) și rulează Linux (Raspberry Pi 4 8GB) care poate fi văzut creierul acestui sistem. Acesta comandă unitatea secundară, denumită și Unitatea Secundară de Senzori și Actuatore (USSA) ce rulează FreeRTOS.

USSA este un modul software și hardware care a fost special conceput pentru a abstractiza nivelul de hardware. Acesta are și scopul de a gestiona prelucrarea datelor senzorilor, pentru a controla eventualele actuatore din sistem și pentru a facilita comunicarea cu UCC. Sistemul a fost construit utilizând un microcontroler Atmel Atmega2560 ¹, cu o frecvență de funcționare de 16Mhz, care a fost selectat pe baza specificațiilor sale și a disponibilității extinse de pini pe care o oferă (100 pini). Rata de actualizare a USSA poate fi configurată individual pentru fiecare driver și din experimente s-a constatat că cea mai eficientă rată, atât din punct de vedere computațional cât și pentru valorile prelevate, este de 10 milisecunde pe ciclu de eșantionare. Pentru a utiliza resursele într-un mod cât mai eficient și pentru a optimiza capacitatea de reacție a sistemului s-a ales folosirea unui sistem de operare în timp real, FreeRTOS ce oferă capabilități de multitasking. Pentru dezvoltarea software ca și mediu de dezvoltare a fost utilizat Atmel Studio 7 împreună cu o placă de depanare special creată ce facilitează identificarea și rezolvarea eficientă a problemelor întâlnite în timpul procesului de dezvoltare, sporind astfel eficiența activităților de depanare în timpul dezvoltării software folosind debuggerul Atmel Ice.

¹Atmel Atmega2560 este un microcontroler pe 8biți, cu arhitectură RISC, dezvoltat de către compania Microchip Technology (fosta Atmel Corporation)

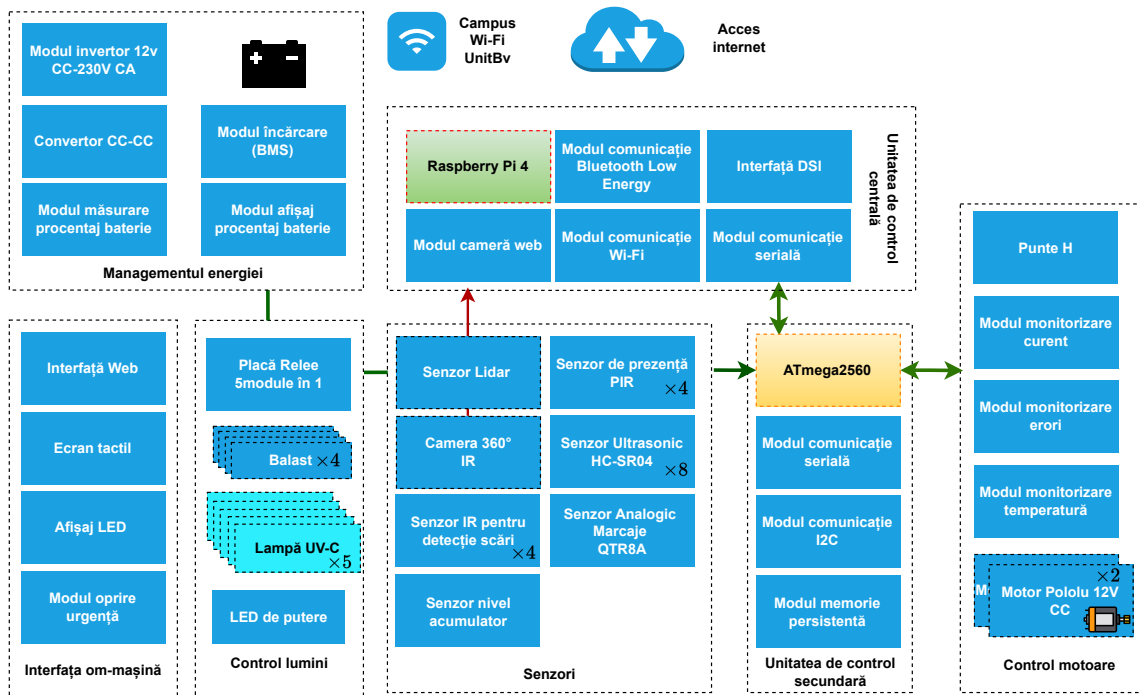


Figura 4.9: Diagrama bloc a sistemului.

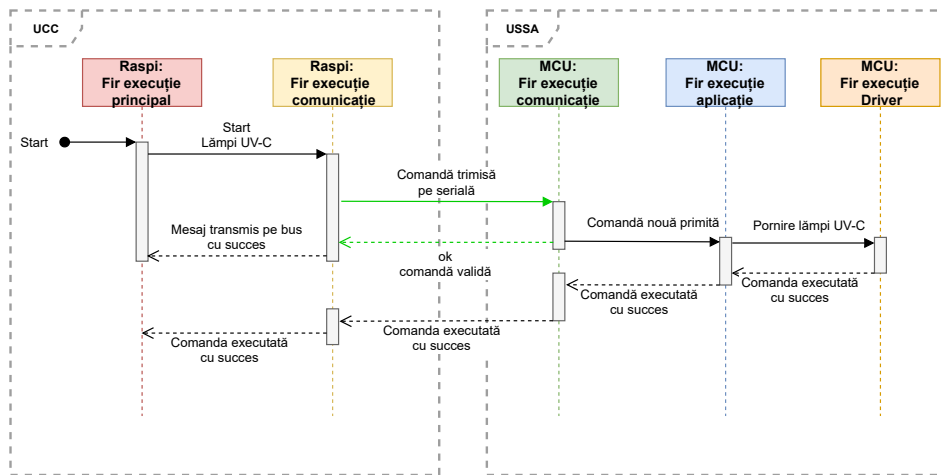


Figura 4.10: Diagrama de secvență între cele două unități logice UCC și USSA.

Pentru a facilita implementarea de noi servicii acestui robot, s-a ales ca UCC să folosească un limbaj de programare cât mai apropiat de cel uman și anume Python, care controlează în mod generic actuatorii și achiziționează datele de la senzori fără a avea nevoie de specificațiile tehnice ale fiecărui driver fizic în parte. UCC va controla placa USSA prin interfața serială. Acesta metodă este similară cu cea a modelului *Leader-Follower*¹ unde *Leader* (sau conducător) este UCC. Mai mult decât atât, UCC este capabilă să susțină sistemul de procesare a imaginilor, drept urmare detecția oamenilor este efectuată pe această unitate. În atribuțiile acesteia intră și alte sarcini precum serverul web sau procesarea datelor

¹Modelul Leader-Follower este nouă adaptare după conceptul consacrat, Master-Slave.

de la senzorul LiDAR, verificarea conexiunii la internet dar și rularea logicii sistemului.

Arhitectura software ce rulează pe Unitatea Secundară de Senzori și Actuatore încorporează mai multe fire de execuție distincte pentru o mai bună segregare a sarcinilor. Firele de execuție atât pentru acshortucc cât și USSA sunt prezentate și în figura 4.10. Pe USSA **firul de execuție de comunicare** menține sincronizarea datelor între USSA și UCC iar **firul de execuție al aplicației** conține logica și procesul decizional al sistemului doar în situații de urgență, asigurând oprirea rapidă a sistemului în lipsa unui răspuns din partea unității centrale. **Firul de execuție al driverelor** achiziționează datele și controlează senzorii și actuatorele, asigurând o actualizare rapidă a datelor (10 ms) și executarea promptă a acțiunilor. Unitatea Centrală de Comandă rulează pe Raspbian OS și are diverse fire de execuție precum UCC diferența este că pe aceasta există mai multe resurse și se pot rula alte programe în paralel cum ar fi programul pentru aplicația web, programul de interfață grafică afișat pe display și programul principal (comunicarea între UCC și USSA). Sistemul transmite instrucțiuni către dispozitiv, cum ar fi mișcarea motoarelor, fără a fi necesară cunoașterea specificațiilor individuale ale fiecărei componente.

4.2.3.3 Implementarea sistemului avansat pentru detecția umană

Utilizarea lămpilor UV în prezența oamenilor nu este sigură, așadar este importantă detectarea oamenilor sau animalelor. Primul sistem, bazat pe senzorii PIR funcționează independent pe USSA și oprește lămpile UV-C în caz de detectare a prezenței umane. Al doilea sistem, prezent UCC, utilizează o cameră 360° pentru detectarea umană și citirea codurilor QR pentru gestionarea procesului de sterilizare.

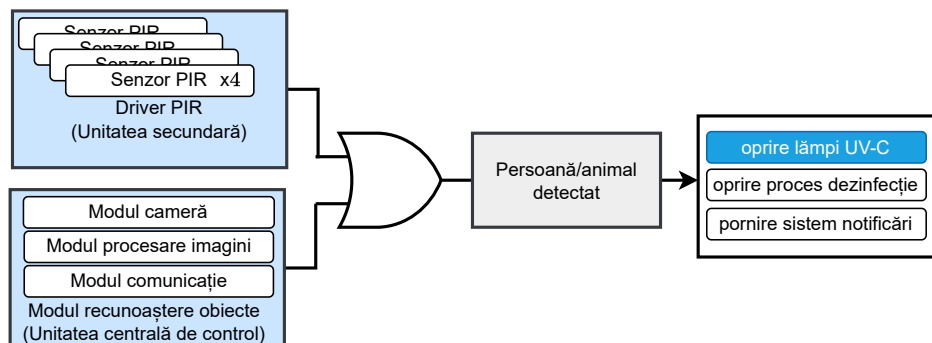


Figura 4.11: Diagrama bloc simplificată a modului de detecție oameni și animale.

Prin combinarea algoritmului YOLO [112, 113] cu algoritmul HAAR[114, 115, 116], se realizează detectarea persoanelor sau obiectelor de interes, cu oprirea lămpilor în caz de detectare de persoane. După un interval predefinit, se reexaminează prezența persoanelor și se reia procesul de sterilizare în lipsa acestora. Algoritmul HAAR este o tehnică de detectare de obiecte în învățarea automată, potrivită pentru sarcini precum detectarea fețelor. Acești algoritmi pot fi schimbați cu ușurință, cu condiția ca puterea de procesare să fie adecvată pentru detectarea obiectelor.



Figura 4.12: Sistemul de detecție în diferite condiții de iluminare în spectrul luminii vizibile.



Figura 4.13: Sistemul de detecție în condiții speciale.

4.2.3.4 Utilizarea marcajelor pentru definirea regulilor specifice

Eficacitatea sistemului este îmbunătățită prin scanarea codurilor QR plasate de-a lungul holurilor pe uși (figura 4.14) de unde pot fi colectate informații semnificative despre procesul curent. Acestea

transmit date importante, inclusiv probabilitatea de infectare a camerei și protocoalele de sterilizare iar programarea în Python permite modificarea ușoară a regulilor și o navigare îmbunătățită. Aceste marcaje sporesc, de asemenea, flexibilitatea, acuratețea și multifuncționalitatea sistemului, asigurând un sistem fiabil și eficient.



(a) Marcaje plasate pe podea și cod QR plasat pe ușă. Codurile QR conțin regulile sălii respective cu privire la procesul de sterilizare.



(b) RoboCoV Cleaner folosind marcaje pentru sterilizarea holului Universității Transilvania din Brașov, 2021.



(c) Marcajele plasate pe podea pot avea trasee diferite, iar algoritmul de detectare a obiectelor poate fi folosit pentru a înțelege traseul.



(d) RoboCoV Cleaner folosind marcaje plasate pe podea și cod QR plasat pe ușă pentru a lua decizia la o intersecție a marcajelor.

Figura 4.14: RoboCoV Cleaner și modul autonom de sterilizare folosind marcaje.

4.2.3.5 Informații despre recunoașterea obiectelor și locației




Figura 4.15: Detectarea obiectelor într-o cameră în timpul sterilizării cu lumină UV.

De asemenea, sistemul dispune de funcționalități care se extind dincolo de detectarea umană, așa cum este ilustrat în figura 4.15. Sistemul are capacitatea de a furniza date statistice, îmbunătățindu-și astfel performanța cu un nivel suplimentar de înțelegere analitică asupra obiectelor din jur. Acest lucru poate fi folosit pentru a înțelege mai bine câte obiecte există în câmpul lui vizual și de ce fel sunt, și dacă lumina UV le va afecta pe termen lung.

În cadrul analizei experimentale, s-a stabilit distanța și durata optimă de sterilizare pentru un robot, care ar trebui să fie cuprinsă între 2 și 2,5 metri, în timp ce durata optimă ar trebui să fie de 10 secunde pentru a acoperi eficient o anumită suprafață, menținând simultan o durată extinsă de viață a bateriei pentru robot.

4.2.3.6 Proiectarea electrică și mecanică

Proiectarea electrică s-a concentrat pe simplificarea sistemului pentru a reduce costurile, cu prioritatea siguranței utilizatorului la tensiuni de 220V sau radiația UV-C. Robotul include 5 lămpi Philips UV-C de 18W (figura 4.9), un invertor 220V, un acumulator de 12V pentru până la 4 ore de funcționare, precum și senzori precum PIR pentru detectarea persoanelor și RPLidar A1 pentru maparea mediului înconjurător folosit pentru planificarea și optimizarea procesului de dezinfectare în funcție de suprafața camerei.

Senzorii infraroșu sunt folosiți pentru detectarea scărilor și golurilor în scopul opririi de urgență. Pentru detectarea obstacolelor și protejarea lămpilor UV-C, robotul utilizează 8 senzori ultrasonici, în special pentru obiecte precum birourile sau scaunele. Acest robot este echipat cu două motoare puternice de 12V și o punte H de la Pololu¹, controlate de un microcontroler Atmega2560. Releele controlează lămpile UV-C, iar LED-ul de 5W îmbunătățește vizibilitatea la distanțe mari, dar scade autonomia

¹Pololu este un producător de electronice Pololu fondată în anul 2000 de trei studenți de la Massachusetts Institute of Technology.

bateriei, cu un efect pozitiv asupra detectării umane.

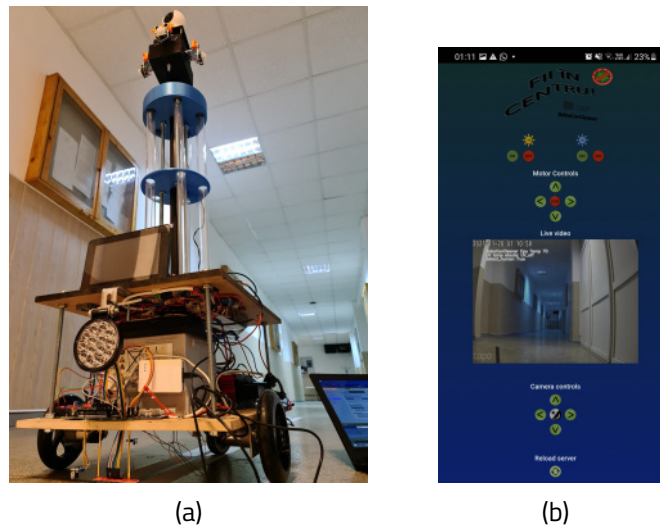


Figura 4.16: Robotul RoboCoV Cleaner asamblat (a) și interfața sa web (b).

Baza robotului a fost construită din placaj, întărită cu două suporturi "L" pentru motoarele de curent continuu. S-au folosit șuruburi M10 (30 cm) pentru o fundație solidă, iar lămpile UV-C au fost fixate pe suporturile imprimate 3D cu o țevă de aluminiu atașată la baza robotului pentru a menține centrul de greutate scăzut.

Sistemul are două moduri de funcționare: autonom (cu reguli prestabilite) și manual (prin intermediul unei interfețe web, figura 4.16b). Prin aplicație, utilizatorul poate monitoriza mediul în timp real, controla camera și mișcarea robotului, precum și lămpile UV și LED. Modulul manual poate fi activat în cazuri de urgență sau pentru accesul în zone neobișnuite, oferind control complet și siguranță.

4.2.4 Considerații finale

În această secțiune au fost prezentate sistemele robotice autonome de asistență pentru persoanele cu nevoi speciale, precum și obstacolele actuale și direcțiile viitoare pentru îmbunătățirea calității vieții acestor categorii de oameni. Prin adresarea problematicilor „Monitorizarea stării și sănătății persoanelor asistate”, „Mobilitatea acestor sisteme și a persoanelor asistate” și „Înțelegerea mediului cu ajutorul percepției senzoriale” prezentate la începutul acestei secțiuni a rezultat implementarea unui serviciu în forma unui robot autonom multifuncțional de asistență, având ca scop asigurarea unui mediu mai sigur pentru categoriile vulnerabile predispuse la diverse amenințări.

Sistemul robotic, bazat pe IA, detectează oameni, animale și obiecte și poate fi personalizat pentru diverse servicii, cum ar fi asistență medicală sau locomoție virtuală. Acesta are potențialul de a îmbunătăți calitatea vieții pentru categoriile vulnerabile și de a sprijini îngrijitorii și personalul medical, reducând suprasolicitarea acestora.

Capitolul 5

Contribuții la aplicarea inteligenței artificiale în sprijinul persoanelor cu nevoi speciale

Inteligența artificială a apărut ca o tehnologie care se dezvoltă rapid și revoluționează diverse aspecte ale vieții umane.

Sprijinirea persoanelor cu nevoi speciale este un domeniu în care IA are un impact tot mai semnificativ. De exemplu, acesta se poate aplica persoanelor în vârstă dar și celor afectați de afecțiuni precum paralizile sau problemele neurologice motorii, cum ar fi scleroza laterală amiotrofică¹ care poate provoca pierderea controlului muscular.

Sistemele bazate pe IA pot îmbunătăți calitatea vieții și accesibilitatea persoanelor sănătoase dar și celor cu nevoi speciale, însă se confruntă cu diferite obstacole. Acest capitol explorează aplicațiile IA în susținerea persoanelor cu nevoi speciale.

5.1 Aplicațiile inteligenței artificiale pentru detectarea și clasificarea aritmiei cardiace

Boala cardiacă ischemică și accidentul vascular cerebral sunt printre cele mai comune cauze de deces la nivel global. Monitorizarea activității cardiace, în special cu ajutorul EKG-ului, joacă un rol crucial în prevenirea și tratamentul acestor afecțiuni. Electrocardiograma înregistrează activitatea electrică a inimii și, ajută la detectarea anomaliilor și la diagnosticarea și gestionarea bolilor cardiace.

Astăzi, EKG-urile interpretate de mașini, utilizate pe scară largă în dispozitivele medicale, au constrângerii în ceea ce privește predicția diagnosticelor și necesită adesea interpretare umană. Utilizarea algoritmilor de învățare automată pentru evaluări precise și complet automate ale EKG-urilor ar putea îmbunătăți semnificativ precizia și eficiența diagnosticării, în special în contextul dispozitivelor porta-

¹Scleroza laterală amiotrofică fiind o boală de care suferea fizicianul Stephen Hawking.

bile [117]. Adnotările realizate de cardiologi certificați și disponibilitatea bazelor de date pe PhysioNet oferă sistemului robustețe în detectarea tulburărilor specifice aritmiei în electrocardiograme. Cu volumul crescut de date EKG colectate zilnic, metodele bazate pe învățare automată devin din ce în ce mai esențiale pentru monitorizare și interpretare.

În ultimii ani învățarea profundă a generat o schimbare fundamentală atât în industrie cât și mediul academic, asistența medicală fiind unul dintre cele mai influențate domenii. O strategie avansată de învățare profundă este propusă în cadrul acestei abordări pentru identificarea aritmiilor din EKG folosind diferite metode: semnale brute de imagini EKG cu o singură dimensiune și Transformata Wavelet.

5.1.1 Obstacole întâlnite în procesul electrocardiografiei

Utilizarea tot mai extinsă a electrocardiografiei în practica medicală aduce cu sine diverse obstacole care afectează educația, aspectele financiare, securitatea datelor și expertiza tehnică, punând presiune asupra specialiștilor din domeniul medical. Principalele obstacole în educația și interpretarea EKG conform [118] sunt:

- ▣ absență educație formală disponibilă pentru EKG;
- ▣ dificultatea în dezvoltarea unui curriculum EKG cuprinzător;
- ▣ dificultăți în adaptarea programelor de pregătire a rezidenților pentru interpretarea EKG;
- ▣ încrederea excesivă în interpretarea computerizată a EKG;
- ▣ inexactitățile și limitările asociate cu software-ul de interpretare computerizată a EKG-urilor;

Pe lângă acestea, mai pot fi adăugate:

- ▣ **zgomotul și artefactele** care afectează calitatea semnalului;
- ▣ **variabilitatea formelor de undă EKG** ce poate fi influențată de factori precum vârsta, sexul și afecțiunile cardiace ale pacientului;
- ▣ **specificitate limitată** în diagnosticarea anumitor afecțiuni cardiace;
- ▣ **complexitatea aritmiilor** crește semnificativ interpretarea electrocardiogramei;
- ▣ **monitorizarea și interpretarea la distanță a datelor EKG** din cauza problemelor legate de securitatea și confidențialitatea informațiilor pacienților.

5.1.2 Colectarea și preprocesarea datelor

Datele, utilizate au fost adnotate de cardiologi certificați și provin din baza de date PhysioNet și includ înregistrări EKG achiziționate între 1975 și 1979 de la Laboratorul de aritmie al Spitalului Beth

Israel. Această bază de date conține 48 de înregistrări EKG (aproximativ 30 minute) cu două canale de la 47 de subiecți cu vârste cuprinse între 23 și 89 de ani, incluzând bărbați și femei.

Bazele de date utilizate din PhysioNet includ baza de date de aritmie supraventriculară MIT-BIH, baza de date al Institutului de Tehnică Cardiologică din Sankt Petersburg și baza de date cu moartea cardiacă bruscă.

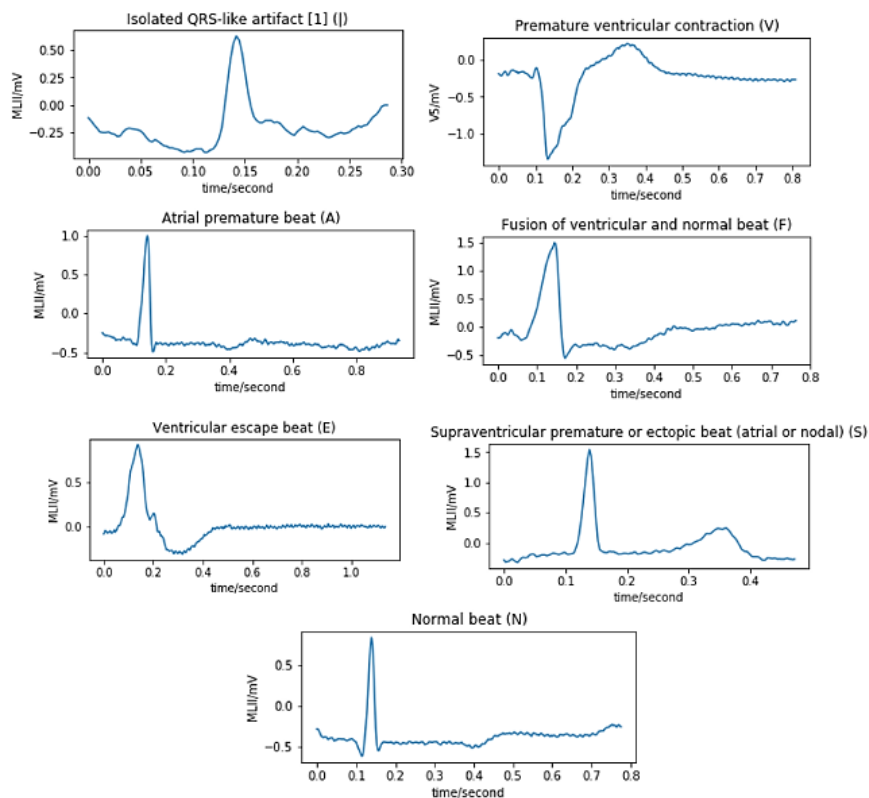


Figura 5.1: Semnale EKG brute trasate, 7 clase.

Pentru cercetarea inițială, o rețea neuronală profundă a fost instruită să detecteze șapte tipuri de aritmii din semnalele EKG. Aceste tipuri de aritmii sunt: bătăi normale („N”), premature atriale („A”), fuziunea bătăii ventriculare și normale („F”), artefact izolat asemănător QRS („I”), contracție ventriculară prematură („V”), bătăi de evacuare ventriculară („E”) și premature sau ectopice (atriale sau nodale) („S”). În procesul de formare a rețelei, un script Python a fost folosit pentru a salva eșantioanele ca imagini .PNG.

Cadrul ferestrei, având aproximativ o secundă lungime (variabilă în funcție de adnotarea vârfului R), a fost folosit pentru detectarea secțiunii relevante a semnalelor, bazată pe vârful R. Asta implică faptul că fiecare fereastră de semnal conține un singur vârf R, iar ciclul cardiac a fost identificat prin extragerea semnalului din 150 de milisecunde înainte de vârful R curent până la 150 de milisecunde înainte de următorul vârf R.

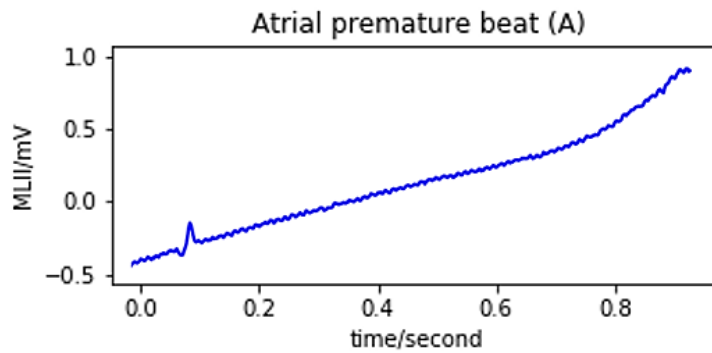


Figura 5.2: Bătăie zgomotoasă prematură atrială.

5.1.3 Arhitectura rețelei neuronale propuse

Următoarea subsecțiune descrie arhitectura rețelei ce a fost utilizată în toate experimentele. Arhitectura modelului (12 straturi în figura 5.3) este una secvențială, deoarece acesta îi permite utilizatorului să creeze modele strat cu strat, astfel încât fiecare strat este conectat la următorul [117]. Optimizatorul folosit a fost *Adam* cu o rată de învățare de 0,0008 ce este eficient din punct de vedere computațional și potrivit pentru gestionarea unui volum mare de date și parametri, necesitând puține ajustări ale hiperparametrilor [119].

Layer (type)	Output Shape	Param #
conv2d_9 (Conv2D)	(None, 275, 105, 32)	320
max_pooling2d_9 (MaxPooling2D)	(None, 137, 52, 32)	0
conv2d_10 (Conv2D)	(None, 135, 50, 64)	18496
max_pooling2d_10 (MaxPooling2D)	(None, 67, 25, 64)	0
conv2d_11 (Conv2D)	(None, 65, 23, 128)	73856
max_pooling2d_11 (MaxPooling2D)	(None, 32, 11, 128)	0
conv2d_12 (Conv2D)	(None, 30, 9, 128)	147584
max_pooling2d_12 (MaxPooling2D)	(None, 15, 4, 128)	0
flatten_3 (Flatten)	(None, 7680)	0
dropout_3 (Dropout)	(None, 7680)	0
dense_5 (Dense)	(None, 512)	3932672
dense_6 (Dense)	(None, 7)	3591
Total params: 4,176,519		
Trainable params: 4,176,519		
Non-trainable params: 0		

Figura 5.3: Rețea neuronală convoluțională-Arhitectura rețelei.

Parametrii optimizatorului au fost lăsați în starea inițială așa cum este recomandat ($\beta_1 = 0,9$, $\beta_2 = 0,999$, $\epsilon = 1 \times 10^{-8}$, descompunere = 0, 0) [119].

Funcția de pierdere a fost eroarea medie pătratică, deoarece este sensibilă pentru valorile exterioare. Pentru a avea rezultate corespunzătoare la ieșire, modelul necesită cunoștințe despre forma de

intrare și cum ar trebui să arate aceasta. Primul strat din modelul Secvențial trebuie să primească informații despre forma intrării acestuia (277, 107, 3), aceasta reprezentând dimensiunea imaginii în pixeli și canale (3 este pentru modul de culoare RGB). Stratul următor este un strat Conv2D, care este un strat de convoluție. Întrucât întreaga rețea este o rețea neuronală convoluțională (CNN) specializată pentru lucrul în acest caz cu date sub format de imagini bidimensionale. Stratul convoluțional din această rețea aplică o operație liniară, iar funcția de activare utilizată a fost funcția neliniară ReLU.

Straturile următoare conțin Poolingul Maxim și are ca rezultat scăderea dimensionalității sale și permite realizarea unor ipoteze cu privire la caracteristicile incluse în sub-regiuni (grupate). Pentru a evita supra-încărcarea datelor și costurile de calcul ridicate a fost utilizat și stratul *Dropout* care scoate 50% din noduri în timpul antrenamentului. În ultimul strat, care este unul dens, unde toate intrările sunt conectate la ieșire cu o greutate, funcția de activare a fost aleasă Sigmoid (valori între 0 și 1). În consecință, este aplicat în special pentru modelele în care probabilitatea trebuie să fie prevăzută ca o ieșire.

5.1.4 Aplicarea transformatei Wavelet

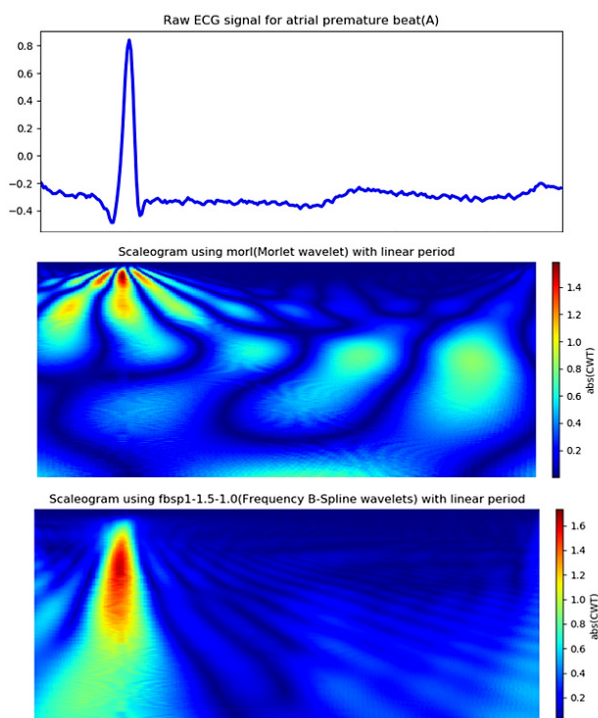


Figura 5.4: Reprezentarea grafică a unei bătăi atriale premature și transformarea ei în scaleograme Wavelet (morl și fbsp).

Transformata Wavelet [120] este o metodă matematică pentru efectuarea analizei semnalului atunci când frecvența acestuia se întinde pe o perioadă de timp. Analiza Wavelet oferă informații mai precise despre datele semnalului decât alte tehnici de analiză a semnalului, cum ar fi Transformata Fourier (FT). Acest tip de transformată poate fi utilizată în procesarea vorbirii, imaginilor, semnalului audio, chiar și în domeniul biomedical [121, 122, 123].

Transformata Wavelet (WT) este aplicată pe scară largă [124, 123, 122, 125] pentru a reprezenta caracteristicile morfologiei EKG iar diferențele dintre semnalele de aritmie vor fi mai ușor detectate de rețeaua neurală.

Sistemul propus folosește transformata Morlet Wavelet și transformata Wavelet a frecvenței B-Spline pentru a identifica mai bine aritmiile din semnalul EKG. Imaginea scalogrammei arată în figura 5.4.

5.1.5 Evaluarea performanțelor obținute

În această secțiune, sunt prezentate rezultatele obținute în urma experimentelor. După cum s-a menționat anterior, în cadrul acestui studiu s-au efectuat mai multe experimente notabile.

Tabel 5.1: Rezultatele antrenării - imagini în tonuri de gri ale semnalelor brute cu șapte clase, filtrate (1000 de eșantioane echilibrate).

Epoca	Pierdere	Precizie	Pierdere_val	Precizie_val	Timp (s)
1	0,1228	0,2200	0,0401	0,8247	9
2	0,0435	0,8122	0,0166	0,9253	8
3	0,0303	0,8663	0,0194	0,9155	8
4	0,0241	0,8888	0,0122	0,9513	8
10	0,0094	0,9594	0,0080	0,9696	8
11	0,0097	0,9566	0,0135	0,9416	8
30	0,0034	0,9869	0,0068	0,9805	8

Datele de intrare au constat în imagini (dimensiune 277x107 pixeli) cu reprezentări diferite și un număr distinct de eșantioane.

5.1.5.1 Clasificarea seriilor temporale, șapte clase (1000 eșantioane)

Pentru primul experiment s-au folosit 1000 de eșantioane din care 20% au fost utilizate pentru testare, iar restul de 80% au fost utilizate pentru antrenare. Semnalele au fost împărțite în șapte clase, cu o rată de detecție de 98,05% după 30 de epoci, dar antrenarea s-a oprit după epoca 30 din cauza lipsei de îmbunătățiri a metricii „val_acc”.

5.1.5.2 Clasificarea Transformatelor Wavelet Morlet, șapte clase (1000 eșantioane)

În al doilea experiment, datele de intrare au fost aceleași, cu excepția faptului că semnalul a fost transformat într-o scaleogramă folosind Transformata Wavelet Morlet (figura 5.4). Din prima epocă, metricile „acc” și „val_acc” au înregistrat valori mai mari, evidențiind beneficiile CWT. De asemenea, în a șasea epocă, modelul a atins cea mai bună valoare pentru metrica „val_acc” și, ca urmare, antrenamentul s-a încheiat, deoarece nu mai aducea îmbunătățiri.

Deși se observă un timp mai îndelungat pe epocă, al doilea experiment a obținut rezultate de peste două ori mai bune decât primul. Acest fenomen se explică prin ajustarea rețelei pentru modul RGB în locul modului de culoare tonuri de gri, pentru a utiliza un kernel de convoluție care gestionează variatele culori necesare pentru Transformata Wavelet.

Tabel 5.2: Rezultatele antrenamentului - imagini Wavelet (morl) ale celor șapte clase filtrate (1000 de eșantioane echilibrate).

Epocă	Pierdere	Precizie	Pierdere_val	Precizie_val	Timp (s)
1	0,0720	0,8549	0,0221	0,9594	16
2	0,0326	0,9399	0,0403	0,9115	15
3	0,0234	0,9579	0,0263	0,9469	15
4	0,0211	0,9612	0,0323	0,9311	15
6	0,0166	0,9702	0,0105	0,9869	15

5.1.5.3 Clasificarea seriilor temporale, trei clase (3000 eșantioane)

Pentru al treilea și al patrulea experiment (Tabelul 5.3), eșantioanele utilizate au fost doar din baza de date *MIT-BIH Arrhythmia* și au fost antrenate doar pentru trei clase: bătăi normale („N”), premature atriale („A”) și fuziunea între bătăi ventriculare și normale („F”).

Tabel 5.3: Rezultatele antrenării - imagini color ale semnalelor brute, nefiltrate (3000 de eșantioane echilibrate) cu trei clase.

Epocă	Pierdere	Precizie	Pierdere_val	Precizie_val	Timp (s)
1	0,1054	0,7789	0,0436	0,9313	23
2	0,0437	0,9194	0,0292	0,9406	19
3	0,0301	0,9493	0,0271	0,9556	21
4	0,0249	0,9568	0,0145	0,9688	20
5	0,0216	0,9619	0,0144	0,9778	21
7	0,0185	0,9686	0,0119	0,9810	20
10	0,0149	0,9760	0,0091	0,9844	20

În această configurație cu 3000 de eșantioane, păstrând proporția 20% testare și 80% antrenare, s-au utilizat și eșantioane zgomotoase fără filtrare manuală. Deja din prima epocă, „val_acc” a ajuns la 93,13%, arătând că precizia crește cu mai multe eșantioane și că datele zgomotoase au un impact redus. În acest experiment, imaginile conțin doar semnalul EKG unidimensional. Modelul s-a oprit la a zecea epocă, obținând o precizie mai mare decât în primul experiment, dar nu semnificativ mai mare decât în al doilea experiment cu Transformata Wavelet, totuși cu un timp mai mare pe epocă.

Tabel 5.4: Rezultatele antrenării - imagini Wavelet color, nefiltrate (fbps1-1.5-1.0) (3000 de eșantioane) cu trei clase.

Epocă	Pierdere	Precizie	Pierdere_val	Precizie_val	Timp (s)
1	0,1290	0,7269	0,0981	0,7844	25
2	0,0772	0,8559	0,0637	0,8594	23
3	0,0485	0,9063	0,0481	0,9139	24
4	0,0339	0,9406	0,0335	0,9406	23
5	0,0314	0,9413	0,0297	0,9470	24
7	0,0261	0,9550	0,0197	0,9719	24
43	0,0055	0,9916	0,0033	0,9938	23

Această îmbunătățire se datorează creșterii numărului de eșantioane și configurării rețelei pentru modul de culoare RGB, similar cu al doilea experiment. De asemenea, în a patra epocă, al treilea expe-

riment a atins cea mai bună valoare pentru metrica „val_acc”, depășind 96%, în comparație cu celelalte două experimente.

5.1.5.4 Clasificarea Transformatei Wavelet B-Spline, trei clase (3000 eșantioane)

În al patrulea experiment, s-a folosit Transformata Wavelet B-Spline de Frecvență (fbsp1-1.5-1) cu 3000 de eșantioane, similar cu al treilea experiment. Datele nu au fost filtrate, ceea ce a dus la o antrenare mai lentă, dar cu o precizie excelentă de 99,38% în epoca a 43-a. Complexitatea imaginilor a crescut, justificând creșterea timpului per epocă.

5.1.6 Considerații finale

În concluzie, antrenarea unei rețele neuronale convoluționale pentru detecția aritmiilor cardiace din electrocardiografe a condus la performanțe remarcabile de până la 99,38%. Rețeaua formată din 12 straturi s-a dovedit eficientă atunci când datele sunt reprezentate bidimensional prin Transformata Wavelet, cum ar fi Transformata Morlet sau Transformata B-Spline de Frecvență. Cu toate acestea, încă există dificultăți în detectarea aritmiilor rare sau neobișnuite, precum și în gestionarea datelor zgomotoase. Detectarea automată a aritmiilor poate accelera diagnosticul, mai ales în cazul EKG-urilor colectate pe perioade mai lungi. Dispozitivele inteligente, EKG-urile portabile și holterele accesibile pentru o gamă variată de persoane, inclusiv cele vulnerabile, permit pacienților să monitorizeze și să detecteze singuri aritmii, precum și să primească asistență medicală precoce.

5.2 Aplicațiile inteligenței artificiale în clasificarea sarcinilor motorii

În ultimii ani, a crescut semnificativ interesul pentru aplicarea tehnicilor de învățare automată pentru dezvoltarea tehnologiilor de asistență pentru persoanele din diverse arii chiar și pentru cele cu nevoi speciale [126, 127, 128, 129]. Semnalele EEG oferă informații valoroase despre activitatea electrică a creierului, oferind o metodă directă și noninvasivă pentru detectarea anumitor anomalii sau chiar boli. Metodele de învățare automată, în special cele pentru extragerea de caracteristici din semnalele EEG, permit clasificarea activităților pacientului, oferind asistență personalizată și adaptabilă pentru persoanele cu nevoi speciale. Recunoașterea și clasificarea precisă a acțiunilor, cum ar fi activitățile motorii, facilitează feedback-ul în timp real și interacțiunea independentă a persoanelor cu nevoi speciale cu mediul lor. Pentru clasificarea activităților motorii pe baza semnalelor EEG, trebuie luate în considerare aspecte precum achiziția datelor, amplasarea electrozilor, numărul acestora, confidențialitatea și confortul participanților, în special pentru persoanele cu cerințe speciale. Rețelele neuronale convoluționale (CNN) s-au dovedit promițătoare în domeniul interfețelor creier-computer (BCI) [130, 131, 48], deoarece pot procesa semnale brute fără necesitatea extragerii manuale a caracteristicilor. Aceasta reduce complexitatea procesului, îmbunătățește eficiența sistemului și mărește precizia.

5.2.1 Obstacole întâlnite în cadrul interfețelor creier-computer

Clasificarea semnalelor EEG are o importanță cheie în interfețele creier-computer (BCI), neurologie, neuroștiința cognitivă și alte domenii, dar implică unele obstacole semnificative:

- ❑ **confidențialitatea și etică** ce pot crea dileme etice și provocări atunci când vine vorba de utilizarea și stocarea acestor date;
- ❑ **artefacte** (clipitul ochilor) ce pot introduce distorsiuni și interferențe semnificative;
- ❑ **diferențele de semnal** ce pot apărea de la un individ la altul iar pe termen lung semnalul de la același subiect poate fi diferit;
- ❑ **lipsa datelor adnotate** sau chiar adnotarea incorectă a semnalelor EEG;
- ❑ **interpretarea datelor** poate fi dificilă, din cauza complexității semnalelor EEG.

Utilizarea algoritmilor de învățare pentru clasificarea semnalelor EEG brute prezintă numeroase avantaje, precum creșterea preciziei clasificării, extragerea automată a caracteristicilor și funcționarea în timp real. Acești algoritmi au potențialul de a îmbunătăți o gamă variată de aplicații, inclusiv interfețele creier-computer, reabilitarea post AVC, jocurile video, realitatea virtuală, etc.

5.2.2 Arhitectura sistemului în aplicațiile interfeței creier-computer

Sistemele de interfață creier-calculator (BCI) utilizează semnalele EEG pentru a transforma activitățile cerebrale în comenzi. Clasificarea imaginilor motorii reprezintă un subiect de interes în creștere în neuroștiință, cu progrese notabile în algoritmi de procesare a semnalelor și în tehnologiile de neuro-imagistică. Aceste dezvoltări își propun să îmbunătățească eficiența și accesibilitatea interfețelor BCI, cu un potențial semnificativ de ajutor pentru persoanele cu dizabilități sau afecțiuni precum leziuni ale măduvei spinării sau scleroza laterală amiotrofică (ALS).

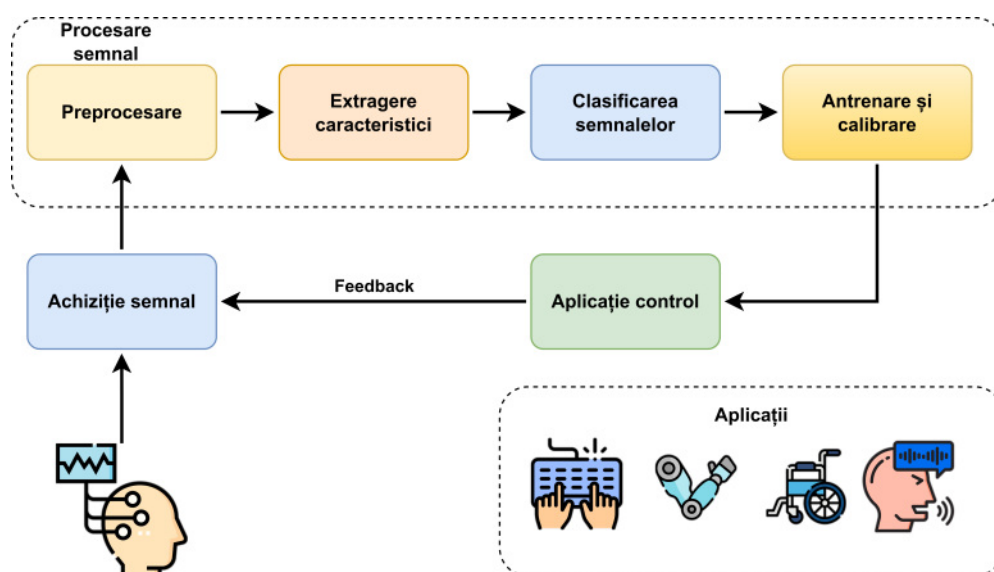


Figura 5.5: Schema bloc generală a unui sistem BCI bazat pe semnale encefalografice.

O arhitectură BCI tipică bazată pe învățare automată constă din componente care facilitează comunicarea între creier și un dispozitiv extern. Schema bloc generală (figura 5.5) ilustrează următorii pași:

1. **Achiziția semnalelor cerebrale** prin electrozii EEG detectează activitatea electrică a creierului;
2. **Preprocesarea datelor** sau așa-numita prelucrare prealabilă în care semnalele cerebrale achiziționate ce conțin anomalii și zgomot trebuie filtrate;
3. **Extragerea caracteristicilor** unde caracteristicile relevante sunt extrase după ce au fost pre-procesate;
4. **Clasificarea datelor** caracteristicile extrase sau selectate sunt introduse într-un model de învățare automată;
5. **Antrenarea și calibrarea** unde modelul de clasificare este antrenat cu date etichetate corelate cu anumite acțiuni;
6. **Aplicații în timp real** odată ce modelul a fost antrenat și calibrat, poate fi utilizat pentru predicția în timp real în anumite sisteme existente (scaun cu rotile, braț robotic).

5.2.2.1 Îmbunătățiri aduse arhitecturilor folosite pentru interfețele creier-computer

Procesul de analiză și clasificare a datelor EEG este complex și implică achiziționarea, preprocesarea, extragerea caracteristicilor, construirea și validarea modelelor, precum și clasificarea semnalelor. Fiecare etapă este esențială pentru clasificarea corectă a semnalelor EEG. Schema generală a acestei proceduri poate fi observată în figura 5.12.

Etapă de pregătire a datelor și filtrare urmează achiziției datelor brute și extragerii caracteristicilor, îmbunătățind calitatea semnalelor prin eliminarea zgomotului și a semnalelor nedorite. În această fază, se selectează canalele relevante, se elimină semnalele zgomotoase, iar caracteristicile procesate sunt folosite ca intrări în modelele de clasificare, adesea bazate pe rețele neuronale convoluționale.

În această fază de dezvoltare și formare a modelului, se selectează strategia de antrenare și se utilizează rețele neuronale convoluționale (CNN), rețele neuronale recurente (RNN), sau alte arhitecturi pentru a clasifica datele. În cadrul acestui studiu, rețelele convoluționale 1D au fost preferate pentru performanța lor superioară și timpul de execuție mai scurt în comparație cu alte metode, precum transformările Wavelet. De asemenea, alegerea arhitecturii modelului depinde de caracteristicile datelor, oferind flexibilitate pentru ajustarea și optimizarea performanței.

După instruirea modelului, se efectuează o validare inițială pentru a evalua performanța utilizând un set de date separat de cel de antrenare, cu accent pe parametri precum acuratețea, sensibilitatea și specificitatea. Modelul este salvat doar dacă performanța este satisfăcătoare, din considerente de economisire a resurselor computaționale. În cazul în care modelul inițial are performanță nesatisfăcătoare, acesta poate fi îmbunătățit prin ajustarea hiperparametrilor, modificarea arhitecturii sau prin utilizarea învățării prin transfer, care poate accelera instruirea și îmbunătăți performanța modelului.

În etapa finală, modelul ales este supus unei verificări riguroase pentru a evalua robustețea sa. Acest model este folosit pentru clasificarea semnalelor EEG, identificând tipul de activitate cerebrală corespunzătoare fiecărui semnal. Modelul final are o gamă largă de aplicații, inclusiv în interfețele creier-computer și diagnosticarea bolilor neurologice. Abordarea iterativă a acestui proces necesită multiple runde de validare și îmbunătățire și poate varia de la individ la individ, dar folosirea de modele pre-antrenate poate accelera și îmbunătăți rezultatele în aplicații specifice.




Figura 5.6: Procedură de achiziție a datelor ilustrată pentru experimentele locale.

5.2.3 Metode privind colectarea și preprocesarea seturilor de date experimentale

În domeniul clasificării datelor EEG, cercetătorii se confruntă cu alegerea între utilizarea seturilor de date proprii sau a celor consacrate. Utilizarea unui set de date personalizat permite personalizarea achiziției de date și o înțelegere mai profundă a procesului, dar poate avea limitări de generalizare. Pe de altă parte, seturile de date consacrate oferă protocoale standardizate, documentare detaliată și au fost utilizate în numeroase studii, facilitând comparația și reproducerea rezultatelor. O abordare hibridă care capitalizează beneficiile ambelor metode poate fi benefică în cercetarea EEG.

5.2.3.1 Metoda achiziționării seturilor de date EEG locale. Investigarea sarcinilor motorii

Conform tabelului 5.6, s-au efectuat diverse experimente folosind echipamentul de la Neurosoft ce a fost împrumutat de la SC LIAMED SRL, o companie locală specializată în echipamente medicale.

În ceea ce privește subiecții aceștia au fost în număr de trei (tabelul 5.5). Autorul tezei gestionează și realizează studiul, fiind în același timp implicat activ în întregul proces (figura 5.6). A fost utilizat un laptop **(2)** pentru achiziție, izolat de rețeaua electrică pentru a evita interferențele, și un alt laptop multime-

Tabel 5.5: Participanți experiment encefalograf.

Subiect	Vârstă	Sex	Ocupație
Subiect 0 (s0)	30	M	Doctorand (Autor)
Subiect 1 (s1)	20	M	Student
Subiect 2 (s2)	20	M	Student

dia**(5)** pentru înregistrarea și redarea experimentului, conectat la un monitor LCD pentru participant**(8)**. De asemenea, un al doilea monitor**(3)** a fost folosit pentru monitorizarea în timp real a experimentului și a altor date relevante. Două dispozitive de înregistrare**(7)** sunt utilizate pentru a capta experimentul din perspective diferite. O cameră web pentru o vedere frontală **(7)** și un telefon inteligent **(10)** pentru o vedere laterală. Participantul**(2)** este esențial pentru experiment. Electrozii de pe scalp sunt conectați la echipamentul de achiziție Neuron Spectrum 65**(14)**. și înregistrează atât activitatea EEG cât și EKG. Acesta se alimentează exclusiv de la un cablu USB**(15)**, asigurând citiri precise fără interferențe din rețea. Primul subiect (notat cu s0 în această teză și s0d în înregistrările EDF) este autorul tezei, în vârstă de 30 de ani. Acesta a participat la o instrucție la sediul SC LIAMED SRL Brașov, care a inclus folosirea aparatului medical și a softului. Ulterior, autorul a efectuat mai multe experimente în zilele de 1, 21, 22, 25 și 28 martie 2022, înregistrând diverse tipuri de semnale, inclusiv artefacte, pentru a se familiariza cu sistemul și achiziția datelor.

Subiectul 2 (s1 în această teză și s0 în înregistrări) este un student în vârstă de 20 de ani fiind cunoscut ca o persoană calmă, capabilă să se concentreze cu ușurință la sarcini. Pentru a diversifica rezultatele, experimentele cu acest subiect s-au desfășurat la diferite ore și în diferite contexte, inclusiv seara după orele de facultate, dimineața după somn și după activități fizice, cum ar fi antrenamentele la sală. De asemenea, s-au înregistrat eșantioane variate, acoperind diverse activități și artefacte, precum clipirea ochilor sau bătăile inimii.

Ultimul subiect (s2 în înregistrări) este un student în vârstă de 20 de ani care a participat în special la primele experimente și la colectarea datelor referitoare la diferite artefacte. Pentru a asigura o achiziție de date cât mai bună, s-a avut grijă să mențină impedanța la un nivel cât mai mic și în parametri.

Descrierea experimentelor

Majoritatea experimentelor s-au desfășurat în corpul V al Universității Transilvania din Brașov. Fiecare participant avea în fața sa un monitor LCD aflat la o distanță de aproximativ 45 cm, pe care se derulau instrucțiunile pentru experiment.

Experimentul „0 - Inițierea”

Acest experiment a reprezentat prima experiență a autorului și a celor doi subiecți cu un echipament medical EEG. În cadrul experimentului, s-a desfășurat o sesiune de instruire la sediul companiei SC LIAMED SRL din Brașov, urmată de un experiment în care subiecții (s1 și s2) au fost expuși la o prezentare pe un ecran LCD. Aceștia au fost instruiți să rămână calmi și să evite mișcările excesive, cu monitorizarea pulsului sub 90 de bătăi pe minut, deschizând ochii doar în momentul în care au auzit semnale sonore



Figura 5.7: Capturi experimentul „Inițierea” cu subiectul s1, locație Sediul SC LIAMED SRL.

sub forma unui bip.

Subiecții au fost supuși la diferite sarcini, cum ar fi clipitul, înghițitul, zâmbitul, și mișcarea ochilor în diferite direcții. Apoi, li s-au prezentat figuri geometrice de diferite forme și culori, precum pătrate, triunghiuri, cercuri sau stele în negru, roșu sau verde. Experimentul s-a încheiat cu prezentarea unor imagini reprezentând alimente, expresii faciale și versuri din poezii celebre, cu scopul de a stârni diverse senzații și emoții în subiecți.

După terminarea primului experiment, participanții au fost intervievați, menționând dificultatea de a se concentra pe parcursul experienței. Acest feedback a condus la ajustări în experimentele ulterioare. De-a lungul acestui experiment inițial, autorul a acumulat experiență în folosirea echipamentului și a învățat să minimizeze artefactele, cu focus pe reacțiile naturale ale subiecților.

Experimentul „Primăvara”

Al doilea experiment, intitulat „Primăvara” datorită datei de 1 martie 2022 unde autorul a făcut ajustări pe baza feedback-ului primit din experimentul inițial, scurtând durata și păstrând doar figurile de culoare neagră cu slide-uri albe intercalate. Subiecții trebuiau să închidă ochii în timpul slide-urilor albe și să aștepte semnalul acustic pentru a-i deschide. Feedback-ul de la subiecți a indicat o concentrare îmbunătățită, dar disconfortul cauzat de căștii rămânea o problemă.



(a) Vedere laterală stânga, clasa „stea”.



(b) Vedere laterală stânga, clasa „triunghi”.



(c) Vedere laterală stânga, clasa „cerc”.




(d) Vedere laterală stânga, ecran alb.

Figura 5.8: Capturi din experimentul „Primăvara” cu subiectul s1, locație Corpul V al Universității Transilvania din Brașov.

Subiecții au mărturisit că în urma vizualizării unei forme de culoare neagră pe un fundal alb, după ce închideau ochii încă vedeau figura geometrică, iar în anumite momente încă se gândeau involuntar la aceasta iar sunetul produs la schimbarea slide-urilor a fost perceput ca neprietenos, iar predictibilitatea slide-urilor a fost un alt aspect notat. Autorul a identificat fluctuații semnificative în semnalul înregistrat de EEG în timpul sunetelor produse din direcții diferite, posibil din cauza reacțiilor subiecților sau a activării părților creierului responsabile de percepția auditivă. În plus, zgomotele din afara încăperii, cum ar fi sirena unei ambulanțe, au indus distorsiuni în semnal, dar nu au fost eliminate din experiment pentru a păstra autenticitatea acestuia.

Experimentul „Alb-Negru”


S-a desfășurat la distanță de câteva săptămâni de la experimentele anterioare, a inclus procesarea datelor anterioare, crearea algoritmilor de adnotare automată și dezvoltarea unui algoritm de adnotare pentru secvențele video. Pentru a obține mai multe date relevante, au fost reduse clasele și timpul de expunere al ecranului de odihnă între clase.



(a) Tranziție neagră afișată pe monitor.



(b) Vedere frontală subiectul s2 (a se vedea tabelul 5.5).



(c) Pregătirea subiectului s2 (a se vedea tabelul 5.5).



(d) Vedere frontală subiectul s1.

Figura 5.9: Capturi din experimentul „Forța” și „Finale” cu subiectul s1 și s2, locație Corpul V al Universității Transilvania din Brașov.

Experimentul “Alb-Negru” a implicat eliminarea sunetului, înlocuirea secvențelor albe cu secvențe negre și cerința ca participanții să clipească de 2-3 ori în timpul ecranului negru. Autorul a continuat să se familiarizeze cu echipamentul medical și artefactele înregistrate pentru calibrare și antrenare. Artefactele au reprezentat informații valoroase pentru distingerea acestora de semnalele reale.

Experimentul „Odihnit”

Experimentul a avut loc după o perioadă de somn bun și a implicat achiziția de date de la subiectul s1. Semnalele EEG nu au fost semnificativ diferite de cele din alte experimente, dar ritmul cardiac al subiectului a fost mai scăzut. Subiectul a fost mai confortabil și mai concentrat în acest experiment, care a avut loc pe 22 martie 2022, cu o durată de 3600 de secunde.

Experimentul „Forța”

Al cincilea experiment din serie, a implicat examinarea subiectului s1 după o sesiune la sala de forță. Pulsul participantului a fost crescut în urma activității fizice intense.

În cadrul acestui experiment s-a decis să se îndrepte atenția preponderent către persoanele cu nevoi speciale, pentru a înțelege cum ar trebui un astfel de sistem să fie folosit de persoanele care au sau sunt predispuse la probleme, precum afecțiuni de motricitate care necesită asistență. Astfel, în loc ca participantul să se gândească la sensul propriu al marcajelor stânga, dreapta, sus sau jos, trebuia să își imagineze că mișcă câte o mână, pe rând, în funcție de sensul săgeților, uneori efectuând acțiunea, iar când săgeata era îndreptată în jos acestea să își imagineze sau să își miște tălpile picioarelor și să

strângă din tălpi. În cazul în care săgeata sus era afișată acesta trebuia să își imagineze că va mișca privirea în sus. Acest lucru este foarte important mai ales pentru persoanele ce își pierd mobilitatea în timp și care pot avea astfel de sisteme pe care le pot antrena iar mai apoi să le folosească în activități fizice pentru aș îmbunătăți viața cotidiană. Acest mod de imagineare poartă numele de „imagineare motrică”.



Figura 5.10: Captură din cadrul experimentului „Finale”, săgeată stânga, locație Corpul V al Universității Transilvania din Brașov.

Experimentul „Finale”

Ultimele cercetări au avut loc pe data de 25 și 28 martie 2022 și au fost similare cu experimentul „Forța”, însă doar subiecții s0 și s1 au fost implicați, iar experimentele au fost repetate cu scopul de a avea cât mai multe date pentru antrenare.

5.2.3.2 Achiziția datelor

Electrozii tip punte Ag/AgCl sunt alegerea potrivită pentru înregistrările EEG datorită stabilității semnalului, reutilizabilității, potențialului electric de compensare scăzut și costului redus. Acești electrozi oferă longevitate și compatibilitate cu scalpul pacienților, fără a provoca iritații, ceea ce îi face ideali pentru înregistrările EEG pe termen lung.

Informațiile sunt colectate cu ajutorul Neurosoft-Spectrum-65 [65], care captează semnalele cerebrale folosind 22 de canale (cu semnalul EKG inclus) la o rată de eșantionare de 500 Hz.

Neuron-Spectrum-65 este un echipament EEG cu 39 de canale de generația a șasea, conceput pentru utilizare medicală în institutele publice și private. Acesta include monitorizare video-EEG extinsă, polisomnografie, portabilitate pentru pacienți, monitorizare continuă a impedanței, analize matematice avansate, și permite exportul datelor pentru analize statistice ulterioare.

Montajele sunt anumite aranjamente logice, ordonate, de derivații sau canale encefalografice care sunt create pentru a afișa activitatea cerebrală. Cel mai adesea, montajele monopolare, bipolare și referențiale sunt utilizate pentru montajele encefalografice.

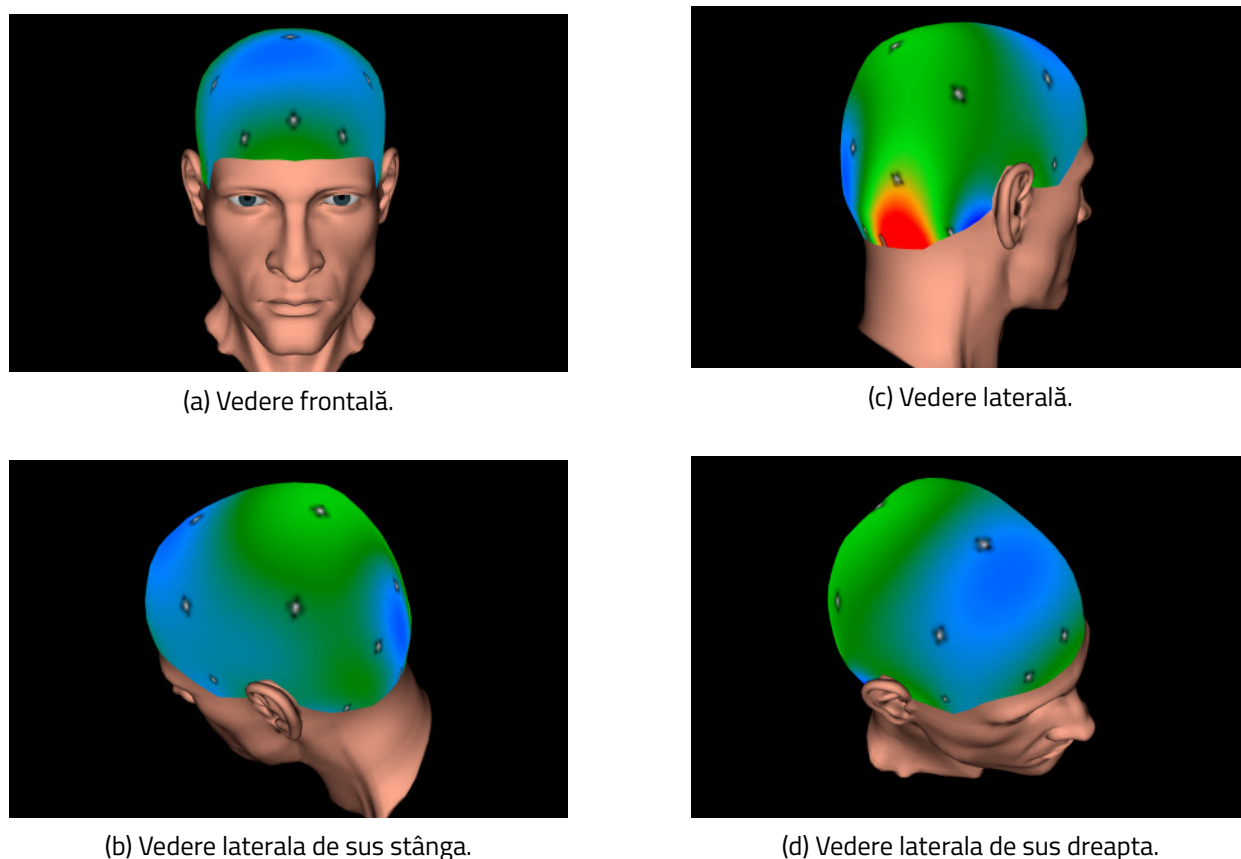


Figura 5.11: Harta spectrală a undelor teta și alfa și amplasarea electrozilor pe scalp. Captură din programul Neurosoft-Spectrum.NET.

Considerațiile finale ale experimentului local

Se poate observa din tabelul 5.6 că au fost implicați mai mulți participanți de-a lungul a aproximativ 7 experimente cu o durată medie de 16 minute fiecare, influențată de disponibilitatea și confortul subiecților. Subiecții au manifestat disconfort datorat electrozilor și uneori au acuzat dureri de cap sau migrene. Montajul electrozilor și asigurarea conexiunii cu dispozitivul de achiziție necesitau între 10 și 15 minute per pacient.

Experimentele repetitive au ajutat cercetătorul să înțeleagă echipamentul și procesul de achiziție a datelor, identificând motivele declanșării artefactelor și observând reacțiile variate ale participanților. Alegerea locației adecvate a fost crucială pentru minimizarea zgomotelor acustice și electrice.

Tabel 5.6: Experimente, subiecții implicați, data experimentelor și durata totală a acestora.

Nr. Exp.	Data	Subiecți	Durată exp. (s)
1	24.02.2022	s0, s1, s2	9705
2	01.03.2022	s0, s1, s2	5155
3	21.03.2022	s1, s2	3106
4	22.03.2022	s1	3676
5	24.03.2022	s0, s1, s2	6357
6	25.03.2022	s0, s1	3036
7	28.03.2022	s1	5778

Aceste experimente au reprezentat un real succes, apropiind autorul de mediul medical și aducându-i o perspectivă detaliată asupra domeniului. Cercetătorul a înțeles aspecte cruciale, care nu puteau fi obținute din baze de date existente, precum achiziționarea echipamentului medical, găsirea și pregătirea atentă a participanților. Interacțiunea cu profesioniști și pasionați din domeniu a permis stabilirea de conexiuni valoroase pentru viitoarele studii de cercetare, iar promptitudinea participanților în răspunsuri și asistență a adus o dimensiune umană și practică cercetării.

5.2.3.3 Metoda utilizării unui set de date consacrat

Setul de date EEG Motor Movement/Imagery Dataset V1.0.0¹ [132] de pe PhysioBank constă în înregistrări de semnal EEG de la 103 participanți, cuprinzând 14 încercări experimentale și 4 sarcini de imaginare motorie. Înregistrările au fost realizate cu un sistem BCI2000 și configurație EEG cu 64 de canale la o frecvență de 160 Hz. Setul de date oferă potențial pentru cercetarea imaginii motorii și dezvoltarea interfețelor creier-computer. Fiecare adnotare este etichetată ca **T0**, **T1** sau **T2**, iar fiecare sesiune constă în secvențe de 4 secunde de fiecare tip, însumând 15 semnale **T0**, 8 semnale **T1**, și 7 semnale **T2**. Unele înregistrări au fost excluse din experiment din cauza unor erori de adnotare (S105, S104, S101, S100, S092, S089, S088, S038 și S001).

În cadrul cercetării, s-au stabilit patru clase distincte pentru a reprezenta diferite stări mentale și sarcini de imagistică motorie. Aceste clase includ starea de bază, imaginația motorie a mișcării pumnului stâng, imaginația motorie a mișcării ambilor pumni și imaginația motorie a mișcării ambelor picioare, fiecare fiind etichetată corespunzător în analiza datelor cu „B”, „S”, „P” și „D”.

Setul de date a prezentat o inițială dezechilibrare a claselor, iar pentru a corecta acest aspect, s-au aplicat tehnici de echilibrare atât în perioada de antrenament, cât și în cea de testare. De asemenea, s-a asigurat o distribuție echilibrată a setului de date de validare prin selectarea a 1000 de eșantioane per clasă. În etapa de instruire, inițial, distribuția claselor a fost ajustată pentru a aborda dezechilibrul, inclusiv prin utilizarea tehnicii de supra-eșantionare a minorităților sintetice (SMOTE [40] [133]).

În plus, pentru a îmbunătăți precizia, au fost selectate canale specifice care au fost considerate cele mai relevante pentru activitățile motorii. Aceste canale selectate au inclus FC1, FC2, FC3, FC4, FC5, FC6, C5, C6, C3, C4, C1, C2, CP1, CP2, CP3, CP4, CP5 și CP6. Scopul a fost de a evidenția aceste canale pentru a capta cele mai informative semnale asociate cu mișcările motorii. Astfel, după aplicarea tehnicii SMOTE clasele folosite pentru antrenare au avut forma [30000 30000 30000 30000] clasele balansate.

Tabel 5.7: Semnificații cod adnotări din setul de date EEG Motor Movement/Imagery Dataset [132].

Cod	Descrierea Mișcării	Număr Experiment
T0	Starea de bază (odihnă)	-
T1	Mișcarea pumnului stâng (reală sau imaginară)	3, 4, 7, 8, 11, 12
	Mișcarea ambilor pumni (reală sau imaginară)	5, 6, 9, 10, 13, 14
T2	Mișcarea pumnului drept (reală sau imaginară)	3, 4, 7, 8, 11, 12
	Mișcarea ambelor picioare (reală sau imaginară)	5, 6, 9, 10, 13, 14

¹disponibil la adresa <https://physionet.org/content/eegmmidb/1.0.0/>

5.2.3.4 Considerații finale. Experimente proprii sau baze de date recunoscute

După efectuarea experimentelor de achiziții de date EEG cu participanți reali, se observă mai multe avantaje, inclusiv cunoașterea detaliată a configurării experimentale, controlul complet asupra proiectului experimental, confidențialitatea datelor, standardizarea achiziției de date și selectarea participanților după criterii de interes. De asemenea, feedback-ul direct de la pacienți și posibilitatea de a alege echipamentul reprezintă reale beneficii. Cu toate acestea, în ceea ce privește achizițiile proprii ale semnalelor EEG, există și câteva dezavantaje, cum ar fi necesitatea de a dobândi competențe tehnice, procesul de adnotare a datelor EEG, identificarea participanților adecvați și costul ridicat al echipamentelor.

Alegerea între utilizarea unui set de date public și generarea datelor proprii în cercetarea EEG poate beneficia de o abordare hibridă care îmbină avantajele ambelor metode. Cercetătorii pot folosi datele proprii pentru investigații specifice, testarea ipotezelor și explorarea noi direcții de cercetare, în timp ce seturile de date existente pot servi ca referințe pentru validare și aplicabilitatea rezultatelor. Cu o planificare atentă și resurse adecvate, cercetătorii pot depăși provocările legate de achiziționarea și gestionarea datelor EEG, aducând contribuții semnificative la domeniul cercetării în ciuda acestor obstacole.

5.2.4 Extragerea caracteristicilor importante

5.2.4.1 Filtrarea datelor

Filtrele în prelucrarea semnalului EEG sunt esențiale pentru eliminarea frecvențelor nedorite și a zgomotelor, însă trebuie să găsească un echilibru între curățarea semnalului și păstrarea activității neuronale relevante, în special a undelor cerebrale legate de imaginile motorii. Filtrul trece-sus, trece-jos și filtrul oprește-bandă sunt cele mai utilizate în acest context, permitând concentrarea pe benzi de frecvență specifice, precum undele beta (11-30 Hz), asociate activității senzoriale și motorii. În cazul de față s-a ales pentru acest LFF (*Low Frequency Filter*) o frecvență de 0,5 Hz, pentru HFF 35 Hz și filtrul *Notch* dezactivat. Filtrul de frecvență joasă (LFF) este caracterizat de o frecvență de tăiere de 0,5 Hz. Filtrul oprește-banda se utilizează pentru frecvențe de 50 Hz – frecvența rețelei electrice locale.

5.2.4.2 Adnotarea automată a datelor din experimentul local

Adnotarea semnalului EEG este adesea o sarcină laborioasă și de lungă durată, în care experți umani examinează și identifică manual evenimentele sau segmentele relevante din semnalele înregistrate. În scenariul de față, a fost dezvoltat un program pentru a automatiza generarea de adnotări ale semnalelor profitând ca punctul de început, cât și cel de sfârșit al experimentului erau cunoscute dar mai ales se știa cât dura fiecare activitate. După ce au fost create adnotările automate, acestea au fost importate în EDFBrowser și a accelerat semnificativ procesul de adnotare.

5.2.4.3 Selectarea canalelor de interes

Selectarea canalelor EEG este importantă mai ales că artefactele produse de mișcările ochilor și clipit pot afecta semnalele. Chiar dacă participanții au fost instruiți să nu miște ochii prea des au existat anumite acțiuni ce au afectat canalele apropiate de ochi. Algoritmul de IA a obținut inițial rezultate slabe, însă după eliminarea canalelor afectate, acuratețea a crescut semnificativ, depășind 90%.

5.2.4.4 Selecția datelor de interes din experimentul local

Procesul de selecție a datelor pentru experiment a implicat tăierea inițială a fișierelor EDF pentru a include doar datele relevante ale experimentului, urmată de adnotarea automată pe baza cunoașterii duratei experimentelor, permițând identificarea evenimentelor specifice activităților. Subiecții au fost instruiți să efectueze diverse acțiuni, inclusiv mișcarea ochilor, pentru a furniza identificatori pentru localizarea artefactelor, contribuind astfel la selecția datelor cu puține artefacte (în experimente).

Patru fișiere EDF au fost alese datorită cantității substanțiale de date pe care le-au oferit, acoperind un interval mai mare de timp pentru subiectul 0 (s0) și asigurând reducerea zgomotului în date. Aceste date au fost destinate analizelor ulterioare și sarcinilor de clasificare în cadrul experimentului de procesare a semnalului EEG.

Tabel 5.8: Informații fișiere EDF subiectul s0 și durata acestora pentru activitățile motrice.

Fișier EDF	Timp început experiment	Timp sfârșit experiment	Durăță (MM:SS)
sOp0.edf	19:17:04 28.03.2022	19:30:45 28.03.2022	13:41
sOp1.edf	19:40:26 28.03.2022	19:56:52 28.03.2022	16:26
sOp2.edf	21:15:30 28.03.2022	21:31:50 28.03.2022	16:20
sOp3.edf	21:41:30 28.03.2022	21:57:21 28.03.2022	16:16

5.2.5 Antrenarea, calibrarea și clasificarea datelor

Cercetarea actuală a utilizat rețelele neuronale ca instrumente flexibile de procesare a semnalelor și de extragere a caracteristicilor pentru a investiga modele complexe în cadrul datelor EEG ale undelor cerebrale. Această secțiune explorează utilizarea atât a arhitecturilor convenționale, cât și a altor arhitecturi ale rețelelor neuronale în scopul decodificării datelor.

5.2.5.1 Arhitecturi de rețele neuronale artificiale folosite pentru clasificarea semnalelor de la acțiuni sau a imaginărilor motorii.

Pentru a oferi o bază solidă pentru procedurile experimentale, s-au utilizat o varietate de topologii de rețele neuronale artificiale preexistente sau cu anumite îmbunătățiri, concepute special pentru a valorifica atributele distinctive inerente datelor electroencefalogrammei. Arhitecturile *EEGNet* [134], *EEGNetSSVEP* [135, 136], *DeepConv*, *ImprovedNet*, *ImprovedNet2* și *ImprovedNet3* construite special pentru analiza EEG, au fost utilizate datorită capacității sale de a capta eficient relațiile temporale.

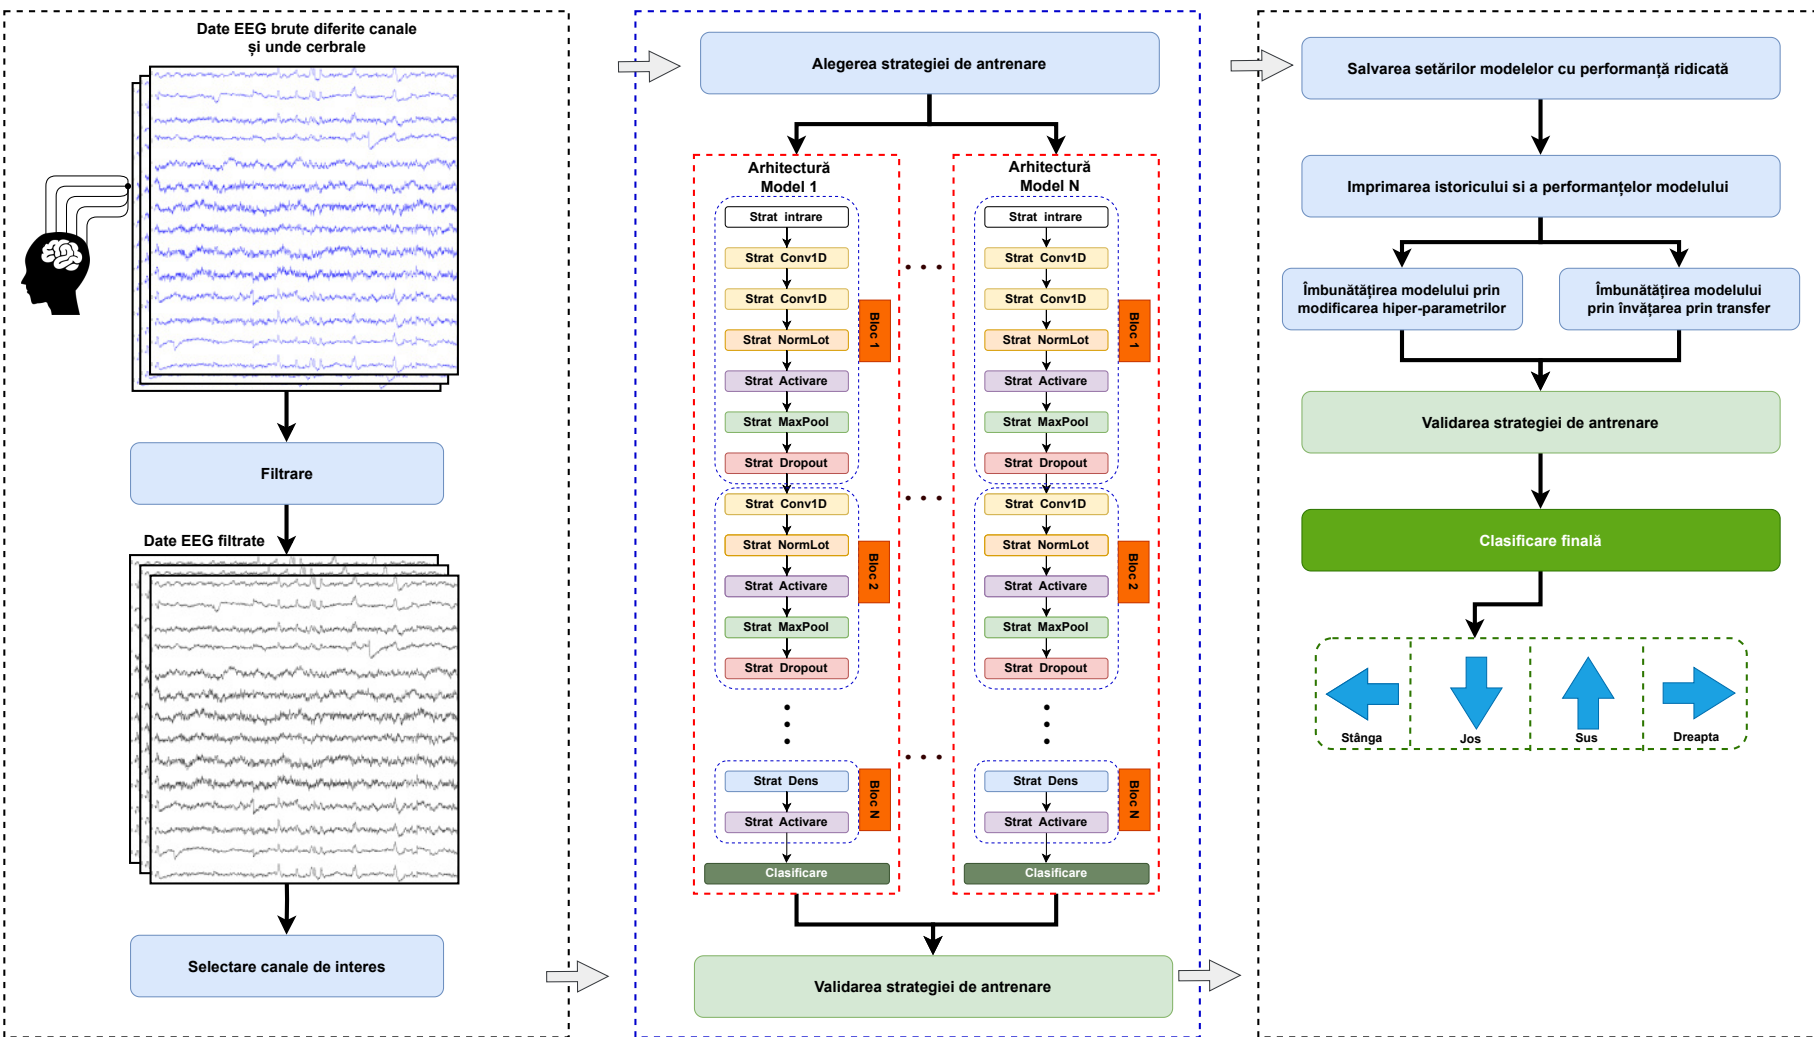


Figura 5.12: Descrierea procesului de antrenare, calibrare și validare folosind diferite arhitecturi neuronale, cu precădere rețele neuronale convoluționale, diferite și anumite tehnici prin care se poate îmbunătăți acuratețea și robustețea unui sistem (de exemplu, prin îmbinarea mai multor rețele prin tehnica învățării de transfer) – propunere de implementare.

Arhitecturile menționate anterior au fost proiectate cu atenție cu scopul de a crește adâncimea convoluțională și de a implementa aranjamente unice pentru a spori performanța clasificării. Decizia arhitecturală selectată servește drept bază pentru capacitatea de a modifica cu ușurință setările și, mai important, de a sprijini implementarea abordărilor de învățare prin transfer. Acest lucru oferă posibilitatea de a personaliza arhitecturile rețelelor neuronale în funcție de caracteristicile unice ale diferitelor seturi de date EEG, fără a necesita o reproiectare extinsă. Acest proces este reprezentat în figura 5.12. Specificațiile arhitecturale ale rețelelor neuronale artificiale utilizate sunt furnizate și în anexele din teză.

5.2.6 Evaluarea performanțelor obținute

Această secțiune sintetizează rezultatele evaluării performanțelor rețelelor neuronale, evidențiind precizia, pierderile și matricele de confuzie în două abordări distincte, una folosind un set de date specific și alta un set de date local. Evaluarea arhitecturilor de rețele neuronale a început, ca primă abordare, cu utilizarea setului de date **EEGMMIDB**¹.

Tabel 5.9: Distribuția eșantioanelor pentru cele două abordări folosind diferite seturi de date.

Abordare	Clasă	Instruire	Validare	Testare
EEGMMIDB	Clasa 1 (B)	30000	1000	1000
	Clasa 2 (S)	30000	1000	1000
	Clasa 2 (P)	30000	1000	1000
	Clasa 4 (D)	30000	1000	1000
Local	Clasa 1 (B)	921	116	115
	Clasa 2 (S)	921	115	116
	Clasa 2 (P)	922	115	115
	Clasa 4 (D)	922	115	115

Procedura de antrenare a inclus implementarea unor măsuri pentru a garanta o reprezentare echitabilă a celor patru clase alese. Atât setul de validare, cât și cel de testare au fost alese în așa fel încât să existe distribuții echilibrate ale claselor și a fost utilizată tehnica supra-eșantionării, pentru clasele cu mai puține date, ceea ce a dus la o alocare mai echilibrată de 30000 de eșantioane pentru fiecare clasă, pentru antrenare, după cum reiese și din tabelul 5.9.

În cele ce urmează sunt prezentate cele mai ridicate performanțe obținute cu rețeaua *Improved-Net2* cu performanțe ridicate folosind setul de date EEGMMIDB și setul de date local. Ambele rezultă în acuratețe ridicată de peste 90%. După obținerea rezultatelor promițătoare în prima abordare, procesul de validare s-a concentrat pe un set de date local achiziționat de autor, cu o distribuție echilibrată a claselor și un număr total de 3688 de eșantioane pentru antrenare și 461 pentru validare.

¹Disponibil la adresa <https://physionet.org/content/eegmmidb/1.0.0/>

Tabel 5.10: Rezultatele arhitecturii *ImprovedNet2* folosind setul de date EEGMMIDB.

Clasă	Precizie	Recall	Scorul F1	Suport
Clasa 1 (B)	0,95	0,97	0,96	1000
Clasa 2 (S)	1,00	0,98	0,99	1000
Clasa 2 (P)	0,96	0,97	0,97	1000
Clasa 4 (D)	0,99	0,98	0,98	1000
Acuratețe			0,97	4000
Medie	0,97	0,97	0,97	4000
Medie Pond.	0,97	0,97	0,97	4000

Tabel 5.11: Rezultatele arhitecturii *ImprovedNet2* folosind setul de date local.

Clasă	Precizie	Recall	Scorul F1	Suport ¹
Clasa 1 (B)	0,92	0,90	0,91	115
Clasa 2 (S)	0,96	0,94	0,95	116
Clasa 2 (P)	0,94	0,89	0,91	115
Clasa 4 (D)	0,87	0,96	0,91	115
Acuratețe			0,9197	461
Medie	0,92	0,92	0,92	461
Medie Pond.	0,92	0,92	0,92	461

¹ Aceasta coloană indică numărul de instanțe din fiecare clasă care au fost utilizate pentru a calcula aceste metrice.

Rezultatele rețelei *ImprovedNet2* prezentate în tabelul 5.11 prezintă indicatorii de performanță ai diferitelor clase. Dintre acestea, clasa „S” a obținut cea mai mare precizie de 0,96 și cea mai mare valoare de *Recall* de 0,94, rezultând un scor F1 impresionant de 0,95. Pe de altă parte, clasa „D” a demonstrat o valoare de *Recall* remarcabilă de 0,96, în timp ce clasa „B” a prezentat valori echilibrate de precizie și *Recall*, contribuind la o precizie globală de 0,9197 pentru toate clasele.

Tabel 5.12: Compararea acurateței și a scorului F1 a diferitelor arhitecturi.

Arhitectură	Precizie	Scorul F1
ImprovedNet2	0,91	0,92
ImprovedNet3	0,88	0,88
EEGNetSSVEP	0,83	0,82
EEGNet	0,90	0,90
ImprovedNet	0,85	0,85
DeepConvNet	0,78	0,78

În concluzie, în tabelul 5.12 se prezintă o comparație succintă a preciziei și a valorilor scorului F1 pentru diferite arhitecturi de rețele neuronale în contextul experimentului local. În special, arhitectura *ImprovedNet2* prezintă o acuratețe ridicată de 0,9197, însoțită de un scor F1 de 0,92. Rețeaua *ImprovedNet* este un clasificator fiabil pentru semnalele EEG, prezentând o precizie, un scor F1 și o acuratețe superioare, ceea ce îl face o alegere puternică pentru această sarcină de clasificare specifică.

5.2.7 Considerații finale

În ultimii ani, interesul pentru utilizarea învățării automate în tehnologiile de asistență, inclusiv pentru persoanele cu nevoi speciale, a crescut semnificativ. Semnalele EEG furnizează informații valoroase, permițând clasificarea sarcinilor efectuate sau imaginate de pacienți și facilitează dezvoltarea diverselor aplicații. Prin decodificarea semnalelor produse de creier se pot crea aplicații ce pot îmbunătăți interacțiunea persoanelor cu nevoi speciale cu mediul înconjurător, să le sporească mobilitatea și, în final, să le crească independența. Ca și aplicații reale se poate oferi ca exemplu controlul noninvaziv al unui scaun cu roțile sau comunicarea cu cei din exterior în cazul unui accident de pierdere a mobilității.

În cadrul acestei secțiuni au fost abordate aplicațiile inteligenței artificiale în clasificarea sarcinilor motorii, având un impact semnificativ în îmbunătățirea vieții persoanelor cu nevoi speciale. S-a dezvoltat un sistem flexibil pentru tranziția între diferite arhitecturi de rețele neuronale convoluționale. S-au făcut experimente pe baze de date consacrate și s-au creat anumite experimente locale. Aceste teste au condus la explorarea unor noi abordări și la propunerea și dezvoltarea unor noi arhitecturi de rețele neuronale artificiale, obținând procente semnificative de acuratețe. Contribuțiile aduse au un impact semnificativ în domeniul cercetării EEG și al inteligenței artificiale în special în ceea ce privește persoanele cu probleme locomotorii.

Capitolul 6

Concluzii generale

În peisajul tehnologic cotidian, inteligența artificială (IA) a apărut ca o forță de transformare, remodelând societatea și îmbunătățind calitatea vieții. În contextul acestei revoluții tehnologice, este esențial să acordăm o atenție deosebită și persoanelor cu nevoi speciale, cum ar fi vârstnicii, cei cu mobilitate redusă sau cu diverse dizabilități și afecțiuni medicale. Utilizarea tehnicilor de IA are potențialul de a aduce beneficii majorității, dar și să îmbunătățească viața celor cu nevoi speciale. Explorarea tehnologiilor de *edge computing* pe dispozitive de putere redusă are potențialul de a îmbunătăți domenii precum robotică, dispozitive medicale și asistență personalizată, dar rămân încă aspecte nerezolvate.

Pe parcursul tezei, au fost prezentate o serie de abordări pentru câteva dintre obstacolele existente. Aceste abordări fac referire la dezvoltarea și implementarea unor soluții inteligente sub forma unui robot autonom de asistență multifuncțională sau la soluții ce folosesc tehnologii noninvazive precum EKG sau EEG. De asemenea, prin clasificarea semnalelor EEG se poate efectua „citirea gândurilor” și putem reda capacitatea de comunicare sau locomoție celor ce au probleme motrice. Toate aceste soluții pot fi implementate pe dispozitive eficiente din punct de vedere energetic.

6.1 Realizarea obiectivelor și contribuții originale

Această secțiune evidențiază îndeplinirea cu succes a obiectivelor descrise prin intermediul unui efort susținut de valorificarea IA pentru a răspunde cerințelor persoanelor cu nevoi speciale și care constituie, de fapt, și obiectivul general așa cum a fost prezentat în secțiunea 1.3. Obiectivele de investigare a arhitecturilor rețelelor neuronale, de creare a unor soluții personalizate și de dezvoltare a unor tehnologii adaptabile au fost urmărite cu rigurozitate, făcând posibile progrese tangibile care au un impact pozitiv asupra vieții acestei categorii de persoane.

Astfel, obiectivul OS1 a fost îndeplinit prin următoarele realizări și contribuții originale:

- Realizarea unei analize complexe a stadiului actual al arhitecturilor de rețele neuronale artificiale și tehnologii IA adaptate nevoilor speciale ale anumitor categorii;
- Identificarea avantajelor și evidențierea impedimentelor actuale atât în cadrul persoanelor cu nevoi speciale cât și a aplicării tehnicilor de IA asupra acestei categorii. Prin aceasta se dorește

avansarea aplicațiilor medicale prin intermediul IA, aliniindu-se în același timp la nevoile specifice anumitor grupuri cu anumite afecțiuni.

Obiectivul OS2 a fost îndeplinit prin următoarele realizări și contribuții originale:

- Dezvoltarea unui sistem de procesare eficientă a seriilor temporale utilizând tehnici de inteligență artificială și *edge computing* pe dispozitive de consum redus. Acest sistem are potențialul de a îmbunătăți semnificativ calitatea vieții persoanelor cu nevoi speciale în aplicațiile în care seriile temporale sunt predominante:
 - Propunerea și implementarea unei arhitecturi de rețea neuronală artificială în scopul detectării anomaliilor în seriile temporale folosind o rețea de tipul *Autoencoder* îmbunătățită cu metode de clasificare clasice cu scopul rulării pe dispozitive de putere redusă. În urma antrenării și validării, acest model neuronal a obținut performanțe ridicate, de peste 80% și este un demonstrator în rularea algoritmilor de inteligență artificială și detecția anomaliilor din seriile temporale pe dispozitive *edge computing*;
 - Propunerea și implementarea unui sistem embedded pentru migrarea aplicațiilor de inteligență artificială de pe o infrastructură de servere energointensive pe dispozitive de consum redus cât mai aproape de sursa generatoare de date. Implementarea acestui sistem de procesare inteligentă și descentralizată a seriilor temporale, prezintă beneficii precum confidențialitatea crescută și latența redusă a datelor, diminuarea lățimii de bandă și reducerea costurilor suplimentare. Sistemul poate avea și aplicații medicale, furnizând specialiștilor date precise, în timp real, despre semnalele cerebrale sau musculare și ritmul cardiac sau cel respirator.
- Propunerea de șase noi beneficii ce pot fi aduse pentru îmbunătățirea calității vieții persoanelor cu nevoi speciale. Prin procesarea eficientă a seriilor temporale utilizând tehnici de inteligență artificială și *edge computing* pe dispozitive de putere redusă se deschid perspective importante în domeniul soluțiilor accesibile personalizate, al asistenței medicale permanente, al monitorizării și interpretării datelor, al autonomiei, securității și confidențialității;
- Proiectarea și dezvoltarea unui sistem robotic multifuncțional de asistență care rulează cu ajutorul tehnologiilor de *edge computing* și inteligență artificială, pentru a sprijini anumite categorii vulnerabile. Acest robot poate oferi și alte servicii-suport în diverse domenii precum asistența personalizată, monitorizarea mediului, mijloc de locomoție virtual și educație:
 - Propunerea și implementarea unui sistem modularizat ce decuplează partea de control (cea logică) de cea fizică a robotului prin îmbinarea diferitelor tehnologii, ce rulează pe dispozitive de consum redus. Această soluție oferă o platformă eficientă și ușor de utilizat eliminând necesitatea cunoașterii detaliate a hardware-ului specific în logica de control. Sistemul are la bază o arhitectură software în care s-au folosit diferite programe și fire de execuție rulate pe

cele două unități distincte. Acest sistem s-a concretizat prin realizarea unui sistem robotic multifuncțional de asistență în sprijinul anumitor categorii vulnerabile conceput cu scopul extinderii de noi servicii în beneficiul categoriei anterior menționate;

- Propunerea și implementarea unui sistem de detecție și siguranță dual și redundant, folosind tehnici de inteligență artificială îmbinate cu datele de la senzori specifici pentru detectarea animalelor și a persoanelor. Totodată acest sistem oferă statistici referitoare la obiectele din jur și descrie mediul în care se află. Acesta asigură un nivel sporit de siguranță în funcționarea robotului în medii diverse și poate sprijini anumite categorii de persoane pentru îmbunătățirea calității vieții acestora.

- Propunerea de șase noi aplicații pentru sistemele robotice autonome de asistență pentru oferi sprijin persoanelor cu nevoi speciale, deschizând perspective importante în domeniul asistenței, al monitorizării, al educației, al mijlocului de locomoție virtual și al incluziunii sociale;

Obiectivul OS3 a fost îndeplinit prin următoarele realizări și contribuții originale:

- Dezvoltarea unui sistem de învățare profundă pentru detecția și clasificarea aritmiilor pentru persoanele cu afecțiuni cardiace. Acest sistem poate oferi și suport medicilor în identificarea aritmiilor cardiace, având un impact pozitiv asupra practicii clinice:

- Proiectarea și implementarea unei arhitecturi pentru o rețea neuronală convoluțională (CNN) folosind eșantioane din baze medicale consacrate adnotate de medici cardiologi. În urma antrenării și validării, acest model neuronal a obținut performanțe ridicate, de până la 98,05%;
- Propunerea unei metode inedite de utilizare a rețelelor neuronale artificiale 2D de învățare profundă, pentru detectarea și clasificarea aritmiilor cardiace din datele electrocardiogramelor (EKG) cu ajutorul transformărilor Wavelet, Morlet și B-Spline. Această soluție sporește eficacitatea metodei anterioare, iar în urma antrenării și validării, performanțele obținute au crescut până la 99,38%.

- Dezvoltarea unui sistem de învățare profundă pentru clasificarea sarcinilor motorii provenite din semnalele encefalografice:

- Elaborarea mai multor experimente în domeniul persoanelor cu nevoi speciale, al căror scop principal a fost interpretarea semnalelor provenite de la encefalograf. Ulterior, cu ajutorul tehnicilor de inteligență artificială, se pot crea aplicații pentru a îmbunătăți viața persoanelor cu anumite deficiențe;
- Propunerea și dezvoltarea a patru noi arhitecturi de rețele neuronale convoluționale ce pot fi utilizate în clasificarea semnalelor EEG. În urma antrenării și validării, aceste rețele au obținut performanțe ridicate de până la 91%;

- Testarea și validarea arhitecturilor propuse anterior în diverse scenarii din baze de date consacrate (*EEG Motor Movement/Imagery Dataset*) cât și pe eșantioanele achiziționate local, demonstrând astfel eficacitatea acestor rețele.
- Realizarea unui script software pentru adnotarea automată a semnalelor EEG, dar și a videoclipurilor aferente, contribuind la analiza și îmbunătățirea etapei de preprocesare a datelor;
- Proiectarea, dezvoltarea și elaborarea un sistem flexibil, inovativ, pentru a asigura tranziția între diferite arhitecturi de rețele neuronale artificiale convoluționale facilitând antrenarea, testarea, validarea și alegerea modelelor cu performanțe ridicate.

În concluzie, această teză și-a atins cu succes obiectivul general de a utiliza tehnologii de inteligență artificială pentru a sprijini și îmbunătăți viața persoanelor cu nevoi speciale.

Explorând subiecte de cercetare specifice, cum ar fi detectarea și clasificarea aritmiilor cardiace folosind metode inovative și procesarea eficientă a seriilor temporale cu ajutorul tehnologiei de inteligență artificială pe dispozitive edge computing, s-au adus contribuții semnificative în domeniu. De asemenea, crearea unui sistem robotic autonom de asistență versatil, cu perspective de extindere către noi servicii, și clasificarea semnalelor EEG au adus valoare adăugată în această cercetare.

Toate aceste direcții de dezvoltare pot fi privite ca o simbioză, în care elementele individuale contribuie la formarea unui sistem complex, menit să ofere sprijin și beneficii semnificative pentru categoriile de persoane cu nevoi speciale.

6.2 Direcții viitoare de cercetare

Teza prezentată deschide posibilități pentru viitoarele direcții de cercetare în domeniul utilizării tehnologiei și a inteligenței artificiale pentru a sprijini persoanele cu nevoi speciale. Astfel, următoarele domenii prezintă oportunități de explorare și îmbunătățire continuă:

- **Diagnosticare medicală avansată prin integrarea dispozitivelor inteligente** – se referă la dezvoltarea de algoritmi ce pot rula dispozitive portabile pentru diagnosticarea și altor afecțiuni medicale. Una dintre direcțiile posibile poate implica adaptarea algoritmului pentru a funcționa pe telefoane sau ceasuri inteligente, permițând persoanelor cu astfel de afecțiuni să detecteze într-un stadiu incipient eventualele probleme, evitând astfel agravarea stării de sănătate. O altă direcție este integrarea acestui sistem în dispozitive medicale, cum ar fi holterele EKG, ce pot ajuta personalul medical în identificarea rapidă a problemelor atunci când trebuie analizate date pe o perioadă mai lungă de timp. Extinderea capacităților algoritmului pentru a detecta și îmbunătăți viața pacienților cu diverse afecțiuni medicale este o altă direcție promițătoare. Cercetările viitoare ar putea implica antrenarea algoritmului pe o gamă mai largă de aritmii și utilizarea unor tehnici precum SMOTE (descrisă în secțiunea 2.1.4.4) pentru a genera mostre pentru afecțiuni mai rar întâlnite;

- ▣ **Sisteme îmbunătățite pentru procesarea eficientă a seriilor temporale** pe dispozitivele de putere redusă cât mai aproape de sursa generatoare de date. Se poate explora utilizarea diferiților algoritmi de inteligență artificială, precum LSTM, pentru a evalua performanța acestora în contexte variate. De asemenea, se poate avansa în dezvoltarea de modele compacte, menite să testeze eficient scenarii noi, și în integrarea cipurilor specializate de inteligență artificială în infrastructura de *edge computing*, cu scopul de a permite detectarea în timp real a anomaliilor în aplicațiile critice. Această abordare reprezintă o direcție promițătoare pentru cercetare;
- ▣ **Dezvoltarea sistemelor robotice de asistență multifuncționale prin extinderea serviciilor existente**, acoperind o gamă largă de domenii, inclusiv furnizarea de asistență personalizată, stimularea angajamentului social, educație și monitorizarea mediului pentru pacienții specifici, ce au fost descrise și în secțiunea 4.2.2. O altă direcție este încorporarea de noi senzori și actuatori sau modernizarea unității centrale de procesare pentru o putere de calcul mai mare ce poate îmbunătăți capacitățile robotului procesând algoritmi mai complecși de inteligență artificială;
- ▣ **Progrese în clasificarea semnalelor EEG**, oferind un domeniu de cercetare complex și multidimensional, cu numeroase aplicații potențiale. Cercetările viitoare pot explora extinderea domeniului de aplicare, de exemplu, permițând persoanelor să tasteze pe tastaturi virtuale sau să comunice cu alte persoane fără mișcare fizică. Un alt exemplu poate fi adăugarea mai multor clase ce corespund mai multor acțiuni și utilizarea de echipamente performante cu mai mulți electrozi și stagii de amplificare sau filtrare mai bună ce vor realiza un sistem mult mai robust. O altă direcție importantă este achiziția și validarea rezultatelor, reflectată în aplicațiile reale. De exemplu, în cazuri de deficiențe locomotorii la persoane în vârstă se poate implementa un scaun cu roțile controlat prin interpretarea semnalelor EEG. În plus, se dorește o procesare în timp real a datelor EEG pe dispozitive cu consum redus de energie, cum ar fi căștile EEG, ajungând la soluții mai eficiente și mai accesibile pentru persoanele cu nevoi speciale.

6.3 Diseminarea rezultatelor cercetării

Această secțiune oferă o analiză a inițiativelor de diseminare implementate pe parcursul programului de doctorat. Rezultatele cercetării au fost valorificate, validate și diseminate prin implicarea activă în diverse conferințe internaționale, precum și prin publicații în reviste naționale și internaționale, ca autor principal sau colaborator. Calitatea de coordonator în cadrul mai multor proiecte de cercetare subliniază poziția de lider a autorului și ilustrează angajamentul său de a împărtăși expertiza sa. Totodată, cunoștințele autorului au fost consolidate prin participarea la numeroase ateliere de lucru sau conferințe din domeniu.

6.3.1 Lista de publicații

- **D.-V. Bratu**, R.Ș.T. Ilinoiu, A. Cristea, M.-A. Zolya, S.-A. Moraru, „**Anomaly Detection Using Edge Computing AI on Low Powered Devices**”, IFIP Advances in Information and Communication Technology (Book series), Vol. 646 IFIP, 18th IFIP WG 12.5 **Int. Conf. on Artificial Intelligence Applications and Innovations, AIAI 2022, Hersonissos, Grecia, 2022**, pag. 96 – 107. (Scopus, DOI: 10.1007/978-3-031-08333-4_8);
- **D.-V. Bratu**, M.-A. Zolya, S.-A. Moraru, „**A Different View on Artificial Intelligence Applications for Cardiac Arrhythmia Detection and Classification**”, Book Series: Lecture Notes in Networks and Systems, Vol. 298, Proceedings of the 18th **International Conference on Remote Engineering and Virtual Instrumentation REV2022, Hongkong, 2022**, pag. 415 – 427. (ISI Web of Science, Scopus, DOI: 10.1007/978-3-030-82529-4_41);
- **D.-V. Bratu**, S.-A. Moraru, L.G. Gușeală, „**A Performance Comparison between Deep Learning Network and Haar Cascade on an IoT Device**”, **Lisabona, Portugalia, 2019 International Conference on Sensing and Instrumentation in IoT Era (ISSI)**
doi:10.1109/issi47111.2019.9043714;
- A.F. Popov, D.M. Kristaly, **D.-V. Bratu**, M.-A. Zolya, S.-A. Moraru, „**A Method for Using GSM Technology and SCADA Systems to Monitor and Control Decommissioned and Partially Decommissioned Railway Stations**”, **2023, Applied Sciences**, 13 (8), 4874,
doi: 10.3390/app13084874;
- L.G. Gușeală, **D.-V. Bratu**, S.-A. Moraru, „**Continuous Testing in the Development of IoT Applications**”, **2019 International Conference on Sensing and Instrumentation in IoT Era (ISSI), Lisabona, Portugalia, 2019**, pp. 1-6, doi: 10.1109/ISSI47111.2019.9043692;
- A.F. Popov, **D.-V. Bratu**, S.-A. Moraru, „**Remote Control of Railway Switch Heating Using GSM Modems**”, The Annals of “Dunarea de Jos” University of Galati. Fascicle IX, **Metallurgy and Materials Science 42 1, 2019**, 42–47. Remote Control of Railway Switch Heating Using GSM Modems;
- L.G. Gușeală, **D.-V. Bratu**, S.-A. Moraru, „**DevOps Transformation for Multi-Cloud IoT Applications**”, **2019 International Conference on Sensing and Instrumentation in IoT Era (ISSI), Lisabona, Portugalia, 2019**, doi: 10.1109/ISSI47111.2019.9043730.

6.3.2 Coordonator, concursuri și participarea la sesiuni științifice

- **Coordonator științific**, Sesiunea Cercurilor Științifice Studentești, anul **2019**, titlul proiectului „**Wall-e, intervention tank**”, secțiunea **ROBO**, locație **Institutul de Cercetare Dezvoltare Brașov**, studenți **Mădălin-Andrei Sava** (anul III - AIA) și **Petruț Condrea** (anul III – ROBO);

- ❑ **Coordonator științific**, Sesiunea Cercurilor Științifice Studentești, anul **2019**, titlul proiectului „**Ma-ilo**”, secțiunea **TI**, locație **Institutul de Cercetare Dezvoltare Brașov**, student **Nicolae Iosif**, (anul III - AIA);
- ❑ **Coordonator științific**, Sesiunea Cercurilor Științifice Studentești, anul **2021**, titlul proiectului „**RoboCovCleaner**”, secțiunea **SAATI**, locație **Institutul de Cercetare Dezvoltare Brașov**, studenți **Maria-Alexandra Zolya**, (anul I – SAATI) și **Ana-Maria Andrei** (anul I – SAATI);
- ❑ **Coordonator științific**, Sesiunea Cercurilor Științifice Studentești, anul **2022**, titlul proiectului „**Sistem pentru automatizarea procesului de sterilizare în spațiile interioare - RoboCovCleaner**”, secțiunea **SAATI**, locație **Institutul de Cercetare Dezvoltare Brașov**, studenți **Maria-Alexandra Zolya** (anul II – SAATI) și **Ana-Maria Andrei** (anul II – SAATI);
- ❑ **Coordonator științific**, Proiect de **disertație**, anul **2022**, titlul lucrării „**Sistem pentru automatizarea procesului de sterilizare în spațiile interioare - RoboCovCleaner**”, Facultatea de Inginerie electrică și știința calculatoarelor Programul de studii **SAATI**, studenți **Maria-Alexandra Zolya** (anul II – SAATI) și **Ana-Maria Andrei** (anul II – SAATI);
- ❑ **Coordonator științific**, Proiect de **disertație** și proiect în cadrul evenimentului **Absolvenții în Fața Companiilor - AFCO** , anul **2021**, titlul lucrării „**Tehnici de Machine Learning Aplicate in Smart Home si IoT**”, Facultatea de Inginerie electrică și știința calculatoarelor, Departamentul **EC**, Programul de studii **SECI**, student **Alexandru Cristea** (anul II – SECI);
- ❑ **Coordonator științific**, Proiect de **licență** și proiect în cadrul evenimentului **Absolvenții în Fața Companiilor - AFCO** , anul **2021**, titlul lucrării „**Tehnici de Machine Learning Aplicate in Smart Home si IoT**”, Facultatea de Inginerie electrică și știința calculatoarelor, Departamentul **ATI**, Programul de studii **TI**, student **Rareș Ștefan Tiberius Ilinoiu** (anul IV – TI).

6.3.3 Participarea la conferințe de domeniu

- ❑ **Prezentator tehnic** al temei „**Inteligența artificială și noile tehnologii în viața noastră de zi cu zi**” în cadrul conferinței „**Future Summit Brașov**”. Data **30.03.2023**, locație **Brașov, România**;
- ❑ **Coordonator și participant al echipei de lucru „RoboCovCleaner”**, împreună cu doi studenți, pentru dezvoltarea și implementarea robotului „**RoboCovCleaner**”, din cadrul programului „**Fii în centru!**”, anul **2020-2021**, locație **Brașov, România**;
- ❑ **Participant** în cadrul summit-ului de specialitate al inovației „**Bucharest tech week - Inovation Summit**”. Teme abordate: IA, CleanTech, Wearables, Sustainability, IoT, Web3, și robotică, anul **2023**, locație **București, România**;

- ❑ **Coordonator tehnic** atelier practic „**MMWM - Miele - Mini Washing Machine**”, data **12.02.2020**, locație **Facultatea de Electronică, Telecomunicații și Tehnologia Informației, UPB, București, România;**
- ❑ **Coordonator tehnic** atelier de lucru pentru studenți în cadrul evenimentului **BuzzCamp**, data **20.11.2018**, locație **Hotel Ambient Brașov, România;**
- ❑ **Coordonator tehnic** la atelier de lucru pentru studenți în cadrul evenimentului **BuzzCamp**, tema „**Connect to Miele Smart World – Creează-ți propria mașina de spălat smart**”, data **19.11.2019**, locație **Hotel Ambient Brașov, România;**
- ❑ **Participant** la **atelierul de lucru** organizat în cadrul conferinței „**Future co-creation exercise**”. Obiectiv: discuții despre sustenabilitate, noile tehnologii și viitorul orașului Brașov. Data **30.03.2023**, locație **Brașov, România;**
- ❑ **Participant** în cadrul **conferinței** de specialitate de dezvoltare software și tehnologii de inteligență artificială „**DevTalks 2022**”. Data **08.06.2022-10.06.2022**, locație **hibrid, online-fizic (București, România);**
- ❑ **Participant** în cadrul **conferinței** de specialitate „**Romanian AI Days 2023**”. Data **20.09.2023-21.09.2023**, locație **Brașov, România);**
- ❑ **Participant** în cadrul **conferinței** de specialitate de dezvoltare software și tehnologii de inteligență artificială „**DevTalks Reimagined 2021**”. Data **09.06.2021-11.06.2021**, locație **online;**
- ❑ **Participant** în cadrul **conferinței** de specialitate de dezvoltare topic „**Artificial Intelligence: The Future of Software**”, data **06.06.2019**, locație **București, România;**
- ❑ **Participant** în cadrul **conferinței** de specialitate pentru dispozitive de consum redus „**Embedded world 2022**”. Data **21.06.2022-23.06.2022**, locație **Nuremberg, Germania;**
- ❑ **Prezentator** în cadrul sesiunii „**Parteneriat strategic între Universitate și industria electronică**” în cadrul conferinței și expoziției **IEEE 25th International Symposium for Design and Technology in Electronic Packaging SIITME**, data **23-26.11.2019**, locație **Cluj, România;**
- ❑ **Participant conferință** de specialitate în domeniul tehnologiilor de inteligență artificială și tehnologii Cloud, în cadrul conferinței „**Google Cloud Day**”, data **12.11.2019**, locație **București, România.**

Referințe

- [1] R. Neamtu, A. Camara, C. Pereira, and R. Ferreira, "Using artificial intelligence for augmentative alternative communication for children with disabilities," in *Human-Computer Interaction–INTERACT 2019: 17th IFIP TC 13 International Conference, Paphos, Cyprus, September 2–6, 2019, Proceedings, Part I* 17, pp. 234–243, Springer, 2019.
- [2] M. Coeckelbergh, "Health care, capabilities, and AI assistive technologies," *Ethical theory and moral practice*, vol. 13, pp. 181–190, 2010.
- [3] C. Morrison, E. Cutrell, A. Dhareshwar, K. Doherty, A. Thieme, and A. Taylor, "Imagining artificial intelligence applications with people with visual disabilities using tactile ideation," in *Proceedings of the 19th international acm sigaccess conference on computers and accessibility*, pp. 81–90, 2017.
- [4] L. Aspen and G. Wolbring, "Coverage of ethics within the artificial intelligence and machine learning academic literature: The case of disabled people," *Assistive Technology*, 2019.
- [5] World Health Organization, "Disability." <https://www.who.int/news-room/fact-sheets/detail/disability-and-health>, 2023. [Online].
- [6] P. Jenkins and M. Muller, "AI Fairness for People with Disabilities." https://researcher.watson.ibm.com/researcher/view_group.php?id=9666, 2019. [Online].
- [7] J. Snowthursday, "How People with Disabilities Are Using AI to Improve Their Lives." <https://www.pbs.org/wgbh/nova/article/people-with-disabilities-use-ai-to-improve-their-lives>, 2019. [Online].
- [8] M. Stone, E. Aravopoulou, Y. Ekinci, G. Evans, M. Hobbs, A. Labib, P. Laughlin, J. Machtynger, and L. Machtynger, "Artificial intelligence (AI) in strategic marketing decision-making: a research agenda," *The Bottom Line*, vol. 33, no. 2, pp. 183–200, 2020.
- [9] Eurostat, "Archive:disability statistics - labour market access." https://ec.europa.eu/eurostat/statistics-explained/index.php?title=Disability_statistics_-_labour_market_access&oldid=411116, 2018. [Online].
- [10] J. Roach, "The Power of Technology for People with Disabilities." <https://news.microsoft.com/source/features/work-life/the-power-of-technology-for-people-with-disabilities/>, 2023. [Online].
- [11] A. D. Babu, "Artificial Intelligence vs machine learning vs deep learning (AI vs ML VS DL)." <https://link.medium.com/qiXuou0dxCb>, 2019. [Online].

- [12] R. E. Wright, "Logistic regression.," *Reading and understanding multivariate statistics*, pp. 217–244, 1995.
- [13] G. Guo, H. Wang, D. Bell, Y. Bi, and K. Greer, "KNN model-based approach in classification," in *On The Move to Meaningful Internet Systems 2003: CoopIS, DOA, and ODBASE: OTM Confederated International Conferences, CoopIS, DOA, and ODBASE 2003, Catania, Sicily, Italy, November 3-7, 2003. Proceedings*, pp. 986–996, Springer, 2003.
- [14] Y.-Y. Song and L. Ying, "Decision tree methods: applications for classification and prediction," *Shanghai archives of psychiatry*, vol. 27, no. 2, p. 130, 2015.
- [15] W. S. Noble, "What is a support vector machine?," *Nature biotechnology*, vol. 24, no. 12, pp. 1565–1567, 2006.
- [16] G. I. Webb, E. Keogh, and R. Miikkulainen, "Naive Bayes.," *Encyclopedia of machine learning*, vol. 15, pp. 713–714, 2010.
- [17] L. P. Kaelbling, M. L. Littman, and A. W. Moore, "Reinforcement learning: A survey," *Journal of artificial intelligence research*, vol. 4, pp. 237–285, 1996.
- [18] M. H. Vrejoiu, "Deep Reinforcement Learning. Studiu de caz: Deep Q-Network," *Romanian Journal of Information Technology & Automatic Control/Revista Română de Informatică și Automatică*, vol. 29, no. 3, 2019.
- [19] F. Rosenblatt, "The perceptron: a probabilistic model for information storage and organization in the brain," *Psychological review*, vol. 65, no. 6, p. 386, 1958.
- [20] H. Taud and J. Mas, "Multilayer perceptron (MLP)," *Geomatic approaches for modeling land change scenarios*, pp. 451–455, 2018.
- [21] L. Noriega, "Multilayer perceptron tutorial," *School of Computing. Staffordshire University*, vol. 4, p. 5, 2005.
- [22] B. Gao and L. Pavel, "On the properties of the softmax function with application in game theory and reinforcement learning," *arXiv preprint arXiv:1704.00805*, 2017.
- [23] N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever, and R. Salakhutdinov, "Dropout: a simple way to prevent neural networks from overfitting," *The journal of machine learning research*, vol. 15, no. 1, pp. 1929–1958, 2014.
- [24] H. Gholamalinezhad and H. Khosravi, "Pooling methods in deep neural networks, a review," *arXiv preprint arXiv:2009.07485*, 2020.
- [25] N. Murray and F. Perronnin, "Generalized max pooling," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 2473–2480, 2014.
- [26] Computer Science Wiki, "Max-pooling/Pooling." https://computersciencewiki.org/index.php/Max-pooling/_/_Pooling, 2021. [Online].
- [27] M. Yani, M. Budhi Irawan, Si, and C. Setiningsih, "Application of transfer learning using convolutional neural network method for early detection of terry's nail," in *Journal of Physics: Conference Series*, vol. 1, IOP Publishing, 2019.
- [28] A. Shrestha and A. Mahmood, "Review of deep learning algorithms and architectures," *IEEE ac-*

- cess, vol. 7, pp. 53040–53065, 2019.
- [29] K. Janocha and W. M. Czarnecki, "On loss functions for deep neural networks in classification," *arXiv preprint arXiv:1702.05659*, 2017.
- [30] H. Zhao, O. Gallo, I. Frosio, and J. Kautz, "Loss functions for image restoration with neural networks," *IEEE Transactions on computational imaging*, vol. 3, no. 1, pp. 47–57, 2016.
- [31] H. Zhao, O. Gallo, I. Frosio, and J. Kautz, "Loss functions for neural networks for image processing," *arXiv preprint arXiv:1511.08861*, 2015.
- [32] L. Yang and A. Shami, "On hyperparameter optimization of machine learning algorithms: Theory and practice," *Neurocomputing*, vol. 415, pp. 295–316, 2020.
- [33] H. Jiang and O. Nachum, "Identifying and correcting label bias in machine learning," in *International Conference on Artificial Intelligence and Statistics*, pp. 702–712, PMLR, 2020.
- [34] A. Yapó and J. Weiss, "Ethical implications of bias in machine learning," *Proceedings of the 51st Hawaii International Conference on System Sciences*, 2018.
- [35] T. Hellström, V. Dignum, and S. Bensch, "Bias in Machine Learning—What is it Good for?," *arXiv preprint arXiv:2004.00686*, 2020.
- [36] L. Liu, H. Jiang, P. He, W. Chen, X. Liu, J. Gao, and J. Han, "On the variance of the adaptive learning rate and beyond," *arXiv preprint arXiv:1908.03265*, 2019.
- [37] A. Ng, "Deep learning specialization." <https://www.coursera.org/specializations/deep-learning>, 2017. [Online].
- [38] A. Lydia and S. Francis, "Adagrad—an optimizer for stochastic gradient descent," *Int. J. Inf. Comput. Sci.*, vol. 6, no. 5, pp. 566–568, 2019.
- [39] Z. Zhang, "Improved adam optimizer for deep neural networks," in *2018 IEEE/ACM 26th international symposium on quality of service (IWQoS)*, pp. 1–2, IEEE, 2018.
- [40] V. Chawla, K. Bowyer, L. Hall, and P. Kegelmeyer, "SMOTE: synthetic minority over-sampling technique," *Journal of artificial intelligence research*, vol. 16, pp. 321–357, 2002.
- [41] M. Teplan *et al.*, "Fundamentals of EEG measurement," *Measurement science review*, vol. 2, no. 2, pp. 1–11, 2002.
- [42] B. Lim and S. Zohren, "Time-series forecasting with deep learning: a survey," *Philosophical Transactions of the Royal Society A*, vol. 379, no. 2194, p. 20200209, 2021.
- [43] J. C. B. Gamboa, "Deep learning for time-series analysis," *arXiv preprint:1701.01887*, 2017.
- [44] Y. Roy, H. Banville, I. Albuquerque, A. Gramfort, T. H. Falk, and J. Faubert, "Deep learning-based electroencephalography analysis: a systematic review," *Journal of neural engineering*, 2019.
- [45] G. B. Young, C. F. Bolton, Y. M. Archibald, T. W. Austin, and G. A. Wells, "The electroencephalogram in sepsis-associated encephalopathy," *Journal of Clinical Neurophysiology*, vol. 9, no. 1, 1992.
- [46] D. Alvarez-Estevéz, "EDF+ and EDF specifications and guidelines." <https://edfplus.info/>, 2023. [Online].
- [47] T. Beelen, "EDF Browser." <https://www.teuniz.net/edfbrowser/>, 2021. [Online].
- [48] E. Lashgari, J. Ott, A. Connelly, P. Baldi, and U. Maoz, "An end-to-end CNN with attentional me-

- chanism applied to raw EEG in a BCI classification task," *Journal of Neural Engineering*, vol. 18, no. 4, p. 0460e3, 2021.
- [49] J. Long, Y. Li, H. Wang, T. Yu, J. Pan, and F. Li, "A hybrid brain computer interface to control the direction and speed of a simulated or real wheelchair," *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 20, no. 5, pp. 720–729, 2012.
- [50] N. Kobayashi and M. Nakagawa, "BCI-based control of electric wheelchair," in *2015 IEEE 4th Global Conference on Consumer Electronics (GCCE)*, pp. 429–430, IEEE, 2015.
- [51] S. H. Lim, H. Nisar, K. W. Thee, and V. V. Yap, "A novel method for tracking and analysis of EEG activation across brain lobes," *Biomedical Signal Processing and Control*, 2018.
- [52] M. Strotzer, "One century of brain mapping using Brodmann areas," *Clinical Neuroradiology*, vol. 19, no. 3, p. 179, 2009.
- [53] P. E. Rasser, P. J. Johnston, P. B. Ward, and P. M. Thompson, "A deformable Brodmann area atlas," in *2004 2nd IEEE International Symposium on Biomedical Imaging: Nano to Macro*, pp. 400–403, IEEE, 2004.
- [54] K. Sukel, "Neuroanatomy the basics." <https://www.dana.org/article/neuroanatomy-the-basics/>, 2022. [Online].
- [55] K. Brodmann, "Vergleichende Lokalisationslehre der Grosshirnrinde in ihren Prinzipien dargestellt auf Grund des Zellenbaues," *Barth*, 1909.
- [56] L. J. Hirsch and R. Brenner, "Atlas of EEG in critical care," *John Wiley & Sons*, 2011.
- [57] U. R. Acharya, S. V. Sree, G. Swapna, R. J. Martis, and J. S. Suri, "Automated eeg analysis of epilepsy: a review," *Knowledge-Based Systems*, vol. 45, pp. 147–165, 2013.
- [58] J. Dauwels, F. Vialatte, and A. Cichocki, "Diagnosis of Alzheimer's disease from EEG signals: where are we standing?," *Current Alzheimer Research*, vol. 7, no. 6, pp. 487–505, 2010.
- [59] L. Murri, S. Gori, R. Massetani, E. Bonanni, F. Marcella, and S. Milani, "Evaluation of acute ischemic stroke using quantitative EEG: a comparison with conventional EEG and CT scan," *Neurophysiologie Clinique/Clinical Neurophysiology*, vol. 28, no. 3, pp. 249–257, 1998.
- [60] M. Kocúřová and J. Juhár, "Comparison of Dry Electrodes for Mobile EEG System," in *ITAT*, pp. 180–183, 2019.
- [61] A. C. N. Society *et al.*, "A Proposal for Standard Montages to be Used in Clinical EEG." <http://www.acns.org/pdf/guidelines/Guideline-6.pdf>, 2006. [Online].
- [62] M. Herklots, "EEGpedia." <http://eegpedia.org/>, 2021. [Online].
- [63] J. V. Stone, "Independent component analysis: an introduction," *Trends in cognitive sciences*, vol. 6, no. 2, pp. 59–64, 2002.
- [64] M. F. Issa and Z. Juhasz, "Improved EOG artifact removal using wavelet enhanced independent component analysis," *Brain sciences*, vol. 9, no. 12, p. 355, 2019.
- [65] E. Paschalidis, "Neurosoft." <https://neurosoft.com/en>, 2022. [Online].
- [66] A. Atkielski, "QRS Complex." https://en.wikipedia.org/wiki/QRS_complex, 2022. [Online].
- [67] J. Hampton and J. Hampton, "The ECG made easy e-book," *Elsevier Health Sciences*, 2019.

- [68] Mayo Clinic, "Electrocardiogram (ECG or EKG)." <https://www.mayoclinic.org/tests-procedures/ekg/about/pac-20384983>, 2022. [Online].
- [69] A. L. Goldberger, L. A. Amaral, L. Glass, J. M. Hausdorff, P. C. Ivanov, R. G. Mark, J. E. Mietus, G. B. Moody, C.-K. Peng, and H. E. Stanley, "PhysioBank, PhysioToolkit, and PhysioNet: components of a new research resource for complex physiologic signals," *circulation*, vol. 101, no. 23, pp. e215–e220, 2000.
- [70] R. Cioffi, M. Travaglioni, G. Piscitelli, A. Petrillo, and F. De Felice, "Artificial intelligence and machine learning applications in smart production: Progress, trends, and directions," *Sustainability*, vol. 12, no. 2, p. 492, 2020.
- [71] G. Carvalho, B. Cabral, V. Pereira, and J. Bernardino, "Edge computing: current trends, research challenges and future directions," *Computing*, vol. 103, pp. 993–1023, 2021.
- [72] K. Cao, Y. Liu, G. Meng, and Q. Sun, "An overview on edge computing research," *IEEE access*, vol. 8, pp. 85714–85728, 2020.
- [73] B. Varghese, N. Wang, S. Barbhuiya, P. Kilpatrick, and D. S. Nikolopoulos, "Challenges and opportunities in edge computing," in *2016 IEEE international conference on smart cloud (SmartCloud)*, pp. 20–26, IEEE, 2016.
- [74] Y. Mao, C. You, J. Zhang, K. Huang, and K. B. Letaief, "A survey on mobile edge computing: The communication perspective," *IEEE communications surveys & tutorials*, 2017.
- [75] K. Wang, "Migration strategy of cloud collaborative computing for delay-sensitive industrial IoT applications in the context of intelligent manufacturing," *Computer Communications*, vol. 150, pp. 413–420, 2020.
- [76] J. Wang, J. Pan, F. Esposito, P. Calyam, Z. Yang, and P. Mohapatra, "Edge cloud offloading algorithms: Issues, methods, and perspectives," *ACM Computing Surveys (CSUR)*, vol. 52, no. 1, pp. 1–23, 2019.
- [77] W. Zhang, Y. Hu, Y. Zhang, and D. Raychaudhuri, "Segue: Quality of service aware edge cloud service migration," in *2016 IEEE International Conference on Cloud Computing Technology and Science (CloudCom)*, pp. 344–351, IEEE, 2016.
- [78] J. Al-Muhtadi, R. Campbell, A. Kapadia, M. D. Mickunas, and S. Yi, "Routing through the mist: Privacy preserving communication in ubiquitous computing environments," in *Proceedings 22nd International Conference on Distributed Computing Systems*, pp. 74–83, IEEE, 2002.
- [79] Eurostat, "Cloud computing - statistics on the use by enterprises." https://ec.europa.eu/eurostat/statistics-explained/index.php?title=Cloud_computing_-_statistics_on_the_use_by_enterprises, 2022. [Online].
- [80] M. Antonini, M. Vecchio, F. Antonelli, P. Ducange, and C. Perera, "Smart audio sensors in the internet of things edge for anomaly detection," *IEEE Access*, vol. 6, 2018.
- [81] D.-V. Bratu, R. Ș. T. Ilinoiu, A. Cristea, M.-A. Zolya, and S.-A. Moraru, "Anomaly Detection Using Edge Computing AI on Low Powered Devices," in *Artificial Intelligence Applications and Innovations: 18th IFIP WG 12.5 International Conference, AIAI 2022, Hersonissos, Crete, Greece, June*

- 17–20, 2022, *Proceedings, Part I*, pp. 96–107, Springer, 2022.
- [82] Lee, Jay, Qiu, H, Yu, G, Lin, and J, "Bearing data set, nasa ames prognostics data repository," *Rex-nord Technical Services, IMS, University of Cincinnati*, 2007.
- [83] V. Clocotici, "Dicționar explicativ de statistică." <https://profs.info.uaic.ro/~val/statistica/StatGloss.htm>, 2021. [Online].
- [84] Leys, Christophe, Ley, Christophe, Klein, Olivier, Bernard, Philippe, Licata, and Laurent, "Detecting outliers: Do not use standard deviation around the mean, use absolute deviation around the median," *Journal of experimental social psychology*, vol. 49, no. 4, 2013.
- [85] E. Broadbent, R. Stafford, and B. MacDonald, "Acceptance of healthcare robots for the older population: Review and future directions," *International journal of social robotics*, 2009.
- [86] G. Zhang and J. P. Hansen, "Telepresence robots for people with special needs: A systematic review," *International Journal of Human-Computer Interaction*, vol. 38, no. 17, 2022.
- [87] G. D'Onofrio, L. Fiorini, H. Hoshino, A. Matsumori, Y. Okabe, M. Tsukamoto, R. Limosani, A. Vitanza, F. Greco, A. Greco, *et al.*, "Assistive robots for socialization in elderly people: results pertaining to the needs of the users," *Aging clinical and experimental research*, 2019.
- [88] M. Avci, O. Ozgenc, S. A. Coskuner, and A. I. Olut, "Hospital acquired infections (HAI) in the elderly: comparison with the younger patients," *Archives of gerontology and geriatrics*, vol. 54, no. 1, pp. 247–250, 2012.
- [89] A. Despotovic, B. Milosevic, I. Milosevic, N. Mitrovic, A. Cirkovic, S. Jovanovic, and G. Stevanovic, "Hospital-acquired infections in the adult intensive care unit—Epidemiology, antimicrobial resistance patterns, and risk factors for acquisition and mortality," *American journal of infection control*, vol. 48, no. 10, pp. 1211–1215, 2020.
- [90] J. A. Al-Tawfiq and P. A. Tambyah, "Healthcare associated infections (HAI) perspectives," *Journal of infection and public health*, vol. 7, no. 4, pp. 339–344, 2014.
- [91] S. W. X. Ong and Y. K. Tan and P. Y. Chia and T. H. Lee and O. T. Ng and M. S. Y. Wong and and K. Marimuthu, "Air, surface environmental, and personal protective equipment contamination by severe acute respiratory syndrome coronavirus 2 (sars-cov-2) from a symptomatic patient," *Jama*, p. 1610–1612, 2020.
- [92] R. Zhang and Y. Li and A. L. Zhang and Y. Wang and and M. J. Molina, "Identifying airborne transmission as the dominant route for the spread of covid- 19," *Proceedings of the National Academy of Sciences*, p. 14 857–14 863, 2020.
- [93] W. Kowalski, T. Walsh, and V. Petraitis, "Covid-19 coronavirus ultraviolet susceptibility," *Purple-sun Inc*, 2020.
- [94] J. Young, "The Carolina Panthers will use a \$125,000 virus-killing robot in their stadium as fans return with covid-19 restrictions." <https://www.cnn.com/2020/10/01/carolina-panthers-use-virus-killing-robot-covid-19-stadium-nfl-fans.html>, 2020. [Online].
- [95] UVD Robots Co., "Advanced UV Disinfection Solutions: Discover UVD Robots." <https://uvd.blue-ocean-robotics.com/us>, 2021. [Online].

- [96] Surfacide Co., "Helios UV-C Disinfection System | Surfacide | UV-C Disinfection Robots." <https://www.surfacide.com/helios>, 2021. [Online].
- [97] Tru-D SmartUVC, "How UVC Works? Why Choose UVC Disinfection?." <https://tru-d.com/howuvcworks/>, 2022. [Online].
- [98] Honeywell Company, "Honeywell UV Treatment System." <https://aerospace.honeywell.com/us/en/products-and-services/product/hardware-and-systems/cabin/uv-treatment-system>, 2022. [Online].
- [99] ZENZOE Co., "Robot—ZENZOE." <https://zenzoe.tech/robot/>, 2021. [Online].
- [100] I. Mehta, H.-Y. Hsueh, N. Kourtzanidis, M. Brylka, and S. Saeedi, "Far-UVC Disinfection with Robotic Mobile Manipulator," in *2022 International Symposium on Medical Robotics (ISMR)*, pp. 1–8, IEEE, Apr 2022.
- [101] S. Perminov, N. Mikhailovskiy, A. Sedunin, I. Okunevich, I. Kalinov, M. Kurenkov, and D. Tsetserukou, "Ultrabot: Autonomous Mobile Robot for Indoor UV-C Disinfection," in *2021 IEEE 17th International Conference on Automation Science and Engineering (CASE)*, pp. 2147–2152, IEEE, 2021.
- [102] A. Zaman, M. S. Majib, S. A. Tanjim, S. M. A. Siddique, S. Islam, M. S. Aadeeb, N. I. Khan, R. Haque, M. R. U. Islam, and M. R. F. e. a. Faisal, "UVC-PURGE: A Novel Cost-Effective Disinfection Robot for Combating COVID-19 Pandemic," *IEEE Access*, vol. 10, pp. 37613–37634, 2022.
- [103] E. Lighting, "What is UV disinfection." [Online].
- [104] M. M, M. SJ, A. JG, and W. G., "Inactivation of bacterial pathogens following exposure to light from a 405-nanometer light-emitting diode array," *Appl Environ Microbiol*, pp. 75(7):1932–1937, 2009.
- [105] W. A. Rutala, H. Kanamori, M. F. Gergen, E. E. Sickbert-Bennett, D. J. Sexton, D. J. Anderson, J. Laux, D. J. Weber, C. P. E. Program, *et al.*, "Antimicrobial activity of a continuous visible light disinfection system," *Infection Control & Hospital Epidemiology*, vol. 39, no. 10, pp. 1250–1253, 2018.
- [106] HyperPhysics, "International System of Quantities." <http://hyperphysics.phy-astr.gsu.edu/hbase/Forces/isq.html>. Accessed in December 2020.
- [107] M. Heßling, K. Hönes, P. Vatter, and C. Lingenfelder, "Ultraviolet irradiation doses for coronavirus inactivation—review and analysis of coronavirus photoinactivation studies," *GMS hygiene and infection control*, vol. 15, 2020.
- [108] A. Gidari, S. Sabbatini, S. Bastianelli, S. Pierucci, C. Busti, D. Bartolini, A. M. Stabile, C. Monari, F. Galli, M. Rende, *et al.*, "SARS-CoV-2 survival on surfaces and the effect of UV-C light," *Viruses*, vol. 13, no. 3, p. 408, 2021.
- [109] E. Criscuolo, R. A. Diotti, R. Ferrarese, C. Alippi, G. Viscardi, C. Signorelli, N. Mancini, M. Clementi, and N. Clementi, "Fast inactivation of SARS-CoV-2 by UV-C and ozone exposure on different materials," *Emerging Microbes & Infections*, vol. 10, no. 1, pp. 206–209, 2021.
- [110] N. Storm, L. G. McKay, S. N. Downs, R. I. Johnson, D. Birru, M. de Samber, W. Willaert, G. Cennini, and A. Griffiths, "Rapid and complete inactivation of SARS-CoV-2 by ultraviolet-C irradiation," *Scientific Reports*, vol. 10, no. 1, p. 22421, 2020.

- [111] B. Ma, P. M. Gundy, C. P. Gerba, M. D. Sobsey, and K. G. Linden, "UV inactivation of SARS-CoV-2 across the UVC spectrum: KrCl* excimer, mercury-vapor, and light-emitting-diode (LED) sources," *Applied and environmental microbiology*, vol. 87, no. 22, pp. e01532–21, 2021.
- [112] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, "You Only Look Once: Unified, Real-Time Object Detection," in *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 779–788, 2016.
- [113] J. Redmon and A. Farhadi, "YOLOv3: An Incremental Improvement," *arXiv*, 2018.
- [114] P. Viola and M. J. Jones, "Rapid object detection using a boosted cascade of simple features," *Proc. Computer Vision and Pattern Recognition*, vol. 1, pp. 511–518, 2001.
- [115] P. Viola and M. J. Jones, "Robust real-time face detection," *International journal of computer vision*, vol. 57, pp. 137–154, 2004.
- [116] K. Kadir, M. Kushsairy, H. Nasir, S. Safie, and Z. A. K. Bakti, "A comparative study between LBP and Haar-like features for Face Detection using OpenCV," *International Conference on Engineering Technology and Technopreneuship*, vol. 4, 2014.
- [117] D.-V. Bratu, M.-A. Zolya, and S.-A. Moraru, "A different view on artificial intelligence applications for cardiac arrhythmia detection and classification," in *Online Engineering and Society 4.0: Proceedings of the 18th International Conference on Remote Engineering and Virtual Instrumentation*, pp. 415–427, Springer, 2022.
- [118] N. Rafie, A. H. Kashou, and P. A. Noseworthy, "ECG Interpretation: Clinical Relevance, Challenges, and Advances," *Hearts*, vol. 2, no. 4, pp. 505–513, 2021.
- [119] S. J. Pan and Q. Y. Fellow, "A Survey on Transfer Learning," *IEEE*, 2007.
- [120] J. Schmidhuber, "Deep learning in neural networks: An overview," *Neural networks*, vol. 61, pp. 85–117, 2015.
- [121] J. Vincent, "What counts as artificially intelligent? AI and DL." <https://www.theverge.com/2016/2/29/11133682/deep-learning-ai-explained-machine-learning>, 2016. [Online].
- [122] L. Bell, "Machine learning versus AI: what's the difference?." <http://www.wired.co.uk/article/machine-learning-ai-explained>, 2016. [Online].
- [123] Y. LeCun, Y. Bengio, and G. Hinton, "Deep learning," *Nature*, vol. 521, 2015.
- [124] R. Ebrahimpour, K. Babakhan, A. Arani, and S. Masoudnia, "Epileptic seizure detection using a neural network ensemble method and wavelet transform," *Neural Network World*, 2012.
- [125] F. Leon, "Introducere în Inteligența Artificială – Sinteză," 2020.
- [126] T. Poornappriya and R. Gopinath, "Application of Machine Learning Techniques for Improving Learning Disabilities," *International Journal of Electrical Engineering and Technology (IJEET)*, vol. 11, no. 10, pp. 392–402, 2020.
- [127] S. Trewin, "AI fairness for people with disabilities: Point of view," *arXiv preprint arXiv:1811.10670*, 2018.
- [128] C. Lewis, "Implications of developments in machine learning for people with cognitive disabilities," *ACM SIGACCESS Accessibility and Computing*, no. 124, pp. 1–1, 2020.

- [129] S. Caton and C. Haas, "Fairness in machine learning: A survey," *arXiv preprint arXiv:2010.04053*, 2020.
- [130] T. Ma, S. Wang, Y. Xia, X. Zhu, J. Evans, Y. Sun, and S. He, "CNN-based classification of fNIRS signals in motor imagery BCI system," *Journal of Neural Engineering*, vol. 18, no. 5, p. 056019, 2021.
- [131] M. T. Sadiq, M. Z. Aziz, A. Almogren, A. Yousaf, S. Siuly, and A. U. Rehman, "Exploiting pretrained CNN models for the development of an EEG-based robust BCI framework," *Computers in Biology and Medicine*, vol. 143, p. 105242, 2022.
- [132] G. Schalk, D. J. McFarland, T. Hinterberger, N. Birbaumer, and J. R. Wolpaw, "BCI2000: a general-purpose brain-computer interface (BCI) system," *IEEE Transactions on biomedical engineering*, vol. 51, no. 6, pp. 1034–1043, 2004.
- [133] A. Fernández, S. Garcia, F. Herrera, and N. V. Chawla, "SMOTE for learning from imbalanced data: progress and challenges, marking the 15-year anniversary," *Journal of artificial intelligence research*, vol. 61, pp. 863–905, 2018.
- [134] V. J. Lawhern, A. J. Solon, N. R. Waytowich, S. M. Gordon, C. P. Hung, and B. J. Lance, "EEGNet: a compact convolutional neural network for EEG-based brain-computer interfaces," *Journal of neural engineering*, vol. 15, no. 5, p. 056013, 2018.
- [135] Y. Zhu, Y. Li, J. Lu, and P. Li, "EEGNet with ensemble learning to improve the cross-session classification of SSVEP based BCI from ear-EEG," *IEEE Access*, vol. 9, 2021.
- [136] R. P. Kumar, S. S. Vandana, D. Tejaswi, K. Charan, R. Janapati, and U. Desai, "Classification of SS-VEP Signals using Neural Networks for BCI Applications," in *2022 International Conference on Intelligent Controller and Computing for Smart Power (ICICCSPP)*, IEEE, 2022.