

UNIVERSITATEA TEHNICĂ "GHEORGHE ASACHI" DIN IAȘI

RECTORATUL

Către

Vă facem cunoscut că, în ziua de **12/07/2023** la ora **15:00** în **Sala de Consiliu a Facultății de Electronică, Telecomunicații și Tehnologia Informației**, corpul A al Universității Tehnice "Gheorghe Asachi" din Iași, va avea loc susținerea publică a tezei de doctorat intitulată:

"Contribuții la dezvoltarea sistemelor de tip HCI prin intermediul tehnologiei IoT"

elaborată de domnul **Severin Ionuț-Cristian** în vederea conferirii titlului științific de doctor.

Comisia de doctorat este alcătuită din:

1. Prof.univ.dr.ing Daniela Tărniceriu

Universitatea Tehnică „Gheorghe Asachi” din Iași

președinte

2. Prof.univ.dr.ing Dobrea Dan-Marius

Universitatea Tehnică „Gheorghe Asachi” din Iași

conducător de doctorat

3. Prof.univ.dr.ing Rusu Corneliu-Gheorghe

Universitatea Tehnică din Cluj-Napoca

referent oficial

4. Dr.ing Hariton Nicolae-Costin CS2

Institutul de informatică Teoretică, Academia Română-Filia Iași

referent oficial

5. Prof.univ.dr.ing Teodorescu Horia-Nicolai

Universitatea Tehnică „Gheorghe Asachi” din Iași

referent oficial

Cu această ocazie vă invităm să participați la susținerea publică a tezei de doctorat




RECTOR,

Prof.univ.dr.ing. DAN CAȘCAVAL

Secretar universitate,

Ing. Cristina Nagiț



UNIVERSITATEA TEHNICĂ "GHEORGHE ASACHI" DIN IAȘI
ȘCOALA DOCTORALĂ A FACULTĂȚII DE ELECTRONICĂ,
TELECOMUNICAȚII ȘI TEHNOLOGIA INFORMAȚIEI



CONTRIBUȚII LA DEZVOLTAREA SISTEMELOR DE TIP HCI PRIN INTERMEDIUL TEHNOLOGIEI IOT

-REZUMAT TEZĂ DE DOCTORAT-

**Conducător Științific,
Prof.univ.dr.ing. Dan-Marius Dobrea**

**Doctorand:
Ing. Severin Ionuț-Cristian**

IAȘI, 2023

CONTRIBUȚII LA DEZVOLTAREA SISTEMELOR DE TIP HCI PRIN INTERMEDIUL TEHNOLOGIEI IOT

Ing. Severin Ionuț-Cristian

domeniul Electronică, Telecomunicații și Tehnologii Informaționale

Președinte comisie doctorat: Prof.univ.dr.ing Daniela Tărniceriu

Conducător de doctorat: Prof.univ.dr.ing Dobrea Dan-Marius

Referenți oficiali: Prof.univ.dr.ing Teodorescu Horia-Nicolai

Prof.univ.dr.ing Rusu Corneliu-Gheorghe

Dr.ing Hariton Costin-Nicolae

CUPRINS

CUPRINS	4
Lista Figurilor	6
Lista Tabelelor	6
Lista Abrevierilor.....	8
CAPITOLUL 1	10
1.1 Introducere	10
1.2 Motivație	11
1.3 Obiectivele tezei de doctorat	11
1.4 Diseminarea rezultatelor (contribuții și lucrări publicate).....	12
1.5 Structura tezei de doctorat	14
CAPITOLUL 2	15
Stadiul actual și aplicabilitatea sistemelor inerțiale în domeniul HCI și IoT	15
2.1 Introducere	15
2.2 Stadiul actual al interfețelor om calculator bazat pe interpretarea semnalelor inerțiale.	15
2.3 Arhitectura unei interfețe om calculator în domeniul HCI și IoT.....	17
2.4 Aplicabilitatea sistemelor inerțiale în domeniul HCI și IoT.....	18
2.5 Avantajele și dezavantajele sistemelor HCI și IoT.....	18
CAPITOLUL 3	19
Aspecte teoretice asupra metodelor și sistemelor folosite în determinarea poziției spațiale	19
3.1 Generalități	19
.....	20
3.2 Metode de control și evaluare folosite în sistemele inerțiale	21
3.2.1 <i>Metode de control folosite în sistemele de interfațare om-calculator</i>	21
CAPITOLUL 4	22
Aspecte privind achiziția, procesarea și utilizarea seriilor inerțiale	22
4.1 Generalități	22
4.2 Metode de achiziție	23
4.3 Metode de grupare și etichetare a seturilor de date	24
4.4 Metode de extragere a trăsăturilor din seturilor de date	24
CAPITOLUL 5	25
Metode inteligente folosite în clasificarea semnalelor: Algoritmi clasici de tip învățare automată ...	25
5.1 Metode de tip învățare automată supervizată	25
5.1.1 <i>Clasificatorul Support Vector Machine</i>	25
5.1.2 <i>Clasificatorul k-Nearest Neighbors (“Cei mai apropiați k vecini”)</i>	26
5.1.3 <i>Clasificatorul Random Forest (“Pădure Aleatorie”)</i>	26
5.2 Metode de evaluare a performanțelor.....	26
5.2.1 <i>Matricea de confuzie</i>	26
5.2.2 <i>Precizie, Acuratețe, Senzitivitate și Specificitate</i>	27
5.2.3 <i>Curba ROC și Curba Precizie-Senzitivitate</i>	27
CAPITOLUL 6	28

Metode inteligente folosite în clasificarea semnalelor: Algoritmi de tip învățare automată profundă	28
6.1 Introducere	28
6.2 Rețele neuronale recurente	29
6.3 Rețele neuronale convoluționale	29
6.4 Rețele neuronale mixte	30
CAPITOLUL 7	31
Contribuții personale la dezvoltarea sistemelor de identificare a gesturilor motorii	31
7.1 Prezentarea implementării hardware a sistemelor dezvoltate	31
7.1.1 Sistem cravată inteligentă	31
7.1.2 Sistem de identificare a mișcărilor capului cu un singur senzor inerțial	32
7.1.3 Sistem multi-senzor de identificare a mișcărilor capului (cervical și cap)	32
7.2 Achiziția seturilor de date inerțiale	33
7.2.1 Achiziționarea setului de date capacitiv utilizat în identificarea gesturilor motorii de la nivelul capului	33
7.2.2 Achiziționarea setului de date inerțial utilizat în identificarea gesturilor motorii de la nivelul capului	35
7.2.3 Achiziționarea setului de date inerțial utilizat în identificarea posturii corporale	37
7.3 Componente software utilizate la achiziția, analiza și clasificarea activităților motorii	39
7.3.1 Soluții software utilizate pentru achiziția semnalelor inerțiale	39
7.3.2 Tehnici utilizate în prelucrarea semnalelor inerțiale	40
7.3.3 Antrenarea algoritmilor folosiți în clasificarea gesturilor de la nivelul capului	41
7.4 Rezultate experimentale obținute	45
7.4.1 Rezultate obținute pe baza algoritmilor clasici ce folosesc principiul de încapsularea al datelor	45
7.4.2 Rezultate obținute pe baza algoritmilor clasici ce folosesc principiul similarităților	52
7.4.3 Rezultate obținute pe baza rețelelor neuronale de tip multilayer perceptron (MLP)	54
7.4.4 Rezultate obținute pe baza algoritmilor cu învățare profundă CNN, LSTM și BLSTM	56
7.4.5 Rezultate obținute pe baza algoritmilor hibridi cu învățare profundă CNN-LSTM și CNN-BLSTM	58
7.4.6 Rezultate obținute de algoritmi clasici folosind analiza comparativă a metodelor de extragere de trăsături	60
CAPITOLUL 8	63
Concluzii finale și contribuții personale	63
8.1.1 Concluzii generale	63
8.1.2 Contribuții personale și elemente de originalitate	66
8.1.3 Valorificarea rezultatelor obținute (Lista publicațiilor originale realizate)	67
8.1.4 Direcții de continuare și dezvoltări ulterioare a cercetărilor	68
BIBLIOGRAFIE	69

Lista Figurilor

Figură 1 Reprezentarea generalizată a unei arhitecturi de interfațare om-calculator bazată pe interpretarea semnalelor inerțiale.....	17
Figură 2 Exemple de senzori ambientali și purtabili utilizați în determinarea orientării spațiale a corpului	20
Figură 3 Exemplu de proces utilizat la implementarea sistemelor de recunoaștere a activităților de la nivelul capului folosind senzorii inerțiali.....	23
Figură 4 Formă de undă dependentă de mișcarea de la nivelul capului.....	23
Figură 5 Structura unei rețele neuronale biologice	28
Figură 6 Sistem de monitorizare a gesturilor folosind senzori capacitivi	31
Figură 7 Schema bloc a sistemului de monitorizare cu un senzor inerțial cu 6	32
Figură 8 Schema bloc a sistemului de monitorizare cu trei senzori inerțiali.....	33
Figură 9 Activități template definite pentru captarea semnalelor inerțiale de la nivelul capului	35
Figură 10 Activități template definite pentru captarea semnalelor inerțiale de la nivelul capului	36
Figură 11 Activități template definite pentru captarea semnalelor inerțiale utilizate la identificarea posturilor relevante mișcării capului.....	38
Figură 12 Aplicația “blesTags” folosită pentru achiziția semnalelor capacitiv inerțiale	39
Figură 13 Calcularea metricilor Precizie, Recall și scorul F1 pentru fiecare clasă predefinită	46
Figură 14 Curba ROC pentru algoritmul ADAB antrenat cu setul de date CDB.....	46
Figură 15 Diferite curbe de învățare obținute folosind metoda de validare încrucișată k-FS și setul de date CDB	48
Figură 16 Diferite curbe de învățare obținute folosind metoda de validare încrucișată k-FMC și setul de date CDB	48
Figură 17 Calcularea metricilor Precizie, Recall și scorul F1 pentru fiecare clasă predefinită	49
Figură 18 Calcularea metricilor Precizie, Recall și scorul F1 pentru fiecare clasă predefinită	51
Figură 19 Matricea de confuzie pentru algoritmul 6-kNN antrenat pe setul CDB.....	52
Figură 20 Matricea de confuzie pentru algoritmul SVM antrenat pe setul SIDB	53
Figură 21 Performanțele de clasificare obținute folosind modele clasice cu învățare automată	64
Figură 22 Performanțele de clasificare obținute folosind modele cu învățare automată profundă	65

Lista Tabelelor

Tabel 3 Rezultate de clasificare obținute pe setul de test folosind baza de date CDB (cu 20% din valori pentru test și 80% pentru antrenare)	45
Tabel 2 Rezultate de clasificare obținute folosind setul CDB și metoda de validare încrucișată k-FS cu 10 partiții.....	47
Tabel 3 Rezultate de clasificare obținute folosind setul CDB și metoda de validare încrucișată k-FMC cu 10 partiții.....	47
Tabel 4 Rezultate de clasificare obținute pe setul de test folosind baza de date SIDB (cu 20% din valori pentru test și 80% pentru antrenare)	48
Tabel 5 Rezultate de clasificare obținute folosind setul SIDB și metoda de validare încrucișată k-FS cu 10 partiții.....	50
Tabel 6 Rezultate de clasificare obținute folosind setul SIDB și metoda de validare încrucișată k-FMC cu 10 partiții.....	50
Tabel 7 Rezultate de clasificare obținute pe setul de test folosind baza de date MIDB (cu 20% din valori pentru test și 80% pentru antrenare)	50
Tabel 8 Rezultate de clasificare obținute folosind setul MIDB și metoda de validare încrucișată k-FS cu 10 partiții.....	51
Tabel 9 Rezultate de clasificare obținute folosind setul MIDB și metoda de validare încrucișată k-FMC cu 10 partiții.....	51
Tabel 10 Rezultate obținute folosind un număr diferit de neuroni pe stratul ascuns în rețeaua de tip MLP, cu 20% din valori pentru test și 80% pentru antrenare.....	55
Tabel 11 Rezultate obținute pe setul MIDB de către algoritmi CNN, LSTM și BLSTM pentru diferite valori ale filtrelor prezente în structura straturilor ascunse.....	56
Tabel 12 Rezultate obținute folosind diferite funcții de activare pentru straturile complet conectate	57
Tabel 13 Rezultate obținute pe setul CDB de către algoritmi CNN, LSTM și BLSTM pentru diferite valori ale filtrelor prezente în structura straturilor ascunse	58

Tabel 14 Rezultate de clasificare obținute cu ajutorul algoritmilor CNN-LSTM și CNN-BLSTM, folosind diferite funcții de activare pentru straturile complet conectate	59
Tabel 15 Rezultate obținute folosind metoda PSC cu ajutorul algoritmilor clasici cu învățare automată ..	60
Tabel 16 Rezultate obținute folosind metoda TES cu ajutorul algoritmilor clasici cu învățare automată ..	61
Tabel 17 Rezultate obținute folosind setul CDB, cu 20% din valori pentru test și 80% pentru antrenare ..	61
Tabel 18 Rezultate obținute folosind setul MIDB, cu 20% din valori pentru test și 80% pentru antrenare	62
Tabel 19 Rezultate obținute folosind setul SIDB, cu 20% din valori pentru test și 80% pentru antrenare .	62
Tabel 20 Rezultate obținute folosind metoda JFFT cu 20% din valori pentru test și 80% pentru antrenarea algoritmilor clasici cu învățare automată	63

Lista Abrevierilor

	Eng.	Ro.
HCI	Human Computer-Interface	Interfațare Om-Calculator
IoT	Internet of Things	Internetul Lucrurilor
RF	Random Forest Classifier	Clasificatorul Pădure Aleatorie
k-NN	k-Neighbors Classifier	Clasificatorul k-Vecini
DTC	Decision Tree Classifier	Clasificatorul Arbore de decizie
ET	Extra Tree Classifier	Clasificatorul Abori de decizie extins
GNB	Gaussian Naive Bayes	Clasificatorul Bayesian
GBC	Gradient Boosting Classifier	Clasificatorul bazat pe creșterea gradientului
LR	Logistic Regression Classifier	Clasificatorul regresie logistică
ADAB	Adaptive Boosting Classifier	Clasificatorul adaptiv de amplificare
SVM	Support Vector Machine	Mașini cu suport vectorial
DCM	Direction Cosine Matrix	Matricea Cosinului de Direcție
FFT	Discrete Fourier Transform	Trasformată Fourier Discretă
CNN	Convolutional Neural Network	Rețele Neuronale Convoluționale
LSTM	Long Short-Term Memory	Rețea Neuronală cu memorie pe termen scurt
3D	Three dimension	Tridimensional
2D	Two dimension	Bi-dimensional
BPOC	Chronic obstructive pulmonary disease	Boala pulmonară obstructivă cronică
OMS	World Health Organization	Organizația Mondială a Sănătății
MPU	Micro Processor Unit	Unitate de Microprocesare
RGDB	Red Green Blue-Depth	Roșu-Verde-Albastru-Adâncime
LPF	Low Pass Filter	Filtru Trece Jos
HPF	High Pass Filter	Filtru Trece Sus
GM	Modelul Gauss–Markov	Model Gauss–Markov
AR	Autoregressive model	Model autoregresiv
DWT	Discrete Wavelet Transform	Transformata Wavelet discretă
DCT	Discrete Cosine Transform	Transformata Cosinus discretă
LWL	Locally Weighted Learning	Învățare ponderată local
CART	Classification and Regression Tree	Arbore de clasificare și regresie
MLE	Maximum Likelihood Estimation	Estimarea Probabilității Maxime
PCA	Analiza Componentelor Principale	Analiza Componentelor Principale
LDA	Linear Discriminant Analysis	Analiza Discriminantă Liniară
ERM	Empirical risk minimization	Minimizarea riscului empiric
VAE	Variational AutoEncoder	AutoEncoder Variațional
RBM	Restricted Boltzmann Machine	Mașină Boltzmann Restrictivă
MISE	Mean integrated squared error	Eroare medie medie pătrată
ROC	Receiver operating characteristic curve	Curba caracteristică de funcționare a receptorului
AUC	Area under the ROC curve	Aria de sub curba ROC
ReLU	Rectified Linear Unit	Unitate liniară Rectificată

APIT	The backpropagation algorithm in time	Algoritmul de propagare inversă în Timp
IMU	Inertial Sensor Module	Modul de senzor Inerțial
GATT	Generic Attribute Profile	Profil generic al atributului
BLE	Bluetooth Low Energy	Bluetooth cu consum redus
VBA	Visual Basic for Application	Visual Basic pentru Aplicații
UART	Universal Asynchronous Receiver/Transmitter	Transmițător/Receptor Asincron Universal
HW	Hardware	Hardware
IFFT	Inverse Discrete Fourier Transform	Transformata Fourier Discretă Inversă
TSFRESH	Time Series Feature Extraction on basis of Scalable Hypothesis tests	Extragerea caracteristicilor din serii temporale pe bază testelor de ipoteză
CSV	Comma Separated Values	Valori Separabile prin virgulă
RBF	Radial Basis Function Neural Network	Rețele Neuronale cu funcție de bază radială
CDB	Capacitive Database	Bază de date capacitivă
SIDB	Single Inertial Database	Bază de date de la un singur senzor inerțial
MIDB	Multiple inertial Database	Bază de date de la mai mulți senzori inerțiali
k-FS	Stratified K-Fold Cross Validation	Validare încrucișată stratificată K-Fold
k-FMC	Monte Carlo K-Fold Cross Validation	Validare încrucișată K-Fold Monte Carlo
CNN	Convolutional Neural Network	Rețea neuronală convolutivă
BLSTM	Bidirectional Long Short-Term Memory	Rețea Neuronală cu memorie pe termen scurt bidirecțională
MEMS	Microelectromechanical system	Sistem microelectromecanic
ANN	Artificial Neural Network	Rețea neuronală artificială

CAPITOLUL 1

1.1 Introducere

Astăzi, sistemele inteligente dezvoltate pentru a facilita creșterea nivelului de trai sau de a asista operatorii umani la execuția anumitor sarcini locomotorii au cunoscut o cerere semnificativă, datorită abilității acestor dispozitive de a îmbunătăți calitatea vieții umane. Acest lucru vine ca urmare a dezvoltării continue a diverselor arii de cercetare ca: Interfațare Om Calculator (HCI) (Tripathi, et al., 2022), Internetul Lucrurilor (IoT) (Perumal, et al., 2022), dezvoltarea de dispozitive medicale (Dorszewski, et al., 2022), dezvoltarea de soluții de asistare și monitorizare a activității șoferului (Darapaneni, et al., 2022), dezvoltarea de soluții de automatizare aplicabile în agricultură, s.m.d.. Cu toate că, nivelul de expertiză al soluțiilor deja existente este unul destul de ridicat, există totuși cerere pentru crearea de soluții aplicabile în domenii ca: interfațare om calculator (HCI), internetul lucrurilor (IoT) sau al creării de dispozitive medicale, prin reducerea costurilor de dezvoltare și de optimizare a performanțelor oferite. În majoritatea soluțiilor de interfațare om calculator cu aplicabilitate în domeniul medical sau în cel IoT, senzorii utilizați sunt reprezentați de: camere foto-video (Pothula, et al., 2022), senzori bazați pe eco-locăție (Biswas, et al., 2022), senzori Kinect (Szücs, et al., 2019), senzori inductivi, senzori de flexiune, senzori de presiune (Shao, et al., 2022), s.m.d.. O altă abordare, de achiziție și interpretare a informațiilor din mediul înconjurător este acela de a utiliza senzorii inerțiali. Această categorie de senzori este deja integrată în diverse aplicații industriale cum ar fi: aviație (Faghihinia, et al., 2022), navigație (Zhu, et al., 2022), sisteme de monitorizare și control cu aplicabilitate în medicină (Lueken, et al., 2022), jocuri video (Kim, et al., 2019), realitate augmentată (Dao, 2022), etc.. Deoarece în domeniul HCI sau cel IoT această abordare este relativ la început, scopul acestei lucrări de doctorat este acela de a studia posibilitatea utilizării, interpretării și clasificării semnalelor inerțiale în determinarea orientării spațiale a corpului omenesc sau de interpretare a anumitor activități locomotorii, oferind posibilitatea interfațării între om și calculator pentru persoanele cu dizabilități. Prin urmare, scopul acestei teze este acela de a analiza și demonstra utilitatea senzorilor inerțiali în determinarea caracteristicilor locomotorii de la nivelul capului prin propunerea de noi dispozitive cu aplicabilitate în domeniul HCI, IoT respectiv cel medical. Domeniul analizei seturilor de date a cunoscut un progres semnificativ în ultima perioadă, remarcându-se prin apariția unor algoritmi noi folosiți pentru rezolvarea anumitor sarcini computaționale, metode/tehnici predictive sau metode de optimizare prin selectarea caracteristicilor principale. Aceste tehnici/metode au fost deja validate de comunitatea științifică prin aplicarea lor pentru rezolvarea diferitor probleme predictive precum: clasificare, grupare și probleme de regresie, pentru diverse aplicații din lumea reală. Deoarece marea majoritate a algoritmilor sau metodelor predictive au fost proiectate să lucreze pe seturi de date ce conțin imagini, provocarea cea mai mare în acest moment este dată de adaptarea acestor metode pentru a lucra cu succes pe seriile temporale inerțiale.

Un alt punct de interes este reprezentat de către posibilitatea de a estima cu precizie pe baza informațiilor deja existente, producerea/apariția unor evenimente critice. Aceste evenimente critice pot fi reprezentate de simptome ale persoanelor cu dizabilități cum ar fi: leșin, tulburări neuro-motorii, etc. Din acest motiv, din dorința de a îmbunătăți calitatea

vieții, domeniul HCI, IoT sau cel al dezvoltării de soluții cu aplicabilitate în medicină au devenit în ultima perioadă, domeniile cu cel mai mare interes pentru cercetători.

1.2 Motivație

Scopul cercetării prezentate, este acela de a studia și propune soluții inovative bazate pe interpretarea semnalelor inerțiale. Acest lucru oferind o înțelegere profundă asupra avantajelor și dezavantajelor oferite de utilizarea senzorilor inerțiali în contextul interfațării om calculator. Un alt aspect ce este vizat în această teză de doctorat, este legat de studierea și propunerea de metode folosite în preprocesarea semnalului inerțial cu scopul de a îmbunătăți performanțele de clasificare a algoritmilor cu învățare automată. Pe perioada studiilor de cercetare efectuate, s-a urmărit investigarea rezultatelor din două puncte de vedere: prin utilizarea algoritmilor clasici de învățare automată, respectiv a algoritmilor cu învățare profundă ce conțin în structura lor rețele neuronale. Focusul cercetării a fost pus pe determinarea și clasificarea activităților desfășurate la nivelul capului, însă acest lucru nu constituie o limitare, rezultatele obținute putând fi utilizate în diverse domenii interconectate de domeniul HCI sau IoT. În plus, s-a urmărit studierea și clasificarea activităților desfășurate de către un operator uman folosind senzorii inerțiali ca o alternativă la soluțiile bazate pe rețele de senzori complexe ce au un cost de implementare și întreținere mult mai mare. La ora actuală, astfel de senzori sunt deja incluși în diverse dispozitive electronice (telefoane inteligente, ceasuri inteligente, brățări inteligente, etc.), acest lucru făcând mult mai ușoară interpretarea informațiilor ce provin de la operatorii umani. În trecut, diverse studii au vizat detecția și interpretarea semnalelor inerțiale, însă marea majoritate a aplicațiilor propuse întâmpină unele limitări de natură constructivă, de complexitate ori de portabilitate al prototipurilor propuse. Acest lucru face ca unele soluții propuse de către cercetătorii din întreaga lume să fie utilizate numai în cadrul unor medii controlate (laboratoare), îngreunând astfel extinderea acestor idei la o scară mai largă de utilizare. Din acest motiv, studiile efectuate în cadrul acestei teze de doctorat, au urmărit să satisfacă condiția portabilității sistemelor dezvoltate și a obținerii unui nivel de complexitate moderat pentru prototipurile finale.

1.3 Obiectivele tezei de doctorat

Principalul obiectiv al acestei teze de doctorat este reprezentat de studierea, analiza și propunerea de noi dispozitive de monitorizare și control bazate pe interpretarea semnalelor inerțiale și capacitive. Obiectivul final al acestor soluții, este acela de a diagnostica sau de a ajuta persoanele cu probleme medicale să poată controla cu ușurință anumite ansambluri mecanice sau informatice (scaun cu roțile, aplicații mobile, aplicații web, s.a.m.d.). De asemenea, pentru atingerea obiectivului principal propus s-au considerat 2 abordări, utilizând 2 metode neconvenționale de citire, interpretare și clasificare a activităților de la nivelul capului. Prima dintre acestea, s-a bazat pe interpretarea și clasificarea activităților pe baza senzorilor capacitivi instalați pe o cravată inteligentă. În timp ce ce-a de-a doua abordare a constat în utilizarea senzorilor inerțiali cu 6, respectiv 9 grade de libertate. Pentru atingerea obiectivului stabilit inițial, în lucrarea de doctorat propusă s-au tratat următoarele aspecte:

- Studierea și prezentarea principalelor noutăți din domeniul HCI și IoT bazate pe analiza seriilor temporale cu scopul de a clasifica activitățile desfășurate de operatorii umani.

- Evidențierea și explicarea principalelor noțiuni teoretice legate de utilizarea seriilor de timp în domeniul HCI și IoT
- Evidențierea noțiunilor teoretice cu privire la determinarea ecuațiilor de modelare a unui obiect în spațiul 3D
- Descrierea noțiunilor teoretice ce vizează algoritmi cu învățare automată clasici și cei cu învățare profundă
- Studiarea tehnicilor de preprocesare a seriilor temporale cu scopul de a optimiza și crește performanțele de clasificare
- Studiarea tehnicilor de adaptare a formatului seriilor de timp pentru a putea fi utilizate cu succes în antrenarea algoritmilor de clasificare și predicție
- Propunerea și implementarea prototipurilor experimentale bazate pe senzori inerțiali și capacitivi
- Modelarea gesturilor exercitate la nivelul capului prin intermediul algoritmilor cu învățare automată clasici
- Modelarea gesturilor exercitate la nivelul capului prin intermediul algoritmilor cu învățare profundă ce conțin în structura lor rețele neuronale
- Modelarea gesturilor exercitate la nivelul capului prin intermediul algoritmilor hibridi cu învățare profundă ce conțin în structura lor rețele neuronale
- Dezvoltarea unor baze de date noi utilizate pentru antrenarea modelelor predictive studiate
- Evaluarea rezultatelor de clasificare obținute și determinarea concluziilor aferente studiilor efectuate (avantaje și dezavantaje).
- Validarea rezultatelor obținute comparativ cu cele raportate de comunitatea științifică.

1.4 Diseminarea rezultatelor (contribuții și lucrări publicate)

Rezultatele obținute în urma desfășurării activității de cercetare au fost diseminate în 12 lucrări:

- 2 lucrări publicate într-o revistă Open Access cotate **CNCSIS B+**
- 8 lucrări au fost publicate în volumele unor conferințe internaționale, dintre care:
 - 6 indexate în **ISI Web of Science**
 - 2 indexate în alte baze de date internaționale (**IEEE Xplore** și **SCOPUS**)
- 1 lucrare publicată într-o revistă Open Access cu **IF (2022): 2.635 (Q3)** și indexată în **ISI Web of Science, DBLP, SCOPUS** și **DOAJ**.
- 1 lucrare publicată într-o revistă Open Access cu **IF (2022): 3.4 (Q3)** și indexată în **ISI Web of Science, PubMed, DOAJ** și **SCOPUS**.
- 2 lucrări prezentare în cadrul unei conferințe naționale (**CSD 2021**)

Dintre lucrările prezentate mai sus la 11 dintre acestea sunt prim autor, în timp ce la 6 dintre acestea sunt unic autor.

Studiile de cercetare efectuate până în acest moment s-au axat pe: propunerea, implementarea și analizarea performanțelor de clasificare pe baza utilizării diverselor

tehnicile computaționale și a seriilor de timp inerțiale și capacitive. Găsirea metodelor optime de selecție a caracteristicilor prezente în seriile temporale și formatarea structurii seturilor de date astfel încât să poată fi utilizate cu ușurință în antrenarea modelelor predictive, a constituit un alt obiectiv al cercetărilor efectuate. În lucrarea (Severin, Dobrea, & Dobrea, 2020) s-a propus un dispozitiv bazat pe un singur senzor inerțial cu șase grade de libertate ce a fost utilizat pentru recunoașterea gesturilor de la nivelul capului. Evaluarea performanțelor de clasificare s-a făcut prin intermediul utilizării algoritmilor clasici cu învățare automată. Pentru validarea rezultatelor, în lucrarea (Dobrea, Dobrea, & Severin, 2019), s-a propus un nou sistem de recunoaștere a gesturilor bazat pe 4 senzori capacitivi. Pentru ambele cazuri, rezultatele obținute au fost foarte bune cu o rată de clasificare a activităților mai mare de 70 %. Pentru îmbunătățirea ratei de clasificare, în (Severin, 2020), s-a propus și studiat o metoda de selecție a caracteristicilor definatorii din seriile temporale inerțiale pe baza Transformatei Fourier directe, Transformatei Fourier inverse și a calculării caracteristicii Jerk din seriile temporale. Metoda propusă a constat în împărțirea seriilor de timp cu ajutorul unor ferestre glisante, urmată apoi de translarea fiecărei ferestre în domeniul frecvență prin aplicarea Transformatei Fourier. După selectarea componentelor principale din domeniul frecvență, s-a aplicat Transformata Fourier Inversă obținând astfel seriile de timp definatorii fiecărei activități predefinite. Ulterior, caracteristicile Jerk au fost calculate pentru fiecare serie de date inițială, urmând să fie atașate setului final de date obținut prin aplicarea Transformatei Fourier. O altă metodă propusă și utilizată a fost descrisă în (Severin, 2020a), aceasta a constat în extragerea componentei date de trendul seriei temporale urmată apoi de o filtrare cu ajutorul filtrului median. O altă abordare studiată în aceeași lucrare, a constat în selectarea a 16 caracteristici statistice principale. Rezultatele obținute au fost validate prin generarea automată a caracteristicilor definatorii cu ajutorul unei librării python. Pentru antrenarea și testarea rezultatelor de clasificare, s-a optat pe utilizarea metodei K-Fold și a metodei clasice de împărțire a setului de date în două cu un procentaj de 80 % set de antrenare și 20 % set de testare. În continuare, s-a propus în (Severin, 2020d), un sistem de monitorizare și control bazat pe 3 senzori inerțiali. Prin intermediul acestui experiment, s-a studiat impactul pe care îl are creșterea numărului de senzori inerțiali în determinarea cu precizie a activităților de la nivelul capului. În (Severin, 2020f), performanțele de clasificare au fost studiate pe baza algoritmilor clasici ca: Random Forest Classifier (RF), k-Neighbors Classifier (k-NN), Decision Tree Classifier (DT), Extra Tree Classifier (ET), Gaussian Naive Bayes (GNB), Logistic Regression Classifier (LR), Adaptive Boosting Classifier (ADAB) și Support Vector Machine (SVM). Pe lângă aceste metode predictive, în (Severin & Dobrea, 2020), s-au studiat performanțele de clasificare pe baza algoritmilor cu învățare profundă ce conțin în structura lor rețele neuronale. Printre acești algoritmi se pot aminti: rețele neuronale convolutive (CNN), rețele Long Short-Term Memory (LSTM) și rețele bidirecționale Long Short-Term Memory (BLSTM). Pe lângă aceste modele de rețele neuronale, s-a studiat și posibilitatea de a crea structuri hibride cum sunt: rețeaua de tip Convolutional Neural Network-Long Short-Term Memory Network (CNN-LSTM) și rețeaua Convolutional Neural Network - Bidirectional LSTM Network (CNN - BLSTM).

Metodele propuse, împreună cu studiile de cercetare realizate, au condus la obținerea rezultatelor prezentate în această lucrare de doctorat. Acest lucru, a scos în evidență capacitățile de achiziție, analiză și clasificare a activităților locomotorii prin intermediul utilizării senzorilor inerțiali precum și a avantajelor și dezavantajelor oferite de fiecare caz în parte.

1.5 Structura tezei de doctorat

Teza de doctorat este structurată în opt capitole ce acoperă partea introductivă, noțiuni tehnice fundamentale, descrierea pașilor experimentali efectuați, rezultatele experimentale obținute, respectiv concluziile și contribuțiile finale aduse domeniului studiat.

În primul și al doilea capitol s-a realizat o prezentare a domeniului studiat din punct de vedere al avantajelor respectiv al aplicabilității sistemelor de interfațare dintre om și calculator, existente la ora actuală în rândul comunității de cercetători din întreaga lume.

În primul capitol sunt prezentate principalele aspecte decizionale ce au stat la alegerea și studierea temei tratate pe parcursul acestei lucrări. De asemenea s-au prezentat principalele obiective avute pentru cercetările efectuate, precum și informații cu privire la contribuțiile aduse domeniului studiat (diseminarea rezultatelor).

În capitolul al doilea sunt prezentate informații generale cu privire la stadiul actual al soluțiilor de interfațare dintre om și calculator ce se bazează pe achiziția și interpretarea semnalelor inerțiale. De asemenea sunt evidențiate principalele abordări cu privire la structura tehnică a soluțiilor existente (arhitectură, metodă de achiziție, clasificarea datelor, etc.).

În capitolul al treilea sunt prezentate principalele metode de determinare și interpretare al activităților desfășurate de întreg corpul sau de o anumită parte a acestuia, din perspectiva determinării poziției spațiale. De asemenea, sunt prezentate principalele metode de modelare matematică, precum și principalele activități studiate pentru crearea interfețelor HCI.

În capitolul al patrulea sunt descrise principalele aspecte legate de modul de achiziție, procesare și utilizare al seriilor inerțiale temporale utilizate la dezvoltarea sistemelor de monitorizare și control propuse în această teză. De asemenea sunt evidențiate informații cu privire la modul de grupare și etichetare al seturilor de date, precum și informații relevante cu privire la cele mai comune metode de extragere a trăsăturilor din semnalele inerțiale.

În capitolul al cincilea sunt descriși principalii algoritmi clasici cu învățare automată studiați pentru rezolvarea paradigmei de clasificare a activităților motorii de la nivelul corpului. De asemenea, sunt descrise principalele tehnici de optimizare a performanțelor de clasificare pentru fiecare algoritm în parte.

În capitolul șase sunt descrise principalele categorii de algoritmi cu învățare automată profundă. De asemenea, s-a evidențiat modul prin care aceste soluții pot fi adaptate pentru a învăța și recunoaște tiparele generate de mișcarea unei anumite părți a corpului.

În capitolul șapte sunt descriși pașii experimentali realizați, precum și soluțiile propuse pentru procesarea și clasificarea gesturilor motorii de la nivelul capului. De asemenea, sunt evidențiate contribuțiile personale aduse în domeniul HCI prin metodele studiate și rezultatele obținute ca urmare a cercetării efectuate.

În continuare, în capitolul opt sunt prezentate concluziile finale, precum și direcțiile viitoare de cercetare considerând ca fundament rezultatele obținute și prezentate în această teză.

CAPITOLUL 2

Stadiul actual și aplicabilitatea sistemelor inerțiale în domeniul HCI și IoT

Acest capitol prezintă stadiul actual al literaturii cu privire la soluțiile de interfațare om-calculator bazate pe interpretarea semnalelor inerțiale. Aplicabilitatea aplicațiilor de interfațare om-calculator, precum și avantajele/dezavantajele oferite de acestea vor constitui ultima parte a acestui capitol.

2.1 Introducere

Domeniul aplicațiilor de interacțiune om-calculator (HCI) cuprinde o arie vastă de domenii interconectate ce au ca principal scop crearea soluțiilor de Interfațare între om (utilizator) și calculator. Crearea unei astfel de conexiuni, implică citirea reacțiilor locomotorii prin interpretarea și analiza semnalelor achiziționate de la senzori.

Un sistem de tip HCI, conține în structura sa pe lângă partea senzorică și o componentă dedicată procesării seturilor de date ce permite analiza și interpretarea activităților locomotorii cu scopul de a crea un canal de comunicare între utilizator și un dispozitiv extern (proteze medicale inteligente, scaun cu roțile, angrenaje mecanice, etc.).

Apariția conceptului de Internetul Lucrurilor (IoT) pentru prima dată la începutul anului 1982, urmată apoi de descrierea conceptului în 1994 de către Reza Raji în publicația IEEE Spectrum (Internet of things, 2022), a făcut ca dispozitivele de interfațare între om și calculator, să cunoască o dezvoltare majoră. Acest lucru, a condus la apariția soluțiilor portabile HCI care pot fi utilizate în domenii conexe cum sunt: domeniul medical prin monitorizarea zilnică a nivelului de sănătate, dezvoltarea de brațe robotizate cu control de la distanță, monitorizarea și oferirea de asistență pe parcursul exercitării diverselor activități zilnice, s.m.d..

2.2 Stadiul actual al interfețelor om-calculator bazat pe interpretarea semnalelor inerțiale.

Domeniul HCI precum și cel IoT a cunoscut un interes mare în ultimele două decenii din partea cercetătorilor, datorită cererii crescânde de aplicații folosite în analiza și clasificarea activităților zilnice, determinării profilurilor comportamentale, crearea posibilității de interfațare cu mecanismele robotizate, etc.. Determinarea cu precizie a anumitor activități zilnice sau detectia fenomenelor de risc la persoanele ce suferă de boli neuronale sau locomotorii constituie câteva dintre subiectele de interes care în prezent sunt dificil de rezolvat datorită anumitor factori externi. Printre acești factori se pot enumera: determinarea poziției optime a senzorilor, utilizarea metodelor optime de achiziție și procesare a seturilor de date sau utilizarea metodelor computaționale ce oferă performanțele cele mai bune de clasificare. Ținând cont de aceste aspecte, dezvoltarea aplicațiilor de interfațare om-calculator pe baza interpretării seriilor inerțiale, se pot grupa în 3 mari clase (Gupta, 2020):

- În funcție de tehnologia de calcul utilizată (analiza seturilor de date de intrare, tehnicile de extragere a trăsăturilor, algoritmi de învățare utilizați)

- În funcție de tipul sistemelor de recunoaștere a activităților (clasificare în timp real, monitorizare și clasificare pentru o singură persoană sau pe mai multe persoane, etc.)
- În funcție de domeniul de aplicabilitate (medical, divertisment, case inteligente, automotive, etc.)

În literatura de specialitate sunt menționate două abordări diferite de utilizare a senzorilor inerțiali. Prima abordare se referă la utilizarea independentă a senzorilor accelerometrici și giroscopici, în timp ce ce-a de a doua metodă constă în utilizarea unor sisteme inerțiale complexe ce interpretează informațiile inerțiale de la cel puțin 3 senzori (de ex.: accelerometru, giroscop și magnetometru). De asemenea, în (Reich et al., 2020) se sugerează faptul că în majoritatea aplicațiilor de recunoaștere a gesturilor, cea mai comună abordare cu privire la plasarea senzorilor inerțiali este cea în care senzorii sunt plasați la nivelul cavității toracice, urmată de cea în care senzorii sunt plasați la nivelul membrelor superioare și inferioare. O abordare ce nu a fost studiată foarte mult până în acest moment, este cea în care senzorii inerțiali sunt poziționați la extremitățile corpului omenesc (de ex.: cap sau extremitățile de la nivelul membrelor superioare sau inferioare). Acest lucru, evidențiind faptul că majoritatea studiilor au fost axate pe analiza activităților generale și mai puțin pe analiza și clasificarea unor activități exercitate de o anumită parte a corpului. Marea majoritate a aplicațiilor existente în literatura au ca obiectiv determinarea cu precizie a anumitor activități zilnice uzuale ca: îmbrăcare, mers normal, șezut pe scaun, urcat scări, coborât pe scări, s.a.m.d.. O altă categorie de aplicații vizează identificarea unor evenimente de risc întâlnite în general la persoanele vârstnice, cu scopul de a crește nivelul de siguranță. Printre aceste evenimente se pot enumera: detectarea căzăturilor accidentale la persoanele vârstnice (Nahian, et al., 2021), detectarea sindromului înghețării mersului pentru persoanele ce suferă de boala Parkinson (Demrozi et al., 2020b), detecția poziției coloanei vertebrale (Bramhapurika, et al., 2018), (Liu, et al., 2022), etc.. O altă abordare întâlnită în dezvoltarea soluțiilor de interfațare om-calculator se bazează pe utilizarea telefoanelor inteligente (Mekruksavanich, et al., 2022a) sau a ceasurilor inteligente (Mekruksavanich, et al., 2022b) în citirea anumitor fenomene psihologice sau locomotorii provenite de la utilizatorii acestora. Studiile publicate în ultimii 5 ani în domeniul HCI și IoT bazate pe utilizarea senzorilor inerțiali, au vizat 4 puncte de interes: studierea fenomenelor locomotorii și neurologice utilizând diferite tipuri de senzori inerțiali, studierea tehnicilor de combinare a semnalelor inerțiale (Eng. “Fusion algorithms”), evaluarea performanțelor prin aplicarea metodelor de calcul inteligente (algoritmi clasici cu învățare automată sau algoritmi cu învățare profundă automată), studierea tehnicilor de inginerie a datelor și studierea diferiților subiecți umani (de ex., persoane vârstnice, persoane cu probleme medicale locomotorii, s.a.m.d).

Cel mai important rol al sistemelor HCI sau IoT bazat pe interpretarea semnalelor inerțiale este acela de a detecta mișcarea sau orientarea spațială cu scopul de a diagnostica, interpreta sau de a controla anumite interfețe HCI.

În ceea ce privește componenta de calcul, în literatură s-au identificat două abordări majore. Prima abordare se bazează pe utilizarea algoritmilor cu învățare automată clasici. În timp ce a doua abordare constă în utilizarea algoritmilor cu învățare profundă. Deși rezultatele publicate până în acest moment în literatura de specialitate sunt foarte bune, domeniul HCI și IoT este în continuă dezvoltare datorită nevoii crescânde de soluții tehnice ce trebuie să respecte următoarele criterii: cost, performanță și purtabilitate.

2.3 Arhitectura unei interfețe om calculator în domeniul HCI și IoT

Un sistem HCI bazat pe utilizarea senzorilor inerțiali este compus din 4 componente principale: un bloc de achiziție, urmat de un bloc de preprocesare (de ex., filtrare a semnalelor inerțiale), un bloc de procesare a seturilor de date (extragere trăsături), un bloc de predicție și clasificare și un bloc de diagnoză și control.

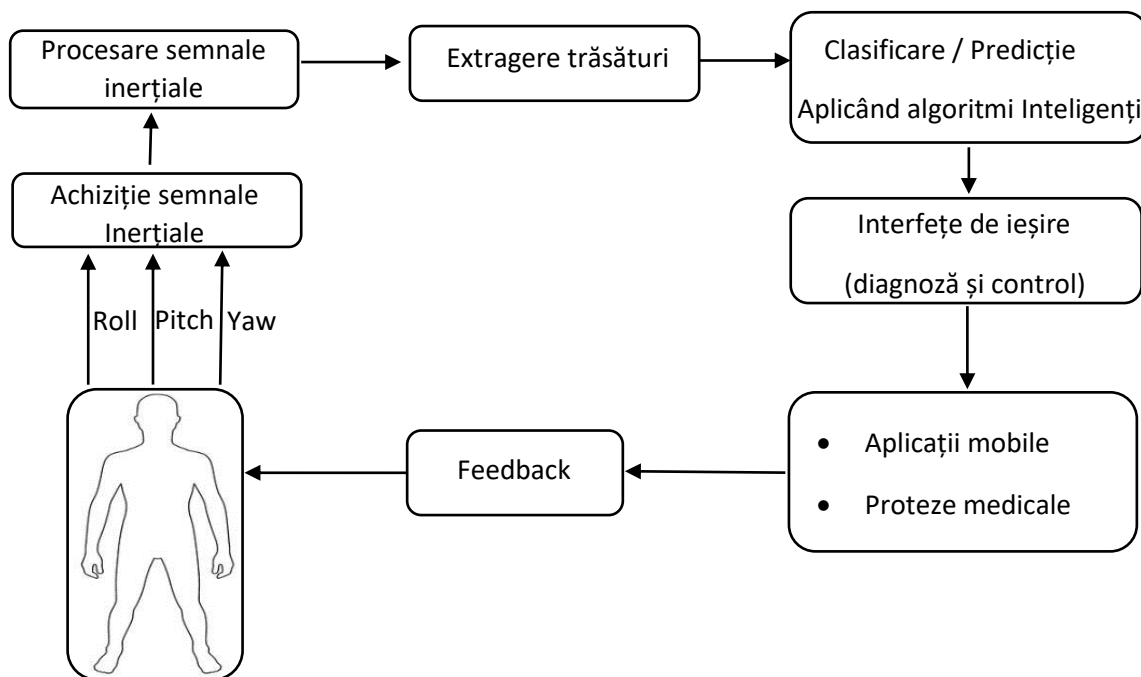
Blocul de achiziție și filtrare a datelor, are rolul de a citii informațiile generate de mișcarea întregului corp sau a unei anumite părți din corp (cap, brațe, picioare) prin utilizarea senzorilor inerțiali poziționați în diferite părți a corpului.

Blocul de procesare a seturilor de date, are rolul de a extrage trăsăturile definitorii din seriile temporale inerțiale și de a formata structura acestora cu scopul de a putea fi utilizate ulterior în antrenarea algoritmilor inteligenței de clasificare și predicție. Rolul blocului de clasificare și predicție fiind acela de detecție și clasificare a activităților exercitate de către utilizatori. Blocul de diagnoză și control oferă un stimul sau o suită de informații ca urmare a analizei seturilor de date de intrare, către dispozitivul sau mecanismul electromecanic extern.

Includerea senzorilor inerțiali în diverse dispozitive portabile (telefoane mobile, ceasuri inteligente, etc.), face ca la ora actuală astfel de senzori să fie utilizați în diverse sisteme de comandă, control sau diagnosticare în detrimentul altor topologii de senzori.

Provocările din acest moment constau în proiectarea și realizarea dispozitivelor portabile ce trebuie să ofere performanțe de clasificare ridicate cu un cost redus de dezvoltare a soluției hardware și software, precum și determinarea activităților desfășurate de anumite părți ale corpului, respectând condiția de portabilitate și uzabilitate în condiții reale de utilizare.

O reprezentare generalizată a unui astfel de sistem se poate observa în Figura 1.



Figură 1 Reprezentarea generalizată a unei arhitecturi de interfațare om-calculator bazată pe interpretarea semnalelor inerțiale

2.4 Aplicabilitatea sistemelor inerțiale în domeniul HCI și IoT

Inspectând domeniul tehnic, s-a observat o diversitate în ceea ce privește domeniile de aplicabilitate, însă marea majoritate a aplicațiilor au ca scop asistarea, diagnosticarea sau oferirea posibilității de control pentru anumite mecanisme electromecanice sau interfețe grafice. Printre domeniile vizate de aplicațiile HCI și IoT se pot aminti: domeniul dezvoltării aplicațiilor medicale de diagnosticare (detectia fluxului respirator (Karacocuk, et al., 2019), detectia calitatii somnului (Doheny, et al., 2020), detectia nivelului de stres (Verma, et al., 2019), etc.), domeniul dezvoltării echipamentelor de protecție în medii cu un grad ridicat de risc (căști de protecție inteligente pentru persoanele ce lucrează în fabrici) (Tao, et al., 2018), domeniul construcțiilor (Sung, et al., 2018), pompieri (Hackett, et al., 2019), etc.), domeniul dezvoltării aplicațiilor de asistare a persoanelor în vârstă (detectarea căzăturilor involuntare (Shen, et al., 2021), detectarea rutinelor zilnice cu scopul detectării stării de sănătate (Cheng & Jing, 2017), etc., domeniul dezvoltării aplicațiilor de monitorizare a activităților zilnice (Nandy, et al., 2019), domeniul dezvoltării aplicațiilor de control (scaune cu roțile inteligente (Gomes, et al., 2019), control roboți (Wang, Y., et al., 2020), etc.), Entertainment (Seo & Choi, 2018), sisteme de monitorizare a traficului (Tian, et al., 2018), sisteme de monitorizare a activității șoferului (Hsieh, et al., 2018), sisteme inteligente de zbor (drone) (Xiaomin, et al., 2021), sisteme de detecție a condițiilor de condus (Bassam, et al., 2020), sisteme de diagnoză și de detecție a erorilor (Windau & Itti, 2018), sisteme de detecție și asistare a activităților sportive (Farrokhi, et al., 2021), aplicații medicale de asistare a persoanelor cu probleme neurologice sau locomotorii (epilepsie (Jeyabharathi, et al., 2020), Parkinson (Pierleoni, et al., 2019), Alzheimer (Varatharajan, et al., 2018), stenoza coloanei lombare și osteoartrita genunchiului (Odonkor, et al., 2020), etc.) sau sisteme de ameliorare a stării de sănătate (ameliorarea activităților fizice (Li J., et al., 2021), reabilitare (Pereira, et al., 2019), etc.).

Creșterea calității vieții, precum și diagnosticarea sau detectarea din timp a anumitor probleme de sănătate, au făcut ca domeniul medical să devină unul dintre principalele arii tehnice unde senzorii inerțiali pot fi utilizați. Un alt factor care a favorizat interesul tot mai mare pentru acest domeniu, a fost cauzat de dorința de a dezvolta soluții inovative pentru persoanele ce locuiesc în medii izolate sau la o distanță relativ mare față de cele mai apropiate centre medicale. Astfel, soluțiile HCI și IoT cu aplicabilitate în medicină încearcă să determine cu exactitate următoarele sarcini: prevenție, detecție, diagnosticare, reabilitare sau control. Atenția principală în rezolvarea fiecărei sarcini amintite anterior, este pusă asupra citirii, procesării și clasificării cu exactitate a diverselor activități neuro-motorii realizate de întreg corpul sau de o anumită parte a acestuia.

2.5 Avantajele și dezavantajele sistemelor HCI și IoT

Până în acest moment, în literatura de specialitate, numeroase studii de cercetare au vizat studierea sistemelor HCI și IoT oferind informații prețioase cu privire la performanțele, avantajele sau dezavantajele date de aceste sisteme. Printre provocările apărute în dezvoltarea sistemelor HCI și IoT se pot aminti: timpii petrecuți în achiziția și procesarea semnalelor, purtabilitatea sistemelor propuse, timpii petrecuți în antrenarea modelelor de clasificare și predicție sau limitările datorate utilizării zilnice a sistemelor propuse. Prin urmare, sistemele HCI și IoT se confruntă cu o serie de provocări atât din punct de vedere hardware, cât și software. La nivel hardware, principalele provocări apărute pot fi: dimensiunea dispozitivului de achiziție, rata de transfer a informațiilor,

modul de extragere al trăsăturilor, etapei de calibrare sau de filtrare a zgomotului. Pe lângă provocările amintite anterior, o altă provocare ce apare este datorată tipului de senzor utilizat și a modului de plasare a acestuia. Astfel, în literatură sunt prezente 3 abordări principale prin care activitățile desfășurate de întreg corpul pot fi monitorizate. Aceste metode sunt cunoscute ca: vision-based (interpretarea semnalului foto-video), sensors-based (utilizarea informației de la diverși senzori purtabili) sau smartphone-based (utilizarea telefonului mobil și a senzorilor montați în interiorul acestuia). Aceste metode oferă o serie de avantaje și dezavantaje în funcție de complexitatea activităților monitorizate și de nivelul de portabilitate avut în vedere.

Astfel, au apărut două direcții majore, prima s-a bazat pe utilizarea senzorilor inerțiali înglobați în telefoanele mobile, în timp ce a doua s-a bazat pe studierea și utilizarea senzorilor inerțiali purtabili independenți în diverse soluții HCI. Printre principalele limitări oferite de sistemele HCI bazate pe utilizarea senzorilor inerțiali plasați în interiorul telefoanelor mobile se pot aminti: imposibilitatea monitorizării unor anumite zone ale corpului, imposibilitatea determinării cu exactitate a gesturilor cu o complexitate ridicată sau imposibilitatea de extindere a numărului de senzori. Ca și principale avantaje oferite de această metodă menționez: sistemul este ușor de utilizat și de purtat, oferă posibilitatea utilizării zilnice și oferă posibilitatea achiziției de date de la un grup mare de utilizatori fără a necesita o pregătire prealabilă a utilizatorilor. Metoda bazată pe utilizarea senzorilor inerțiali purtabili este o metodă relativ nouă ce vizează determinarea cu acuratețe a gesturilor sau activităților efectuate de întreg corpul sau de o anumită parte a acestuia. Printre avantajele oferite de această abordare se regăsesc: posibilitatea plasării senzorilor în diverse părți ale corpului, posibilitatea proiectării unor prototipuri moderne și ușor de utilizat, oferă un cost redus de implementare și pot opera în medii dificile. Cu toate acestea, sistemele HCI bazate pe senzori inerțiali purtabili întâmpină câteva limitări de natură constructivă. Astfel, această categorie de sisteme, necesită utilizarea unei rețele de senzori care trebuie purtați ori montați în diferite părți ale corpului, acest lucru limitând posibilitatea utilizării zilnice.

O altă problemă majoră a sistemelor HCI de monitorizare și clasificare a gesturilor este cauzată de lipsa unei metode de generalizare a activităților realizate pe diverse grupe de oameni. Un avantaj oferit de sistemele HCI inerțiale este dat de posibilitatea combinării seturilor de date prin utilizarea altor tipuri de senzori, astfel crescându-se nivelul de încredere și de precizie, obținându-se astfel un set de date cât mai robust.

CAPITOLUL 3

Aspecte teoretice asupra metodelor și sistemelor folosite în determinarea poziției spațiale

3.1 Generalități


Dezvoltarea sistemelor HCI de asistare și monitorizare a activităților reprezintă o paradigmă ce implică explorarea comportamentală a mediului într-un mod inteligent și adaptabil bazat pe analiza acțiunilor realizate de oameni. Acest lucru, conduce la obținerea unor soluții dinamice de interfațare ce oferă o îmbunătățire a calității vieții prin creșterea eficienței de execuție a anumitor sarcini sau de creștere a confortului zilnic. Alegerea

tipului de senzor este un pas foarte important și trebuie luat în considerare atunci când se dorește propunerea și dezvoltarea unor sisteme HCI.

În literatura de specialitate se regăsesc două categorii majore de senzori folosiți pentru citirea tiparelor relevante produse prin mișcarea corpului: senzori ambientali și senzori purtabili. O serie de senzori ambientali ca senzorii audio, camere video, senzori de prezență, sau senzori Kinect au fost deja introduși în dezvoltarea aplicațiilor HCI în ultimul deceniu. Cu toate că performanțele oferite de astfel de senzori cu privire la citirea mișcării și localizării operatorilor umani sunt destul de bune, această topologie de senzori necesită o infrastructură statică ceea ce limitează aria de utilizare la un anumit spațiu. Acest lucru, a făcut ca utilizarea senzorilor purtabili să devină o alternativă fiabilă prin intermediul căreia semnalele de interes sunt citite direct de la utilizatori. Față de categoria senzorilor ambientali, senzorii purtabili oferă o serie de avantaje precum: nu necesită un echipament fix de referință și nu sunt dependenți de mediul în care sunt realizate măsurătorile. Cele două topologii de senzori utilizați în determinarea poziției spațiale sau a activităților corporale sunt evidențiate în Figura 2.

Pentru determinarea cu exactitate a orientării în spațiul tridimensional, în literatura de specialitate există o serie de modele matematice ce pot fi utilizate pentru determinarea ecuațiilor de mișcare, bazate pe informații achiziționate de la senzorii purtabili plasați pe corp. Printre metodele matematice de predicție existente, se pot aminti:

- Determinarea orientării în spațiul 3D utilizând normalizarea cuaternarilor și matricea de rotație folosind unghiurile Euler
- Utilizarea filtrului Kalman
- Utilizarea filtrului complementar
- Utilizarea filtrului Madgwick



Senzori Ambientali:

Senzor de proximitate: 10

Senzor de prezență: 11

Camera foto-video: 12

Senzor de intensitate luminoasă: 13

Senzori Purtabili:

Senzor Inerțial: 1,3, 7, 8, 9

Senzor de detecție a semnalelor vitale: 5

Senzor Pedometru: 2

Camera video: 6

Figură 2 Exemple de senzori ambientali și purtabili utilizați în determinarea orientării spațiale a corpului

3.2 Metode de control și evaluare folosite în sistemele inerțiale

În domeniul medical, sistemele bazate pe interpretarea semnalelor inerțiale au început să fie introduse în utilizări clinice reale, astfel în acest context se pune problema identificării performanței unui astfel de sistem și a determinării performanțelor oferite de acestea în rezolvarea anumitor sarcini predefinite. În procesul de proiectare și dezvoltare a unui astfel de sistem, un pas important îl constituie etapa de evaluare și validare a rezultatelor. În continuare, în această secțiune se vor prezenta câteva dintre metodele uzual folosite în procesul de identificare, clasificare și evaluare a sistemelor de interfațare om-calculator prin intermediul interpretării semnalelor inerțiale.

3.2.1 Metode de control folosite în sistemele de interfațare om-calculator

Pe parcursul acestei teze de doctorat, prin metode de control se face referire la tehnicile utilizate în fuziunea semnalelor inerțiale provenite de la diverse categorii de senzori inerțiali (accelerometru, giroscop sau magnetometru). Pentru ca un sistem HCI inerțial să obțină performanțe adecvate, este necesară operarea pe seturi de date ce cuprind mărimi relevante (trăsături). Astfel, prin identificarea și extragerea elementelor perturbatoare din semnalele inerțiale brute, se pot obține trăsături relevante ce pot conduce la sisteme de interfațare eficiente și cu performanțe de clasificare ridicate. S-a identificat faptul că cele mai comune abordări și în același timp cele mai eficiente sunt date de către filtrul Kalman și filtrul Complementar (López-Nava & Meléndez-Muñoz, 2016).

Metoda Kalman este cunoscută în literatura de specialitate sub denumirea de estimator pătratic liniar. Acesta oferă posibilitatea de estimare a valorilor necunoscute, utilizând o serie de măsurători observabile într-o perioadă de timp. Acest algoritm de predicție este compus din două etape: etapa de actualizare a setului de date și etapa actualizării perioadei de timp.

Principala caracteristică a filtrului Kalman este dată de faptul că, pentru a oferi o estimare a valorii dorite cât mai exactă se va face o medie ponderată. Estimarea certitudinii pentru fiecare măsurătoare face ca evaluarea comportamentului filtrului Kalman să fie făcută din punct de vedere al câștigului (K_k). Factorul de câștig, este conceput ca o modalitate prin care se poate obține control asupra gradului de estimare.

Un avantaj îl reprezintă faptul că funcționează foarte bine în cadrul sistemelor dinamice ce conțin componenta de eroare (zgomot), acesta atenuând erorile de înaltă și joasă frecvență de pe fiecare canal de măsurare. O alternativă la algoritmul filtrului Kalman, este dată de utilizarea topologiei filtrelor complementare. Această metodă realizează estimarea poziției spațiale combinând informațiile provenite de la ambele categorii de senzori purtabili (inerțiali și magnetici) incluși într-un sistem inerțial. Filtrele complementare pot fi utilizate în combinarea informației provenite din două măsurători diferite ale unui semnal comun ce conțin diferite niveluri de zgomot cu scopul de a produce o ieșire unică (Young, 2009). Astfel, această categorie de algoritmi de predicție, iau în considerare caracteristicile spectrale complementare ale semnalelor zgomotoase, realizând astfel o estimare finală a orientării corpului în spațiu. Estimarea orientării obținută pe baza informațiilor provenite de la accelerometru și magnetometru sunt zgomotoase, însă precizia pe termen lung nu este afectată. În ceea ce privește estimarea orientării spațiale pe baza senzorului giroscopic, acestea sunt precise pe o perioadă scurtă, în timp ce pe perioade mai mari acestea prezintă un factor de derivă în timp. În acest context, proprietățile semnalelor inerțiale provenite de la fiecare dintre cele 3 categorii pot

fi exploatare și interpretate în domeniul frecvență. Astfel, pentru cazul informațiilor provenite de la senzorul giroscopic, componenta utilă relevantă pentru mișcarea corpului în spațiu este regăsită la frecvență înaltă. Pentru filtrarea lor de celelalte componente de semnal, s-a utilizat filtrul trece sus. În schimb, pentru accelerometru și magnetometru componentele de semnal de interes sunt localizate la frecvențe joase. Acest lucru face ca filtrarea acestora să fie realizată prin intermediul filtrului trece jos. Din acest motiv, pentru cazul Filtrului Complementar trebuie avut în vedere faptul că, această tehnică de fuziune a datelor cuprinde două mari componente: componenta filtrului trece sus și componenta filtrului trece jos. În acest context, filtrul trece jos, are rolul de a lăsa să treacă doar modificările pe termen lung, filtrând astfel fluctuațiile întâlnite pe termen scurt. Ce-a de-a doua componentă a filtrului complementar, dată de către filtrul trece sus, are rolul de a lăsa să treacă doar modificările pe termen scurt, filtrând astfel fluctuațiile întâlnite pe termen lung. Pentru a ține cont de cele două caracteristici amintite anterior, filtrul complementar implică calcule de mediere între valorile date de accelerometru și magnetometru, cu cele date de senzorul giroscopic.


Așa cum s-a precizat în acest capitol, informațiile provenite de la senzorii purtabili sunt afectate de către componenta de eroare, ce în majoritatea situațiilor este un factor limitativ în obținerea unor performanțe de clasificare satisfăcătoare. Astfel, această componentă poate fi împărțită în două categorii: erori sistematice sau erori aleatorii. Erorile sistematice sunt datorate erorilor de proiectare a senzorilor purtabili sau a caracteristicilor de fabricare. În timp ce erorile aleatorii sunt cauzate de interferențe, zgomot de fundal, instabilitatea sistemelor de măsurare, etc.. Astfel această clasă se poate divide la rândul ei în două subgrupuri cunoscute sub denumirea de: zgomot de bandă largă (necorelat) și zgomot de bandă îngustă (corelat) (Collin, et al., 2018).

CAPITOLUL 4

Aspecte privind achiziția, procesarea și utilizarea seriilor inerțiale

4.1 Generalități

Proiectarea și validarea sistemelor noi de detecție cuprind 4 pași principali. Primul pas este reprezentat de identificarea topologiei senzorilor purtabili și a metodei de achiziție. Al doilea pas este reprezentat de către achiziția seturilor de date și identificarea metodelor de preprocesare al acestora. Următoarea etapă constă în identificarea metodelor de calcul inteligente (algoritmi clasici cu învățare automată vs algoritmi clasici cu învățare profundă) și de antrenare al acestora utilizând seturile de date obținute la pasul anterior. Ultimul pas este dat de evaluarea performanțelor de clasificare oferite de către modelele de calcul alese. Pentru exemplificarea afirmațiilor anterioare, în Figura 3 este evidențiat procesul propus și utilizat în această teză de doctorat, pentru cazul sistemelor purtabile ce au ca obiectiv identificarea mișcărilor de la nivelul capului.



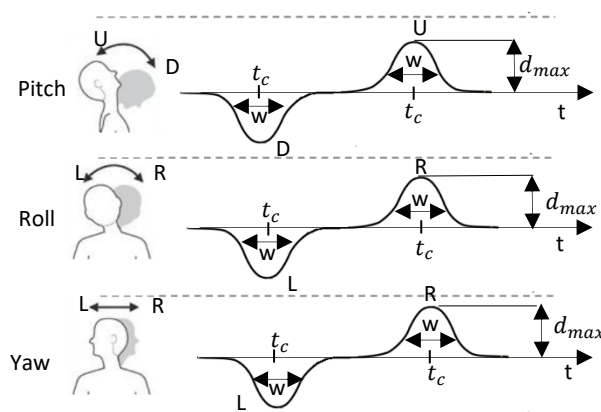
Figură 3 Exemplu de proces utilizat la implementarea sistemelor de recunoaștere a activităților de la nivelul capului folosind senzorii inerțiali

4.2 Metode de achiziție

Achiziția semnalelor inerțiale în condiții reale de operare reprezintă un cadru ideal pentru partea experimentală, însă, în anumite situații nu este posibilă explorarea acesteia. Astfel, partea experimentală se poate realiza în medii semi-controlate de laborator, cu scopul de a simula condiții reale. În caz contrar, mediile experimentale complet controlate reprezintă ultima sursă de achiziție a datelor, deși validitatea rezultatelor obținute este incertă până în momentul în care acestea sunt verificate în medii reale de operare. Câteva dintre problemele observate la sistemele propuse în literatură, sunt datorate nivelului scăzut de generalizare, reproductibilitate scăzută ori purtabilitate limitată (Severin, 2021b). Achiziția semnalelor relevante pentru analiza orientării spațiale a corpului poate fi realizată utilizând senzorii înglobați în dispozitive purtabile (Ex: telefoane mobile, ceasuri inteligente, etc.) ori utilizând senzorii inerțiali ca elemente independente ce pot fi atașate de anumite părți ale corpului prin intermediul dezvoltării unor sisteme expert. Achiziția semnalelor utilizând dispozitive purtabile este caracteristică analizei și monitorizării mișcării locomotorii generale efectuate la nivelul întregului corp. Prin această metodă de achiziție, este dificilă analiza unei anumite părți a corpului. Prin urmare, utilizarea senzorilor inerțiali independenți este oportună pentru identificarea gesturilor realizate de anumite părți ale corpului. Un aspect important în procesul de achiziție a semnalelor inerțiale este stabilirea unor șabloane inițiale pentru fiecare activitate locomotorie studiată. Acest lucru facilitează atât analiza cât și procesarea ulterioară a seturilor de date. Astfel, în procesul de măsurare a mișcării capului, deplasarea capului (d) în spațiul 3D pe o perioadă dată de timp (t), poate fi aproximată sub forma unei funcții Gauss descrisă de următoarea relație matematică:

$$d = d_{max} * e^{-\left(\frac{t-t_c}{\omega}\right)^2} \quad Eq.1$$

Deplasarea maximă a capului este caracterizată de către d_{max} , t_c definește centroidul distribuției Gauss, în timp ce ω caracterizează lățimea vârfului.



Figură 4 Formă de undă dependentă de mișcarea de la nivelul capului

O exemplificare a caracteristicii de semnal create în urma deplasării capului în planul 3D se poate observa în Figura 4.

4.3 Metode de grupare și etichetare a seturilor de date

Procesul de clasificare al sarcinilor locomotorii, realizate la nivelul capului reprezintă o etapă ce se bazează pe interpretarea seriilor temporale, cu scopul de a realiza o predicție asupra seturilor de date observabile (activități motorii). Gruparea seturilor de date în funcție de activitatea motorie de interes, este o etapă ce în cazul sistemelor portabile se realizează manual. Acest lucru, constând în asocierea unei etichete fiecărei serii temporale cu scopul de a identifica și interpreta ulterior seturile de date prezise de către modelele de calcul utilizate. Un astfel de model de învățare (supravegheat), va asocia întotdeauna tiparelor necunoscute, etichete ale claselor definite, pe baza informațiilor (cunoscute) stabilite inițial. În literatura de specialitate, există două abordări distincte în funcție de topologia modelului, astfel, se identifică modele de tip supravegheat unde etichetarea datelor este obligatorie, respectiv modele de tip nesupravegheat, unde etichetarea datelor nu este obligatorie. Din moment ce sistemele portabile de detecție și clasificare a mișcărilor de la nivelul capului, trebuie să returneze o etichetă corespunzătoare unei sarcini, cum este de exemplu: mișcare la dreapta, mișcare la stânga, etc., majoritatea sistemelor existente folosesc modele supravegheate. Modul de operare folosind modele de tip nesupravegheat, oferă informații de predicție greu de interpretat într-un context de sistem cu modele de calcul de tip complet nesupravegheat. Astfel, o soluție este utilizarea sistemelor hibride ce cuprind atât structuri ale modelelor de tip supravegheat, cât și structuri ale modelelor de tip nesupravegheat. În funcție de domeniul de lucru și formatul semnalelor de intrare, setul de date a fost caracterizat de trei categorii: caracteristici brute, caracteristici în domeniul timp, și caracteristici în domeniul frecvență.

În funcție de tipul de model de clasificare utilizat (model clasic cu învățare automată vs model cu învățare profundă), etichetele pot fi definite având diferite forme (text, numeric sau binar). În ceea ce privește stabilirea dimensiunii oportune a unei ferestre de timp, astfel încât toată informația relevantă să fie acoperită, în literatură nu există o metodă standard prin care se poate determina această valoare. Astfel, determinarea dimensiunii optime pentru fiecare fereastră se realizează prin încercări pe perioada realizării fazei de testare. Totuși, în literatură există o metodă dinamică, ce oferă posibilitatea captării întregii cantități de informație prin suprapunerea unei anumite porțiuni din informație. Această metodă este cunoscută sub denumirea de metoda “Ferestrelor glisante”.

S-a identificat faptul că factorul de suprapunere poate avea valori între 1% și 50%, însă această valoare este stabilă independent de fiecare aplicație în parte. Pe parcursul pașilor experimentali realizați, factorul de suprapunere a fost configurat la valoarea de 50%, cu o fereastră de 256 (5.12s) elemente pentru fiecare categorie în parte (Severin, 2020c).

4.4 Metode de extragere a trăsăturilor din seturilor de date

Pentru a obține performanțe ridicate de clasificare, un sistem de tip HCI trebuie să lucreze cu mărimi ce descriu proprietăți relevante ale semnalelor utilizate. Aceste mărimi sunt cunoscute în literatură sub denumirea de “trăsături relevante”. Trăsăturile identificate trebuie să fie relevante și să descrie bine semnalele locomotorii produse prin mișcarea corpului, respectiv a unei anumite părți a acestuia (cap, mâini, picioare, etc.), în caz contrar, algoritmi de predicție utilizați vor oferi informații eronate. Rezultatul aplicării acestor metode de extragere a trăsăturilor, constă în construirea unui vector de date,

utilizat ulterior în definirea setului final de antrenare pentru modelele de clasificare. Astfel, etapa de identificare și extragere a trăsăturilor are ca principal scop realizarea unei reprezentări potrivite a setului de date cu scopul de a crește performanțele sistemului final de clasificare. În domeniul timp, caracteristicile statistice de semnal pot fi determinate prin utilizarea ecuațiilor matematice.

În domeniul frecvență, caracteristicile de semnal sunt adesea determinate prin utilizarea Transformatei Fourier (FFT), Analiză Spectrală ori prin utilizarea Transformatei Wavelet. În ceea ce privește domeniul spațial, metoda analizei pe componente principale (Principal component analysis-PCA), respectiv cea a analizei liniare discriminantă (Linear Discriminant Analysis- LDA) oferă posibilitatea identificării caracteristicilor de semnal, astfel încât, în final algoritmi de clasificare să poată identifica cu ușurință fiecare clasă asociată unei activități locomotorii.

Strategia de alegere a caracteristicilor de semnal, este stabilită în general experimental în funcție de obiectivul fiecărei aplicații în parte.

CAPITOLUL 5

Metode inteligente folosite în clasificarea semnalelor: Algoritmi clasici de tip învățare automată

În acest capitol sunt descrise principalele metode de calcul cu învățare automată utilizate în procesul de recunoaștere al gesturilor motorii produse de corpul uman.

5.1 Metode de tip învățare automată supervizată

În continuare se va face o descriere asupra algoritmilor de învățare automată utilizați la evaluarea modelului de recunoaștere a gesturilor de la nivelul capului, utilizând senzorii inerțiali.

5.1.1 Clasificatorul Support Vector Machine

În cadrul algoritmului SVM, fiecare valoare este reprezentată de un punct în spațiul n -dimensional (unde n este numărul total de caracteristici de intrare), în timp ce valoarea unui atribut determină coordonatele fiecărui punct (Harrington, 2012). Sarcina de clasificare, se va implementa prin intermediul determinării hiperplanului ce diferențiază cele n clase de apartenență. Intuitiv, o delimitare bună a seturilor de date, este obținută de hiperplanul care are cea mai mare distanță până la cea mai apropiată valoare de antrenament, indiferent de clasa din care acesta face parte. Deși, modelul inițial este definit într-un spațiu finit dimensional, este posibil ca setul de date să nu fie separabil liniar în acel spațiu. Din această cauză, s-a propus ca spațiul finit original să fie proiectat într-un spațiu mai mare ca dimensiune, separarea seturilor de date fiind mai ușor de realizat. Alegerea vectorilor care caracterizează hiperplanurile, poate fi realizată ca o combinație liniară cu parametrii α_i ai vectorilor de caracteristici care există în setul de date.

Modelele SVM sunt algoritmi cu învățare automată supervizată, ce oferă posibilitatea analizării setului de date de intrare cu scopul recunoașterii de tipare, utilizate apoi pentru a rezolva sarcinile de regresie și de clasificare. Acest algoritm are proprietăți de

generalizare bune iar performanțele de clasificare nu sunt influențate de dimensiunea setului de date.

5.1.2 Clasificatorul *k*-Nearest Neighbors (“Cei mai apropiați *k* vecini”)

Clasificatorul *k*-NN sau “*cei mai apropiați k vecini*”, reprezintă o metodă de clasificare ce se bazează pe cele mai apropiate *k* clase din setul de antrenare. Acest algoritm este unul dintre cei mai simpli algoritmi de învățare, deoarece un element din setul de date este clasificat în funcție de “votul” majoritar al vecinilor săi, astfel în final, acestea sunt grupate ca făcând parte din categoria unde sunt plasați cei mai mulți *k* vecini. Etapa de învățare este bazată pe calcularea similarităților a *n* elemente din setul de test, cu *k* elemente din setul de antrenament. În etapa de clasificare, pentru fiecare element din setul de testare, se va asocia o clasă corespunzătoare cu distanța minimă față de aceasta. Parametrul *k*, este o caracteristică specifică ce are de obicei valori mici. Alegerea optimă a valorii pentru acest parametru este dată de caracteristica setului de date.

Un principal avantaj oferit de acest algoritm este dat de simplitatea în crearea modelelor de predicție. Algoritmii *k*NN sunt populari în rândul cercetătorilor din domeniul HCI, deoarece aceștia operează bine pe seturi de date cu dimensiuni reduse.

5.1.3 Clasificatorul *Random Forest* (“Pădure Aleatorie”)

Acest algoritm este încadrat în categoria algoritmilor de tip ansamblu, acest lucru constând în combinarea multiplă a mai multor structuri de modele predictive într-un singur model predictiv, pentru a reduce varianța erorii și pentru a crește astfel performanțele de clasificare. Structura acestuia este bazată pe un ansamblu de arbori de decizie instruiți cu metoda încapsulării (Hastie, et al., 2017). Acest algoritm construiește o multitudine de arbori de decizie, pe care apoi îi îmbină, cu scopul de a obține o predicție precisă și stabilă.

O caracteristică definitorie a acestui algoritm, este dată de faptul că odată cu creșterea numărului de “arbori” din structura sa, va crește și gradul de identificare corectă a fiecărei clase prin partiționări recursive. Acest lucru este caracterizat de faptul că algoritmul caută cea mai bună caracteristică dintr-un subset aleatoriu de valori, având ca rezultat o diversitate mare de valori și implicit de un model cu performanțe de clasificare mai bune.

Un avantaj oferit de acest model, este dat de faptul că oferă rezultate satisfăcătoare de clasificare, utilizând valorile implicite ale hiperparametrilor. S-a observat faptul că, odată cu creșterea numărului de arbori din structura algoritmului, performanțele de clasificare cresc exponențial, însă odată cu acest pas, crește și timpul de execuție al algoritmului.

5.2 Metode de evaluare a performanțelor

5.2.1 Matricea de confuzie

Această metodă constă în crearea unui tabel, prin care se determină informații legate de precizia cu care se identifică fiecare clasă. Astfel, pe o axă a matricei de confuzie sunt plasate valorile etichetelor pe care modelul le-a prezis, în timp ce pe cealaltă axă sunt plasate valorile reale ale etichetelor (specificate în setul de date inițial). Numărul elementelor de pe fiecare axă în parte este direct dependent de numărul etichetelor prezente în setul de date. Valorile prezente pe diagonala matricei de confuzie sunt valori

corect determinate. În timp ce, informațiile prezente în restul matricei sunt caracterizate de componenta de eroare în clasificarea claselor.

5.2.2 Precizie, Acuratețe, Senzitivitate și Specificitate

O altă categorie de metrice utilizate pentru evaluarea performanțelor de clasificare sunt reprezentate de calcularea preciziei, acurateței, sensibilității și specificității. Astfel, precizia se poate defini ca raportul creat între valorile corect clasificate (TP) raportate la numărul total de valori clasificate corect. Pentru cazul calculării acurateței, această metrică se poate defini ca fiind proporția creată între valorile clasificate corect (TP și TN) raportat la numărul total al instanțelor clasificate (TP, FP, FN și TN).

Astfel, această metrică oferă informații despre cât de bine modelul propus clasifică fiecare clasă independentă. Valoarea sensibilității este o măsură ce oferă informații despre cât de bine modelul de clasificare, clasifică fiecare valoare din setul de date ca aparținând clasei corecte (TP) raportat la numărul total de predicții pozitive. În contrast cu metrica de *sensitivitate*, metrica de *specificitate* determină cât de bine modelul de clasificare determină corect că nu aparține unei clase (TN).

Pe lângă metricile prezentate anterior, în literatura de specialitate există o serie de metrici statistice care pot fi utilizate pe scară largă, cum este cazul graficului de învățare, scorului F1, determinarea curbei ROC (receiver operating characteristic curve) sau determinarea graficului Precizie-Senzitivitate. Prin calcularea scorului F (Eng. F-Score), se determină o caracteristică generală a acurateței, prin combinarea informațiilor date de valoarea preciziei și specificității. Astfel, această metrică este adesea utilizată în situațiile în care setul de date are o distribuție inegală a claselor.

5.2.3 Curba ROC și Curba Precizie-Senzitivitate

Această metrică este utilă în determinarea dezechilibrelor apărute în procesul de clasificare, oferind astfel o generalizare asupra stabilității de clasificare a sistemului analizat. Modul de reprezentare al acestei metrici, constă în utilizarea repartiției valorilor ca “False positive” pe axa x, în timp ce pe axa y este utilizată repartiția valorilor clasificate ca “True Positive”. Astfel, curba ROC evidențiază rata de modificare a acestor două distribuții pe parcursul modificării pragurilor de clasificare.

O altă modalitate de determinare a performanțelor oferite de un clasificator, se poate realiza prin trasarea graficului *Precizie-Senzitivitate*. Prin această abordare se pot determina care sunt parametrii de operare optimi pentru modelele utilizate, astfel încât nivelul de generalizare al sistemului să fie unul ridicat. Modul de calcul și reprezentare al acestei metrici, este similar ca în cazul curbei ROC, singura diferență este dată de faptul că atât valoarea preciziei cât și cea a sensibilității trebuie să fie apropiată de valoarea 1, pentru ca sistemul de clasificare să obțină performanțe bune în identificarea claselor.


CAPITOLUL 6

Metode inteligente folosite în clasificarea semnalelor: Algoritmi de tip învățare automată profundă

În acest capitol sunt descriși algoritmi cu învățare profundă utilizați în experimentele efectuate pentru această teză de doctorat. De asemenea, sunt prezentate principalele topologii existente și modul prin care aceste soluții pot fi adaptate pentru a învăța și recunoaște tiparele generate ca urmare a mișcării realizate de o anumită parte a corpului.

6.1 Introducere

În procesul de dezvoltare a metodelor inteligente, trebuie ținut cont de modul prin care procesul de învățare se produce în contextul organismelor biologice. În cazul sistemului nervos, întâlnit la oameni, acesta este compus dintr-o multitudine de celule, cunoscute sub denumirea de neuroni. Aceștia sunt interconectați între ei prin intermediul sinapselor (conexiunea care se realizează de cele mai multe ori între dendrite și axon) creând în final o rețea neuronală. O astfel de reprezentare este prezentată în Figura 5 (Aggarwal, 2018):



Figură 5 Structura unei rețele neuronale biologice

Acest mecanism biologic de învățare este simulat în rețelele neuronale artificiale prin intermediul unor componente de calcul, făcând referire la neuroni. În structura rețelelor neuronale fiecare unitate de calcul este conectată la o altă unitate de calcul prin intermediul ponderilor, care în acest caz simulează puterea conexiunilor sinaptice întâlnite la organisme biologice. Prin urmare, o astfel de structură neuronală artificială calculează o funcție a intrărilor prin propagarea valorilor de la neuronii de intrare la neuronii de ieșire prin intermediul ponderilor. În structura rețelelor neuronale, etapa de învățare generează schimbarea ponderilor ce creează legături între diferiți neuroni. Similar ca în cazul rețelelor neuronale biologice, procesul de învățare este realizat prin apariția stimulilor externi, furnizați prin intermediul setului de date de antrenare ce conțin exemple de perechi intrare-ieșire ale funcției de învățare. Ajustarea ponderilor dintre neuroni într-o rețea neuronală este o consecință a erorii de predicție/clasificare. Astfel, obiectivul ajustării ponderilor dintre neuroni este acela de a modifica componenta de calcul astfel încât să se realizeze predicții corecte la următoarele iterații de învățare.

Cea mai simplă rețea neuronală este reprezentată de elementul de tip perceptron. Neuroni prezenți într-o rețea de tip perceptron calculează două operații de bază în fiecare nod (neuron). Aceste funcții sunt date de funcția de sumare și funcția de activare. Pentru ca rețeaua neuronală să fie capabilă să recunoască mai mult de două clase, este necesară introducerea unor straturi ascunse suplimentare. Prin introducerea acestor straturi ascunse, se crește generalizarea rețelei și implică a problemei tratate.

6.2 Rețele neuronale recurente

În acest subcapitol, este prezentată una dintre cele mai cunoscute arhitecturi neuronale, cunoscută sub numele de Rețea Neuronală Recurentă. Această arhitectură a fost proiectată pentru a lucra cu seturi de date secvențiale. Semnalele inerțiale generate de mișcarea capului într-un spațiu 3D ($\bar{x}_1, \dots, \bar{x}_n$) se vor interpreta secvențial (\bar{x}_t) într-o perioadă de timp t având o dimensiune d . Diferența dintre o astfel de arhitectură și o rețea clasică constă în prezența straturilor recurente, unde conexiunile dintre neuronii componenți manifestă o caracteristică ciclică (Aggarwal, 2018). În experimentele realizate pentru această teză de doctorat, vectorul \bar{x}_t conține d valori reprezentative pentru o anumită perioadă de timp t . Fiecare secvență selectată este dependentă de secvențele anterioare, prin urmare este optimă recepționarea unei secvențe particulare \bar{x}_t numai după ce un număr de secvențe au fost deja introduse în rețea și convertite în stări ascunse (Nilsson, 1998). Astfel, fiecare strat recurent este actualizat după fiecare element furnizat la intrarea rețelei. Prin urmare, predicția vectorului de ieșire \bar{y}_t depinde atât de vectorul de intrare \bar{x}_t , cât și de ponderile obținute la nivelul straturilor ascunse h_t care sunt actualizate în timp. Prin urmare, valorile ponderilor din straturile ascunse la momentul t de timp, sunt descrise de o funcție a valorilor de intrare la momentul t de timp și valorile vectorilor din straturile ascunse la momentul $(t-1)$ (Aggarwal, 2018).

O extensie a rețelei neuronale recurente utilizată în practică este *Rețeaua Neuronală cu Memorie pe Termen Lung* (Long-Short Term Memory). În structura acestei rețele, straturile recurente sunt compuse dintr-o serie de elemente adiționale, cunoscute sub denumirea de *porți*. Acestea au rolul de a atenua problemele create de gradientii cu valori prea mici ori prea mari (vanishing gradients sau exploding gradients). O rețea de tip LSTM moștenește arhitectura de bază a unei rețele neuronale recurente, cu diferența că fiecare strat ascuns (h_t), este înlocuit cu o “celulă de memorie”, c_t .

Deși această arhitectură este utilizată în diverse aplicații cotidiene cum este cazul aplicațiilor de procesare a textului, de procesare automată a semnalului foto-video sau de analiză și sintetizare a semnalului vocal, în domeniul analizei semnalelor provenite de la senzori purtabili, aceste metode sunt la început (Severin & Dobrea, 2021), necesitând studii de aprofundare pentru determinarea capacităților de calcul.

6.3 Rețele neuronale convoluționale

Structura convențională a unei rețele convolutive cuprinde straturi tridimensionale și un nivel de “adâncime” asociat cu numărul de trăsături. În rețelele neuronale convolutive, terminologia de adâncime a unui singur strat este diferită de nivelul de adâncime, în ceea ce privește numărul de straturi din structura rețelei. În stratul de intrare, aceste trăsături sunt asociate cu fiecare canal de transmisie pentru senzorii purtabili (ex. Unghi Roll, Unghi Pitch sau Unghi Yaw), în timp ce straturile ascunse sunt asociate cu diferite caracteristici codificate din semnal. Această topologie de rețea neuronală cuprinde două tipuri de straturi principale, stratul convolutiv respectiv stratul de subeșantionare. Acest lucru facilitează posibilitatea identificării cu precizie a seturilor de activități realizate de corpul uman, unde pe anumite porțiuni cuprind caracteristici comune. Deoarece arhitectura inițială a fost proiectată să lucreze cu imagini, informațiile provenite de la senzori necesită o adaptare în format 1D sau 2D (Severin & Dobrea, 2020) astfel încât fiecare reprezentare să capteze necesarul de informație pentru fiecare activitate locomotorie predefinită. Pentru cazul tratat în această teză, rețeaua convolutivă a fost adaptată să încorporeze fiecare activitate predefinită, urmând ca apoi captarea

caracteristicilor definatorii să fie realizată prin utilizarea filtrelor 1D (kernels) cu lățimi diferite.

Deși, performanțele oferite de structura clasică a acestei topologii de rețea neuronală este una satisfăcătoare, în literatura de specialitate a apărut ideea de *rețea neuronală mixtă* (Wang & Zhu, 2020). Acest concept se bazează pe integrarea proprietăților din diferite topologii sub o singură arhitectură, cu scopul de a obține rezultate bune de clasificare și generalizare.

6.4 Rețele neuronale mixte

Rețelele mixte sunt o noutate în domeniul algoritmilor inteligenți și aduc contribuții semnificative în diminuarea problemelor întâlnite în arhitecturile clasice prezentate anterior în această lucrare (ex. overfitting). Printre aceste topologii, se pot aminti: *Rețeaua Neuronală Convolutivă cu Memorie pe Termen Lung* (CNN-LSTM) (Mutegeki & Han, 2020), *Rețea Bidirecțională cu Memorie pe Termen Lung* (BLSTM) (Hernández, et al., 2019) sau *Rețea Neuronală Convoluțională Bidirecțională cu Memorie pe Termen Lung* (CNN-BLSTM) (Guo, et al., 2019).

O arhitectură de tip *Rețea Bidirecțională cu Memorie pe Termen Lung* (BLSTM) este o extensie a rețelei LSTM, creată cu scopul de a îmbunătăți rata de clasificare a modelului inițial și de a rezolva problemele de clasificare apărute prin utilizarea seriilor temporale. Diferența dintre cele două arhitecturi constă în faptul că arhitectura BLSTM antrenează două rețele LSTM, fapt ce conduce la o predicție mai bună a modelului, considerând pentru straturile ascunse atât proprietățile de semnal de la momentul anterior cât și de la cel viitor. O altă topologie de rețea neuronală mixtă dată de *Rețeaua Neuronală Convolutivă cu Memorie pe Termen Lung* (CNN-LSTM). Această topologie a fost inițial proiectată pentru cazul în care seturile de intrare au o caracteristică spațială. În această categorie, se regăsesc seturile de date ce conțin imagini sau fișiere video. Avantajul oferit de o astfel de arhitectură, constă în clasificarea cu precizie a secvențelor de intrare, unde se utilizează atât proprietățile oferite de rețeaua CNN cât și de proprietățile rețelei LSTM.

Rețeaua mixtă de tip CNN-LSTM, oferă avantajul identificării caracteristicilor complexe din seturile inertiiale cu ajutorul rețelei CNN, în timp ce rețeaua LSTM este eficientă în captarea informațiilor temporale. Avantajul oferit de o astfel de rețea este datorat faptului că seturile de intrare pot fi folosite în forma lor brută, fără a mai fi nevoie să se realizeze etapa de procesare a datelor. Este de remarcat faptul că în funcție de complexitatea problemei tratate, arhitectura inițială *CNN-LSTM* poate fi extinsă către o nouă topologie ce cuprinde două straturi LSTM. O astfel de arhitectură este cunoscută în literatură sub numele de *Rețea Bidirecțională cu Memorie pe Termen Lung* (BLSTM). Aceasta este una dintre topologiile cele mai reprezentative pentru sistemele ce lucrează cu serii temporale, combinând atât proprietățile de extragere a caracteristicilor din semnal prin intermediul rețelei convolutive, cât și proprietățile de învățare a dinamicii temporale în timp oferită de rețeaua LSTM, care ia în considerare atât proprietățile de semnal de la momentul anterior cât și de la cel viitor.

CAPITOLUL 7

Contribuții personale la dezvoltarea sistemelor de identificare a gesturilor motorii

În acest capitol sunt prezentați pașii experimentali realizați și soluțiile propuse pentru achiziția, procesarea și clasificarea activităților motorii de la nivelul capului. De asemenea, sunt evidențiate contribuțiile personale aduse în domeniul HCI prin metodele tratate și rezultatele obținute pe baza diseminării rezultatelor obținute, ca urmare a cercetărilor efectuate.

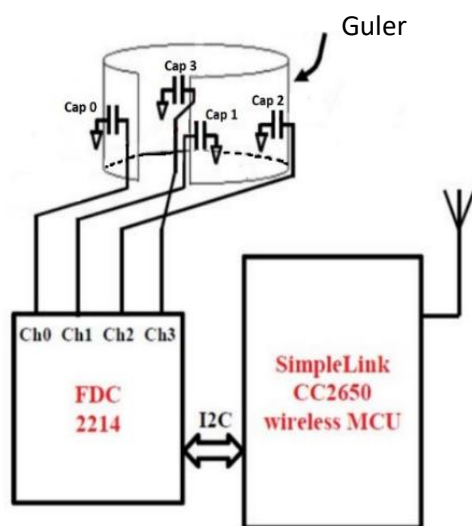
7.1 Prezentarea implementării hardware a sistemelor dezvoltate

7.1.1 Sistem cravată inteligentă

Primul dintre dispozitivele portabile propuse, utilizează 4 senzori capacitivi înglobați într-un accesoriu vestimentar (cravată) (Dobrea, et al., 2019), astfel încât informațiile relevante despre mișcarea capului în planul 3D să fie achiziționate și clasificate corect. Structura HW a acestui sistem cuprinde pe lângă componenta senzorică, un circuit driver FDC2214 și un sistem de dezvoltare wireless CC2650 ce oferă posibilitatea transmiterii datelor folosind protocolul Bluetooth, crescând astfel portabilitatea sistemului.

Obiectivul principal al acestui sistem a fost acela de achiziție și detecție a gesturilor de la nivelul capului prin intermediul utilizării unei topologii noi de senzori. Această abordare este o alternativă la soluțiile clasice unde sunt utilizați senzori cu o complexitate ridicată ori cu un nivel ridicat de procesare.


O schemă bloc a sistemului portabil propus, bazat pe senzori inerțiali capacitivi se poate observa în Figura 6.



Figură 6 Sistem de monitorizare a gesturilor folosind senzori capacitivi (Dobrea, et al., 2019)

7.1.2 Sistem de identificare a mișcărilor capului cu un singur senzor inerțial

O altă modalitate, folosită pe parcursul experimentelor pentru citirea și clasificarea gesturilor de la nivelul capului, constă în utilizarea senzorilor inerțiali. Ținând cont de acest lucru, s-a propus două sisteme folosind această categorie de senzori. Prima abordare a constat în utilizarea unui singur senzor plasat deasupra capului (Severin, et al., 2020). În timp ce a doua abordare, a constat în utilizarea a trei senzori inerțiali plasați în jurul gâtului la distanțe egale unul de altul (Severin, 2020f). Pentru primul caz (utilizarea unui singur senzor inerțial), senzorul a fost plasat deasupra capului prin intermediul unei perechi de căști audio. Prin această abordare, senzorul a fost aliniat cu centrul de greutate al corpului, fapt ce a avantajat citirea orientării spațiale cu precizie. Pentru acest caz, senzorul MPU6050, utilizat în prototipul de monitorizare, conține în structura sa doi senzori inerțiali, un accelerometru cu trei axe (3DOF), respectiv un giroscop cu trei axe (3DOF). Astfel, la ieșirea senzorului IMU au fost generate șase semnale, ce au fost combinate (fuzionate) prin utilizarea filtrului Kalman, obținând în final o reprezentare pe trei axe sub forma unghiurilor Roll, Pitch și Yaw. O schemă bloc a sistemului purtabil propus, bazat pe un singur senzor inerțial se poate observa în Figura 7.



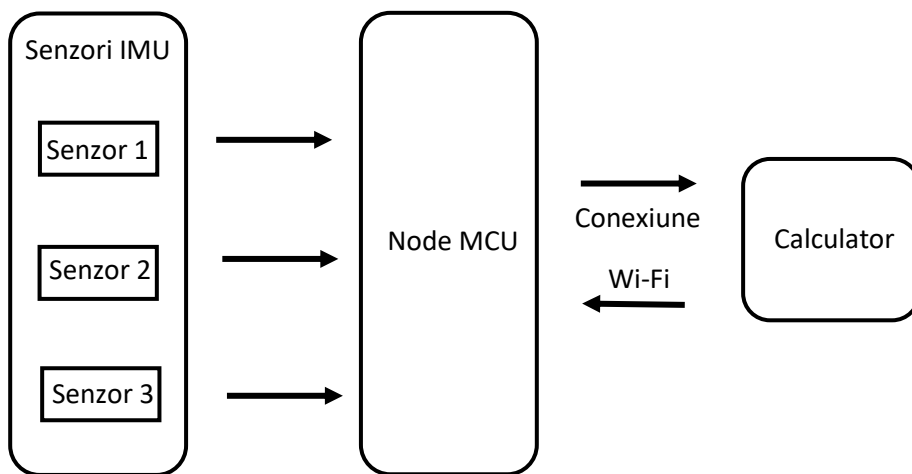
Figură 7 Schema bloc a sistemului de monitorizare cu un senzor inerțial cu 6 grade de libertate (6DOF)

În Figura 7, A_{xyz} sunt valorile de pe fiecare axă de la accelerometru, în timp ce G_{xyz} sunt valorile de pe fiecare axă de la giroscop. Pasul de achiziție al semnalelor inerțiale, procesarea și transmiterea mai departe a datelor către calculator, cu scopul de a fi salvate offline, a fost realizat cu ajutorul plăcii de dezvoltare MEGA2560. Pentru cazul amintit anterior, seriile de timp inerțiale (Roll, Pitch și Yaw) au fost transmise prin intermediul comunicației seriale UART la o rată de eșantionare egală cu 50 Hz.

7.1.3 Sistem multi-senzor de identificare a mișcărilor capului (cervical și cap)

Un al doilea dispozitiv propus și dezvoltat constă dintr-un sistem purtabil la nivelul gâtului, ce conține 3 senzori inerțiali (Severin, 2020d), (Severin, 2020f). Doi dintre acești senzori sunt reprezentați de senzori cu 9 grade de libertate (MPU9250), în timp ce al 3-lea senzor este un senzor cu 6 grade de libertate (MPU6050). Senzorii au fost plasați la o distanță egală cu 45 de grade unul față de altul în jurul gâtului. Utilizarea celor doi senzori cu 9 grade de libertate a avut ca principal scop validarea orientării 3D a capului, citită prin intermediul senzorului cu 6 grade de libertate. Pentru acest caz, informațiile achiziționate de la cei trei senzori inerțiali sunt transmise către terminalul final prin intermediul conexiunii Wi-Fi la o rată de achiziție egală cu 10ms. Pasul de achiziție și procesare al

datelor a fost realizat prin intermediul utilizării unei plăci de dezvoltare NodeMCU ESP 8266. În continuare, s-a utilizat o arhitectură client-server prin care placa NodeMCU a fost configurată să funcționeze ca slave, în timp ce aplicația de achiziție ce a rulat pe laptop a fost configurată să lucreze ca server. Transmiterea datelor prin intermediul conexiunii Wi-Fi a fost posibilă prin crearea unui canal de legătură intitulat socket, prin care datele sunt transmise între placa de dezvoltare și calculator, fără întârzieri datorate propagării informației (Severin, 2020d). O schemă bloc a sistemului purtabil propus, bazat pe trei senzori inerțiali, se poate observa în Figura 8.



Figură 8 Schema bloc a sistemului de monitorizare cu trei senzori inerțiali

7.2 Achiziția seturilor de date inerțiale

În acest capitol, se realizează o prezentare detaliată asupra protocolului de achiziție al datelor, stabilit pentru fiecare caz în parte.

7.2.1 Achiziționarea setului de date capacitiv utilizat în identificarea gesturilor motorii de la nivelul capului

Semnalul capacitiv, generat de mișcarea capului, a fost achiziționat în urma stabilirii unor reguli, utilizate ulterior pe parcursul procesului experimental. Prima regulă a constat în stabilirea unui număr fix de activități de referință. Astfel, acestea au fost definite în continuare sub forma unor șabloane de control pentru cazul persoanelor ce suferă de tetrapareză spastică. Pentru experimentele realizate și prezentate în această teză de doctorat, s-au ales șase gesturi de tip șablon.


A doua regulă, a constat în stabilirea unui protocol experimental, utilizat ulterior în procesul de măsurare și achiziție. Astfel, fiecare voluntar implicat în etapa de măsurare, a respectat indicațiile stabilite inițial în protocolul experimental definit. Pentru acest caz, 5 persoane (femei și bărbați) au participat în etapa de achiziție a datelor. Fiecare dintre cele șase activități predefinite au fost efectuate din poziția șezut pe un scaun, simulând astfel condiția unui bolnav de tetrapareză ce este așezat într-un cărucior cu roțile inteligent. Astfel, pentru a simula cât mai ideal cazul unui bolnav de tetrapareză, fiecare voluntar a efectuat activitățile șablon, din poziția șezut fără să își miște restul corpului. Prin urmare, cinci dintre aceste activități șablon sunt caracterizate de comenzi de control reprezentate

de: *mişcare înainte*, *mişcare înapoi*, *mişcare la stânga*, *mişcare la dreapta* și *comanda de oprire*. Cea de a șasea activitate șablon a fost considerată ca fiind o *mişcare aleatorie*, referențiată în măsurătorile efectuate cu setul "Garbage". Fiecare dintre cele cinci activități șablon au fost achiziționate cu o frecvență de 10Hz și o lungime de 3s fiecare. Singura excepție apare pentru *comanda de oprire* și pentru clasa "Garbage", unde perioada de achiziție s-a ales 3.5s, respectiv 120s.


În continuare, fiecare dintre activitățile șablon stabilite inițial au fost realizate după cum urmează (Dobrea, et al., 2019):

- Mișcarea "*înainte*" a capului (A1): efectuarea unei înclinări a capului spre stânga urmată apoi de o înclinare a capului cu privirea spre podea;
- Mișcarea "*înapoi*" a capului (A2): efectuarea unei înclinări a capului spre stânga urmată apoi de o înclinare a capului cu privirea spre tavan;
- Mișcarea la "*stânga*" a capului (A3): efectuarea unei înclinări a capului spre stânga, urmată apoi de o rotație a capului tot spre stânga;
- Mișcarea la "*dreapta*" a capului (A4): efectuarea unei înclinări a capului spre dreapta, urmată apoi de o rotație a capului tot spre dreapta;
- Mișcarea de "*oprire*" (A5): efectuarea unei înclinări a capului în sus, cu privirea spre tavan, urmată apoi de o înclinare a capului în jos, cu privirea spre podea, urmată de rotirea capului la stânga și la dreapta;
- Mișcarea capului pentru clasa "garbage" (A6): Înregistrarea mișcării capului pe o perioadă de 3.5s, considerând o mișcare aleatorie în planul tridimensional.


Pentru a evidenția modul prin care fiecare activitate șablon a fost realizată conform cu descrierea făcută anterior în acest subcapitol, se consideră următoarea reprezentare grafică:



Comanda "înainte":



Comanda "înapoi":



Figură 9 Activități template definite pentru captarea semnalelor inertiiale de la nivelul capului

În urma etapei de achiziție, s-a creat offline o bază de date nouă, utilizată ulterior în antrenarea algoritmilor cu învățare automată și realizarea pașilor experimentali. Setul de date creat este unic, în literatură nefiind identificată o abordare similară până în momentul efectuării experimentelor pentru această teză de doctorat (Severin & Dobrea, 2021).

7.2.2 Achiziționarea setului de date inerțial utilizat în identificarea gesturilor motorii de la nivelul capului

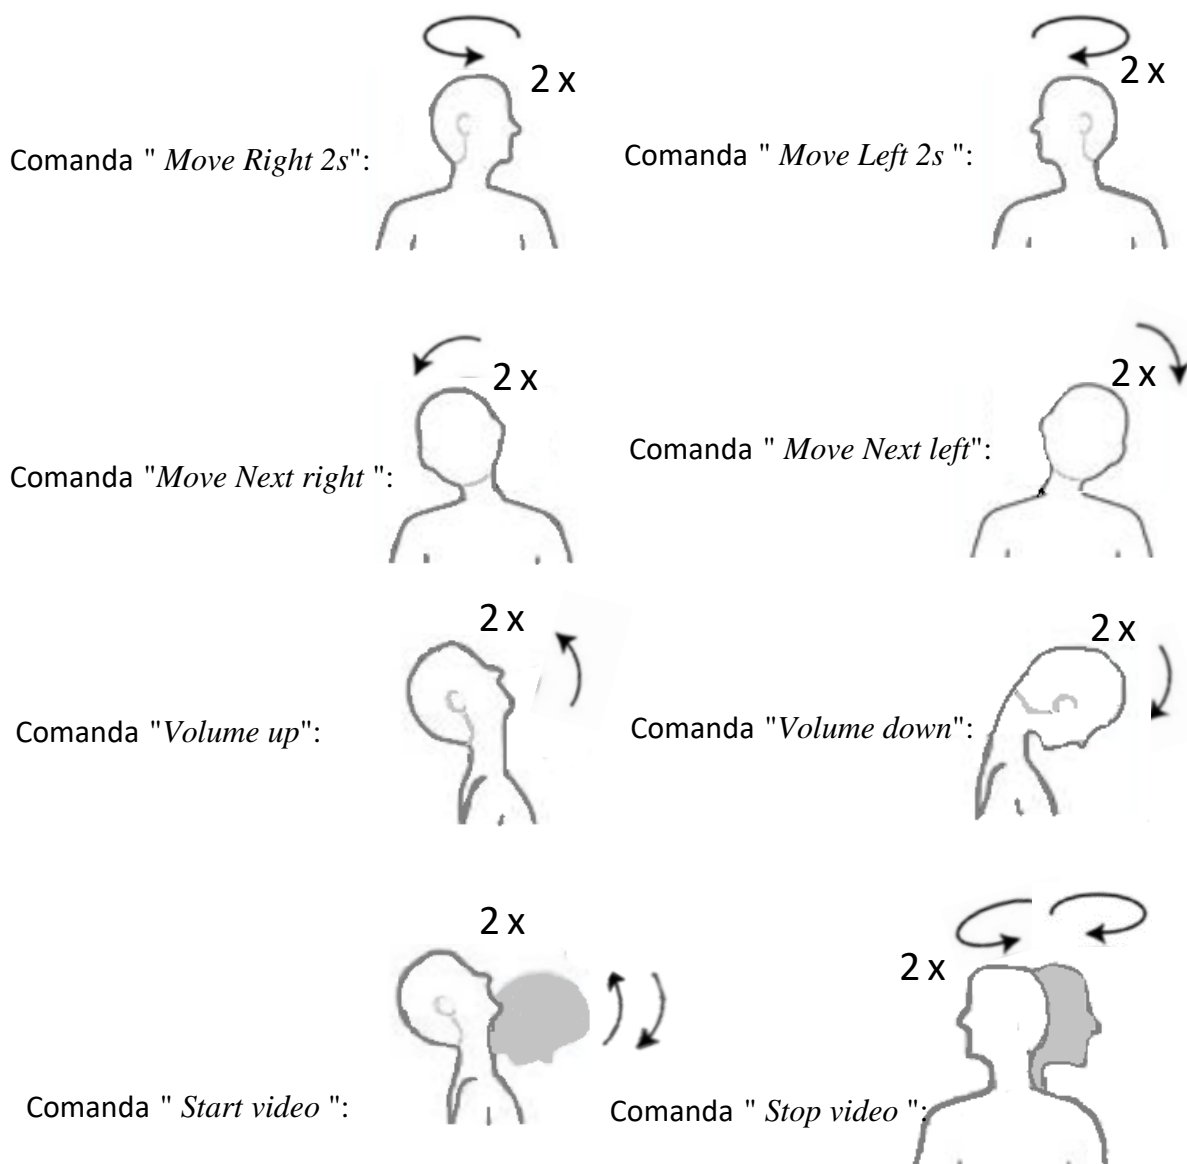
În continuare se va descrie cazul protocolului utilizat pentru achiziția semnalului inerțial folosind dispozitivul cu un singur senzor, descris în Figura 7. Achiziția datelor s-a realizat prin implicarea a 9 voluntari cu vârste cuprinse între 20 și 40 de ani (Severin & Dobrea, 2020). Setul de activități a fost ales, astfel încât să aibă un grad ridicat de generalizare. Prin urmare, gesturile șablon alese oferă posibilitatea de a controla o aplicație HCI (ex. player audio/video). Comenzile stabilite sunt: *Move Right 2s* (a- sari la o perioadă viitoare de timp), *Move Left 2s* (b- sari la o perioadă anterioară de timp), *Move Next right* (c- treci la următorul element), *Move Next left* (d- revenire la un element anterior), *Volume up* (e- creșterea volumului), *Volume down* (f- reducerea volumului), *Start video* (g- pornire redare) și *Stop video* (h- oprire redare). Fiecare mișcare a capului a fost efectuată pornind de la o poziție inițială (ex. privire înainte) până la revenirea în poziția din care s-a început executarea fiecărei activități șablon. Înclinarea laterală spre stânga și dreapta a fost efectuată în raport cu planul sagital, iar rotațiile capului spre stânga și dreapta au fost efectuate raportat la planul orizontal. În timp ce mișcările înainte-înapoi sunt asociate cu planul frontal.

În continuare, fiecare dintre activitățile șablon stabilite inițial au fost realizate după cum urmează (Severin, et al., 2020):

- Activitatea a): Rotirea capului de două ori în partea dreaptă în jurul axei yaw cu revenirea orientării capului în poziția inițială.
- Activitatea b): Rotirea capului de două ori în partea stângă în jurul axei yaw cu revenirea orientării capului în poziția inițială.

- Activitatea c): Înclinarea capului de două ori în partea dreaptă în jurul axei de Roll, cu revenirea orientării capului în poziția inițială.
- Activitatea d): Înclinarea capului de două ori în partea stângă în jurul axei de Roll, cu revenirea orientării capului în poziția inițială.
- Activitatea e): Rotirea capului spre tavan în jurul axei pitch cu revenirea orientării capului în poziția inițială.
- Activitatea f): Coborârea capului de două ori înspre podea, în jurul axei pitch, cu revenirea orientării capului în poziția inițială.
- Activitatea g): Coborârea și ridicarea de două ori a capului spre tavan și podea, în jurul axei pitch, cu revenirea orientării capului în poziția inițială.
- Activitatea h): Rotirea capului de două ori de la maxim dreapta la maxim stânga, în jurul axei de yaw, cu revenirea orientării capului în poziția inițială.

Comenzile menționate mai sus, au fost stabilite pentru a oferi posibilitatea persoanelor cu tetrapareză să controleze o aplicație multimedia, ce poate reda conținut audio/video. Pentru a evidenția modul prin care fiecare activitate șablon a fost realizată, conform cu descrierea făcută în acest subcapitol, se consideră următoarea reprezentare grafică:



Figură 10 Activități template definite pentru captarea semnalelor inertiiale de la nivelul capului

Pentru fiecare dintre voluntarii implicați în efectuarea protocolului de achiziție al datelor, s-a realizat o instruire preliminară asupra modului de execuție pentru fiecare șablon definit inițial. Pe lângă acest lucru, un singur voluntar a efectuat comenzile fără a cunoaște modul de executare corectă. Prin această situație s-a simulat cazul real, unde persoanele ce utilizează sistemul propus, nu execută corect sau nu cunosc modul de efectuare corectă a fiecărei activități șablon.

În urma etapei de achiziție s-a creat offline o bază nouă de date ce s-a utilizat ulterior la antrenarea algoritmilor cu învățare automată și realizarea pașilor experimentali prezentați în această teză.

7.2.3 Achiziționarea setului de date inerțial utilizat în identificarea posturii corporale

Pentru această situație, semnalul inerțial produs de mișcarea capului, a fost achiziționat în contextul desfășurării a 9 activități uzuale. Acest scenariu a fost ales astfel încât să se simuleze condițiile reale de utilizare, unde astfel de senzori sunt utilizați pe întreaga zi, cu scopul de a monitoriza și clasifica gesturile de la nivelul capului. Fiecare dintre voluntarii implicați în experiment au fost rugați să poarte dispozitivul prezentat în Figura 8 (Severin, 2020f). În continuare, experimentul a fost gândit astfel încât cele 9 activități șablon stabilite să fie împărțite în două categorii. Prima categorie constă în stabilirea unui set de activități statice. În această categorie sunt incluse următoarele activități șablon: citirea unei cărți din poziția șezut pe scaun, poziție relaxată șezând pe un scaun, scris pe caiet din poziția șezut, scrierea unui document la laptop, utilizarea telefonului mobil din poziția șezut și vizionarea unui fișier video din poziția șezut. O a doua categorie este dată de clasa activităților dinamice, unde sunt considerate următoarele activități șablon: utilizarea unui telefon mobil din poziția stând în picioare, mers normal și poziție dreaptă stând în picioare. Pentru a distinge dacă o activitate s-a realizat corect sau nu, pe parcursul experimentului s-a stabilit o regulă suplimentară. Această condiție a constat în etichetarea fiecărui șablon pentru condiția corectă, respectiv incorectă de efectuare a fiecărui gest. Pentru a realiza acest lucru, fiecare voluntar a fost rugat să efectueze două repetiții, una pentru cazul în care activitatea este corect realizată conform cu indicațiile specificate în literatura de specialitate și una pentru cazul considerat greșit. Pentru a simula o poziție incorectă s-a considerat un prag de deviație cervicală mai mare de 30° . În timp ce, pentru simularea unei posturi normale a capului, s-a presupus ca limita de deviație să fie cuprinsă între 0° și 20° . De asemenea, fiecare deviație cervicală a fost comparată cu o valoare de referință, egală cu 90° . Această valoare standard (alinierea poziției capului la 90° de grade), s-a simulat pe parcursul măsurătorilor, prin alinierea poziției capului cu restul corpului în planul vertical. Gradul de aliniere al capului cu restul corpului a fost determinat experimental, prin utilizarea unui sistem de referință reprezentat pe un perete, cu valori al unghiurilor plasate la fiecare 20° față de linia verticală (Severin, 2020d). Această condiție a fost menținută pentru 1.5s, atât pentru situația considerată corectă, cât și pentru cazul unei posturi incorecte.

În continuare, fiecare dintre activitățile șablon stabilite inițial au fost etichetate după cum urmează :

- Citirea unei cărți din poziția șezut (A1- Normal, A2- Anormal)
- Utilizarea unui telefon mobil din poziția în picioare (A3- Normal, A4- Anormal)
- Mers normal (A5- Normal, A6- Anormal)
- Poziție relaxată șezând pe un scaun (A7- Normal, A8- Anormal)

- Scris pe caiet din poziția șezut (A9- Normal, A10- Anormal)
- Scris la laptop (A11- Normal, A12- Anormal)
- Poziție dreaptă stând în picioare (A13- Normal, A14- Anormal)
- Utilizare telefon mobil din poziția șezut (A 15- Normal, A16- Anormal)
- Vizionare videoclip din poziția șezut (A17- Normal, A18- Anormal)

Pentru fiecare dintre cele 9 activități amintite anterior, datele au fost transmise de la distanță (prin intermediul unei conexiuni Wi-Fi) către aplicația de achiziție și stocare ce a rulat pe un laptop plasat în apropiere. Durata întregului experiment a fost de 10 minute pentru fiecare persoană implicată în experiment. După efectuarea fiecărei activități șablon, datele au fost salvate offline și etichetate manual. Pentru cazul acestui experiment, 3 voluntari au fost implicați în experiment.

Activitățile șablon prezentate anterior, au fost stabilite pentru a oferi posibilitatea identificării și corectării posturilor corporale prin intermediul achiziției și analizei semnalelor inerțiale de la nivelul capului. Prin această abordare s-a dorit identificarea și evidențierea posibilelor avantaje și dezavantaje obținute prin plasarea senzorilor inerțiali la nivelul capului, ca alternativă la soluțiile deja studiate și publicate în literatura de specialitate, unde senzorii au fost poziționați în diferite locuri ale corpului cum ar fi: torace (Alvarez, et al., 2015), picioare (Anderson, et al., 2019), brațe (Brandt, et al., 2015), etc.. Câteva dintre activitățile șablon menționate anterior în acest subcapitol, sunt evidențiate în Figura 11:



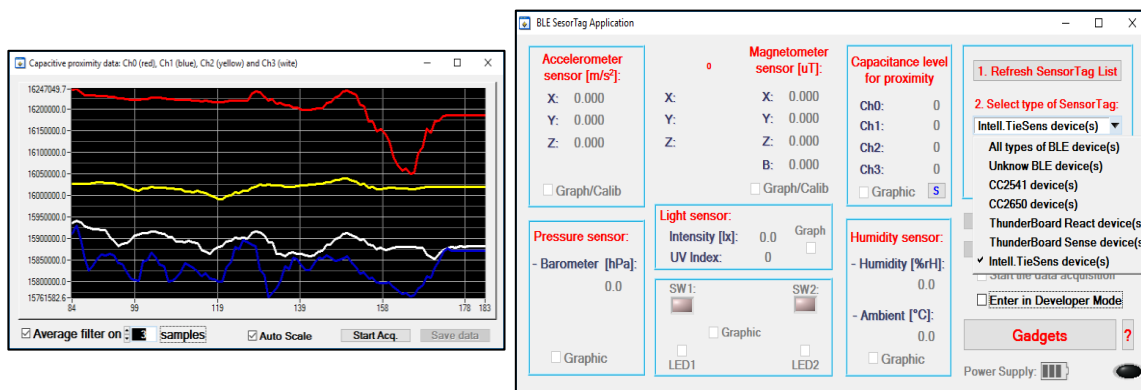
Figură 11 Activități template definite pentru captarea semnalelor inerțiale utilizate la identificarea posturilor relevante mișcării capului. Citirea unei cărți din poziția șezut: a) Normal, b) Anormal; Utilizare telefon mobil din poziția șezut: c) Normal d) Anormal; Scris la laptop: e) Normal f) Anormal;

7.3 Componente software utilizate la achiziția, analiza și clasificarea activităților motorii

În acest capitol, se realizează o prezentare, asupra soluțiilor software utilizate pentru achiziția semnalelor inerțiale, respectiv a condițiilor de simulare și testare.

7.3.1 Soluții software utilizate pentru achiziția semnalelor inerțiale

Prima aplicație software utilizată pentru achiziția semnalelor inerțiale este dată de “blesTags” (Dobrea & Dobrea, 2018). Această aplicație a fost utilizată pentru a stabili legătura cu dispozitivul purtabil prezentat în Figura 6, unde pentru citirea informațiilor relevante despre mișcarea capului, s-au utilizat senzori capacitivi. Pentru acest caz, dispozitivul *Intell TieSens* a fost configurat să lucreze ca server GATT (Generic Attribute Profile). Prin urmare, această metodă se bazează pe modelul de transmisie al datelor de tip server-client. În continuare, dispozitivul *Intell TieSens* a fost configurat ca server, în timp ce aplicația “blesTags” a fost configurată să funcționeze ca și client. Pe parcursul încercărilor experimentale, aplicația Windows a fost folosită pentru configurarea, interogarea, obținerea datelor și salvarea acestora local. În continuare, structura acestei aplicații este evidențiată în Figura 12.



Figură 12 Aplicația “blesTags” folosită pentru achiziția semnalelor capacitive inerțiale

O altă modalitate software prin care semnalele inerțiale au fost achiziționate, a constat în utilizarea unor scripturi ce rulează pe un dispozitiv final (calculator personal). Un astfel de exemplu este scriptul VBA utilizat în achiziția semnalelor inerțiale folosind prototipul descris în Figura 7. Această soluție software, a preluat informațiile transmise de la senzori, prin intermediul plăcii de dezvoltare MEGA2560, cu ajutorul protocolului serial de transmisie al datelor (UART protocol) (Severin, et al., 2020). Astfel, seriile temporale provenite de la senzorul inerțial plasat pe cap, au fost transmise printr-o conexiune fizică serială între placa de achiziție MEGA 2560 și blocul terminal, unde se rulează scriptul de achiziție. Deoarece pentru acest caz datele sunt transmise printr-o conexiune fizică, pe parcursul experimentelor, s-a extins plaja experimentală prin dezvoltarea unei soluții software prin care să se achiziționeze seriile temporale prin intermediul conexiunii Wi-Fi. Pentru această situație, dispozitivul descris în Figura 8, a fost configurat să utilizeze transmisia datelor prin socketuri de transmisie între placa NodeMCU și aplicația software ce rulează pe terminalul final (calculator personal) (Severin, 2020f). În continuare, aplicația de achiziție dezvoltată, a salvat datele local, urmând ca după finalizarea

procesului de achiziție, fiecare set de date obținut (de la fiecare voluntar), să fie inclus într-un set de date final.

7.3.2 Tehnici utilizate în prelucrarea semnalelor inerțiale

În experimentele realizate, pasul de prelucrare al semnalelor inerțiale, a fost împărțit în două etape. Prima etapă a constat în filtrarea semnalului inerțial obținut de la fiecare senzor utilizat. Urmând ca cea de-a doua etapă să fie reprezentată de procesarea seturilor de date offline prin aplicarea metodelor statistice de selecție a caracteristicilor din semnal. În acest sens, s-au propus și studiat o suită de metode ca: extragerea caracteristicilor elementare din seriile temporale prin intermediul utilizării transformatei Fourier și a calculării caracteristicilor Jerk (Severin, 2020c), determinarea caracteristicilor principale pe baza componentelor statistice (Severin, 2020a) și extragerea componentei de trend și zgomot din seriile temporale prin modelarea seriei temporale sub forma unui sistem aditiv (Severin, 2020a).

Prima etapă a vizat preprocesarea semnalelor inerțiale cu scopul de a reduce componenta de zgomot inclusă ca urmare a acționării factorilor externi din mediu sau a celor interni (zgomot de cuantizare, etc.). Astfel, o primă metodă utilizată, a constat în utilizarea filtrului complementar. Prin urmare, această metodă conține două componente: prima componentă, realizează filtrarea perturbațiilor apărute pe intervale scurte de timp, în timp ce a doua componentă realizează filtrarea perturbațiilor apărute pe intervale lungi de timp. În urma încercărilor experimentale făcute, s-a observat faptul că valoarea coeficientului pentru filtrul trece sus trebuie să fie cât mai apropiată de valoarea 1, în timp ce pentru filtrul trece jos valoarea aleasă trebuie să fie apropiată de valoarea 0. Deoarece valorile coeficienților de filtrare sunt constanți, acest filtru oferă o acuratețe scăzută la prelucrarea datelor dinamice (mișcarea rapidă). O altă metodă de preprocesare a semnalelor inerțiale utilizată este dată de tehnica filtrului Kalman. Comparativ cu filtrul complementar, această metodă nu mai utilizează coeficienți constanți de reglare, lucru ce a condus la obținerea unor rezultate mult mai satisfăcătoare din punct de vedere al preciziei filtrării datelor. Astfel, Filtrul Kalman a reușit cu succes să compenseze perturbațiile apărute în timpul măsurătorilor atât la frecvențe înalte, cât și la frecvențe joase.

A doua etapă a constat în procesarea semnalului inerțial, folosind diverse tehnici de identificare a caracteristicilor din semnal (statistice), cu scopul de a crește performanțele de generalizare a algoritmilor utilizați ulterior în clasificarea gesturilor de la nivelul capului. Metoda bazată pe aplicarea transformatei Fourier și cea de calculare a componentelor Jerk (Severin, 2020c), constă inițial în aplicarea unui filtru median, care are rolul de a elimina zgomotul rămas pe semnalele inerțiale. Semnalul obținut este în continuare împărțit în ferestre glisante, egale cu o valoare de 5.12 sec și aproximativ 50% factor de suprapunere (256 valori/fereastră). În continuare, detecția componentei de mișcare s-a realizat prin aplicarea transformatei Fourier și selectarea în domeniul frecvență a componentelor de frecvență principale pe fiecare fereastră de timp selectată. De asemenea, în această etapă, s-a selectat și componenta de gravitație, urmând ca elementele spectrale aflate în domeniul 23 Hz la 25 Hz (componente spectrale ce apar aleatoriu) să nu fie luate în calcul. După executarea pașilor amintiți anterior, caracteristicile spectrale s-au convertit înapoi în domeniul timp prin aplicarea transformatei Fourier Inverse (IFFT). Reconstrucția semnalelor în domeniul timp a fost posibilă utilizând teorema lui Nyquist. Acest pas s-a repetat pentru fiecare fereastră dedusă, urmând ca apoi fiecare serie de timp dedusă în acest mod să fie concatenată, construind astfel seria de timp finală. Următorul pas al metodei de procesare a constat în

calcularea semnalelor Jerk, care au fost incluse în setul de date de antrenament final (Severin, 2020c). Metoda bazată pe aplicarea transformatei Fourier și cea de calculare a componentelor Jerk, a scos în evidență faptul că textura definitorie a activităților efectuate la nivelul capului este cuprinsă în domeniul 0.3 Hz și 23 Hz (Severin, 2020c).

Un alt studiu realizat, a vizat identificarea componentelor principale, prin calcularea caracteristicilor statistice principale din semnal. Astfel, experimental s-au identificat 16 caracteristici principale pentru semnalul inerțial. Caracteristicile statistice au fost alese astfel încât să modeleze cât mai bine semnalele inerțiale pentru componenta de mișcare, realizată la nivelul capului (Severin, 2020a). O altă modalitate de preprocesare a semnalelor inerțiale a constat în împărțirea fiecărei serii de timp într-o sumă de 3 elemente principale. Prin urmare, fiecare serie temporală este descrisă de următoarea relație matematică (Severin, 2020a):

$$y(t) = S(t) + T_r(t) + R_e(t) \quad Eq.2$$

În Ecuația 2, s-au realizat următoarele notații:

- $y(t)$: valoarea seriei temporale
- $S(t)$: componenta repetitivă de scurtă durată (Eng. “Seasonal component”)
- $T_r(t)$: trendul seriei temporale
- $R_e(t)$: componenta reziduală (valoarea utilă din semnal)
- t : componenta timp

Pe baza experimentelor realizate, se poate aproxima faptul că modelarea seriilor temporale cu ajutorul unui model matematic aditiv este o soluție optimă pentru cazul seriilor temporale inerțiale, unde componenta de semnal este afectată de o multitudine de factori externi. Un alt avantaj observat, constă în faptul că această metodă poate fi aplicată pe toate tipurile de semnal inerțial generat de diferite topologii de senzori purtabili.

Validarea metodelor prezentate anterior s-a realizat, prin utilizare unei metode automate de identificare și selecție a caracteristicilor din semnal. Acest pas a fost posibil prin utilizarea unei librării software dezvoltată în python și intitulată TSFRESH (Eng. „*Time Series Feature Extraction on basis of Scalable Hypothesis tests*”). Această metodă a fost dezvoltată și prezentată către comunitatea științifică în anul 2018 de către Maximilian Christ et.al (Christ, et al., 2018). Pe parcursul studiilor efectuate, librăria software a fost configurată să returneze cele mai importante caracteristici statistice, bazându-se pe informațiile oferite de la 63 de metode de caracterizare a seriilor temporale.

7.3.3 Antrenarea algoritmilor folosiți în clasificarea gesturilor de la nivelul capului

Antrenarea și testarea offline a algoritmilor cu învățare automată este un proces costisitor, ce are ca obiectiv final identificarea modelelor ce oferă rezultatele cele mai bune pentru problema studiată. Astfel, pentru această teză, o serie de experimente au fost realizate cu scopul de a determina utilitatea soluțiilor dezvoltate și a problemei de clasificare studiată. Acest lucru a fost realizat în două moduri. Prima abordare, a constat în antrenarea modelelor cu învățare automată folosind structura seriilor inerțiale în forma lor brută (așa cum este primită de la senzori). În timp ce a doua modalitate a constat în extragerea trăsăturilor principale din semnal, folosind metodele amintite în capitolele anterioare.

Atât pentru cazul utilizării seriilor temporale în forma lor brută, cât și pentru cazul preprocesării acestora folosind diverse metode de calcul, acestea au fost împărțite în

ferestre cu o dimensiune egală (256 citiri/ferastră). În acest mod, la intrarea fiecărui model cu învățare automată a fost generată o imagine de tip matrice cu n coloane asociate fiecărui canal de la senzor (caracteristici).

Această aproximare a facilitat studierea unor algoritmi ce lucrează adesea pe seturi de date de tip imagine, prin intermediul cărora s-a încercat identificarea și clasificarea automată a caracteristicilor din semnal. Un astfel de exemplu este cazul rețelei convolutive (Severin & Dobrea, 2020).

Antrenarea modelelor cu învățare automată s-a realizat offline prin prestabilirea unui număr total de epoci de antrenare. Pe parcursul etapei de antrenare, fiecărui model cu învățare automată i-a fost transmis la intrarea și ieșirea sa, atât vectorul trăsături cât și vectorul etichetă ce conțin clasele dorite (Severin, et al., 2020).

Un număr total de 9 algoritmi clasici cu învățare automată (Severin, 2021), respectiv 5 algoritmi de tip învățare profundă (Severin & Dobrea, 2020), au fost antrenați pentru a clasifica fiecare activitate șablon stabilită inițial. Prin urmare, pentru fiecare model studiat, parametrii de configurare au fost setați experimental (prin mai multe sesiuni de antrenare) astfel încât aceștia să fie sincronizați cu datele de intrare inerțiale.

În ceea ce privește dezvoltarea și antrenarea modelelor cu învățare profundă (ex: rețeaua convolutivă (CNN) sau rețea recurentă cu memorie LSTM), acestea au fost adaptate pentru a lucra cu seriile temporale folosite în clasificarea gesturilor de la nivelul capului. Astfel, rețeaua convolutivă dezvoltată pentru experimentele realizate a fost configurată să primească la intrarea sa, seturi de date organizate sub forma unor matrici cu n coloane (vectori n dimensionali), valori asociate cu numărul caracteristicilor de intrare (ex; semnalele Roll, Pitch și Yaw de pe fiecare axă). Ținând cont de faptul că rolul principal al unei rețele convolutive este acela de a reduce seturile de date într-un format mai ușor de procesat (identificarea caracteristicilor principale), parametrul principal implicat în efectuarea operației de convoluție a fost dat de dimensiunea ferestrei nucleu (kernel) ce are rolul de a selecta componentele principale oferite ca ieșire de stratul anterior din model. Parcurgerea completă a vectorului de caracteristici cu ajutorul parametrului nucleu s-a realizat prin deplasarea sa cu o anumită valoare a pasului, până în momentul în care întregul vector de caracteristici a fost parcurs.

Măsurarea performanțelor de clasificare pe parcursul epocilor de antrenare s-a realizat prin utilizarea funcției de cross-entropie, folosită pentru calcularea distribuției de probabilități. Actualizarea ponderilor a fost posibilă prin intermediul utilizării algoritmului de optimizare Adam. Structura algoritmului dezvoltat este:

Soluție Software 2: Rețeaua neuronală convolutivă

Function CNN_Model ()

```
model = Sequential()
model.add(Conv1D(nrFilters,kernalSize1,input_shape=(timesteps,input_dim),activation='relu'))
model.add(MaxPooling1D(pool_size=poolingWindowSize,padding='valid'))
model.add(Dropout(dropOutRatio))
model.add(Conv1D(numFilters,kernalSize1,border_mode='same',activation='relu'))
model.add(MaxPooling1D(pool_size=poolingWindowSize, border_mode='same'))
model.add(Dropout(dropOutRatio))
model.add(Flatten())
model.add(Dense(n_classes, activation='softmax'))
model.compile(loss='categorical_crossentropy', optimizer='adam', metrics=['accuracy'])
return model
```

end

O altă arhitectură dezvoltată și adaptată pentru a putea lucra cu seriile temporale inerțiale a fost reprezentată de arhitectura LSTM (Long short-term memory), încadrată în categoria rețelelor neuronale recurente. Această topologie, are la baza sa o rețea neuronală de tip Perceptron multistrat (eng. Multi-Layer Perceptron), fiind astfel compusă din una sau mai multe unități de prelucrare a informației. Stratul LSTM din modelul final dezvoltat a avut rolul de a păstra o cantitate de informație un timp îndelungat, lucru ce a ajutat la recunoașterea evenimentelor produse la un moment specific de timp. Structura convențională a acestui model a fost adaptată pentru a lucra cu serii inerțiale de timp provenite de la senzorii studiați în această teză. Modelul dezvoltat a fost conceput să aibă un singur strat LSTM urmat de un strat de regularizare al datelor și de evitare a supraadaptării cu un factor egal cu 20%. Măsurarea performanțelor de clasificare pe parcursul epocilor de antrenare, s-a realizat prin utilizarea funcției de cross-entropie, în timp ce actualizarea ponderilor a fost posibilă prin intermediul utilizării algoritmului de optimizare Adam, cu o pondere de învățare egală cu 0.001. Structura algoritmului dezvoltat este:

Soluție Software 3: Rețeaua neuronală de tip LSTM

Function LSTM_Model ()

```
model = Sequential()
model.add(LSTM(n_hidden, input_shape=(timesteps, input_dim))) # LSTM layer
model.add(Dropout (0.2))
model.add(Dense(256, activation='relu')) # fully connected layer with, 256 outputs
model.add(Dense(128, activation='relu')) # second fully connected layer, 128 outputs
model.add(Dense(n_classes, activation='softmax')) # third fully connected layer, n outputs
model.compile(loss='categorical_crossentropy', optimizer='adam', metrics=['accuracy'])
```

return model

end

O extensie a modelului LSTM studiat în această teză a fost reprezentat de către modelul BLSTM. Structura algoritmului dezvoltat este:

Soluție Software 4: Rețeaua neuronală de tip BLSTM

Function BLSTM_Model ()

```
model = Sequential()
model.add(Bidirectional(LSTM(128, return_sequences=True),
                        input_shape=(timesteps, input_dim))) # BLSTM layer
model.add(Dropout (0.2))
model.add(Dense(n_classes, activation='softmax')) # fully connected layer, n outputs
model.compile(loss='categorical_crossentropy', optimizer='adam', metrics=['accuracy'])
```

return model

end

Această arhitectură înglobează două rețele LSTM în structura sa, lucru ce a făcut ca pasul de antrenare să se realizeze în două etape. Prima etapă a constat în antrenarea modelului folosind secvența de intrare inițială, urmând ca în a doua etapă antrenarea modelului să se facă pe baza unei copii inversate a secvenței de intrare. Astfel, față de cazul modelului LSTM, rețeaua de tip BLSTM oferă o predicție mai bună a datelor de intrare, deoarece ia în considerare atât caracteristicile de semnal de la momentul anterior

cât și de la cel viitor. Stratul BLSTM a fost configurat să aibă un număr de 128 straturi ascunse pentru fiecare celulă LSTM. Similar cu cazul anterior, regularizarea datelor a fost realizată cu o rație egală cu 20%. Măsurarea performanțelor de clasificare pe parcursul epocilor de antrenare s-a realizat prin utilizarea funcției de cross-entropie, în timp ce actualizarea ponderilor a fost posibilă prin intermediul utilizării algoritmului de optimizare Adam cu o pondere de învățare egală cu 0.001.

O altă categorie de modele cu învățare profundă, dezvoltate și studiate în această teză, au luat naștere din dorința de a aplica proprietățile rețelei recurente LSTM cu proprietățile rețelei CNN. Astfel, modelul hibrid propus pentru clasificarea gesturilor de la nivelul capului a fost prevăzut cu două straturi convolutive și un strat LSTM. Structura algoritmului CNN-LSTM dezvoltat este:

Soluție Software 5: Rețeaua neuronală de tip CNN-LSTM

Function CNN_LSTM_Model ()

```
model = Sequential()
model.add(Conv1D(128, 2, input_shape=(timesteps, input_dim),activation='relu'))
model.add(MaxPooling1D(pool_size=2, padding='valid'))
model.add(Dropout(0.2))
model.add(Conv1D(128, 2, border_mode='same',activation='relu'))
model.add(MaxPooling1D(pool_size=2, border_mode='same'))
model.add(Dropout(0.2))
model.add(LSTM(128, input_shape=(timesteps, input_dim )))
model.add(Dropout(0.2))
model.add(Dense(n_classes, activation='softmax'))
model.compile(loss='categorical_crossentropy', optimizer='adam', metrics=['accuracy'])
return model
end
```

Similar cu situația modelului prezentat anterior, s-a dezvoltat structura modelului hibrid de tip CNN-BLSTM. Particularitatea acestui model fiind dată de utilizarea structurii bidirecționale de tip LSTM în locul structurii convenționale LSTM. Structura algoritmului CNN-BLSTM dezvoltat este:

Soluție Software 6: Rețeaua neuronală de tip CNN-BLSTM

Function CNN_BLSTM_Model ()

```
model = Sequential()
model.add(Conv1D(128, 2, input_shape=(timesteps, input_dim),activation='relu'))
model.add(MaxPooling1D(pool_size=2, padding='valid'))
model.add(Dropout(0.2))
model.add(Conv1D(128, 2, border_mode='same',activation='relu'))
model.add(MaxPooling1D(pool_size=2, border_mode='same'))
model.add(Dropout(0.2))
model.add(Bidirectional(LSTM(128, return_sequences=True),
                        input_shape=(timesteps, input_dim)))
model.add(Dropout(0.2))
model.add(Flatten())
model.add(Dense(n_classes, activation='softmax'))
model.compile(loss='categorical_crossentropy', optimizer='adam', metrics=['accuracy'])
return model
end
```

Rezultatele de clasificare obținute cu o astfel de arhitectură au fost mult mai bune decât cele obținute cu arhitecturile clasice (Severin & Dobrea, 2020). Avantajul oferit de o astfel de rețea este datorat faptului că, seturile de intrare pot fi utilizate în forma lor brută fără să mai fi nevoie de preprocesarea lor ulterioară. Singurul pas necesar, pentru ca modelele cu învățare profundă să poată interpreta seturile de date inerțiale, constă în împărțirea acestora în ferestre cu dimensiune egală.

7.4 Rezultate experimentale obținute

În acest subcapitol sunt prezentate rezultatele obținute pe baza algoritmilor cu învățare automată, prezentați anterior în această teză.

7.4.1 Rezultate obținute pe baza algoritmilor clasici ce folosesc principiul de încapsularea al datelor

În continuare, se va nota **CDB** (setul de date capacitiv)(Dobrea, et al., 2019)(Severin, 2021a), **SIDB** (setul de date cu un singur senzor inerțial)(Severin, et al., 2020) și **MIDB** (setul de date cu mai mulți senzori inerțiali) (Severin, 2020f)(Severin, 2020d).

Pentru acest caz, o serie de algoritmi au fost dezvoltați și utilizați pentru construirea modelelor predictive de clasificare a gesturilor de la nivelul capului. Printre aceștia se pot aminti: Random Forest (RF), Extremely Randomized Trees (ET), Decision Tree (DT), Ada Boost Classifier (ADAB) sau Gradient Boosting Classifier (GBC). Pentru situația setului **CDB**, performanțele de clasificare obținute pentru situația în care seriile temporale sunt folosite în forma lor brută sunt prezentate în Tabelul 3:

Tabel 1 Rezultate de clasificare obținute pe setul de test folosind baza de date CDB (cu 20% din valori pentru test și 80% pentru antrenare)(Severin & Dobrea, 2021)

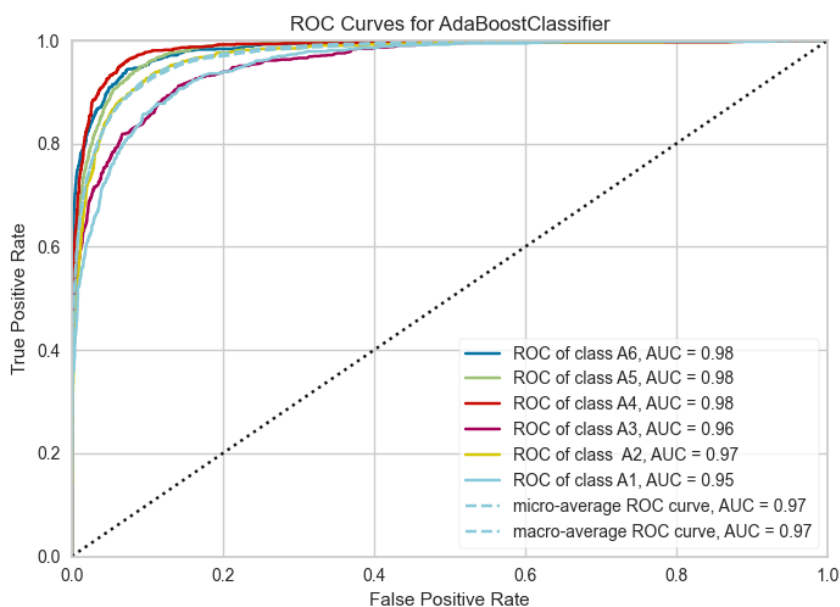
Clasificatori	Analiza PCA	Analiza LDA	Serii brute
	Acuratețe [%]	Acuratețe [%]	Acuratețe [%]
RF	80.46 %	80.46 %	80.46 %
ET	81.42 %	81.01 %	81.03%
DT	73.58 %	73.17 %	73.36 %
ADAB	81.03 %	80.90 %	81.19 %
GBC	74.36 %	74.36 %	74.36 %

Performanțele de clasificare au fost mai mari de 73% (DT) ajungând până la 81% (ADAB și ET) pentru cazul în care seriile temporale au fost utilizate în forma lor brută. O altă modalitate de evaluare a performanțelor de clasificare, s-a realizat prin calcularea preciziei, factorului recall și a scorului F1. În Figura 13 s-a reprezentat sub formă matricială cele trei metrici pentru cazul algoritmului ADAB. Observând situația prezentată în Figura 13, pentru fiecare clasă, valoarea preciziei s-a situat între 75.5% (clasa A1) și 86.6% (clasa A6). Acest lucru sugerează faptul că fiecare clasă predefinită este capabilă să fie identificată de model cu o rată maximă de eroare egală cu 24.5% (clasa A1). Valoarea sensibilității (Recall) oferă informații despre cât de bine modelul clasifică fiecare valoare din setul de date ca aparținând clasei corecte (TP) raportat la numărul total de predicții pozitive. Astfel, conform cu datele prezentate în Figura 13, se observă faptul că pentru 4 din clasele studiate, valoarea sensibilității (recall) este între 80.7% (clasa A2) și 87.7% (clasa A4). În timp ce, pentru două dintre acestea modelul a întâlnit dificultăți în diferențierea datelor (clasa A1 și A3). Scorul F1 sugerează capabilitățile generale ale

modelului ADAB în clasificarea fiecărei clase considerând valoarea preciziei și a sensibilității (recall). Prin urmare, valorile de clasificare obținute, sugerează faptul că modelul este capabil să identifice cu precizie fiecare dintre cele 6 clase predefinite. De asemenea, acest lucru evidențiază faptul că dispozitivul propus oferă un nivel de generalizare ridicat, eliminând specificitatea caracteristicilor corporale date de fiecare utilizator în parte.



Figură 13 Calcularea metricilor Precizie, Recall și scorul F1 pentru fiecare clasă predefinită (Severin & Dobra, 2021)



Figură 14 Curba ROC pentru algoritmul ADAB antrenat cu setul de date CDB (Severin & Dobra, 2021)

Identificarea dezechilibrelor apărute în procesul de clasificare a fost posibilă prin implementarea curbei ROC. Astfel, pe baza graficului prezentat în Figura 14, s-a observat faptul că modelele ce folosesc principiul încapsulării, reușesc să identifice corect apartenența punctelor pentru fiecare clasă identificată, singurele clase ce au arătat o instabilitate au fost reprezentate de clasele A1 și A3.

Determinarea stabilității sistemului propus a fost posibilă prin utilizarea metodei de împărțire a setului inițial în 10-partiții, folosind metoda de validare încrucișată. Pentru cazul experimentelor efectuate două metode particulare au fost utilizate comparativ. Prima metodă a fost reprezentată de metoda k-Fold stratificată (k-FS), în timp ce a doua a fost reprezentată de metoda Monte Carlo (k-FMC) de validare încrucișată. Rezultatele obținute pe baza celor două metode, aplicabile pentru fiecare clasificator ce utilizează metoda încapsulării, sunt prezentate în Tabelul 2 și Tabelul 3.

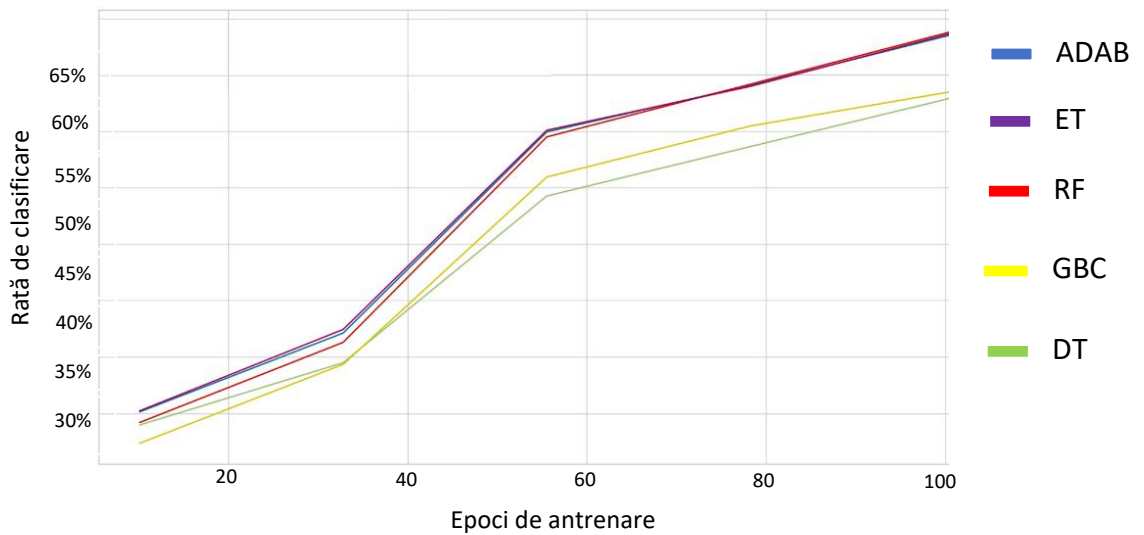
Tabel 2 Rezultate de clasificare obținute folosind setul CDB și metoda de validare încrucișată k-FS cu 10 partiții

Clasificatori	Partiție 1	Partiție 2	Partiție 3	Partiție 4	Partiție 5	Partiție 6	Partiție 7	Partiție 8	Partiție 9	Partiție 10
RF	59.75%	66.95%	66.02%	60.21%	66.77%	69.76%	69.16%	75%	51.26%	54.04%
ET	59.92%	66.09%	65.52%	60.03%	65.91%	69.16%	67.59%	75.18%	51.05%	54.40%
DT	55.47%	59.96%	57.21%	53.79%	61.88%	63.92%	62.10%	68.94%	46.02%	48.55%
ADAB	59.82%	65.88%	65.24%	61.56%	66.31%	69.48%	68.80%	75.57%	50.16%	54.75%
GBC	56.11%	61.85%	59.07%	57.68%	63.13%	65.52%	63.17%	68.91%	44.31%	45.81%

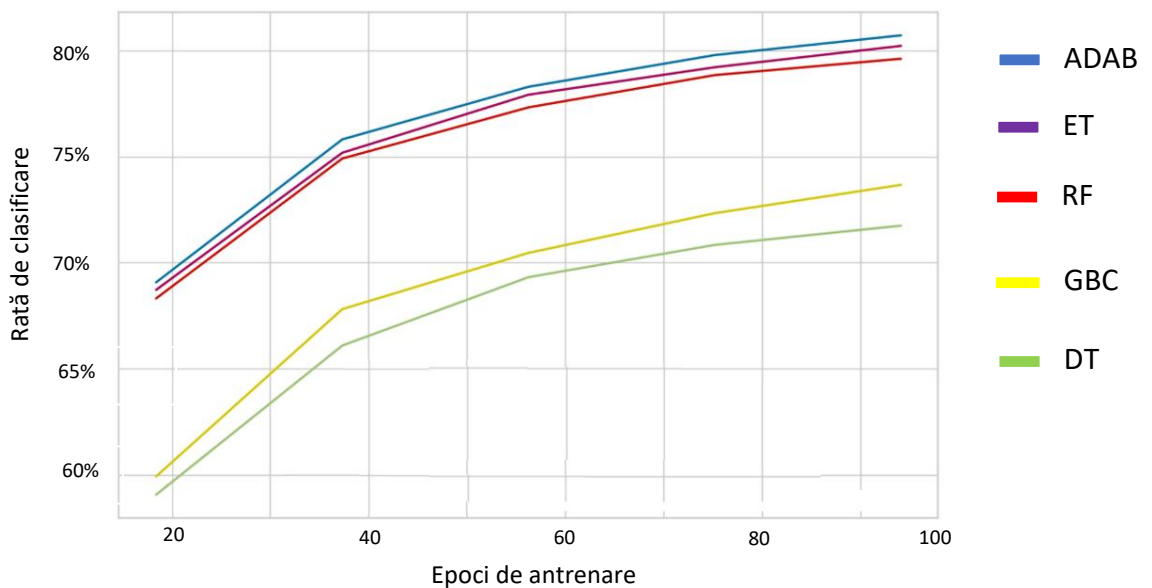
Tabel 3 Rezultate de clasificare obținute folosind setul CDB și metoda de validare încrucișată k-FMC cu 10 partiții

Clasificatori	Partiție 1	Partiție 2	Partiție 3	Partiție 4	Partiție 5	Partiție 6	Partiție 7	Partiție 8	Partiție 9	Partiție 10
RF	79.57%	79.85%	78.91%	80.55%	79%	79.85%	79.42%	79.39%	78.87%	79.57%
ET	81.24%	80.83%	81.51%	79.54%	80%	81.53%	80.26%	79.73%	79.83%	80%
DT	72.21%	71.55%	71.21%	72.26%	72.54%	71.15%	71.30%	72.62%	73.22%	71.72%
ADAB	79.91%	80.26%	80.71%	80.94%	80.01%	80.51%	80.48%	80.16%	79.26%	80.07%
GBC	73.04%	73.17%	74.09%	74.77%	74.01%	72.54%	73.49%	73.19%	73.81%	74.82%

Conform cu informațiile prezentate în Tabelul 2 și Tabelul 3, s-a concluzionat, faptul că modelele ce utilizează principiul de încapsulare al datelor sunt capabile să clasifice gesturile de la nivelul capului cu o precizie de până la 80% (folosind date brute). Un alt aspect observat, constă în faptul că performanțele acestei categorii de modele sunt direct dependente de dimensiunea setului de antrenament, lucru ce a făcut ca rezultatele obținute prin aplicarea metodei de validare încrucișată stratificată (k-FS) să fie mai mici față de rezultatele obținute folosind metoda Monte Carlo (k-FMC). Evoluția ratei de învățare pentru cele două metode de validare încrucișată este evidențiată în Figura 15 și Figura 16.



Figură 15 Diferite curbe de învățare obținute folosind metoda de validare încrucișată k -FS și setul de date **CDB** (Severin et al., 2020)



Figură 16 Diferite curbe de învățare obținute folosind metoda de validare încrucișată k -FMC și setul de date **CDB** (Severin et al., 2020)

Tabel 4 Rezultate de clasificare obținute pe setul de test folosind baza de date **SIDB** (cu 20% din valori pentru test și 80% pentru antrenare) (Severin et al., 2020)

Clasificatori	Analiza PCA	Analiza LDA	Serii brute
	Acuratețe [%]	Acuratețe [%]	Acuratețe [%]
RF	74,37 %	74.95 %	76.20 %
ET	74.47 %	75.11 %	76.31 %
DT	73.47 %	73.82 %	75.80 %
ADAB	74.23 %	74.86 %	76.19 %
GBC	71.96 %	72.31 %	74.27 %

Pentru setul **SIDB**, performanțele de clasificare obținute pentru situația în care seriile temporale sunt folosite în forma lor brută sunt prezentate în Tabelul 4. Rezultatele

obținute, evidențiază stabilitatea și capabilitatea modelelor de recunoaștere a gesturilor folosind seriile inerțiale provenite de la un singur senzor inerțial.



Figură 17 Calcularea metricilor Precizie, Recall și scorul F1 pentru fiecare clasă predefinită (Severin, et al., 2020)

În Figura 17 fiecare gest este evaluat prin intermediul factorului de precizie, recall și al scorului F1. Astfel, pentru cazul factorului de precizie, performanțele de clasificare se regăsesc în intervalul 65 % (e) și 84% (c). În continuare, performanțele generale obținute prin calcularea scorului F, sugerează faptul că gesturile a), b) și c) pot fi recunoscute cu o precizie mai mare de 80 %, în timp ce gesturile cu o complexitate ridicată (e, f, g sau h) sunt identificate cu o precizie de peste 67%, fapt ce evidențiază o oarecare instabilitate și incapacitate a sistemului propus în recunoașterea gesturilor cu un nivel ridicat de complexitate (Severin, et al., 2020). De asemenea, rezultatele obținute prin utilizarea algoritmilor ce folosesc principiul de încapsulare al datelor sugerează faptul că anumiți factori externi pot afecta capabilitățile de recunoaștere al gesturilor.

Printre acești factori externi se pot aminti: nivelul de înclinare al capului, alinierea senzorului cu centrul de greutate al corpului, viteza de efectuare a gesturilor, zgomotul de fundal, perturbațiile electromagnetice produse de diferite echipamente electronice, etc. Prin urmare, obținerea unui nivel de generalizare în recunoașterea gesturilor de la nivelul capului, prin utilizarea unui singur senzor inerțial, este mult mai dificilă decât în situația senzorilor capacitivi (Dobrea, et al., 2019). Determinarea stabilității sistemului ce folosește un singur senzor inerțial a fost realizată prin utilizarea metodei de împărțire a setului inițial în 10-partiții folosind metoda de validare încrucișată k-Fold stratificată (k-FS) și metoda Monte Carlo (k-FMC). Rezultatele obținute pe baza celor două metode aplicate pentru fiecare clasificator ce utilizează metoda încapsulării sunt prezentate în Tabelul 5 și Tabelul 6.

Conform cu rezultatele obținute, mișcările realizate la nivelul capului pot fi recunoscute cu o precizie maximă egală cu 87%, însă performanțele pot fi afectate de diverși factori externi, lucru ce conduce la imposibilitatea identificării cu succes a caracteristicilor de semnal, de către această topologie de algoritmi.

Tabel 5 Rezultate de clasificare obținute folosind setul SIDB și metoda de validare încrucișată k-FS cu 10 partiții

Clasificatori	Partiție 1	Partiție 2	Partiție 3	Partiție 4	Partiție 5	Partiție 6	Partiție 7	Partiție 8	Partiție 9	Partiție 10
RF	46.66%	43.06%	80.26%	86.26%	74.46%	51.18%	48.42%	30.04%	42.56%	29.82%
ET	49.10%	43.91%	80.53%	86.98%	74.24%	51.66%	49.09%	29.63%	45.93%	30.90%
DT	44.80%	43.21%	79.25%	86.99%	73.56%	49.04%	46.04%	29.37%	40.60%	28.88%
ADAB	40.18%	19.57%	84.55%	87.16%	60.71%	31.60%	35.98%	15.54%	34.84%	25.20%
GBC	44.97%	42.13%	75.62%	82.63%	71.16%	47.39%	45.67%	30.57%	41.46%	29.41%

Tabel 6 Rezultate de clasificare obținute folosind setul SIDB și metoda de validare încrucișată k-FMC cu 10 partiții

Clasificatori	Partiție 1	Partiție 2	Partiție 3	Partiție 4	Partiție 5	Partiție 6	Partiție 7	Partiție 8	Partiție 9	Partiție 10
RF	75.56%	75.57%	75.47%	75.69%	75.60%	75.45%	75.79%	75.74%	75.69%	75.58%
ET	75.87%	75.73%	75.72%	75.77%	75.76%	75.75%	75.87%	75.82%	75.51%	75.18%
DT	75.22%	74.70%	75.31%	74.98%	75.24%	75.15%	74.90%	74.86%	74.82%	74.82%
ADAB	75.22%	74.98%	75.25%	75.45%	75.71%	75.33%	75.27%	75.12%	75.48%	75.33%
GBC	73.64%	73.57%	73.59%	73.62%	73.72%	73.51%	73.15%	73.49%	73.37%	73.46%

Rezultatele obținute de modelele predictive ce folosesc principiul încapsulării pe baza setului de date **MIDB** sunt prezentate în Tabelul 7. Conform cu rezultatele obținute, performanțele de clasificare pentru cazul în care sunt utilizați 3 senzori inerțiali au fost în jurul valorii de 99% (Severin, 2020f). Pentru această categorie de modele predictive, se observă faptul că acestea lucrează mult mai ușor pe seturi de date categorice (de tip corect/încorect), reușind astfel să identifice fiecare caz în parte cu o acuratețe foarte bună.

Tabel 7 Rezultate de clasificare obținute pe setul de test folosind baza de date MIDB (cu 20% din valori pentru test și 80% pentru antrenare) (Severin, 2020d)

Clasificatori	Analiza PCA	Analiza LDA	Serii brute
	Acuratețe [%]	Acuratețe [%]	Acuratețe [%]
RF	95.50 %	95.27 %	98.70 %
ET	95.51 %	95.11 %	98.72 %
DT	94.18 %	94.30 %	98.13 %
ADAB	95.72 %	95.22 %	98.72 %
GBC	94.59 %	94.52 %	99.31 %

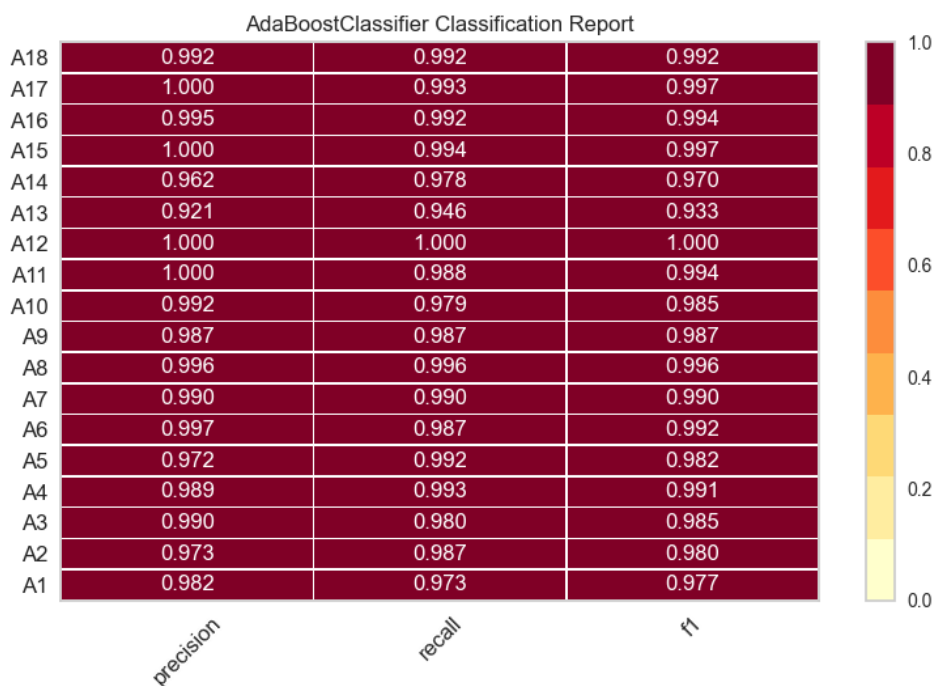
Acest lucru este confirmat și de rezultatele prezentate în Tabelul 8 și Tabelul 9, unde s-au evidențiat valorile obținute prin intermediul utilizării metodelor k-Fold.

Tabel 8 Rezultate de clasificare obținute folosind setul MIDB și metoda de validare încrucișată k-FS cu 10 partiții

Clasificatori	Partiție 1	Partiție 2	Partiție 3	Partiție 4	Partiție 5	Partiție 6	Partiție 7	Partiție 8	Partiție 9	Partiție 10
RF	99.07%	99.52%	98.78%	99.75%	98.89%	99.09%	99.52%	98.78%	99.79%	98.89%
ET	99.53%	99.78%	99.40%	99.39%	99.95%	99.87%	99.97%	99.66%	99.74%	99.84%
DT	98.52%	99.43%	98.95%	99.82%	98.93%	98.67%	98.76%	98.94%	99.55%	99.88%
ADAB	99.61%	99.86%	99.21%	99.82%	99.73%	99.36%	99.97%	99.78%	99.59%	99.27%
GBC	99.49%	99.69%	99.51%	99.78%	99.61%	99.59%	99.56%	99.54%	99.78%	99.87%

Tabel 9 Rezultate de clasificare obținute folosind setul MIDB și metoda de validare încrucișată k-FMC cu 10 partiții

Clasificatori	Partiție 1	Partiție 2	Partiție 3	Partiție 4	Partiție 5	Partiție 6	Partiție 7	Partiție 8	Partiție 9	Partiție 10
RF	98.10%	98.52%	98.19%	98.39%	98.45%	98.31%	98.37%	98.23%	98.31%	98.09%
ET	98.51%	98.69%	98.76%	98.31%	98.46%	98.64%	98.47%	98.26%	98.49%	98.60%
DT	97.09%	97.30%	96.86%	97.22%	96.83%	96.90%	97.24%	97.06%	97.30%	97.15%
ADAB	98.35%	98.63%	98.52%	98.56%	98.26%	98.57%	98.56%	98.30%	98.63%	98.49%
GBC	97.06%	96.96%	97.22%	97.21%	97.15%	97.14%	97.46%	97.29%	97.37%	97.05%



Figură 18 Calcularea metricilor Precizie, Recall și scorul F1 pentru fiecare clasă predefinită (Severin, 2020f)

Conform cu rezultatele prezentate în Tabelul 8 și Tabelul 9, s-a concluzionat faptul că nivelul de generalizare al sistemului propus (Severin, 2020d) este unul ridicat, astfel încât pentru fiecare partiție determinată modelele predictive studiate în acest capitol au fost capabile să identifice fiecare caz cu o precizie mai mare de 96%.

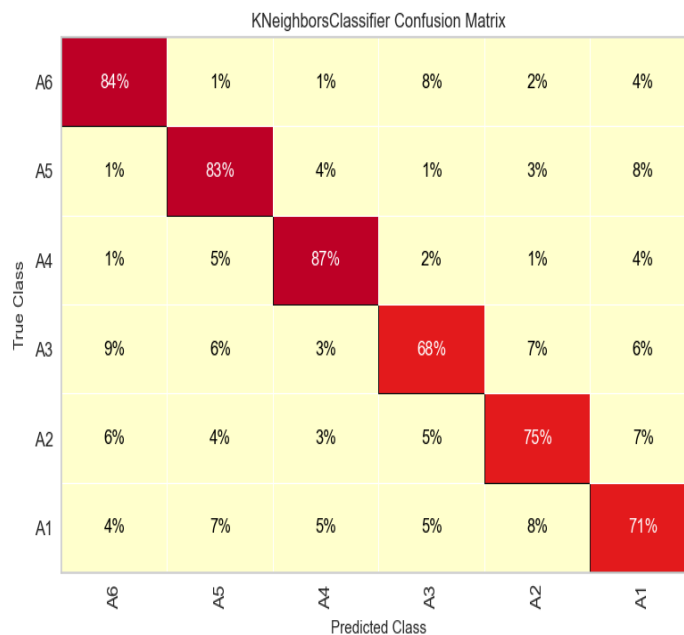
În Figura 18 s-a prezentat sub formă matricială performanțele de clasificare, pentru cazul algoritmului ADAB. Astfel, pentru fiecare clasă definită, valoarea preciziei s-a situat între 92% (clasa A13) și 100% (clasa A11). Valoarea senzitivității (recall), a fost între 94.6% (clasa A13) și 100% (clasa A12).

7.4.2 Rezultate obținute pe baza algoritmilor clasici ce folosesc principiul similarităților

Pentru cazul algoritmului SVM, determinarea hiperplanurilor de separare între cele n clase asociate cu gesturile realizate la nivelul capului s-a realizat prin utilizarea funcțiilor nucleu liniare, polinomiale, sigmoide și RBF. Alegerea parametrilor de configurare pentru modelul SVM s-a realizat prin efectuarea unei căutări repetitive în spațiul de parametri și identificarea celui mai bun model prin utilizarea metodelor de validare încrucișată.

Pentru cazul modelului k-Nearest Neighbor (kNN), etapa de determinare a parametrilor de tuning s-a realizat prin efectuarea unei căutări repetitive în spațiul de parametri, cu scopul de a determina cel mai optim model. Pentru studiile realizate, numărul de vecini (**k**) pentru care modelul a fost evaluat a fost configurat să fie între 1 și 10. În continuare, sunt prezentate rezultatele obținute de modelul kNN pe setul de date **CDB**. Experimental, s-a observat faptul că valoarea optimă pentru parametrul k a fost situată între 3 și 10 vecini.

În Figura 19 este prezentată matricea de confuzie obținută pentru modelul 6-kNN (6 vecini). Conform cu această reprezentare s-a observat faptul că cele mai dificile activități de recunoscut, au fost date de A3 (Mișcarea la "stânga"), A2 (Mișcarea "înapoi") și A1 (Mișcarea "înainte").



Figură 19 Matricea de confuzie pentru algoritmul 6-kNN antrenat pe setul CDB (Dobrea et al., 2019)

Pentru cazul modelului SVM antrenat pe setul de date **CDB**, cele mai bune rezultate s-au obținut folosind funcția nucleu (kernel) RBF. Pentru această situație, modelul a fost

capabil să identifice fiecare clasă cu o acuratețe maximă generală de 62.5%. Comparativ cu modelul 6-kNN, algoritmul SVM a întâmpinat dificultăți în identificarea fiecărei clase de apartenență, pentru cazul în care acesta a fost antrenat folosind seriile temporale în forma lor brută. Comparând rezultatele obținute de această categorie de modele (kNN vs. SVM), s-a observat faptul că modelul kNN este mult mai capabil să identifice fiecare clasă din setul de date **CDB** decât modelul SVM, unde nivelul de confuzie a fost foarte crescut pentru fiecare clasă în parte. În continuare, pentru setul de date **SIDB**, cele mai bune rezultate de clasificare s-au obținut folosind funcția nucleu de tip **RBF** pe perioada de antrenarea a algoritmului SVM. Astfel, pentru acest caz, acuratețea modelului a fost între 34% (clasa **g**) și 76% (clasa **c**). Aceste observații sunt prezentate în Figura 20, unde a fost prezentată matricea de confuzie obținută pentru acest caz. Valoarea medie a preciziei pentru acest caz a fost în jurul valorii de 63%, cu 10% mai mare decât în cazul în care modelul SVM a fost antrenat cu ajutorul seriilor capacitive brute.

SVC Confusion Matrix

True Class	a	b	c	d	e	f	g	h
a	56%	7%	2%	3%	13%	18%	1%	0%
b	3%	60%	7%	7%	4%	13%	4%	1%
c	0%	4%	76%	2%	4%	11%	2%	1%
d	1%	5%	4%	57%	9%	10%	5%	9%
e	2%	2%	8%	1%	72%	13%	0%	2%
f	2%	3%	6%	1%	13%	72%	3%	1%
g	2%	3%	4%	9%	25%	19%	34%	5%
h	2%	4%	12%	17%	8%	5%	1%	52%
	a	b	c	d	e	f	g	h

Predicted Class

Figură 20 Matricea de confuzie pentru algoritmul SVM antrenat pe setul SIDB

Deși acest model a obținut rezultate destul de bune în clasificarea gesturilor generale de mișcare, pentru cazul clasificării gesturilor de la nivelul capului, acesta a obținut printre cele mai slabe performanțe de clasificare pe seturile de antrenament în forma lor brută. Acest lucru sugerează faptul că modelul SVM este sensibil la componenta zgomot și componenta de neliniaritate prezentă în clasele definite.

Pentru cazul algoritmului kNN s-a observat faptul că cele mai bune performanțe s-au obținut în momentul în care numărul vecinilor a fost mai mare de 4. Astfel, pentru cazul studiat, modelul kNN a obținut performanțe cuprinse între 72.24% (k=1) și 74,82%(k=10).

Comparând rezultatele obținute de modelul kNN pe setul **CDB** cu cele obținute pe setul **SIDB**, s-a constatat faptul că pentru cel de-al doilea caz, rezultatele au fost în medie mai mici cu 4% (metoda k-FMC) și 9% (metoda k-FS). Această observație sugerează faptul că un sistem de recunoaștere ce folosește senzori inerțiali reușește să capteze mult mai optim componenta mișcare decât senzorii capacitivi, ținând cont de numărul senzorilor prezenți în soluția finală. De asemenea, această observație este susținută și de faptul că semnalele capacitive sunt predispuse la factori perturbatori externi (Ex: zgomot produs de dispozitivele electronice), față de senzorii inerțiali convenționali (accelerometru, giroscop sau magnetometru) unde componenta eroare este diminuată semnificativ. Pentru cel de-al treilea caz, în care s-a utilizat setul de date **MIDB**, algoritmi SVM și kNN au obținut rezultate semnificativ mai bune față de situațiile menționate anterior. Față de situația

precedentă, unde un singur senzor a fost utilizat, acuratețea de clasificare pentru cazul sistemului de recunoaștere ce folosește mai mult de 1 senzor inerțial a crescut cu 20% pentru cazul algoritmului kNN, respectiv cu 14% pentru cazul algoritmului SVM. Astfel, pe baza informațiilor generate la ieșirea modelelor predictive (SVM și kNN), s-a observat faptul că modelul kNN atinge o precizie maximă egală cu 98%, în timp ce modelul SVM obține o precizie egală cu 80%.

7.4.3 Rezultate obținute pe baza rețelelor neuronale de tip multilayer perceptron (MLP)

Alegerea parametrilor de configurare pentru modelul MLP s-a realizat prin efectuarea unei căutări repetitive în spațiul de parametri ai modelului, astfel creându-se contextul optim pentru identificarea celui mai bun model evaluat după performanțele de clasificare. Pe parcursul încercărilor experimentale rețeaua neuronală de tip MLP a fost configurată să conțină un număr variabil de neuroni cuprins între 1 și 34 de valori. În continuare, sunt prezentate rezultatele obținute de modelul **MLP** pe cele 3 seturi de date inerțiale (**CDB**, **SIDB** și **MIDB**) utilizate pe parcursul studiilor realizate. Experimental, s-a observat faptul că acest model obține o acuratețe maximă de ~65% pentru setul **CDB**, ~60% pentru setul **SIDB** și ~96.87% pentru setul **MIDB**. Pentru cazul seturilor de date **CDB** și **SIDB**, rețeaua neuronală nu reușește să clasifice cu succes fiecare clasă datorită prezenței componentei zgomot și a faptului că distribuția datelor nu este liniar separabilă (valorile aparținând diferitelor clase de apartenență se suprapun). În timp ce pentru cazul setului **MIDB** s-a constatat faptul că distribuția datelor este liniar separabilă, fapt ce a condus la o valoare a acurateței comparativ mai mare. Cele mai bune rezultate pentru cazul setului de date **CDB** și **SIDB** au fost obținute cu ajutorul funcției de activare sigmoid și a metodei „lbfgs” de optimizare a ponderilor. În timp ce pentru cazul setului **MIDB** s-a constatat faptul că, pentru fiecare dintre cele 2 funcții de activare studiate s-au obținut valori de peste 90%. În Tabelul 10 sunt prezentate rezultatele obținute de rețeaua neuronală MLP pentru cazul în care numărul neuronilor din stratul ascuns sunt în domeniul 1-34. De asemenea, rezultatele prezentate în Tabelul 10 au fost obținute pentru cazul în care algoritmul de optimizare a fost configurat să fie „lbfgs” pentru cele două situații – mai mult, aici am avut o ANN cu un singur strat neuronal ascuns. Rezultatele obținute și prezentate în tabel, pentru fiecare număr de neuroni de pe stratul ascuns, au fost obținute alegând performanțele maxime de clasificare după un număr de 100 antrenări ale rețelei neuronale. Similar s-a procedat și pentru cazul funcției de activare unde s-a ales funcția sigmoid. Conform informațiilor prezentate în Tabelul 10, s-a concluzionat faptul că acest model reușește să obțină performanțe bune de clasificare de peste 85% cu doar 6 neuroni în stratul ascuns, pentru cazul în care numărul senzorilor inerțiali incluși în sistemul de recunoaștere este egal cu 3. Astfel, pentru situația setului de date **MIDB** (utilizarea mai multor senzori inerțiali), rețeaua MLP a obținut un nivel maxim de confuzie egal cu 15%, în timp ce pentru cazul setului de date **SIDB** (utilizarea unui singur senzor inerțial), nivelul de confuzie obținut de rețeaua MLP a fost cuprins între 22% (clasa c) și 65% (clasa g).

Tabel 10 Rezultate obținute folosind un număr diferit de neuroni pe stratul ascuns în rețeaua de tip MLP, cu 20% din valori pentru test și 80% pentru antrenare

Nr. Neuroni	Setul CDB	Setul SIDB	Setul MIDB
	Acuratețe [%]	Acuratețe [%]	Acuratețe [%]
1	28.60%	23.21%	20.72%
2	33.65%	31.24%	49.07%
3	33.48%	41.06%	50.13%
4	46.45%	46.70%	70.66%
5	43.20%	50.19%	68.79%
6	45.84%	50.25%	85.41%
7	46.24%	50.35%	89.08%
8	52.04%	52.27%	85.95%
9	50.57%	51.87%	91.28%
10	53.03%	54.91%	90.32%
11	54.58%	54.44%	91.63%
12	53.35%	55.85%	93.39%
13	58.06%	56.52%	94.37%
14	57.93%	57.27%	94.24%
15	61.25%	56.39%	94.62%
16	58.74%	57.12%	93.86%
17	38.45%	57.71%	95.06%
18	60.23%	57.43%	98.87%
19	61.84%	57.74%	94.23%
20	62.01%	59.18%	95.33%
21	62.99%	58.41%	94.99%
22	62.86%	58.86%	96.18%
23	65.52%	59.20%	95.72%
24	63.25%	50.85%	96.65%
25	63.79%	57.63%	96.51%
26	62.87%	58.54%	96.36%
27	66.97%	58.33%	95.90%
28	63.73%	58.62%	96.49%
29	66.12%	58.54%	96.57%
30	67.14%	58.66%	96.48%
31	68.31%	58.85%	96.16%
32	64.03%	59.10%	96.74%
33	65.94%	59.70%	96.83%
34	65.27%	58.55%	96.87%

Valoarea medie a preciziei obținută pe cele trei seturi de date a fost: 71% (SIDB), 79% (CDB) și 99% (MIDB).

Rezultatele de clasificare obținute cu ajutorul acestui model sunt promițătoare pentru problema clasificării gesturilor de la nivelul capului, fiind comparabile cu rezultatele obținute de modelele clasice supravegheate, prezentate anterior. Avantajul acestui model (comparativ cu alte modele predictive), este dat de faptul că lucrează bine pe seturi de date dezechilibrate ori etichetate inexact.

7.4.4 Rezultate obținute pe baza algoritmilor cu învățare profundă CNN, LSTM și BLSTM

Alegerea parametrilor de configurare pentru modelele cu învățare profundă s-a realizat prin efectuarea unei căutări repetitive în spațiul de parametrii al modelelor, astfel creându-se contextul pentru identificarea parametrilor optimi ai acestora pentru problema studiată. În urma analizei efectuate pentru setul **MIDB** s-a identificat faptul că dimensiunea optimă a filtrelor prezente în straturile ascunse (primul, respectiv al doilea strat ascuns) pentru modelele CNN și LSTM a fost egală cu 16, 32, 64, 128, 256 și 512 (Severin & Dobrea, 2020). Pentru acest caz, acuratețea maximă obținută a fost de 97.89% (CNN) și 95.79% (LSTM). Pentru cazul modelului BLSTM s-a observat faptul că dimensiunea optimă a filtrelor prezente în straturile ascunse a fost egală cu 4, 16, 32, 64 și 128, unde s-a obținut o acuratețe maximă egală cu 96.84%.

Această observație este prezentată în Tabelul 11, unde sunt evidențiate performanțele de clasificare al modelelor CNN, LSTM și BLSTM pentru situația în care numărul filtrelor din structura modelului final este diferită, iar funcția de activare utilizată în structura straturilor complet conectate este SoftMax plus.

Tabel 11 Rezultate obținute pe setul MIDB de către algoritmii CNN, LSTM și BLSTM pentru diferite valori ale filtrelor prezente în structura straturilor ascunse (Severin & Dobrea, 2020)

Nr. Filtre	CNN	LSTM	BLSTM
4	29.47%	12.63%	93.68%
16	96.84%	84.21%	96.84%
32	94.74%	88.42%	96.84%
64	97.89%	94.74%	96.84%
128	93.68%	95.79%	78.95%
256	91.58%	94.74%	21.05%
512	93.68%	90.53%	17.89%

Conform cu datele prezentate în Tabelul 11, s-a constatat faptul că modelul BLSTM reușește să clasifice fiecare clasă cu succes având configurat în structura straturilor ascunse un număr de doar 4 filtre. În continuare, s-a observat faptul că funcțiile de activare (prezente pe straturile complet conectate) cu cele mai bune rezultate au fost date de: funcția sigmoid, funcția treaptă și funcția soft-max. În timp ce, pentru cele mai slabe performanțe, straturile complet conectate au fost configurate cu funcția tangentă hiperbolică. Aceste observații sunt prezentate în Tabelul 12, unde sunt evidențiate

performanțele de clasificare a modelelor CNN, LSTM și BLSTM pentru diferite funcții de activare folosite în structura straturilor complet conectate.

Tabel 12 Rezultate obținute folosind diferite funcții de activare pentru straturile complet conectate (Severin & Dobrea, 2020)

Modele DL	Nr. Filtre	ReLu	Sigmoid	SoftMax	SoftMax Plus	SoftSign	Tanh
CNN	4	34.74%	29.47%	12.63%	29.47%	56.84%	36.84%
	16	95.79%	86.32%	63.16%	96.84%	95.79%	95.79%
	32	93.68%	97.89%	42.11%	94.74%	93.68%	74.74%
	64	97.89%	97.89%	62.11%	97.89%	97.89%	97.89%
	128	96.84%	96.84%	87.37%	93.68%	96.84%	95.79%
	256	97.89%	96.84%	68.42%	91.58%	95.79%	95.79%
	512	91.58%	94.74%	72.63%	93.68%	93.68%	94.74%
LSTM	4	28.42%	21.05%	14.74%	12.63%	23.16%	28.42%
	16	65.26%	30.53%	18.95%	84.21%	73.68%	68.42%
	32	84.21%	69.47%	28.42	88.42%	93.68%	93.68%
	64	93.68%	97.89%	44.21%	94.74%	98.95%	97.89%
	128	92.63%	94.74%	37.89%	95.79%	84.21%	94.74%
	256	93.68%	96.84%	45.26%	94.74%	96.84%	92.63%
	512	91.58%	96.84%	32.63%	90.53%	92.63%	94.74%
BLSTM	4	17.89%	94.74%	83.37%	93.68%	16.84%	16.84%
	16	17.89%	96.84%	96.84%	96.84%	16.84%	17.89%
	32	17.89%	96.84%	95.79%	96.84%	17.89%	17.89%
	64	17.89%	95.79%	97.89%	96.84%	16.84%	9.47%
	128	17.89%	17.89%	98.95%	78.95%	17.89%	9.47%
	256	17.89%	17.89%	94.74%	21.05%	14.74%	9.47%
	512	17.89%	17.89%	97.89%	17.89%	16.84%	17.89%

Conform cu datele prezentate în Tabelul 12, s-a concluzionat faptul că selecția funcțiilor de activare este direct dependentă de topologia modelului folosit. Modelele LSTM și CNN, au obținut valori ridicate ale preciziei pentru situația în care numărul filtrelor din structura straturilor ascunse a fost mai mare de 16. Astfel, alegerea corespunzătoare a funcției de activare împreună cu numărul de filtre prezente în straturile ascunse a rețelei conduc la controlul asupra capacității modelului de a clasifica corect fiecare clasă prestabilită.

Pentru cazul în care s-a folosit setul **CDB**, cele mai bune rezultate de clasificare s-au obținut pentru cazul algoritmului BLSTM. Astfel, pentru cazul în care funcția de activare pentru straturile complet conectate a fost SoftMax Plus, acest model a reușit să obțină performanțe de peste 75% pentru cazul în care numărul filtrelor din straturile ascunse au fost egale cu 16, 32, 64, 128 și 256. În timp ce pentru modelele LSTM și CNN, pentru aceeași dimensiune a filtrelor, performanțele obținute au fost sub 60%. Rezultatele mici obținute pe acest set de date se datorează faptului că dimensiunea setului de date este redusă și numărul de parametri generați sunt relativ puțini, ca urmare a utilizării unei ferestre pentru fiecare clasă egală cu 128 elemente. Dimensiunea ferestrei pentru fiecare clasă menționată în acest set de date a fost aleasă astfel încât să înglobeze cât mai bine fiecare caracteristică de semnal, asociată unei mișcări de la nivelul capului. În Tabelul 13 sunt prezentate rezultatele obținute de fiecare dintre cele trei modele pentru valori similare a dimensiunii filtrelor din structura straturilor ascunse.

Tabel 13 Rezultate obținute pe setul CDB de către algoritmi CNN, LSTM și BLSTM pentru diferite valori ale filtrelor prezente în structura straturilor ascunse (Severin & Dobrea, 2020)

Nr. Filtre	CNN	LSTM	BLSTM
4	21.77%	21.77%	60.48%
16	22.58%	22.58%	74.19%
32	44.35%	46.77%	75.81%
64	41.94%	19.35%	81.45%
128	45.97%	35.48%	78.23%
256	44.35%	44.35%	75.81%
512	24.19%	24.19%	25.81%

Conform cu rezultatele prezentate în Tabelul 13, s-a constatat faptul că pentru cazul seriilor temporale capacitive modelul convolutiv CNN a obținut o performanță de peste 76%, pentru cazul în care funcția de activare a fost ReLu. În timp ce, pentru celelalte funcții de activare studiate s-au obținut rate de sub 68%.

În continuare, în urma analizei efectuate pentru setul **SIDB** s-a constatat faptul că dimensiunea optimă a filtrelor pentru această situație a fost egală cu 16, 32, 64, 128, 256 și 512, pentru fiecare dintre cele trei modele studiate. Pentru acest caz, acuratețea maximă obținută de fiecare model în parte a fost de 86% (CNN) și 90% pentru modelul LSTM și BLSTM. Comparativ cu rezultatele obținute pe setul **MIDB**, performanțele obținute pe setul **SIDB** sunt mai mari cu aproximativ 10% pentru modelul CNN, respectiv 5% pentru modelele LSTM și BLSTM.

7.4.5 Rezultate obținute pe baza algoritmilor hibridi cu învățare profundă CNN-LSTM și CNN-BLSTM

Similar cu algoritmi prezentați în capitolul precedent, algoritmi hibridi CNN-LSTM și CNN-BLSTM au fost evaluați în funcție de dimensiunea filtrelor prezente în straturile ascunse, respectiv în funcție de performanțele de clasificare obținute pentru cazul în care diferite funcții de activare au fost utilizate în arhitectura internă a acestora. Prin urmare, rezultatele preliminare obținute pentru această categorie de modele sunt evidențiate în Tabelul 14. Astfel, s-a observat faptul că arhitectura cu cele mai bune rezultate de clasificare a fost reprezentată de către CNN-BLSTM. Pentru acest model, performanțele obținute au fost de 74% pentru setul **CDB** și de peste 92% pentru cazul setului **MIDB**, respectiv **SIDB** (Severin & Dobrea, 2020). De asemenea, s-a observat faptul că tipul funcțiilor de activare utilizate în arhitectura finală a modelului nu au avut un impact comportamental major, prin urmare pentru fiecare dintre funcțiile studiate, valorile de clasificare au fost apropiate. Un alt aspect important a fost reprezentat de faptul că această arhitectură a obținut performanțe bune de clasificare inclusiv pentru cazul în care numărul filtrelor din straturilor ascunse au avut o dimensiune scăzută (4, 16 sau 32). Acest, lucru a făcut ca timpul necesar pentru etapa de calcul să fie unul redus. Pentru situația modelului CNN-LSTM această arhitectură a manifestat o dependență mare de numărul filtrelor din componența straturilor ascunse inclusiv de topologia funcțiilor de activare utilizate.

Tabel 14 Rezultate de clasificare obținute cu ajutorul algoritmilor CNN-LSTM și CNN-BLSTM, folosind diferite funcții de activare pentru straturile complet conectate

Modelle DL	DB	Nr. Filtre	ReLU	Sigmoid	SoftMax	SoftMax Plus	SoftSign	Tanh
CNN-LSTM	CDB	4	36.82%	21.32%	21.32%	15.44%	33.09%	27.21%
		16	55.88%	15.44%	26.47%	50.74%	55.88%	57.35%
		32	72.06%	32.35%	28.68%	47.06%	68.38%	69.12%
		64	81.62%	25%	28.68%	22.79%	72.79%	79.41%
		128	82.35%	21.32%	22.06%	23.53%	71.21%	80.88%
		256	87.50%	21.32%	13.97%	21.32%	78.68%	79.41%
		512	80.88%	21.32%	21.32%	16.18%	79.41%	77.21%
		4	41.82%	35.76%	37.58%	55.15%	60.91%	53.64%
	16	76.36%	78.79%	79.09%	80.61%	83.64%	83.64%	
	32	91.21%	82.73%	81.52%	87.27%	84.85%	83.94%	
	64	92.12%	90%	72.73%	87.88%	85.76%	91.82%	
	128	89.39%	93.03%	74.55%	94.55%	84.48%	90%	
	256	92.42%	92.12%	75.76%	93.33%	88.79%	93.03%	
	512	93.94%	93.94%	93.94%	67.88%	90.61%	91.21%	
	4	13.63%	16.84%	36.84%	24.21%	38.95%	36.84%	
	16	76.84%	83.16%	53.68%	81.05%	91.58%	81.05%	
	32	97.89%	77.89%	37.89%	88.42%	96.84%	95.79%	
	64	96.84%	88.42%	56.84%	96.84%	98.95%	96.84%	
	128	96.84%	97.89%	42.11%	97.89%	89.47%	95.79%	
	256	97.89%	97.89%	12.63%	97.89%	97.89%	96.84%	
	512	96.84%	96.84%	29.47%	96.84%	98.95%	97.89%	
	4	78.68%	76.47%	78.68%	75%	83.09%	73.53%	
	16	75%	77.94%	71.32%	80.88%	78.68%	75%	
	32	77.21%	78.68%	76.47%	80.15%	80.15%	66.18%	
64	78.68%	74.26%	77.94%	73.53%	75.74%	80.15%		
128	78.68%	83.09%	80.15%	72.06%	74.26%	77.94%		
256	72.79%	75%	73.53%	76.47%	73.53%	73.53%		
512	77.21%	77.94%	73.53%	72.06%	74.26%	76.47%		
4	90.61%	92.12%	91.52%	90.61%	91.21%	91.52%		
16	90.30%	91.52%	92.73%	89.70%	91.21%	91.52%		
32	92.42%	92.12%	92.12%	91.82%	92.42%	90.91%		
64	92.12%	90.91%	91.52%	93.3%	91.52%	92.73%		
128	92.42%	91.82%	91.52%	92.42%	92.73%	90.30%		
256	92.73%	92.73%	91.52%	91.21%	93.64%	92.73%		
512	90.32%	90.91%	91.82%	91.21%	90.30%	90.91%		
4	96.84%	96.84%	96.84%	97.89%	96.84%	97.89%		
16	97.89%	96.84%	98.95%	96.84%	98.95%	97.89%		
32	95.79%	97.89%	97.89%	97.89%	95.79%	95.79%		
64	97.89%	97.89%	98.95%	96.84%	97.89%	96.84%		
128	95.79%	98.95%	97.89%	97.89%	97.89%	95.79%		
256	95.79%	95.79%	96.84%	95.79%	95.79%	95.79%		
512	96.84%	97.89%	97.89%	98.95%	95.79%	96.84%		

Prin urmare, pentru cazul în care modelul final a fost antrenat cu ajutorul setului **CDB**, acesta a reușit să identifice fiecare gest cu o precizie de peste 70% pentru situația în care numărul filtrelor a fost între 32 și 512 iar funcțiile de activare au fost reprezentate de funcția, ReLU și Tanh. Pentru cazul setului de date **SIDB** modelul a scos în evidență faptul că dimensiunea ideală pentru numărul filtrelor este cuprinsă între 32 și 128, unde s-au obținut rate de până la 94%. Același comportament s-a regăsit și pentru cazul setului **MIDB** unde ratele de clasificare a modelului au atins o valoare maximă de 98.95% pentru situația în care s-a folosit funcția de activare de tip SoftSign.

Experimental, s-a identificat faptul că modelul CNN-LSTM reușește să realizeze pașii de calcul mai lent decât modelul CNN-BLSTM. Astfel, pentru primul caz (modelul CNN-LSTM) rata de clasificare a atins o valoare de peste 80% după aproximativ 40 de epoci de antrenare, față de modelul CNN-BLSTM unde s-a atins un nivel similar de clasificare după numai 10 epoci de antrenare, pentru cazul în care s-a utilizat setul de date **MIDB**. Pentru cazul setului **SIDB** și **CDB** rezultatele obținute de cele două modele au fost similare, singura diferență fiind legată de timpul de calcul efectuat de fiecare model în parte. Față de modelele clasice cu învățare automată, modelele cu învățare profundă reușesc să obțină performanțe satisfăcătoare fără a necesita pași suplimentari de procesare a datelor, această etapă realizându-se la nivelul straturilor ascunse din structura rețelei.

7.4.6 Rezultate obținute de algoritmi clasici folosind analiza comparativă a metodelor de extragere de trăsături

Metodele de extragere a trăsăturilor principale din semnal, studiate în această teză, au fost reprezentate de: extragerea caracteristicilor elementare din seriile temporale prin intermediul utilizării transformatei Fourier și a calculării caracteristicilor Jerk (**JFFT**) (Severin, 2020c), determinarea caracteristicilor principale pe baza componentelor statistice (**PSC**) (Severin, 2020a) și metoda bazată pe extragerea componente de trend și zgomot din seriile temporale (**TES**) (Severin, 2020a).

Tabel 15 Rezultate obținute folosind metoda PSC cu ajutorul algoritmilor clasici cu învățare automată

Clasificatori	CDB	SIDB	MIDB
RF	99.88%	99.89%	99.99%
ET	99.89%	99.99%	99.78%
DT	99.79%	99.79%	99.01%
ADAB	99.69%	99.89%	99.10%
GBC	99.99%	99.99%	99.68%
kNN	66%	50%	55%
SVM	99.89%	99.89%	99.78%
NB	99.99%	99.99%	99.43%
MLP	99.99%	98.21%	99.51%

Pe lângă metodele amintite anterior, analiza făcută asupra seturilor de date achiziționate folosind senzorii inerțiali s-a realizat suplimentar prin utilizarea metodelor **PCA** și **LDA** (Severin, et al., 2020). Validarea s-a realizat ulterior prin utilizarea unei metode automate

de extragere a trăsăturilor cunoscută sub denumirea de TSFRESH (Eng. „Time Series Feature Extraction on basis of Scalable Hypothesis tests”).

Prin aplicarea metodei de procesare a datelor s-a obținut o creștere a performanțelor de până la 11% față de cazul în care algoritmi clasici cu învățare automată au fost antrenați cu serii temporale aflate în forma lor brută (Severin, 2020a). În continuare, în Tabelul 16 sunt reprezentate ratele de clasificare pentru situația în care s-a utilizat metoda **TES**.

Tabel 16 Rezultate obținute folosind metoda TES cu ajutorul algoritmilor clasici cu învățare automată

Clasificatori	CDB	SIDB	MIDB
RF	88.14%	90.64%	84.65%
ET	89.64%	90.69%	84.67%
DT	88.02%	86.00%	85.86%
ADAB	89.64%	88.08%	84.68%
GBC	89.04%	89.60%	85.74%
kNN	86.32%	83.50%	84.68%
SVM	72.37%	55%	85.26%
NB	43.68%	47.01%	51.75%
MLP	54%	49%	62.29%

Rezultatele obținute cu ajutorul metodei **TES** au îmbunătățit în medie performanțele de clasificare a fiecărui gest de la nivelul capului cu aproximativ 9% față de situația în care valorile de antrenare au fost folosite în forma lor brută. Prin aplicarea metodei **TES**, cele mai bune rezultate s-au obținut pentru cazul setului de date **SIDB**, respectiv pentru cazul setului de date **CDB** unde performanțele de clasificare au fost de până la 91%. În Tabelul 17 sunt prezentate comparativ rezultatele de clasificare obținute de algoritmi cu învățare automată prin aplicarea metodelor **TES**, **PSC**, **LDA** și **PCA**.

Tabel 17 Rezultate obținute folosind setul CDB, cu 20% din valori pentru test și 80% pentru antrenare

Clasificatori	Analiza PCA	Analiza LDA	Analiza PSC	Analiza TES	Serii brute
	Acuratețe [%]	Acuratețe [%]	Acuratețe [%]	Acuratețe [%]	Acuratețe [%]
RF	80.46 %	80.46 %	99.88%	88.14%	80.46 %
ET	81.42 %	81.01 %	99.89%	89.64%	81.03%
DT	73.58 %	73.17 %	99.79%	88.02%	73.36 %
ADAB	81.03 %	80.90 %	99.69%	89.64%	81.19 %
GBC	74.36 %	74.36 %	99.99%	89.04%	74.36 %
kNN	60.69%	58.78%	66%	86.32%	74.70%
SVM	53.74%	52.79%	99.89%	72.37%	62.53%
NB	30.69%	34%	99.99%	43.68%	26.04%
MLP	41.81%	42.35%	99.99%	54%	47.27%

Rezultatele de clasificare obținute cu ajutorul analizei PCA respectiv LDA au evidențiat faptul că performanțele algoritmilor cu învățare automată clasici au obținut valori comparabile cu situația în care seriile au fost folosite în forma lor brută. Pentru cazul utilizării senzorilor capacitivi, s-a identificat faptul că metodele propuse și studiate au

îmbunătățit performanțele de clasificare cu peste 10% și au scăzut timpul petrecut de fiecare algoritm în clasificarea fiecărei clase.

Tabel 18 Rezultate obținute folosind setul MIDB, cu 20% din valori pentru test și 80% pentru antrenare

Clasificatori	Analiza PCA	Analiza LDA	Analiza PSC	Analiza TES	Serii brute
	Acuratețe [%]	Acuratețe [%]	Acuratețe [%]	Acuratețe [%]	Acuratețe [%]
RF	95.50 %	95.27 %	99.99%	84.65%	98.70 %
ET	95.51 %	95.11 %	99.78%	84.67%	98.72 %
DT	94.18 %	94.30 %	99.01%	85.86%	98.13 %
ADAB	95.72 %	95.22 %	99.10%	84.68%	98.72 %
GBC	94.59 %	94.52 %	99.68%	85.74%	99.31 %
kNN	86.36%	84.50%	55%	84.68%	96.81%
SVM	77.85%	79.77%	99.78%	85.26%	95.49%
NB	47.57%	58.68%	99.43%	51.75%	50.36%
MLP	56.58%	67.62%	99.51%	62.29%	77.15%

Tabel 19 Rezultate obținute folosind setul SIDB, cu 20% din valori pentru test și 80% pentru antrenare

Clasificatori	Analiza PCA	Analiza LDA	Analiza PSC	Analiza TES	Serii brute
	Acuratețe [%]	Acuratețe [%]	Acuratețe [%]	Acuratețe [%]	Acuratețe [%]
RF	74,37 %	74.95 %	99.89%	90.64%	76.20 %
ET	74.47 %	75.11 %	99.99%	90.69%	76.31 %
DT	73.47 %	73.82 %	99.79%	86.00%	75.80 %
ADAB	74.23 %	74.86 %	99.89%	88.08%	76.19 %
GBC	71.96 %	72.31 %	99.99%	89.60%	74.27 %
kNN	70.90%	70.85%	50%	83.50%	70.39%
SVM	58.76%	59.45%	99.89%	55%	58.76%
NB	41.66%	44%	99.99%	47.01%	46.72%
MLP	52.60%	51.46%	98.21%	49%	52.19%

Pentru situația în care s-a utilizat setul de date **SIDB**, rata de clasificare a crescut în medie cu 10%, similar cu situația precedentă unde pentru clasificarea gesturilor de la nivelul capului s-au utilizat senzori capacitivi.

Rezultatele obținute de metoda de procesare **JFFT** (Severin, 2020c), sunt evidențiate în Tabelul 20. Folosind această metodă, s-a identificat faptul că cele mai bune rezultate s-au obținut pentru cazul seturilor de date **SIDB** și **MIDB**. Pentru cazul setului **CDB**, performanțele de clasificare au fost influențate de variația fiecărei clase predefinite. Din acest motiv, pentru cazul algoritmilor bazați pe principiul similarității datelor (eg. kNN, SVM), performanțele de clasificare au avut valori scăzute. Cu toate acestea, algoritmi bazati pe principiul de încapsularea al datelor (ET, DT, RF, etc.) nu au fost influențați de variația din interiorul claselor de apartenență, obținând astfel rezultate bune de clasificare, cu valori de peste 90%. Rezultatele prezentate anterior în acest capitol, au scos în evidență faptul că cele trei metode de preprocesare a datelor pot îmbunătății în medie performanțele de clasificare cu valori de peste 10%. O altă observație, constă în faptul că rezultate obținute prin aplicarea celor trei metode enumerate anterior în acest capitol au fost

comparabile cu rezultatele obținute prin aplicarea metodei *TSFRESH* unde performanțele au fost în medie egale cu 90% (Severin, 2020a).

Tabel 20 Rezultate obținute folosind metoda JFFT cu 20% din valori pentru test și 80% pentru antrenarea algoritmilor clasici cu învățare automată

Clasificatori	CDB	SIDB	MIDB
RF	90.77%	98.82%	100%
ET	90.71%	99.35%	100%
DT	91.28%	96.46%	99.98%
ADAB	90.41%	99.36%	100%
GBC	91.47%	97.57%	99.73%
kNN	30.30%	91.1%	96.22%
SVM	31.37%	85.34%	99.13%
NB	28.24%	65.89%	53.56%
MLP	30.62%	70.46%	88.15%

CAPITOLUL 8

Concluzii finale și contribuții personale

În acest capitol sunt prezentate concluziile finale și diseminarea rezultatelor experimentale obținute ca urmare a cercetării realizate. De asemenea sunt prezentate contribuțiile personale aduse domeniului HCI prin subiectul de cercetare abordat, precum și direcțiile viitoare de cercetare ce pot surveni acestei teze.

8.1.1 Concluzii generale


În această teză de doctorat s-a prezentat o suită de contribuții legate de analiza și recunoașterea activităților motorii realizate la nivelul capului prin intermediul utilizării senzorilor purtabili neconvenționali (senzori capacitivi și senzori inerțiali MEMS). Achiziția semnalelor inerțiale prin intermediul cărora s-a studiat componenta mișcării, reprezintă prima etapă în implementarea unui sistem de interfațare om-calculator. Pasul de achiziție a semnalelor inerțiale, a necesitat definirea unei strategii de înregistrare (protocol experimental) pentru executarea fiecărei mișcări/gest de referință. De asemenea, definirea gesturilor de referință a implicat un proces amplitu de studiu prin care s-a încercat identificarea caracteristicilor de generalizare a problemei studiate. În urma procesului de achiziție, s-au obținut trei seturi de date proprii obținute de la un număr definit de subiecți sănătoși. Seturile de date obținute sunt unice, în literatură nefiind identificate studii similare prin care mișcările de la nivelul capului să fie determinate prin intermediul acestor topologii de senzori (Severin & Dobrea, 2021).

În pasul următor s-a realizat extragerea trăsăturilor principale din semnalele inerțiale, cu scopul de a maximiza capacitatea de generalizare a algoritmilor studiați. Astfel, această etapă a fost realizată offline prin intermediul a două metode standard (folosind analiza LDA și PCA), respectiv prin aplicarea a trei metode implementate pentru obiectivul acestei

teze (*JFFT*, *TES* și *PSC*). Dezvoltarea modelelor de clasificare a reprezentat următorul pas în procesul de propunere și dezvoltare a sistemelor de recunoaștere a gesturilor motorii. Paradigma clasificării gesturilor realizate la nivelul capului, a fost îndeplinită în continuare prin dezvoltarea și adaptarea a nouă algoritmi clasici cu învățare automată (Severin, 2021), respectiv a cinci algoritmi cu învățare profundă (Severin & Dobrea, 2020). Evaluarea performanțelor oferite la ieșirea fiecărui model a fost posibilă prin implementarea și utilizarea metricilor de evaluare consacrate. Astfel s-a constatat faptul că prin utilizarea semnalelor inerțiale în forma lor brută performanțele obținute de clasificatorii clasici s-au situat în jurul valorii de 70% (setul **CDB**), 75% (setul **SIDB**) și 95% (setul **MIDB**).

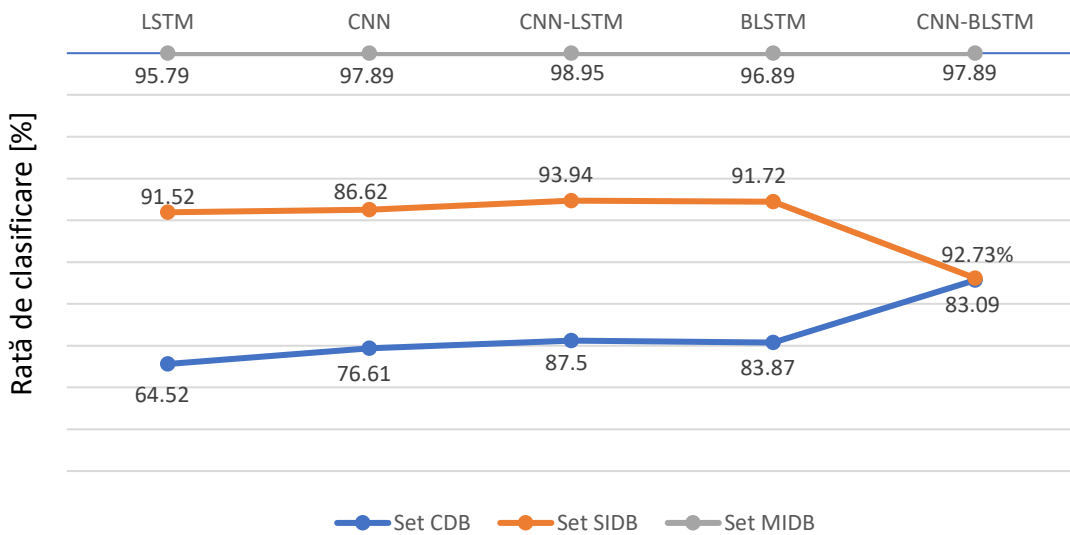
Astfel, cele mai bune rezultate de clasificare au fost obținute cu ajutorul *algoritmilor clasici ce folosesc principiul de încapsulare al datelor* (ex. *RF*, *ET*, *DT*, *ADAB* sau *GBC*). Pentru cazul algoritmilor ce folosesc *principiul similarității existente între clase* performanțele de clasificare au fost în medie egale cu 70% pentru seturile de date **CDB** și **SIDB**, în timp ce pentru setul de date **MIDB** performanțele de clasificare au fost de peste 90%.

Rețelele neuronale de tip multilayer perceptron (MLP) au reprezentat o altă categorie de modele studiate, ce au avut performanțele de clasificare egală cu 65% pentru setul **CDB**, 60% pentru setul **SIDB** și 96.87% pentru setul **MIDB**. Rezultatele obținute prin utilizarea algoritmilor clasici cu învățare automată au scos în evidență faptul că anumiți factori externi pot afecta capacitățile de recunoaștere al gesturilor. Printre acești factori externi se pot amintii: nivelul de înclinare al capului, alinierea senzorilor cu centrul de greutate al corpului, viteza de efectuare a gesturilor, zgomotul de fundal, perturbațiile electromagnetice produse de diferite echipamente electronice aflate în perimetrul apropiat, etc. Prin urmare, s-a constatat faptul că senzorii inerțiali de tip MEMS captează mult mai bine caracteristica de mișcare comparativ cu senzorii capacitivi, fapt ce a condus la performanțe de clasificare mai bune cu până la 20% pentru cazul sistemelor ce folosesc senzorii inerțiali MEMS în detrimentul senzorilor capacitivi. Această observație este evidențiată în Figura 21 (Severin, 2021):



Figură 21 Performanțele de clasificare obținute folosind modele clasice cu învățare automată

Modelele cu învățare profundă CNN, LSTM și BLSTM, CNN-BLSTM și modelul CNN-LSTM au obținut performanțe de clasificare mai mari de 65% pentru fiecare set de antrenament. Cele mai slabe rezultate s-au obținut pentru cazul în care s-au utilizat senzori capacitivi. În timp ce, rezultatele cele mai satisfăcătoare au fost obținute pentru cazul în care s-au utilizat senzori inerțiali MEMS. Rezultatele obținute pentru fiecare caz în parte sunt prezentate în Figura 22 (Severin & Dobrea, 2021c)(Severin, 2021).



Figură 22 Performanțele de clasificare obținute folosind modele cu învățare automată profundă

Comparativ cu modelele clasice cu învățare automată, modelele cu învățare profundă au reușit să obțină performanțe satisfăcătoare fără a necesita pași suplimentari de procesare a datelor. Astfel, configurarea corectă a modelelor cu învățare profundă poate avea implicații în reducerea numărului de senzori inerțiali plasați în sistemele de achiziție, caracteristică observată pe parcursul cercetărilor realizate.

Algoritmii hibridi cu învățare profundă constituie o noutate în domeniul sistemelor de clasificare a gesturilor, fiind în acest moment în stadiul de analiză și dezvoltare pentru diverse arii de cercetare. Rezultatele obținute cu această categorie de modele, au fost printre cele mai bune pentru fiecare caz studiat, observație evidențiată și în Figura 22. Prin urmare, caracteristicile acestor modele oferă un compromis bun între viteza de execuție și precizia cu care fiecare gest este clasificat corect.

Rezultatele de clasificare obținute cu ajutorul algoritmilor studiați (algoritmii clasici cu învățare automată și algoritmii cu învățare profundă), au condus la concluzia că dispozitivele portabile folosite pentru recunoașterea gesturilor prin intermediul senzorilor inerțiali (capacitivi sau MEMS), sunt o soluție viabilă pentru achiziția și recunoașterea caracteristicilor de mișcare, având potențialul de a deveni o alternativă pentru senzorii cu un nivel ridicat de complexitate (de ex. senzori foto/video, Kinect, etc.) sau pentru cei cu un cost ridicat de achiziție.

Sistemele propuse și studiate pe parcursul cercetărilor realizate au fost concepute să ofere posibilitatea persoanelor tetraplegice să controleze un dispozitiv media sau un scaun cu roțile inteligent de la distanță prin intermediul mișcărilor realizate la nivelul capului. Deși cercetările realizate au fost orientate pentru o problemă specifică, rezultatele obținute pot fi utilizate ca sursă de referință pentru cercetările ulterioare din domeniul HCI ce studiază această categorie de senzori pentru recunoașterea și înțelegerea semnalelor motorii realizate la nivelul corpului.

Astfel, considerând obiectivul principal al acestei cercetări s-au identificat o serie de avantaje și dezavantaje pentru fiecare clasă de senzori utilizați. Pentru situația senzorilor capacitivi, avantajele oferite de aceștia sunt reprezentate de nivelul scăzut al complexității HW, dimensiuni scăzute (fapt ce favorizează includerea cu ușurință în dispozitive portabile), pot funcționa perioade îndelungate de timp având un consum mic de energie

sau au un cost mic de achiziție. Printre principalele dezavantaje observate, se poate aminti faptul că această categorie de senzori sunt predispuse la zgomotul produs de echipamentele aflate în imediata proximitate, pot fi imprecizi datorită faptului că pot fi afectați de deplasările inerente produse la nivelul sistemului purtabil sau pot fi afectați de proprietățile fiziologice ale utilizatorilor. Pentru situația senzorilor inerțiali MEMS (accelerometru, giroscop și magnetometru), avantajele oferite de aceștia sunt date de ușurința de integrare în dispozitive portabile, precizie ridicată pentru captarea caracteristicilor de mișcare și nu sunt limitați de o anumită zonă de operare (parte a corpului). Prin urmare, luând în calcul faptul că acești senzori sunt întotdeauna transportați de utilizator (prin includerea lor în dispozitive comune cum sunt ceasuri, telefoane sau căști inteligente), aceștia sunt omniprezenți în viața cotidiană ne fiind astfel constrânși de caracteristicile corporale ale utilizatorilor ori de utilizare (nu sunt constrânși de condiții experimentale controlate). Ca principale dezavantaje, se poate menționa faptul că acești senzori pot devenii incomozi pentru utilizatorii obișnuiți (de exemplu, dacă trebuie re poziționați în mod constant după fiecare utilizare sau dacă trebuie utilizată o anumită procedură) și nu pot fi utilizați un timp îndelungat (în condiții reale de utilizare) fără a reîncărca sursa de alimentare în mod regulat.

8.1.2 Contribuții personale și elemente de originalitate

Deși domeniul HCI are o aplicabilitate diversă în zilele noastre, dispozitivele HCI ce folosesc senzorii inerțiali pentru citirea și clasificarea gesturilor de la nivelul capului sunt relativ la început necesitând studii suplimentare de aprofundare (Severin & Dobrea, 2021). Pe parcursul acestei teze s-au prezentat o serie de contribuții legate de recunoașterea gesturilor de la nivelul capului utilizând două categorii de senzori portabili neconvenționali. Astfel, s-a explorat posibilitatea dezvoltării de sisteme portabile de ultimă generație, atât hardware cât și software, pentru recunoașterea gesturilor centrate pe om, cu scopul final de a crește calitatea vieții. Principalele contribuții aduse prin această lucrare sunt următoarele:

- Propunerea și dezvoltarea unui nou sistem de interfațare om-calculator pentru citirea gesturilor de la nivelul capului utilizând senzori capacitivi.
- Propunerea și dezvoltarea a două noi sisteme de interfațare om-calculator pentru citirea gesturilor de la nivelul capului utilizând senzori inerțiali MEMS (accelerometru, giroscop și magnetometru) cu șase și nouă grade de libertate.
- Crearea a trei baze de date proprii (*CDB*, *SIDB* și *MIDB*), obținute prin achiziția semnalelor de mișcare de la un număr definit de voluntari sănătoși antrenați să simuleze situația unor persoane ce suferă de tetrapareză.
- Propunerea și dezvoltare unui proces general de ultimă generație ce poate fi folosit în dezvoltarea și evaluarea sistemelor de recunoaștere a gesturilor de la nivelul capului prin intermediul utilizării semnalelor inerțiale.
- Propunerea, dezvoltarea și studierea a nouă modele clasice cu învățare automată utilizate pentru rezolvarea paradigmei de clasificare a gesturilor realizate la nivelul capului.
- Propunerea, dezvoltarea și studierea a 3 modele cu învățare profundă (*CNN*, *LSTM* și *BLSTM*) utilizate pentru rezolvarea paradigmei de clasificare a gesturilor realizate la nivelul capului prin utilizarea senzorilor inerțiali.
- Propunerea, dezvoltarea și studierea a două modele hibride cu învățare profundă (*CNN-LSTM*, și *CNN-BLSTM*) utilizate pentru rezolvarea paradigmei de

clasificare a gesturilor realizate la nivelul capului prin utilizarea senzorilor inerțiali.

- Propunerea și studierea a trei metode de procesare a seturilor de date inerțiale cu scopul de a studia posibilitățile de creștere a nivelului de generalizare și clasificare pentru modelele finale create.

8.1.3 Valorificarea rezultatelor obținute (Lista publicațiilor originale realizate)

Diseminarea rezultatelor a presupus publicarea unui număr de 12 lucrări, dintre care 11 ca prim autor. Dintre acestea, 4 sunt publicate în reviste, dintre care 2 sunt indexate ISI, iar una dintre ele este o revistă cotate ISI având factorul de impact de 2.635 (Q3). 8 articole sunt indexate ISI Web of Science iar 4 articole sunt indexate în alte baze de date cu circulație internațională (IEEE Xplore, SCOPUS, PubMed, DBLP sau DOAJ):

Reviste:

1. **I.C. Severin**, D.M. Dobra and M.C. Dobra, Head Gesture Recognition using a 6DOF Inertial IMU, International Journal of Computers Communications & Control, vol. 15, no. 3, 2020, ISSN: 1841-9836, DOI: 10.15837/ijccc.2020.3.3856, WOS: 000528258600005, **lucrare indexată în: ISI Web of Science, DBLP, Scopus, DOAJ, revistă cotate ISI IF (2022): 2.635 (Q3).**
2. **I.C. Severin**, and Dobra Dan-Marius. 2021. "Using Inertial Sensors to Determine Head Motion—A Review" Journal of Imaging 7, no. 12: 265. <https://doi.org/10.3390/jimaging7120265>, **lucrare indexată în: ISI Web of Science, PubMed, DOAJ, Scopus, IF (2022): 3.4 (Q3).**
3. **I.C. Severin** and Dobra, Dan-Marius. "Head Gesture Recognition Based on Capacitive Sensors Using Deep Learning Algorithms" Bulletin of the Polytechnic Institute of Iași. Electrical Engineering, Power Engineering, Electronics Section, vol.67, no.3, 2021, pp.73-92. <https://doi.org/10.2478/bipie-2021-0018>
4. **I.C. Severin**. "SYSTEM FOR DETECTING THE TRANSMISSION ERROR RATE DURING WI-FI COMMUNICATION WITH CC3220SF LAUNCHPAD" Bulletin of the Polytechnic Institute of Iași. Electrical Engineering, Power Engineering, Electronics Section, vol.66, no.3, 2020, pp.77-97.

Conferințe:

1. M.C. Dobra, D.M. Dobra and **I.C. Severin**, A new wearable system for head gesture recognition designed to control an intelligent wheelchair, The 7th IEEE International Conference on E-Health and Bioengineering (EHB 2019), Iasi, Romania, 21-23 Nov. **2019**, ISBN: 978-1-7281-2603-6, **INSPEC Accession Number:** 19300443, DOI: 10.1109/EHB47216.2019.8969993, WOS: 000558648300125, **lucrare indexată în: IEEE Xplore, ISI Web of Science**
2. **I.C. Severin**, Time series feature extraction for Head gesture recognition: Considerations toward HCI Applications, 24th International Conference on System Theory, Control and Computing (ICSTCC 2020), Sinaia, Romania, 8-10 Oct. **2020**, Electronic ISBN: 978-1-7281-9809-5, **INSPEC Accession Number:** 20198664, DOI: 10.1109/ICSTCC50638.2020.9259741, **lucrare indexată în: IEEE Xplore, ISI Web of Science**
3. **I.C. Severin** and D. M. Dobra, 6DOF Inertial IMU Head Gesture Detection: Performance Analysis Using Fourier Transform and Jerk-Based Feature Extraction, IEEE Microwave Theory and Techniques in Wireless Communications (MTTW 2020), Riga, Latvia, **2020**, pp. 118-123, 1-2 Oct. 2020, Electronic ISBN: 978-1-7281-9398-4, **INSPEC Accession Number:** 20133391, DOI: 10.1109/MTTW51045.2020.9245072, **lucrare indexată în: IEEE Xplore și SCOPUS**
5. **I.C. Severin**, Head Posture monitor based on 3 IMU sensors: Consideration toward Healthcare application, The 8-th IEEE International Conference on e-Health and Bioengineering (EHB 2020), Iasi, Romania, 29-30 Oct. **2020**, Electronic ISBN: 978-1-7281-8803-4, DOI: 10.1109/EHB50910.2020.9280106, **lucrare indexată în: IEEE Xplore, ISI Web of Science**

6. **I.C. Severin**, D.M. Dobrea, Head Gesture Recognition based on 6DOF Inertial sensor using Artificial Neural Network, International Symposium on Electronics and Telecommunications (ISETC 2020), Timisoara, Romania, 5-6 Nov. **2020**, Electronic ISBN: 978-1-7281-9513-1, Print ISBN: 978-1-7281-8921-5, DOI: 10.1109/ISETC50328.2020.9301099, Indexata in IEEE Xplore, **lucrare indexată în: IEEE Xplore, ISI Web of Science**
7. **I.C. Severin**, The Head Posture System Based on 3 Inertial Sensors and Machine Learning Models: Offline Analyze, 3rd International Seminar on Research of Information Technology and Intelligent Systems (ISRITI 2020), Yogyakarta, Indonesia, 10-11 Dec. **2020**, Electronic ISBN: 978-1-7281-8406-7, Print ISBN: 978-1-7281-8404-3, DOI: 10.1109/ISRITI51436.2020.9315418, **lucrare indexată în: IEEE Xplore și SCOPUS**
8. **I.C. Severin**, "Head Gesture-Based on IMU Sensors: a Performance Comparison Between the Unimodal and Multimodal Approach," 2021 International Symposium on Signals, Circuits and Systems (ISSCS), 2021, pp. 1-4, doi: 10.1109/ISSCS52333.2021.9497434, **lucrare indexată în: IEEE Xplore**
9. **I.C. Severin**, "A Brief Review of Using the Inertial Sensor to Determine the Driver Head Posture," *2021 International Conference on e-Health and Bioengineering (EHB)*, 2021, pp. 1-4, doi: 10.1109/EHB52898.2021.9657575, **lucrare indexată în: IEEE Xplore, ISI Web of Science**

8.1.4 Direcții de continuare și dezvoltări ulterioare a cercetărilor

În urma activităților realizate în întreaga perioadă de studii doctorale s-au identificat o serie de direcții viitoare de cercetare prin care subiectul principal tratat în această teză poate fi studiat și îmbunătățit în continuare:

- Completarea bazelor de date deja create cu date de la mai mulți voluntari (astfel încât distribuția claselor să fie echilibrată și omogenă din punct de vedere al influenței caracteristicilor corporale date de fiecare utilizator) sau prin generarea sintetică a seriilor temporale (ex. Algoritmul Generative Adversarial Networks (GAN), Inserarea de anomalii, etc.).
- Dezvoltarea unei baze de date noi cu măsurători realizate în condiții reale (ex. achiziția semnalelor inerțiale de la persoane ce suferă de tetrapareză).
- Explorarea posibilității de dezvoltarea a unui mecanism de etichetare automată a gesturilor provenite de la utilizatorii noii implicați în etapa de achiziție.
- Îmbunătățirea modelelor de clasificare dezvoltate prin adăugarea unor etape de preprocesare suplimentare dinamice astfel încât sistemele de recunoaștere a gesturilor să facă față la diferite viteze de mișcare ale capului (ex. prin aplicarea metodei de deformarea dinamică a timpului (DTW)).
- Studiarea paradigmei de segmentare dinamică a seriilor inerțiale ce pot cuprinde mai multe gesturi efectuate simultan (de exemplu mișcarea capului simultan cu mișcarea membrelor superioare, etc.).
- Evaluarea sistemelor propuse prin implementarea unei aplicații ce rulează în timp-real și poate fi utilizată în condiții reale.
- Explorarea și implementarea strategiilor de învățare semi-automată prin care gesturile provenite de la noi utilizatori (activități neetichetate) pot fi combinate cu datele deja antrenate etichetate pentru a produce îmbunătățiri considerabile în precizia învățării sistemului. Acest lucru poate aduce avantaje utilizatorilor noi, în special celor cu condiții speciale, cum ar fi mișcarea foarte lentă, handicap motor pronunțat (absența mobilității capului, absența posibilității de mișcare completă a capului, etc.).
- Explorarea posibilității de utilizare a senzorilor ambiențiali (ex. senzori de proximitate, GPS, camere foto-video, etc.) pentru corectarea și validarea

procesului de clasificare realizat de sistemele bazate pe senzori inerțiali dezvoltate în această teză.

- Explorarea posibilității utilizării combinate, a acestor clase de senzori prezentați în această teză, cu senzori clasici domeniului sau mai noi (precum cei textili) prin intermediul algoritmilor de fuziune a datelor în vederea obținerii de performanțe superioare în cadrul gesturilor complexe.
- Extinderea aplicabilității sistemelor propuse pentru rezolvarea altor probleme de clasificare prezente în alte domenii de interes (ex. automotive (Severin, 2021d) sau divertisment).

BIBLIOGRAFIE

- Agarwal, T. (2019). Gyroscope sensor- working, Types & Applications. Retrieved 10 23, 2022, from <https://www.elprocus.com/gyroscope-sensor/3>
- Aggarwal, C. C. (2018). *Neural Networks and Deep Learning*. Berlin, Germany: Springer.
- Alvarez, D., Alvarez, J., Gonzalez, R., & Lopez, A. (2015). Upper limb joint angle measurement in occupational health. *Comput Methods Biomech Biomed Engin.*, 19(2), 159-170.
- Anderson, J., Granat, M., Williams, A., & Nester, C. (2019). Exploring occupational standing activities using accelerometer-based activity monitoring. *Ergonomics*, 68(8), 1055–1065.
- Awad, M., & Khanna, R. (2015). *Efficient Learning machines, Theories, Concepts, and Applications for Engineers and System Designers*. Springer Nature.
- Balfas, M., Ahamed, S. I., Tamma, C., Arif, M., Kattan, A. J., & Chu, W. (2018). A Study and Estimation a Lost Person Behavior in Crowded Areas Using Accelerometer Data from Smartphones. *2018 IEEE 42nd Annual Computer Software and Applications Conference (COMPSAC)*, (pp. 860-865). Tokyo, Japan.
- Bao, L., & Intille, S. (2004). *Activity Recognition from User-Annotated Acceleration Data* (Vol. 3001). Berlin: Springer Berlin Heidelberg.
- Barreto, A., Oliveira, R., Sousa, F., Cardoso, A., & Duarte, C. (2014). Environment-aware system for Alzheimer's patients. *2014 4th International Conference on Wireless Mobile Communication and Healthcare - Transforming Healthcare Through Innovations in Mobile and Wireless Technologies (MOBIHEALTH)*, (pp. 300-303). Athens, Greece.
- Bassam, A.-S., Majid, H., & Thamer, A.-R. (2020). A Novel Approach for the Detection of Road Speed Bumps using Accelerometer Sensor. *TEM Journal*, 9(2), 469-476.
- Bearman, A. L., & Dong, C. (2015). Human Pose Estimation and Activity Classification Using Convolutional Neural Networks. *Stanford CS231n*.
- Bieda, R., & Jaskot, K. (2016). Determining of an object orientation in 3D space using direction cosine matrix and non-stationary Kalman filter. *Archives of Control Sciences*, 26(2), 223-244.
- Bishop, C. (2006). *Pattern Recognition and Machine Learning*. New York: Springer.
- Bishop, C. M. (2016). *Pattern Recognition and Machine Learning*. New York: Springer.
- Biswas, M., & al., e. (2022). Prototype Development of an Assistive Smart-Stick for the Visually Challenged Persons. *2022 2nd International Conference on Innovative Practices in Technology and Management (ICIPTM)*, (pp. 477-482). Gautam Buddha Nagar, India.
- Borrego-Carazo, J., Castells-Rufas, D., Carrabina, J., & Biempica, E. (2020). Capacitive-sensing module with dynamic gesture recognition for automotive applications. *2020 23rd International Symposium on Design and Diagnostics of Electronic Circuits & Systems (DDECS)*, (pp. 1-6). Novi Sad, Serbia.
- Bramhapurikar, K., Prabhune, A., Chavan, S., Ghivela, G. C., & Sengupta, J. (2018). A Wearable Posture Corrector Device. *2018 9th International Conference on Computing, Communication and Networking Technologies (ICCCNT)*, (pp. 1-5). Bengaluru, India.
- Brandt, M., Madeleine, P., Ajslev, J., Jakobsen, M., Samani, A., Sundstrup, E., . . . Andersen, L. (2015). Participatory intervention with objectively measured physical risk factors for musculoskeletal disorders in the construction industry: study protocol for a cluster randomized controlled trial. *BMC Musculoskeletal Disord*.

- Brown, R., & Hwang, P. (1997). *Introduction to Random Signals and Applied Kalman Filtering*. New York: John Wiley & Sons.
- Burkov, A. (2021). The Hundred-Page Machine Learning Book. *Journal of Data Analysis and Information Processing*, 9(2).
- Chen, C., Lin, Y., Lin, C., Chen, Y., Lee, Y., & Wang, C. (2020). Rehabilitation System for Limbs using IMUs. *2020 21st International Symposium on Quality Electronic Design (ISQED)*, (pp. 285-291). Santa Clara, USA.
- Chen, J., Zhu, J., & Guo, M. (2022). An SVM-Based Pedestrian Gait Recognition Algorithm Using a Foot-Mounted IMU. *2022 IEEE 5th International Conference on Electronics Technology (ICET)*, (pp. 1085-1090). Chengdu, China.
- Christ, M., Braun, N., Neuffer, J., & Kempa-Liehr, A. W. (2018). Time Series Feature Extraction on basis of Scalable Hypothesis tests (tsfresh – A Python package). *Neurocomputing*, 307, 72-77.
- Cohn, G., Morris, D., Patel, S., & Tan, D. (2012). Humantenna: Using the body as an antenna for real-time whole-body interaction. *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems*, 1901-1910.
- Collin, J., Davidson, P., Kirkko-Jaakkola, M., & Leppäkoski, H. (2018). Inertial sensors and their applications. *Handbook of Signal Processing Systems*, 51-85.
- Conway, D., & White, J. (2012). *Machine Learning For Hackers*. O'Reilly Media, Inc.
- Cortes, C., & Vapnik, V. (1995). *Support-vector networks* (Vol. 20). Springer.
- Dao, L. (2022). Orientation Prediction for VR and AR Devices Using Inertial Sensors Based on Kalman-like Error Compensation. *IEEE Access*.
- Darapaneni, N., & al., e. (2022). Distracted Driver Monitoring System Using AI. *2022 Interdisciplinary Research in Technology and Management (IRTM)* (pp. 1-8). Kolkata, India: IEEE.
- Deep, S., & Zheng, X. (2019). Hybrid Model Featuring CNN and LSTM Architecture for Human Activity Recognition on Smartphone Sensor Data. *2019 20th International Conference on Parallel and Distributed Computing, Applications and Technologies (PDCAT)*, (pp. 259-264). Gold Coast, Australia.
- Demrozi, F., Bacchin, R., Tamburin, S., Cristani, M., & Pravadelli, G. (2020). Toward a wearable system for predicting freezing of gait in people affected by parkinson's disease. *IEEE Journal of Biomedical and Health Informatics*, 24(9), 2444-2451.
- Demrozi, F., Pravadelli, G., Bihorac, A., & Rashidi, P. (2020). Human Activity Recognition Using Inertial, Physiological and Environmental Sensors: A Comprehensive Survey. *IEEE Access*, 8, 210816-210836.
- Dobrea, D. M. (2017). Tehnici de inteligență computațională. Aplicații în electronică și biomedicină. (p. 180). Iași, România: Editura Performantica.
- Dobrea, D. M., & Dobrea, M. C. (2018). A Neuronal Model of the 3D Head Position Based on a Wearable System. *2018 International Conference and Exposition on Electrical And Power Engineering (EPE)*, (pp. 0341-0346). Iasi, Romania.
- Dobrea, M. C., Dobrea, D. M., & Severin, I. C. (2019). A new wearable system for head gesture recognition designed to control an intelligent wheelchair. *The 7th IEEE International Conference on E-Health and Bioengineering (EHB 2019)* (pp. 1-5). Iasi Romania: IEEE.
- Doheny, E. P., Lowery, M. M., Russell, A., & Ryan, S. (2020). Estimation of respiration rate and sleeping position using a wearable accelerometer. *2020 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)*, (pp. 4668-4671). Montreal, Canada.
- Dorszewski, T., Jiang, W., & Sigg, S. (2022). Detection of an Ataxia-type disease from EMG and IMU sensors. *2022 IEEE International Conference on Pervasive Computing and Communications Workshops and other Affiliated Events (PerCom Workshops)* (pp. 712-717). Pisa, Italy: IEEE.
- Drucker, H., Burges, C., Kaufman, L., Smola, A., & Vapnik, V. (1997). Support vector regression machines. *Advances in Neural Information Processing Systems (NIPS)*, 9, 155–161.
- Eddison, L. (2017). *Python programming: A step by step guide for beginners*. Leonard Eddison.
- Erickson, Z., Clever, H. M., Gangaram, V., Turk, G., Liu, C. K., & Kemp, C. C. (2019). Multidimensional Capacitive Sensing for Robot-Assisted Dressing and Bathing. *2019 IEEE 16th International Conference on Rehabilitation Robotics (ICORR)*, (pp. 224-231). Toronto, Canada.
- Faghihinia, A., Atashgah, M. A., & Dehghan, S. M. (2022). Model-Based Cooperative Navigation for a Group of Flying Robots. *IEEE Transactions on Aerospace and Electronic Systems*, 58(5), 3895-3905.

- Fajar, R., Suciati, N., & Navastara, D. A. (2020). Real Time Human Activity Recognition Using Convolutional Neural Network and Deep Gated Recurrent Unit. *2020 International Conference on Electrical Engineering and Informatics (ICELTICs)*, (pp. 1-6). Aceh, Indonesia.
- Farrokhi, A., Farahbakhsh, R., Rezazadeh, J., & Minerva, R. (2021). Application of Internet of Things and artificial intelligence for smart fitness: A survey. *Computer Networks*, *189*, 107859.
- Fasel, B., & J. Spörri, P. S. (2017). Validation of functional calibration and strap-down joint drift correction for computing 3D joint angles of knee, HIP, and trunk in Alpine Skiing. *PLOS ONE*, *12*(7).
- Fleury, A., Vacher, M., & Noury, N. (2010). SVM-based multimodal classification of activities of daily living in health smart homes: Sensors, algorithms, and first experimental results. *IEEE Transactions on Information Technology in Biomedicine*, *14*(2), 274-283.
- Fonseca, L., Guiraud, D., Haiarrassary, A., Fattal, C., & Azevedo-Coste, C. (2022). A Residual Movement Classification Based User Interface for Control of Assistive Devices by Persons With Complete Tetraplegia. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, *30*, 569-578.
- Fu, B., Damer, N., Kirchbuchner, F., & Kuijper, A. (2020). Sensing Technology for Human Activity Recognition: A Comprehensive Survey. *IEEE Access*, *8*, 83791-83820.
- Fukunaga, K. (1990). *Introduction to Statistical Pattern Recognition*. 2nd ed. San Diego, CA: Academic Press Prof., Inc.
- Gatt, T., Seychell, D., & Dingli, A. (2019). Detecting human abnormal behaviour through a video generated model. *2019 11th International Symposium on Image and Signal Processing and Analysis (ISPA)*, (pp. 264-270). Dubrovnik, Croatia.
- Géron, A. (2019). *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow*, 2nd Edition. O'Reilly Media, Inc.
- Ghosh, A., Chakraborty, A., Chakraborty, D., Saha, M., & Saha, S. (2019). UltraSense: A non-intrusive approach for human activity identification using heterogeneous ultrasonic sensor grid for smart home environment. *Journal of Ambient Intelligence and Humanized Computing*, *10*(3).
- Gomes, D., Fernandes, F., Castro, E., & Pires, G. (2019). Head-movement interface for wheelchair driving based on inertial sensors. *2019 IEEE 6th Portuguese Meeting on Bioengineering (ENBENG)*, (pp. 1-4). Lisbon, Portugal.
- Guo, F., He, R., & Dang, J. (2019). Implicit Discourse Relation Recognition via a BiLSTM-CNN Architecture With Dynamic Chunk-Based Max Pooling. *IEEE Access*, *7*, 169281-169292.
- Gupta, A., Gupta, K., Gupta, K., & Gupta, K. (2020). A Survey on Human Activity Recognition and Classification. *2020 International Conference on Communication and Signal Processing (ICCSP)*, (pp. 0915-0919). Chennai, India.
- Gyro sensors - how they work and what's ahead: About gyro sensor: Technical information: Information. (n.d.). Retrieved 10 23, 2022, from https://www5.epsondevice.com/en/information/technical_info/gyro/
- Hackett, S., Cai, Y., & Siegel, M. (2019). Activity Recognition from Sensor Fusion on Fireman's Helmet. *2019 12th International Congress on Image and Signal Processing, BioMedical Engineering and Informatics (CISP-BMEI)*, (pp. 1-6). Suzhou, China.
- Harrington, P. (2012). *Machine Learning in Action*. Shelter Island, New York: Manning Publications Co.
- Hastie, T., Tibshirani, R., & Friedman, J. (2017). *The elements of statistical learning : Data Mining, Inference, and Prediction*. New York: Springer.
- Hernández, F., Suárez, L. F., Villamizar, J., & Altuve, M. (2019). Human Activity Recognition on Smartphones Using a Bidirectional LSTM Network. *2019 XXII Symposium on Image, Signal Processing and Artificial Vision (STSIVA)*, (pp. 1-5). Bucaramanga, Colombia.
- Hochreiter, S., Bengio, Y., Frasconi, P., & Schmidhuber, J. (2001). Gradient flow in recurrent nets: the difficulty of learning long-term dependencies. *Kolen J, Kremer S (eds) Field guide to dynamical recurrent networks*.
- Hsieh, T., Zheng, B., Lin, F., & Yang, C. (2018). An IoT Peripheral Sensor Integration to Assist Elderly Drivers. *2018 International Automatic Control Conference (CACs)*, (pp. 1-6). Taoyuan, Taiwan.
- Hubel, D., & Wiesel, T. (1959). Receptive fields of single neurones in the cat's striate cortex. *The Journal of Physiology*, *124*(3), 574-591.
- Human computer interaction - brief intro. (n.d.), (p. The Interaction Design Foundation). Retrieved 10 22, 2022, from <https://www.interaction-design.org/literature/book/the-encyclopedia-of-human-computer-interaction-2nd-ed/human-computer-interaction-brief-intro>

- Internet of things. (2022)., (p. Wikimedia Foundation). Retrieved 10 22, 2022, from https://en.wikipedia.org/wiki/Internet_of_things
- Jalloul, N. (2018). Wearable sensors for the monitoring of movement disorders. *Biomedical Journal*, 41(4), 249-253.
- James, G., Witten, D., Hastie, T., & Tibshirani, R. (2013). An introduction to statistical learning : with applications in R.
- Jeyabharathi, D., Kesavaraja, D., & Sasirekac, D. (2020). iEpilepsy monitoring and alerting system using machine learning algorithm and WHMS. *Journal of Applied Research and Technology*, 18(3).
- Jing, L., & Cheng, Z. (2017). Recognition of daily routines and accidental event with multipoint wearable inertial sensing for seniors home care. *2017 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*, (pp. 2324-2389). Banff, Canada.
- Kabanov, A. A., & Shchelkanov, A. I. (2018). Development of a Wearable Inertial System for Motor Epileptic Seizure Detection. *2018 XIV International Scientific-Technical Conference on Actual Problems of Electronics Instrument Engineering (APEIE)*, (pp. 339-342). Novosibirsk, Russia.
- Karacocuk, G., Hoflinger, F., Zhang, R., Reindl, L., Laufer, B., Moller, K., . . . Zdzieblik, D. (2019). IEEE Transactions on Instrumentation and Measurement. *IEEE Transactions on Instrumentation and Measurement*, 68(11), 4268-4275.
- Kawaguchi, N., Yang, Y., Yang, T., Ogawa, N., Iwasaki, Y., Kaji, K., . . . Nishio, N. (2011). HASC2011corpus: towards the common ground of human activity recognition. *International Conference on Ubiquitous Computing*, (pp. 571-572).
- Khusainov, R., Azzi, D., Achumba, I. E., & Bersch, S. D. (2013). Real-Time Human Ambulation, Activity, and Physiological Monitoring: Taxonomy of Issues, Techniques, Applications, Challenges and Limitations. *Sensors 2013*, 13(10), 12852-12902.
- Kim, J. Y., Chu, C. H., & Kang, M. S. (2021). IoT-Based Unobtrusive Sensing for Sleep Quality Monitoring and Assessment. *IEEE Sensors Journal*, 21(3), 3799-3809.
- Kim, S., Kim, J., & Suh, D. (2019). Game Controller Position Tracking using A2C Machine Learning on Inertial Sensors. *2019 IEEE Games, Entertainment, Media Conference (GEM)*, (pp. 1-6). New Haven, USA.
- Kingma, D., & Ba, J. (2014). Adam: A Method for Stochastic Optimization. *International Conference on Learning Representations (ICLR)*. San Diego.
- Kirkko-Jaakkola, M., Collin, J., & Takala, J. (2012). Bias Prediction for MEMS Gyroscopes. *IEEE Sensors Journal*, 12(6), 2157 - 2163.
- K-nearest neighbors – the laziest machine learning technique. (2017)., (p. KDnuggets). Retrieved 10 23, 2022, from <https://www.kdnuggets.com/2017/09/rapidminer-k-nearest-neighbors-laziest-machine-learning-technique.html>
- Krutaranyom, S., Sengchuai, K., Booranawong, A., & Jaruenpunyasak, J. (2022). Pilot Study on Gait Classification Using Machine Learning. *2022 International Electrical Engineering Congress (iEECON)*, (pp. 1-4). Khon Kaen, Thailand.
- Kubat, M. (2017). An Introduction to Machine Learning. second edition.
- Kwapisz, J. R., Weiss, G. M., & Moore, S. A. (2011). Activity recognition using cell phone accelerometers. *ACM SigKDD Explorations Newsletter*, 12(2), 74-82.
- Lahdenoja, O., Hurnanen, T., Iftikhar, Z., Nieminen, S., Knuutila, T., Saraste, A., . . . Koivisto, T. (2018). Atrial Fibrillation Detection via Accelerometer and Gyroscope of a Smartphone. *IEEE Journal of Biomedical and Health Informatics*, 22(1), 108-118.
- Larsson, R., Skog, I., & Händel, P. (2017). Inertial sensor driven smartphone and automobile coordinate system alignment. *2017 IEEE 20th International Conference on Intelligent Transportation Systems (ITSC)*, (pp. 1-6). Yokohama, Japan.
- LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278-2324.
- Lee, F., & Lee, C. (2018). User Activity Recognition Based on Smart Chair with Pressure Sensors. *2018 IEEE International Conference on Consumer Electronics-Taiwan (ICCE-TW)*, (pp. 1-2). Taichung, Taiwan.
- Li, J., Wang, Z., Qiu, S., Zhao, H.-Y., Wang, J., Shi, X., . . . Fortino, G. (2021). Multi-body sensor data fusion to evaluate the hippotherapy for motor ability improvement in children with cerebral palsy. *Information Fusion*, 70, 115-128.

- Li, S., Jiang, J., Ruppel, P., Liang, H., Ma, X., Hendrich, N., . . . Zhang, J. (2020). A Mobile Robot Hand-Arm Teleoperation System by Vision and IMU. *2020 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, (pp. 10900-10906). Las Vegas, USA.
- Liang, X., Heidari, H., & Dahiya, R. (2017). Wearable Capacitive-Based Wrist-Worn Gesture Sensing System. *2017 New Generation of CAS (NGCAS)*, (pp. 181-184). Genova, Italy.
- Liao, D. (2016). Design of a Secure, Biofeedback, Head-and-Neck Posture Correction System. *2016 IEEE First International Conference on Connected Health: Applications, Systems and Engineering Technologies (CHASE)*, (pp. 119-124). Washington, USA.
- Liu, H., Sanchez, E., Parkerson, J., & Nelson, A. (2019). Gesture Classification with Low-Cost Capacitive Sensor Array for Upper Extremity Rehabilitation. *2019 IEEE SENSORS*, 1-4.
- Liu, Y., Chen, Q., & Zhu, M. (2022). Estimation of Vertical Jump Height Based on IMU Sensor. *2022 8th International Conference on Control, Automation and Robotics (ICCAR)*, (pp. 191-196). Xiamen, China.
- López-Nava, I. H., & Meléndez-Muñoz, A. (2016). Wearable inertial sensors for Human Motion Analysis: A Review. *IEEE Sensors Journal*, *16*(22), 7821-7834.
- Lueken, M., Wenner, J., Leonhardt, S., & Ngo, C. (2022). Using Synthesized IMU Data to Train a Long-Short Term Memory-based Neural Network for Unobtrusive Gait Analysis with a Sparse Sensor Setup. *2022 44th Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)*, (pp. 3653-3656). Glasgow, Scotland, United Kingdom.
- Ma, W., Xiao, Z., Liu, X., Tang, D., & Hu, W. (2020). Fall Detection Based on an Inertial Sensor and a Customized Artificial Neural Network Algorithm. *2020 IEEE 15th International Conference on Solid-State & Integrated Circuit Technology (ICSICT)*, (pp. 1-3). Kunming, China.
- Mekruksavanich, S., Jantawong, P., & Jitpattanakul, A. (2022). Recognition of Complex Human Activities for Wellness Management from Smartwatch using Deep Residual Neural Network. *2022 Joint International Conference on Digital Arts, Media and Technology with ECTI Northern Section Conference on Electrical, Electronics, Computer and Telecommunications Engineering (ECTI DAMT & NCON)*, (pp. 350-353). Chiang Rai, Thailand.
- Mekruksavanich, S., Jantawong, P., Hnoohom, N., & Jitpattanakul, A. (2022). Heterogeneous Recognition of Human Activity with CNN and RNN-based Networks using Smartphone and Smartwatch Sensors. *2022 3rd International Conference on Big Data Analytics and Practices (IBDAP)* (pp. 21-26). Bangkok, Thailand: IEEE.
- Mika, S., Ratsch, G., Weston, J., Scholkopf, B., & Mullers, K. (1999). Fisher discriminant analysis with kernels. *Neural Networks for Signal Processing IX: Proceedings of the 1999 IEEE Signal Processing Society Workshop (Cat. No.98TH8468)*, (pp. 41-48). Madison, USA.
- Moermond, J. (2017). What is a capacitive sensor? Retrieved 10 23, 2022, from <https://automation-insights.blog/2017/06/07/what-is-a-capacitive-sensor/>
- Montesinos, L., Castaldo, R., & Pecchia, L. (2018). Wearable Inertial Sensors for Fall Risk Assessment and Prediction in Older Adults: A Systematic Review and Meta-Analysis. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, *26*(3), 573-582.
- Müller, A. C., & Guido, S. (2016). *Introduction to Machine Learning with Python*. O'Reilly Media, Inc.
- Murphy, K. P. (2021). *Probabilistic Machine Learning: An Introduction*.
- Mutegeki, R., & Han, D. S. (2020). A CNN-LSTM Approach to Human Activity Recognition. *2020 International Conference on Artificial Intelligence in Information and Communication (ICAIC)*, (pp. 362-366). Fukuoka, Japan.
- Nahian, M., Ghosh, T., Banna, M., Aseeri, M., Uddin, M., Ahmed, M., . . . Kaiser, M. (2021). Towards an accelerometer-based elderly fall detection system using cross-disciplinary time series features. *IEEE Access*, *9*, 39413-39431.
- Nandy, A., Saha, J., Chowdhury, C., & Singh, K. P. (2019). Detailed Human Activity Recognition using Wearable Sensor and Smartphones. *2019 International Conference on Opto-Electronics and Applied Optics (Optronix)*, (pp. 1-6). Kolkata, India.
- Nilsson, N. J. (1998). *INTRODUCTION TO MACHINE LEARNING*. Stanford, CA: Department of Computer Science.
- Noras, M. A. (2021). Activity Detection and Recognition With Passive Electric Field Sensors. *IEEE Transactions on Industry Applications*, *58*(1), 800 - 806.

- Odonkor, C., Kuwabara, A., Tomkins-Lane, C., Zhang, W., Muaremi, A., Leutheuser, H., . . . Smuck, M. (2020). Gait features for discriminating between mobility-limiting musculoskeletal disorders: Lumbar spinal stenosis and knee osteoarthritis. *Gait & Posture*, *80*, 96-100.
- Ohtaki, Y., & Mamizuka, N. (2014). Gait characterization of pre- and postoperative patients with lumbar spinal stenosis utilizing a body-mounted inertial measurement unit. *2014 IEEE Healthcare Innovation Conference (HIC)*, (pp. 111-114). Seattle, USA.
- Papadopoulos, A., Kyritsis, K., Klingelhoefer, L., Bostanjopoulou, S., Chaudhuri, K. R., & Delopoulos, A. (2020). Detecting Parkinsonian Tremor From IMU Data Collected in-the-Wild Using Deep Multiple-Instance Learning. *IEEE Journal of Biomedical and Health Informatics*, *24*(9), 2559-2569.
- Peng, L., Chen, L., Wu, X., Guo, H., & Chen, G. (2016). Hierarchical complex activity representation and recognition using topic model and classifier level fusion. *IEEE Transactions on Biomedical Engineering*, *64*(6), 1369 - 1379.
- Pereira, A., Folgado, D., Nunes, F., Almeida, J., & Sousa, I. (2019). Using Inertial Sensors to Evaluate Exercise Correctness in Electromyography-based Home Rehabilitation Systems. *2019 IEEE International Symposium on Medical Measurements and Applications (MeMeA)*, (pp. 1-6). Istanbul, Turkey.
- Pérez-Jiménez, M. A., Martínez-Castillo, J., Morales-González, E., & Herrera-May, A. L. (2019). A Portable and Wireless System for Monitoring Hand Tremors in Parkinson's Disease Patients. *2019 IEEE International Conference on Engineering Veracruz (ICEV)*, (pp. 1-4). Boca del Rio, Mexico.
- Perumal, T., Ramanujam, E., Suman, S., Sharma, A., & Singhal, H. (2022). Internet of Things Centric Based Multi-Activity Recognition in Smart Home Environment. *IEEE Internet of Things*, 1-1.
- Petritoli, E., Leccese, F., & Spagnolo, G. S. (2020). Inertial Navigation Systems (INS) for Drones: Position Errors Model. *2020 IEEE 7th International Workshop on Metrology for AeroSpace (MetroAeroSpace)*, (pp. 500-504). Pisa, Italy.
- Pi, M. (2020). Gait Control of Robotic Leg Prosthesis Based on Motion Predictive System. *2020 5th International Conference on Advanced Robotics and Mechatronics (ICARM)*, (pp. 525-528). Shenzhen, China.
- Pierleoni, P., Belli, A., Bazgir, O., Maurizi, L., Paniccia, M., & Palma, L. (2019). A Smart Inertial System for 24h Monitoring and Classification of Tremor and Freezing of Gait in Parkinson's Disease. *IEEE Sensors Journal*, *19*(23), 11612-11623.
- Pothula, P. K., Marisetty, S., & Rao, M. (2022). A Real-Time Seizure Classification System Using Computer Vision Techniques. *2022 IEEE International Systems Conference (SysCon)*, (pp. 1-6). Montreal, Canada.
- Ramírez, J. M., Rodríguez, M. D., Andrade, Á. G., Castro, L. A., Beltrán, J., & Armenta, J. S. (2019). Inferring Drivers' Visual Focus Attention Through Head-Mounted Inertial Sensors. *IEEE Access*, *7*, 185422-185432.
- Rantanen, V., Venesvirta, H., Spakov, O., Verho, J., Vetek, A., Surakka, V., & Lekkala, J. (2013). Capacitive measurement of facial activity intensity. *IEEE Sensors Journal*, *13*(11), 4329-4338.
- Reddy, S., Mun, M., Burke, J., Estrin, D., Hansen, M., & Srivastava, M. (2010). Using mobile phones to determine transportation modes. *ACM Transactions on Sensor Networks*, *6*(2), 1-27.
- Reich, O., Hübner, E., Ghita, B., Wagner, M. F., & Schäfer, J. (2020). A Survey Investigating the Combination and Number of IMUs on the Human Body Used for Detecting Activities and Human Tracking. *2020 World Conference on Computing and Communication Technologies (WCCCT)*, (pp. 20-27). Warsaw, Poland.
- Reiss, A., & Stricker, D. (2012). Introducing a new benchmarked dataset for activity monitoring. *2012 16th International Symposium on Wearable Computers*, (pp. 108-109). Newcastle, UK.
- Reyes-Ortiz, J. L., Oneto, L., Sama, A., Parra, X., & Anguita, D. (2016). Transition-aware human activity recognition using smartphones. *Neurocomputing*, *171*, 754-767.
- Saeyns, Y., Inza, I., & Larrañaga, P. (2007). A review of feature selection techniques in bioinformatics. *Bioinformatics*, *23*(19), 2507-2517.
- Schölkopf, B., Smola, A., & Müller, K. (1998). Nonlinear component analysis as a kernel eigenvalue problem. *Neural computation*, *10*(5), 1299-1319.
- Seo, W., & Choi, Y. (2018). BMK Stick: IMU-Based Motion Recognition Air Mouse and Five-Multikey Keyboard. *TENCON 2018 - 2018 IEEE Region 10 Conference*, (pp. 0367-0372). Jeju, Korea (South).

- Severin, I. C. (2020). 6DOF Inertial IMU Head Gesture Detection: Performance Analysis Using Fourier Transform and Jerk-Based Feature Extraction. *IEEE Microwave Theory and Techniques in Wireless Communications (MTTW 2020)*, (pp. 118-123). Riga, Latvia.
- Severin, I. C. (2020). Head Posture monitor based on 3 IMU sensors: Consideration toward Healthcare application. *The 8-th IEEE International Conference on e-Health and Bioengineering (EHB 2020)*. Iasi.
- Severin, I. C. (2020). SYSTEM FOR DETECTING THE TRANSMISSION ERROR RATE DURING WI-FI COMMUNICATION WITH CC3220SF LAUNCHPAD. *Bulletin of the Polytechnic Institute of Iasi. Electrical Engineering, Power Engineering, Electronics Section*, 66(3), 77-97.
- Severin, I. C. (2020). The Head Posture System Based on 3 Inertial Sensors and Machine Learning Models: Offline Analyze. *3rd International Seminar on Research of Information Technology and Intelligent Systems (ISRITI 2020)*. Yogyakarta, Indonesia.
- Severin, I. C. (2020). Time series feature extraction for Head gesture recognition: Considerations toward HCI Applications. *2020 24th International Conference on System Theory, Control and Computing (ICSTCC)*. Sinaia, Romania.
- Severin, I. C. (2021). A Brief Review of Using the Inertial Sensor to Determine the Driver Head Posture. *2021 International Conference on e-Health and Bioengineering (EHB)*, (pp. 1-4). Iasi, Romania.
- Severin, I. C. (2021). Head Gesture-Based on IMU Sensors: a Performance Comparison Between the Unimodal and Multimodal Approach. *2021 International Symposium on Signals, Circuits and Systems (ISSCS)*, (pp. 1-4). 2021.
- Severin, I. C., & Dobrea, D. M. (2020). Head Gesture Recognition based on 6DOF Inertial sensor using Artificial Neural Network. *International Symposium on Electronics and Telecommunications (ISETC 2020)*. Timisoara, Romania.
- Severin, I. C., & Dobrea, D. M. (2021). Head Gesture Recognition Based on Capacitive Sensors Using Deep Learning Algorithms. *Bulletin of the Polytechnic Institute of Iasi. Electrical Engineering, Power Engineering, Electronics Section*, 67(3), 73-93.
- Severin, I. C., & Dobrea, D. M. (2021). Using Inertial Sensors to Determine Head Motion—A Review. *Journal of Imaging*, 12, 265.
- Severin, I. C., Dobrea, D. M., & Dobrea, M. C. (2020). Head Gesture Recognition using a 6DOF Inertial IMU. *International Journal of Computers Communications & Control*, 15(3).
- Shalev-Shwartz, S., & Ben-David, S. (2022). *Understanding machine learning: From theory to algorithms*. Cambridge: Cambridge University Press.
- Shao, X., Ning, H., Yang, W., & Niu, Y. (2022). Design of Intentional Eye-blink Signal Acquisition and Control System Based on Pressure Sensor. *2022 7th International Conference on Intelligent Computing and Signal Processing (ICSP)*, (pp. 1848-1851). Xi'an, China.
- Shen, H.-M., Lian, C., Wu, X.-W., Bian, F., Yu, P., & Yang, G. (2021). Full-pose estimation using inertial and magnetic sensor fusion in structurized magnetic field for hand motion tracking. *Measurement*, 170, 108697.
- Shi, B. (2022). Detection of Freezing of Gait Using Convolutional Neural Networks and Data From Lower Limb Motion Sensors. *IEEE Transactions on Biomedical Engineering*, 69(7), 2256-2267.
- Shi, X., Chen, Z., Wang, H., Yeung, D., Wong, W., & Woo, W. (2015). Convolutional LSTM Network: A Machine Learning Approach for Precipitation Nowcasting. *Advances in Neural Information Processing Systems*, 28.
- Sierociuk, D., Tejado, I., & Vinagre, B. (2011). Improved fractional Kalman filter and its application to estimation over lossy networks. *Signal Processing*, 91(3), 542-552.
- Simeone, O. (2018). A Brief Introduction to Machine Learning for Engineers. *Foundations and Trends® in Signal Processing*, 12(3-4), 200-431.
- Sung Hun, K., Changwon, W., Se Dong, M., & Seung Hyun, L. (2018). Safety Helmet Wearing Management System for Construction Workers Using Three-Axis Accelerometer Sensor. *Applied Science, Mechanical Engineering Section*, 8(12).
- Szücs, V., Guzvinez, T., & Magyar, A. (2019). Improved algorithms for movement pattern recognition and classification in physical rehabilitation. *2019 10th IEEE International Conference on Cognitive Infocommunications (CogInfoCom)*, (pp. 417-424). Naples, Italy.
- Tan, P., Steinbach, M., & Kumar, V. (2005). Cluster Analysis: Basic Concepts and Algorithms. *Introduction to Data Mining*.

- Tao, W., Lai, Z.-H., Leu, M., & Yin, Z. (2018). Worker Activity Recognition in Smart Manufacturing Using IMU and sEMG Signals with Convolutional Neural Networks. *Procedia Manufacturing*, 1159-1166.
- Theobald, O. (2021). *Machine learning for absolute beginners: A Plain English introduction*. Amazon Digital Services LLC.
- Tian, L., Abdullaha, M., & Christian, C. (2018). An IMU-based traffic and road condition monitoring system. *HardwareX*, 4, e00045.
- Tran, L. (2017). *Data Fusion with 9 Degrees of Freedom Inertial Measurement Unit To Determine Object's Orientation*. ELECTRICAL ENGINEERING. Retrieved from <https://digitalcommons.calpoly.edu/eesp/400/>
- Tripathi, A., Mondal, A. K., Kumar, L., & Prathosh, A. P. (2022). ImAiR: Airwriting Recognition Framework Using Image Representation of IMU Signals. *IEEE Sensors Letters*, 6(10), 1-4.
- Tsai, A., Ou, Y., Sun, C. A., & Wang, J. (2017). VQ-HMM classifier for an activity recognition based on R-GBD sensor. *2017 International Conference on Orange Technologies (ICOT)*, (pp. 201-204). Singapore.
- Umek, A., Tomazic, S., & Kos, A. (2014). Autonomous Wearable Personal Training System with Real-Time Biofeedback and Gesture User Interface. *2014 International Conference on Identification, Information and Knowledge in the Internet of Things*, (pp. 122-125). Beijing, China.
- Valencia-Rosado, L. O., Rojas-Velázquez, D., & Etcheverry, G. (2018). Driver intent data analysis & classification. *2018 International Conference on Electronics, Communications and Computers (CONIELECOMP)*, (pp. 207-211). Cholula, Mexico.
- Varatharajan, R., Gunasekaran, M., Priyan, M. K., & Sundarasekar, R. (2018). Wearable sensor devices for early detection of Alzheimer disease using dynamic time warping algorithm. *Cluster Computing* 21, 681–690.
- Verma, R., Mitra, B., & Chakraborty, S. (2019). Avoiding Stress Driving: Online Trip Recommendation from Driving Behavior Prediction. *2019 IEEE International Conference on Pervasive Computing and Communications (PerCom)*, (pp. 1-10). Kyoto, Japan.
- Voss, R. (1979). 1/F (flicker) noise: A brief review. *33rd Annual Symposium on Frequency Control*.
- Vyas, R., & Doddabasappa, K. (2022). FFT Spectrum Spread With Machine Learning (ML) Analysis of Triaxial Acceleration From Shirt Pocket and Torso for Sensing Coughs While Walking. *IEEE Sensors Letters*, 6, 1-4.
- Walse, K., Dharaskar, R., & Thakare, V. (2016). *Proceedings of First International Conference on Information and Communication Technology for Intelligent Systems*, 429-436.
- Wang, L., Sun, Y., Li, Q., Liu, T., & Yi, J. (2020). Two Shank-Mounted IMUs-Based Gait Analysis and Classification for Neurological Disease Patients. *IEEE Robotics and Automation Letters*, 5(2), 1970-1976.
- Wang, S., & Zhu, X. (2020). A Hybrid Deep Neural Networks for Sensor-based Human Activity Recognition. *2020 12th International Conference on Advanced Computational Intelligence (ICACI)*, (pp. 486-491). Dali, China.
- Wang, Y., Lv, H., Zhou, H., Cao, Q., Li, Z., & Yang, G. (2020). A Sensor Glove Based on Inertial Measurement Unit for Robot Teleoperation. *IECON 2020 The 46th Annual Conference of the IEEE Industrial Electronics Society*, (pp. 3397-3402). Singapore.
- Werbos, P. J. (1990). Backpropagation Through Time: What It Does and How to Do It. *Proceedings of the IEEE*, 78(10), 1550 - 1560.
- Windau, J., & Itti, L. (2018). Inertial Machine Monitoring System for Automated Failure Detection. *2018 IEEE International Conference on Robotics and Automation (ICRA)*, (pp. 93-98). Brisbane, Australia.
- Wong, K. I., Chen, Y., Lee, T., & Wang, S. (2019). Head Motion Recognition Using a Smart Helmet for Motorcycle Riders. *2019 International Conference on Machine Learning and Cybernetics (ICMLC)*, (pp. 1-7). Kobe, Japan.
- Xia, S., Peng, D., Meng, D., Zhang, C., Wang, G., Giem, E., . . . Chen, Z. (2022). Ball k k-Means: Fast Adaptive Clustering With No Bounds. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 44(1), 87 - 99.
- Xiaomin, Z., Zhiyao, Z., Zhaoyang, W., & Xiaoyi, W. (2021). Fault Detection and Identification Method for Quadcopter Based on Airframe Vibration Signals. *Sensors*, 21(2), 581.

- Yang, C. M., Yang, T. I., Wu, C. C., & Chu, N. N. (2011). A breathing game with capacitive textile sensors. *2011 IEEE International Games Innovation Conference (IGIC)*, (pp. 134-136). Orange, CA.
- Yang, M., Zheng, H., Wang, H., McClean, S., Hall, J., & Harris, N. (2012). A machine learning approach to assessing gait patterns for complex regional pain syndrome. *Medical Engineering and Physics*, *34*(6), 740–746.
- Yoav, F., & Schapire, R. E. (1997). A Decision-Theoretic Generalization of On-Line Learning and an Application to Boosting. *Journal of Computer and System Sciences*, *55*(1), 119–139.
- Yoon, S., Lim, H., Kim, J. H., Lee, H. S., Kim, Y. T., & Sull, S. (2022). Deep 6-DOF Head Motion Prediction for Latency in Lightweight Augmented Reality Glasses. *2022 IEEE International Conference on Consumer Electronics (ICCE)* (pp. 1-6). Las Vegas, USA: IEEE.
- Young, A. D. (2009). Comparison of orientation filter algorithms for realtime wireless inertial posture tracking. *2009 Sixth International Workshop on Wearable and Implantable Body Sensor Networks*, (pp. 59-64). Berkeley, USA.
- Yunfang, C., Yitian, Z., Wei, Z., & Ping, L. (2018). Survey of Human Posture Recognition Based on Wearable Device. *2018 IEEE International Conference on Electronics and Communication Engineering (ICECE)*, (pp. 8-12). Xi'an, China.
- Zeng, Y., Chang, W., & Chien, Y. (2017). Activity recognition and vital sign measure using single pressure sensor. *2017 IEEE 6th Global Conference on Consumer Electronics (GCCE)*, (pp. 1-4). Nagoya, Japan.
- Zhu, M., Wu, Y., & Luo, S. (2022). f²IMU-R: Pedestrian Navigation by Low-Cost Foot-Mounted Dual IMUs and Interfoot Ranging. *IEEE Transactions on Control Systems Technology*, 247-260.
- Zou, Y., Wang, D., Hong, S., Ruby, R., Zhang, D., & Wu, K. (2020). A Low-Cost Smart Glove System for Real-Time Fitness Coaching. *IEEE Internet of Things Journal*, *7*(8), 7377-7391.