

Metode inteligente, proactive pentru diagnosticul precoce si personalizarea tratamentului bolilor neurologice

ALAMEDA

Număr Proiect: 66 din 01/11/2021

PN-III-P3-3.6-H2020-2020-0186

Etapa 3: Testarea componentelor dezvoltate

31.12.2022-31.12.2023

Cuprins

1 Obiective etapa 3.....	1
2 Rezumatul etapei.....	1
3 Descrierea științifică și tehnică - Testarea componentelor dezvoltate (activitatea 3.1)....	2
3.1 Analiza mersului folosind senzori IMU portabili.....	3
3.2 Analiza mersului folosind brânțuri inteligente	9
3.3 Detectia elementelor caracteristice bolnavilor de Parkinson.....	10
3.4 Detectia exercițiilor de recuperare pentru pacienții cu accident vascular	17
4 Diseminare	19
5 Bibliografie.....	20

1 Obiective etapa 3

Obiectivele prevăzute pentru etapa 3 a proiectului ALAMEDA au fost atinse prin implementarea următoarei activități în cursul anului 2023:

Activitatea 3.1: Testarea componentelor dezvoltate

Rezultat etapă: Raport al performanțelor obținute

2 Rezumatul etapei

Scopul proiectului ALAMEDA este de a cerceta și prototipa următoarea generație de sisteme de asistență medicală personalizate, bazate pe inteligență artificială, având ca scop răspunsul la nevoile persoanelor cu boli și tulburări neurologice, concentrându-se în mod special pe nevoile tratamentelor de reabilitare ale pacienților și pe trei afecțiuni: Parkinson, scleroză multiplă și accident vascular cerebral.

În cadrul acestei etape au fost realizate următoarele:

- Analiza mersului folosind senzori IMU portabili, detectarea activităților anormale pot ajuta potențial la gestionarea și reducerea riscului multor boli, cum ar fi tulburările neurologice, bolile cardiovasculare. Pentru dezvoltarea analizei mersului au fost utilizate diferite seturi de date de publice pentru recunoașterea activităților, cum ar fi WISDM și UCIHAR, precum și setul de date propriu colectat în cadrul Universității de Știință și Tehnologie Norvegia folosind o centura inteligentă. Analiza a fost realizată folosind modele bazate pe rețele convoluționale. Performanțele cele mai bune au fost obținute de către modelul CNN-BiLSTM.
- Analiza mersului folosind date colectate de la Novel Loadsol prin aplicarea metodelor bazate pe rețele convoluționale pentru identificarea pentru “înghețării” mersului. Performanțele cele mai bune au fost obținute de modelul modelul InSEption aplicat pe setul de date Gait in Parkinson’s Disease.
- Detecția elementelor caracteristice bolnavilor de Parkinson în ceea ce privește prezența/absența tremorului, bradikineziei și diskineziei și nivelului lor de severitate prin aplicarea diferitelor modele: Logistic Regression, kNN, Multilayered Perceptron, Decision Tree, AdaBoost, Random Forest și SVM pe setul de date Levodopa Response Study.
- Detecția exercițiilor de recuperare pentru pacienții cu accident vascular folosind accelerația pe axele x, y și z achiziționate de la brățara GENEActiv. Modelul aplicat se bazează pe arhitectura TS2VEC. Experimentele au fost efectuate pe setul de date SPARSE9X pentru recunoașterea exercițiilor de recuperare a umerilor.

În cadrul acestei etape, proiectul a fost diseminat prin publicarea a 3 articole: 1 articol de conferință cu proceedings indexat ISI, 2 articole de jurnal jurnal Q2, indexat ISI, cu factor de impact și prezentarea proiectului în cadrul evenimentului BeHealth.

Toate obiectivele au fost realizate integral, gradul de atingere al rezultatelor fiind de 100%.

3 Descrierea științifică și tehnică - Testarea componentelor dezvoltate (activitatea 3.1)

Scopul proiectului ALAMEDA constă în cercetarea și prototiparea următoarei generații de sisteme de asistență medicală personalizate, bazate pe inteligență artificială, având ca scop răspunsul la nevoile persoanelor cu boli și tulburări neurologice, concentrându-se în mod special pe nevoile tratamentelor de reabilitare ale pacienților și pe trei afecțiuni: Parkinson, scleroză multiplă și accident vascular cerebral. Inovațiile ALAMEDA sunt ancorate în integrarea datelor colectate asupra stilului de viață, precum și a fluxurilor noi de date de monitorizare a pacienților în timpul activităților zilnice, inclusiv comportamentul de somn, implementarea analizei avansate a datelor și a serviciilor de recomandare asupra stilului de viață, bazate pe inteligență artificială. Această abordare oferă personalului medical posibilitatea de a modifica intervențiile pe baza înregistrărilor de date personalizate, care pot include atât opțiuni terapeutice farmacologice, cât și non-farmacologice, cum ar fi regimurile de efort.

În cadrul acestei etape au fost experimentate metode pentru:

- Analiza mersului folosind senzori IMU portabili prin detectarea activităților anormale.
- Analiza mersului folosind date colectate de la braturile Loadsol pentru identificarea “înghețării” mersului.
- Detecția elementelor caracteristice bolnavilor de Parkinson prezenței/absenței tremorului, bradichineziei și dischineziei și nivelului lor de severitate.
- Detecția exercițiilor de recuperare a umerilor pentru pacienții cu accident vascular.

3.1 Analiza mersului folosind senzori IMU portabili

Analiza mersului (Gait Analysis - GA) folosind date de la senzori portabili s-a dovedit deja a fi eficientă în asistența medicală pentru evaluarea rezultatelor și a stării pacientului în ceea ce privește mobilitatea. Aplicațiile practice ale GA în asistența medicală includ monitorizarea în timp real a stării de sănătate, detectarea activităților anormale și a situațiilor de alarmă și recunoașterea evenimentelor și comportamentelor zilnice ale oamenilor pentru a-și îmbunătăți starea de sănătate, ceea ce duce la o calitate mai bună a vieții, reducând în același timp costurile de asistență medicală¹. Pe baza analizei literaturii de specialitate se observă că monitorizarea și recunoașterea regulată a activității fizice pot ajuta potențial la gestionarea și reducerea riscului multor boli, cum ar fi tulburările neurologice, bolile cardiovasculare și diabetul de tip 2². De exemplu, aplicațiile GA pot fi folosite pentru a detecta înghețarea mersului și pentru a preveni riscul de cădere la persoanele bolnave de Parkinson, unde se monitorizează continuu mișcarea și pacienții sunt ajutați să-și coordoneze mersul, oferind o simulare auditivă ritmică^{3,4}.

Importanța GA bazată pe senzori devine evidentă din faptul că poate fi folosită nu numai pentru recunoașterea activităților zilnice, ci și pentru modul în care sunt efectuate activitățile. Acest lucru poate fi util în monitorizarea recuperării unui pacient după o intervenție chirurgicală, diagnosticarea stării bolilor sau predicția căderilor. Echipamentele utilizate pentru analiza mersului folosesc diferite tipuri de senzori, inclusiv accelerometru, giroscop și magnetometru. Accelerometrul măsoară forțele de accelerație în mai multe direcții, inclusiv cele trei axe: X, Y și Z. Prin analiza datelor de la accelerometru, pot fi identificate modele legate de diferite activități. De exemplu, mersul pe jos prezintă de obicei un model distinct caracterizat de maxime și minime repetitive în semnalul achiziționat de la accelerometru. Alergarea, săriturile și alte activități fizice au, de asemenea, modele unice care pot fi recunoscute prin analiza datelor de la accelerometru. Giroscopul măsoară viteza unghiulară sau mișcarea de rotație a corpului. El oferă informații despre orientarea corpului și schimbările de direcție. Prin analiza datelor de la giroscop, pot fi detectate modele legate de mișcările de rotație se rotesc și modificările orientării corpului. Magnetometrul detectează modificările câmpului magnetic. Prin combinarea datelor de la acești senzori, pot fi obținute informații detaliate despre mișcare, orientare și poziționare în spațiu, permițând o analiză cuprinzătoare a mersului.


Diferitele metode de analiză a mersului pot fi clasificate în 2 categorii și anume, metode calitative și cantitative⁵. Metodele calitative se concentrează pe observații subiective și descrieri ale modelelor de mers. Aceste metode presupun evaluarea vizuală și interpretarea mișcării individului în timpul mersului. Parametrii analizați sunt: lungimea pasului, plasarea piciorului, unghiurile articulațiilor, simetria, echilibrul și calitatea generală a mișcării. Metodele cantitative, pe de altă parte, implică utilizarea tehnologiei și a instrumentelor avansate pentru a obține măsurători precise și date obiective despre parametrii mersului. Aceste metode se bazează pe diverse dispozitive, cum ar fi sisteme de captare a mișcării, plăci de forță, senzori portabili și branțuri sensibile la presiune, pentru a colecta informații cantitative în timpul mersului. Aceste dispozitive captează date despre factori precum unghiurile articulațiilor, forțele exercitate pe sol, parametrii temporali și spațiali, activitatea musculară și mișcările segmentelor corpului. Datele colectate sunt apoi analizate folosind algoritmi de învățare automată pentru a extrage valori semnificative și informații cantitative. Metodele calitative în analiza mersului oferă perspective subiective, evaluare în timp real și o înțelegere holistică a mersului, dar sunt predispuse la subiectivitate, precizie scăzută și consumatoare de timp. Pe de altă parte, metodele cantitative oferă măsurători obiective, precizie ridicată, capacități de analiză statistică și în timp util, dar pot fi complexe în aplicații în timp real și pot lipsi informațiile contextuale.

Chiar dacă în ultimii ani s-au înregistrat progrese semnificative, există încă multe provocări în dezvoltarea unui set de instrumente de analiză a mersului⁶, care pot afecta acuratețea și fiabilitatea GA. Acestea includ implementarea poziției și orientării sensorului pe corp și, prin urmare, semnalul poate varia, complexitatea implementării GA în timp real și explicabilitatea deciziilor date de instrument. Colectarea datelor are, de asemenea, mai multe probleme, conform diverselor studii, inclusiv seturi de date neetichetate, lipsa de cunoștințe temporale, recunoașterea claselor necunoscute și limitările de date care trebuie abordate pentru recunoașterea și predicția mersului. În plus, adnotarea manuală a datelor necesită timp pentru medici și are ca rezultat o etichetare inexactă și ambiguitate în momentul apariției evenimentului. O adnotare incorectă pentru un set de date poate reduce acuratețea GA. În plus, colectarea datelor prin monitorizare continuă într-un mediu dinamic pentru o perioadă lungă de timp este o provocare și, prin urmare, dificil de realizat în practică.

Pentru dezvoltarea analizei mersului au fost utilizate diferite seturi de date de publice pentru recunoașterea activităților, cum ar fi WISDM și UCIHAR, precum și setul de date propriu colectat în cadrul Universității de Știință și Tehnologie Norvegia. Cele mai multe dintre seturile de date utilizate au fost colectate folosind un senzor inerțial (IMU) încorporat în smartphonouri.

Setul de date BS-NTNU este colectat în cadrul Universității de Știință și Tehnologie Norvegia (NTNU) folosind senzorul centura inteligentă, proiectată și dezvoltată la NTNU. Datele centurii inteligente au fost colectate în campusul universitar al NTNU prin efectuarea de experimente pe doisprezece voluntari pentru realizarea activităților zilnice. Aceste activități includ mers, urcare și coborâre scări, așezat, întins și în picioare. Fiecare activitate este executată de două ori. Figură 1 prezintă un exemplu de eșantioane de activitate zilnică colectate de la un senzor IMU montat pe șoldul stâng al unei persoane care efectuează o activitate de „mers” cu două încercări (repetări).

Fiecare persoană a purtat simultan trei senzori IMU poziționați în jurul taliei pentru a măsura activitățile zilnice. Rata de eșantionare a fost de 100Hz și un total de 22 de attribute au fost colectate de la senzori pentru fiecare activitate. Senzorii purtați de fiecare persoană au fost montați pe o centură elastică obișnuită. Acest lucru a dus la o mișcare minimă între senzor și centura elastică. Tuturor participanților li s-a cerut să realizeze toate cele șase activități în mod obișnuit. Senzorii au înregistrat date atât de la accelerometru, cât și de la giroscop.



Figură 1. Exemplificare date pentru mers.

Setul de date WISDM⁷ a fost lansat de laboratorul Wireless Sensor Data Mining de la Universitatea Fordham. Acesta conține un număr de 1098209 de exemple colectate de la 36 de persoane, în timp ce aceștia au efectuat șase activități zilnice: mers pe jos, jogging, urcare și coborâre scări, așezat și stat în picioare pentru o anumită perioadă. Toți participanții purtau un senzor de mișcare al smartphone-ului (aflat în buzunarul din față pe piciorul stâng). Pentru

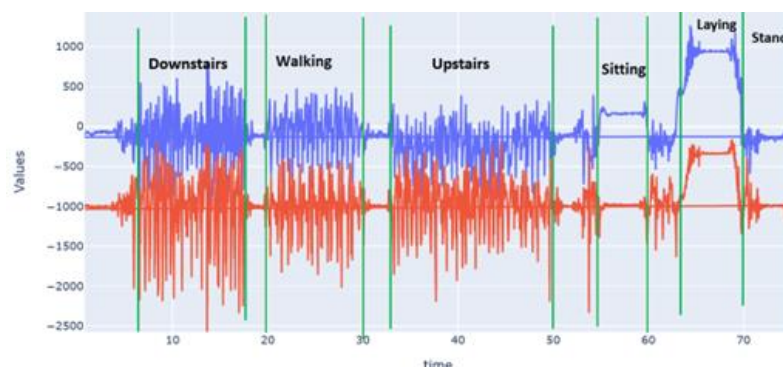
Înregistrarea fiecărei activități a fost folosit un accelerometru cu o frecvență de eșantionare de 20 Hz, iar procesul de colectare a datelor a fost supravegheat de o persoană dedicată pentru a asigura calitatea datelor. Setul de date WISDM este un set de date dezechilibrat în care activitatea de mers pe jos ocupă cel mai mult, ajungând la 38,6%, în timp ce statul în picioare reprezintă doar 4,4%.

Setul de date UCI HAR⁸ este un set de date pentru recunoașterea activităților. Setul de date conține 10.299 de exemple, care au fost colectate de la 30 de persoane. Fiecare activitate a fost realizată o singură dată. Experimentele au fost înregistrate video pentru a adnota manual setul de date. Setul de date furnizează semnale inerțiale brute colectate de la un senzor încorporat în smartphone care a captat accelerația liniară pe 3 axe precum și viteza unghiulară pe 3 axe la o rată de eșantionare constantă de 50Hz. Setul de date conține 6 activități de bază: stând în picioare, așezat, culcat, mers, urcat și coborât scări.

O serie de prelucrări asupra datelor au fost considerate. Preprocesarea datelor include de obicei metode, cum ar fi completarea valorilor lipsă, adnotarea datelor, reeșantionarea, filtrarea semnalului și normalizarea. În continuare sunt descrise fiecare dintre metodele de preprocesare.

Interpolare liniară: Valorile lipsă sunt o problemă reală comună, iar înlocuirea valorilor lipsă este un pas critic în etapa de preprocesare a datelor. Valorile datelor pot fi ratate sau pierdute din diferite motive, cum ar fi conexiunea Wi-Fi slabă, funcționarea defectuoasă a senzorilor sau alte probleme tehnice într-o rețea de senzori. Pentru seturile de date menționate mai sus (WISDM, UCI HAR și BS-NTNU), este utilizată o abordare bazată pe interpolare liniară pentru a completa valorile lipsă din setul de date.

Adnotarea datelor: Cele două seturi de date publice (WISDM și UCI HAR) sunt deja etichetate manual. Pentru BS-NTNU, odată ce sunt realizate, semnalele colectate au fost adnotate folosind un instrument de adnotare, numit NOVA⁹. Pentru cei trei senzori IMU de pe centură, adnotarea a fost efectuată luând în considerare marcajele de timp de început și de sfârșit ale înregistrărilor de pe fiecare senzor. S-a evitat acordul la nivel scăzut cu privire la ora de începere și de sfârșit a activităților prin eliminarea unor secunde la începutul și sfârșitul fiecărei activități. Acest lucru ajută la prevenirea etichetării subiective în procesul de adnotare. Un exemplu de adnotare a semnalului este exemplificat în Figură 2. Activitățile de tranziție, cum ar fi stând în picioare – așezat, așezat - întins și întins - stând în picioare au fost excluse din procesul de adnotare, deoarece procentul acestor activități de tranziție este foarte mic pentru analiză, iar scopul este de a recunoaște doar cele șase activități zilnice: mers, urcat și coborât scări, stat în picioare, așezat și culcat.



Figură 2. Adnotarea datelor.

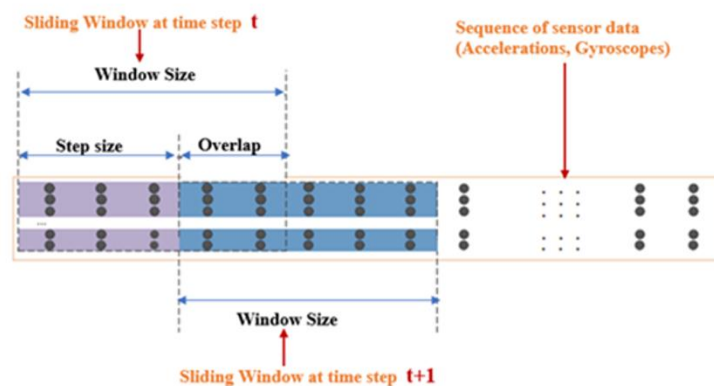
Filtrarea semnalului: Semnalele triaxiale de accelerație liniară și de viteză unghiulară sunt alcătuite din mai multe componente și, prin urmare, pot exista componente de zgomot. Prin

urmare, este important să se realizeze filtrarea zgomotului înainte de a utiliza datele brute colectate. Pentru a reduce zgomotul și a îmbunătăți calitatea semnalului, în cele trei seturi de date au fost utilizate un filtru median și un filtru Butterworth de ordinul al treilea, cu o frecvență de tăiere de 20 Hz. Metodele existente au pus în evidență faptul că majoritatea informațiilor conținute în mișcarea corpului uman sunt sub 20Hz, astfel încât rata de filtrare selectată este suficientă pentru a capta mișcarea corpului uman.

Reeșantionarea datelor: pentru analiza mersului, unele activități apar mai frecvent decât altele, cum ar fi mersul pe jos, urcarea și coborârea scârilor, în timp ce alte activități apar mai rar, cum ar fi așezat, stând în picioare și întins. Antrenarea unui clasificator cu clase cu număr de exemple / clasă dezechilibrat va produce rezultate nedorite, cum ar fi performanțe mult mai scăzute și un număr tot mai mare de fals negative. O modalitate de a rezolva acest lucru constă în reeșantionarea datelor, astfel încât fiecare activitate să aibă aceeași cantitate de instanțe de date. Reeșantionarea se poate face fie prin supra-eșantionarea clasei minoritare, fie prin sub-eșantionarea clasei majoritare. În acest caz a fost aplicată sub-eșantionării setului de date WISDM și supra-eșantionarea pentru seturile de date BS-NTNU. În setul de date UCI HAR, clasele sunt aproximativ echilibrate și, prin urmare, nu se aplică reeșantionare. O limitare a reeșantionării este că distribuția claselor poate să nu fie reprezentativă pentru populația reală sau poate duce la pierderea de informații.

Normalizare: Scopul normalizării constă în a schimba valorile caracteristicilor din setul de date la o scară comună, fără a distorsiona diferențele dintre intervalele de valori. Deoarece senzorul IMU folosit de participanți a capturat atât accelerații liniare, cât și unghiulare, procesul de normalizare este aplicat și tuturor celor 3 axe și este tentat să ofere aceeași pondere tuturor axelor. Normalizarea min-max este utilizată pentru a transforma valoarea fiecărui senzor inerțial în intervalul 0 și 1 cu media și abaterea standard.

Segmentarea datelor: Segmentarea semnalului este un pas fundamental pentru activitatea continuă și detecția mișcării. Segmentarea este procesul de împărțire a semnalelor în segmente de dimensiune mai mică (ferestre temporale). Metodele existente prezintă diferite tehnici de segmentare pentru a obține informații relevante dintr-un flux continuu de date ale senzorului. În acest caz, implementarea ferestrelor glisante a fost realizată pe fiecare set de date în care eșantioanele sunt încadrate într-o fereastră de dimensiunea n . Pentru o fereastră care conține mai multe activități, cea mai frecventă activitate eșantion este selectată ca etichetă a ferestrei respective. Figura 3 ilustrează procesul de segmentare a datelor achiziționate de la centura inteligentă.



Figură 3. Segmentarea datelor.

În seturile de date smart belt și WSIDM, au fost aplicate diferite aspecte ale lungimii secvenței ferestrelor pentru segmentarea semnalelor brute provenite de la senzor. Pentru setul de date

UCI-HAR, lungimea ferestrei glisante este de 128. Semnalele senzorilor din toate aceste seturi de date sunt împărțite în ferestre cu lungime fixă cu o suprapunere între ferestrele adiacente pentru a crește numărul de exemple de antrenament, precum și pentru a evita lipsa tranzițiilor de la o activitate la alta.

Evaluarea rezultatelor: Implementarea și experimentele au fost realizate folosind diferite frameworkuri, cum ar fi Anaconda cu Python 3.10.5 și TensorFlow 2.9 cu Keras. Modelul propus a fost antrenat și evaluat folosind setul de date pentru centura inteligentă BS-NTNU, care a fost segmentat și remodelat în dimensiuni de intrare adecvate. Eșantioanele generate au fost împărțite într-un set de date de antrenare și un set de date de testare în raport de 80% și 20%. Pe setul de date de antrenare, metoda a fost aplicată metoda grid-search cu 5-fold cross-validation în vederea determinării parametrilor optimi.

Au fost efectuate o serie de experimente folosind centura inteligentă și seturile de date prezentate pentru a evalua performanțele modelelor de analiză a mersului. Inițial a fost examinată influența creșterii lungimii secvenței ferestrei asupra performanței modelului CNN-BiLSTM pentru recunoașterea acțiunii. Performanța modelului hibrid propus a fost validată variind lungimile secvenței ferestrelor (0,5,1,2, 3,..., 9 secunde).


Se face o comparație între diferite lungimi de secvență pentru a determina impactul acestora asupra performanței modelului CNN-BiLSTM propus, iar rezultatele sunt prezentate în Tabel 1. Se observă că atunci când lungimea secvenței crește, performanța modelului CNN-BiLSTM este îmbunătățită semnificativ pe setul de date pentru centura inteligentă. Performanța modelului crește pentru ferestre de dimensiuni mai mari, unde cea mai bună acuratețe (96,02%) și scorul F1 (95,96%) sunt obținute la o lungime a ferestrei de 5s. După durata secvenței de 5 secunde, performanța devine constantă și începe să scadă pentru toate valorile de evaluare. Deși ferestrele mai mari oferă mai multe informații trecute și viitoare pentru a analiza și identificarea activităților mai complexe, ele conțin informații redundante și conduc la o latență mare de recunoaștere. Pentru această analiză, o dimensiune a ferestrei de tăiere de 5s este utilizată ca cel mai bun compromis între acuratețe și latență pentru a evalua performanța modelului CNN-BiLSTM.

	Window Size (seconds)									
	0.5	1	2	3	4	5	6	7	8	9
Accuracy	79.72	84.52	88.21	92.47	92.32	96.02	91.88	93.59	93.87	94.58
Precision	81.40	85.20	88.70	92.61	92.65	96.00	91.95	93.54	93.95	94.53
Recall	79.50	84.60	88.31	92.57	92.19	95.97	92.05	93.28	93.97	94.66
F1-Score	80.00	84.70	88.20	92.38	92.32	95.96	91.82	93.33	93.85	94.55


Tabel 1. Performanțele modelului CNN-BiLSTM în funcție de lungimile secvenței ferestrelor.

Figură 4 **Error! Reference source not found.** prezintă matricea de confuzie obținută din evaluarea CNN-BiLSTM la dimensiunea ferestrei de 5s, care rezumă numărul de predicții corecte și incorecte făcute de model pentru fiecare clasă. După cum se observă, cu excepția activităților de „așezat” și „mers”, toate celelalte activități au fost clasificate perfect cu o precizie ridicată ($\geq 95\%$) folosind modelul CNN-BiLSTM. Toate exemplele din activitatea „stat în picioare” au fost clasificate corect, cu o acuratețe de 98,4%, doar 1,6% dintre exemple fiind clasificate greșit ca „întins” și „coborat scări”. De asemenea, este evident că modelul CNN-BiLSTM a avut cele mai multe dificultăți în a distinge activitățile „întins” fata de activitățile „stat în picioare” și „așezat”. Acest lucru se datorează parțial pentru că „întins” și „în picioare” sunt foarte asemănătoare pentru unii dintre subiecți, generând astfel semnale de

mişcare similară. Pentru activitatea „mers”, unde 5,66% dintre exemple sunt clasificate greșit drept „coborat scari” și „in picioare”. Figură 5 exemplifică acuratețea modelului pentru 50 de epoci în care se poate observa o scădere treptată a loss-ului pe parcursul antrenării.



Figură 4. Matricea de confuzie pentru modelul CNN-BiLSTM.



Figură 5. : Loss-ul modelului CNN-BiLSTM.

Modelul CNN-BiLSTM a fost comparat cu alte modele hibride în ceea ce privește acuratețea, precizia, retragerea și scorul F1. **Error! Not a valid bookmark self-reference.** prezintă comparația CNN-BiLSTM cu celelalte trei modele hibride, și anume CNN-LSTM, CNN-GRU și CNN-BiGRU, în termeni de acuratețe, precizie, recall și scor F1 folosind o lungime de fereastră de 5s. Rezultatele comparative din **Error! Not a valid bookmark self-reference.** demonstrează că modelul CNN-BiLSTM a obținut cea mai mare performanță în toate măsurile de evaluare.

Tabel 2. Performanta modelelor pentru centura inteligenta.

Models	Accuracy	Precision	Recall	F1-Score
CNN-LSTM	95.59	99.95	95.50	95.50
CNN-GRU	95.73	95.64	95.69	95.70
CNN-BiGRU	95.02	95.08	95.00	94.99
CNN-BiLSTM	96.02	96.00	95.97	95.96

3.2 Analiza mersului folosind branțuri inteligente

Măsurarea forței de reacție a solului calculează nivelurile de forță care sunt înregistrate de diferite regiuni ale piciorului (de obicei, antepiciorul, mijlocul piciorului și călcâiul) pe măsură ce o persoană execută mișcări cu viteza de mers. Indiferent dacă se înregistrează presiunea reală sau doar forța reactivă, senzorii de presiune plantară pentru branțuri sunt o alegere populară pentru furnizarea de metrice corecte pentru sistemele de analiză a mersului și sunt a doua modalitate de senzori utilizată (după senzorii IMU) pentru colectarea datelor brute despre mers.

Senzorii de presiune plantară din branțuri sunt proiectați pentru a înregistra atât presiunea plantară dinamică, cât și datele spațio-temporale. Analiza realizată de Chen et al.¹⁰ prezintă diverse tehnologii de construcție a senzorilor de presiune plantară, de la abordări tradiționale precum mijloace piezorezistive, capacitive, piezoelectrice sau inductive, până la tehnici mai noi care folosesc principii de lucru optice sau bazate pe presiunea aerului.

Atunci când se analizează mersul pacienților cu boli neurologice pe baza intrărilor de la senzorii de presiune plantari pot fi identificate două categorii principale de parametri.

Parametrii spațio-temporali de interes includ metrice cuprinzătoare (viteza mersului, cadența, lungimea pasului, ciclul mersului, durata totală a sprijinului bilateral) și unilaterale (pe picior) (durata sprijinului unilateral, durata fazei de balansare, durata fazei de sprijin). Parametrii spațiali măsoară distanța fizică dintre doi pași (cum ar fi lungimea forței); parametrii temporali evaluează timpul petrecut pentru a finaliza un ciclu de mers (cum ar fi cadența, durata balansării și faza de poziție).

În ceea ce privește utilizarea pentru analiza stării de sănătate a pacienților PMSS (Parkinson, scleroza multiplă, atac vascular cerebral), valorile bazate pe GRF (Gait Analysis using Ground Reaction Force) sunt cunoscute că oferă o capacitate predictivă bună (acuratețe > 87%) în ceea ce privește diferențierea între mersul persoanelor sănătoase față de persoanele cu Parkinson¹¹, putând fi utilizate pentru a determina evoluția calității mersului (în termeni de viteză și simetrie a mișcărilor) la pacienții post-accident vascular cerebral¹², au capacitatea de a evalua cantitativ disfuncția mersului la persoanele cu scleroza multiplă în secțiune transversală¹³ cât și longitudinală (pe o durată de un an) (chiar și în absența modificării EDSS (Expanded Disability Status Scale) - principalul test de evaluare a stării de sănătate a persoanelor cu scleroză multiplă).

În proiectul ALAMEDA sunt utilizați senzori de presiune plantară existenți în branțuri produse de Novel Loadsol-AP¹⁴. Branțurile Loadsol sunt conectate la un procesor electronic de dimensiuni mici, care măsoară forța totală în timpul mișcării în două zone ale piciorului. Sistemul este recomandat pentru a monitoriza progresul recuperării sportivilor, dar și pentru a monitoriza asimetriile care pot rezulta datorită diferitelor deficiențe de mers pentru persoanele cu probleme neurologice, respectiv ar putea oferi evaluări mai cuprinzătoare și perspective noi asupra cineticii pacienților în mediul natural. Numeroase studii, Burns et al (2019)¹⁵, Blazey et al (2021)¹⁶, Villa et al (2017)¹⁷ au evidențiat faptul că branțurile Loadsol reprezintă un instrument consistent și valid pentru măsurarea forței dintre pantof și suprafața plantară.

Setul de date Gait in Parkinson's Disease¹⁸ a fost utilizat pentru a dezvolta un model de clasificare Hoehn & Yahr. Setul de date conține semnale VGRF de la senzorii din branțurile inteligente de la o plimbare de 2 minute de la 93 de pacienți bolnavi de parkinson și 73 de subiecți de control.

Ca parte a etapei de preprocesare, au fost excluse cele 2 secunde inițiale și finale din înregistrări, deoarece nu conțineau date relevante de mers. Semnalele au fost apoi normalizate

folosind MinMax Scaling. Caracteristici statistice, cum ar fi valoarea maxima, medie, mediană, abaterea standard, asimetrie, domeniul de valori și intervalul dintre quartile au fost extrase din semnalele in domeniul timp. Transformata Fourier a fost aplicată semnalelor de timp și aceleași caracteristici au fost extrase din domeniul frecvenței, inclusiv variabilitatea și energia semnalului. Pentru a aborda dezechilibrul dintre clase din setul de antrenare, a fost aplicata tehnica SMOTE pentru a crea date sintetice suplimentare. În plus, a fost folosita o metodă de împachetare pentru selecția caracteristicilor, care a identificat și a eliminat în mod eficient caracteristicile nefolositoare din setul de date.

Modele inițiale pentru detecția “înghețării” mersului folosind seturile de date Daphnet și IMU: Configurațiile celor două modele propuse pentru detecția “înghețării” mersului au fost determinate euristic folosind metricile propuse. Mai exact, funcția de loss folosită a fost Binary CrossEntropy, cea mai comună în scopuri de clasificare binară, iar dimensiunea batch-ului a fost de 128 și rata de învățare de 0,0001. Aceste modele au folosit optimizatorul Adam și moment. În final, pentru a evita overfitting, s-a oprit antrenarea în momentul în care 70 de epoci consecutive nu au mai obținut nicio îmbunătățire în reducerea loss-ului.

Modelul InSEption pentru “înghețării” mersului a oferit rezultate excelente, în comparație cu unele modele de referință. Pentru a facilita comparațiile, au fost testate experimentele propuse cu aceleași seturi de date. Rezultatele sunt evidențiate în Tabel 3.

Tabel 3. Rezultate comparative pentru detecția “înghețării” mersului.

Metrici	custom CNN	custom LSTM	LN- Inception	InSEption
Sensitivity	97%	97%	97%	98%
Specificity	96%	97%	99%	99%
Macro-F1	92%	93%	96.9%	97%
Geometric Mean	96.49%	97%	98%	98.49%
AUC	96.47%	97%	98.2%	98.6%

3.3 Detecția elementelor caracteristice bolnavilor de Parkinson

Metoda propusă este evaluată pe baza setului de date „Levodopa Response Study”¹⁹. Acest set de date conține date brute ale accelerometrului 3-axial colectate de la ambele încheieturi și de la talia a 28 de pacienți cu Parkinson folosind o brățară GENEActiv, un ceas inteligent Pebble și, respectiv, un smartphone, pe parcursul unei perioade de monitorizare de 4 zile. Aceste date sunt adnotate în timpul a 2 vizite clinice și etichetele respective corespund prezenței/absenței tremurului, bradichineziei și dischineziei și nivelului lor de severitate într-o scală de 5 puncte (scoruri 0-4). În timpul acestor examinări, pacienții efectuează în mod repetat o serie de sarcini motorii, care conțin atât exerciții din evaluarea MDS-UPDRS III (de exemplu, mișcări de

la degete la nas și mișcări alternante rapide ale mâinii), cât și activități zilnice (de exemplu, mers, desen, tastare, plierea unui prosop etc.), simularea activităților într-un mediu de viață liber.

Capacitatea de predicție a modelelor propuse este evaluată pe baza atât a validării 5-fold cross validation și a validării cross-validation (LOSO). Se preferă validarea cross-validation, deoarece este mai robustă. În plus, se optează pentru utilizarea strategiilor de validare încrucișată la nivel de grup, în care fiecare grup este compus din toate observațiile unuia sau mai multor utilizatori din setul de date. Deoarece setul de date este foarte dezechilibrat și există chiar și unii pacienți care nu manifestă niciodată simptome specifice, adăugăm metoda de stratificare pentru a păstra distribuția claselor în fiecare diviziune pentru a evita rezultatele înșelătoare produse de diviziunile distorsionate.

Cele mai bune scoruri obținute pentru fiecare dintre cele 3 simptome luate în considerare (tremur, bradichinezie, dischinezie) sunt afișate în tabelele de mai jos, analizând următoarele metode: **Logistic Regression (LR)**, **kNN**, **Multilayered Perceptron (MLP)**, **Decision Tree (DT)**, **AdaBoost**, **Random Forest (RF)** și **SVM**.

Tabel 4. Performanțe detecție tremur.

	Accuracy	Precision	Recall	F1-Score	AUC-ROC	AUC-PR
Logistic Regression	70.02%	54.55%	67.14%	59.82%	0.6944	0.6639
kNN	63.01%	46.62%	73.79%	56.95%	0.6564	0.6457
Multilayered Perceptron	69.97%	54.06%	65.22%	59.05%	0.6866	0.6542
Decision Tree	65.81%	49.14%	55.84%	51.98%	0.6337	0.5990
AdaBoost	67.54%	51.44%	64.78%	56.94%	0.6697	0.6404
Random Forest	71.85%	57.69%	59.92%	58.54%	0.6893	0.6552
SVM	70.50%	55.20%	63.79%	58.90%	0.6890	0.6557

	Macro Average Precision	Macro Average Recall	Macro Average F1-Score	Weighted Average Precision	Weighted Average Recall	Weighted Average F1-Score
Logistic Regression	67.84%	69.44%	67.91%	72.63%	70.02%	70.72%
kNN	64.01%	65.64%	62.12%	71.18%	71.81%	71.24%
Multilayered Perceptron	67.26%	68.66%	67.54%	71.90%	69.97%	70.57%
Decision Tree	62.61%	63.37%	62.62%	67.42%	65.81%	66.31%
AdaBoost	65.51%	66.97%	65.39%	70.56%	67.54%	68.33%
Random Forest	68.55%	68.93%	68.56%	72.53%	71.85%	72.04%
SVM	67.70%	68.90%	67.89%	72.22%	70.50%	71.03%

	MCC	CK	JI
Logistic Regression	0.3721	0.3650	0.4284
kNN	0.2959	0.2726	0.3998
Multilayered Perceptron	0.3589	0.3545	0.4203
Decision Tree	0.2595	0.2567	0.3521
AdaBoost	0.3242	0.3164	0.3993
Random Forest	0.3746	0.3729	0.4156
SVM	0.3656	0.3615	0.4189

Tabel 5. Performanțe al detecție bradichineziei.

	Accuracy	Precision	Recall	F1-Score	AUC-ROC	AUC-PR
Logistic Regression	68.47%	48.50%	66.44%	55.79%	0.6804	0.6261
kNN	64.71%	45.12%	73.82%	55.67%	0.6750	0.6361
Multilayered Perceptron	68.85%	48.85%	59.97%	53.65%	0.6629	0.6042
Decision Tree	67.54%	47.21%	60.03%	52.62%	0.6552	0.5971
AdaBoost	68.83%	48.80%	61.00%	54.02%	0.6668	0.6081
Random Forest	70.97%	51.86%	61.56%	56.09%	0.6840	0.6260
SVM	67.58%	47.45%	65.89%	54.95%	0.6716	0.6189

	Macro Average Precision	Macro Average Recall	Macro Average F1-Score	Weighted Average Precision	Weighted Average Recall	Weighted Average F1-Score
Logistic Regression	65.56%	68.04%	65.63%	72.55%	68.47%	69.56%
kNN	64.67%	67.50%	63.15%	72.66%	64.71%	66.13%
Multilayered Perceptron	64.81%	66.29%	65.02%	71.32%	68.85%	69.66%
Decision Tree	63.76%	65.52%	63.95%	70.52%	67.54%	68.48%
AdaBoost	64.93%	66.68%	65.21%	71.53%	68.83%	69.71%
Random Forest	66.78%	68.40%	67.18%	72.84%	79.97%	71.59%
SVM	64.80%	67.16%	64.76%	71.84%	67.58%	68.70%

	MCC	CK	JI
Logistic Regression	0.3350	0.3234	0.3886
kNN	0.3203	0.2938	0.3870
Multilayered Perceptron	0.3106	0.3060	0.3672
Decision Tree	0.2921	0.2861	0.3585
AdaBoost	0.3154	0.3100	0.3712
Random Forest	0.3512	0.3468	0.3924
SVM	0.3186	0.3064	0.3820

Tabel 6. Performanțe detecție dischinezie.

	Accuracy	Precision	Recall	F1-Score	AUC-ROC	AUC-PR
Logistic Regression	70.77%	21.91%	61.56%	31.89%	0.6666	0.4381
kNN	67.99%	20.51%	64.26%	30.79%	0.6626	0.4432
Multilayered Perceptron	73.13%	22.49%	55.11%	31.39%	0.6525	0.4130
Decision Tree	75.85%	20.98%	41.24%	27.36%	0.6072	0.3440
AdaBoost	67.67%	19.86%	54.26%	28.75%	0.6280	0.3952
Random Forest	80.56%	28.67%	43.80%	33.76%	0.6447	0.3933
SVM	76.32%	25.21%	55.47%	34.24%	0.6710	0.4272

	Macro Average Precision	Macro Average Recall	Macro Average F1-Score	Weighted Average Precision	Weighted Average Recall	Weighted Average F1-Score
Logistic Regression	57.90%	66.66%	56.61%	86.04%	70.77%	76.03%
kNN	57.24%	66.26%	54.93%	85.92%	67.99%	73.89%
Multilayered Perceptron	57.75%	65.25%	57.31%	85.34%	73.13%	77.63%
Decision Tree	56.26%	60.72%	56.41%	83.85%	75.85%	79.12%
AdaBoost	56.29%	62.80%	54.67%	84.76%	69.67%	75.04%
Random Forest	60.54%	64.47%	61.17%	85.64%	80.56%	82.70%
SVM	59.41%	67.10%	59.87%	86.21%	76.32%	80.05%

	MCC	CK	JI
Logistic Regression	0.2278	0.1879	0.1936
kNN	0.2156	0.1693	0.1847
Multilayered Perceptron	0.2157	0.1868	0.1889
Decision Tree	0.1628	0.1497	0.1602
AdaBoost	0.1785	0.1498	0.1712
Random Forest	0.2447	0.2356	0.2085
SVM	0.2522	0.2262	0.2116

Discuții: Pentru detecția tremurului se observă că RF și LR depășesc celelalte modele având o precizie de 71,85% și, respectiv, 70,02%. Pentru detecția bradichineziei, RF obține cele mai mari performanțe pentru marea majoritate a metricilor de evaluare dintre metodele evaluate, obținând o acuratețe de 70,97%. În ceea ce privește detecția dischineziei, RF demonstrează cele mai mari performanțe de clasificare, dar nu reușește să detecteze cu acuratețe clasa minoritară (prezența dischineziei). SVM, LR și kNN obțin următoarele performanțe, detectând dischinezia cu un succes mai mare (55,47%, 61,56% și, respectiv, 64,26% recall). În cele din urmă, în toate cazurile, kNN a reușit să detecteze simptomele având recall-ul cel mai mare, dar în detrimentul unei detecții mai slabe a simptomelor, care este mult mai frecventă în setul de date specific, afectând în mare măsură metricile medii respective.

Datorită dezechilibrării semnificative a setului de date, acuratețea, poate fi înșelătoare, deoarece ar putea fi prea mare prin capturarea numai a clasei majoritare. În mod similar, precizia medie macro și medie ponderată, recall-ul și scorul F1 pot fi, de asemenea, mari datorită detectării cu succes a clasei majoritare, chiar dacă clasa minoritară este detectată slab. Deci, este foarte important să identificăm un set de metrici de evaluare adecvate pentru a testa capacitatea de generalizare a abordărilor noastre propuse. AUC-ROC și AUC-PR sunt de obicei alegeri mai bune pentru seturile de date dezechilibrate. Precizia medie ponderată, recallul și scorul F1 sunt, de asemenea, luate în considerare, dar combinate cu o valoare satisfăcătoare de recall pentru a se asigura că clasa minoritară este detectată în multe cazuri.

Mai mult, în general, se observă că pe măsură ce dimensiunea ferestrei crește, toate modelele pentru toate cele 3 simptome tind să se generalizeze mai bine.

Tabel 7. Influența dimensiunii ferestrei asupra performanțelor.

	Accuracy	Precision	Recall	F1-Score	AUC-ROC	AUC-PR
128 exemple	61.07%	14.15%	56.22%	22.56%	0.5875	0.3727
256 exemple	62.24%	15.06%	58.59%	23.74%	0.6059	0.3887
512 exemple	63.15%	14.78%	62.12%	23.73%	0.6266	0.4024
1024 exemple	70.05%	21.65%	62.74%	31.77%	0.6679	0.4421

Standardizarea a jucat, de asemenea, un rol important atât în îmbunătățirea rezultatelor clasificărilor, cât și în reducerea timpului de antrenare. De exemplu, la detecția tremurului cu un model LR simplu pe ferestre de 512 exemple, precizia a crescut de la 57,51% la 68,23% prin standardizarea caracteristicilor utilizate.

În plus, de cele mai multe ori, tehnica de supra-eșantionare SMOTE depășește supra-eșantionarea aleatoare și sub-eșantionarea aleatoare. În majoritatea metodelor explorate, supra-

eșantionarea SMOTE a crescut semnificativ capacitatea modelelor de a detecta clasa minoritară (prezența simptomelor), chiar dacă aceasta a fost de obicei însoțită de o mică scădere a preciziei din cauza efectului dezechilibrului. În plus, de cele mai multe ori, menținerea doar a observațiilor de la un subset de pacienți selectați având un set destul de echilibrat de etichete are ca rezultat valori mai mari ale performanței pentru clasificare. Acest lucru duce însă la utilizarea a mai puțin de 50% dintre utilizatori, astfel că nu se va utiliza pentru demonstrarea rezultatelor respective. Toate rezultatele afișate în tabelele de mai sus provin în urma evaluărilor pe numărul total de utilizatori.

3.4 Detectia exercițiilor de recuperare pentru pacienții cu accident vascular


Setul de date colectat în ALAMEDA este relativ mic în comparație cu alte seturi de date utilizate având în vedere timpul limitat al proiectului și disponibilitatea limitată a adnotărilor datelor. Astfel, s-a încercat extragerea informațiilor semnificative din datele colectate, utilizând metode auto-supervizate prin utilizarea datelor colectate care nu trebuie adnotate. De exemplu, o brățară ce are un accelerometru cu o gamă limitată de mișcare, definită de cele mai probabile mișcări ale mâinii unui om, toate acestea fiind informații fiind folosite pentru a face previziuni mai bune.

Astfel metoda de învățare va prelua datele colectate de la accelerometrul brățării (de exemplu, accelerația pe axele x, y și z a brățării GENEActiv) și, pentru fiecare punct de date din setul de date, se creează o reprezentare latentă (de exemplu, un vector de 128 de dimensiuni) care descrie cel mai bine datele dat fiind contextul său. Această reprezentare este apoi utilizată de orice model (de exemplu, un simplu clasificator liniar) pentru a efectua sarcini precum clasificarea exercițiilor de recuperare sau a face o distincție între „utilizarea zilnică a mâinilor” și „sesiunile de exerciții”.

Modelul propus se bazează pe arhitectura TS2VEC⁹¹ și este compus dintr-o rețea de codificatori, folosind convoluții 1D, care realizează învățarea contrastantă peste vederi de context augmentat pentru a extrage reprezentări contextuale robuste. Astfel de înglobări sunt generate pentru fiecare dată, totuși, prin efectuarea unei operații simple de max-pooling, ele pot fi agregate pentru a crea o singură reprezentare pentru o întreagă secvență. Este inclus un obiectiv suplimentar de antrenare adversarial, a cărui sarcină este de a face modulul de încorporare a exercițiului agnostic pentru persoană care execută exercițiul (adică se dorește să se surprindă variabilitatea doar în cadrul tipurilor de exerciții, nu și în cadrul persoanelor care execută exercițiul). Acest lucru se realizează printr-o rețea de discriminare, alcătuită din două straturi liniare complet conectate cu activare GELU, care preia vectorii de caracteristici și încearcă să-i atribuie fiecare dintre aceștia unuia dintre pacienți, pe baza etichetelor din setul de date. Codificatorul este constrâns să facă înglobări mai generale, ceea ce face din ce în ce mai greu pentru rețeaua de discriminare să recunoască ce pacient a înregistrat ce secvență. Este combinată loss-ul de clasificare a discriminatorului cu loss-ul de contrast ierarhic al codificatorului ca $L = HCL + 1/CI$.

Experimentele au fost efectuate pe setul de date pentru recunoașterea exercițiilor de recuperare a umerilor (SPARSE9X). Setul de date SPARSE9X constă din date inerțiale captate de ceasurile inteligente. Acest set de date include date de la 20 de subiecți sănătoși în timp ce aceștia au efectuat exerciții de fizioterapie supravegheate pentru recuperarea umerilor (vezi exemplul din Figură 6. Exemple exerciții din setul de date SPARSE9X.). Setul de date include, de asemenea, cel puțin 3 ore de date pentru fiecare subiect, deoarece se angajează în activități neconexe și nestructurate. Exercițiile selectate includ atât exemple cu activare și scurtare musculară, cât și exerciții izometrice (activare musculară fără modificarea lungimii). Pentru ca abordarea să fie

similară cu datele colectate în cadrul proiectului, capturate cu brățelele GENEActiv, au fost eliminate datele provenite de la giroscop, magnetometru și senzorul de ritm cardiac, păstrând numai datele accelerometrului pe axele X, Y și Z.



Figură 6. Exemple exerciții din setul de date SPARSE9X.

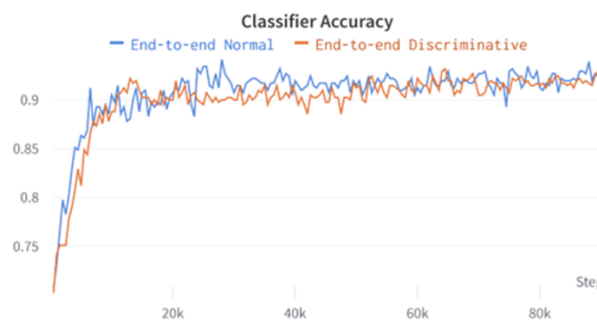
Pentru antrenare s-au utilizat trei configurații: (i) modelul TS2VEC vanilla, (ii) modelul TS2VEC cu extensie adversară adăugată, (iii) modelul TS2VEC end-to-end cu strat de clasificare a exercițiilor. Pentru primele două configurații, clasificarea finală a exercițiilor este efectuată folosind o regresie liniară standard din biblioteca scikit-learn python.

Acuratețea clasificărilor pentru configurațiile (i) și (ii) peste care s-a aplicat o regresie liniară este redată în Figură 7.



Figură 7. Acuratețe model (i) (grafic verde) și model (ii) (grafic violet).

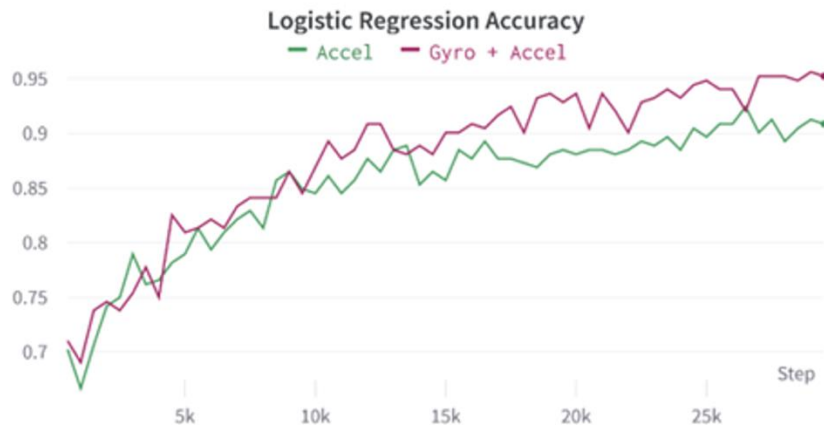
Dacă se antrenează modelul ca în configurația (iii) acuratețea clasificării exercițiilor crește ~93% (Figură 8). Ca observație, în setul de date SPARSE9X, subiecții execută exercițiile destul de similar, fără a exista un grad mare de variabilitate între subiecți.



Figură 8. Clasificare exerciții folosind modelul (iii).

Este important de reținut că folosim doar datele de accelerație în experimentele descrise anterior. Deoarece unele exerciții sunt simetrice în execuție, informațiile se pierd prin faptul că nu se ține cont și de schimbarea orientării unghiulare. Pentru a cuantifica cantitatea de informații pierdute pentru acest set de date, este realizată comparația între clasificarea exercițiilor ce folosește numai datele de la accelerometru (graficul verde din Figură 9) și varianta în care sunt utilizate datele de la accelerometru și giroscop (graficul violet din Figură 9).

Rezultatele indică o pierdere de ~4% a predicției, ceea ce este un rezultat încurajator, având în vedere că unele exerciții (de exemplu, rotația externă versus internă, extensia și abducția umerilor spre piept) pot fi greu de discriminat doar pe baza informațiilor accelerometrului.



Figură 9. Comparatie clasificare folosind datele de la accelerometru (grafic verde) si datele de la accelerometru si giroscop (grafic violet).

4 Diseminare

În cadrul acestei etape, proiectul a fost diseminat prin:

- publicarea a 3 articole (1 articol publicat la conferința internațională cu proceedings IEEE și în curs de indexare ISI) și 2 articole de jurnal indexat ISI (jurnal Q2, factor de impact 2.8):

A. Sorici, L. Băjenaru, I. Mocanu and A. M. Florea, "An Intelligent Ecosystem for Improving Brain Disease Monitoring of Patients Using Wearable Devices and Artificial Intelligence," *2023 24th International Conference on Control Systems and Computer Science (CSCS)*, Bucharest, Romania, 2023, pp. 452-459, doi: 10.1109/CSCS59211.2023.00077.

Bajenaru, Lidia, Alexandru Sorici, Irina Georgiana Mocanu, Adina Magda Florea, Florina Anca Antochi, and Athena Cristina Ribigan. 2023. "Shared Decision-Making to Improve Health-Related Outcomes for Adults with Stroke Disease" *Healthcare* 11, no. 12: 1803. <https://doi.org/10.3390/healthcare11121803>

Sorici, A.; Băjenaru, L.; Mocanu, I.G.; Florea, A.M.; Tsakanikas, P.; Ribigan, A.C.; Pedullà, L.; Bougea, A. "Monitoring and Predicting Health Status in Neurological Patients: The ALAMEDA Data Collection Protocol". *Healthcare* 2023, 11, 2656. <https://doi.org/10.3390/healthcare11192656>

- prezentarea proiectului în cadrul evenimentului BeHealth, 25 Octombrie 2023, organizat de ROHEALTH - Cluster for Health and Bioeconomy <https://behealth-2023.b2match.io>.

5 Bibliografije

-
- ¹ M. M. Hassan, M. Z. Uddin, A. Mohamed, and A. Almogren, "A robust human activity recognition system using smartphone sensors and deep learning," *Futur. Gener. Comput. Syst.*, 2018, doi: 10.1016/j.future.2017.11.029.
- ² E. Cero Dinarević, J. Baraković Husić, and S. Baraković, "Step by Step Towards Effective Human Activity Recognition: A Balance between Energy Consumption and Latency in Health and Wellbeing Applications," *Sensors (Basel, Switzerland)*. 2019. doi: 10.3390/s19235206.
- ³ Sigcha et al., "Deep learning approaches for detecting freezing of gait in parkinson's disease patients through on-body acceleration sensors," *Sensors (Switzerland)*, 2020, doi: 10.3390/s20071895.
- ⁴ R. E. A. Van Emmerik et al., "An Activity Recognition Framework for Monitoring Non-Steady-State Locomotion of Individuals with Parkinson's Disease," *Sensors (Switzerland)*, 2021.
- ⁵ Đurić-Jovičić, Milica D., et al. "Quantitative and qualitative gait assessments in Parkinson's disease patients." *Vojnosanitetski preglad* 71.9 (2014): 809-816.
- ⁶ Shen, Chuanfu, et al. "A comprehensive survey on deep gait recognition: algorithms, datasets and challenges." *arXiv preprint arXiv:2206.13732* (2022).
- ⁷ J. R. Kwapisz, G. M. Weiss, and S. A. Moore, "Activity recognition using cell phone accelerometers," *ACM SIGKDD Explor. Newsl.*, 2011, doi: 10.1145/1964897.1964918.
- ⁸ D. Anguita, A. Ghio, L. Oneto, X. Parra, and J. L. Reyes-Ortiz, "Human activity recognition on smartphones using a multiclass hardware-friendly support vector machine," 2012. doi: 10.1007/978-3-642-35395-6_30.
- ⁹ A. Heimerl, T. Baur, F. Lingenfeller, J. Wagner, and E. Andre, "NOVA-A tool for eXplainable Cooperative Machine Learning," 2019. doi: 10.1109/ACII.2019.8925519.
- ¹⁰ Chen, J. L., Dai, Y. N., Grimaldi, N. S., Lin, J. J., Hu, B. Y., Wu, Y. F., & Gao, S. (2022). Plantar Pressure-Based Insole Gait Monitoring Techniques for Diseases Monitoring and Analysis: A Review. *Advanced Materials Technologies*, 7(1), 2100566.
- ¹¹ Alam, M. N., Garg, A., Munia, T. T. K., Fazel-Rezai, R., & Tavakolian, K. (2017). Vertical ground reaction force marker for Parkinson's disease. *PloS one*, 12(5), e0175951.
- ¹² Patterson KK, Gage WH, Brooks D, Black SE, McIlroy WE. Changes in gait symmetry and velocity after stroke: a cross-sectional study from weeks to years after stroke. *Neurorehabil Neural Repair* (2010) 24:783–90. doi: 10.1177/1545968310372091
- ¹³ Martin CL, Phillips BA, Kilpatrick TJ, Butzkueven H, Tubridy N, McDonald E, et al. Gait and balance impairment in early multiple sclerosis in the absence of clinical disability. *Mult Scler* (2006) 12:620–8. doi:10.1177/1352458506070658
- ¹⁴ <https://novel.de/products/loadsol/>
- ¹⁵ Burns, G. T., Zender, J. D. and Zernicke, R. F. (2019), "Validation of a wireless shoe insole for ground reaction force measurement". *J Sports Sci.*, 37(10), 1129-1138.
- ¹⁶ Blazey, P. , Michie, T. V. and Napier, C. (2021), "A narrative review of running wearable measurement system accuracy and reliability: can we make running shoe prescription objective? ", *Footwear Science*.
- ¹⁷ Villa, C., Loiret I, Dauriac, B., Bonnet, X., Bascou, J., Fode, P., Martinet, N., Paysant, J. and Pillet, H. (2017), "Reliability of pressure insoles to assess normal ground reaction forces during gait of healthy people", *Annals of Physical and Rehabilitation Medicine*, 60, E43.
- ¹⁸ Goldberger A. L., Amaral, L. A. et al. "PhysioBank, PhysioToolkit, and PhysioNet: components of a new research resource for complex physiologic signals." *Circulation* vol. 101, 23, e215-e220 (2000)
- ¹⁹ J.-F. Daneault *et al.*, "Accelerometer data collected with a minimum set of wearable sensors from subjects with Parkinson's disease," *Sci. Data*, vol. 8, no. 1, Art. no. 1, Feb. 2021, doi: 10.1038/s41597-021-00830-0.