

Proiect EMGP-AI

–Raport științific și tehnic in extenso 2022–

Corneliu BURILEANU, Anamaria RĂDOI, Ana NEACȘU, George CIOROIU, Cristina ANDRONACHE, Marian NEGRU, Georgian NICOLAE

Program: PNCDI III - Programul 2: Creșterea competitivității economiei românești prin cercetare, dezvoltare și inovare

Subprogram: *Proiect experimental demonstrativ (PED)*

Titlu proiect: *Platformă integrată de achiziție a semnalelor EMG cu Set de Instrumente software pentru Inteligență Artificială*

Acronim proiect: *EMGP-AI*

Data: *22.10.2022*

Etapa: **3/2022**

Activitățile:

- Activitatea 3.1 – Dezvoltarea unui raport privind starea artei
- Activitatea 3.2 – Implementarea modulului de extragere de trăsături
- Activitatea 3.3 – Dezvoltarea arhitecturii de clasificare și implementarea acesteia
- Activitatea 3.4 – Asigurarea robusteții
- Activitatea 3.5 – Validarea experimentală a sistemului de recunoaștere automată a gesturilor
- Activitatea 3.6 – Diseminare și raportare - partea a II-a

Cod proiect: PN-III-P2-2.1-PED-2019-2392

Număr contract: 425PED/2020

Director proiect: **Prof. Corneliu BURILEANU**

Cuprins

ETAPA III. Sistemul automat de recunoașterea gesturilor	2
1 Rezumatul etapei	2
2 Descrierea științifică și tehnică	3
A3.1 Dezvoltarea unui raport privind starea artei	3
A3.2 Implementarea modulului de extragere de trăsături	10
A3.3 Proiectarea arhitecturii și implementarea clasificatorului	11
A3.4 Asigurarea robusteții	12
A3.5 Validarea experimentală a sistemului de recunoaștere automată a gesturilor	14
A3.6 Diseminare și raportare – partea II	17
Concluzii	17
Locuri de muncă susținute prin program	18
Bibliografie	18

ETAPA III. Sistemul automat de recunoașterea gesturilor

1 Rezumatul etapei

Cea de a treia etapă a proiectului EMGP-AI a avut 3 obiective principale ce au fost realizate în proporție de 100%:

1. Dezvoltarea unui raport privind starea artei – analiza literaturii actuale în ceea ce privește clasificarea de semnale EMG pentru a verifica diferențele care au apărut la nivelul stării artei raportat la momentul propunerii proiectului.
2. Implementarea sistemului de recunoaștere automată a gesturilor împreună cu cercetarea aferentă – în cadrul acestui obiectiv a fost creată și rafinată arhitectura rețelei neurale care realizează clasificarea gesturilor în timp real.
3. Evaluarea sistemului de recunoaștere automată a gesturilor – validarea a fost făcută pe baza de date cu semnale EMG care a fost achiziționată în cadrul etapei 2/2021. Aceasta a cuprins 15 gesturi înregistrate de la 50 de participanți.

Etapa 3/2022 a proiectului EMGP-AI s-a desfășurat în perioada 01.01.2022 – 22.10.2022, și a constat în următoarele activități:

- **Activitatea 3.1. Dezvoltarea unui raport privind starea artei.** De la momentul realizării stării artei pentru propunerea inițială a proiectului au trecut aproximativ 3 ani. Prin urmare, nivelul cunoștințelor a evoluat iar o nouă documentare este necesară.
- **Activitatea 3.2. Implementarea modulului de extragere de trăsături.** Pentru a ajuta un sistem de clasificare să identifice corelații între exemplele date la intrare și datele de la ieșire, este nevoie de extragerea unor trăsături relevante pentru sarcina respectivă. În această activitate s-au extras trăsături de timp și frecvență.
- **Activitatea 3.3. Proiectarea arhitecturii și implementarea clasificatorului.** Pentru a maximiza capacitatea de clasificare a sistemului au fost testate mai multe arhitecturii de rețele neurale. Acestea au fost la rândul lor calibrate în cadrul procesului de *fine-tunning*.
- **Activitatea 3.4. Asigurarea robusteții.** O problemă care poate să apară la rețelele neurale este faptul că în timpul antrenării devin dependente de specificitățile bazei de date folosite. Această dependență poate fi atât de pregnantă încât chiar și modificări foarte mici aplicate datelor de intrare pot face un clasificator cu performanțe foarte bune pe datele de testare să eșueze în mod constant. În cadrul acestei activități s-a analizat și s-a propus o metodă ce garantează teoretic un model mai robust la posibile perturbării adversariale ale intrării.
- **Activitatea 3.5. Validarea experimentală a sistemului de recunoaștere automată a gesturilor.** Această activitate s-a concentrat pe testarea sistemului într-un mod independent de etapa de antrenare a rețelei.
- **Activitatea 3.6. Diseminare și raportare** Pentru a prezenta rezultatele obținute în cadrul etapei 3 a acestui proiect au fost dezvoltate două publicații internaționale. În plus, întregul cod dezvoltat pentru EMGP-AI este disponibil online.

În urma activităților A3.1 – A3.6 din etapa 3/2022 a proiectului EMGP-AI, au rezultat livrabile asumate de echipă la începutul acestei etape:

- raport privind starea actuală a artei;
- dezvoltarea și implementarea software a sistemului pentru clasificare EMG;
- *framework*-ul pentru sistemul de clasificare automată a gesturilor;
- 2 articole în publicații internaționale.

2 Descrierea științifică și tehnică

A3.1 Dezvoltarea unui raport privind starea artei

Introducere

Evoluția științifică din ultimii ani s-a concentrat asupra conceptului de interacțiune om-mașină (*eng. Human-Computer Interaction*), care împreună cu algoritmi de învățare automată (*eng. Machine Learning*), a dus la realizarea unor tehnologii remarcabile din societatea actuală. Astfel de sisteme autonome sunt folosite cu succes într-un număr din ce în ce mai mare în domenii de interes pentru viețile de zi cu zi ale oamenilor, precum domeniul medical [33], conducerea autonomă [46], procesarea limbajului natural [92], *etc.* Cercetători din întreaga lume se concentrează pe furnizarea unor noi metode precise și intuitive pentru interacțiunea cu dispozitivele din jur, pe baza analizei gesturilor, a vocii sau a vederii umane [44].

Electromiografia (EMG) reprezintă procesul de măsurare a activității electrice produse de mușchii corpului uman atunci când se contractă. Acest lucru se poate face folosind electrozi pe suprafața pielii sau direct introduși în mușchi [7]. Cu ajutorul semnalelor de suprafață de tip electromiografic, prescurtate semnale sEMG, se poate decoda intenția motorie, care mai departe poate fi folosită ca metodă de control intuitiv pentru proteze multi-funcționale [80], precum și interfețe de recunoaștere a gesturilor [78]. Astfel de proteze pot corela activitatea reziduală a mușchilor cu mișcarea unui dispozitiv, prin folosirea unor algoritmi de recunoaștere a tiparelor pentru a identifica semnalele EMG repetitive și distinctive pentru fiecare tip de mișcare. Cele mai performante sisteme de recunoaștere a tiparelor EMG folosite pentru proteze multi-funcționale în mod uzual parcurg mai multe etape: o etapă de pre-procesare, de segmentare a datelor, extragere de trăsături, reducerea dimensiunii datelor, clasificare semnalelor, respectiv o etapă de control pentru post-procesare [59]. Conceptual, un astfel de sistem poate facilita un control intuitiv ce imită modul natural de comunicare al creierului cu restul organismului. În ciuda eforturilor substanțiale de cercetare și dezvoltare în specialitate, în ultimii zeci de ani singura aplicație comercială a semnalelor EMG a fost reprezentată de proteze. În ultimul deceniu, odată cu lansarea dispozitivelor EMG portabile pentru controlul mișcării și al gesturilor, precum brățara Myo din 2013, s-a mărit zona de interes pentru semnalele EMG. Altfel spus, progresele tehnologice privind dispozitivele portabile au permis accesul dispozitivelor bazate pe semnale sEMG să pătrundă în viața de zi cu zi a oamenilor. Cu toate acestea, astfel de sisteme ce se ocupă cu recunoașterea gesturilor prezintă sensibilități similare la mulți factori din lumea reală ce au fost identificați deja în domeniul protezelor artificiale [66, 72].

Adevărata problemă pentru proteze și interfețe de recunoaștere a gesturilor este dată de factorii dinamici ce produc schimbări în caracteristicile semnalelor EMG. Ca și consecință a acestor fenomene, apar diferențe privind rezultatele sistemului între etapa de antrenare și în utilizarea lor practică. Se creează astfel o discrepanță între rezultatele algoritmului dintr-un mediu constrâns de laborator și fiabilitatea acestora în viața de zi cu zi. În condiții ideale, s-a raportat că folosind protezele multi-funcționale într-un mediu controlat, capacitatea de utilizare a acestora este afectată atunci când acuratețea de clasificare a sistemului scade sub 90% [31, 42]. Deși metrica de acuratețe pentru o problemă de clasificare oferă un punct de referință într-un mediu de laborator, utilizarea sistemului în viața reală introduce în mod cert variabile dinamice care nu sunt prezente în condițiile de antrenare, iar acest lucru duce la scăderea acurateței, prin urmare și la scăderea fiabilității dispozitivului [29, 80]. În fiecare zi, gradul de încredere al modelelor pre-antrenate variază foarte mult în funcție de diferiți factori, precum: repetabilitatea inter-subiect, zgomotul introdus, diferite intensități și durate ale contractiilor musculare, poziția membrului cu ajutorul căruia se extrag date precum și orientarea acestuia, deplasări ale electrozilor sau oboseală musculară. Pentru problema de recunoaștere a gesturilor, în cazul în care sunt folosite semne ce necesită mișcarea degetelor se introduce o complexitate suplimentară asupra semnalului înregistrat. Mai mult, în timp ce domeniul care se ocupă cu studiul protezelor s-a concentrat mai mult asupra modelelor ce pot fi integrate ca parte a corpului uman, domeniul de interacțiune om-mașină ar beneficia pe scară mai largă de îmbunătățirea modelelor de clasificare multi-utilizator, cu scopul de a elimina necesitatea personalizării dispozitivului (de exemplu evitarea etapelor de calibrare a lungimii ce trebuie respectate).

Recunoașterea de gesturi pe baza semnalelor EMG

Interpretarea gesturilor constituie un mod universal și intuitiv de comunicare, având potențialul de a aduce experiența IoT (*eng. Internet of Things*) la un nivel diferit, mai organic [74]. Algoritmi de recunoaștere în mod automat a gesturilor (*eng. Automatic Gesture Recognition – AGR*) pot fi utilizați cu succes în diverse aplicații, precum recunoașterea limbajului semnelor (*eng. Sign Language Recognition – SLR*) [14] sau chiar în jocuri de realitate virtuală [91]. De asemenea, capacitatea de a clasifica răspunsurile electrice musculare reprezintă o etapă fundamentală în crearea de proteze inteligente și fiabile pentru persoanele care și-au pierdut un membru, având rolul de a oferi acestor oameni o viață cât mai normală. Pe lângă astfel de aplicații, un sistem capabil să clasifice gesturile în timp real poate fi folosit pentru a interacționa cu diverse alte dispozitive, precum drone sau mașini pentru supraveghere și explorare, oferind un control mult mai intuitiv și interactiv [2, 6]. Chiar dacă acest domeniu ce se ocupă cu interpretarea gesturilor are un potențial mare atât pentru cercetare cât și pentru industrie, tehnici fiabile și accesibile de clasificare automată a gesturilor folosind semnale EMG (semnale de tip electromiografic) nu sunt încă disponibile comercial. Uzual, proiectele de clasificare a semnalelor EMG nu iau în considerare proiectarea propriului modul de achiziție, datorită complexității realizării unui astfel de dispozitiv. În general, se preferă folosirea unui sistem deja existent, care este renumit datorită faptului că achiziționează date EMG într-un mod eficient. Un astfel de dispozitiv, folosit de mai mulți cercetători este reprezentat de brățara Myo, un modul cunoscut în literatură pentru înregistrarea semnalelor EMG [50, 32, 45, 4], dar acesta nu mai este disponibil pentru cumpărare [89]. Ideal, se dorește un sistem cât mai puțin dependent de factori externi, atât din punct de vedere hardware, cât și software.

Sistemele de recunoaștere a gesturilor parcurg în general mai multe etape, după cum se observă și în Figura 1: pre-procesarea datelor, segmentarea datelor, extragerea de trăsături, reducerea dimensionalității, respectiv clasificarea gesturilor [63]. Prin această structură, astfel de sisteme au fost utilizate cu mare succes în mai multe domenii, precum ingineria bio-medicală sau controlul mioelectric [80].

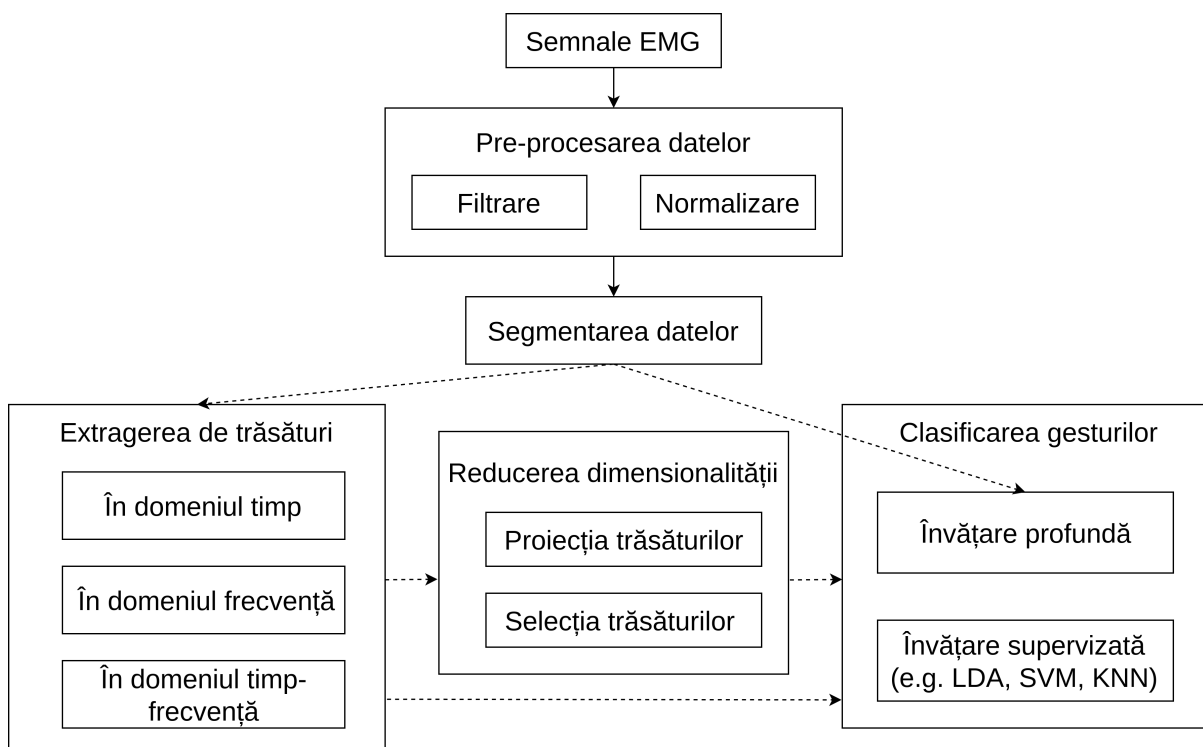


Figura 1: Structura unui sistem EMG pentru recunoașterea gesturilor [63]

Etapa de pre-procesare implică eliminarea în mod strategic a datelor care pot fi corupte sau pot introduce o eroare în antrenarea modelului. În aplicații EMG, după ce semnalul EMG este prelucrat, mai mulți pași de pre-procesare sunt realizați pentru a reduce influența zgomotului, deoarece ar putea compromite interpretarea semnalelor. Sursele de zgomot comune aplicațiilor EMG sunt reprezentate

în general de artefacte de mișcare, surse de alimentare și zgomotul electronic inerent echipamentului. Pașii de pre-procesare sunt folosiți pentru a reduce impactul acestor surse și au scopul de a pregăti datele pentru analize suplimentare [15, 77].

Segmentarea datelor presupune diferite tehnici pentru a pregăti în continuare semnalele EMG, înainte de a fi aplicați algoritmi de clasificare. Această etapă este necesară datorită faptului că semnalele EMG, obținute sub forma de serii temporale de amplitudine variabilă în domeniul timp, sunt nestaționare sau prezintă proprietăți de nestaționaritate. Multe metode de extragere a trăsăturilor presupun faptul că datele sunt staționare, așadar semnalul EMG de durată lungă este împărțit în segmente scurte EMG pentru a estima proprietățile semnalului. Totuși, pentru sistemele de control electric în timp real, lungimea acestor segmente și alte calcule computaționale trebuie să fie mai mici de 300ms pentru a evita întârzieri sesizabile [20]. Cele două tehnici principale pentru segmentare datelor presupun împărțirea semnalelor în ferestre fie adiacente, fie suprapuse. În primul caz segmentele sunt disjuncte și se utilizează o lungime predefinită. Cel de-al doilea caz este mai des folosit și presupune segmente care se suprapun cu o lungime mai mică decât dimensiunea ferestrei, această abordare fiind utilizată ca și metodă de augmentare a bazei de date, cu scopul de a învăța un model cu mai multe date pentru a obține o performanță mai bună.

Extragerea de trăsături este un proces folosit pentru a îmbunătăți relevanța informației extrase dintr-un semnal, adesea prin transformarea semnalelor dintr-un spațiu de intrare cu multe dimensiuni într-un spațiu de caracteristici de dimensiuni reduse. Selectarea unor trăsături adecvate are un impact major asupra performanței oricărui sistem de recunoaștere a gesturilor, iar set-ul ideal de caracteristici depinde în mare măsură de sarcina de clasificare. În literatură, trăsăturile EMG sunt împărțite uzual în 3 mari categorii: caracteristici în domeniul timp, în domeniul frecvență (spectral), respectiv în timp-frecvență [65, 67, 69, 71]. Disponibilitatea unor trăsături de foarte bună calitate, cu o separabilitate mare asupra claselor ce trebuie învățate, precum și o complexitate minimă, respectiv o robustețe asupra factorilor dinamici, reprezintă cele mai esențiale criterii pentru o performanță bună a unui sistem de control mioelectric automat [9, 94].

Reducerea dimensionalității reprezintă metoda prin care fie se caută din spațiul de trăsături un sub-spațiu optimal cu cele mai performante trăsături (proces numit selecția trăsăturilor), fie se combină toate trăsăturile inițiale, acestea fiind apoi proiectate într-un alt spațiu cu ajutorul unei asocieri liniare sau non-liniare (proces numit proiecția trăsăturilor), cu scopul de a maximiza performanța clasificatorului. Tehnici uzuale de reducere a dimensionalității sunt reprezentate de selecția directă secvențială (*eng. Sequential Forward Selection – SFS*), algoritmi genetici (*eng. Genetic Algorithms – GA*) respectiv analiza componentelor principale (*eng. Principal Component Analysis – PCA*) și analiza componentelor independente (*eng. Independent Component Analysis – ICA*) [59, 64, 68].

În final, etapa de clasificare implică utilizarea unui separator între clase, sau un discriminant antrenat în mod iterativ pentru a estima clasa semnalului curent, prin intermediul caracteristicilor reprezentative extrase din acesta. Au fost explorate diverse metode pentru dezvoltarea unui algoritm de clasificare în domeniul controlului mioelectric, precum analiza discriminantă liniară (*eng. Linear Discriminant Analysis – LDA*), mașini cu vectori suport (*eng. Support Vector Machines – SVM*), modele Markov cu stări ascunse (*eng. Hidden Markov Models – HMM*) și rețele neurale artificiale (*eng. Artificial Neural Networks – ANN*) [59, 68, 80].

Structura sistemului discutată anterior și prezentată în Figura 1 reprezintă o schemă generală, dar recunoașterea în mod automat a gesturilor (AGR) este o sarcină ce poate fi abordată în mai multe moduri, precum propunerea unor soluții pe baza unei imagini sau a unui videoclip, utilizând algoritmi de analiză video din domeniul *Computer Vision* [25, 41, 18]. Abordări multi-modale pentru clasificarea gesturilor au fost de asemenea studiate [56]. Cu toate că se obține o performanță bună pe date din laborator, în viața reală aceste sisteme pot fi sensibile la condițiile de mediu, precum nivelul de luminozitate, fundalul în care sunt realizate imaginile, *etc.* Suplimentar, astfel de sisteme sunt adesea solicitante din punct de vedere computațional, deci în consecință nu sunt întotdeauna potrivite pentru aplicații în timp real. Din acest motiv, abordări clasice ce includ algoritmi de tipul *Support Vector Machine* (SVM) sau *Random Forest* (RF) sunt încă populari datorită simplității lor [39]. O altă soluție, bazată pe rețele neurale, ține cont de corelația temporală a datelor dintr-un semnal de tip EMG. Astfel, se pot folosi rețele care iau în considerare particularitățile temporale ale semnalelor,

precum rețelele neurale recurente (*Recurrent Neural Networks – RNN*). Simao *et al.* [84] arată faptul că folosind arhitecturi de tipul RNN, precum LSTM (*Long Short-Term Memory*) și GRU (*Gated Recurrent Unit*), se obțin rezultate bune, dar eficiența acestora (din punct de vedere al acurateții) este similară cu performanța rețelelor complet-conectate (*eng. feed-forward networks*), obținând rezultate de 91%-95%, în funcție de baza de date folosită. Cu toate acestea, astfel de modele dinamice sunt relevante datorită faptului că necesită mai puțină putere computațională, reducând astfel numărul de parametri necesari pentru faza de antrenare.

Accelerometre în combinație cu senzori EMG oferă o tehnologie alternativă la un cost redus pentru detectarea gesturilor. Sistemele de tipul sEMG sunt în general folosite ca dispozitive de terapie pentru reabilitare sau control postural pentru persoanele cu deficiențe fizice [37]. Datorită dezvoltării continue a tehnicilor de procesare a semnalelor și a sistemelor de calcul necesare, aplicațiile în care semnalele EMG pot fi utilizate s-au extins, existând o gamă largă de domenii, precum realitatea augmentată, industria jocurilor, domeniul militar, *etc.* [38, 57]. Achiziționarea unui set de date EMG multi-canal reprezintă o provocare, datorită constrângerii de a păstra mereu senzorii în aceeași poziție relativă la grupele musculare pentru toți subiecții care participă la achiziție. De asemenea, în timpul înregistrării, toți participanții ar trebui să realizeze experimentul cu membrul superior folosit (uzual mâna dominantă) în aceeași poziție ca cea menținută de ceilalți subiecți.

Influența factorilor externi asupra recunoașterii gesturilor

Cu toate că s-au obținut rate de clasificare de peste 90% în multe studii, mai multe probleme trebuie rezolvate înainte de realizarea unui sistem de control mioelectric robust și practic ce poate fi folosit comercial. Astfel, trebuie ținut cont de mai multe efecte, precum: (1) variații ce pot apărea prin utilizarea zilnică a aparatului, (2) zgomotul introdus, (3) modificări ale forței exercitate în realizarea gestului, precum și (4) schimbarea poziției și orientării membrului folosit în execuția mișcării.

Reutilizarea și sustenabilitatea sistemelor de control mioelectric reprezintă o preocupare majoră pentru aplicațiile din lumea reală, întrucât dispozitivele concepute pentru utilizarea pe termen lung necesită adesea schimbări și actualizări frecvente. Indiferent de performanța inițială a modelului, nestaționaritatea semnalelor EMG (caracteristicile acestora se schimbă pe parcursul zilei și între zile diferite) degradează performanța sistemului în timp (până la 20-30% mai puțin [51, 60]). Sursele acestor variații naturale de-a lungul timpului sunt reprezentate de orientarea spațială (deplasarea electrozilor), factori electro-fiziologici (oboseală musculară, transpirație, impedanța pielii, *etc.*), forța utilizatorului (efortul depus pentru contracția musculară), precum și alți mulți factori. Majoritatea studiilor fac falsă presupunere că semnalele EMG reprezintă un proces staționar, așadar se neglijează modelarea variațiilor temporale ale semnalelor în timp. O caracteristică comună a acestor experimente este perioada scurtă de achiziție a acestora (*i.e.* o singură sesiune sau câteva într-o zi), cu constrângeri de laborator, evitând în mare măsură astfel de schimbări naturale ale semnalului.

Performanța clasificării semnalelor EMG, atât pentru subiecții sănătoși, cât și pentru cei amputați, se degradează pe măsură ce crește diferența de timp dintre momentele de achiziție pentru datele de antrenare și cele de testare [3, 10, 34, 70, 90]. Cu toate acestea, nu există un consens privind cantitatea suficientă de date de antrenare pentru ca un model de clasificare să poată oferi o acuratețe stabilă. În timp ce Waris *et al.* [90] au constatat o scădere continuă a performanței pe parcursul a 7 zile, alte studii au descoperit că pot exista perioade în care eficiența modelului de clasificare rămâne destul de stabilă sau chiar se îmbunătățește. Unele cercetări au arătat cum inițial acuratețea scade exponențial, dar apoi se stabilizează după 3 zile [70], 4 zile [3, 34], respectiv 6 zile pentru subiecți sănătoși [10] și 6-9 zile pentru oamenii amputați [34]. O posibilă explicație este faptul că subiecții încep să se familiarizeze cu procesul și pot repeta mai exact gesturile dorite. Deoarece această acomodare apare în principal în primele zile [86], colectarea datelor de antrenare după această perioadă poate reduce necesitatea de adaptare la utilizator a algoritmului de clasificare. De exemplu, Milosevic *et al.* [51] a remarcat că prin antrenarea unui clasificator cu date de antrenare luate după 4 și 5 zile de utilizare au oferit rezultate mai bune pentru zilele ulterioare (date de testare din ziua 6), față de antrenarea cu date achiziționate din ziua 1 și 2 (cu date de testare din ziua 3).

Majoritatea metodelor de procesare a semnalului EMG și de recunoaștere a gesturilor presupun faptul că astfel de semnale sunt de calitate foarte bună. Acest lucru poate duce la rezultate sau

interpretări greșite în cazul în care datele nu sunt ideale. Este cunoscut faptul că în momentul achiziției semnalelor de tip EMG, în mod inevitabil este introdus și zgomot. Cu alte cuvinte, semnalele EMG conțin de obicei nu doar informații utile, ci conțin și informații irelevante sau confuze care adaugă ambiguitate în eșantioanele semnalului. Așadar, semnalele EMG nu pot fi folosite direct, ci este necesară o etapă de pre-procesare pentru a reduce efectul zgomotului și pentru a îmbunătăți rezoluția spectrală a semnalului. Există mai multe tipuri de zgomot comune în semnalele EMG [15, 24, 49, 88], precum: (a) artefacte de mișcare, (b) interferențe electrocardiografice (ECG), (c) interferența sursei de alimentare, (d) zgomot de cuantizare, (e) efecte introduse de conversia analog-digitală, (f) saturația amplificatorului, (g) vârfuri false de amplitudine date de zgomot de fundal, respectiv (h) zgomot alb gaussian aditiv. Totuși, mai multe tipuri de zgomot se manifestă în afara bandei de energie utilă a semnalului EMG sau doar într-o bandă îngustă specifică de frecvențe. De exemplu, interferența sursei de alimentare este concentrată în jurul valorii de 50 Hz sau 60 Hz (în funcție de locația geografică), în timp ce artefactele de mișcare tind să fie limitate în intervalul de frecvențe 0 – 20 Hz [77]. Prin folosirea metodelor convenționale de tipul filtre cu răspuns finit (*eng. finite-impulse response – FIR*), respectiv filtre cu răspuns infinit (*eng. infinite-impulse response – IIR*), se pot reduce astfel de zgomote cu un impact minim asupra semnalului EMG util [30, 19]. De exemplu, De Luca *et. al.* [19] recomandă folosirea unui filtru de tip Butterworth cu o frecvență de trecere de 20 Hz și o pantă de 12 dB/octavă pentru a filtra artefactele de mișcare și alte zgomote uzuale. Powar *et. al.* [73] folosesc un filtru FIR cu coeficienți ce duc la obținerea unor performanțe bune pe semnale EMG, măbind acuratețea de clasificare a sistemului cu 20.5%. De asemenea, au fost propuse și filtre digitale adaptive pentru eliminarea acestor zgomote, precum metoda LMS (*eng. Least Mean Square*) și RLS (*eng. Recursive Least Square*) [23, 58, 95].

Sistemele convenționale pentru controlul mioelectric folosesc uzual un estimator de amplitudine EMG (precum valoarea absolută medie MAV sau valoarea efectivă RMS [71]) pentru a asocia intensitatea contracției musculare cu nivelul sau poziția unui cursor sau dispozitiv [82]. Totuși, controlul mioelectric bazat pe recunoașterea gesturilor se folosește de gruparea tiparelor repetitive ale activității EMG pentru recunoașterea claselor. Contracțiile realizate la diferite niveluri de forță pot duce la caracteristici drastic diferite, având un impact semnificativ asupra performanței clasificatorului. Într-un studiu condus de Scheme *et. al.* [80], s-a studiat capacitatea de recunoaștere a gesturilor oamenilor în timp ce intensitatea contracției musculare a fost variată. Au fost înregistrate semnale EMG pentru 10 gesturi la intensități diferite, 11 subiecți sănătoși modificând între 20 și 80% contracția voluntară maximă efectuată (*Maximum Voluntary Contraction MVC*), prin folosirea unei brățări EMG cu 8 canale. Pentru a testa capacitatea sistemului de a gestiona niveluri de forță neîntâlnite, clasificatorul a fost antrenat cu fiecare nivel de forță și apoi testat cu toate nivelurile existente. Intuitiv, s-a obținut o acuratețe maximă atunci când clasificatorul a fost antrenat și testat cu niveluri similare de forță, în timp ce atunci când sunt prezente contracții cu niveluri neîntâlnite de forță, eroarea crește considerabil (între 32 și 44%). Astfel de experimente au fost refăcute când Al-Timemy *et. al.* [1] au investigat efectul variației de forță cu două persoane amputate. Similar, rezultatele acestora arată cum performanța scade până la 60% atunci când nivelul forței este variat. În plus, o altă constatare importantă a fost faptul că acuratețea a fost mai mică pentru niveluri mari de forță, deoarece subiecții realizau cu greu astfel de contracții de intensități mari și nu le puteau menține [1].

Aceleași gesturi ale mâinii sau mișcări de încheietură pot genera, de asemenea, semnale foarte diferite atunci când sunt efectuate în diferite poziții ale membrelor și orientări ale antebrăului, măbind eroarea de clasificare și deci reducând robustețea modelului pentru utilizarea în viața reală [13, 22, 36, 47, 81]. S-a remarcat totuși faptul că impactul modificării poziției este mai puțin important la persoanele amputate față de subiecții sănătoși [27, 35]. Au fost propuse 3 principale metode pentru a aborda problema schimbării poziției dispozitivului: (1) antrenarea unui clasificator de semnale EMG înregistrate la diferite poziții fixe predefinite sau în timpul mișcării dinamice între poziții cunoscute; (2) folosirea accelerometrelor pentru a măsura poziția mâinii și orientarea acesteia; (3) dezvoltarea unor metode robuste de extragere de trăsături, reducere a dimensionalității, respectiv algoritmi de clasificare care pot reduce efectul variației poziției și orientării.

Ca și în cazul schimbării nivelului de forță, a fost folosită cu succes o strategie similară ce evidențiază limitele efectelor de schimbare a poziției și a orientării antebrăului prin includerea de exemple

din fiecare poziție și orientare în timpul etapei de antrenare a sistemului [13, 22, 36, 81]. De exemplu, Scheme *et. al.* [81] au antrenat un clasificator LDA folosind date EMG înregistrate în 8 poziții diferite pentru a discrimina 8 gesturi. Cea mai bună acuratețe a fost obținută atunci când mâna era ținută complet în jos, în timp ce poziția cu cea mai slabă acuratețe a fost atunci când cotul a fost îndoit la 90°. Similar, Mukhopadhyay *et al.* [52] clasifică 8 gesturi folosind tehnici de inteligență artificială, iar pentru fiecare gest au fost înregistrate 5 poziții diferite ale membrului superior utilizat. Cea mai bună acuratețe obținută a fost de 98.88%, folosind un clasificator bazat pe rețele neurale, dar trebuie menționat faptul că baza de date a fost formată doar din 5 subiecți, ceea ce reprezintă un număr prea mic de participanți, astfel încât acest tip de sistem nu este indicat să fie folosit într-o aplicație comercială, care necesită funcționarea corectă pentru orice utilizator. Khushaba *et. al.* [36] au antrenat un clasificator de tip SVM folosind semnale EMG înregistrate cu 3 orientări diferite ale antebrațului (*i.e.* încheietura mâinii complet ridicată, în poziție de repaus, respectiv complet coborâtă în jos) pentru a clasifica 6 tipuri de gesturi. Yang *et. al.* [93] au investigat efectul atât a schimbării poziției, cât și a orientării, remarcând faptul că în cazul problemei de clasificare a gesturilor mâinii și ale degetelor, performanța este mai puternic influențată de orientarea antebrațului decât de poziția membrului. Acest rezultat este intuitiv având în vedere poziția mușchilor extrinseci ai mâinii, folosiți ca puncte cheie pentru captarea semnalelor EMG. Cu toate că s-a demonstrat faptul că prin încorporarea datelor extrase din diferite poziții se îmbunătățește performanța modelului, timpul de antrenare și efortul necesar pentru obținerea acestor date limitează viabilitatea acestor sisteme [8]. Așadar, se preferă folosirea fie a mișcării dinamice între poziții predefinite, fie mișcarea liberă a mâinii în spațiul 3D în timpul execuției gesturilor [26, 76, 79].

Asigurarea robusteții într-un sistem de recunoaștere a gesturilor

În plus față de ce s-a discutat deja anterior, pentru dezvoltarea unor algoritmi de recunoaștere automată a gesturilor pe baza semnalelor EMG, trebuie luate în considerare 2 criterii: timpul de inferență trebuie să fie suficient de rapid pentru a asigura o senzație cât mai realistă pentru utilizator, precum și o clasificare precisă și robustă pentru a garanta că gestul este corect identificat indiferent de condițiile de mediu. În ultimul deceniu, metodele de învățare automată au devenit soluții omniprezente pentru o gamă largă de sarcini, inclusiv recunoașterea automată a gesturilor, datorită capacității acestora de a rezolva o mare varietate de probleme, pornind de la probleme simple de regresie până la clasificări complexe de tip multi-modal.

Principalul dezavantaj al rețelelor neurale este dat de faptul că au nevoie de seturi extinse de date pentru a se antrena corespunzător, astfel încât să ofere performanțe ridicate [75], dar avantajul este faptul că rezultatele pot fi remarcabile. În [17] se studiază cum caracteristicile generale și reprezentative ale semnalelor EMG pot fi învățate din cantități mari de date, prin agregarea semnalelor de la mai mulți utilizatori, reducând astfel numărul de achiziții necesare și în același timp mărinșd capacitatea sistemului de recunoaștere a gesturilor. Autorii propun aplicarea unei metode de învățare prin transfer (*eng. transfer learning*) pe aceste date agregate de la mai mulți participanți, valorificând în același timp capacitatea algoritmilor de învățare profundă de a învăța caracteristici discriminante din seturi mari de date, care pot fi apoi folosite pentru problema specifică ce se dorește a fi rezolvată. Folosind brățara Myo, sunt construite 3 baze de date, cu 19, 17, respectiv 10 participanți, iar prima bază (fiind cea mai mare) este folosită pentru pre-antrenarea a 3 rețele neurale diferite, cu scopul de fi folosite apoi în procesul de învățare prin transfer. Pentru testare sunt folosite cele 2 baze de date mai mici. Sunt experimentate 3 tipuri de semnale ca date de intrare: semnalul EMG propriu-zis, spectrograme extrase din semnalul EMG, respectiv transformata *wavelet* continuă corespondentă (*eng. Continuous Wavelet Transform – CWT*).

Cu toate acestea, rețelele neurale adânci, care reprezintă acum cele mai puternice metode, pot fi considerate niște sisteme necunoscute (*eng. black boxes*) a căror robustețe nu este întotdeauna bine controlată. Pentru aplicații în viața reală, este obligatoriu să se garanteze fiabilitatea unor astfel de algoritmi. În zilele noastre, principala dificultate constă în dezvoltarea unor sisteme performante, care sunt, de asemenea, sigure și de încredere. O provocare suplimentară este evitarea realizării unei rețele neurale foarte complexe în timpul fazei de antrenare, deoarece este dificil de integrat într-un sistem cu capacitate limitate, datorită numărului prea mare de parametri.

În [85], autorii au arătat faptul că prin modificarea ușoară a datelor de la intrare, clasificate deja corect de o rețea neurală, se poate ajunge la o clasificare greșită a acestora [43, 11, 87], folosind aceeași rețea. Această constatare a stat la originea conceptului de intrare adversarială, care este reprezentată de date de intrare alterate în scop malițios, ce pot face ca modelele bazate pe învățare automată să ia decizii greșite. De exemplu, în [11] se arată cum interfețele vocale pot fi păcălite prin crearea unor date de intrare audio concepute în mod artificial, formate din voci neinteligibile care sunt greșit clasificate de către sistem ca și comenzi vocale specifice. De asemenea, [28] introduce mai multe metode pentru generarea de exemple adversariale folosind baza de date cu imagini *ImageNet*, astfel încât aceste exemple sunt foarte asemănătoare cu datele originale din punct de vedere vizual (nu se remarcă diferențe între exemplul original și cel alterat), dar cu toate acestea rețeaua neurală va clasifica greșit astfel de date de intrare adversariale.

Trebuie subliniat faptul că datele de intrare adversariale nu sunt neapărat artificial create cu intenția de a sabota un sistem automat. Precum alte semnale fiziologice, *e.g.* EEG sau ECG, semnalele EMG au componente de frecvențe joase (uzual în intervalul 10 – 150 Hz), precum și amplitudini mici (≤ 10 mV Vârf la Vârf). Datorită acestor lucruri semnalele EMG sunt foarte sensibile la zgomot sau la perturbații exterioare ce pot apărea în mod natural, sub forma de zgomot provenit de la dispozitivele de achiziție, din cauza senzorilor de contact, firelor de păr, *etc.* Acestea pot afecta semnificativ performanța în cazul aplicațiilor din viața reală, bazate pe modele pre-antrenate [53].

Pentru a limita efectele nedorite introduse de atacurile adversariale, autorii din [28] arată cum robustețea unei rețele neurale poate fi controlată cu ajutorul constantei Lipschitz. Prin aceasta, se poate limita efectul perturbației conținute în datele de intrare, obținându-se în acest mod un sistem cu performanțe bune chiar dacă exemplele de la intrare sunt alterate. Recent, au fost analizate mai multe tehnici pentru a asigura stabilitatea comportamentului Lipschitz a rețelelor neurale. De exemplu, [87] propune o nouă metodă de normalizare spectrală a ponderilor sistemului, folosită pentru a stabiliza etapa de antrenare a blocului discriminator într-o rețea de tip GAN (*eng. Generative Adversarial Network*). În acest exemplu, constanta Lipschitz este considerată ca un hiper-parametru al rețelei ce poate fi reglat în timpul procesului de antrenare, pentru generarea de noi imagini. Astfel, acest lucru duce la antrenarea unui model îmbunătățit, cu o capacitate de generare mai bună. În [5] sunt propuse mai multe tipuri de arhitecturi, bazate pe constrângeri a normei ponderilor dintr-o rețea. Se arată în acest mod faptul că astfel de arhitecturi pot fi utilizate ca o aproximare universală a funcției Lipschitz, autorii aplicând o conservare a normei gradientului pentru a crea rețele de tip Lipschitz care oferă o garanție asupra robusteții adversariale. În [16] autorii introduc rețelele de tip Parseval, ce reprezintă o altă abordare în proiectarea rețelelor, astfel încât acestea sunt robuste în mod natural la zgomotul adversarial, prin impunerea ca pentru fiecare strat al sistemului constanta Lipschitz să fie mai mică decât 1. În [21] se introduce un algoritm de optimizare convexă pentru a calcula limitele superioare pentru constanta Lipschitz în cadrul rețelelor DNN (*eng. Deep Neural Networks*). Acesta ține cont de faptul că funcțiile de activare utilizate în mod obișnuit sunt bazate pe gradienti de funcții convexe. Alte abordări semi-definite pentru asigurarea robusteții sunt de asemenea explorate în [62].

În concluzie, în această etapă s-au revizuit și discutat diferite metode de procesare a semnalelor EMG, precum și tehnici de clasificare ale acestora pentru un sistem de control mioelectric. În special, s-au analizat posibile efecte ce pot afecta performanța sistemului (variații zilnice ale semnalelor EMG, tipurile de zgomot introduse, variații în forță, modificarea poziției și a orientării), precum și metode de combatere ale acestor efecte, prin asigurarea unei robusteți cât mai bune a modelului antrenat pentru problema de clasificare. Din toate aceste observații, se remarcă faptul că necesitatea unui sistem capabil atât să achiziționeze semnale EMG, cât și să le prelucreze într-un mod automat, reprezintă o problemă esențială în acest domeniu. Mai mult, componenta hardware trebuie să poată înregistra datele într-un mod non-invaziv, cu o eficiență maximă. De asemenea, implementarea software trebuie să asigure o robustețe la posibilele zgomote introduse din exterior, precum și o performanță cât mai bună și independentă de baza de date, astfel încât sistemul să ofere rezultate corecte pentru orice utilizator.

A3.2 Implementarea modului de extragere de trăsături

O etapă importantă în procesul realizării unui clasificator este extragerea de trăsături. Acestea oferă o reprezentare optimală a datelor și ajută la găsirea unui hiper-plan care separă exemplele corespondente claselor de interes. În practică, pentru clasificarea datelor EMG se pot extrage trăsături în timp, frecvență sau timp-frecvență. Totuși, caracteristicile asociate cu domeniul frecvență sau timp-frecvență durează mai mult pentru a fi calculate comparativ cu cele de timp. Prin urmare, pentru a urmări o abordare de clasificator care să funcționeze în timp real, proiectul EMGP-AI s-a concentrat în principal pe trăsături în timp de o complexitate matematică scăzută.

Pentru a oferi o reprezentare a datelor electromiografice care să încorporeze aspecte cât mai variate cu privire la evoluția semnalului în timp, au fost alese 8 trăsături. Acestea sunt detaliate mai jos:

1. **Mean Absolute Value (MAV)** – valoarea medie absolută

$$\text{MAV}(x) = \frac{1}{K} \sum_{k=0}^{K-1} |x_k|. \quad (1)$$

2. **Zero Crossing Rate (ZCR)** – rata de treceri prin zero. Această trăsătură înnumără de câte ori semnalul trece prin valoarea 0. În practică se folosește o valoare de prag $\alpha \geq 0$ astfel încât să fie minimizat efectul zgomotului. Din punct de vedere matematic, ZCR poate fi definit astfel:

$$\text{ZCR}(x) = \left| \{k \in \{1, \dots, K-1\} \mid |x_k - x_{k-1}| \geq \alpha \text{ și } x_k x_{k-1} < 0\} \right|. \quad (2)$$

3. **Waveform Length (WL)** – această trăsătură oferă o caracterizare simplă a formei de undă aferentă semnalului. Corespunde cu următoarea variație a seminorme:

$$\text{WL}(x) = \sum_{k=1}^{K-1} |x_k - x_{k-1}|. \quad (3)$$

4. **Slope Sign Changes (SSC)** – măsoară frecvența cu care semnul pantei semnalului se schimbă. Pentru a verifica acest lucru, este suficient să se verifice o condiție la nivelul a 3 eșantioane consecutive x_k, x_{k-1}, x_{k+1} unde $k \in \{2, \dots, K-2\}$:

$$\text{SSC}(x) = \left| \{k \in \{2, \dots, K-2\} \mid (x_k - x_{k-1})(x_k - x_{k+1}) \geq \alpha\} \right|, \quad (4)$$

valoarea de prag $\alpha > 0$ este folosită pentru a minimiza influența zgomotului.

5. **Root Mean Square (RMS)** – această trăsătură, care de asemenea este legată de media pătratică sau de energia locală a semnalului este dată de formula:

$$\text{RMS}(x) = \sqrt{\frac{1}{K} \sum_{k=0}^{K-1} x_k^2}. \quad (5)$$

6. **Parametri Hjorth** – reprezintă un set de 3 trăsături care au fost dezvoltate pentru caracterizarea semnalului electroencefalografic dar sunt folosite cu succes și în cazul semnalului sEMG (*surface EMG*). Cel mai relevant parametru Hjorth este descris ca puterea spectrală integrată și corespunde cu varianța semnalului:

$$\sigma^2(x) = \frac{1}{K} \sum_{k=0}^{K-1} (x_k - \mu(x))^2, \quad (6)$$

unde $\mu(x)$ reprezintă media semnalului. Deviația standard și $\text{RMS}(x)$ sunt egale atunci când media este 0.

7. **Skewness** – măsoară asimetria generală a distribuției de probabilitate a semnalului:

$$\text{Skew}(x) = \frac{1}{K} \sum_{k=0}^{K-1} \left(\frac{x_k - \mu(x)}{\sigma(x)} \right)^3. \quad (7)$$

8. **Integrated Square-root EMG (ISEMG)** – este o trăsătură care oferă suma radicalilor valorilor absolute ale eșantioanelor semnalului:

$$\text{ISEMG}(x) = \sum_{k=0}^{K-1} \sqrt{|x_k|}. \quad (8)$$

Mai exact, pentru a crea un vector de trăsături pentru fiecare canal EMG, au fost concatenate cele 8 trăsături descrise mai sus. Prin urmare, unui exemplu de înregistrare EMG îi corespunde un vector de trăsături de dimensiunea 64 (8 canale \times 8 trăsături). Trăsăturile au fost extrase din ferestre de timp de 250 de milisecunde cu suprapunere de 50%¹.

Pe lângă abordarea bazată pe caracteristici în domeniul timp, a fost testată și o metodă de extragere de trăsături care presupune aplicarea transformatei Fourier asupra semnalelor. Mai exact, s-a calculat transformata Fourier de scurtă durată (*eng. Short Time Fourier Transform – STFT*) în 128 de puncte. Fereastra folosită a fost de tip Hanning. Aceasta a fost aplicată la fiecare 125 de eșantioane (echivalentul în timp a 250 de milisecunde, frecvența de eșantionare fiind 500Hz).

Pentru a ilustra beneficiile aduse de etapa de extragere de trăsături, echipa noastră a testat și o variantă de arhitectură de rețea neurală care primește la intrare datele neprelucrate. Având în vedere corelația temporală puternică între eșantioanele aferente aceleiași înregistrări, o rețea de timp LSTM (*eng. Long Short Term Memory*) s-ar preta, cel puțin în teorie, pe sarcina de față. Rezultatele obținute cu datele neprelucrate, cu trăsăturile în frecvență și respectiv în timp sunt prezentate în secțiunea **A3.5 Validarea experimentală a sistemului de recunoaștere automată a gesturilor**.

Codul aferent implementării de trăsături se găsește la pagina de `gitlab` a proiectului la adresa: <https://gitlab.upb.ro/mnegru/emg>

A3.3 Proiectarea arhitecturii și implementarea clasificatorului

Pentru sistemul de clasificare am decis implementarea a trei variante de rețele neurale, fiecare dintre ele având la intrare o reprezentare diferită a semnalului EMG.

Primul astfel de clasificator a fost proiectat pentru a lucra cu semnale neprelucrate (*eng. raw data*). Datorită faptului că există o corelație temporală între eșantioanele semnalelor EMG, s-a implementat o rețea neurală recurentă cu ajutorul celulei LSTM. Rețeaua este similară cu cea prezentată în [40], principalele diferențe fiind: împărțirea semnalului în ferestre disjuncte de 20 de eșantioane (echivalentul a 40ms), respectiv păstrarea doar ultimei ieșiri temporale a stratului recurent. Astfel, rețeaua a obținut o acuratețe de 80.62% pe datele de testare.

În continuare am decis să investigăm dacă spectrul semnalului poate fi folosit ca intrare pentru clasificator. Semnalul a fost împărțit în ferestre de 125 eșantioane (echivalentul a 250ms) cu suprapunere de 50%, iar pentru fiecare fereastră s-a aplicat transformata Fourier rapidă, obținându-se o fereastră de spectru care va fi intrarea pentru modelul de clasificare. Din moment ce spectrul conține informație corelată cu vecinii apropiați, am decis să folosim straturi de convoluție în timp (1D). Astfel, am construit un bloc format dintr-un strat convoluțional 1D activat de funcția ReLU (*eng. Rectified Linear Unit*) urmat de o operație de normalizare și o operație de *max pooling* unidimensională. În rețea, au fost înlănțuite șase astfel de blocuri, urmate de două straturi complet conectate. Rețeaua este prezentată și în Figura 2. Acuratețea maximă pe datele de testare a fost de 97.52% pentru această rețea.

Ultima abordare s-a bazat pe trăsături temporale extrase din ferestre cvasi-staționare. În mod similar cu exemplul anterior, semnalul a fost împărțit în ferestre de 250 eșantioane (echivalentul a 500ms) cu suprapunere de 50% și pentru fiecare fereastră au fost calculate trăsăturile temporale

¹Suprapunerea a avut drept scop augmentarea datelor.

menționate în subcapitolul anterior. Am ales aceste trăsături deoarece oferă rezultate bune și se pot calcula rapid de către procesor. Datorită experienței anterioare cu semnale EMG, am pornit de la arhitectura modelului pe care l-am obținut anterior și adaptat-o pentru noul set de date. Mai precis, am înlocuit numărul de neuroni de pe ultimul strat ce realiza clasificarea (întrucât acum avem un număr mai mare de clase). Astfel, modelul învață să asocieze trăsăturile extrase din semnalul EMG cu clasa dorită la ieșire (*eng. end-to-end model*). Se obține astfel cea mai bună acuratețe, de 98.67%, ceea ce arată faptul că trăsăturile alese în domeniul timp sunt relevante pentru a discrimina gesturile executate printr-un sistem automat. Arhitectura completă a rețelei este prezentată în Figura 3.




Figura 2: Arhitectura generală a EMG-CNN. Blocul **A** conține următoarele: un strat convoluțional 1D, urmat de activare ReLU, *batch normalization* și o operație de *max pooling*. După fiecare bloc **A** numărul de filtre este dublat. Operația de *max pooling* realizează înjumătățirea dimensiunilor. Blocul **FC** reprezintă un strat complet conectat (*eng. fully connected*).




Figura 3: Arhitectura generală a EMG-DNN-15. Blocul **B** este format din următoarele componente: un strat complet conectat cu 128 neuroni, un strat de *dropout*, un strat de tipul *batch normalization* și activare LeakyReLU cu parametrul $\alpha = 0.1$. Blocurile de tip **C** sunt formate din următoarele: un strat complet conectat (cu 64, 32 sau 16 neuroni), strat pentru *batch normalization* și activare LeakyReLU ($\alpha = 0.1$)

A3.4 Asigurarea robusteții

După cum s-a prezentat în secțiunea **A3.1 Dezvoltarea unui raport privind starea artei**, un astfel de sistem bazat pe semnale EMG trebuie să fie rezistent la perturbații exterioare, fie introduse în mod intenționat (atacuri adversariale), fie produse în mod natural (zgomot provenit de la dispozitivul de achiziție, din cauza senzorilor de contact, firelor de păr, etc.). Altfel spus, trebuie asigurată robustețea modelului antrenat cu scopul de clasifica gesturile executate astfel încât să poată funcționa în orice situație și pentru orice utilizator.

În [28] se arată faptul că robustețea rețelelor împotriva exemplurilor adversariale este puternic corelată cu comportamentul Lipschitz al acestora. Constanta Lipschitz a rețelei ne permite să aflăm limita superioară a unei perturbații de intrare care să nu modifice semnificativ ieșirea. Controlul acestei constante reprezintă o soluție fezabilă pentru a limita efectul exemplurilor adversariale. Calculul exact al constantei Lipschitz pentru o rețea neuronală este o problemă complexă, astfel încât provocarea este de a găsi strategii inteligente pentru a o aproxima corect.

Deși există algoritmi pentru a asigura stabilitatea Lipschitz a rețelelor neuronale, am decis să explorăm asigurarea robusteții prin folosirea unei noi scheme de antrenare a rețelelor. Ne dorim să antrenăm rețelele sub constrângeri de normă spectrală care să asigure un bun echilibru între acuratețe și robustețe. Pentru a asigura o bună aproximare a constantei Lipschitz a rețelei, vom lucra cu rețele ce au ponderi non-negative. Pentru a înțelege principiul pe care se bazează metoda propusă, considerăm o rețea neurală ca fiind modelată printr-o compoziție de operatori $T = T_m \circ \dots \circ T_1$, unde m reprezintă numărul de straturi din rețea. Fie vectorul x intrarea în rețea și $T(x)$ ieșirea din rețea. Dacă intrarea este afectată de un zgomot aditiv:

$$\tilde{x} = x + z,$$

atunci ieșirea rețelei respectă inegalitatea:

$$\|T(\tilde{x}) - T(x)\| \leq \theta_m \|z\|, \quad (9)$$

unde $\theta_m \geq 0$ denotă constanta Lipschitz a rețelei care permite controlul sensibilității rețelei la diverse perturbații. O aproximare uzuală a acesteia este:

$$\theta_m = \prod_{i=1}^m \|W_i\|_S, \quad (10)$$

unde $\|\cdot\|_S$ denotă norma spectrală a unei matrici. În articolul dezvoltat de echipă în cadrul proiectului EMGP-AI [54] se arată faptul că o aproximare exactă a constantei Lipschitz a unei rețele neurale directe cu parametri non-negativi este:

$$\vartheta_m = \|W_m \cdots W_1\|_S$$

Algoritmul standard de antrenare a rețelelor neuronale constă în minimizarea unei funcții de cost ținând cont de parametrii modelului și folosind un algoritm iterativ. Pentru a asigura robustețea, se impune o constrângere asupra normei spectrale pentru matricile ponderi. Mai specific, s-a implementat o variantă modificată a gradientului stocastic: după pasul clasic de actualizare a valorilor ponderilor se calculează o proiecție a ponderilor pe setul de constrângeri.

Prima constrângere pe care o impunem este cea de non-negativitate a tuturor matricilor pondere din rețea:

$$\mathcal{D}_i = \{W_i \in \mathbb{R}^{N_i \times N_{i-1}} \mid W_i \geq 0\} \quad (11)$$

A doua constrângere, pentru a controla robustețea rețelei la exemple adversariale, este dată de limita superioară a constantei Lipschitz $\bar{\vartheta}$:

$$\|W_m \cdots W_1\|_S \leq \bar{\vartheta}, \quad (12)$$

În cadrul antrenării trebuie să ținem cont de ambele constrângeri în mod simultan. Forțarea non-negativității este simplă întrucât este o constrângere convexă. Pe de altă parte, există mai multe proiecții care să respecte limita superioară a constantei Lipschitz. Se introduce astfel următoarea mulțime închisă și convexă:

$$\mathcal{C}_{i,n} = \{W_i \in \mathbb{R}^{N_i \times N_{i-1}} \mid \|A_{i,n} W_i B_{i,n}\|_S \leq \bar{\vartheta}\} \quad (13)$$

unde $A_{i,n}$ reprezintă produsul matricilor ponderi deja proiectate iar $B_{i,n}$ produsul matricilor ponderi ce urmează să fie proiectate. În [54] este prezentat algoritmul de antrenare care ține cont de aceste constrângeri.

O aproximare grosieră, standard a constantei Lipschitz a rețelei este dată de produsul normelor spectrale, aproximare ce poate fi aplicată și rețelelor ce conțin ponderi cu semn arbitrar. Deși controlul individual al fiecărei norme este o soluție mai simplă din punct de vedere computațional, această aproximare reprezintă de fapt doar o limită superioară a constantei reale. Pentru a implementa și această metodă putem impune în timpul antrenării următoarea condiție:

$$\prod_{i=1}^m \|W_i\|_S \leq \bar{\vartheta}. \quad (14)$$

Două strategii au fost implementate pentru a impune această constrângere. Prima a constat în a impune aceeași constrângere la nivelul fiecărei matrici pondere:

$$(\forall i \in \{1, \dots, m\})$$

$$\tilde{\mathcal{C}}_i = \{W_i \in \mathbb{R}^{N_i \times N_{i-1}} \mid \|W_i\|_S \leq \tilde{\vartheta}^{1/m}\}. \quad (15)$$

A doua strategie oferă o flexibilitate mai mare pentru norma matricilor ponderi și se bazează pe următoarea mulțime convexă:

$$(\forall n \in \mathbb{N} \setminus \{0\})(\forall i \in \{1, \dots, m\})$$

$$\tilde{\mathcal{C}}_{i,n} = \left\{ W_i \in \mathbb{R}^{N_i \times N_{i-1}} \mid \|W_i\|_S \leq \|W_{i,n}\|_S \left(\frac{\vartheta}{\prod_{j=1}^m \|W_{j,n}\|_S} \right)^{1/m} \right\}. \quad (16)$$

Calculul proiecției pe setul de constrângeri $\mathcal{P}_{S_{i,n}}$ poate fi o operație complexă motiv pentru care s-a explorat și folosirea unei proiecții approximate:

$$(\forall W \in \mathbb{R}^{N_i \times N_{i-1}}) \quad \tilde{\mathcal{P}}_{S_{i,n}}(W) \simeq \begin{cases} W & \text{if } \|W\|_S \leq \tilde{\vartheta} \\ \frac{\tilde{\vartheta}}{\|W\|_S} W & \text{în rest.} \end{cases} \quad (17)$$

Folosirea proiecției approximate nu mai garantează convergența algoritmilor de antrenare, deși noi nu am observat acest lucru în testele noastre. Totuși, un avantaj al acesteia este dat de faptul că elementele non-negative rămân non-negative.

După stabilirea contextului matematic al constantei Lipschitz în asigurarea robusteții, s-a trecut la etapa de testare într-un scenariu practic. Pentru a verifica performanța în ceea ce privește robustețea, a fost dezvoltată o rețea neurală care a fost folosită în acest sens. Arhitectura folosită este ilustrată în Figura 4.

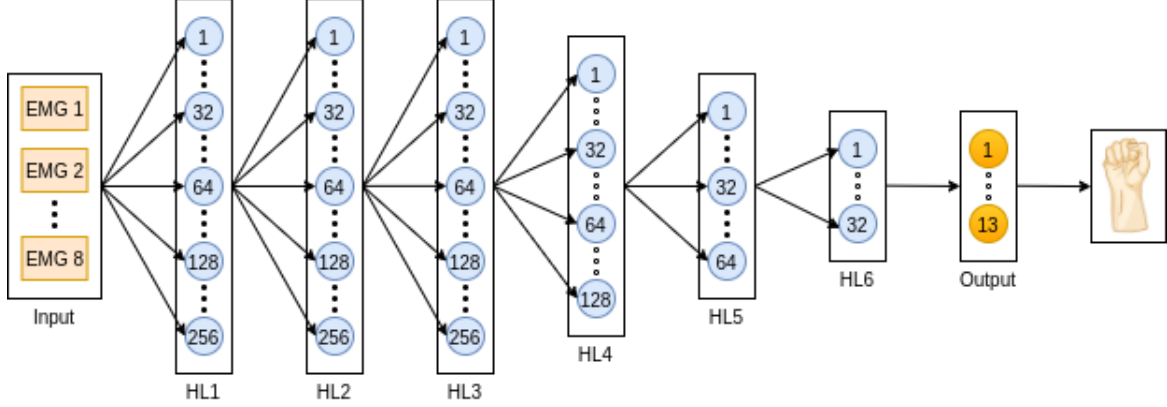


Figura 4: Arhitectura propusă în cazul testării robusteții. Toate straturile mai puțin ultimul folosesc activarea ReLU; ultimul strat folosește Softmax. Numărul de neuroni ai fiecărui strat sunt: 128, 128, 128, 64, 32, 16, în cazul bazei de date cu 7 gesturi și 256, 256, 256, 128, 64, 32 în cazul bazei de date cu 13 gesturi. Ultimul strat are 7 sau 13 neuroni în funcție de numărul de gesturi clasificate. Fiecare bloc EMG reprezintă un vector coloană conținând 8 trăsături în timp.

Rezultatele numerice aferente testării robusteții sunt prezentate și comentate în secțiunea **A3.5 Validarea experimentală a sistemului de recunoaștere automată a gesturilor.**

A3.5 Validarea experimentală a sistemului de recunoaștere automată a gesturilor

Pentru a valida sistemul de clasificare dezvoltat în cadrul proiectului EMGP-AI s-au considerat metricile de acuratețe și \mathcal{K} -index. Formula pentru metrica din urmă este prezentată mai jos:

$$\mathcal{K}\text{-index} = \frac{\frac{1}{N} \sum_{i=1}^l C_{ii} - \frac{1}{N^2} \sum_{i=1}^l C_{i+} C_{+i}}{1 - \frac{1}{N^2} \sum_{i=1}^l C_{i+} C_{+i}}, \quad (18)$$

unde C este matricea de confuzie, N este numărul total de exemple, l este numărul de categorii de gesturi iar C_{i+} și C_{+i} se calculează astfel:

$$C_{i+} = \sum_{j=1}^l C_{ij} \quad (19)$$

$$C_{+i} = \sum_{j=1}^l C_{ji} \quad (20)$$

Tabela 1 prezintă o comparație între rezultatele obținute cu trăsături în timp, cu date neprelucrate și cu transformata Fourier. Bazele de date folosite sunt cele cu 7 gesturi [17] și cea achiziționată în cadrul proiectului EMGP-AI cu 15 gesturi. Experimentele noastre au arătat că cele mai bune rezultate se obțin folosind trăsături de timp ale datelor. Arhitectura EMG-DNN (figura 3) dezvoltată de noi oferă rezultate mai bune pe ambele baze de date (cea de 7 gesturi și cea de 15 gesturi). Se poate remarca că deși noua bază de date are dublul numărului de gesturi a primei, rezultatele bune se conservă cu EMG-DNN (98.67% în comparație cu 99.78% [55]). Totuși, atunci când se folosește rețeaua EMG-LSTM [40], acuratețea are o scădere semnificativă (de la 95.79% la 80.62%). Acest lucru arată că semnalul EMG în forma originală nu este adecvat pentru clasificarea unui număr mare de gesturi.

De asemenea, se poate observa că datele colectate cu dispozitivul nostru de achiziție (cel cu care s-a achiziționat baza de date cu 15 gesturi) sunt mai bine clasificate atunci când se analizează componentele spectrale. Acest lucru este datorat faptului că echipa noastră a folosit o frecvență de eșantionare mai mare, prin urmare achiziția a fost făcută cu o mai bună reprezentare a semnalului în frecvență.

Baza de date	Rețea neurală	Acuratețe [%]	\mathcal{K} -index
7 gesturi [17]	EMG-LSTM [40]	95.79	0.9862
	EMG-CNN	95.07	0.9971
	EMG-DNN-7 [55]	99.78	0.9975
15 gesturi	EMG-LSTM [40]	80.62	0.9337
	EMG-CNN	97.52	0.9812
	EMG-DNN-15	98.67	0.9716

Tabela 1: Rezultate pentru setul de date de test. Sunt raportate valorile pentru acuratețe și \mathcal{K} -index care au fost obținute cu cele 3 metode folosite.

O altă componentă a proiectului EMGP-AI care a fost validată experimental este cea legată de asigurarea robusteții.

		Acuratețe	75 %	80 %	85 %	90 %	95%
Constanta Lipschitz	$\tilde{\mathcal{C}}_i \cap \mathcal{D}_i$	$\tilde{P}_{\tilde{\mathcal{C}}_i \cap \mathcal{D}_i}$	19.5	37.5	68.3	3.5×10^4	3.5×10^8
		$P_{\tilde{\mathcal{C}}_i \cap \mathcal{D}_i}$	0.66	13.47	74.16	1.04×10^3	1.39×10^5
	$\check{\mathcal{C}}_{i,n} \cap \mathcal{D}_i$	$\tilde{P}_{\check{\mathcal{C}}_{i,n} \cap \mathcal{D}_i}$	0.71	1.84	3.42	6.87	11.60
		$P_{\check{\mathcal{C}}_{i,n} \cap \mathcal{D}_i}$	0.70	1.35	3.41	6.79	11.20
	$\mathcal{C}_{i,n} \cap \mathcal{D}_i$	$\tilde{P}_{\mathcal{C}_{i,n} \cap \mathcal{D}_i}$	0.44	1.79	2.93	4.85	5.68
		$P_{\mathcal{C}_{i,n} \cap \mathcal{D}_i}$	0.35	0.46	0.65	0.82	0.95

Tabela 2: Constanta Lipschitz obținută cu diferite strategii de optimizare constrânse pentru niveluri diferite ale acurateții – baza de date cu 7 gesturi.

Tabela 2 și tabela 3 prezintă valorile pentru constanta Lipschitz atunci când se obține o anumită acuratețe pe setul de testare. Antrenarea s-a realizat impunând o anumită limită superioară pentru constanta Lipschitz. Se poate observa faptul că se poate atinge o acuratețe de 95% cu o constantă Lipschitz apropiată de valoarea 1 pentru constrângerea dată de formula 11. Folosirea proiecției approximate oferă constante mai mari, dar timpul de antrenare este mai mic.

		Acuratețe	75 %	80 %	85 %	90 %	95%
Constanta Lipschitz	$\tilde{\mathcal{C}}_i \cap \mathcal{D}_i$	$\tilde{P}_{\tilde{\mathcal{C}}_i \cap \mathcal{D}_i}$	20.2	41.8	145.2	2.2×10^5	1.21×10^{11}
		$P_{\tilde{\mathcal{C}}_i \cap \mathcal{D}_i}$	0.85	20.47	112.3	1.62×10^4	2.31×10^8
	$\check{\mathcal{C}}_{i,n} \cap \mathcal{D}_i$	$\tilde{P}_{\check{\mathcal{C}}_{i,n} \cap \mathcal{D}_i}$	0.84	2.08	4.23	7.54	12.02
		$P_{\check{\mathcal{C}}_{i,n} \cap \mathcal{D}_i}$	0.81	2.01	4.12	7.50	11.92
	$\mathcal{C}_{i,n} \cap \mathcal{D}_i$	$\tilde{P}_{\mathcal{C}_{i,n} \cap \mathcal{D}_i}$	0.54	1.87	3.38	4.20	5.78
		$P_{\mathcal{C}_{i,n} \cap \mathcal{D}_i}$	0.49	0.53	0.75	0.92	1.25

Tabela 3: Constanta Lipschitz obținută cu diferite strategii de optimizare constrânse pentru niveluri diferite ale acurateții – baza de date cu 13 gesturi.

		Acuratețe	75%	80%	85%	90%	95%
Constanta Lipschitz	\mathcal{C}_i	$\tilde{P}_{\tilde{\mathcal{C}}_i}$	72.03	127.5	1296	8.75×10^4	5.43×10^9
		$P_{\tilde{\mathcal{C}}_i}$	52.06	102.49	905.45	7.23×10^4	8.14×10^8
	<i>Deel-lip</i> [83]	75.81	126.9	1283.6	8.70×10^4	5.43×10^9	

Tabela 4: Constanta Lipschitz pentru rețele antrenate cu gesturi arbitrare – baza de date cu 7 gesturi

		Acuratețe	75%	80%	85%	90%	95%
Constanta Lipschitz	\mathcal{C}_i	$\tilde{P}_{\tilde{\mathcal{C}}_i}$	76.59	125.20	1016	2.03×10^4	4.3×10^8
		$P_{\tilde{\mathcal{C}}_i}$	61.22	99.74	740	1.26×10^4	6.7×10^7
	<i>Deel-lip</i> [83]	77.21	125.63	1120	2.04×10^4	4.5×10^8	

Tabela 5: Constanta Lipschitz pentru rețele antrenate cu gesturi arbitrare – baza de date cu 13 gesturi.

Atac	Acuratețe [%]					
	model robust		modelul de referință			
	adversarial	non-adversarial	adversarial	non-adversarial	adversarial	non-adversarial
FGSM [28]	91.75	92.95	76.48	99.78	71.21	92.99
C&W ℓ_∞ [12]	90.09		48.03		45.85	
PGD [48]	91.92		59.36		56.38	
JSMA [61]	91.10		89.37		81.27	

Tabela 6: Rezultatele atacurilor de tip „cutie-albă” pentru modele constrânse și neconstrânse

Tabela 4 și tabela 5 prezintă valorile pentru constanta Lipschitz atunci când se renunță la constrângerea de non-negativitate. Datorită timpului mare de antrenare, am folosit doar proiecția aproximată. Rezultatele noastre sunt similare cu cele raportate în [83], dar mai slabe decât folosirea ambelor constrângeri.

Tabela 6 prezintă rezultatele la atacuri adversariale. Folosim ca modele de referință cel mai bun model pe care l-am avut și un model cu rezultate similare cu cel antrenat cu constrângeri. Indiferent de atacul folosit, acuratețea modelului antrenat cu constrângeri rămâne peste 90.00% în timp ce acuratețea modelelor de referință scade semnificativ la anumite atacuri.

Figura 5 prezintă rezultatele modelului atunci când semnalul este afectat aditiv de un zgomot normal. Antrenăm modelul în mod normal, în mod constrâns și în mod adversarial. Antrenarea adversarială constă în folosirea atât datelor afectate de zgomot cât și a celor originale. Se observă faptul că antrenarea cu constrângeri este mereu cea mai bună variantă.

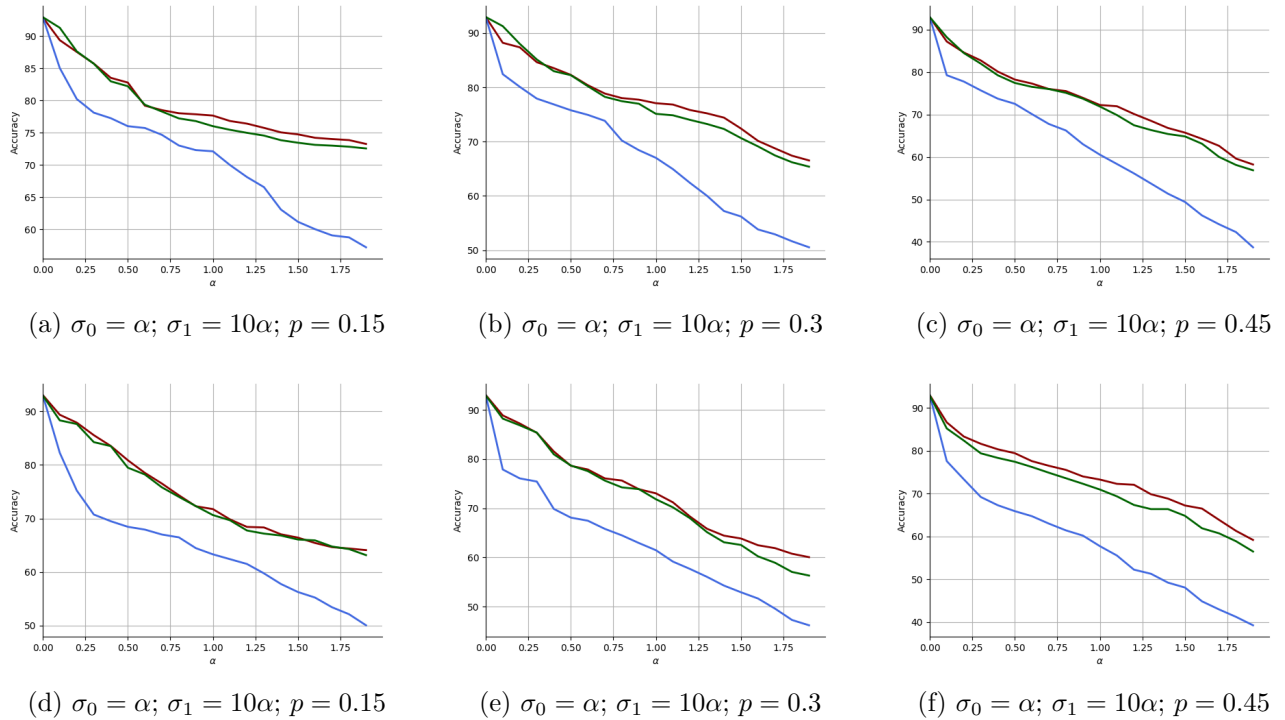


Figura 5: Acuratețe raportat la α în contextul antrenării cu date zgomotoase. Prima linie: baza de date cu 7 gesturi; a doua linie: baza de date cu 13 gesturi. Linia roșie: model robust; linie albastră: model de referință; linie verde: modelul antrenat în mod adversarial.

A3.6 Diseminare și raportare – partea II

Prima activitate a acestei etape a constat în realizarea unui *state-of-the-art* actualizat. Documentația cuprinzând starea artei se găsește în cadrul acestui raport la secțiunea A3.1 Dezvoltarea unui raport privind starea artei.

Întregul cod aferent cumulului de activități cuprinzând extragerea de trăsături, antrenarea rețelelor și testarea robusteții sunt disponibile online la adresa de [gitlab: https://gitlab.upb.ro/mnegru/emg](https://gitlab.upb.ro/mnegru/emg).

De asemenea, în cadrul părții a doua a activității de diseminare și raportare a proiectului EMGP-AI au fost concepute 2 materiale științifice. Un jurnal ce a fost trimis către Elsevier – Pattern Recognition intitulat *EMG-Based Automatic Gesture Recognition Using Robust Neural Networks* și care este momentan în procesul de revizie. De asemenea, a fost prezentat articolul *Automatic gesture recognition framework based on forearm EMG activity* în cadrul unei conferințe de specialitate în domeniul procesării de semnal, 45th International Conference on Telecommunications and Signal Processing (TSP).

Concluzii

La finalul proiectului EMGP-AI se poate concluziona asupra principalelor obiective atinse. În primul rând a fost dezvoltat un dispozitiv de înregistrare a semnalelor EMG sub forma unei brățări portabile, apoi cu ajutorul acestei a fost achiziționată o bază de date amplă, iar în cele din urmă au fost folosite tehnici de învățare automată pentru a clasifica datele într-un mod robust și performant.

Etape de proiectare și realizare al sistemului propriu de achiziție a semnalelor electromiografice a fost îndeplinit cu succes iar produsul final este eficient, comod de purtat pentru utilizator și poate înregistra datele cu o frecvență de eșantionare suficient de mare încât să cuprindă particularitățile semnalului biomedical analizat.

În ceea ce privește baza de date, aceasta a fost concepută pentru a cuprinde gesturi cu o utilitate zilnică extinsă iar numărul de participanți să fie suficient de mare astfel încât setul de semnale EMG să fie cât mai variat. Mai exact, au fost înregistrate 15 gesturi diferite de la 50 de participanți.

Analiza folosind tehnici de *machine learning* a datelor EMG a avut 2 componente principale. Prima a constat în dezvoltarea unui sistem de clasificare care să aibă o acuratețe maximizată. În cadrul acestei etape s-a ajuns la o performanță a sistemului de 98.67%. Cea de-a doua componentă s-a concentrat pe studiul robusteții sistemului prin analiza constantei Lipschitz.

În concluzie, proiectul EMGP-AI a constat în dezvoltarea unui modul de achiziție sub forma unei brățări, în achiziția unei baze de date EMG ample atât din punct de vedere al numărului de gesturi cât și al numărului de participanți și în analiza datelor folosind tehnici de învățare automată pentru a clasifica semnalele electromiografice achiziționate.

Locuri de muncă susținute prin program

Față de etapa precedentă a proiectului, echipa de cercetare nu s-a modificat. Componenta acestuia rămâne cea prezentată în tabelul 7.

Nr.	Nume	Calitatea	Poziție	Normă
1	Corneliu BURILEANU	Prof. Univ.	Director proiect	Parțială
2	Anamaria RĂDOI	Conf. Univ	Membru cercetător	Parțială
3	Ana NEACȘU	ACS	Membru doctorand	Parțială
4	George CIOROIU	ACS	Membru doctorand	Parțială
5	Cristina ANDRONACHE	ACS	Membru cercetător	Parțială
6	Marian NEGRU	ACS	Membru cercetător	Parțială
7	Georgian NICOLAE	ACS	Membru cercetător	Parțială

Tabela 7: Echipa de cercetare

Bibliografie

- [1] Ali H Al-Timemy, Guido Bugmann, Javier Escudero, and Nicholas Outram. A preliminary investigation of the effect of force variation for myoelectric control of hand prosthesis. In *2013 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, pages 5758–5761. IEEE, 2013.
- [2] Cemil Altin and O Er. Designing wearable joystick and performance comparison of emg classification methods for thumb finger gestures of joystick control. *Biomed Res India*, 28:4730–4736, 2017.
- [3] Sebastian Amsüss, Liliana P Paredes, Nina Rudigkeit, Bernhard Graimann, Michael J Herrmann, and Dario Farina. Long term stability of surface emg pattern classification for prosthetic control. In *2013 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, pages 3622–3625. IEEE, 2013.
- [4] Cristina Andronache, Marian Negru, Ana Neacsu, George Cioroiu, Anamaria Radoi, and Corneliu Burileanu. Towards extending real-time EMG-based gesture recognition system. In *2020 43rd International Conference on Telecommunications and Signal Processing (TSP)*, pages 301–304. IEEE, 2020.
- [5] Cem Anil, James Lucas, and Roger Grosse. Sorting out Lipschitz function approximation. In *Proc. Int. Conf. Mach. Learn.*, pages 291–301, Long Beach, California, USA, 9–15 Jun 2019.
- [6] Ray Antonius and Hendra Tjahyadi. Electromyography gesture identification using cnn-rnn neural network for controlling quadcopters. In *Journal of Physics: Conference Series*, volume 1858, page 012075. IOP Publishing, 2021.

- [7] Manfredo Atzori, Arjan Gijsberts, Claudio Castellini, Barbara Caputo, Anne-Gabrielle Mittaz Hager, Simone Elsig, Giorgio Giatsidis, Franco Bassetto, and Henning Müller. Electromyography data for non-invasive naturally-controlled robotic hand prostheses. *Scientific data*, 1(1):1–13, 2014.
- [8] Joseph L Betthausen, Christopher L Hunt, Luke E Osborn, Rahul R Kaliki, and Nitish V Thakor. Limb-position robust classification of myoelectric signals for prosthesis control using sparse representations. In *2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, pages 6373–6376. IEEE, 2016.
- [9] Reza Boostani and Mohammad Hassan Moradi. Evaluation of the forearm emg signal features for the control of a prosthetic hand. *Physiological measurement*, 24(2):309, 2003.
- [10] Alexander Boschmann, Paul Kaufmann, Marco Platzner, and Michael Winkler. Towards multi-movement hand prostheses: Combining adaptive classification with high precision sockets. In *Proceedings of the 2nd European Conference Technically Assisted Rehabilitation*. Citeseer, 2009.
- [11] Nicholas Carlini, Pratyush Mishra, Tavish Vaidya, Yuankai Zhang, Micah Sherr, Clay Shields, David Wagner, and Wenchao Zhou. Hidden voice commands. In *USENIX Security Symp.*, pages 513–530, Austin, TX, USA, 10–12 Aug 2016.
- [12] Nicholas Carlini and David Wagner. Towards evaluating the robustness of neural networks. In *IEEE Symp. Security Privacy*, pages 39–57, San Jose, CA, USA, 22–24 May 2017.
- [13] Liang Chen, Yanjuan Geng, and Guanglin Li. Effect of upper-limb positions on motion pattern recognition using electromyography. In *2011 4th International Congress on Image and Signal Processing*, volume 1, pages 139–142. IEEE, 2011.
- [14] Ming Jin Cheok, Zaid Omar, and Mohamed Hisham Jaward. A review of hand gesture and sign language recognition techniques. *Int. J. Mach. Learn. Cyber.*, 10(1):131–153, 2019.
- [15] Rubana H Chowdhury, Mamun BI Reaz, Mohd Alauddin Bin Mohd Ali, Ashrif AA Bakar, Kalai-vani Chellappan, and Tae G Chang. Surface electromyography signal processing and classification techniques. *Sensors*, 13(9):12431–12466, 2013.
- [16] Moustapha Cisse, Piotr Bojanowski, Edouard Grave, Yann Dauphin, and Nicolas Usunier. Par-seval networks: Improving robustness to adversarial examples. In *Proc. Int. Conf. Mach. Learn.*, pages 854–863, Sydney, NSW, Australia, 06–11 Aug 2017.
- [17] Ulysse Côté-Allard, Cheikh Latyr Fall, Alexandre Drouin, Alexandre Campeau-Lecours, Clément Gosselin, Kyrre Glette, François Laviolette, and Benoit Gosselin. Deep learning for electromyographic hand gesture signal classification using transfer learning. *IEEE transactions on neural systems and rehabilitation engineering*, 27(4):760–771, 2019.
- [18] Trevor J Darrell, Irfan A Essa, and Alex P Pentland. Task-specific gesture analysis in real-time using interpolated views. *IEEE Trans. Pattern Anal. Mach. Intell.*, 18(12):1236–1242, 1996.
- [19] Carlo J De Luca, L Donald Gilmore, Mikhail Kuznetsov, and Serge H Roy. Filtering the surface emg signal: Movement artifact and baseline noise contamination. *Journal of biomechanics*, 43(8):1573–1579, 2010.
- [20] Kevin Englehart and Bernard Hudgins. A robust, real-time control scheme for multifunction myoelectric control. *IEEE transactions on biomedical engineering*, 50(7):848–854, 2003.
- [21] Mahyar Fazlyab, Alexander Robey, Hamed Hassani, Manfred Morari, and George Pappas. Efficient and accurate estimation of lipschitz constants for deep neural networks. In *Adv. Neural Info. Process. Syst.*, pages 11423–11434, Vancouver, Canada, 08–14 Dec. 2019.

- [22] Anders Fougner, Erik Scheme, Adrian DC Chan, Kevin Englehart, and Øyvind Stavdahl. Resolving the limb position effect in myoelectric pattern recognition. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 19(6):644–651, 2011.
- [23] Graham D Fraser, Adrian DC Chan, James R Green, N Abser, and Dawn MacIsaac. Cleanemg—power line interference estimation in semg using an adaptive least squares algorithm. In *2011 annual international conference of the IEEE engineering in medicine and biology society*, pages 7941–7944. IEEE, 2011.
- [24] Graham D Fraser, Adrian DC Chan, James R Green, and Dawn T MacIsaac. Automated bisignal quality analysis for electromyography using a one-class support vector machine. *IEEE Transactions on Instrumentation and Measurement*, 63(12):2919–2930, 2014.
- [25] Xiaojie Gao, Yueming Jin, Qi Dou, and Pheng-Ann Heng. Automatic gesture recognition in robot-assisted surgery with reinforcement learning and tree search. In *Proc. IEEE Int. Conf. Robot. Autom.*, pages 8440–8446, Paris, France, 31 May – 31 Aug. 2020.
- [26] Marco Gazzoni, Nicolo Celadon, Davide Mastrapasqua, Marco Paleari, Valentina Margaria, and Paolo Ariano. Quantifying forearm muscle activity during wrist and finger movements by means of multi-channel electromyography. *PloS one*, 9(10):e109943, 2014.
- [27] Yanjuan Geng, Ping Zhou, and Guanglin Li. Toward attenuating the impact of arm positions on electromyography pattern-recognition based motion classification in transradial amputees. *Journal of neuroengineering and rehabilitation*, 9(1):1–11, 2012.
- [28] Ian J. Goodfellow, Jonathon Shlens, and Christian Szegedy. Explaining and harnessing adversarial examples. In *Int. Conf. Learn. Represent.*, San Diego, CA, USA, 7–9 May 2015.
- [29] Levi Hargrove, Erik Scheme, and Kevin Englehart. Myoelectric prostheses and targeted reinnervation. *Introduction to neural engineering for motor rehabilitation*, pages 291–310, 2013.
- [30] Levi Hargrove, Erik Scheme, Kevin Englehart, and Bernie Hudgins. Filtering strategies for robust myoelectric pattern classification. *CMBES Proceedings*, 31, 2008.
- [31] Levi J Hargrove, Erik J Scheme, Kevin B Englehart, and Bernard S Hudgins. Multiple binary classifications via linear discriminant analysis for improved controllability of a powered prosthesis. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 18(1):49–57, 2010.
- [32] Hussein F Hassan, Sadiq J Abou-Loukh, and Ibraheem Kasim Ibraheem. Teleoperated robotic arm movement using electromyography signal with wearable Myo armband. *Journal of King Saud University-Engineering Sciences*, 32(6):378–387, 2020.
- [33] Jianxing He, Sally L Baxter, Jie Xu, Jiming Xu, Xingtao Zhou, and Kang Zhang. The practical implementation of artificial intelligence technologies in medicine. *Nat. med.*, 25(1):30–36, 2019.
- [34] Jiayuan He, Dingguo Zhang, Ning Jiang, Xinjun Sheng, Dario Farina, and Xiangyang Zhu. User adaptation in long-term, open-loop myoelectric training: implications for emg pattern recognition in prosthesis control. *Journal of neural engineering*, 12(4):046005, 2015.
- [35] Ning Jiang, Silvia Muceli, Bernhard Graimann, and Dario Farina. Effect of arm position on the prediction of kinematics from emg in amputees. *Medical & biological engineering & computing*, 51(1):143–151, 2013.
- [36] Rami N Khushaba, Ali Al-Timemy, Sarath Kodagoda, and Kianoush Nazarpour. Combined influence of forearm orientation and muscular contraction on emg pattern recognition. *Expert Systems with Applications*, 61:154–161, 2016.
- [37] Rami N Khushaba and Sarath Kodagoda. Electromyogram (EMG) feature reduction using mutual components analysis for multifunction prosthetic fingers control. In *Int. Conf. Control Autom. Robotics & Vision*, pages 1534–1539, Guangzhou, China, 5–7 Dec 2012.

- [38] Jonghwa Kim, Stephan Mastnik, and Elisabeth André. EMG-based hand gesture recognition for realtime biosignal interfacing. In *Proc. Int. Conf. Intell. User Interfac.*, pages 30–39, Canaria, Spain, 13–16 Jan 2008.
- [39] Jhonatan Kobylarz, Jordan J Bird, Diego R Faria, Eduardo Parente Ribeiro, and Anikó Ekárt. Thumbs up, thumbs down: Non-verbal human-robot interaction through real-time EMG classification via inductive and supervised transductive transfer learning. *Journal of Ambient Intelligence and Humanized Computing*, 11(12):6021–6031, 2020.
- [40] Philipp Koch, Mark Dreier, Marco Maass, Huy Phan, and Alfred Mertins. RNN with stacked architecture for sEMG based sequence-to-sequence hand gesture recognition. In *2020 28th European Signal Processing Conference (EUSIPCO)*, pages 1600–1604. IEEE, 2021.
- [41] Okan Kopuklu, Neslihan Kose, and Gerhard Rigoll. Motion fused frames: Data level fusion strategy for hand gesture recognition. In *Proc. IEEE Conf. Comput. Vis. Pattern Recogn.*, pages 2103–2111, Utah, USA, 19-22 Jun. 2018.
- [42] Todd A Kuiken, Laura A Miller, Robert D Lipschutz, Blair A Lock, Kathy Stubblefield, Paul D Marasco, Ping Zhou, and Gregory A Dumanian. Targeted reinnervation for enhanced prosthetic arm function in a woman with a proximal amputation: a case study. *The Lancet*, 369(9559):371–380, 2007.
- [43] Alexey Kurakin, Ian Goodfellow, and Samy Bengio. Adversarial machine learning at scale. In *Int. Conf. Learn. Represent.*, Toulon, France, 24–26 Apr 2017.
- [44] Alexey Kurakin, Zhengyou Zhang, and Zicheng Liu. A real time system for dynamic hand gesture recognition with a depth sensor. In *Proc. IEEE European Signal Processing Conf.*, pages 1975–1979, Bucharest, Romania, 27–31 Aug. 2012.
- [45] Sumantri R Kurniawan and Daniel Pamungkas. MYO armband sensors and neural network algorithm for controlling hand robot. In *2018 International Conference on Applied Engineering (ICAE)*, pages 1–6. IEEE, 2018.
- [46] Peiliang Li, Xiaozhi Chen, and Shaojie Shen. Stereo R-CNN based 3D object detection for autonomous driving. In *Proc. IEEE Conf. Comput. Vis. Pattern Recogn.*, pages 7644–7652, Long Beach, CA, USA, 16–20 Jun. 2019.
- [47] Jianwei Liu, Dingguo Zhang, Jiayuan He, and Xiangyang Zhu. Effect of dynamic change of arm position on myoelectric pattern recognition. In *2012 IEEE International Conference on Robotics and Biomimetics (ROBIO)*, pages 1470–1475. IEEE, 2012.
- [48] Aleksander Madry, Aleksandar Makelov, Ludwig Schmidt, Dimitris Tsipras, and Adrian Vladu. Towards deep learning models resistant to adversarial attacks. In *Proc. Int. Conf. Learning Representations*, Vancouver, BC, Canada, 30 Apr.–03 May 2018.
- [49] Paul McCool, Graham D Fraser, Adrian DC Chan, Lykourgos Petropoulakis, and John J Soraghan. Identification of contaminant type in surface electromyography (emg) signals. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 22(4):774–783, 2014.
- [50] Irene Mendez, Bo Winther Hansen, Christine Marie Grabow, Erik Joannes Leivsgard Smedegard, Nanna Bloch Skogberg, Xenia Jørgensen Uth, Astrid Bruhn, Bo Geng, and Ernest Nlandu Kamavuako. Evaluation of the Myo armband for the classification of hand motions. In *2017 International Conference on Rehabilitation Robotics (ICORR)*, pages 1211–1214. IEEE, 2017.
- [51] Bojan Milosevic, Elisabetta Farella, and Simone Benatti. Exploring arm posture and temporal variability in myoelectric hand gesture recognition. In *2018 7th IEEE International Conference on Biomedical Robotics and Biomechatronics (Biorob)*, pages 1032–1037. IEEE, 2018.

- [52] Anand Kumar Mukhopadhyay and Suman Samui. An experimental study on upper limb position invariant EMG signal classification based on deep neural network. *Biomedical signal processing and control*, 55:101669, 2020.
- [53] Ana Neacsu, Jean-Christophe Pesquet, and Corneliu Burileanu. Accuracy-robustness trade-off for positively weighted neural networks. In *Proc. IEEE Int. Conf. Acoust. Speech Signal Process.*, pages 8389–8393, Barcelona, Spain, 4–8 May 2020.
- [54] Ana Neacsu, Jean-Christophe Pesquet, and Corneliu Burileanu. Emg-based automatic gesture recognition using robust neural networks (extended version). *Paperprint submitted to Elsevier*, 2022.
- [55] Ana Antonia Neacsu, George Cioroiu, Anamaria Radoi, and Corneliu Burileanu. Automatic EMG-based hand gesture recognition system using time-domain descriptors and fully-connected neural networks. In *2019 42nd International Conference on Telecommunications and Signal Processing (TSP)*, pages 232–235. IEEE, 2019.
- [56] Natalia Neverova, Christian Wolf, Graham Taylor, and Florian Nebout. Moddrop: adaptive multi-modal gesture recognition. *IEEE Trans. Pattern Anal. Mach. Intell.*, 38(8):1692–1706, 2015.
- [57] Alvaro David Orjuela-Cañón, Andrés F Ruíz-Olaya, and Leonardo Forero. Deep neural network for EMG signal classification of wrist position: Preliminary results. In *IEEE Latin American Conf. Comput. Intell.*, pages 1–5, Arequipa, Peru, 8–10 Nov 2017.
- [58] Rodrigo Lício Ortolan, Ricardo Naoki Mori, Roberto R Pereira, Cristina MN Cabral, José Carlos Pereira, and Alberto Cliquet. Evaluation of adaptive/nonadaptive filtering and wavelet transform techniques for noise reduction in emg mobile acquisition equipment. *IEEE transactions on neural systems and rehabilitation engineering*, 11(1):60–69, 2003.
- [59] Mohammadreza Asghari Oskoei and Huosheng Hu. Myoelectric control systems—a survey. *Biomedical signal processing and control*, 2(4):275–294, 2007.
- [60] Francesca Palermo, Matteo Cognolato, Arjan Gijsberts, Henning Müller, Barbara Caputo, and Manfredo Atzori. Repeatability of grasp recognition for robotic hand prosthesis control based on semg data. In *2017 International Conference on Rehabilitation Robotics (ICORR)*, pages 1154–1159. IEEE, 2017.
- [61] Nicolas Papernot, Patrick McDaniel, Somesh Jha, Matt Fredrikson, Z. Berkay Celik, and Ananthram Swami. The limitations of deep learning in adversarial settings. In *IEEE Symp. Security Privacy*, Saarbrücken, Germany, 21–24May 2016.
- [62] Patricia Pauli, Anne Koch, Julian Berberich, Paul Kohler, and Frank Allgower. Training robust neural networks using Lipschitz bounds. *IEEE Control Syst. Lett.*, 6:121–126, 2021.
- [63] Angkoon Phinyomark, Evan Campbell, and Erik Scheme. Surface electromyography (emg) signal processing, classification, and practical considerations. In *Biomedical signal processing*, pages 3–29. Springer, 2020.
- [64] Angkoon Phinyomark, Huosheng Hu, Pornchai Phukpattaranont, and Chusak Limsakul. Application of linear discriminant analysis in dimensionality reduction for hand motion classification. *Measurement Science Review*, 12(3):82–89, 2012.
- [65] Angkoon Phinyomark, Chusak Limsakul, and Pornchai Phukpattaranont. Application of wavelet analysis in emg feature extraction for pattern classification. *Measurement Science Review*, 11(2):45, 2011.
- [66] Angkoon Phinyomark, Rami N. Khushaba, and Erik Scheme. Feature extraction and selection for myoelectric control based on wearable emg sensors. *Sensors*, 18(5):1615, 2018.

- [67] Angkoon Phinyomark, Asan Nuidod, Pornchai Phukpattaranont, and Chusak Limsakul. Feature extraction and reduction of wavelet transform coefficients for emg pattern classification. *Elektronika ir Elektrotechnika*, 122(6):27–32, 2012.
- [68] Angkoon Phinyomark, Pornchai Phukpattaranont, and Chusak Limsakul. A review of control methods for electric power wheelchairs based on electromyography signals with special emphasis on pattern recognition. *IETE Technical Review*, 28(4):316–326, 2011.
- [69] Angkoon Phinyomark, Pornchai Phukpattaranont, and Chusak Limsakul. Feature reduction and selection for emg signal classification. *Expert systems with applications*, 39(8):7420–7431, 2012.
- [70] Angkoon Phinyomark, Pornchai Phukpattaranont, and Chusak Limsakul. Investigating long-term effects of feature extraction methods for continuous emg pattern classification. *Fluctuation and Noise Letters*, 11(04):1250028, 2012.
- [71] Angkoon Phinyomark, Franck Quaine, Sylvie Charbonnier, Christine Serviere, Franck Tarpin-Bernard, and Yann Laurillau. Emg feature evaluation for improving myoelectric pattern recognition robustness. *Expert Systems with applications*, 40(12):4832–4840, 2013.
- [72] Angkoon Phinyomark and Erik Scheme. A feature extraction issue for myoelectric control based on wearable emg sensors. In *2018 IEEE Sensors Applications Symposium (SAS)*, pages 1–6, 2018.
- [73] Omkar S Powar, Krishnan Chemmangat, and Sheron Figarado. A novel pre-processing procedure for enhanced feature extraction and characterization of electromyogram signals. *Biomedical Signal Processing and Control*, 42:277–286, 2018.
- [74] Jinxian Qi, Guozhang Jiang, Gongfa Li, Ying Sun, and Bo Tao. Intelligent human-computer interaction based on surface EMG gesture recognition. *IEEE Access*, 7:61378–61387, 2019.
- [75] Anita Rácz, Dávid Bajusz, and Károly Héberger. Effect of dataset size and train/test split ratios in QSAR/QSPR multiclass classification. *Molecules*, 26(4):1111, 2021.
- [76] Ashkan Radmand, Erik Scheme, and Kevin Englehart. On the suitability of integrating accelerometer data with electromyography signals for resolving the effect of changes in limb position during dynamic limb movement. *JPO: Journal of Prosthetics and Orthotics*, 26(4):185–193, 2014.
- [77] Mamun Bin Ibne Reaz, M Sazzad Hussain, and Faisal Mohd-Yasin. Techniques of emg signal analysis: detection, processing, classification and applications. *Biological procedures online*, 8(1):11–35, 2006.
- [78] T Scott Saponas, Desney S Tan, Dan Morris, Ravin Balakrishnan, Jim Turner, and James A Landay. Enabling always-available input with muscle-computer interfaces. In *Proceedings of the 22nd annual ACM symposium on User interface software and technology*, pages 167–176, 2009.
- [79] Erik Scheme, K Biron, and Kevin Englehart. Improving myoelectric pattern recognition positional robustness using advanced training protocols. In *2011 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, pages 4828–4831. IEEE, 2011.
- [80] Erik Scheme and Kevin Englehart. Electromyogram pattern recognition for control of powered upper-limb prostheses: state of the art and challenges for clinical use. *Journal of Rehabilitation Research & Development*, 48(6), 2011.
- [81] Erik Scheme, A Fougner, Øyvind Stavdahl, Adrian DC Chan, and Kevin Englehart. Examining the adverse effects of limb position on pattern recognition based myoelectric control. In *2010 annual international conference of the IEEE engineering in medicine and biology*, pages 6337–6340. IEEE, 2010.
- [82] Erik Scheme, Blair Lock, Levi Hargrove, Wendy Hill, Usha Kuruganti, and Kevin Englehart. Motion normalized proportional control for improved pattern recognition-based myoelectric control. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 22(1):149–157, 2013.

- [83] Mathieu Serrurier, Franck Mamalet, Alberto González-Sanz, Thibaut Boissin, Jean-Michel Lobes, and Eustasio del Barrio. Achieving robustness in classification using optimal transport with hinge regularization. In *Proc. IEEE Conf. Comput. Vis. Pattern Recogn.*, pages 505–514, Nashville, USA, 19–25 Jun. 2021.
- [84] Miguel Simão, Pedro Neto, and Olivier Gibaru. EMG-based online classification of gestures with recurrent neural networks. *Pattern Recognition Letters*, 128:45–51, 2019.
- [85] Christian Szegedy, Wojciech Zaremba, Ilya Sutskever, Joan Bruna, Dumitru Erhan, Ian Goodfellow, and Rob Fergus. Intriguing properties of neural networks. In *Proc. Int. Conf. Learn. Represent.*, Banff, Canada, 14–16 Apr 2014.
- [86] Aaron Tabor, Scott Bateman, and Erik Scheme. Evaluation of myoelectric control learning using multi-session game-based training. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 26(9):1680–1689, 2018.
- [87] Miyato Takeru, Kataoka Toshiaki, Koyama Masanori, and Yoshida Yuichi. Spectral normalization for generative adversarial networks. In *Int. Conf. Learn. Represent.*, Vancouver, Canada, 30 Apr–3 May 2018.
- [88] Sirinee Thongpanja, Angkoon Phinyomark, Franck Quaine, Yann Laurillau, Chusak Limsakul, and Pornchai Phukpattaranont. Probability density functions of stationary surface emg signals in noisy environments. *IEEE Transactions on Instrumentation and Measurement*, 65(7):1547–1557, 2016.
- [89] Stefano Tortora, Michele Moro, and Emanuele Menegatti. Dual-myo real-time control of a humanoid arm for teleoperation. In *2019 14th ACM/IEEE International Conference on Human-Robot Interaction (HRI)*, pages 624–625, 2019.
- [90] Asim Waris, Imran Khan Niazi, Mohsin Jamil, Omer Gilani, Kevin Englehart, Winnie Jensen, Muhammad Shafique, and Ernest Nlandu Kamavuako. The effect of time on emg classification of hand motions in able-bodied and transradial amputees. *Journal of Electromyography and Kinesiology*, 40:72–80, 2018.
- [91] Feng Wen, Zhongda Sun, Tianyi He, Qiongfeng Shi, Minglu Zhu, Zixuan Zhang, Lianhui Li, Ting Zhang, and Chengkuo Lee. Machine learning glove using self-powered conductive superhydrophobic triboelectric textile for gesture recognition in VR/AR applications. *Adv. Sci.*, 7(14):2000261, 2020.
- [92] NI Widiastuti. Convolution neural network for text mining and natural language processing. In *IOP Conf.: Mater. Sci. Eng.*, volume 662, Kazimierz Dolny, Poland, 21–29 Nov. 2019.
- [93] Dapeng Yang, Wei Yang, Qi Huang, and Hong Liu. Classification of multiple finger motions during dynamic upper limb movements. *IEEE journal of biomedical and health informatics*, 21(1):134–141, 2015.
- [94] Mahyar Zardoshti-Kermani, Bruce C Wheeler, Kambiz Badie, and Reza M Hashemi. Emg feature evaluation for movement control of upper extremity prostheses. *IEEE Transactions on Rehabilitation Engineering*, 3(4):324–333, 1995.
- [95] Ping Zhou, Blair Lock, and Todd A Kuiken. Real time ecg artifact removal for myoelectric prosthesis control. *Physiological measurement*, 28(4):397, 2007.