

# Proiect EMGP-AI

## –Raport științific și tehnic in extenso 2021–

*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:** *22.11.2021*

**Etapele:** *1/2020, 2/2021*

### Activitățile

- Activitatea 1.1 – Proiectarea modului de achiziție
- Activitatea 1.2 – Implementarea site-ului web al proiectului
- Activitatea 2.1 – Dezvoltarea modului hardware de achiziție de date EMG
- Activitatea 2.2 – Dezvoltarea modului software de achiziție de date EMG
- Activitatea 2.3 – Rafinarea datelor captate de senzori
- Activitatea 2.4 – Achiziționarea bazei de date EMG
- Activitatea 2.5 – Segmentarea datelor
- Activitatea 2.6 – Diseminare și raportare - partea I

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

**Număr contract:** 425PED/2020

**Director proiect:** Prof. Corneliu BURILEANU

# Cuprins

<b>1 ETAPA I. Planificarea proiectului și proiectarea componentei hardware pentru modulul de achiziție de date</b>	<b>2</b>
1.1 Rezumatul etapei . . . . .	2
1.2 Descrierea științifică și tehnică . . . . .	2
A1.1 Proiectarea modulului de achiziție . . . . .	2
A1.2 Implementarea site-ului web al proiectului . . . . .	5
<b>2 ETAPA II. Dezvoltarea modulului de achiziție și crearea resurselor EMG pentru antrenarea și testarea modulului de clasificare a gesturilor</b>	<b>7</b>
2.1 Rezumatul etapei . . . . .	7
2.2 Descrierea științifică și tehnică a activităților . . . . .	8
A2.1 Dezvoltarea modulului hardware de achiziție de date EMG . . . . .	8
A2.2 Dezvoltarea modulului software de achiziție de date EMG . . . . .	11
A2.3 Rafinarea datelor captate de senzori . . . . .	15
A2.4 Achiziționarea bazei de date EMG . . . . .	15
A2.5 Segmentarea datelor . . . . .	17
A2.6 Diseminare și raportare – partea I . . . . .	19
<b>Locuri de muncă susținute prin program</b>	<b>19</b>
<b>Bibliografie</b>	<b>19</b>

# 1 ETAPA I. Planificarea proiectului și proiectarea componentei hardware pentru modulul de achiziție de date

## 1.1 Rezumatul etapei

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

1. Planificarea proiectului – împărțirea sarcinilor și trasarea termenelor limită pentru fiecare activitate, realizarea unor întâlniri săptămânale între membrii echipei pentru a monitoriza îndeaproape evoluția activităților.
2. Proiectarea modulului de achiziție – găsirea celui mai bun raport calitate-preț al arhitecturii sistemului de achiziție.
3. Dezvoltarea paginii web asociate proiectului – diseminarea pe scară largă prin comunicarea și publicarea națională sau internațională a rezultatelor.

Etapa 1/2020 a proiectului EMGP-AI s-a desfășurat în perioada 27.10.2020 – 31.12.2020, și a constat în următoarele activități:

- Activitatea 1.1. Proiectarea modulului de achiziție. Această activitate a constat în documentarea asupra componentelor hardware care vor fi necesare în realizarea platformei de achiziție. Pentru a colecta semnalele EMG de la suprafața pielii este necesară o serie de electrozi specializați. Acești electrozi vor fi conectați la un convertor analog-digital (ADC) care are rolul de a transforma semnalul electric analogic într-unul eșantionat și cuantizat. Mai departe, datele digitalizate vor fi trimise unui microcontroler, al cărui rol principal este acela de a crea o punte de legătură între ADC și modulul Bluetooth. Acesta din urmă va împacheta datele conform protocolul de comunicație menționat anterior și le va trimite către server unde se va efectua clasificarea propriu-zisă utilizând algoritmi de inteligență artificială.
- Activitatea 1.2. Implementarea paginii web a proiectului. Website-ul asociat proiectului a fost dezvoltat în tehnologie `html` și conține atât informații legate de stadiul actual al proiectului cât și detalii despre rezultatele obținute.

În urma activității A1.2 din etapa 1/2020 a proiectului EMGP-AI, a rezultat livrabilul asumat de echipă la începutul acestei etape:

- Site-ul proiectului disponibil la următoare adresă: <http://emgp-ai.speed.pub.ro/>.

## 1.2 Descrierea științifică și tehnică

### A1.1 Proiectarea modulului de achiziție

Întregul proiect EMGP-AI gravitează în jurul semnalelor de tip electromiografic, prescurtat EMG. Acestea reprezintă o clasă de semnale biomedicale care măsoară activitatea electrică a curenților generați de mușchi în timpul contracției [9]. Capacitatea de a înregistra și clasifica răspunsul electric al mușchilor are potențialul de a duce la crearea unor proteze inteligente ce pot ajuta persoanele care și-au pierdut un membru să ducă o viață normală. De asemenea, un sistem capabil să clasifice gesturile în timp real poate fi folosit la comunicarea cu diverse dispozitive electrice, e.g. drone, platforme terestre, etc., făcând controlul acestora mult mai intuitiv și interactiv.

Metode rudimentare de clasificare a semnalelor EMG au mai fost abordate de-a lungul timpului. Încă din 1989 *Hiraiwa et al.* [4] au realizat un sistem care poate clasifica 5 mișcări ale mâinii cu ajutorul unui algoritm de tip rețea neurală. Sistemul lor era de o complexitate redusă având doar un singur electrod de suprafața și extrăgând trăsături spectrale utilizând FFT (Fast Fourier Transform). În 2000 echipa condusă de *F.H.Y. Chan*[2] găsește o abordare superioară folosind sisteme *fuzzy* pentru clasificare, preprocesarea fiind mult mai amplă. Din semnalele colectate sunt extrase 24 de trăsături și apoi datele sunt agregate cu ajutorul algoritmului Basic ISODATA [2]. Pe măsură ce

sistemele de clasificare a semnalelor EMG se dezvoltau, alegerea unui set relevant de trăsături începea să devină o problemă importantă. În [7] este abordat acest subiect. Lucrarea este construită ca o comparație între performanțele sistemelor bazate pe diversele trăsături care se extrăgeau în mod uzual la momentul respectiv. În [6] se prezintă complexitatea asociată metodelor de clasificare a semnalelor EMG. *Mukhopadhyay et al.* construiesc un sistem care poate determina mișcarea realizată de subiect independent de poziționarea electrozilor. Din punct de vedere al clasificatorului folosit, se observă tendința generală către abordarea bazată pe Rețele neurale adânci (*eng. Deep Neural Networks*).

În propunerea originală a proiectului am menționat că vom folosi modulul **Cyton Neural Interface Board** [1], ilustrat în Figura 1. Deși este un modul specializat pentru interfațarea cu senzori de tip EMG, în primii pași pentru definirea arhitecturii hardware, echipa de proiect a descoperit un dezavantaj de natură tehnică în raport cu dispozitivul de achiziție a semnalelor musculare. Dimensiunile fizice ale modulului **Cyton** s-au dovedit a fi nepotrivite pentru integrarea acestuia în prototip atât din punct de vedere al confortului utilizatorului cât și al fiabilității deoarece dispozitivul de achiziție trebuie fixat pe antebraț. Prin urmare, echipa noastră a ajuns la concluzia că, pentru a oferi un produs care să fie cât mai ușor de purtat, ar trebui să ne dezvoltăm un modul propriu, de dimensiuni mai reduse și cu un sistem de fixare adecvat. În vederea unei comparații numerice, **Cyton** are o dimensiune de  $60\text{mm} \times 65\text{mm}$  iar modulul nostru, dezvoltat în etapa 2, are dimensiunile  $62\text{mm} \times 21\text{mm}$ .

Încă de la începutul fazei de proiectare a prototipului, echipa noastră și-a propus realizarea unui modul care să îndeplinească câteva criterii legate de calitatea și performanța dispozitivului:

- Eficiență transmisiunii → conexiunea fără fir îmbunătățește semnificativ practicabilitatea produsului, reduce riscul problemelor hardware cauzate de fire de legătură defectuoase și oferă caracteristici tehnologice de tip Internet of Things (IOT).
- Non-invazivitatea → pentru achizițiile de semnale EMG exista 2 posibilități majore: cele invazive (care presupun inserarea de ace în țesutul muscular al subiectului) și cele neinvazive pentru care este suficientă alăturarea dintre piele și senzor fără a leza subiectul în niciun fel. Ținând cont că prima variantă este disponibilă doar în cazul în care achiziția se face într-un mediu în care există personal cu pregătire medicală, am optat să realizăm o brățară neinvazivă.
- Integrabilitatea → un alt aspect pe care l-am avut în vedere este obținerea unei portabilități crescute a produsului final prin reducerea dimensiunilor. De exemplu, o primă variantă a fost să pornim de la placa de achiziție **Cyton** de la firma **OpenBCI** [1]. Totuși, aceasta este mult prea mare pentru a fi integrată într-un dispozitiv care își propune să fie purtat pe braț.
- Eficiența energetică → dispozitivul pe care l-am dezvoltat folosește drept sursă de energie o baterie. Pentru a maximiza durata de viață până la următoarea reîncărcare a fost necesar ca regimul energetic al părților componente să fie atent monitorizat.




Figura 1: Cyton Neural Interface Board



- Utilizabilitatea → în forma finală, brățara ar trebui să poată fi folosită și de oameni fără cunoștințe tehnice prin adecvarea stilului de interacțiune cu acest tip de interfață.
- Funcționabilitate → frecvență de eșantionare suficient de ridicată pentru a surprinde particularitățile semnalului EMG. Spectrul semnalului electromiografic se află în intervalul de frecvență  $[0; 500Hz]$  dar cel mai dominant este în  $[50; 150Hz]$  [5]. Prin urmare o frecvență de eșantionare de  $500Hz^1$  pentru fiecare canal este mai mult decât suficientă.

În urma celor amintite mai sus, echipa noastră a ajuns la o configurație de componente hardware care să satisfacă toate condițiile stipulate în propunerea de proiect. Schema bloc a modului este ilustrată în figura 2. Justificarea alegerii fiecărei componente este oferită în cele ce urmează.

O etapă critică în dezvoltarea proiectului a constat în documentarea asupra componentelor hardware necesare pentru realizarea platformei de achiziție. Pentru a înregistra semnalele EMG de la suprafața pielii este necesară o serie de electrozi specializați. Acești electrozi vor fi conectați la un convertor analog-digital (ADC) care are rolul de a transforma semnalul electric analogic într-unul eșantionat și cuantizat. Mai departe datele digitalizate vor fi date unui microcontroler al cărui rol principal este acela de a crea o punte de legătură între ADC și modulul Bluetooth. Acesta din urmă va împacheta datele conform protocolul de comunicație menționat anterior și le va trimite către server unde se va face clasificarea propriu-zisă utilizând algoritmi de inteligență artificială.

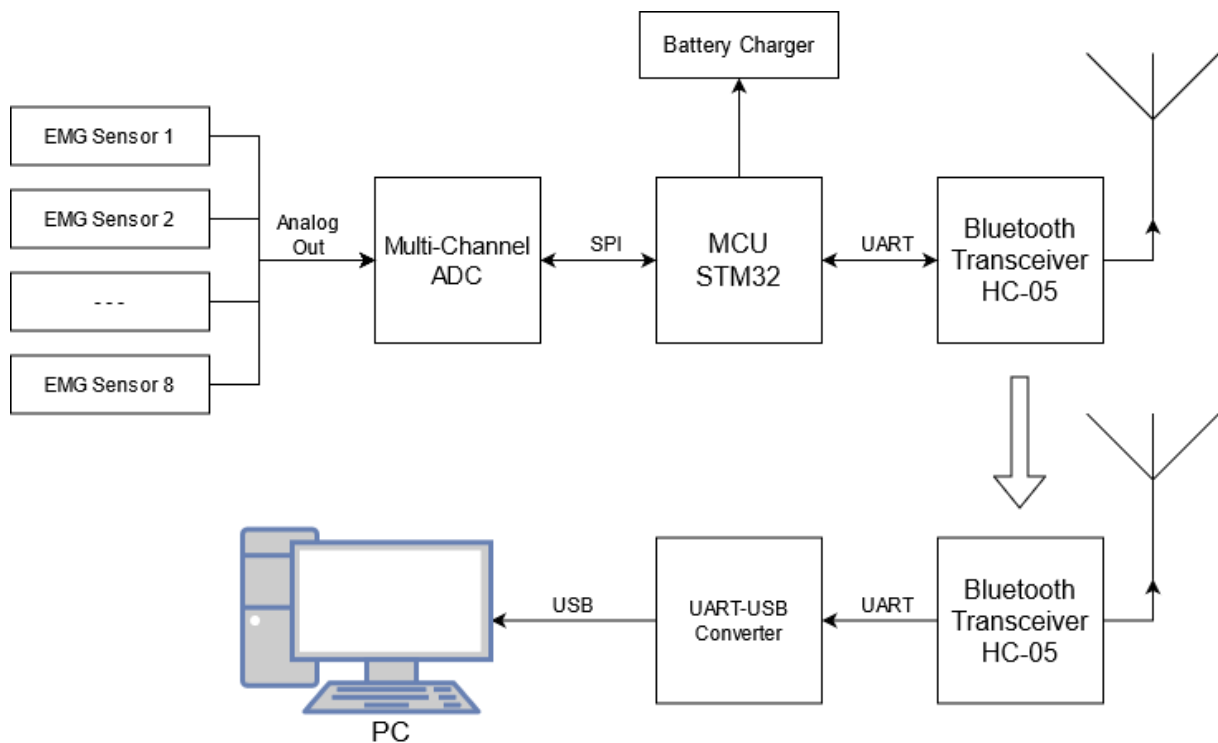


Figura 2: Schema bloc a modului

**Electrozii utilizați pentru colectarea semnalelor EMG.** Semnalul electromiografic este foarte predispus la distorsiuni cauzate de diferite tipuri de zgomot. O anumită clasă de artefacte care poate să apară este reprezentată de artefactele de mișcare. Acestea sunt create de circuitul care ia contact cu pielea subiectului. Mai precis, zgomotul poate să apară la interfața cu electrodul sau prin cablul acestuia [9]. Artefactele de mișcare pot fi reduse dacă circuitul electric care face contact cu pielea este plasat corespunzător, considerând că acest circuit este de o calitate superioară. Conform [8] o deplasare de un singur centimetru a unui electrod poate produce o discrepanță de amplitudine de până la 200%, fără prezența unei diferențe fiziologice. De aceea alegerea electrozilor reprezintă unul dintre pașii esențiali ai proiectului EMGP-AI. Mai precis, ținând cont că ne dorim să construim o brățară care să aibă nevoie de mentenabilitate minimă, echipa noastră a achiziționat o serie de electrozi

<sup>1</sup>placa de achiziție dezvoltată de echipa noastră este capabilă de o frecvență de eșantionare de 4kHz dar aceasta trebuie împărțită pe fiecare canal. Prin urmare frecvența de eșantionare per canal este de 500Hz.

reutilizabili. Aceștia au fost achiziționați în număr de 32. Un prototip are nevoie de 8 senzori, prin urmare se pot construi mai multe prototipuri păstrând și senzori de rezervă în cazul apariției unor defecțiuni.

Senzorii folosiți în cadrul proiectului sunt senzori EMG activi, de suprafață, fără gel. Avantajul celor fără gel este utilizarea și re poziționarea ușoară, iar faptul că sunt activi le oferă avantajul de a realiza amplificarea în mod local (acest aspect reducând per total complexitatea modulului de achiziție). Electrozii achiziționați măsoară semnale EMG în intervalul  $[-1.5V, +1.5V]$ , amplifică semnalul electromiografic brut cu un factor de 1000 și au ca ieșire tensiune unipolară între 0 și 3V, centrată în jurul valorii de 1.5V.

**Convertor analog-digital: AD7124-8** [13]. Considerând faptul că semnalele EMG au banda semnificativă de frecvențe relativ restrânsă (între 50 și 150Hz [5]), este suficient ca ADC-ul să atingă o frecvență de eșantionare de 500Sa/s per canal, iar dacă ADC-ul eșantionează secvențial canalele, pentru 8 canale este nevoie de o frecvență de eșantionare de 4000 Sa/s per total. Având în vedere faptul că semnalul vine preamplificat de senzori, fiind în gama de 0-3V cu *offset* de 1.5V, ADC-ul trebuie să fie capabil să eșantioneze pe 8 biți. Pentru acest proiect am achiziționat AD7124-8. Acesta are și filtru digital încorporat care va optimiza extragerea de frecvențe utile din semnal. De asemenea, AD7124-8 se bucură de versatilitate în ceea ce privește energia necesară funcționării, acesta putând lucra în trei moduri distincte de alimentare în funcție de particularitățile aplicației.

**Microcontroler: STM32L432KC** [15]. Rolul principal al microcontrolerului este acela de a crea puntea de legătură între convertorul analog-digital și modulul Bluetooth. Pentru acest proiect a fost ales microcontrolerul cu arhitectură ARM, STM32L432KC. Acesta are avantajul funcționării la tensiuni de alimentare foarte scăzute (de la 1.71V până la 3.6V), prin urmare maximizând durata de viață a bateriei. De asemenea, dispune de o gamă mare de temperatură în care poate lucra – de la  $-40^{\circ}C$  până la cel puțin  $85^{\circ}C$ . Astfel sistemul de clasificare va putea funcționa la orice temperatură în care s-ar putea afla subiectul uman. În plus, existența unui microcontroler oferă posibilitatea de a scala proiectul în situația în care s-ar pune problema aplicării unor operații matematice asupra semnalelor EMG înainte de a fi trimise serverului. Preprocesarea făcută direct la nivelul sistemului de achiziție ar contribui la scăderea timpului de predicție, astfel ajutând sistemul să își păstreze caracteristicile de funcționare în timp real.

**Modul Bluetooth: HC-05** [14]. Pentru a crea un sistem de clasificare ușor de folosit, proiectul de față își propune să realizeze comunicarea dintre dispozitivul de achiziție și server în mod wireless. Având în vedere faptul că distanța dintre brațara care va colecta datele și dispozitivul de calcul care va eticheta gestul va fi una relativ mică, dar și faptul că brațara va folosi o baterie pentru alimentare, protocolul de comunicație adecvat este Bluetooth. Acesta are un consum de energie scăzut – pentru a face o comparație Wi-Fi are nevoie de o putere dublă față de Bluetooth [3]. Totuși, microcontrolerul nu pot transmite implicit datele folosind acest protocol. Pentru a împacheta semnalul în format Bluetooth este nevoie de un modul special. În mod uzual se folosește un circuit numit HC-05. Pentru EMGP-AI am achiziționat următorul modul [14]. Acesta are dimensiuni foarte reduse, mai precis  $12,7mm \times 27mm$ , ceea ce ajută la realizarea unei brațări practice și ușor de purtat. De asemenea, modulul funcționează cu un consum foarte redus de energie, putând opera la un nivel mic de tensiune de 1.8V.

## A1.2 Implementarea site-ului web al proiectului

Site-ul proiectului poate fi accesat la următoarea adresă: <http://emgp-ai.speed.pub.ro/>. Acesta este actualizat în mod regulat pe parcursul implementării proiectului și conține rezultate intermediare, detalii referitoare la procesul de raportare, și informații cu privire la activitatea științifică asociată proiectului.

De asemenea, toate rezultatele experimentele și codurile utilizate vor fi făcute publice prin intermediul unui depozit GitLab (<https://gitlab.upb.ro/mnegru/emg>) ce va fi actualizat continuu pe tot parcursul proiectului. Scopul este de a asigura transparența experimentelor și de a ușura reproductibilitatea tuturor rezultatelor. În acest fel, promovăm colaborările internaționale și oferim șansa altor echipe de cercetare să beneficieze de experiența noastră.

Pe platforma de GitLab[11] a proiectului se găsesc o serie de fișiere organizate în modul următor:

```
Embedded Platform for EMG acquisition with  
Artificial Intelligence software toolkit
```

```
├── EMG_Acquisition_Hardware  
│   ├── EMG_CubeIDE  
│   └── EMG_PCB  
├── EMG_Acquisition_Software  
│   ├── Data  
│   ├── Storage.py  
│   └── Viewer.py  
├── EMG_Data_Processing  
│   ├── Rescale.py  
│   ├── Filter.py  
│   ├── Segmentation.py  
│   └── main.py  
└── README.md
```

În plus, tot aici, se regăsesc și pagini de tip *Wiki*<sup>2</sup>. Mai precis, pe Gitlab-ul EMGP-AI se găsesc următoarele pagini:

- *EMG\_Acquisition\_Hardware* – descrierea activității A2.1 Dezvoltarea modului hardware de achiziție de date EMG
- *EMG\_Acquisition\_Software* – descrierea activității A2.2 Dezvoltarea modului software de achiziție de date EMG
- *EMG\_Data\_Processing* – descrierea activităților A2.3 Rafinarea datelor captate de senzori și A2.5 Segmentarea datelor
- *EMG\_Dataset* – descrierea activității A2.4 Achiziționarea bazei de date EMG

Pe site-ul web [10] se găsesc următoarele resurse aferente proiectului:

- descriere succintă a proiectului
- raportul de față
- link către baza de date cu 15 gesturi
- un filmuleț demonstrativ
- link către codul sursă aferent proiectului

Considerând cele expuse mai sus, toate obiectivele aferente activităților din etapa 1 au fost realizate cu succes.

---

<sup>2</sup>pagini care conțin o descriere succintă a diverselor etape din proiect

## 2 ETAPA II. Dezvoltarea modului de achiziție și crearea resurselor EMG pentru antrenarea și testarea modului de clasificare a gesturilor

### 2.1 Rezumatul etapei

A doua etapa a proiectului EMGP-AI a avut trei obiective principale ce au fost realizate în proporție de 100%:

1. Realizarea sistemului de achiziție EMG – dezvoltarea propriu-zisă a componentei hardware a modului de achiziție de date EMG în timp real, cât și a modului software asociat.
2. Realizarea modului de rafinare și segmentare de date – implementarea unor tehnici de procesare a semnalului pentru a elimina potențialul zgomot ce se suprapune peste semnalul util din cauza procesului de achiziție. Acest pas este important pentru facilitarea procesului de clasificare automată pe bază de tehnici AI, ce urmează să fie dezvoltat în Etapa III.
3. Dezvoltarea unei baze de date EMG – se va realiza o bază de date care va conține înregistrări de semnale EMG corespunzătoare unor gesturi elementare și câtorva semne utilizate frecvent în limbajul semnelor. Scopul este de a putea clasifica suficiente gesturi, astfel încât o persoană cu handicap să poată comunica cu ceilalți, să apuce obiecte și să indice direcții diferite.

Etapa 2/2020 a proiectului EMGP-AI s-a desfășurat în perioada 01.01.2021 – 22.11.2021, și a constat în următoarele activități:

- Activitatea 2.1 Dezvoltarea modului hardware de achiziție de date EMG. Considerând arhitectura hardware a dispozitivului definită în prima etapă, această activitate a constat în realizarea fizică a prototipului de laborator. Astfel, ținând cont de specificații, echipa de proiect a efectuat integrarea tuturor componentelor hardware într-un dispozitiv funcțional, proces care a presupus rezolvarea problemelor colaterale de natură tehnică (interconectarea componentelor, alimentarea dispozitivului, etc.).
- Activitatea 2.2 Dezvoltarea modului software de achiziție de date EMG. Această activitate a implicat dezvoltarea și implementarea unei componente software dedicate pentru realizarea procesului de achiziție a semnalelor. Astfel, a fost dezvoltat un sistem automat de achiziție folosind modulul hardware de la Activitatea 2.1.
- Activitatea 2.3 Rafinarea datelor captate de senzori. Fiind constrânși de limitările semnalului electromiografic, mai precis amplitudinea și frecvența mică care îl predispune la a fi afectat de zgomot, a trebuit să acordăm o atenție deosebită procesului de filtrare. Păstrarea exclusiv a informației relevante va facilita etapele viitoare care au drept scop clasificarea datelor, prin urmare, am dezvoltat o componentă software de procesare astfel încât să respecte premisele expuse mai sus.
- Activitatea 2.4 Achiziționarea bazei de date EMG. În această activitate am realizat o bază de date biometrică. Astfel am înregistrat semnale electromiografice de la mai mulți subiecți, pentru un număr de 15 gesturi sistemul dezvoltat anterior. Datele obținute vor servi ulterior la antrenarea unui sistem de clasificare automată.
- Activitatea 2.5 Segmentarea datelor. Pentru controlul în timp real, latența este un factor foarte important care trebuie luat în considerare. Considerăm că un bun clasificator și o latență mai mică de 250 ms vor asigura utilizatorului un sentiment de utilizare naturală. Astfel am determinat dimensiunea și tipul unei ferestrei de segmentare care să se ia în considerare un număr rezonabil de eşantioane pentru predicție, fără a pierde aspectul de timp real al sistemului nostru. Întregul set de date a fost segmentat folosind o fereastră glisantă, cu suprapunere.

- Activitatea 2.6 Diseminare și raportare - partea I. Această activitate înglobează efortul de diseminare pe scară largă prin comunicarea și publicarea națională sau internațională a rezultatelor.

În urma activității A1.1 din etapa 1/2020 și a activităților A2.1–A2.6 din 2/2021 a proiectului EMGP-AI, au rezultat toate livrabilele asumate de echipa de proiect la începutul acestei etape:

- Dispozitiv de achiziție de date EMG în timp-real – se poate vizualiza [aici](#).
- Software achiziție date – disponibil [aici](#).
- Bază de date EMG pentru 15 gesturi – disponibilă [aici](#).
- Software de segmentare a datelor – disponibilă [aici](#).
- Diseminarea rezultatelor proiectului (Activitatea 2.6) prin intermediul website-ului proiectului și prin trimiterea spre publicare a următorului articol:
  - R. Ciubotaru, A. Neacșu, J.C. Pesquet, C. Burileanu, *Design of Robust Complex-Valued Feed-forward Neural Networks*, trimis către *IEEE International Conference on Acoustics, Speech, & Signal Processing (ICASSP)*, Mai 22–27, 2022, Singapore.

## 2.2 Descrierea științifică și tehnică a activităților

### A2.1 Dezvoltarea modului hardware de achiziție de date EMG

În urma unei analize aprofundate asupra sistemului pe care ne dorim să îl implementăm am dezvoltat o schemă a brățării de achiziție care să îndeplinească toate criteriile detaliate la etapa 1. Aceasta este prezentată în figura 3.

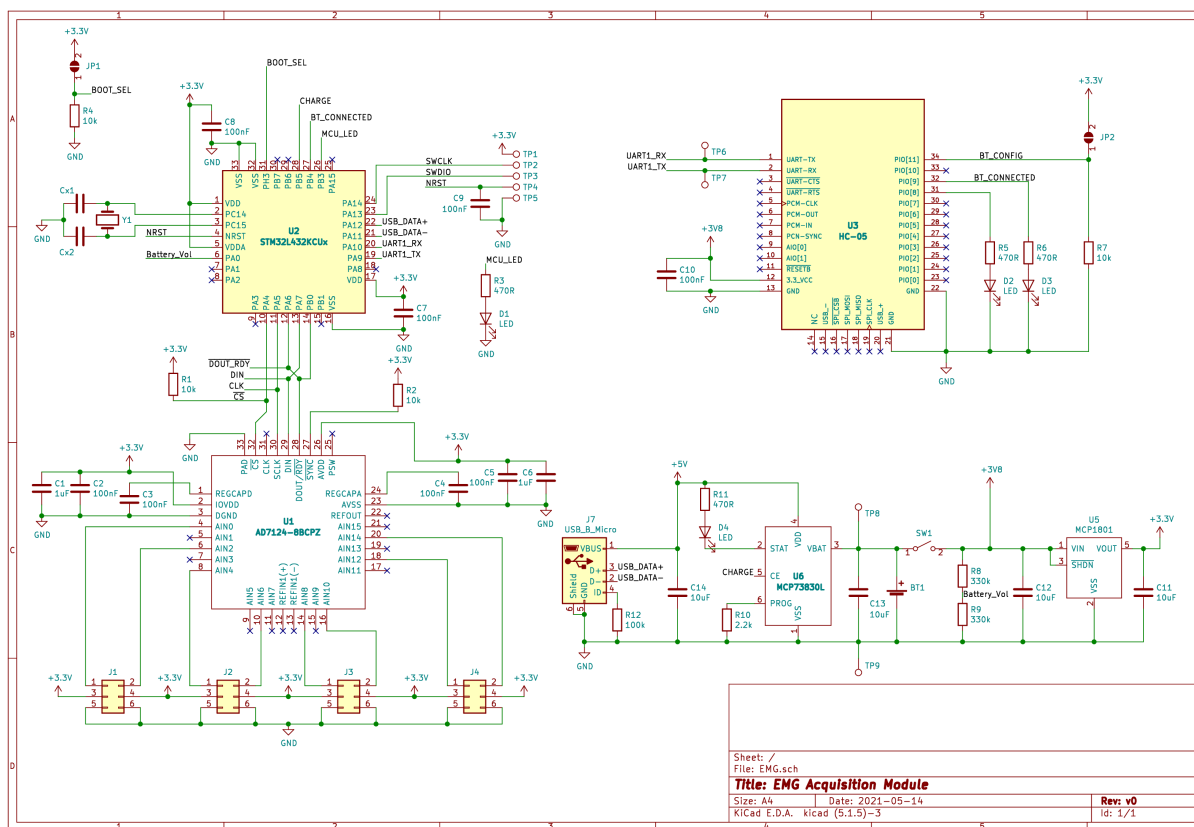


Figura 3: Schema electrică


Pentru a asigura un produs final de o calitate superioară, echipa noastră a trecut prin trei etape de dezvoltare a prototipului:

### 1. Prototipul cu module Breakout<sup>3</sup>

Întrucât ADC-ul și microcontrolerul folosite sunt componente disponibile în capsule QFN (Quad-Flat No-leads), prototiparea cu acestea este dificilă din cauza constrângerilor mecanice. Pentru testarea funcționalității acestora și a lanțului de achiziție într-o primă formă, s-au folosit modulele Breakout aferente. Astfel, pentru ADC s-a folosit ADC-6 Click, echipată cu AD7124-8. În ceea ce privește microcontrolerul, s-au folosit plăcile Nuc1eo-32, echipate cu STM32L432KC, de la STMicroelectronics. Prototipul cu module Breakout este ilustrat în figura 4a. Componentele sunt aranjate în felul următor: în stânga sus este plasa ADC-ului; în stânga jos este microcontrolerul iar în partea dreaptă se găsește modulul Bluetooth.

### 2. Prototipul în format SMD<sup>4</sup>

Dezvoltarea software-ului care rulează pe PC s-a făcut pe prototipul Breakout, dar înaintea fabricării cablajului imprimat, a fost necesară testarea modulului cu componente discrete. Pentru acest lucru s-a realizat același prototip pe un cablaj de test, cu componentele individuale, pentru validarea circuitului. Acesta este ilustrat în figurile 4b și 4c.



(a) Modul Breakout

(b) Protip SMD – Vedere față

(c) Protip SMD – Vedere spate

Figura 4: Primele două etape de dezvoltare a prototipului

### 3. Prototipul cu PCB<sup>5</sup> fabricat

Întrucât proiectul își propune realizarea unui modul portabil, este necesar ca și cablajul să fie într-o formă mai compactă. Astfel s-a realizat schema testată pe prototipul anterior în format PCB (eng. *Printed Circuit Board*), care măsoară dimensiunile de 62mm×21mm și la care se pot conecta senzorii. Prototipul este folosit în mod curent pentru achiziția semnalelor EMG necesare obinerii bazei de date, folosită mai departe în scopul realizării unui sistem de tip rețea neurală care să interpreteze gesturi făcute cu mâna. Modulul PCB este ilustrat în figura 6.

<sup>3</sup>este o plăcuță care „scoate în exterior” pinii componentelor de pe PCB. În acest fel pinii se pot accesa facil. Este o practică des întâlnită la testarea circuitelor.

<sup>4</sup>Surface Mounted Device este un dispozitiv la care componentele sunt montate direct pe suprafața PCB-ului.

<sup>5</sup>Printed Circuit Board este un circuit imprimat care are rolul de a susține mecanic componentele electronice din interiorul ei și conține toate conexiunile aferente lor.



Modulul de achiziție în forma completă este format din 4 componente de bază:

- senzorii EMG → dispuși conform figurii 5<sup>6</sup>;
- ADC-ul;
- microcontrolerul;
- adaptorul wireless care realizează conexiunea dintre calculatorul gazdă și sistemul de achiziție EMG.

Cu privire la adaptorul wireless, trebuie menționat că brățara funcționează, cu anumite limitări, folosind doar Bluetooth pentru transmisia datelor. O problemă ar fi că adaptorul creează un *bottleneck* semnificativ și nu se poate vizualiza semnalul în timp real. O altă problemă descoperită în timpul experimentelor este că modulul Bluetooth pierde din eșantioane în procesul de transmisiune. Prin urmare, o soluție de compromis a fost să adaptăm echipamentul de achiziție să funcționeze și prin USB pentru a colecta baza de date cu semnale EMG (unul dintre obiectivele proiectului). După achiziționarea unui modul Bluetooth mai performant, dispozitivul final va fi capabil să funcționeze wireless în etapa 3, fără pierdere de eșantioane și fără latențe care să împiedice vizualizarea semnalelor în timp real.

Forma finală este prezentată în figura 7.




Figura 5: Organizarea senzorilor






Figura 6: Modul PCB

<sup>6</sup>cele 2 imagini sunt făcute într-o fază intermediară a dezvoltării echipamentului de achiziție. Acesta este motivul pentru care ambele poze prezintă brățara cu doar 4 senzori din cei 8 cu care este echipată aceasta în forma actuală.



(a) Vedere laterală



(b) Vedere de sus

Figura 7: Brățări în forma finală

## A2.2 Dezvoltarea modului software de achiziție de date EMG

Pentru a putea folosi datele care sunt transmise pe adaptorul wireless este necesar un software de achiziție care să interfațeze cele 2 componente. În acest sens, echipa noastră a dezvoltat un program care oferă posibilitatea afișării grafice, în timp real, a semnalelor achiziționate de pe cele 8 canale. Această funcționalitate este foarte importantă deoarece se poate superviza colectarea datelor iar în acest mod se observă dacă apar eventuale anomalii în timpul achiziției (de exemplu, senzori care nu au contact adecvat cu pielea sau dispuneri pe braț ale brățării, care nu permit colectarea semnalelor în mod fidel). În plus, software-ul oferă posibilitatea salvării datelor pentru utilizări ulterioare. În cazul proiectului de față datele<sup>7</sup> vor fi folosite pentru antrenarea de rețele neurale.

Modul de afișare al semnalelor electromiografice este prezentat în figurile 8 și 9. Mai precis, imaginea 8 prezintă formele de undă generate flexia degetelor iar imaginea 9 ilustrează același gest realizat în mod repetat. Se poate remarca cum încordarea mușchilor creează creșteri bruște de amplitudine în dreptul canalelor aferente iar relaxarea duce activitatea electrică aproape de nivelul de *offset*. Acest nivel de *offset* va fi eliminat în activitatea de rafinare a datelor.

Limbaajul de programare folosit pentru realizarea software-ului de achiziție este Python. În dezvoltarea acestei funcționalități s-au folosit următoarele biblioteci:

- **PySerial** → pentru a putea conecta un sistem *embedded* la un calculator, este necesar un port Serial. Transferul de date dintre brățară și aplicația de achiziție presupune accesarea portului serial. PySerial este biblioteca standard pentru astfel de aplicații, aceasta facilitând comunicația dintre aplicație și modulul de achiziție.
- **Numpy** → prelucrările ulterioare ale semnalelor achiziționate de la brățară presupun ca acestea să fie salvate într-un format ușor de gestionat. Numpy este o bibliotecă omniprezentă în aplicațiile

<sup>7</sup>după ce vor fi filtrate și curățate de zgomot



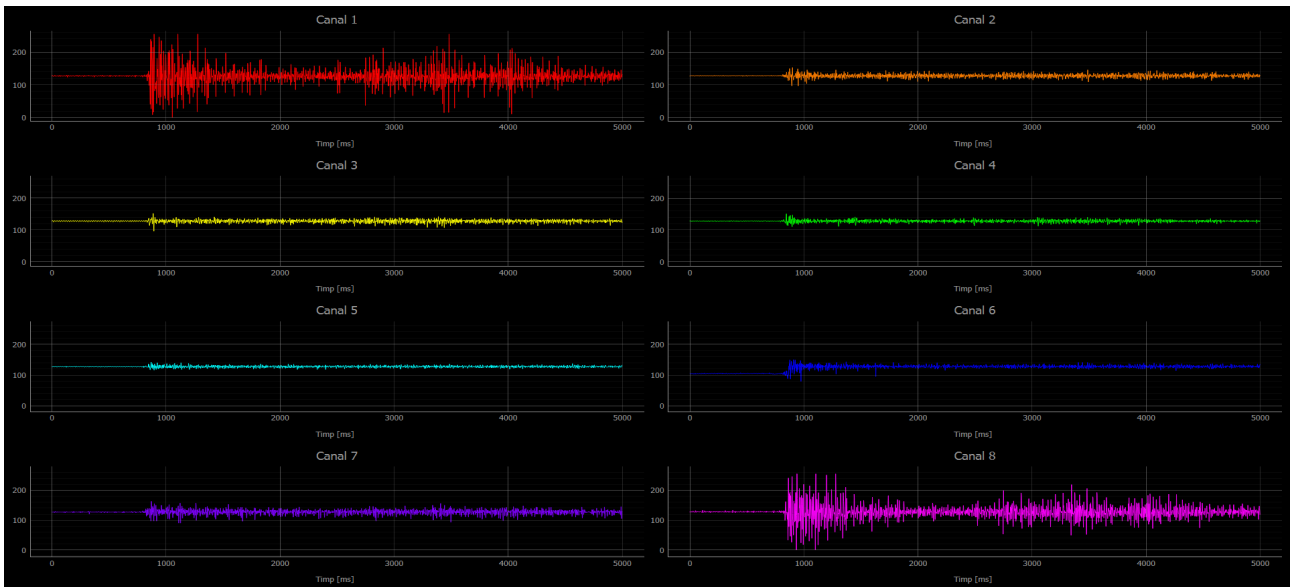


Figura 8: Rezultatul în urma flexiei degetelor

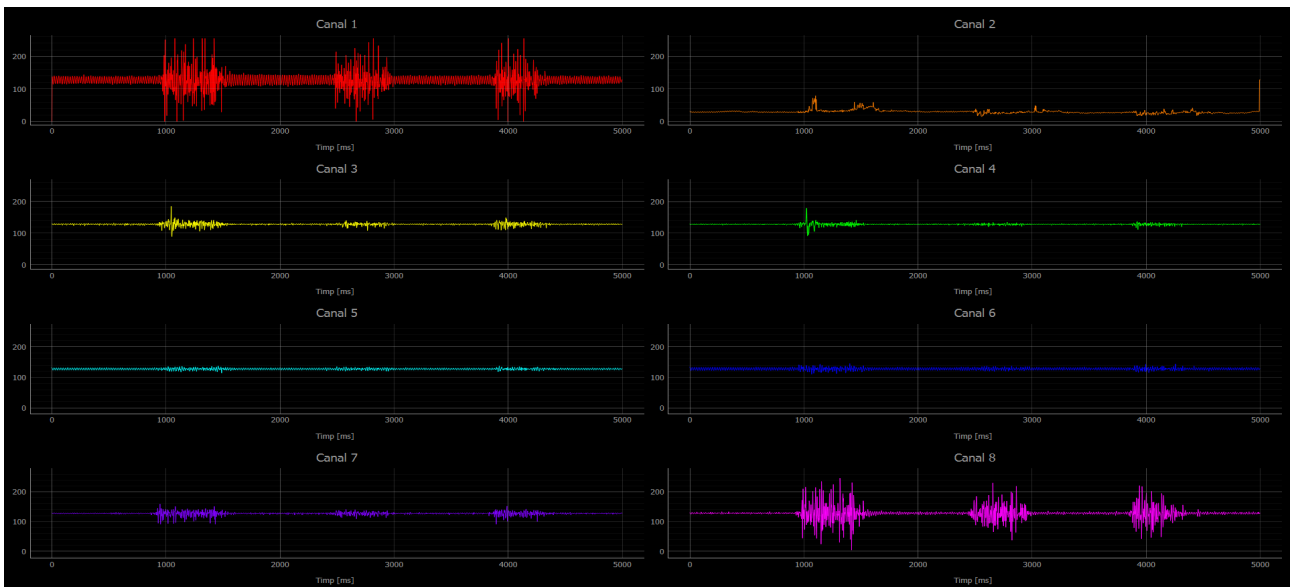


Figura 9: Rezultatul în urma flexiei degetelor în mod repetat

de *data science* și *machine learning*, prin urmare echipa noastră a decis să o utilizeze pentru a asigura compatibilitatea cu viitoare dezvoltări (fie de echipa noastră, fie de alți cercetători interesați de domeniu). În plus, `Numpy` este utilă și în afișarea datelor sub formă de grafice.

- `PyQtGraph` → bibliotecă specializată pentru afișarea graficelor în `Python`. Totuși, acest pachet nu a fost prima opțiune. În primă instanță am încercat să folosim biblioteca `matplotlib`. Problema pe care am descoperit-o cu aceasta a fost faptul că reprezenta un *bottleneck* major în afișarea datelor. Această limitare era atât de gravă încât afișarea în timp real a semnalelor era imposibilă. Biblioteca `PyQtGraph` are în spate o implementare semnificativ mai optimă astfel că ilustrarea grafică a datelor ține pasul cu rata de bit cu care transmite plăcuța de achiziție.

Codul sursă este disponibil integral pe adresa de `GitLab` aferentă proiectului: <https://gitlab.upb.ro/mnegru/emg>.

### A2.3 Rafinarea datelor captate de senzori

Orice semnal real  $x(t)$  este alcătuit dintr-o parte utilă (semnalul dorit  $d(t)$ ) și o parte de zgomot (semnalul nedorit  $z(t)$ ), scris matematic sub următoarea formă:

$$x(t) = d(t) + z(t) \quad (1)$$

Din cauza faptului că semnalul EMG are amplitudine joasă ( $<10\text{mV}$ ), acesta poate conține și zgomot, deoarece ambele semnale au game similare de valori. Din acest motiv, în această etapă este necesară filtrarea datelor electromiografice achiziționate. Un alt aspect care trebuie menționat este faptul că semnalul conține un *offset* de  $1.5\text{V}$  (creat de convertorul analog-digital). Acesta este, de asemenea, eliminat la etapa de rafinare a datelor pentru a obține coeficienți spectrali de valori similare în domeniul frecvență (dacă nu ar fi centrat semnalul în 0 ar apărea un coeficient DC la frecvența 0 cu o valoare mult mai mare față de restul coeficienților).

A filtra un semnal constă în eliminarea componentelor nedorite astfel încât semnalul rezultat să conțină doar semnalul util, în cazul nostru, doar semnalul EMG. În realitate, eliminarea completă a zgomotului este foarte greu de realizat, mai ales pentru zgomote complexe, deci se discută în principal de reducerea zgomotului cât mai mult posibil. Acest lucru se realizează prin trecerea semnalului achiziționat printr-un filtru cu rolul de a „curăța” semnalul. Un filtru digital este un Sistem Discret Liniar Invariant în Timp (*SDLIT*) ce respectă următoarea ecuație cu diferențe finite:

$$y(n) = \sum_{i=0}^M b_i x(n-i) - \sum_{k=1}^N a_k y(n-k) \quad (2)$$

unde  $x(n)$  este intrarea filtrului la momentul de timp  $n$ , iar  $y(n)$  reprezintă ieșirea filtrului;  $b_i$  și  $a_k$  sunt coeficienții calculați ai filtrului.

Pe scurt, există un set de coeficienți constanți  $b_i$  și  $a_k$  care permit calcularea semnalului de la ieșire  $y(n)$  ca o combinație liniară a ultimelor  $M + 1$  eșantioane de la intrare și  $N$  eșantioane de la ieșire.

După cum se observă în ecuația 2, semnalul de ieșire nu depinde doar de cel de la intrare, ci și de un semnal anterior de la ieșire. Astfel, filtrele se împart în două mari categorii:

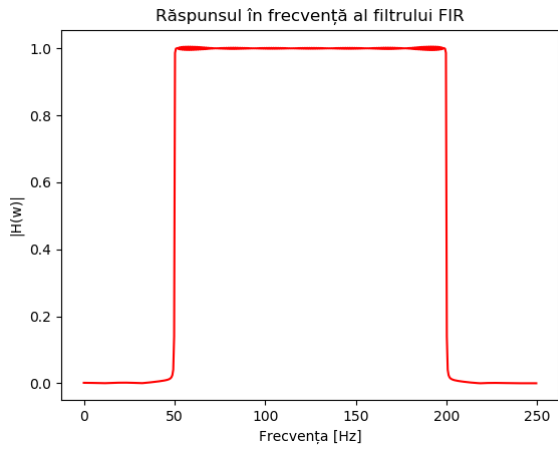
- Filtre cu răspuns finit la impuls (*eng. Finite Impulse Response FIR*) – semnalul de la ieșirea filtrului depinde doar de intrările anterioare, deci se obține un sistem nerecursiv (fără reacție), adică toți coeficienții  $a_k$  au valori egale cu 0
- Filtre cu răspuns infinit la impuls (*eng. Infinit Impulse Response IIR*) – semnalul de la ieșire depinde de semnalele anterioare atât de la intrare, cât și de la ieșire, adică este un sistem cu memorie (recursiv)

Principalul avantaj al filtrelor *FIR* este dat de faptul că oferă garanția unui sistem stabil, deoarece sunt nerecursive, dar este nevoie de un ordin mare al filtrului (un număr mare de coeficienți) pentru a atinge cerințele impuse. Pe de altă parte, filtrele *IIR* oferă performanțe bune cu un ordin mic, dar riscă să fie instabile datorită recursivității acestora.

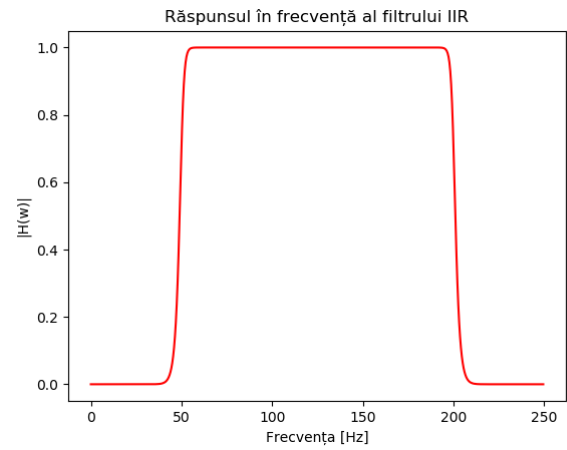
Pentru a decide ce categorie de filtru să folosim, a fost selectat un semnal EMG din baza de date achiziționată și s-a ales un canal din cele 8 pentru a putea vizualiza efectele filtrării semnalului. Compararea între cele două tipuri de filtre este prezentată în figurile 10, 11 și 12. Astfel, pentru această comparație s-a considerat banda de trecere în domeniul frecvență de  $[50\text{Hz} - 200\text{Hz}]^8$ , motivul acestei alegeri fiind faptul că semnalul EMG este cel mai puternic în această bandă de frecvențe.

În cazul filtrului *FIR* s-a ales un ordin de 1000 pentru a obține un răspuns cât mai bun în frecvență. Acest lucru însă implică un răspuns întârziat al filtrului, adică sunt necesare mai multe eșantioane anterioare date la intrare pentru a putea oferi un semnal filtrat la ieșire (cu cât creștem ordinul cu atât răspunsul filtrului va fi mai întârziat, după cum se evidențiază în figura 12). În schimb, pentru filtrul *IIR* un ordin de 20 este suficient astfel încât să obținem banda de trecere dorită, acesta

<sup>8</sup>frecvența utilă se consideră până la  $150\text{Hz}$ [5], totuși, echipa noastră a considerat ca este mai bine să luăm un interval cu  $50\text{Hz}$  mai mare la capătul drept pentru a fi siguri că nu eliminăm informație relevantă din semnal.

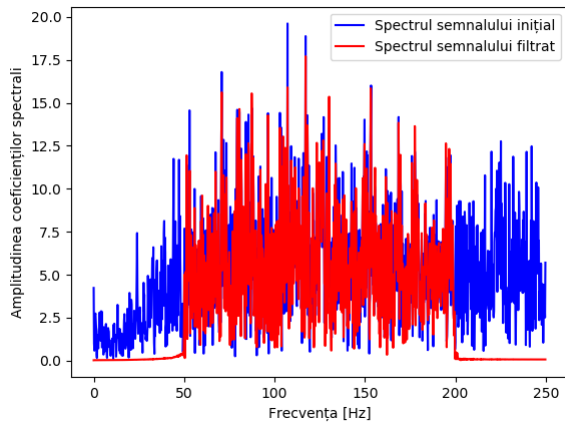


(a) Răspunsul filtrului FIR, de ordin 1000




(b) Răspunsul filtrului IIR, de ordin 20

Figura 10: Comparație între răspunsurile în frecvență ale celor două categorii de filtre




(a) Spectrul semnalului după filtrul FIR

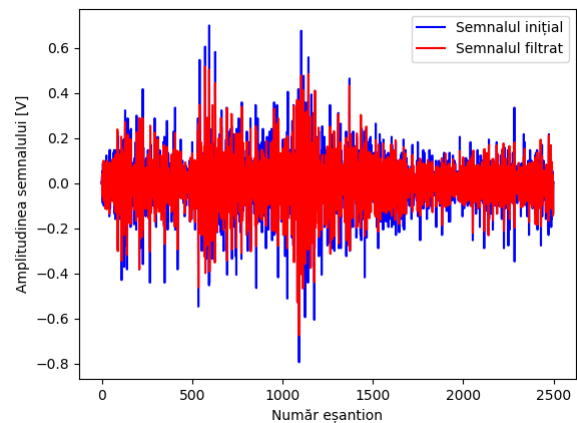


(b) Spectrul semnalului după filtrul IIR

Figura 11: Comparație între spectrele semnalului filtrat cu cele două categorii de filtre



(a) Semnalul după filtrul FIR



(b) Semnalul după filtrul IIR

Figura 12: Comparație între semnalul filtrat cu cele două categorii de filtre

oferind rezultate bune atât în domeniul frecvență, cât și în domeniul timp. S-a folosit filtrul IIR de tipul *Butterworth* datorită răspunsului cât mai plat al acestuia în banda de trecere în frecvență (fără oscilații, *eng. ripples*). Pentru a ne asigura că nu modificăm faza semnalului s-a aplicat acest filtru liniar inițial asupra semnalului pornind de la primele eșantioane (deci direcția înainte) și după a fost aplicat asupra semnalului plecând de la ultimele eșantioane (în direcția inversă). Acest filtru combinat prin aplicarea celor 2 filtre liniare are o fază liniară. Toate aceste observații ne-au convins de faptul că pentru aplicația noastră folosirea filtrelor *IIR*, mai exact, filtrul *Butterworth* de un ordin redus oferă performanțele dorite.

Din punct de vedere al implementării codului, echipa noastră a folosit limbajul de programare *Python*, iar funcțiile de filtrare aparțin bibliotecii *Scipy* [12]. Aceasta este construită deasupra bibliotecii *Numpy* și are funcționalități, printre altele, și pentru procesarea de semnal. De asemenea, *Scipy* este o alegere comună în comunitatea de *data science* și *machine learning*.

## A2.4 Achiziționarea bazei de date EMG

Domeniul biomedical s-a dezvoltat semnificativ în ultimii ani, dar deși s-au făcut progrese remarcabile, semnalele EMG încă sunt analizate în principal manual, de medici. Prin urmare, o aplicație a platformei noastre este utilizarea acesteia pentru îmbunătățirea asistenței medicale în zonele rurale și subdezvoltate. Un alt exemplu de aplicare poate fi autentificarea biometrică folosind semnale EMG ca alternativă la metodele tradiționale de verificare a identității persoanelor.

Motivul dezvoltării unei astfel de platforme este dat de faptul că gesturile mâinilor reprezintă o modalitate foarte naturală și ușoară de a interacționa cu obiectele din jurul nostru, ducând experiența IoT la un nivel superior. Recunoașterea gesturilor mâinii este împărțită în două categorii principale:

- Recunoașterea limbajului semnelor, *eng. Sign Language Recognition (SLR)* – își propune să ajute persoanele cu deficiențe de vorbire să se integreze și să comunice mai ușor în societate
- Controlul automat bazat pe gesturi – se concentrează pe recunoașterea unui set de gesturi care vor fi interpretate și ulterior folosite pentru a interacționa cu alte entități computerizate.

În această etapă s-a urmărit generarea unei baze de date biometrice care conține câteva gesturi de bază împreună cu cele mai utilizate semne din alfabetul limbajului semnelor. Scopul este acela de a clasifica suficiente gesturi astfel încât o persoană cu dizabilități să poată comunica eficient cu ceilalți, iar în funcție de gestul clasificat să se poată executa diferite acțiuni precum apucarea unor obiecte sau indicarea către diferite direcții, folosind un dispozitiv extern. Acest lucru poate fi aplicat cu succes în dezvoltarea unei proteze inteligente, oferind persoanelor care și-au pierdut membrele superioare șansa de a trăi o viață normală. Acest tip de proteză folosește mușchii reziduali din antebraț pentru a detecta ce mișcare încearcă să efectueze utilizatorul. Principalul avantaj este că mișcarea este naturală utilizatorului, facilitând procesul de control. Cea mai mare problemă este dată de cerințele legate de precizia ridicată la ieșirea sistemului, precum și răspunsul în timp real al algoritmului, acestea fiind condiții obligatorii pentru a asigura o interacțiune fluidă și a oferi utilizatorului un sentiment cât mai natural.

Pentru această activitate am urmărit recunoașterea următoarelor 15 gesturi:

- |                          |                                 |
|--------------------------|---------------------------------|
| 1. Poziția neutră        | 9. Litera „D”                   |
| 2. Deviația radială      | 10. Litera „V”                  |
| 3. Flexia încheieturii   | 11. Litera „F”                  |
| 4. Deviația ulnară       | 12. Litera „L”                  |
| 5. Extensia încheieturii | 13. Litera „Y”                  |
| 6. Flexia degetelor      | 14. Gestul de aprobare („Like”) |
| 7. Extensia degetelor    | 15. Gestul de prindere („Grab”) |
| 8. Litera „I”            |                                 |

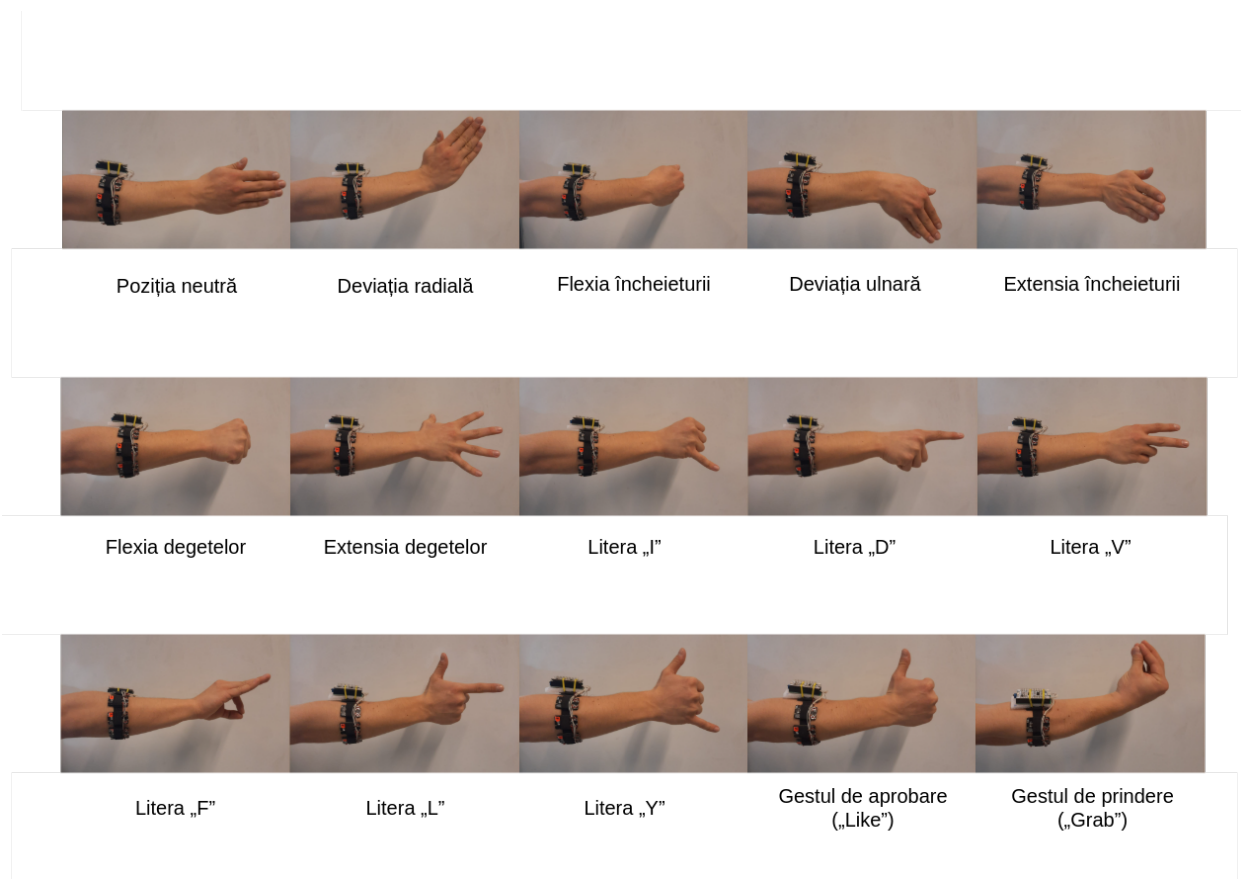


Figura 13: Gesturile din baza de date

Gesturile prezentate anterior se împart în 3 categorii:

- Gesturi fundamentale ale palmei (gesturile 1–7) – sunt mișcări prin care se pot exprima diferite acțiuni uzuale
- Litere din alfabetul american al limbajului semnelor (gesturile 8–13) – sunt mișcări prin care se poate comunica în mod non-verbal
- Gesturi cu aplicabilitate în situații sociale non-verbale (gesturile 14–15) – sunt mișcări prin care se pot exprima interacțiuni complexe, precum prinderea obiectelor sau aprobarea unei situații.

S-a preferat alegerea unor gesturi din mai multe categorii pentru a extinde aplicabilitatea platformei noastre și evitarea limitării la un singur domeniu. Suplimentar, gesturile au fost selectate astfel încât să nu existe oricare 2 gesturi cu contracții similare ale grupurilor de mușchi (ex. realizarea literei „A” din alfabetul limbajului semnelor folosește aceleași grupuri de mușchi ca și gestul „Flexia degetelor”).

Setul de date a fost colectat de la 60 de subiecți apti, cu vârste cuprinse între 20 și 65 de ani, atât bărbați cât și femei. Fiecare participant a fost instruit să execute toate gesturile de 2 ori, cu 2 minute pauză după fiecare ciclu. Fiecare gest a fost menținut timp de 5 secunde iar în acest timp s-a înregistrat activitatea EMG. S-a ales executarea de 2 ori a fiecărui gest deoarece este puțin probabil ca datele să fie identice întrucât nu putem controla într-un mod precis contracția mușchilor la executarea unui gest (participantul poate obosi, sau poate fi ușor distras la diferite momente de timp). Perioada de 5 secunde a fost selectată pentru a cuprinde atât intervalul de contracție maximă (începutul gestului) cât și relaxarea acestuia în timp (motivul este acela că nu se poate menține același nivel de încordare pentru un timp îndelungat). Participanților li s-a explicat înainte de fiecare gest cum ar trebui realizat pentru a obține semnale similare de la toți subiecții. În acest fel, ne-am asigurat că toate datele sunt executate și etichetate corect, gestul fiind inițiat înainte de înregistrare și menținut pe tot parcursul acesteia.

## A2.5 Segmentarea datelor

Un *semnal* prin definiție conține informație despre starea sau evoluția unui sistem fizic și este necesară prelucrarea lui astfel încât informația conținută să fie extrasă parțial sau total. La modul general, putem spune că semnalele EMG sunt semnale unidimensionale ce variază în timp în funcție de contracția mușchilor. Din aceste motive, prelucrarea lor este un aspect foarte important, deoarece este mult mai ușor de lucrat cu semnale deterministe pe durate scurte de timp și periodice, scopul final fiind estimarea anumitor parametrii caracteristici (deci extragerea unei anumite informații), eliminarea sau reducerea unor componente nedorite, sau în scopul transformării unui semnal într-o formă care să fie mai semnificativă din anumite puncte de vedere.

Orice semnal  $x(t)$  poate fi caracterizat prin două reprezentări:

- Reprezentarea în *domeniul timp*, numită forma de undă a semnalului
- Reprezentarea în *domeniul frecvență*, numită spectrul de frecvențe al semnalului

Aceste reprezentări caracterizează în mod univoc semnalul, adică unei reprezentări în timp îi corespunde o singură reprezentare în frecvență și invers, unei reprezentări în *domeniul frecvență* îi corespunde o singură reprezentare în *domeniul timp*.

Un prim pas de preprocesare îl reprezintă normarea semnalului, pentru a obține aceeași gamă de valori ale amplitudinilor, în intervalul  $[-1, 1]$ . Deoarece microcontroler-ul transmite un semnal digital în gama de valori  $[0, 255]$  (datorită faptului că sistemul ADC funcționează pe 8 biți), s-a substras mai întâi valoarea de *offset* pe care este centrat semnalul (valoarea 128) astfel încât să se obțină valori în intervalul  $[-128, 127]$ , acest pas fiind deja realizat la rafinarea datelor. Pasul final pentru normalizarea semnalului în intervalul  $[-1, 1]$  se realizează prin împărțirea fiecărui eșantion la 128. Această etapă de normare a semnalului este importantă deoarece atunci când vom extrage trăsături este posibil să ne dorim trăsături ce folosesc semnalul centrat în 0, cum ar fi trăsătura „Numărul de treceri prin zero”, *eng.* „Zero Crossing Rate” (ZCR). Un alt motiv este faptul că o rețea neuronală va învăța mai ușor pentru un set de date cu aceeași gamă de valori, fiind astfel capabilă să diferențieze mai rapid semnalele, iar scalarea este realizată pentru a obține semnale cu valori mici.

Segmentarea datelor constă în a extrage (selecta) dintr-un semnal de durată mare un segment de lungime finită și reprezintă de fapt multiplicarea semnalului cu o secvență dreptunghiulară alcătuită din  $N$  eșantioane-unitate (ce poartă denumirea de fereastră dreptunghiulară), notată cu  $w_R(n)$  și ilustrată în figura 14a. Astfel, se obține un semnal de forma:

$$x_N(n) = \begin{cases} x(n), & \text{pentru } n = 0, 1, \dots, N - 1 \\ 0, & \text{în rest} \end{cases} \quad (3)$$

unde  $x(n)$  este semnalul original, în cazul nostru semnalul EMG cu o durată de 5 secunde.

Aceasta se numește „tehnica ferestruirii” și este folosită uzual în majoritatea aplicațiilor, cu scopul de a obține semnale cvasistaționare de lungime finită, dintr-un semnal complex.

Multiplicarea în timp a două semnale discrete se va manifesta în domeniul frecvență printr-o convoluție:

$$x(n)w_R(n) \leftrightarrow X(e^{j\omega}) * W_R(e^{j\omega}) = X_N(e^{j\omega}) \quad (4)$$

unde  $X(e^{j\omega})$ ,  $W_R(e^{j\omega})$  și  $X_N(e^{j\omega})$  sunt transformatele Fourier ale semnalului  $x(n)$ , secvenței dreptunghiulare  $w_R(n)$  și respectiv secvenței  $x_N(n)$ . Funcția  $W_R(e^{j\omega})$  este numită și fereastră spectrală. Pentru o secvență dreptunghiulară aceasta este de forma unei funcții **sinc**, având forma unui lob central (cu lărgimea de bază  $2 \times 2\pi/N$ ), înconjurat de lobi laterali mici, care vor descrește progresiv în amplitudine către extremitățile intervalului unei perioade.

Spectrul real  $X_N(e^{j\omega})$  va fi o convoluție între spectrul ideal  $X(e^{j\omega})$  și o funcție de tipul **sinc**. Acest lucru determină o deformare a spectrului ideal, însoțită de apariția unor ondulații în spectrul semnalului  $x_N(n)$ . Acest fenomen se numește dispersie, sau împrăștiere a spectrului (*eng.* *leakage*).

Deoarece spectrul real  $X_N(e^{j\omega})$  va fi „eșantionat” în frecvență pentru a obține coeficienții Fourier  $X_N(k)$ , vor apărea erori în forma acestui spectru discret și în consecință în forma semnalului refăcut din eșantioane. Aceste erori sunt modificări ale amplitudinilor coeficienților spectrali  $X(k)$ , numite

erori de amplitudine (*eng. peaked-fence*), apariția unor frecvențe false (din cauza lobilor laterali din spectrul ferestrei dreptunghiulare), sau pierderea unei informații de frecvență (nu mai pot fi puse în evidență componente de frecvențe foarte apropiate din spectrul unui semnal complex).

Înmulțirea semnalului cu o fereastră dreptunghiulară este în esență o trunchiere „abruptă” a semnalului și are ca principale efecte în domeniul frecvență, o dispersie a componentelor spectrale ale semnalului și o modificare a amplitudinilor acestor componente. Aceste efecte pot fi interpretate în domeniul timp (datorită periodicității transformatei Fourier discrete inverse) precum apariția unor discontinuități la capetele intervalului de analiză.

Pentru a diminua toate aceste efecte, soluția constă în utilizarea unor funcții fereastră, cu o curbă mai „netedă” și cu un spectru care să permită micșorarea acestor efecte. Aceste funcții poartă denumirea de ferestre de ponderare (*eng. window weighting functions*). Astfel, se va realiza o trunchiere mai puțin abruptă, semnalul fiind adus către zero la capetele intervalului de  $N$  eșantioane. Spectrele acestor funcții vor fi formate dintr-un lob central, ce va conține cea mai mare parte din energia semnalului și din lobi laterali cu amplitudine descrescătoare către capetele intervalului.

Astfel, aplicarea unei funcții fereastră (alta decât cea dreptunghiulară) asupra unui semnal determină pierderea unei anumite cantități de informație în timp spre capetele intervalului și duce la obținerea unui spectru cu vârfuri mai largi și de amplitudine mai mică decât în cazul ferestrei dreptunghiulare, dar se atenuează mult lobi laterali și deci se reduce semnificativ fenomenul de dispersie a spectrului.

În acest proiect, se utilizează pentru analiza în domeniul timp fereastra dreptunghiulară (pentru a păstra semnalul nemodificat astfel încât să nu existe pierderi de informație). Pentru analiza în domeniul frecvență se folosește fereastra de ponderare de tip *Hamming* (pentru a reduce fenomenul de dispersie spectrală și erorile de amplitudine). Fereastra *Hamming* este prezentă în figura 14b și are următoarea formulă:

$$w_{HAM}(n) = \begin{cases} \alpha - (1 - \alpha) \cos\left(\frac{2\pi n}{N-1}\right), & \text{pentru } 0 \leq n \leq N - 1 \\ 0, & \text{în rest} \end{cases} \quad (5)$$

(uzual,  $\alpha = 0.54$ )

Această fereastră prezintă următoarele proprietăți:

- primul lob lateral este mult atenuat;
- lobi laterali următori au o descreștere de -6dB / octavă

Lungimea ferestrei de analiză s-a ales de 250 ms pentru a considera semnalul cvasi-staționar pentru acest interval de timp (proprietățile statistice ale semnalului nu se modifică pe durata acestei ferestre). În acest caz, deoarece pentru fiecare canal avem o frecvență de eșantionare de 500 Hz, dacă durata de achiziție este de 5 secunde, vom obține un număr de eșantioane de  $N = 2500$ , iar o fereastră va

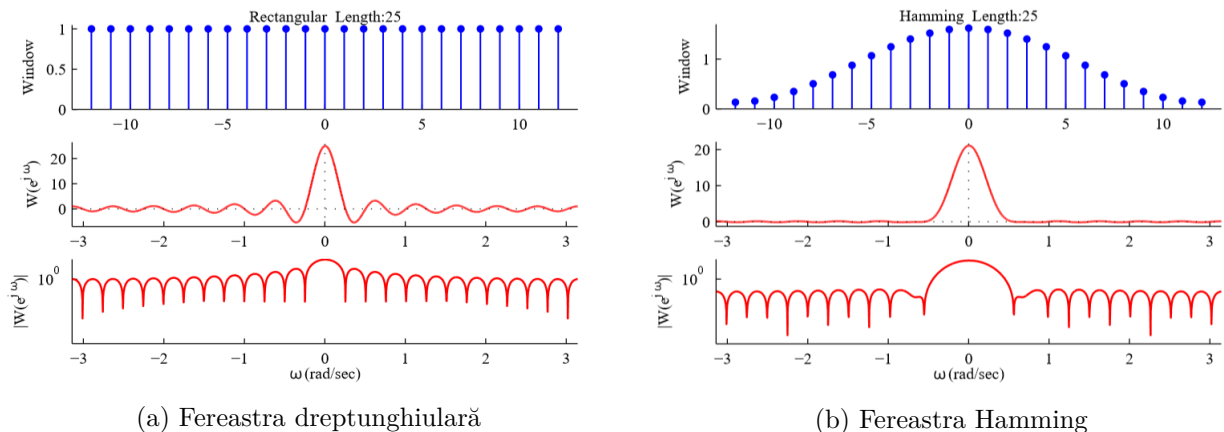


Figura 14: Ferestre folosite pentru procesarea semnalului

fi alcătuită din  $N_w = 125$ . Pentru a augmenta baza de date și a compensa pierderea unei cantități de informație în timp (în cazul folosirii unei ferestre diferite de cea dreptunghiulară), se va folosi o suprapunere de 50% între ferestre.

## A2.6 Diseminare și raportare – partea I

Această activitate sumarizează tot efortul de diseminare ale rezultatelor obținute în cadrul proiectului. Baza de date, împreună cu toate componentele software asociate modulului de achiziție, cât și cel de preprocesare (rafinare și segmentare) sunt disponibile online sub forma unui depozit `GitLab` ce poate fi accesat din pagina web a proiectului.

De asemenea, toate fișierele necesare producerii plăcuței PCB (schema electrică dezvoltată în `KiCad`, cât și fișierele `Gerber`<sup>9</sup> asociate sunt disponibile online, pentru a asigura reproductibilitatea prototipului nostru. Raportul detaliat privind activitățile aferente acestei etape este și el disponibil online.

Totodată, diseminarea rezultatelor proiectului a fost realizată și prin trimiterea unui articol spre publicare la o prestigioasă conferință de procesare de semnal, anume *IEEE International Conference on Acoustics, Speech, & Signal Processing (ICASSP) 2022*.

Considerând cele expuse mai sus, toate obiectivele aferente activităților din etapa 2 au fost realizate cu succes.

## Locuri de muncă susținute prin program

Planificarea inițială a proiectului a inclus în primul rând ocuparea pozițiilor vacante din proiect. În acest scop am organizat un concurs în urma căruia 3 ingineri au fost selectați ca parte a echipei de proiect. În procesul de selecție, s-a urmărit găsirea unor tineri ingineri, cu abilități atât software cât și hardware.

- Ing. Cristina ANDRONACHE – a absolvit facultatea de Electronică, Telecomunicații și Tehnologia Informației, specializarea Electronică Aplicată, iar acum urmează cursurile masterului de *Tehnici Avansate de Imagistică Digitală* în cadrul aceleiași facultăți.
- Ing. Marian NEGRU – a absolvit facultatea de Electronică, Telecomunicații și Tehnologia Informației, specializarea Microelectronică, Optoelectronică și Nanotehnologii, iar acum urmează cursurile masterului de *Tehnici Avansate de Imagistică Digitală* în cadrul aceleiași facultăți.
- Drd. Ing. Georgian NICOLAE – a absolvit facultatea de Electronică, Telecomunicații și Tehnologia Informației, și programul de masterat *Tehnologii Multimedia în Aplicații de Biometrie și Securitatea Informației*. În prezent este doctorand în domeniul electronicii.

Echipei finală de cercetare a Universității Politehnica din București pentru proiectul EMGP-AI este prezentată în Tabelul 1.

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 1: Echipa de cercetare

<sup>9</sup>sunt fișiere care oferă toate informațiile legate de PCB pentru a putea construi la fabrică un circuit imprimat. Acestea conțin informații precum: locația traseelor de cupru, locațiile găurilor, texte imprimate, etc. Formatul de fișiere Gerber este cel mai dominant în industrie.



## Bibliografie

- [1] Openbci: Cyton. <https://shop.openbci.com/collections/frontpage/products/cyton-biosensing-board-8-channel?variant=38958638542>. Last accessed: 2021-11-13.
- [2] Francis HY Chan, Yong-Sheng Yang, FK Lam, Yuan-Ting Zhang, and Philip A Parker. Fuzzy emg classification for prosthesis control. *IEEE transactions on rehabilitation engineering*, 8(3):305–311, 2000.
- [3] Roy Friedman, Alex Kogan, and Yevgeny Krivolapov. On power and throughput tradeoffs of wifi and bluetooth in smartphones. *IEEE Transactions on Mobile Computing*, 12(7):1363–1376, 2012.
- [4] Akira Hiraiwa, Katsunori Shimohara, and Yukio Tokunaga. Emg pattern analysis and classification by neural network. In *Conference Proceedings., IEEE International Conference on Systems, Man and Cybernetics*, pages 1113–1115. IEEE, 1989.
- [5] Muhammad Zahak Jamal. Signal acquisition using surface emg and circuit design considerations for robotic prosthesis. *Computational Intelligence in Electromyography Analysis-A Perspective on Current Applications and Future Challenges*, 18:427–448, 2012.
- [6] 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.
- [7] Angkoon Phinyomark, Pornchai Phukpattaranont, and Chusak Limsakul. Feature reduction and selection for emg signal classification. *Expert systems with applications*, 39(8):7420–7431, 2012.
- [8] Alberto Rainoldi, G Melchiorri, and I Caruso. A method for positioning electrodes during surface emg recordings in lower limb muscles. *Journal of neuroscience methods*, 134(1):37–43, 2004.
- [9] 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.
- [10] <http://emgp-ai.speed.pub.ro/>. Embedded platform for emg acquisition with artificial intelligence software toolkit.
- [11] <https://gitlab.upb.ro/mnegru/emg>. Embedded platform for emg acquisition with artificial intelligence software toolkit.
- [12] <https://scipy.org/>. Scipy.
- [13] <https://www.analog.com/media/en/technical-documentation/data-sheets/ad7124-8.pdf>. AD7124-8 datasheet.
- [14] [https://www.itead.cc/wiki/Serial\\_Port\\_Bluetooth\\_Module\\_\(Master/Slave\)\\_:\\_HC-05](https://www.itead.cc/wiki/Serial_Port_Bluetooth_Module_(Master/Slave)_:_HC-05). HC-05 datasheet.
- [15] <https://www.st.com/resource/en/datasheet/stm32l432kc.pdf>. STM32L432KC datasheet.