



Universitatea  
Transilvania  
din Braşov

**ŞCOALA DOCTORALĂ INTERDISCIPLINARĂ**

**Facultatea de Inginerie Electrică și Știința Calculatoarelor**

Horia Alexandru MODRAN

**Sisteme bazate pe Inteligență Artificială  
în procesarea avansată a semnalelor  
Systems based on Artificial Intelligence  
in Advanced Signal Processing**

**REZUMAT**

**Conducător științific**

**Prof. univ. dr.fiz. Doru URSUȚIU**

**BRAȘOV, 2023**

## Cuprins

<b>INTRODUCERE</b> .....	3
<b>1. DEZVOLTAREA UNUI SISTEM INTELIGENT RECONFIGURABIL DE ACHIZIȚIE ȘI PROCESARE A DATELOR</b> .....	6
1.1. Primul prototip – circuit cu PsoC 6 printat folosind Voltera V-One.....	6
1.2. Al doilea modul experimental – Sistem inteligent.....	10
1.3. Rezumatul capitolului. Diseminare.....	13
<b>2. APLICAȚII ALE INTELIGENȚEI ARTIFICIALE ÎN PROCESAREA SEMNALELOR BIOMEDICALE ȘI FIZIOLOGICE</b> .....	14
2.2. Detectia oboselii folosind dispozitive portabile .....	17
2.3. Clasificarea activităților umane prin tehnici de margine (Edge).....	20
2.4. Rezumatul capitolului. Diseminare.....	24
<b>3. APLICAREA INTELIGENȚEI ARTIFICIALE ÎN PROCESAREA SEMNALELOR AUDIO</b> .....	25
3.1. Recunoașterea stării transmise de muzică utilizând IA .....	25
3.2. Analiza semnalelor audio folosind DeepLearning .....	29
3.3. Detectarea notelor muzicale, a vorbirii și a zgomotului .....	31
3.4. Rezumatul capitolului. Diseminare.....	35
<b>4. REDUCEREA ZGOMOTULUI DIN SEMNALE FOLOSIND INTELIGENȚA ARTIFICIALĂ</b> .....	36
4.1. Reducerea zgomotului din semnalele audio folosind Deep Learning.....	36
4.2. Codificator automat de reducere a zgomotului din semnale.....	39
4.3. Rezumatul capitolului. Diseminare.....	42
<b>5. CONCLUZII FINALE. CONTRIBUȚII ORIGINALE. DISEMINAREA REZULTATELOR ȘI DIRECȚII VIITOARE DE CERCETARE</b> .....	43
5.1. Contribuții originale .....	43
5.2. Diseminarea rezultatelor și distincții internaționale .....	45
<b>BIBLIOGRAFIE (extras)</b> .....	48
<b>REZUMATUL TEZEI (RO/EN)</b> .....	49

## INTRODUCERE

---

Inteligența artificială (IA) este cea mai fascinantă și provocatoare tehnologie a deceniului curent, fiind totodată în centrul celei de-a patra Revoluții Industriale (*Industry 4.0*). Deși a avut mai multe perioade de glorie și decădere de-a lungul timpului, a devenit acum foarte populară, datorită calității sale de a imita inteligența umană în numeroase sarcini uzuale sau de a o susține digital.

Lucrarea de față este o abordare hardware-software complexă ce prezintă diferite aplicații în care utilizarea unor astfel de tehnologii a fost implementată sau este propusă pentru implementarea viitoare; ea oferă și un scurt studiu al modalităților de prelucrare avansată a semnalului, respectiv de inteligență artificială care sunt utilizate în astfel de aplicații. Așadar, teza de doctorat se concentrează pe aplicarea tehnicilor de Inteligență Artificială și Machine Learning în procesarea generală a semnalelor, cu particularizare în prelucrarea semnalelor audio, biomedicale și fiziologice. În realizarea lucrării s-au folosit sursele bibliografice indicate la finalul lucrării și s-au urmărit patru direcții principale pentru experimentele practice efectuate:

1. dezvoltarea unui sistem inteligent de achiziție și procesare a datelor bazat pe chip-ul PSoC 6 dezvoltat de compania Infineon
2. prelucrarea semnalelor biomedicale și fiziologice
  - a. precizarea bolilor cardiovasculare folosind tehnici de Inteligență Artificială
  - b. detectarea oboselii prin intermediul unui ceas inteligent folosind învățare automată
  - c. clasificarea gesturilor prin tehnici de procesare la margine (*edge*)
3. procesarea semnalelor audio – conectată cu disciplinele predate la masterul de Meloterapie
  - a. recunoașterea emoțiilor transmise de muzică prin tehnici de Deep Learning
  - b. analiza semnalelor audio folosind învățarea profundă (clasificare gen muzical)
  - c. detectarea notelor muzicale, a vorbirii și a zgomotului prin procesare edge
4. reducerea zgomotului din semnale
  - a. reducerea zgomotului audio în timp real folosind Deep Learning
  - b. codificator automat de reducere a zgomotului semnalelor prin Inteligență Artificială

### Obiectivele științifice ale tezei de doctorat

Scopul prezentei lucrări este de a dezvolta un sistem de achiziție, de prelucrare a dator obținute în urma efectuării unor măsurători/experimente și apoi de a realiza predicții sau filtrări pe baza tehnicilor de Inteligență Artificială, pentru a dezvolta modele de învățare automată cu largă eficiență și aplicabilitate.

Teza de doctorat prezintă o abordare software-hardware complexă privind realizarea unui sistem de predicție bazat pe algoritmi hibridi de Inteligență Artificială, cu aplicare atât în procesarea semnalelor biomedicale și audio, cât și în procesarea generală și reducerea zgomotului din semnalele electronice.

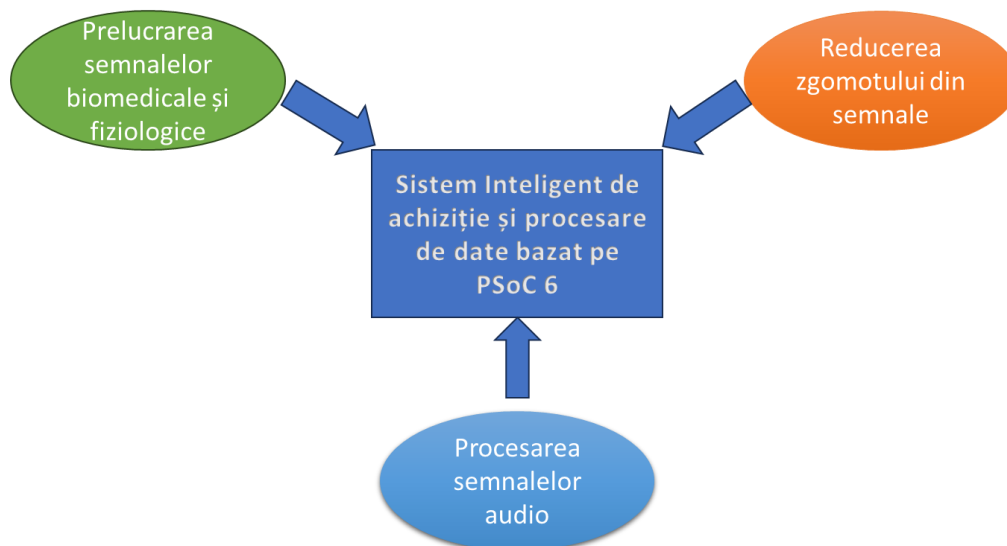
Obiectivul tezei este acela de a proiecta, implementa și valida un sistem inteligent de achiziție de semnale, prin intermediul căreia să poată fi rulate modele inteligente pe datele achiziționate, precum:

1. model de predicție a bolilor cardiovasculare, a oboselei și a diverselor activități umane
2. model de prezicere a stărilor transmise de muzică și de reducere a zgomotului din semnalele audio
3. model de reducere a zgomotului din semnalele electronice

Lucrarea de față urmărește aplicarea procesării inteligente a semnalelor, ce a generat ideea de dezvoltare a unui sistem complet, care să cuprindă atât un sistem de achiziție și procesare avansată a datelor, reprezentate de semnale, cât și analiza lor cu ajutorul tehnicilor de Inteligență Artificială și Machine Learning. Pentru aceasta s-au folosit sisteme hardware de tip Programmable System-on-Chip (PSoC) – respectiv platforma arhitecturală PSoC 6 de la Infineon și ceasuri inteligente. Din punct de vedere software, s-au utilizat soluții precum mediul de dezvoltare LabVIEW, împreună cu modulul de Deep Learning (DeepLTK) și Python API, cu bibliotecile aferente.

Teza este axată pe dezvoltarea unui sistem de analiză și prelucrare inteligentă a semnalelor, atât biomedicale, audio, cât și cele electronice. Din acest obiectiv general al tezei rezultă următoarele obiective specifice (Fig. 1):

1. dezvoltarea unui sistem inteligent de achiziție de date și de procesare a datelor – care să aibă capacitatea de a prelua semnalele biomedicale, audio și electronice, pe care să le prelucreze digital și să realizeze predicția la margine (*edge*)
2. realizarea modelelor bazate pe Inteligență Artificială pentru procesarea datelor biomedicale și fiziologice, care să fie optimizate pentru sistemul realizat
3. construirea de modele bazat pe Inteligență Artificială pentru procesare semnalelor audio compatibile cu sistemul inteligent
4. dezvoltarea unor modele de reducere a zgomotului din semnale, optimizate pentru modulul dezvoltat



**Fig. 1.** Interconectarea Obiectivelor de Cercetare.

## Structura tezei de doctorat

Lucrarea cuprinde introducerea, urmată de 5 Capitoare, care tratează obiectivele propuse, iar ultima secţiune a lucrării este dedicată concluziilor, contribuţiilor originale şi potenţialului de dezvoltare, incluzând şi diseminarea rezultatelor cercetării în publicaţii şi conferinţe internaţionale. La începutul lucrării se prezintă lista de abrevieri folosite, lista figurilor şi a tabelelor, iar în finalul lucrării este inclusă bibliografia şi anexele.

- Partea introductivă prezintă o introducere în tematică, oportunitatea şi actualitatea temei alese şi obiectivele ştiinţifice ale activităţii de cercetare întreprinse.
- Capitolul 1, **“Stadiul actual în Inteligenţă Artificială şi Prelucrarea Semnalelor”** trece în revistă principalele tehnologii şi soluţiile existente de aplicare a Inteligenţei Artificiale în prelucrarea avansată a semnalelor.
- Capitolul 2, **“Dezvoltarea unui sistem inteligent de achiziţie şi procesare a datelor”** prezintă dezvoltarea unei sistem inteligent de achiziţie şi prelucrare a datelor prin metode de Inteligenţă Artificială, bazat pe PSoC 6, care este reconfigurabil prin software.
- Capitolul 3, **“Aplicaţii ale Inteligenţei Artificiale în procesarea semnale biomedicale şi fiziologice”** descrie aplicarea algoritmilor de Inteligenţă Artificiale în prelucrarea semnalelor biomedicale şi fiziologice, axată pe detectarea bolilor cardiovasculare, a oboselii folosind un ceas inteligent şi a activităţilor, prin tehnici de procesare şi predicţie la margine (*edge*).
- Capitolul 4, **“Aplicarea Inteligenţei Artificiale în procesarea semnalele audio”** ilustrează aplicarea modelelor de învăţare profundă în procesarea semnalelor audio, în special pentru detecţia stărilor transmise de muzica, recunoaşterea genului muzical, precum şi a notelor muzicale, a vorbirii şi a zgomotului, utilizând tehnici de procesare de tip *edge*.
- Capitolul 5, intitulat **“Reducerea zgomotului din semnale folosind Inteligenţa Artificială”**, prezintă experimentele realizate pentru suprimarea zgomotului din semnalele audio şi dezvoltarea unui model de reducere a zgomotului şi fluctuaţiilor din semnale.
- Ultimul capitol al tezei prezintă concluziile generale ale lucrării, contribuţiile originale ale autorului, potenţialul de dezvoltare ulterioară a contribuţiilor originale şi diseminarea rezultatelor ştiinţifice în jurnale şi conferinţe internaţionale, în care autorul a publicat rezultatele cercetării din timpul studiilor doctorale.
- Bibliografia cuprinde 102 lucrări din domeniul tezei de doctorat.

# 1. DEZVOLTAREA UNUI SISTEM INTELIGENT RECONFIGURABIL DE ACHIZIȚIE ȘI PROCESARE A DATELOR

Capitolul curent prezintă dezvoltarea unui sistem inteligente de achiziție și prelucrare a datelor prin metode de Inteligență Artificială. De asemenea, sistemul hardware dezvoltat este reconfigurabil prin software, combinând configurabilitatea software oferită de ecosistemul Programmable System-on-Chip (PSoC) de la compania Infineon (fosta Cypress).

## 1.1. Primul prototip – circuit cu PsoC 6 printat folosind Voltera V-One

În prima etapă de dezvoltare s-a urmărit realizarea unui circuit imprimat (PCB) de dimensiuni reduse, care să integreze platforma PSoC 6 BLE Prototyping Kit (CY8CPROTO-063-BLE) și să ofere posibilitatea de a achiziționa diverse semnale prin intermediul acestuia [74].

Circuitul a fost dezvoltat folosind software-ul Proteus. Caracteristicile de baza ale circuitului sunt următoarele (Fig. 2):

- conectori PSoC 6 (21 de pini pentru partea stângă și 21 pentru partea dreaptă)
- 2 rezistoare (de 10k și, respectiv, 100k) și 2 conectoare BNC de intrare
- amplificator 10 x și 100x, cu un switch între ele

Rolul acestui circuit este integrarea PSoC pentru achiziția de date prin intermediul conectorilor BNC și amplificarea datelor achiziționate de 10, respective 100 de ori. După designul circuitului în Proteus, au fost generate fișierele Gerber pentru a putea printa circuitul folosind Voltera V-One.

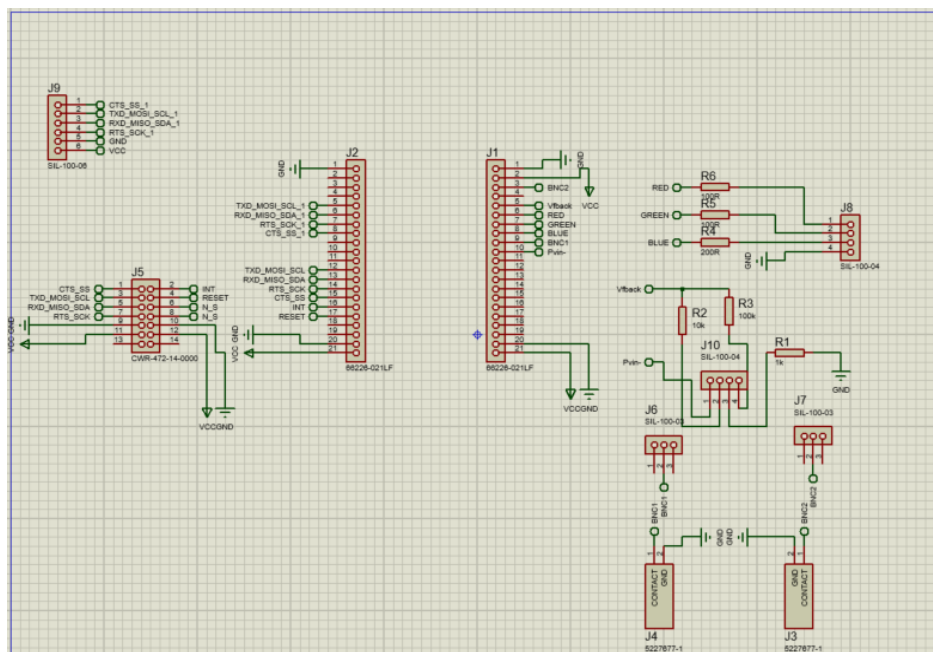


Fig. 2. Design Circuit PCB.

După generarea fişierului Gerber, primul pas în realizarea circuitului este etapa de *drilling* (găurire a circuitului), ce este premergătoare etapei de print. Găurile sunt realizate pe întreaga placă a circuitului imprimate și sunt utilizate pentru interconectarea electrică internă sau folosite pentru poziționarea componentelor pe placă.

După parcurgerea etapelor de găurire, de print și de uscare, urmează plasarea componentelor, care a fost realizată manual. Pe circuitul PCB realizat au fost plasate astfel următoarele componente (Fig. 3):

- modul de prototipaj CY8CPROTO-063-BLE
- 2 conectoare BNC
- 2 switch-uri
- 4 conectori Pmod




Fig. 3. Plasarea componentelor pe circuit.

Pentru testarea ansamblului dezvoltat, microcontroler-ul PSoC6 a fost programat cu o aplicație de achiziție de date folosind un amplificator intern și un convertor de tip analog-digital.

Achiziția de bază a datelor a fost ilustrată prin utilizarea unui semnal de intrare neamplificat și a altuia amplificat, ce au fost conectate prin conectorii BNC ai circuitului. Semnalul a fost introdus într-un bloc ADC și la un receptor-transmițător asincron universal (engl. *Universal Asynchronous Receiver-Transmitter* – prescurtat UART). Placa PSoC a comunicat cu computerul prin portul serial COM care a fost alocat dispozitivului. Design-ul realizat în PSoC Creator este ilustrat în Fig. 4. Aplicația dezvoltată are rolul de achiziție de date biomedicale și nu numai, precum și transmiterea acestora atât prin intermediul portului serial către computer cât și prin intermediul Bluetooth 5.0 către alte dispozitive IoT.

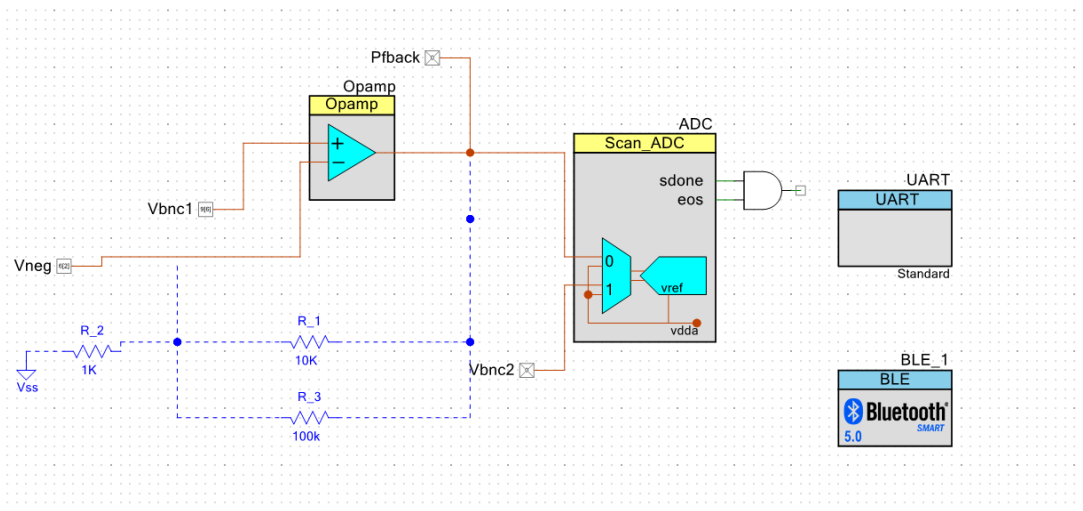


Fig. 4. Diagrama PSoC Creator.

Această aplicație este dezvoltată pentru a fi utilizată împreună cu placa PCB. Comutarea între cele două tipuri de amplificări de face cu ajutorul unui switch, iar datele de intrare vor putea fi preluate prin intermediul celor doi conectori BNC ( $V_{bnc1}$  și  $V_{bnc2}$ ).

Pentru testarea valorilor înainte și după amplificare a fost dezvoltat un Instrument Virtual (VI) în LabVIEW care achiziționează semnalul de la PSoC6 prin portul Serial și îl afișează grafic. Un circuit amplificator non-inversator a fost creat prin conectarea unei componente de amplificator intern la o rețea de rezistență externă. Pentru generarea a două semnale sinusoidale comparabile a fost folosită placa de prototipaj NI ELVIS. Semnalul achiziționat a fost translatat de componenta ADC și a fost testată valoarea atât pentru semnalul neamplificat, cât și pentru cel amplificat. Panoul frontal, valorile citite și reprezentate grafic în structură de tip Waveform Chart pentru amplificarea de 100 de ori sunt ilustrate în Fig. 5.

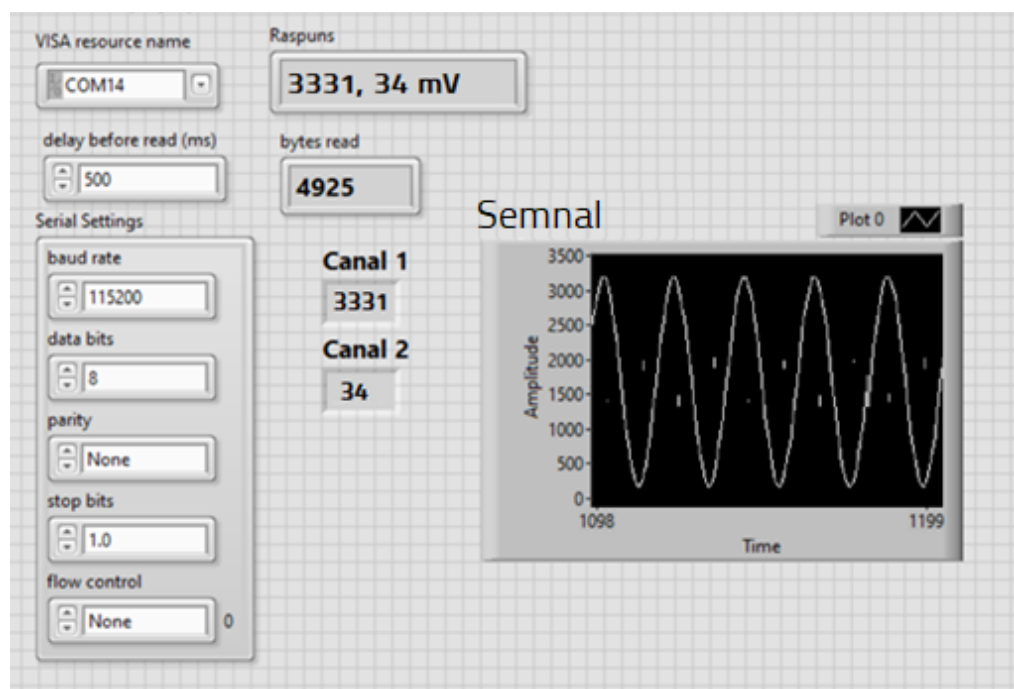


Fig. 5. Panoul frontal al aplicației de achiziție de date.



Datele achiziţionate pot fi apoi transmise folosind tehnologia Bluetooth 5.0 pe telefonul mobil sau orice alt dispozitiv IoT care poate folosi protocolul de comunicare Bluetooth.

Pentru a comunica cu dispozitivul IoT, s-a dezvoltat o aplicaţie Android bazată pe arhitectura Model – View – Controller (MVC). Există şapte clase din această bibliotecă care au fost folosite: BluetoothManager, BluetoothAdapter, BluetoothLeScanner, BluetoothGatt, BluetoothGattCallback, BluetoothGattCharacteristic şi, în cele din urmă, BluetoothGattDescriptor.

Rolul claselor este următorul [74]:

1. BluetoothManager este utilizat pentru a găsi serviciul de sistem Bluetooth pentru telefonul pe care rulează aplicaţia
2. BluetoothAdapter reprezintă adaptorul Bluetooth al telefonului. Acest obiect este folosit pentru a interacţiona cu dispozitivul PSoC şi este găsit folosind metoda getAdapter din BluetoothManager.
3. BluetoothLeScanner este utilizat pentru a găsi dispozitivele BLE (Bluetooth Low Energy) cu care telefonul poate interacţiona. Acesta este un listener pentru pachetele de advertising ale BLE şi apoi notifică existenţa lor.
4. BluetoothGatt este utilizat pentru a permite comunicarea cu un dispozitiv BLE. Acest obiect este creat atunci când ne conectăm la un dispozitiv BLE sau la un periferic BLE.
5. BluetoothGattCallback este utilizat pentru a înregistra evenimente de pe dispozitivul BLE, cum ar fi modificările stării conexiunii şi datele noi disponibile.
6. BluetoothGattCharacteristic este utilizat pentru fiecare dintre caracteristicile conţinute în profilul dispozitivului BLE.
7. BluetoothGattDescriptor este utilizat pentru atributele caracteristice suplimentare. În cazul nostru, va fi utilizat pentru a conţine descriptorul de notificare pentru caracteristica ce transmite valorile obţinute de PSoC6 de pe canale de achiziţie de date.

Interfaţa utilizator a aplicaţiei Android pe telefon este ilustrată în Fig. 6.

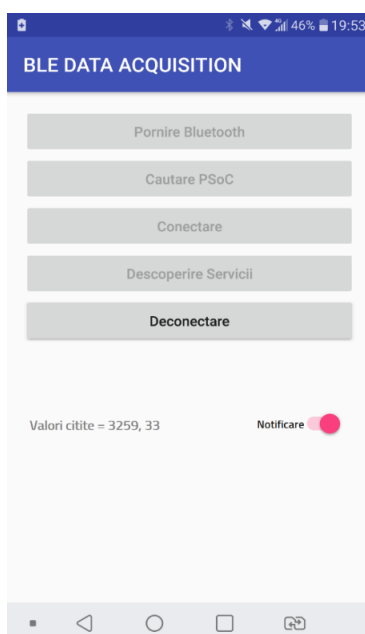


Fig. 6. Interfaţa UI a aplicaţiei Android.

## 1.2. Al doilea modul experimental – Sistem inteligent

În această a doua etapă, a fost dezvoltată o placă configurabilă inteligentă bazată pe chip-ul PSoC 6 CYBLE-416045-02, cu diverse periferice conectate. Placa realizată oferă o platformă robustă de achiziție și procesare inteligentă a datelor, construită în jurul modului scalabil și reconfigurabil PSoC CYBLE-416045-02 EZ-BLE.

Pentru proiectarea sistemului a fost folosit software-ul Proteus. Sursa de alimentare a plăcii este de la baterie Li-Ion, incluzând un regulator de 5V și altul de 3.3V. În plus, a fost inclusă o componentă de testare a sursei de putere, pentru a putea verifica dacă aceasta funcționează corespunzător. Conectorul USB tip C oferă posibilitatea de a programa microcontrolerul PSoC 6 și permite conexiunea serială de la placă la computer, prin intermediul căreia pot fi transmise datele achiziționate la PC. Pentru programarea microcontrolerului a fost nevoie și de includerea unui chip PSoC5, care să joace rol de KitProg2 – ce este practic un programator/depanator cu funcționalitate de USB-I2C și USB-UART bridge. Pentru achiziționarea semnalului a fost integrat un conector microBNC și un amplificator operațional (OpAmp) extern TSV7722IDT. Acesta are o tensiune offset de intrare de mare precizie, gamă largă de tensiuni de alimentare (1.8V – 5V) și o ieșire de tip rail-to-rail. A fost integrat și chip-ul CYBLE-416045-02, în jurul căruia a fost dezvoltată practic întreaga placă. Prin intermediul conexiunii USB-C acesta poate fi programat și reconfigurat, fiind capabil să fie dotat cu diverse modele de Inteligență Artificială, cu ajutorul ecosistemului ModusToolbox.

După finalizarea prototipului plăcii au fost generate fișierele Gerber atât pentru fața plăcii (Fig. 7), cât și pentru spatele acesteia (Fig. 8), fiind verificate în detaliu toate legăturile existente pe placă.

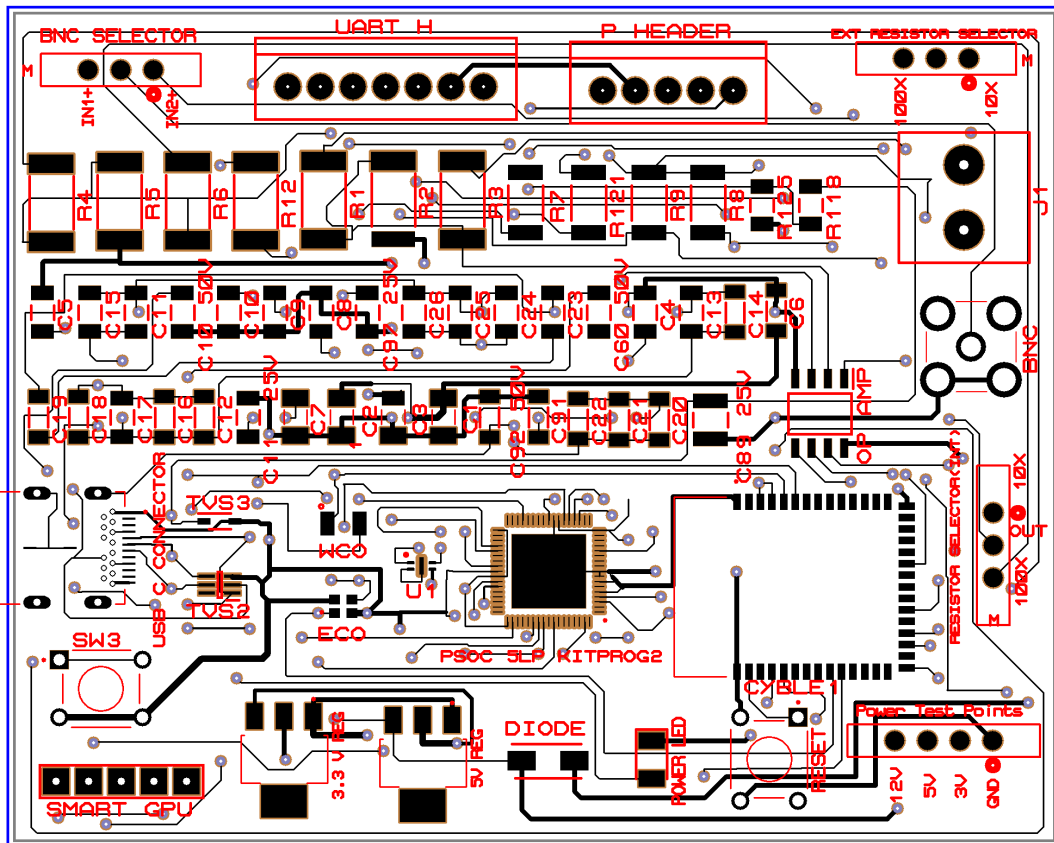


Fig. 7. Prototipul plăcii (față).

Mai întâi a fost exportată și verificată stratul superior al plăcii (Fig. 6), iar apoi cel inferior (Fig. 7).




Fig. 8. Prototipul plăcii (verso).

După realizarea plăcii au fost plasate apoi toate componentele pe placă și a fost apoi alimentată și programată, pentru a verifica toate funcțiile acesteia (Fig. 9).




Fig. 9. Varianta finală a plăcii.

A fost dezvoltată o aplicație flexibilă de achiziție de date pentru această placă utilizând ecosistemul ModusToolbox. Această aplicație utilizează bibliotecile ADC HAL (Hardware Abstraction Library) pentru a efectua achiziționarea de semnal. Componenta Convertor Analog-Digital din biblioteca HAL este configurat să eșantioneze periodic pe un singur canal de tip diferențial tensiunea de intrare și să afișeze tensiunea eșantionată pe UART. În plus, aplicația este flexibilă, putând fi configurată atât rata de eșantionare cât și numărul de puncte care să fie achiziționate.

În aceeași modalitate, utilizatorul poate selecta și numărul de puncte ce vor fi achiziționate într-o singură citire, având următoarele opțiuni:

- 128 de puncte (tasta 1)
- 256 de puncte (tasta 2)
- 512 puncte (tasta 3)
- 1024 puncte (tasta 4)

Tensiunea de intrare este eșantionată la fiecare intervalul specificat de utilizator prin apelarea `cyhal_adc_read_uv`, apoi fiecare valorile citite sunt convertite la milivolți (Fig. 10). De asemenea, în funcție de numărul de eșantioane selectate rezultatul va fi concatenat într-un șir de caractere (String), care la finalul citirii tuturor valorilor va fi transmis prin componenta UART.

```
void adc_single_channel_acquire(char res[])
{
    for(int i = 0; i < NO_OF_SAMPLES; i++) {
        //variabilă pentru a stoca valoarea citită
        int32_t adc_result_0 = 0;

        //citire voltage, convertire la milivolts
        adc_result_0 = cyhal_adc_read_uv(&adc_chan_0_obj) / MICRO_TO_MILLI_CONV_RATIO;
        char val[100] = {};
        //concatenare valoare citită
        sprintf(val, "%d,", adc_result_0);

        strcat(res, val);

        //asteptare rată de eșantionare
        cyhal_system_delay_ms(ADC_SCAN_DELAY_MS);
    }
}
```

Fig. 10. Pini conectați la componenta ADC.

A fost realizat și un Instrument Virtual în LabVIEW prin intermediul căruia să poată fi achiziționate datele, putând fi specificate prin intermediul panoului frontal atât numărul de puncte, cât și rata de eșantionare.

### 1.3. Rezumatul capitolului. Diseminare

Obiectivul acestui capitol a fost acela de a dezvolta o placă inteligentă, reconfigurabilă din punct de vedere software și al funcționalităților. Fiind bazată pe modulul PSoC 6 CYBLE-416045-02 beneficiază din plin de beneficiile oferite de acesta, respectiv dimensiune redusă, arhitectură dual-core, conexiune Bluetooth și serială, securitate și compatibilitate cu o gamă largă de periferice. Câteva exemple de aplicații experimentale flexibile de achiziție și de prelucrare a datelor au fost prezentate în acest capitol, pentru a ilustra reconfigurabilitatea sistemului.

În procesul de realizare a variantei finale a plăcii au existat două stadii diferite de dezvoltare: un prim prototip care integra platforma PSoC 6 BLE Prototyping Kit (CY8CPROTO-063-BLE), iar în al doilea stadiu de dezvoltare a fost realizat o placă PCB ce includea doar chip-ul PSoC6.

Varianta finală a sistemului dezvoltat include:

- chip CYBLE-416045-02 dual-core
- conexiune USB type C
- comunicare Bluetooth BLE
- conector Pmod, pentru conectarea la diverse module periferice sau senzori
- reconfigurabilitate software
- conector microBNC pentru achiziționarea semnalului
- conexiune serială prin UART (la portul USB-C)
- amplificator operațional extern
- alimentare de la baterie

A fost dezvoltată și o aplicație mobilă pe sistemul de operare Android, utilizând arhitectura de tip MVC, care poate comunica prin Bluetooth cu acest placă realizată. În plus, modele de Inteligență Artificială prezentate în capitolele următoare, fiind în mare parte dezvoltate folosind biblioteca Tensorflow, pot fi exportate, programate și rulate pe această placă.

Experimentul descris în acest capitol a prezentat la conferința internațională "International Conference on Interactive Mobile Communication Technologies and Learning" (IMCL) 2021, desfășurată la Salonic (Grecia) în perioada 4 – 5 Noiembrie 2021, și publicată în volumul conferinței - SpringerLink, care este indexat ISI:

- **H. A. Modran**, D. Ursutiu, C. Samoila, T. Chamunorwa: „Intelligent IoT Biomedical Bluetooth Data Acquisition System”, In *New Realities, Mobile Systems, and Applications – Proceedings of the International Conference on Interactive Mobile Communication, Technologies, and Learning (IMCL) 2021*, [http://dx.doi.org/10.1007/978-3-030-96296-8\\_88](http://dx.doi.org/10.1007/978-3-030-96296-8_88)

## 2. APLICAȚII ALE INTELIGENȚEI ARTIFICIALE ÎN PROCESAREA SEMNALELOR BIOMEDICALE ȘI FIZIOLOGICE

### 2.1. Detectarea patologiilor cardiovasculare folosind IoT și IA

Abordarea utilizată în acest studiu se bazează pe dezvoltarea unui sistem de colectare și prelucrare a datelor despre tensiunea arterială folosind algoritmi de învățare automată [75]. Datele achiziționate sunt obținute utilizând un dispozitiv IoT puternic și ieftin bazat pe circuitul integrat cu microcontroler PSoC6 de la compania Infineon. Datele sunt apoi procesate în interiorul unui instrument virtual (VI) creat în Laboratorul de instrumentare virtuală de inginerie (LabVIEW) care folosește un model de învățare automată dezvoltat în Python. S-au comparat cei mai folosiți algoritmi de învățare automată care sunt adecvați pentru o problemă de clasificare și s-a ales cel care are cele mai bune metrice de evaluare. Astfel, sistemul dezvoltat folosește o rețea neuronală de perceptron multistrat pentru a prezice dacă o persoană are un risc ca în următorii 5 ani să dezvolte boli cardiovasculare [76]. Pentru antrenarea modelului s-a folosit un set de date care constă din 70.000 de date. Comparativ cu studii similare [77], modelul de învățare automată dezvoltat a obținut indicatori de performanță și o acuratețe mai mare. Subiecții pe care s-a testat sistemul au semnat un acord IRB conform Regulamentului General privind Protecția Datelor (GDPR), iar datele nu au fost stocate.

Microcontrolerul PSoC6 BLE a fost programat pentru a obține date despre tensiunea arterială în PSoC Creator folosind limbajul de programare C. Pentru schemă (Fig. 11) a fost utilizată o componentă BLE pentru trimiterea datelor folosind Bluetooth 5.0 și o componentă UART pentru transmiterea datelor prin portul serial al computerului. Procesoarele comunică între ele folosind un mutex pentru a controla accesul la o variabilă partajată. Cu securitatea încorporată oferită de PSoC6, sistemul IoT este astfel protejat.

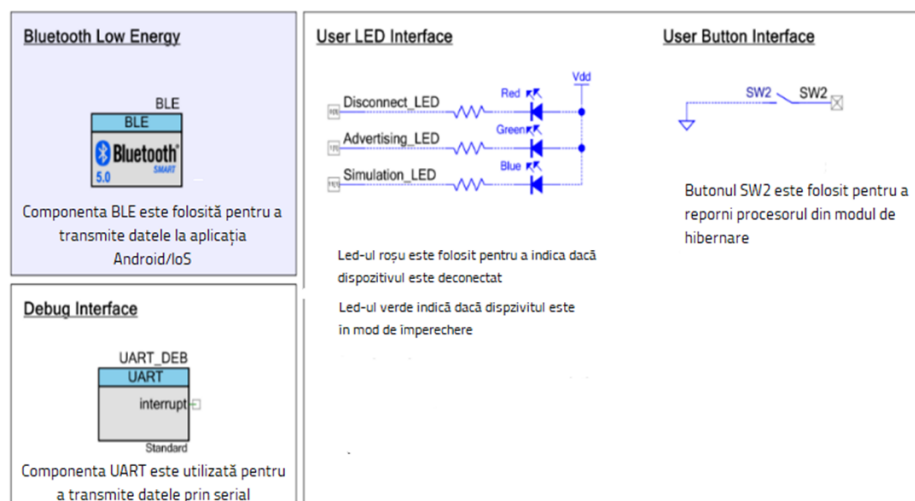


Fig. 11. Schema PSoC a sistemului IoT.

Sistemul IoT poate fi controlat prin Bluetooth utilizând un smartphone Android sau iOS, în timp ce tensiunea arterială sistolică și diastolică achiziționată de dispozitivul PSoC 6 poate fi urmărită pe smartphone în timp real (Fig. 12).





**Fig. 12.** Aplicația Android pentru controlul sistemului.

Datele care se folosesc pentru a realiza modelul pot proveni uneori din distribuții multiple. Există trei seturi principale utilizate în diferite etape ale construirii unui model de învățare automată: setul de date de antrenare, setul de validare și setul de testare, prin urmare setul de date a fost divizat în aceste 3 categorii [79]. Mărimea fiecăruia dintre aceste trei seturi de date poate fi aleasă în funcție de tipologia problemei [80], dar, ca abordare comună, se recomandă ca setul de instruire să conțină aproximativ 60% din setul de date inițial, în timp ce subseturile de validare și instruire ar trebui să cuprindă fiecare 20%.

Procesul de achiziție a datelor poate fi controlat prin intermediul aplicației mobile conectate prin Bluetooth la microcontrolerul PSoC. Kitul PSoC6 a fost programat pentru a obține date de tensiune arterială și pentru a le afișa grafic, utilizând componenta de depanare a receptorului-transmițător universal asincron (engl. Universal Asynchronous Receiver-Transmitter - UART) din schema PSoC Creator, la intervale regulate de timp prin portul serial. Pentru activarea portului de depanare, se setează macrocomanda `DEBUG_UART_ENABLED` la `ENABLED`.

Pentru a se vedea datele afișate pe terminal se poate conecta la portul serial utilizând Putty și acesta va afișa în terminat valorile achiziționate. Aceste date pot fi disponibile și în mediul LabVIEW, fapt pentru care a fost dezvoltat un instrument virtual (engl. Virtual Instrument - VI) care utilizează funcția VISA pentru a se conecta la portul serial al computerului.

Pentru dezvoltarea modelului de învățare automată, a fost utilizat limbajul de programare Python împreună cu bibliotecile NumPy și Pandas. Deoarece modelul este antrenat cu un set de date care conține date etichetate, ar trebui utilizat un algoritm de învățare supervizat. Pentru alegerea algoritmului de învățare supervizat adecvat pentru acest model, au fost comparați algoritmi cei mai utilizați. Deoarece rețelele neuronale au o viteză de predicție mai bună decât SVM-urile, a fost selectată rețeaua neuronală perceptron multistrat (MLP) pentru model (Fig. 13). Modelul care se folosește conține mai multe caracteristici, egal cu numărul caracteristicilor setului de date de

antrenare - dintre care cele mai importante sunt vârsta, tensiunea arterială sistolică și diastolică, și 3 straturi ascunse.

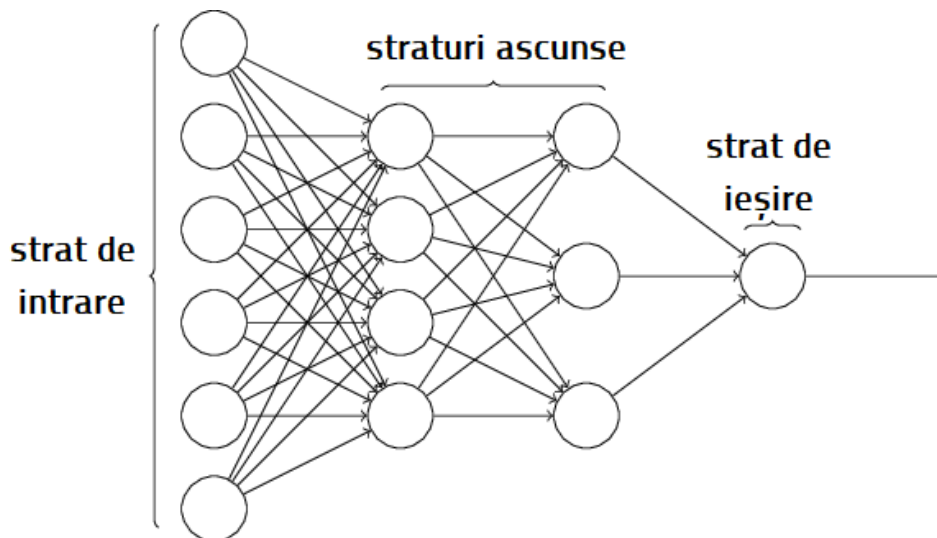


Fig. 13. Arhitectura rețelei neuronale MLP.

Pentru a importa modelul de învățare automată în LabVIEW, a fost creat un subVI care utilizează nodul Python pentru a obține o sesiune Python. Acest subVI a fost apoi folosit în instrumentul virtual principal care are scopul de a achiziționa datele de pe dispozitivul IoT, de a le trimite la modulul Python și de a afișa predicția făcută de modelul de învățare automată. În timp ce pragul implicit de interpretare a probabilităților pentru etichetele din problemele de clasificare este de obicei 0,5 [83], în diagnosticul medical este foarte important ca predicțiile să fie cât mai exacte. Prin urmare, în acest model pragul de încredere pentru predicție a fost stabilit la 0.7. Panoul frontal al acestui VI (Fig. 14) afișează, de asemenea, răspunsul primit de la chip-ul PSoC6 și octeții citiți de la acestea, în scopuri de depanare. Mai mult, în partea dreaptă este afișată și tensiunea arterială sistolică și diastolică.

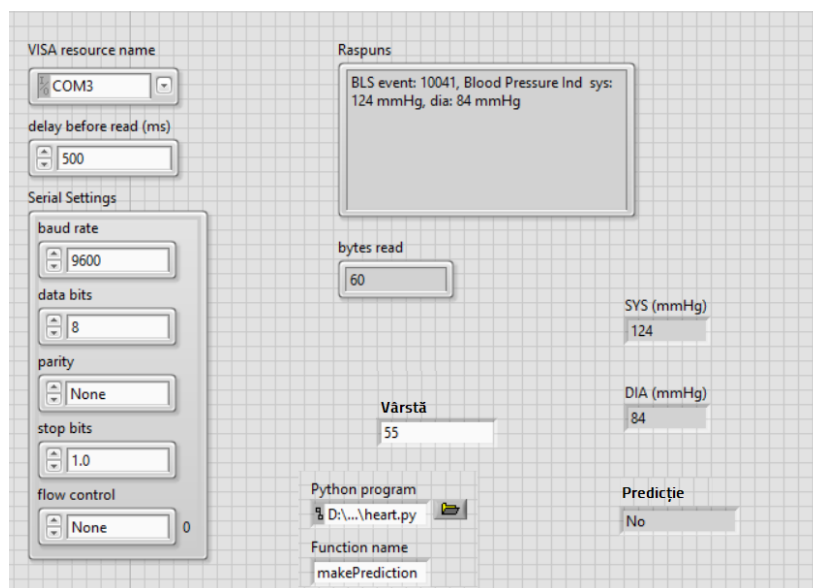


Fig. 14. Panoul frontal al IV de predicție.



## 2.2. Detectia obosealii folosind dispozitive portabile

Oboseala este o afecţiune nespecifică comună care se identifică cu reducerea capacităţii de muncă şi a motivaţiei de a pune în aplicare anumite sarcini. Acumularea de oboseală poate provoca un sindrom de oboseală cronică, tulburări, disfuncţii sau boli asupra sănătăţii umane. Oboseala este clasificată ca:

- a) fizică atunci când afectează performanţa mişcării muşchilor
- b) mentală în cazul în care este legată de suprasolicitarea sau munca sub presiune şi stres
- c) emoţională, care este cunoscută sub numele de oboseală pe termen lung sau cronică, cu incapacitatea de a păstra concentrarea mentală [84].

Tehnicile de învăţare automată (engl. *machine learning* –ML) sunt aplicate pentru a recunoaşte activităţile umane zilnice şi evaluarea severităţii tremurului, precum şi pentru a interpreta datele tremurului şi a prezice oboseala. Pentru compensarea tremurului, sunt necesare recunoaşterea distinctă şi precisă, precum şi separarea mişcărilor involuntare ale mâinilor în timp real.

Studiul actual urmăreşte realizarea unui model neinvaziv pentru estimarea obosealii în timp real, bazat pe semne tipice de oboseală, cum ar fi tremurul şi ritmul cardiac. Obiectivele cercetării sunt de a distinge semnele timpurii ale obosealii şi epuizării, pentru a preveni efectele nefavorabile ale acestora, folosind datele de mişcare şi fiziologice obţinute prin utilizarea unui ceas inteligent (engl. *smartwatch*), cu rol de senzor specializat. Vor fi aplicate tehnici de învăţare automată avansate pentru a crea o aplicaţie mobilă ce va avertiza utilizatorul când apar primele semne de oboseală.

Un grup de 10 de voluntari de diverse vârste au luat parte la acest studiu. Aceştia au purtat ceasul timp de o săptămână, în timpul activităţilor lor zilnice şi, de asemenea, au realizat un jurnal zilnic referitor la activităţile desfăşurate. S-a încheiat, în prealabil, un acord IRB cu aceştia, iar datele achiziţionate şi stocate respectă Regulamentul General privind Protecţia Datelor (GDPR).

Un accelerometru compact de înaltă precizie integrat în smartwatch a fost utilizat pentru a captura tremurul fiziologic de joasă frecvenţă. Senzorul optic de pe smartwatch a colectat datele despre ritmul cardiac. Datele colectate sunt salvate direct pe ceas, ca fişier CSV, cât şi în cloud şi va fi dezvoltat un model de învăţare automata care prezice oboseala pe baza cuantificării tremurului şi a bătăilor inimii. Pentru a colecta datele accelerometrului şi ritmului cardiac în mod continuu în timp real, au fost utilizate ceasurile inteligente TicWatch E<sup>1</sup> şi Polar M600<sup>2</sup>, care combină ambii senzori. Aplicaţia Android dezvoltată pentru smartwatch înregistrează şi afişează grafic datele.

Pentru colectarea datelor fiziologice (ritm cardiac şi tremur) a fost dezvoltată o aplicaţie Android care poate fi rulată şi pe smartwatch. Această aplicaţie are rolul de a afişa grafic pe ecran şi de a stoca local, în fişier CSV, şi pe cloud datele achiziţionate [88].

Aplicaţia dezvoltată poate fi utilizată atât pe smartwatch-uri (ceasuri inteligente) cu ecran rotund (TicWatch), cât şi pentru cele cu ecran pătrat (Polar) (Fig. 15).

---

<sup>1</sup> <https://www.mobvoi.com/af/pages/ticwatchse>

<sup>2</sup> <https://support.polar.com/en/support/m600>



Fig. 15. Aplicația Android pe TicWatch.

Datele colectate din ritmul cardiac sunt înregistrate o dată pe minut (Fig. 16 a), iar cele de tremur la o frecvență de 50Hz (Fig. 16 b) și sunt stocate în fișiere CSV separate, împreună cu data și ora la care au fost înregistrate de către subiect într-o zi normală de lucru.

1	Data	Ritm cardiac
2	14-05-2020 11:23:02	91
3	14-05-2020 11:24:01	113
4	14-05-2020 11:25:01	96
5	14-05-2020 11:27:00	98
6	14-05-2020 11:28:02	99
7	14-05-2020 11:29:02	102
8	14-05-2020 11:30:01	116
9	14-05-2020 11:31:02	111
10	14-05-2020 11:32:01	110
11	14-05-2020 11:33:01	102
12	14-05-2020 11:34:01	100
13	14-05-2020 11:35:02	90
14	14-05-2020 11:36:01	102
15	14-05-2020 11:37:01	112
16	14-05-2020 11:38:01	109
17	14-05-2020 11:39:01	128
18	14-05-2020 11:40:01	112
19	14-05-2020 11:41:02	119
20	14-05-2020 11:42:02	103
21	14-05-2020 11:44:02	99

(a) Date ritm cardiac

1	A	B	C	D	E
1	Data	X	Y	Z	
2	14-05-2020 09:23:37	0.54	-10.48	3.56	
3	14-05-2020 09:23:37	0.45	-10.15	2.47	
4	14-05-2020 09:23:37	1.09	-9.01	3.15	
5	14-05-2020 09:23:37	0.93	-7.54	6.44	
6	14-05-2020 09:23:37	0.93	-8.73	4.85	
7	14-05-2020 09:23:37	0.76	-9.02	4.69	
8	14-05-2020 09:23:37	0.43	-7.66	4.75	
9	14-05-2020 09:23:38	0.73	-7.72	5.64	
10	14-05-2020 09:23:38	0.69	-7.48	5.07	
11	14-05-2020 09:23:38	0.44	-9.97	3.38	
12	14-05-2020 09:23:38	0.6	-8.3	5.83	
13	14-05-2020 09:23:38	1.08	-8.56	4.15	
14	14-05-2020 09:23:38	1.27	-6.35	5.54	
15	14-05-2020 09:23:38	0.64	-7.67	4.58	
16	14-05-2020 09:23:38	0.03	-7.5	6.5	
17	14-05-2020 09:23:42	0.21	-8.06	5.53	
18	14-05-2020 09:23:42	0.21	-5.78	6.59	
19	14-05-2020 09:23:42	0.4	-9.05	5.42	
20	14-05-2020 09:23:42	1.91	-8.34	2.46	

(b) Date tremur

Fig. 16. Fișiere CSV date ritm cardiac și tremur.

Aplicația utilizează un *ForegroundService* pentru a putea rula și achiziționa date și în fundal, sporind durata de viață a bateriei dispozitivului. Conține un serviciu *Heartbeat*, care măsoară datele privind ritmul cardiac și le stochează într-un fișier local și pe Cloud. În plus, include și un *AccelerometerService* care achiziționează date despre tremur și le salvează. Deoarece necesită permisiunea de a accesa senzorii dispozitivului, aplicația va solicita utilizatorului să acorde această permisiune la prima utilizare.

După colectarea timp de mai multe zile a parametrilor medicali și fiziologici, cele două fișiere care conțin aceste date au fost prelucrate și procesate. Datele au fost procesate utilizând mediul de programare Python și apoi afișate grafic, atât pentru ritmul cardiac (Fig. 17), cât și pentru datele de accelerometru (Fig. 18). Aceste grafice oferă posibilitatea de a vizualiza și analiza datele procesate, fiind un pas pregătitor înainte de procesul de curățare și divizare a setului de date. Datele de tremur colectate de accelerometru au fost analizate grafic, atât afișând într-un singur grafic toate cele 3 axe, cât și în trei grafice distincte (câte unul pentru fiecare axă – x, y, z).




Fig. 17. Date ritm cardiac.




Fig. 18. Date accelerometru.

## 2.3. Clasificarea activităților umane prin tehnici de margine (Edge)

De regulă, procesul de dezvoltarea a unui model de recunoaștere a activităților umane constă din patru etape principale (Fig. 19):

1. achiziția semnalului de accelerație
2. preprocesarea datelor
3. recunoașterea activității (bazată pe tehnici de învățare profundă)
4. interfața cu utilizatorul pentru transmiterea și afișarea predicției

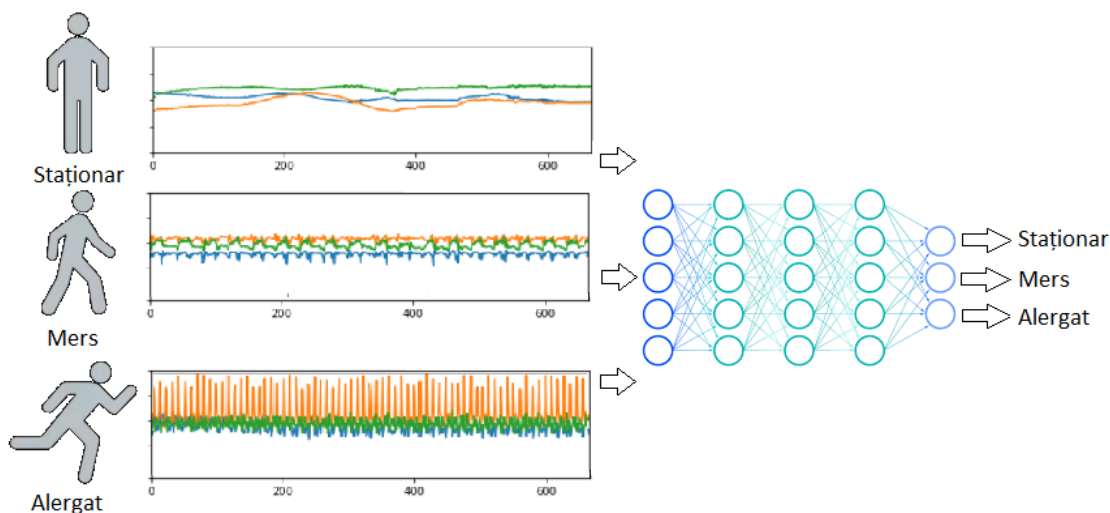


Fig. 19. Etapele dezvoltării unui model de recunoaștere a activităților umane.

Acest experiment realizează clasificarea activităților umane pe baza datelor senzorului de mișcare (accelerometru și giroscop). Model programat pe dispozitivul IoT a fost pre-antrenat pe computer folosind Keras și clasifică câteva activități uzuale: staționar, mers și alergat.

Funcționarea aplicației este descrisă în Fig. 20. Într-o buclă infinită, dispozitivul IoT citește datele de la un senzor de mișcare (BMX160) atașat la PSoC6, pentru a detecta activitățile. Setul de date constă din date de orientare pe 3 axe atât de la accelerometru cât și de la giroscop. Un timer este configurat să întrerupă la 128 Hz. Operatorul de întrerupere citește toate cele 6 axe prin intermediul SPI și semnalează o sarcină de procesare a datelor atunci când buffer-ul intern are 128 de eşantioane noi. Acesta efectuează un filtru IIR și o normalizare min-max pe 128 de eşantioane simultan. Aceste date procesate sunt apoi transmise procesorului de inferență. Procesorul de inferență determină și returnează încrederea de predicție pentru fiecare clasă de activități. Dacă încrederea depășește un procent de 80%, activitatea prezisă este afișată pe terminalul UART.

Această aplicație folosește FreeRTOS. În cadrul acestuia a fost definită și rulată o sarcină în sistem - sarcina activităților, care procesează datele primite și le transmite către modelul de ML.

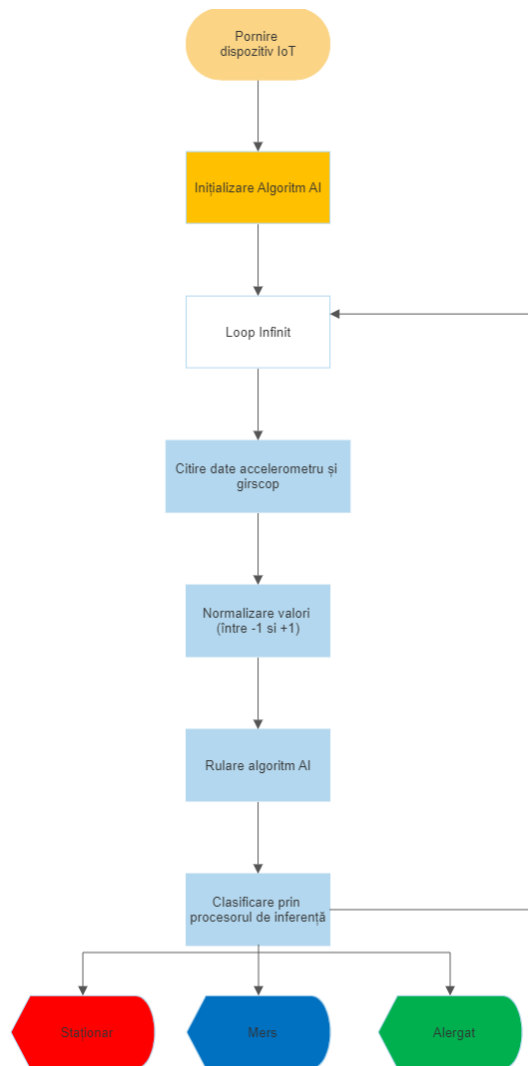


Fig. 20. Schema bloc a programului dezvoltat.

Datele pentru antrenarea modelului de învățare automată au fost colectate de la mai mulți utilizatori în timpul mai multor tipuri de activități, prin intermediul senzorului BMX160 atașat la PSoC6, apoi au fost etichetate în funcție de activitate și salvate într-un fișier CSV.

După colectarea datelor, a fost dezvoltat un model folosind acele date – pas care include atât antrenarea cât și calibrarea modelului. Pentru această problemă a fost realizat un model de rețea neuronală în Python folosind Keras.

Modelul a fost apoi antrenat utilizând datele colectate anterior, folosindu-se următoarele caracteristici:

- optimizator *Adam*
- rată de învățare de 0.0001
- metrice: acuratețe, matrice de confuzie
- 20 epoci (*epochs*) și 1000 de pași la fiecare epocă

Matricea de confuzie a fost afișată grafic, pentru a se putea vizualiza performanțele de clasificare ale modelului (Fig. 21).




Fig. 21. Matricea de Confuzie a Modelului.

Ponderile și structura modelului au fost salvat apoi într-un fișier pentru a putea fi folosit la programarea dispozitivului IoT, iar datele de validare și de calibrare ale acestuia au fost salvate într-un fișier separat. Indicatori de performanță ai modelului sunt ilustrați în Tabelul 1.

Tabelul 1. Indicatori de performanță ai modelului.

Indicator	Valoare
Pierdere ( <i>Loss</i> )	0.0169
Acuratețe	0.9971
Precizie	0.9975
Recall	0.9947
Scor F1	0.9961

Modelul rețelei neuronale convoluționale (CNN) constă din două blocuri convoluționale și două straturi complet conectate. Fiecare bloc convoluțional include operații convoluționale, inclusiv unitate liniară rectificată (*ReLU*) și strat de tip dropout, cu adăugarea unui strat de aplatizare (*Flatten*) a lotului după primul bloc. Straturile convoluționale acționează ca extractoare de caracteristici și oferă reprezentări abstracte ale datelor senzorilor de intrare în harta de caracteristici. Ele captează dependențe pe termen scurt (relații spațiale) ale datelor. În rețeaua dezvoltată, caracteristicile sunt extrase și apoi utilizate ca intrări ale unei rețele complet conectate, folosind activarea *Softmax* pentru clasificare.

După aceasta, modelul generat a fost programat pe dispozitiv pentru a fi testat. Configuratorul ML arată și resursele consumate de modelul realizat, care sunt potrivite pentru orice microcontroler. Modelul a fost validat pe PC, rezultatele fiind foarte bune atât pentru quantizare de tip 8x8 cât și pentru cea de tip float. S-a obținut o acuratețe relativă de 100%, iar eroarea de predicție nepotrivită a fost de doar 0.001, în timp ce memoria utilizată este foarte mică (aprox. 16 kB).

Înainte de a fi programat pe device-ul PSoC6, modelul trebuie verificat pentru a valida dacă acesta este optimizat pentru hardware-ul disponibil pe acel dispozitiv. În urma validării realizate în ML Configurator, s-a obținut o acuratețe de 100% și eroare de predicție 0.01 (Fig. 22).

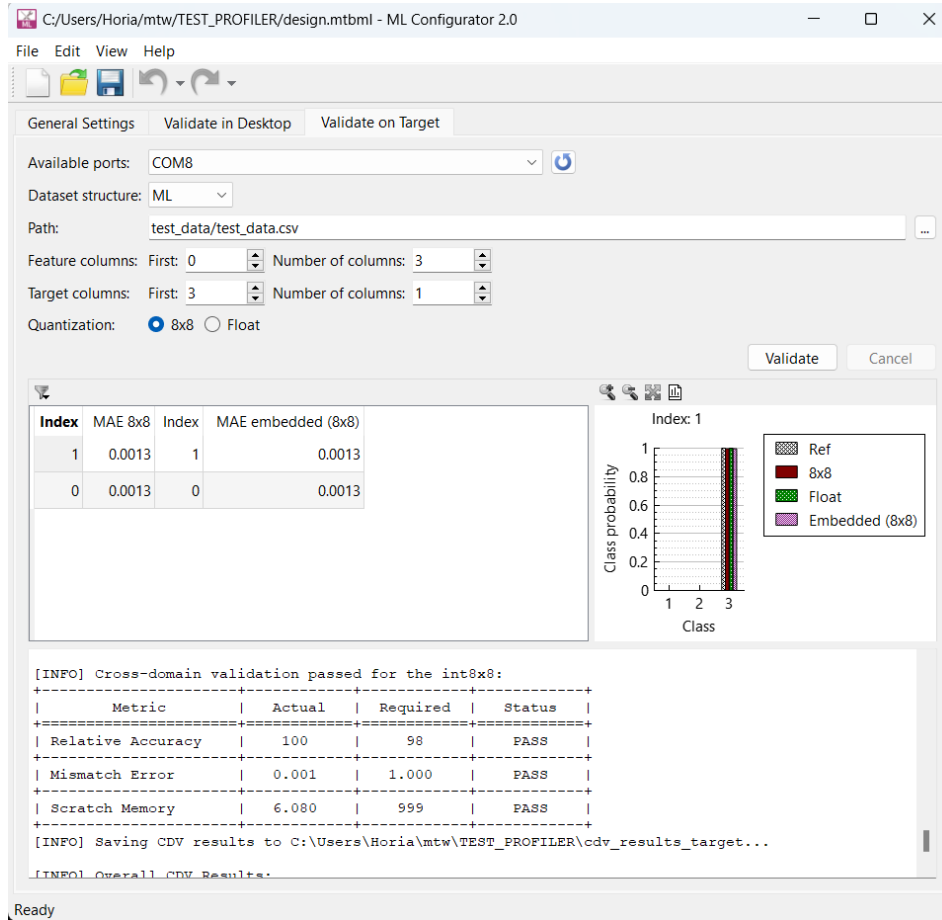


Fig. 22. Validarea modelului pe PSoC6.

După programarea dispozitivului IoT, prin intermediul conexiunii serial la computer, acesta afișează pe terminalul UART predicția în timp real, împreună cu procentajul de încredere pentru fiecare clasă posibilă (Fig. 23).

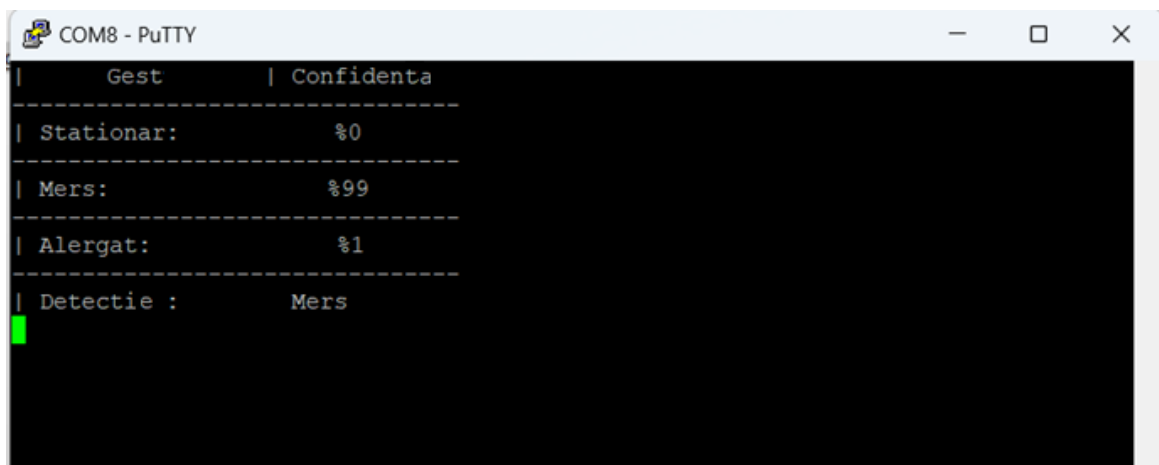


Fig. 23. Predicția modelului.



## 2.4. Rezumatul capitolului. Diseminare

Acest capitol a descris aplicarea algoritmilor de Inteligență Artificială în prelucrarea semnalelor biomedicale și fiziologice, axată pe detectarea bolilor cardiovasculare, a oboselii folosind un ceas inteligent și a activităților, prin tehnici de procesare și predicție la margine (*edge*).

Primul experiment se bazează pe dezvoltarea unui sistem de achiziție și procesare a datelor despre tensiunea arterială folosind un model de învățare automată. Datele despre tensiunea arterială au fost obținute utilizând un dispozitiv IoT foarte accesibil – microcontrolerul PSoC6. Modelul utilizează o rețea neuronală de tip perceptron multistrat (MLP) pentru a prezice cu precizie riscul de 5 ani de a dezvolta BCV în LabVIEW folosind modulul Python Node. În comparație cu studii similare pentru prezicerea BCV, modelul de învățare automată dezvoltat a obținut indicatori de performanță de o acuratețe mai mare.

În cadrul celui de-al doilea studiu se urmărește realizarea unui model proactiv neinvaziv pentru estimarea oboselii în timp real. Au fost colectate și procesate datele de la mai multe persoane și urmează să fie aplicați algoritmi de Inteligență Artificială și învățare automată pe aceste date colectate. Pentru aceasta, se va folosi relația dintre tremur, ritm cardiac și SpO2 pe de o parte și debutul oboselii, pe de altă parte. Rezultatele așteptate sunt definirea unui cadru de avertizare relevant pentru prezența indicațiilor timpurii de oboseală.

Ultimul experiment realizează clasificarea activităților umane pe baza datelor senzorului de mișcare (accelerometru și giroscop). Model programat pe dispozitivul IoT a fost pre-antrenat pe computer folosind biblioteca Keras și clasifică câteva activități uzuale: staționar, mers și alergat. Într-o buclă infinită, dispozitivul IoT citește datele de la un senzor de mișcare (BMX160) atașat la PSoC6, pentru a detecta activitățile. Avantajul principal al acestui experiment este că atât achiziția datelor, cât și procesarea lor și predicția se realizează direct la margine (*edge*), pe chip-ul PSoC6. Această aplicație poate rula direct pe sistemul inteligent descris în Capitolul 2.

Experimentele practice prezentate în acest capitol au prezentate la conferințe internaționale și publicate sau în curs de publicare în volumele conferințelor SpringerLink, indexate ISI:

- **H. A. Modran**, D. Ursuțiu, C. Samoilă, T. Chamunorwa: „Artificial Intelligence System for predicting cardiovascular diseases using IoT devices and Virtual Instrumentation”, In Online Engineering and Society 4.0 – Proceedings of the 18<sup>th</sup> International Conference on Remote Engineering and Virtual Instrumentation (REV) 2021, [http://dx.doi.org/10.1007/978-3-030-82529-4\\_28](http://dx.doi.org/10.1007/978-3-030-82529-4_28).

Web of Science Number: WOS:000772185600028

- **H. A. Modran**, T. Chamunorwa, D. Ursuțiu, C. Samoilă: “Fatigue Estimation using Wearable Devices and Virtual Instrumentation”, In Open Science in Engineering – Proceedings of the 20<sup>th</sup> International Conference on Remote Engineering and Virtual Instrumentation (REV) 2023 (acceptat și prezentat, în curs de publicare).



## 3. APLICAREA INTELIGENŢEI ARTIFICIALE ÎN PROCESAREA SEMNALELOR AUDIO

### 3.1. Recunoaşterea stării transmise de muzică utilizând IA

În experimentul actual, emoția dominantă transmisă de o anumită secvență muzicală a fost estimată folosind un model de Inteligență Artificială [89]. Roata emoțiilor de bază [91] descrie tipurile de emoții în care sunt clasificate melodiile. S-a folosit o abordare categorică, muzica fiind împărțită în grupuri, iar fiecare grupă a fost descrisă cu un adjectiv (trist, fericit, plictisitor etc.).

Structura completă a experimentului presupune următoarele etape (Fig. 24):

- extragere caracteristici audio
- analiza explorativă a datelor
- curățarea setului de date
- antrenarea inițială a modelului
- evaluarea modelului
- proiectarea și dezvoltarea unui clasificator de învățare automată




Fig. 24. Structura experimentului.

Pentru că în viață totul are o vibrație, terapia prin muzică se concentrează pe frecvențe specifice. Șase dintre aceste frecvențe, cunoscute sub numele de frecvențe *sofeggio*, sunt tonuri specifice cunoscute încă din Antichitate pentru a avea un efect benefic asupra minții și a corpului.

Un proces tipic de procesare audio implică achiziția de date și extragerea caracteristicilor acustice relevante pentru problemă, urmate de scheme de luare a deciziilor care implică detectarea, clasificarea și fuziunea cunoștințelor.

Caracteristicile muzicale folosite în cadrul acestui experiment sunt următoarele:

1. caracteristici spectrale:
  - centroid spectral, respectiv frecvența medie a semnalului ponderată după magnitudine
  - roll-off spectral – câte frecvențe sunt concentrate sub un anumit prag
  - flux spectral - cât de mult variază frecvența în timp
  - coeficienți cepstrali de frecvență mel (engl. *mel frequency cepstral coefficients* – MFCCs)
2. caracteristici temporale
  - zero-crossing rate - numărul de treceri prin zero în domeniul temporal într-un cadru
  - centroid temporal - punctul de timp dintr-un semnal ce reprezintă un punct de echilibrare temporal al energiei evenimentului sonor

- timp de atac log - timpul necesar pentru a atinge amplitudinea maximă a unui semnal dintr-un prag minim de timp
3. caracteristici melodice/armonice:
    - profilul clasei de ton - caracteristică îmbunătățită de distribuție a înălțimii, formată din secvențe de vectori caracteristici care descriu tonalitatea
    - claritatea cheii
    - schimbarea armonică - ritmul cu care acordurile se schimbă într-o melodie
    - modul muzical
  4. caracteristici ritmice:
    - histograma bătăilor
    - tempo mediu (măsurat în bătăi pe minut)

Etapa de analiză exploratorie a datelor a fost efectuată după extragerea caracteristicilor audio din setul de date. Scopul principal al acestui pas a fost de a determina care caracteristici ar putea fi utilizate ca indicatori relevanți pentru a face o predicție precisă. Distribuția fiecărei variabile a fost reprezentată grafic și apoi analizată. Cele mai relevante 10 caracteristici audio au fost selectate după analiza fiecărei caracteristici, iar celelalte au fost eliminate din setul de date.

Având în vedere că problemele de clasificare folosesc date etichetate, aceste etichete sunt folosite pentru fiecare fișier audio. Melodiile au fost divizate în 4 categorii, reprezentate prin culori diferite, respectiv „Energetice”, „Calme”, „Fericite” și „Triste”. Aceste categorii au fost selectate pe baza articolului scris de către M. Nuzzolo [97], care explică care este cel mai bun mod de clasificare a muzicii după dispoziție.

În procesul de normalizare a caracteristicilor, a fost utilizat un *MinMaxScaler* pentru a scala valorile între un interval de  $[0,1]$  și păstrarea formei distribuției originale. În cele din urmă, setul de date a fost împărțit, 80% fiind alocate pentru antrenarea rețelei și restul de 20% pentru testare.

Pentru a construi modelul s-a utilizat biblioteca Keras, această bibliotecă fiind concepută pentru a permite experimentarea rapidă cu rețelele neuronale profunde. Au fost testate și comparate mai multe valori posibile la selectarea straturilor de intrare și de ieșire, precum și a funcțiilor de activare.




Fig. 25. Structura rețelei neuronale.

Straturile reţelei neuronale dezvoltate sunt după cum urmează (Fig. 25):

- Un strat de intrare cu 10 caracteristici audio ca intrare
- Un strat ascuns complet conectat cu mai multe noduri cu o funcţie de activare Rectified Linear Unit (*ReLU*)
- Un strat de ieşire care conţine patru ieşiri (una pentru fiecare categorie) cu o funcţie de activare Softmax. Prin urmare, a fost nevoie şi de un clasificator cu rol de estimator

Estimatorul a fost evaluat utilizând validarea încrucişată K-Fold. După experimentarea cu diferite valori posibile, numărul de împărţiri a fost setat la  $K = 10$ . Precizia generală a modelului a fost de 91,49%. În experimentul curent, modelul a fost antrenat pe 8000 de eşantioane. În cele din urmă, pentru a evalua acurateţea modelului, s-a reprezentat grafic matricea de confuzie (Fig. 26). De asemenea, a fost calculat şi scorul de precizie a modelului.

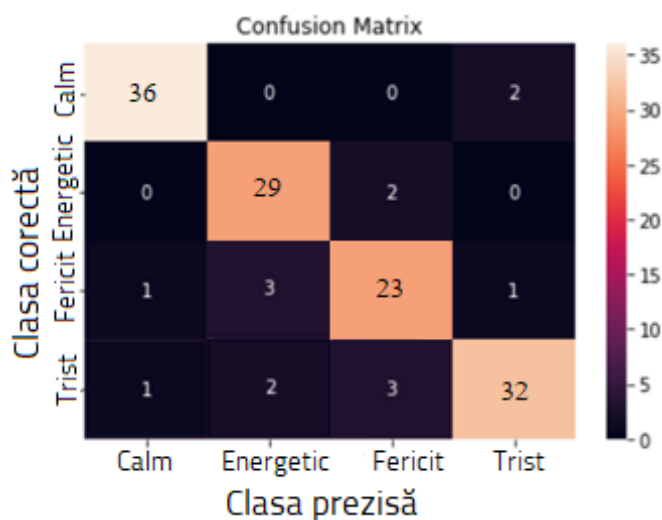


Fig. 26. Matricea de confuzie.

Cu un scor final de acurateţe de 94% şi o în urma analizării matricei de confuzie, s-a observat că modelul a clasificat foarte bine melodiile calme, fericite şi energice, dar acurateţea pentru melodiile triste a fost puţin mai mică, la 85%. De asemenea, a încercat să îmbunătăţească acurateţea modelului prin modificarea unor parametri, cum ar fi dimensiunea lotului, numărul de epoci şi agregarea sau ştergerea unor caracteristici utilizate pentru antrenarea modelului.

Clasificarea se bazează pe un set de date a căror caracteristici au fost deja extrase de către algoritmul prezentat în Subcapitolul 4.1.2, folosind o aplicaţie web dezvoltată în HTML cu JavaScript. Pentru a putea realiza clasificarea, este necesară furnizarea fişierelor ce conţin caracteristicile extrase, generate de aplicaţia Python, fie în format CSV sau JSON. De asemenea, datele sunt validate şi, dacă este cazul, vor fi normalizate, pentru ca algoritmul să aibă o performanţă optimă

Interfaţa utilizator folosită pentru configurarea parametrilor este ilustrată în Fig. 27. Aceasta permite setarea ratei de învăţare, a procentului pentru setul de date de validare, a numărului de epoci şi a numărului de neuronici din stratul ascuns. Apăsând butonul Clasificare, melodiile vor fi clasificate şi rezultatele vor fi afişate în consolă. La rularea clasificatorului, în consolă sunt afişaţi şi parametri de performanţă pentru fiecare pas.

### Clasificare Emoții Muzică

Setarea parametrilor modelului

<b>learningRate</b> <input type="text" value="0.3"/> Număr zecimal între 0 și 1 <i>Default: 0.3</i>	<b>validationSplit</b> <input type="text" value="0.2"/> Număr zecimal între 0 și 1 <i>Default: 0.2</i>	<b>hiddenLayerActivation</b> <input type="text" value="relu"/> <i>Default: relu</i>
<b>outputLayerActivation</b> <input type="text" value="softmax"/> <i>Default: softmax</i>	<b>epochs</b> <input type="text" value="30"/> Număr înreg mai mare decât 1 <i>Default: 30</i>	<b>unitsHiddenLayer</b> <input type="text" value="50"/> Număr înreg mai mare decât 1 <i>Default: 50</i>

Opțiuni rezultat

**yes** Log antrenare

**yes** Rezultate finale

**no** Rezultate intermediare

Fig. 27. UI Aplicație Web.

O altă aplicație Web a fost dezvoltată, permițând meloterapeuților să selecteze unele caracteristici pentru pacient și o melodie, iar, pe baza modelului de învățare automată descris mai sus, aplicația va putea indica dacă acel cântec specific va avea un efect terapeutic pentru pacient. Figura 28 prezintă interfața de utilizator a aplicației.

### Efect Meloterapeutic

<b>Stare</b> <input type="text" value="Fericit"/> Selectați una dintre cele 4 opțiuni	<b>Tipul muzicii</b> <input type="text" value="Clasică"/> Selectați una dintre opțiuni	<b>Selectare melodie</b> <input type="button" value="Choose File"/> Sak....mp3
---	--	---

Fig. 28. Aplicație Web de Clasificare.

Un studiu pentru validarea soluției Machine Learning este în curs de desfășurare, iar sistemul dezvoltat a fost deja testat pe un număr mare de persoane. Participanții au fost fie membri CVCT, fie studenți ai programului de master Meloterapie din cadrul Universității Transilvania din Braşov, care aveau toți dispoziții și gusturi muzicale diferite. Acești subiecți au folosit aplicația în diferite zile și în diverse dispoziții, iar modelul Machine Learning a prezis și ales corect în aproximativ 91,6% din cazuri.

## 3.2. Analiza semnalelor audio folosind DeepLearning

În cadrul acestui experiment a fost construită o rețea neuronală artificială (ANN) pentru clasificarea fișierelor audio în funcție de genul muzical. Spectrogramele au fost afișate folosind biblioteca Librosa din Python.

Fiecare semnal audio constă din mai multe caracteristici. Cu toate acestea, trebuie să extragem caracteristicile relevante pentru problema care încearcă să fie rezolvată. Caracteristicile spectrale (caracteristici bazate pe frecvență), care sunt obținute prin conversia semnalului bazat pe timp în domeniul frecvenței utilizând Transformata Fourier, sunt frecvența fundamentală, componentele de frecvență, centroid spectral, fluxul spectral, densitatea spectrală, derularea spectrală.

Setul de date folosit constă din 1000 de piese audio de 30 de secunde fiecare. Conține 10 genuri, fiecare gen fiind reprezentat de 100 de piese. Piesele sunt toate fișiere audio monofonice pe 16 biți de 22.050 Hz în format *.wav*. Genurile selectate sunt următoarele: Blues, Clasic, Country, Disco, Hiphop, Jazz, Metal, Pop, Raggae și Rock. În primul rând, trebuie convertite fișierele audio în imagini în format PNG (spectrograme). Din aceste spectrograme, trebuie extrase caracteristicile semnificative, adică MFCC-uri, Centroid spectral, Rată de trecere zero, Frecvențe de cromă, Roll-off spectral. Primul pas constă în convertirea fișierelor audio în spectrograme (Fig. 29).




Fig. 29. Exemplu de spectrogramă pentru genului muzical Country.

Din aceste spectrograme au fost extrase următoarele caracteristici ale semnalelor audio:

- Coeficienții cepstrali de frecvență Mel (MFCC)
- Centroid spectral
- Rata de trecere zero
- Frecvențele de cromă
- Roll-off-ul spectral

În pasul următor are loc preprocesarea datelor, ce implică încărcarea datelor CSV, codificarea etichetelor, scalarea caracteristicilor și divizarea setului de date inițial în set de date de antrenare și set de date pentru testare.

Pentru model s-au folosit o reţea neuronală de tip complet conectată, având 4 straturi şi optimizator *adam*.

- strat dens cu 250 de neuroni şi funcţie de activare ReLU
- strat dens cu 128 de unităţi şi funcţie de activare ReLU
- strat dens cu 64 de neuroni şi funcţie de activare ReLU
- strat dens cu 10 unităţi şi funcţie de activare Softmax

După 100 de epoci, precizia atinsă de algoritm a fost de peste 99.8%, obţinându-se astfel o acurateţe mult mai mare decât cea prezentată în alte studii similare existente. După cum ilustrează Fig. 30, în ultimele epoci nu s-a mai îmbunătăţit şi acurateţea, ci doar puţin funcţia de pierdere.

```
Epoch 94/100
7/7 [=====] - 0s 4ms/step - loss: 0.0256 - accuracy: 0.9987
Epoch 95/100
7/7 [=====] - 0s 5ms/step - loss: 0.0209 - accuracy: 0.9987
Epoch 96/100
7/7 [=====] - 0s 5ms/step - loss: 0.0234 - accuracy: 0.9987
Epoch 97/100
7/7 [=====] - 0s 4ms/step - loss: 0.0221 - accuracy: 0.9987
Epoch 98/100
7/7 [=====] - 0s 5ms/step - loss: 0.0175 - accuracy: 0.9987
Epoch 99/100
7/7 [=====] - 0s 5ms/step - loss: 0.0187 - accuracy: 0.9987
Epoch 100/100
7/7 [=====] - 0s 5ms/step - loss: 0.0212 - accuracy: 0.9987
```

**Fig. 30.** Îmbunătăţirea acurateţii reţelei neuronale.

În urma antrenării şi validării modelului în ecosistemul Python, obţinându-se indicatori de performanţă foarte buni (acurateţe de predicţie de aproape 100%), acesta a fost exportat ca model Keras pentru a putea fi utilizat în ModusToolbox şi validat pe microcontrolerul PSoC 6. Având în vedere că modelul a fost optimizat în ceea ce priveşte consumul de memorie pentru a putea fi rulat pe PSoC 6, s-a realizat re-valida modelul pe computer şi, ulterior, pe PSoC6, utilizându-se o cuantizare a ponderilor atât de tip int 8x8, cât şi de tip float. Rezultatele acestei validări sunt prezentate în Tabelul 2.

**Tabelul 2.** Rezultatele validării modelului pe PSoC 6

Indicator de performanţă	Obţinut	Necesar	Status
Acurateţe relativ	100	98	PASS
Eroare de nepotrivire	0.010	1.000	PASS
Memorie scratch	5.280	999	PASS

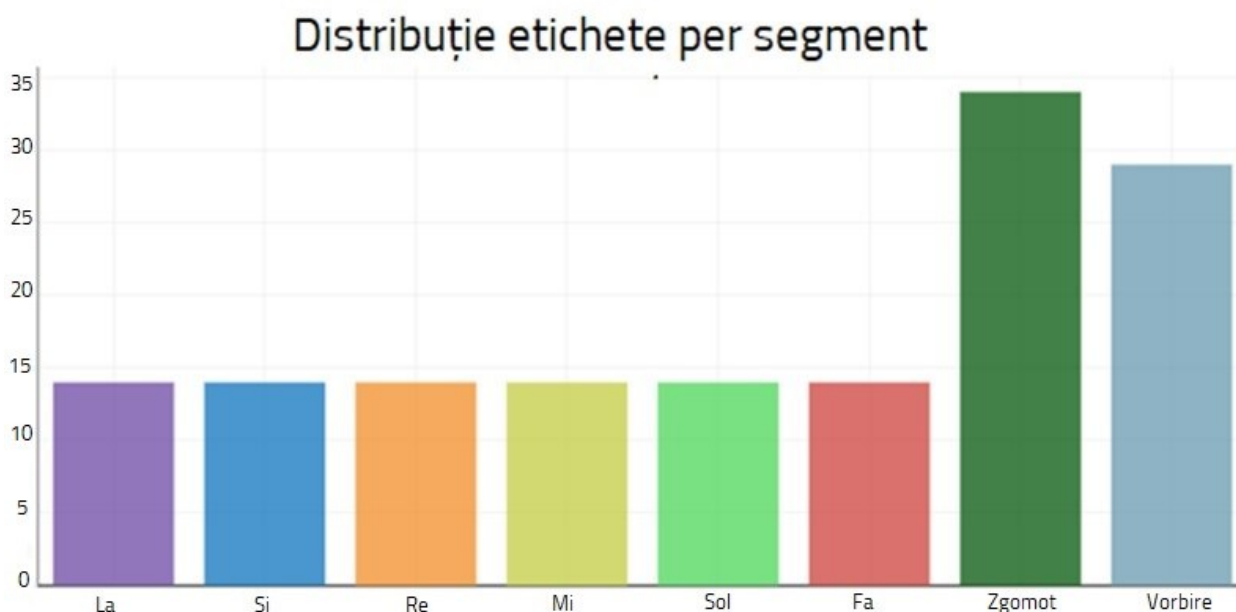
### 3.3. Detectarea notelor muzicale, a vorbirii și a zgomotului

Actualul studiu propune o detectare automată în timp real a notelor muzicale, vorbirii și zgomotului de fundal folosind un model de învățare profundă bazat pe rețea neuronală complet conectată. În acest experiment a fost utilizat plugin-ul SensiML, care ajută la colectarea datelor de la PSoC6 prin senzorii atașați, oferind și metode de etichetare a datelor ce au fost capturate. Când setul de date este colectat și adnotat, poate fi generat și antrenat un model care este optimizat pentru PSoC6. Experimentul constă din următoarele etape:

- achiziția și adnotarea datelor audio
- aplicarea tehnicilor de pre-procesare a semnalului pe datele colectate
- proiectarea și antrenarea unui algoritm de clasificare
- implementarea unui model inteligent optimizat pentru resursele dispozitivului IoT

Datele au fost achiziționate folosind microfonul de pe shield-ul CY8KIT-028-TFT. Acesta conține un microfon digital cu o ieșire de tip Pulse-Width Modulation (PDM) pe un singur bit, permițând convertirea oricărui sunet capturat de microfon într-un semnal digital. Dispozitivul PSoC6 convertește acest semnal digital într-o valoare cuantificată de 16 biți de tip Pulse-Core Modulation (PCM). O întrerupere este declanșată atunci când există suficiente date pentru a fi procesate, și anume cel puțin 128 de eșantioane.

Au fost salvate numeroase segmente pentru fiecare dintre următoarele note muzicale: Re, Mi, Fa, Sol, La, Si. După finalizarea achiziției datelor, acestea au fost etichetate în Data Capture Lab. Pe lângă notele muzicale au fost achiziționate și etichetate mai multe fișiere conținând date audio privind vorbirea și zgomotul ambiental. De asemenea, după achiziție, datele sunt încărcate automat în Cloud. Prin intermediul portalului Cloud datele pot fi vizualizate și pot fi analizate toate etichetele, precum și distribuția lor. După cum ilustrează Fig. 31, pentru fiecare notă muzicală există un număr similar de segmente, în timp ce pentru vorbire și zgomot au fost realizate mai multe, deoarece acestea prezintă o varietate mai mare și caracteristici mai complexe.



**Fig. 31.** Numărul de segmente pentru fiecare etichetă.

Următorul pas este adăugarea unui filtru și setarea întregului Pipeline. În această etapă au fost configurate următoarele elemente (Fig. 32):

- *windowing* de tip segmentator de dimensiune 400 - preia intrarea de la pasul de transformare/filtru al senzorului și memorează datele până când este găsit un segment
- generator de caracteristici în domeniul frecvenței - o colecție de generatori de caracteristici procesează segmentul de date pentru a extrage informațiile semnificative
- data balancing: Undersample Majority Classes - creează un set de date echilibrat prin subeșantionarea claselor majoritare folosind eșantionarea aleatorie fără înlocuire
- cuantizarea caracteristicilor: *min-max scaler* - normalizează și scalează datele la valori întregi între *min\_bound* și *max\_bound*, lăsând coloanele de trecere specificate nescalate
- outlier filter: zscore filter - filtrează vectorii de caracteristici care au valorile în afara unui prag de limită (pragul a fost setat la 3)
- clasificator: TensorFlow Lite for Microcontrollers - preia un vector de caracteristici ca intrare și returnează o clasificare bazată pe un model predefinit
- algoritmul de antrenare: rețea neuronală complet conectată, care cuprinde următoarele caracteristici:
  - staturi dense de dimensiuni (număr de neuroni) 128, 64, 32, 16, 8
  - rată de învățare de 0.01
  - un număr de 4 epoci (*epochs*)
  - activare pentru stratul final de tip Softmax
  - threshold de 0.8 (dacă valoarea clasificată este mai mică, predicția va fi *Unknown*)
  - funcție de pierdere de tip categorical cross entropy
- parametri de validare -acuratețe, scor F1, sensibilitate

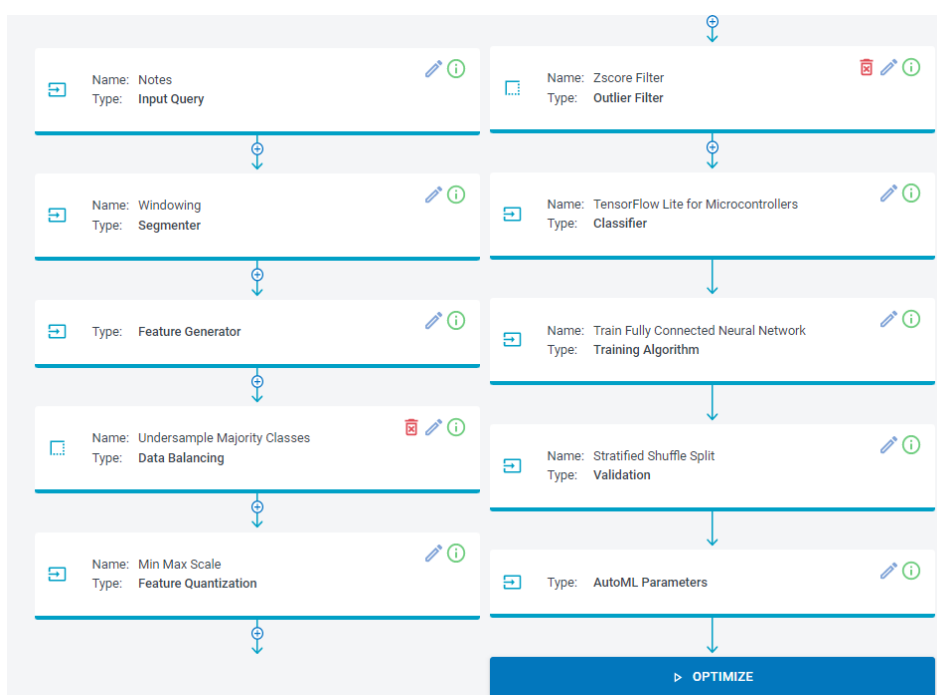


Fig. 32. Caracteristicile pipeline-ului pentru algoritmul ML.



După optimizare este generat un model ale cărui caracteristici sunt afișate grafic (Fig. 33). Așa cum demonstrează Tabelul 3, modelul a obținut indicatori de performanță foarte buni, atât în ceea ce privește acuratețea, sensibilitatea și scorul F1, cât și ca dimensiune a clasificatorului.

**AutoML Results** ▶ RESTART

MODEL NAME	ACCURACY	CLASSIFIER SIZE(B)	NUM. FEATURES	SENSITIVITY	F1-SCORE
Notes_Fold_0	98	20372	23	98	98

Fig. 33. Caracteristicile modelului generat

Tabelul 3. Indicatorii modelului

Indicator	Valoare
Acuratețe	97.69%
Dimensiune clasificator	20372 bytes
Număr caracteristici	23
Senzitivitate	97.6%
Scor F1	98%

Pentru a înțelege mai bine și a analiza cazurile în care clasificatorul a prezis corect sau eronat, a fost determinată matricea de confuzie pe setul de antrenare), cât și una pe setul de validare (Fig. 34). Din acestea reiese faptul că modelul a obținut performanțe foarte bune și similare atât pe setul de date de antrenare (date pe care modelul le-a văzut anterior, fiind furnizate în etapa de antrenare), cât și pe setul de date de validare, pe care rețeaua nu l-a mai văzut până atunci. Singurele predicții eronate observate au fost în ceea ce privește vorbirea și doar într-un caz specific – atunci când intensitatea sunetului este foarte mică și există și zgomot de fundal.

### Validation

	A	B	D	E	E1	G	Noise	Talking	UNK	Support	Sense %
A	198	0	0	0	0	0	0	0	0	198.00	100.00
B	0	191	0	0	0	0	0	0	3	194.00	98.45
D	0	0	190	0	0	0	2	0	5	197.00	96.45
E	0	0	0	197	0	0	0	0	1	198.00	99.49
E1	0	0	0	0	186	0	0	0	0	186.00	100.00
G	0	3	4	1	1	180	1	0	4	194.00	92.78
Noise	0	0	0	0	0	0	182	0	3	185.00	98.38
Talking	0	0	1	0	0	0	5	180	3	189.00	95.24
Total	198.00	194.00	195.00	198.00	187.00	180.00	190.00	180.00	19	1541.00	
Pos_Pred(%)	100.00	98.45	97.44	99.49	99.47	100.00	95.79	100.00		Acc(%)	97.60

Fig. 34. Matricea de confuzie pentru validarea rețelei.

Au fost testate mai multe variante pentru numărul de epoci, iar în urma analizei grafice a acestora s-a ajuns la concluzia că cel mai bun număr atât în ceea ce privește timpul de antrenare și de predicție, precum și acuratețea, este 4.

Având în vedere că modelul funcţionează foarte bine pe datele de testare și validare, poate fi rulat pe date în timp real pentru a valida funcţionalitatea acestuia pe dispozitivul PSoC6. Aplicaţia programată pe PSoC6 transmite predicţia realizată în timp real prin intermediul UART, putând astfel fi vizualizate atât prin Putty/Tera Term sau Open Gateway. Prin intermediul Open Gateway, se poate realiza conexiunea serială la portul COM care a fost alocat dispozitivului IoT. De asemenea, la crearea modelului a fost generat și un fişier JSON pentru a mapa numărul clasei cu numele dată acestora prin intermediul etichetelor. După realizarea conexiunii, în modul testare (*Test Model*) este afişată predicţia curentă în timp real, împreună cu istoricul predicţiilor realizate anterior (Fig. 35).

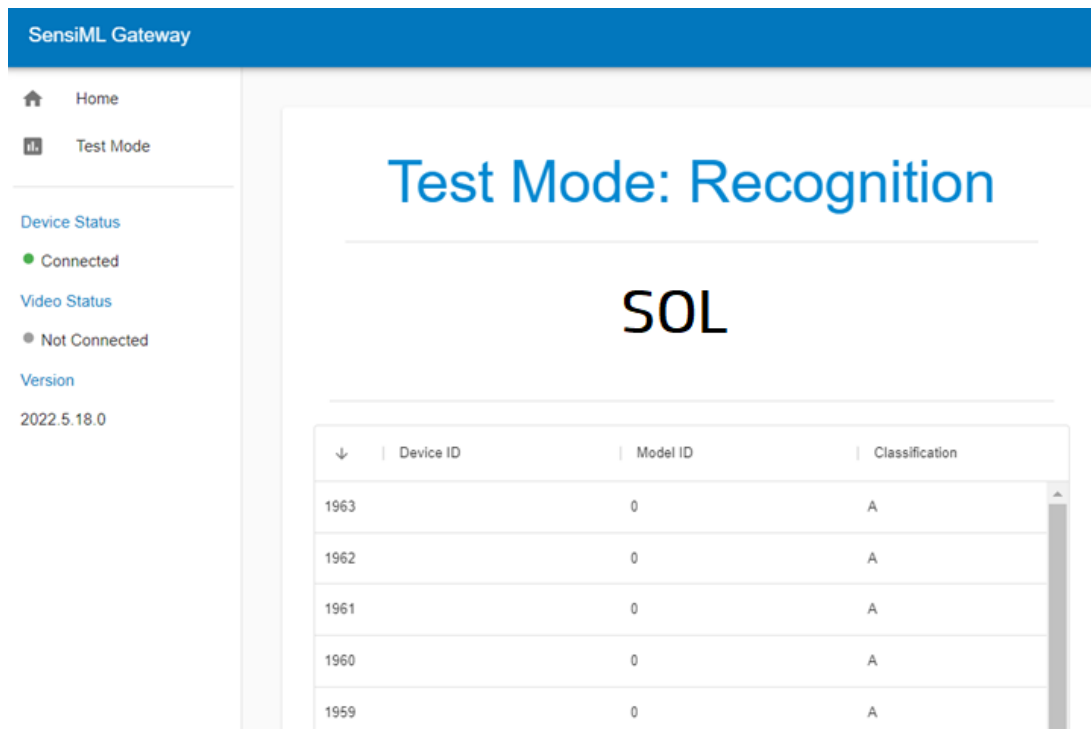


Fig. 35 Testarea modelului pe dispozitivul IoT.

În plus, predicţia este afişată și pe ecranul CY8KIT-028-TFT conectat la PSoC6 (Fig. 36).




Fig. 36. Afişarea predicţiei pe ecranul TFT.

### 3.4. Rezumatul capitolului. Diseminare

Acest capitol ilustrează aplicarea modelelor de învățare profundă în procesarea semnalelor audio, în special pentru recunoașterea stărilor transmise de muzică, detectarea genului muzical, precum și a notelor muzicale, a vorbirii și a zgomotului, utilizând tehnici de procesare de tip *edge* (direct pe microcontroler).

Având în vedere că studiile anterioare nu au abordat în detaliu relația dintre caracteristicile muzicii și efectele lor terapeutice prin procesarea semnalului audio, primul studiu descris în acest capitol a propus o soluție de învățare automată pentru recunoașterea efectului terapeutic transmis de muzică. Algoritmul dezvoltat este un clasificator ce utilizează o rețea neuronală multiclasă. Acesta cuprinde un strat de intrare cu zece caracteristici, un strat ascuns complet conectat cu mai multe unități ascunse și un strat de ieșire. De asemenea, a fost dezvoltată o aplicație Web pentru personalizarea hiperparametrilor modelului de învățare automată, precum și o altă aplicație pentru a prezice dacă o melodie este potrivită pentru o anumită persoană.

În al doilea experiment a fost construită o rețea neuronală artificială pentru clasificarea fișierelor audio în funcție de genului muzical. Semnalele audio au fost transformate în spectrograme, din care au fost extrase caracteristicile semnificative. Caracteristicile spectrale principale de frecvență, care sunt obținute prin conversia semnalului din domeniul timpului în domeniul frecvenței utilizând Transformata Fourier, sunt frecvența fundamentală, componentele de frecvență, centroidul spectral, fluxul spectral, densitatea spectrală, derularea spectrală. După 128 de epoci, precizia atinsă de algoritm a fost de peste 99%, obținând astfel o acuratețe mai mare decât cea ilustrată în alte studii similare existente.

Ultimul experiment practic propune o detectare automată în timp real a notelor muzicale, vorbirii și zgomotului de fundal folosind un model de învățare profundă bazat pe rețea neuronală complet conectată. În acest experiment a fost utilizat plugin-ul SensiML, care ajută la colectarea datelor de la PSoC6 prin senzorii atașați, oferind și metode de etichetare a datelor ce au fost capturate. După ce setul de date a fost colectat și adnotat corespunzător, a fost dezvoltat și antrenat un model de învățare profundă care este optimizat pentru PSoC6. Inovația principală a acestei soluții este că procesarea datelor are loc în timp real, la margine (*edge*), pe chip-ul PSoC6, putând fi astfel rulat pe placa inteligentă descrisă în Capitolul 2.

Studiul descris în acest capitol a fost publicat în jurnalul Sensors de la MDPI:

- **H. A. Modran**, T. Chamunorwa, D. Ursuțiu, C. Samoilă, H. Hedesiu: "Using Deep Learning to Recognize Therapeutic Effects of Music Based on Emotions", Sensors. 2023; 23(2):986, ISSN 1424-8220, <https://doi.org/10.3390/s23020986>  
IF: 3.847, CiteScore: 6.8  
Web of Science Number: WOS:000927263000001  
Journal Rank: JCR - Q2 / CiteScore - Q1

## 4. REDUCEREA ZGOMOTULUI DIN SEMNALE FOLOSIND INTELIGENȚA ARTIFICIALĂ

### 4.1. Reducerea zgomotului din semnalele audio folosind Deep Learning

Reducerea zgomotului din semnalele audio este o problemă foarte populară. Scopul este de a filtra zgomotul din semnalul de intrare, evitând în același timp degradarea calității semnalului. Astfel, sarcina principală a algoritmului de reducere a zgomotului este de a suprima zgomotul de fond pentru a obține o îmbunătățire a semnalului audio [101].

Un Autoencoder este o rețea neuronală ce folosește învățare nesupervizată, ceea ce înseamnă că nu are nevoie de o funcție țintă (*target function*). Există doar un set de antrenare, care este și setul țintă. Un autoencoder convoluțional folosește rețele neuronale convoluționale. Ideea este simplă, implicând o rețea neuronală care are același număr de noduri de ieșire ca și noduri de intrare. În plus, simetria este de obicei prezentă și în straturile ascunse ale rețelei. Un autoencoder transformă semnalul de intrare într-o reprezentare dimensională inferioară folosind componenta numită codificator (Fig. 37). În acest fel, este similar cu un codificator audio, care comprimă un semnal audio într-o reprezentare cu mai puțini biți decât semnalul audio original. Partea decodor a unui acestuia mapează reprezentarea dimensională inferioară înapoi în reprezentarea dimensională superioară. Reconstrucția după partea decodorului ar trebui să fie cât mai apropiată de originalul. Prin urmare, originalul (setul de antrenare) este și ținta. Intrarea trebuie să treacă prin două etape generale:

1. Codor - în această fază, intrarea este restrânsă, fiind construită o reprezentare redusă a intrării. De obicei este denumită *cod*, iar numărul de unități din acest strat este dimensionalitatea reducerii.
2. Decodor – aici, datele de intrare sunt reconstruite din cod.




Fig. 37. Arhitectura generală a unui encoder.

În acest experiment, s-a folosit un set de date de câteva mii de fișiere în format *.wav*. Conține versiunile curate ale înregistrărilor audio, precum și versiunile corespunzătoare ale înregistrărilor

audio zgomotoase. Având în vedere că fişiere sunt stereo, canal stâng a fost utilizat pentru antrenarea reţelei neuronale, iar cel din dreapta pentru testarea modelului. În bucla de antrenare este adăugat zgomot cu un factor de 0.05.

Programul a fost dezvoltat în Python și s-a utilizat un strat convoluțional 1D pentru codificator. În plus, a fost folosită și o funcție de activare de tip *tanh*, care s-a dovedit a funcționa mai bine decât funcția sigmoidă pentru specificul acestei aplicații. A fost utilizat și un „*stride*” (factor de eşantionare), pentru care au fost încercate și testate diverse valori, precum și filtrarea nucleelor de dimensiunea 2N. Acest factor de *stride* a fost redus la 64, ceea ce a dus la obținerea unei calități audio superioare. Astfel, este procesată o cantitate mai mare de date, dar dezavantajul acestui procedeu este faptul că antrenarea și optimizarea rețelei necesită un interval de timp mai mare. La fiecare epocă a procesului de antrenare este adăugat un zgomot diferit, pentru ca modelul să poată generaliza pe orice tip de zgomot pe care îl întâlnește.

Prin urmare, în experimentul dezvoltat în Python, stratul convoluțional de codificator are următoarele proprietăți:

- 1 canal de intrare (*in\_channels*)
- 32 canale de ieșire (*out\_channels*)
- dimensiunea kernelului de 2048
- stride de 32
- padding de 1023

Astfel, se folosește un singur canal de intrare, reprezentând semnalul audio, și 32 de canale de ieșire (reprezentând sub-benzile). În partea de decodor s-a utilizat un strat convoluțional transpus. Pentru acest strat sunt necesare 32 de canale de intrare, reprezentând sub-benzile și un singur canal de ieșire (echivalent semnalului audio reconstruit).

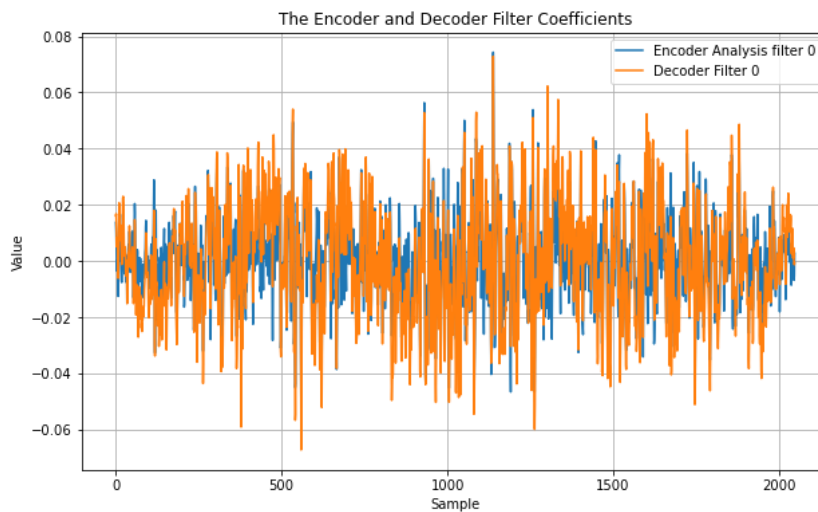
În etapa de antrenare, semnalul de intrare a fost folosit și drept țintă. Lungimea acestuia a fost limitată la lungimea semnalului produs de ieșirea modelului, care poate fi obținută pur și simplu lăsând modelul să ruleze o dată înainte de antrenarea acestuia. Y este semnalul țintă, având aceeași lungime ca ieșirea modelului.

Ca funcție de pierdere, cea mai bună alegere este eroarea pătratică medie (engl. *Mean Squared Error* – prescurtat MSE), precum și radicalul acesteia (Root-Mean-Squared-Error – prescurtat RMSE).

Antrenarea rețelei se face apoi într-o buclă for, folosind 4000 epoci. Pentru îmbunătățirea acurateții modelului, fost folosit și un optimizator de tip Adam, iar rata de învățare inițială a fost setată la  $10^{-4}$ . În timpul procesului de antrenare, modelul început cu o funcție de pierdere foarte mare în primele iterații și a scăzut în timp:

```
0 0.019962582737207413
10 0.01638539507985115
.....
3980 0.0008305259980261326
3990 0.0008273686398752034
```


După ce procesul de antrenare a fost finalizat, ponderile generate în această etapă pot fi citite și folosite a afișa grafic filtrul de analiză al codicatorului și filtrele decodului pentru subbanda 0 (Fig. 38).



**Fig. 38.** Coeficienții filtrului codificatorului și decodorului.

Modelul rezultat a fost testat pe setul de antrenare, putând face predicții pe baza ponderilor determinate anterior. S-a testat și varianta auditivă a semnalului audio prezis, iar rezultatele s-au dovedit a fi de o acuratețe ridicată.

De asemenea, modelul a fost testat și pe setul de validare, pe care modelul nu l-a mai văzut până atunci (Fig. 39). Pentru validarea rezultatelor, s-a calculat raportul semnal/zgomot, rezultând o valoare de aproximativ 67.1 dB.



**Fig. 39.** Valorile prezise de model pe setul de validare.


## 4.2. Codificator automat de reducere a zgomotului din semnale

Alimentând autoencoderele cu date zgomotoase ca intrări și date curate ca ieșiri face posibil ca acestea să poată recunoaște zgomotul din datele de antrenare. În acest fel, autoencoderii pot servi ca denoiseri.

În acest experiment a fost implementat un autoencoder pentru a demonstra acest lucru, prin intermediul unui proces în trei pași:

- realizarea unui set de date mare de mostre de semnal util
- crearea unui set de date mare de mostre la care s-a adăugat zgomot de tip gaussian (aleatoriu)
- dezvoltarea unui autoencoder care învață să transforme intrările zgomotoase în semnalul original, care să reducă zgomotul, și să fie capabil să generalizeze pentru date noi, din afara setului de date folosit

Ca semnale utile (și, prin urmare, ținte de codificare automată), mostrele pure dintr-un domeniu mic. Fig. 40 (a) prezintă forma semnalului. Pentru model au fost utilizate 100.000 de mostre. La fiecare dintre ele, a fost adăugat zgomot gaussian. În timp ce forma globală rămâne prezentă, este clar că semnalul devine zgomotos - Fig. 40 (b).



**Fig. 40.** Reprezentare semnale generate.

Arhitectura modelului de învățare profundă dezvoltat este ilustrată în Fig. 40 și cuprinde opt straturi:

- stratul de intrare, care preia datele de intrare
- trei straturi convoluționale Conv1D cu 128, 64 și, respectiv, 32 filtre, care servesc drept codificator
- trei straturi de transpunere Conv1D cu 32, 64 și 128 filtre, care servesc drept decodificator
- un strat Conv1D cu o singură ieșire, o funcție de activare Sigmoid și padding, care servește ca strat de ieșire

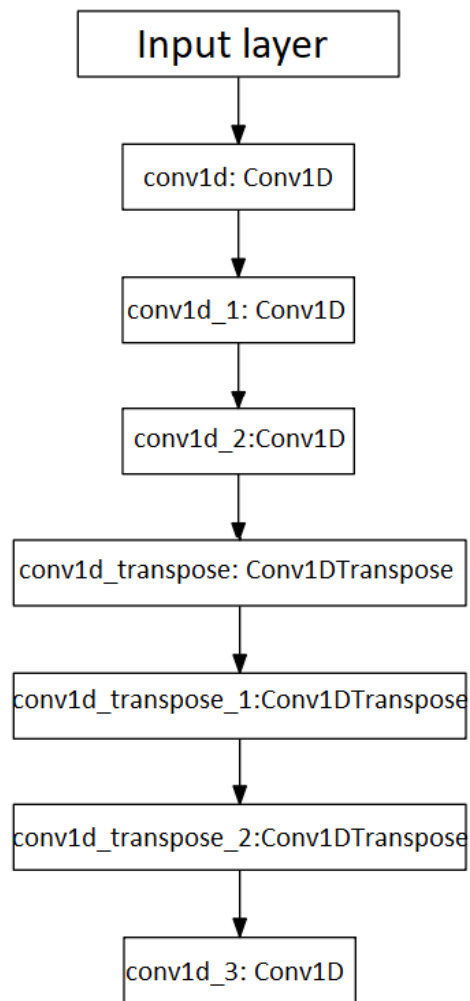


Fig. 41. Structura modelului de Învăţare Profundă.

După generarea datelor, urmează crearea auto-codificatorului, ce presupune următoarele operaţiuni:

- setarea parametrilor de configurare pentru model
- pre-procesarea datelor
- definirea arhitecturii modelului
- compilarea modelului și începerea antrenării
- vizualizarea formelor de undă din setul de testare pentru care s-a eliminat zgomotul, pentru a valida vizual dacă algoritmul funcţionează corespunzător

Modelul reţelei neuronale a fost configurat cu parametri definiţi în Tabelul 4.

Tabelul 4. Parametri reţelei neuronale autoencoder.

Parametru	Valoare
Input_shape	(300, 1)
Batch	125
Ephochs	10
Train_test_split	0.3
Validation Split	0.2
Max norm value	2.0

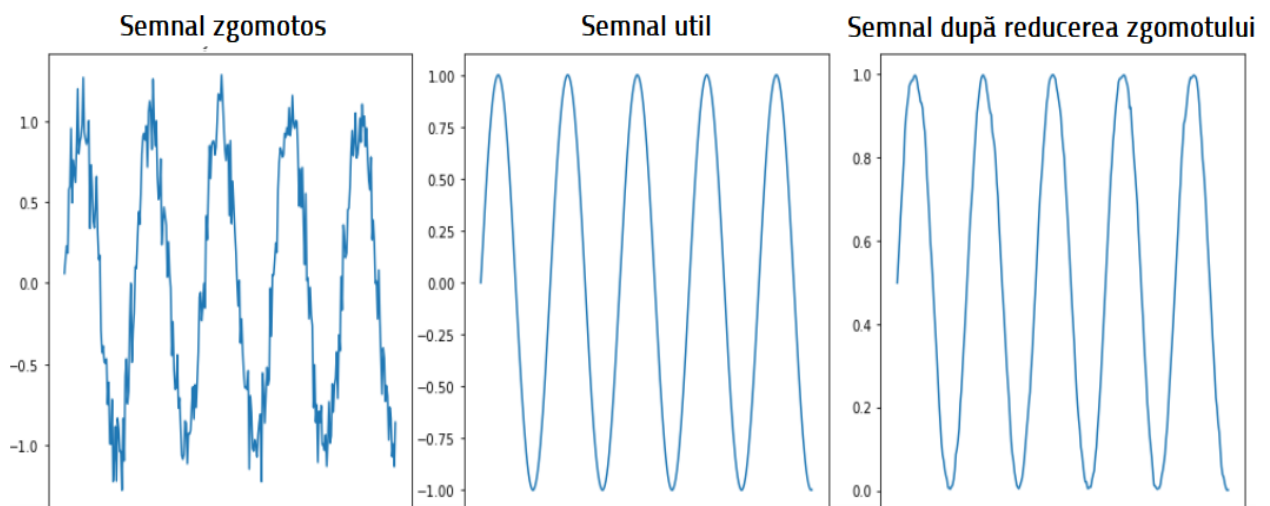


Distribuția straturilor modelului este prezentată în Fig. 42, rezultând în final un număr total de 65.729 parametri în toate cele 7 straturi ale rețelei neuronale.

Layer (type)	Output Shape	Param #
conv1d (Conv1D)	(None, 298, 128)	512
conv1d_1 (Conv1D)	(None, 296, 64)	24640
conv1d_2 (Conv1D)	(None, 294, 32)	6176
conv1d_transpose (Conv1DTranspose)	(None, 296, 32)	3104
conv1d_transpose_1 (Conv1DTranspose)	(None, 298, 64)	6208
conv1d_transpose_2 (Conv1DTranspose)	(None, 300, 128)	24704
conv1d_3 (Conv1D)	(None, 300, 1)	385
=====		
Total params: 65,729		
Trainable params: 65,729		
Non-trainable params: 0		

**Fig. 42.** Distribuția straturilor rețelei neuronale.

După încheierea procesului de antrenare, este necesară testarea dacă modelul funcționează corespunzător. Pentru a realiza acest lucru, au fost generate câteva reconstrucții: o mostră zgomotoasă din setul de testare (care sunt date pe care modelul nu le-a mai văzut până acum) și a fost testat dacă generează semnalul fără zgomot. Fig. 43 ilustrează rezultatul testului efectuat pe o mostră.



**Fig. 43.** Testarea Modelului.

După cum se poate vedea în Fig. 43, codificatorul a învățat să elimine o mare parte din zgomot. Pentru a valida concret rezultatele, s-a determinat valoarea raportului semnal-zgomot, rezultatul obținut fiind de 24.12 dB.

### 4.3. Rezumatul capitolului. Diseminare

Capitolul curent prezintă experimentele realizate pentru suprimarea zgomotului din semnalele audio și dezvoltarea unui model de reducere a zgomotului din semnale.

Reducerea zgomotului din semnalele audio este o problemă foarte populară. Scopul este de a filtra zgomotul din semnalul de intrare, evitând în același timp degradarea calității semnalului. Primul experiment practic propune un „Denoising Autoencoder” ca o posibilă rezolvare pentru această problemă, utilizându-se un set de date de câteva mii de fișiere audio stereo în format *.wav*. Modelul inteligent realizat a fost testat pe setul de antrenare și apoi pe cel de validare, iar rezultatele s-au dovedit a fi foarte bune. De asemenea, s-a testat și varianta auditivă a semnalului audio prezis, observându-se o acuratețe ridicată.

Furnizând autoencoderelor date zgomotoase ca intrări și date curate ca ieșiri face posibil ca acestea să poată recunoaște zgomotul ideosincronic pentru datele de antrenare. În acest fel, autoencoderii pot servi ca denoiseri. Astfel, al doilea experiment constă în dezvoltarea unui autoencoder pentru a demonstra această teorie. Modelul de învățare profundă dezvoltat folosește trei straturi convoluționale care servesc drept codificator și trei straturi de transpunere ca decodificator. Pentru a testa modelul realizat, au fost generate câteva reconstrucții: o mostră zgomotoasă din setul de testare (date pe care modelul nu le-a mai văzut până acum) și a fost testat dacă păstrează semnalul inițial fără zgomot. Rezultatele demonstrează că acest model a învățat să elimine o mare parte din zgomot, fiind astfel foarte bune.

Experimentul descris în acest capitol a fost prezentat la conferința internațională “International Conference on Remote Engineering and Virtual Instrumentation” (REV) 2022, desfășurată la Cairo (Egipt) în perioada 28 Februarie – 2 Martie 2022, și publicată în volumul conferinței - SpringerLink, care este și în curs de indexare ISI:

- **H. A. Modran**, D. Ursutiu, C. Samoila, T. Chamunorwa: “Noise Reduction Through Artificial Intelligence Techniques: An Introductory Study”, In Artificial Intelligence and Online Engineering – Proceedings of the 19<sup>th</sup> International Conference on Remote Engineering and Virtual Instrumentation (REV) 2022, [http://dx.doi.org/10.1007/978-3-031-17091-1\\_3](http://dx.doi.org/10.1007/978-3-031-17091-1_3)

## 5. CONCLUZII FINALE. CONTRIBUȚII ORIGINALE. DISEMINAREA REZULTATELOR ȘI DIRECȚII VIITOARE DE CERCETARE

---

### 5.1. Contribuții originale

Această secțiune prezintă contribuțiile originale ale acestei teze de doctorat, aflate în directă concordanță cu obiectivele științifice principale și obiectivele specifice, detaliate în Introducere:

#### 1. Dezvoltarea unui sistem inteligent de achiziție și procesare a datelor bazat pe PSoC 6

A fost dezvoltat un sistem inteligent inovativ de achiziție și procesare de date bazat pe microcontrolerul PSoC6, care este reconfigurabil software. Varianta finală a acestuia este alimentată de la baterie și conține un chip CYBLE-416045-02 dual-core, conexiune USB type C, comunicare BLE, precum și conectori microBNC și Pmod. Placa dezvoltată este de dimensiuni foarte mici, prezintă mai multe avantaje și inovații care permit dezvoltatorilor să realizeze o gamă largă de aplicații pentru achiziționarea semnalelor din lumea reală, care pot fi apoi procesate prin tehnici de Inteligență Artificială direct pe dispozitiv, la margine. Pentru această placă, au fost dezvoltate câteva aplicații PSoC6, care nu prezintă însă o listă exhaustivă a tuturor capacităților plăcii sau a aplicațiilor pe care le poate rula. Având în vedere reconfigurabilitatea sistemului, numărul de aplicații de Inteligență Artificială ce pot fi programate pe microcontroler nu este finit, depinzând doar de capacitatea și inventivitatea dezvoltatorilor.

#### 2. Prelucrarea semnalelor biomedicale și fiziologice

##### a. Prezicerea bolilor cardiovasculare folosind tehnici de Inteligență Artificială

Abordarea utilizată în acest studiu se bazează pe dezvoltarea unui sistem de colectare și prelucrare a datelor despre tensiunea arterială folosind algoritmi de învățare automată. Datele achiziționate sunt obținute utilizând un dispozitiv IoT puternic bazat pe circuitul integrat cu microcontroler PSoC6. Contribuția originală a acestui experiment este că datele sunt procesate în interiorul unui instrument virtual creat în mediul LabVIEW, care folosește un model de învățare automată dezvoltat în Python. Astfel, modelul dezvoltat constă dintr-o rețea neuronală de tip perceptron multistrat pentru a prezice dacă o persoană prezintă un risc ridicat de a dezvolta boli cardiovasculare. Comparativ cu studii similare, modelul de învățare automată realizat a obținut o performanță și o acuratețe mai mari.

##### b. Detectarea oboselii prin intermediul unui ceas inteligent folosind învățare automată

Acest studiu urmărește dezvoltarea unui model proactiv neinvaziv pentru estimarea oboselii în timp real, care nu a mai fost realizat în alte studii anterioare. Pentru aceasta, se va folosi relația dintre tremur, ritm cardiac și SpO2 pe de o parte și debutul oboselii, pe de altă parte și vor fi luate în considerare vârsta, sexul, comorbiditățile care pot afecta tremurul și exercițiile efectuate, pentru a crea o predicție personalizată a nivelului de oboseală pentru utilizator. Au fost colectate și procesate datele de la mai multe persoane și urmează să fie aplicați algoritmi de Inteligență Artificială și învățare automată pe aceste date colectate. Rezultatele așteptate sunt definirea unui cadru de avertizare relevant pentru prezența indicațiilor timpurii de oboseală.

c. Clasificarea gesturilor prin tehnici de procesare la margine (*edge*)

Contribuția originală a acestui experiment este aducerea procesării semnalelor fiziologice prin tehnici de Inteligența Artificială direct pe chip-ul PSoC6 de dimensiuni foarte mici, fără a avea nevoie de hardware costisitor sau conexiuni la internet fiabile, putând rula astfel direct pe sistemul inteligent prezentat în Capitolul 2 al tezei. Aplicația dezvoltată realizează clasificarea activităților umane pe baza datelor venite de la senzorul de mișcare (accelerometru și giroscop). Model programat pe PSoC6 a fost pre-antrenat pe computer folosind biblioteca Keras și clasifică câteva activități uzuale: staționar, mers și alergat, cu o acuratețe foarte mare (peste 99%).

3. Procesarea semnalelor audio – conectată cu disciplinele predate la masterul de Meloterapie

a. Recunoașterea emoțiilor transmise de muzică prin tehnici de Deep Learning

Având în vedere că, până în prezent, nu a fost abordată în detaliu relația dintre caracteristicile muzicii și efectele lor terapeutice prin procesarea semnalului audio, contribuția adusă prin acest experiment a fost aceea de a propune o soluție de învățare automată pentru recunoașterea efectului terapeutic transmis de muzică. Algoritmul dezvoltat este un clasificator ce utilizează o rețea neuronală multiclasă. Acesta cuprinde un strat de intrare cu zece caracteristici, un strat ascuns complet conectat cu mai multe unități ascunse și un strat de ieșire. De asemenea, a fost dezvoltată o aplicație web pentru personalizarea hiperparametrilor modelului de învățare automată, precum și o altă aplicație pentru a prezice dacă o melodie este potrivită pentru o anumită persoană. Emoția dominantă transmisă de o anumită secvență muzicală a fost estimată folosind un model de Inteligență Artificială. Roata emoțiilor de bază descrie tipurile de emoții în care sunt clasificate melodiile. S-a folosit o abordare categorică, muzica fiind împărțită în grupuri, iar fiecare grupă a fost descrisă cu un adjectiv – de exemplu trist, fericit, plictisitor, etc.

b. Analiza semnalelor audio folosind învățarea profundă (clasificare gen muzical)

În acest studiu a fost realizată o rețea neuronală artificială pentru clasificarea fișierelor audio în funcție de genul muzical. Semnalele audio au fost transformate în spectrograme, din care au fost extrase caracteristicile semnificative. Față de soluțiile prezentate de alte studii similare, au fost utilizate doar caracteristicile spectrale principale de frecvență, care sunt obținute prin conversia semnalului din domeniul timpului în domeniul frecvenței utilizând Transformata Fourier – respectiv frecvența fundamentală, componentele de frecvență, centroidul spectral, fluxul spectral, densitatea spectrală, derularea spectrală. După 128 de epoci, precizia atinsă de algoritm a fost de peste 99%, obținând astfel o acuratețe mai mare decât cea ilustrată în alte studii similare existente.

c. Detectarea notelor muzicale, a vorbirii și a zgomotului prin procesare edge

Studiul realizat propune o detectare automată în timp real a notelor muzicale, vorbirii și zgomotului de fundal folosind un model de învățare profundă bazat pe rețea neuronală complet conectată. În acest experiment a fost utilizat plugin-ul SensiML, care ajută la colectarea datelor de la PSoC6 prin senzorii atașați, oferind și metode de etichetare a datelor ce au fost capturate. După ce setul de date a fost colectat și anotat corespunzător, a fost dezvoltat și antrenat un model de învățare profundă care este optimizat pentru PSoC6. Inovația principală a acestei soluții este că procesarea datelor are loc în timp real pe chip-ul PSoC6, putând fi astfel rulat pe placa inteligentă descrisă în Capitolul 2.

4. Reducerea zgomotelor din semnale
  - a. Reducerea zgomotului audio din semnale folosind Deep Learning

Reducerea zgomotului din semnalele audio este o problemă foarte actuală. Scopul este de a filtra zgomotul din semnalul de intrare, evitând în același timp degradarea calității semnalului. Experimentul realizat propune un „Denoising Autoencoder” inovativ ca o posibilă rezolvare pentru această problemă, utilizându-se un set de date de câteva mii de fișiere audio stereo. Modelul inteligent realizat a fost testat pe setul de antrenare și apoi pe cel de validare, iar rezultatele s-au dovedit a fi foarte bune. De asemenea, s-a testat și varianta auditivă a semnalului audio prezis, observându-se o acuratețe ridicată.

- b. Codificator automat de reducere a zgomotului semnalului prin Inteligență Artificială

Furnizând autoencoderelor date zgomotoase ca intrări și date curate ca ieșiri face posibil ca acestea să poată recunoaște zgomotul din datele de antrenare. În acest fel, autoencoderii pot servi ca denoiseri. Contribuția originală prin acest experiment adusă constă în dezvoltarea unui autonecoder pentru a demonstra practic această teorie. Modelul de învățare profundă dezvoltat folosește trei straturi convoluționale care servesc drept codificator și trei straturi de transpunere ca decodificator. Testarea modelului s-a realizat pe un eșantion zgomotos din setul de testare, pe care modelul nu l-a mai văzut până acum, și a fost verificat dacă păstrează caracteristicile semnalului inițial fără zgomot. Rezultatele demonstrează că acest model a învățat să elimine o mare parte din zgomot, fiind astfel foarte bune.

## 5.2. Diseminarea rezultatelor și distincții internaționale

În domeniul tezei de doctorat s-au realizat următoarele publicații:

### A. Lucrări publicate în reviste (jurnale) cu factor de impact indexate ISI WoS:

- **H. A. Modran**, T. Chamunorwa, D. Ursuțiu, C. Samoilă, H. Hedeșiu: “Using Deep Learning to Recognize Therapeutic Effects of Music Based on Emotions”, *Sensors*. 2023; 23(2):986, ISSN 1424-8220, <https://doi.org/10.3390/s23020986>.  
Web of Science Number: WOS:000927263000001  
IF: 3.847, CiteScore: 6.8 (Journal Rank: JCR - Q2 / CiteScore - Q1)
- T. Chamunorwa, **H. A. Modran**, D. Ursuțiu, C. Samoilă, H. Hedeșiu: „Reconfigurable Wireless Sensor Node Remote Laboratory Platform with Cloud Connectivity”, *Sensors* 21(19):6405, ISSN 1424-8220, <http://dx.doi.org/10.3390/s21196405>.  
Web of Science Number: WOS:000927263000001  
IF: 3.847, CiteScore: 6.8 (Journal Rank: JCR - Q2 / CiteScore - Q1)
- T. Chamunorwa, **H. A. Modran**, D. Ursuțiu, C. Samoilă, H. Hedeșiu: „Cloud-Based, Expandable-Reconfigurable Remote Laboratory for Electronic Engineering Experiments”, *Electronics* 11(20):3292, ISSN 2079-9292, <http://dx.doi.org/10.3390/electronics11203292>.  
Web of Science Number: WOS:000927263000001  
IF: 2.69, CiteScore: 4.7

## B. Lucrări publicate în volume de conferințe SpringerLink indexate ISI WoS (sau în curs de indexare):

- **H. A. Modran**, D. Ursuțiu, C. Samoilă, T. Chamunorwa: „Learning Methods Based On Artificial Intelligence in Educating Engineers for the New Jobs of the 5th Industrial Revolution”, In Educating Engineers for Future Industrial Revolutions - Proceedings of the 23<sup>rd</sup> International Conference on Interactive Collaborative Learning (ICL) 2020, Volume 1, [http://dx.doi.org/10.1007/978-3-030-68201-9\\_55](http://dx.doi.org/10.1007/978-3-030-68201-9_55).  
Web of Science Number: WOS:000772405700055
- **H. A. Modran**, D. Ursuțiu, C. Samoilă, T. Chamunorwa: „Artificial Intelligence System for predicting cardiovascular diseases using IoT devices and Virtual Instrumentation”, In Online Engineering and Society 4.0 – Proceedings of the 18<sup>th</sup> International Conference on Remote Engineering and Virtual Instrumentation (REV) 2021, [http://dx.doi.org/10.1007/978-3-030-82529-4\\_28](http://dx.doi.org/10.1007/978-3-030-82529-4_28). Web of Science Number: WOS:000772185600028
- **H. A. Modran**, D. Ursuțiu, C. Samoilă, T. Chamunorwa: „Intelligent IoT Biomedical Bluetooth Data Acquisition System”, In New Realities, Mobile Systems, and Applications – Proceedings of the International Conference on Interactive Mobile Communication, Technologies, and Learning (IMCL) 2021, [http://dx.doi.org/10.1007/978-3-030-96296-8\\_88](http://dx.doi.org/10.1007/978-3-030-96296-8_88).
- **H. A. Modran**, D. Ursuțiu, C. Samoilă, T. Chamunorwa: “Noise Reduction Through Artificial Intelligence Techniques: An Introductory Study”, In Artificial Intelligence and Online Engineering – Proceedings of the 19<sup>th</sup> International Conference on Remote Engineering and Virtual Instrumentation (REV) 2022, [http://dx.doi.org/10.1007/978-3-031-17091-1\\_3](http://dx.doi.org/10.1007/978-3-031-17091-1_3).
- **H. A. Modran**, T. Chamunorwa, D. Ursuțiu, C. Samoilă: “Fatigue Estimation using Wearable Devices and Virtual Instrumentation”, In Open Science in Engineering – Proceedings of the 20<sup>th</sup> International Conference on Remote Engineering and Virtual Instrumentation (REV) 2023 (acceptat și prezentat, în curs de publicare).
- **H. A. Modran**, T. Chamunorwa, D. Ursuțiu, C. Samoilă: “Integrating Artificial Intelligence and ChatGPT into Higher Engineering Education”, acceptat pentru prezentare și publicare la conferința 26<sup>th</sup> International Conference on Interactive Collaborative Learning (ICL) 2023, ce se va desfășura la Madrid (Spania), în perioada 26 – 29 Septembrie 2023.

## C. Cărți, Îndrumare de laborator

- **H. A. Modran**, D. Ursuțiu: “Instrumentație Virtuală: Îndrumar de laborator”, Editura Universității Transilvania din Braşov, ISBN 9786061915460 (2022)

## D. Distincții Internaționale Obținute

- Conferința Internațională Remote Engineering and Virtual Instrumentation (REV) 2021 – **Best Paper Award 2021: Student Paper Award Winner**
- Conferința Internațională Remote Engineering and Virtual Instrumentation (REV) 2021 – **Best Paper Award 2021: Special Session Award Winner**

- Conferința Internațională New Trends on Sensing-Monitoring-Telediagnosis for Life Sciences (NT SMT-LS) 2022 – **Oral Presentation Award**

De asemenea, împreună cu grupul de cercetare din cadrul CVTC – Univ. Transilvania, în legătură cu activităților conexe tezei de doctorat, s-au realizat următoarele publicații (8 articole în volume ale conferințelor indexate ISI):

- T. Chamunorwa, D. Ursuțiu, C. Samoilă, **H. A. Modran**: „ Embedded System Learning Platform for Developing Economies”, In Educating Engineers for Future Industrial Revolutions - Proceedings of the 23<sup>rd</sup> International Conference on Interactive Collaborative Learning (ICL) 2020, Volume 1, [http://dx.doi.org/10.1007/978-3-030-68201-9\\_60](http://dx.doi.org/10.1007/978-3-030-68201-9_60).
- T. Chamunorwa, D. Ursuțiu, C. Samoilă, H. Hedeşiu, **H. A. Modran**: „ Electronic Educational Laboratory Platform for Students”, In Online Engineering and Society 4.0 – Proceedings of the 18<sup>th</sup> International Conference on Remote Engineering and Virtual Instrumentation (REV) 2021, [http://dx.doi.org/10.1007/978-3-030-82529-4\\_30](http://dx.doi.org/10.1007/978-3-030-82529-4_30).
- C. Samoilă, D. Ursuțiu, **H. A. Modran**: „ The Potential For Transformation Into The Virtual Organization Of Remote Experiment Networks”, In Mobility for Smart Cities and Regional Development - Challenges for Higher Education – Proceedings of the 24<sup>th</sup> International Conference on Interactive Collaborative Learning (ICL) 2021, [http://dx.doi.org/10.1007/978-3-030-93907-6\\_88](http://dx.doi.org/10.1007/978-3-030-93907-6_88).
- T. Chamunorwa, D. Ursuțiu, C. Samoilă, **H. A. Modran**: „Electronic Laboratory Educational Board”, In New Realities, Mobile Systems, and Applications – Proceedings of the International Conference on Interactive Mobile Communication, Technologies, and Learning (IMCL) 2021, [http://dx.doi.org/10.1007/978-3-030-96296-8\\_89](http://dx.doi.org/10.1007/978-3-030-96296-8_89).
- T. Chamunorwa, D. Ursuțiu, C. Samoilă, **H. A. Modran**: “Software Configurable Hardware-based Remote Laboratory System”, In Artificial Intelligence and Online Engineering – Proceedings of the 19<sup>th</sup> International Conference on Remote Engineering and Virtual Instrumentation (REV) 2022, [http://dx.doi.org/10.1007/978-3-031-17091-1\\_2](http://dx.doi.org/10.1007/978-3-031-17091-1_2)
- D. Ursuțiu, **H. A. Modran**, T. Chamunorwa, C. Samoilă, P. Kane: “Digital Tools and Energy Harvesting in IoT Education”, In Learning in the Age of Digital and Green Transition - Proceedings of the 25<sup>th</sup> International Conference on Interactive Collaborative Learning (ICL) 2022, [http://dx.doi.org/10.1007/978-3-031-26190-9\\_99](http://dx.doi.org/10.1007/978-3-031-26190-9_99).
- T. Chamunorwa, **H. A. Modran**, D. Ursuțiu, C. Samoilă: “Embedded Student Board for Digitalization of Engineering Education”, In Learning in the Age of Digital and Green Transition - Proceedings of the 25<sup>th</sup> International Conference on Interactive Collaborative Learning (ICL) 2022, [http://dx.doi.org/10.1007/978-3-031-26190-9\\_100](http://dx.doi.org/10.1007/978-3-031-26190-9_100).
- C. Samoilă, D. Ursuțiu, **H. A. Modran**, T. Chamunorwa: “New Challenges for Remote Experiment Design in the Digitalization Era (Industry 4.0)”, In Learning in the Age of Digital and Green Transition - Proceedings of the 25<sup>th</sup> International Conference on Interactive Collaborative Learning (ICL) 2022, [http://dx.doi.org/10.1007/978-3-031-26190-9\\_98](http://dx.doi.org/10.1007/978-3-031-26190-9_98).



## BIBLIOGRAFIE (extras)

---

- [74] H. A. Modran, D. Ursutiu, C. Samoila, T. Chamunorwa: "*Intelligent IoT Biomedical Bluetooth Data Acquisition System*", In New Realities, Mobile Systems, and Applications – Proceedings of the International Conference on Interactive Mobile Communication, Technologies, and Learning (IMCL) 2021, [http://dx.doi.org/10.1007/978-3-030-96296-8\\_88](http://dx.doi.org/10.1007/978-3-030-96296-8_88) (2022)
- [75] H. A. Modran, D. Ursuțiu, C. Samoilă, T. Chamunorwa: "*Artificial Intelligence System for predicting cardiovascular diseases using IoT devices and Virtual Instrumentation*", In Online Engineering and Society 4.0 – Proceedings of the 18<sup>th</sup> International Conference on Remote Engineering and Virtual Instrumentation (REV) 2021, [http://dx.doi.org/10.1007/978-3-030-82529-4\\_28](http://dx.doi.org/10.1007/978-3-030-82529-4_28).
- [76] D. Sharma, M. Ferguson, T. Kamp, F. Zhao: "*Constructing biomimetic cardiac tissues: a review of scaffold materials for engineering cardiac patches*", Emergent Materials 181-191, DOI: <https://doi.org/10.1007/s42247-019-00046-4> (2019).
- [77] C. Krittanawong, H. Virk, S. Bangalore et al.: "*Machine learning prediction in cardiovascular diseases: a meta-analysis*", Scientific Reports 10, 16057, DOI: <https://doi.org/10.1038/s41598-020-72685-1> (2020).
- [79] K. Tae, Y. Roh, Y. Hun Oh, H. Kim, S. Whang.: "*Data Cleaning for Accurate, Fair, and Robust Models: A Big Data - AI Integration Approach*", arXiv:1904.10761v1 (2019).
- [80] P. Langley: "*The changing science of machine learning*", Machine Learn Journal, vol. 82, Springer Link, DOI: <https://doi.org/10.1007/s10994-011-5242-y> (2011).
- [83] Z. Omary, F. Mtenzi: "*Machine Learning Approach to Identifying the Dataset Threshold for the Performance Estimators in Supervised Learning*", International Journal for Infonomics (IJ), Volume 3, Issue 3, DOI: <http://dx.doi.org/10.20533/iji.1742.4712.2010.0034> (2010).
- [84] J. Wan, Z. Qin, P. Wang, Y. Sun, X. Liu: "*Muscle fatigue: general understanding and treatment*", Experimental & molecular medicine, Vol. 49 (10), e384-e384, DOI: <https://doi.org/10.1038/emm.2017.194> (2017).
- [88] H. A. Modran, T. Chamunorwa, D. Ursuțiu, C. Samoilă: "*Fatigue Estimation using Wearable Devices and Virtual Instrumentation*", In Open Science in Engineering – Proceedings of the 20th International Conference on Remote Engineering and Virtual Instrumentation (REV) (2023)
- [89] H. A. Modran, T. Chamunorwa, D. Ursuțiu, C. Samoilă, H. Hedesiu: "*Using Deep Learning to Recognize Therapeutic Effects of Music Based on Emotions*", Sensors. 2023; 23(2):986, ISSN 1424-8220, <https://doi.org/10.3390/s23020986> (2023).
- [91] Emotion Wheel, [Online] la <https://positivepsychology.com/emotion-wheel/>, accesat 01 Decembrie 2022.



## REZUMATUL TEZEI (RO/EN)

### Rezumatul Tezei

Teza de doctorat prezintă abordare complexă privind realizarea unui sistem de predicție bazat pe algoritmi hibridi de Inteligență Artificială, cu aplicare atât în procesarea semnalelor biomedicale și audio, cât și în reducerea zgomotului din semnalele. Capitolul 1 prezintă stadiul actual. În Capitolul 2, "Dezvoltarea unui sistem inteligent de achiziție și procesare a datelor" este prezentată dezvoltarea unui sistem inteligent reconfigurabil de achiziție și prelucrare a datelor prin metode de Inteligență Artificială, bazat pe PSoC 6. Modele de Inteligență Artificială prezentate în capitolele următoare, fiind în mare parte dezvoltate folosind librăria Tensorflow, pot fi exportate, programate și rulate pe acest sistem. Capitolul 3, "Aplicații ale Inteligenței Artificiale în procesarea semnale biomedicale și fiziologice" descrie aplicarea algoritmilor de Inteligență Artificiale în prelucrarea semnalelor biomedicale și fiziologice, axată pe detectarea bolilor cardiovasculare, a oboselii folosind un ceas inteligent și a activităților, prin tehnici de procesare și predicție la margine. Capitolul 4, intitulat "Aplicarea Inteligenței Artificiale în procesarea semnalele audio" ilustrează aplicarea modelelor de învățare profundă în procesarea semnalelor audio, în special pentru detecția stărilor transmise de muzica, recunoașterea genului muzical, precum și a notelor muzicale, a vorbirii și a zgomotului, utilizând tehnici de procesare de tip edge. În Capitolul 5, "Reducerea zgomotului din semnale folosind Inteligența Artificială sunt prezentate experimentele realizate pentru reducerea zgomotului din semnalele audio și dezvoltarea unui model de filtrare a zgomotului din semnale. Ultimul capitol al tezei prezintă concluziile generale ale lucrării și contribuțiile originale ale autorului.

### Abstract

The doctoral thesis presents a complex approach for developing a prediction system based on hybrid Artificial Intelligence algorithms, with application both in biomedical and audio signal processing, as well as in signal noise reduction. Chapter 1 presents the current state of the art in this field. In Chapter 2, "Development of an intelligent data acquisition and processing system" the development of a reconfigurable intelligent data acquisition and processing system using Artificial Intelligence methods, based on PSoC 6, is presented. Artificial Intelligence models presented in the following chapters, being mostly developed using the Tensorflow library, can be exported, programmed and run on this system. Chapter 3, "Applications of Artificial Intelligence in biomedical and physiological signal processing" describes the application of Artificial Intelligence algorithms in biomedical and physiological signal processing, focused on the detection of cardiovascular diseases, fatigue using a smart watch and human activities, through techniques of processing and prediction at the edge. Chapter 4, entitled "Application of Artificial Intelligence in Audio Signal Processing" illustrates the application of deep learning models in audio signal processing, in particular for the detection of music mood, music genre classification, as well as musical notes, speech and noise, using edge processing techniques. In Chapter 5, "Reduction of noise from signals using Artificial Intelligence, the experiments carried out for the reduction of noise from audio signals and the development of a model for filtering noise from signals are presented. The last chapter of the thesis presents the general conclusions and the original contributions of the author.