



UNIVERSITATEA TEHNICĂ "GHEORGHE ASACHI"
IAȘI Școala Doctorală a Facultății de Inginerie Electrică,
Energetică și Informatică Aplicată



CERCETĂRI PRIVIND ACHIZIȚIA ȘI PRELUCRAREA SEMNALELOR FIZIOLOGICE CU APLICAȚII ÎN BIOMEDICINĂ

REZUMATUL TEZEI DE DOCTORAT

Conducător de doctorat:

Prof. univ. dr. ing. Cristian Foșalău

Doctorand:

Ing. Ionuț – Adrian Iftode

IAȘI - 2025

Cuprins

Cuprins	2
Introducere	4
1 Stadiul actual privind achiziția și prelucrarea indicatorilor fiziologici cu aplicații în biomedicină	7
1.1 Indicatori fiziologici ai funcțiilor vitale	7
1.1.1 Electrocardiograma	7
1.1.2 Fotopletismograma.....	7
1.1.3 Răspunsul galvanic al pielii	8
1.1.4 Ritmul respirator	8
1.1.5 Temperatura corpului	8
1.2 Metode și tehnici de achiziție a indicatorilor fiziologici.....	8
1.2.1 Tipuri de senzori utilizați pentru achiziția indicatorilor fiziologici	8
1.2.2 Sisteme de achiziție și transmisie a indicatorilor fiziologici	10
1.3 Metode de analiză și extragere a trăsăturilor din indicatorii fiziologici.....	10
1.3.1 Metode de analiză a electrocardiogramei.....	11
1.3.2 Metode de analiză a folopletismogramei	13
1.3.3 Metode de analiză a ritmului respirator	14
1.3.4 Metode de analiză a răspunsului galvanic al pielii.....	15
2 Sistem experimental tip IoMT pentru achiziția semnalelor fiziologice.....	16
2.1 Amplasarea sistemului de monitorizare	17
2.2 Descrierea nodurilor de monitorizare.....	17
2.2.1 Nodul de monitorizare ECG (NMECG)	18
2.2.2 Nodul de monitorizare PPG (NMPPG).....	19
2.2.3 Nodul de monitorizare PPG și a temperaturii corpului (NMPPGTC)	20
2.2.4 Nodul de monitorizare RGP (NMRGP).....	21
2.2.5 Nodul de monitorizare a ritmului respirator (NMRR)	22
2.2.6 Nodul de monitorizare a posturii corpului (NMPC)	23
2.3 Serverul de achiziție date	24
3 Prezentarea datelor experimentale.....	27
3.1 Organizarea studiului	27
3.2 Prezentarea variațiilor indicatorilor fiziologici între subiecți și între scenarii	30
3.2.1 Măsurători ECG	30

3.2.2	Măsurători PPG (Încheietură)	31
3.2.3	Măsurători PPG (Deget).....	32
3.2.4	Măsurători de temperatură a corpului	34
3.2.5	Măsurători RGP	35
3.2.6	Măsurători ale ritmului respirator	36
3.2.7	Măsurători privind postura corpului și efort	37
4	Prelucrarea și analiza datelor experimentale.....	38
4.1	Tehnici de prelucrare și analiză a datelor experimentale	38
4.1.1	Prelucrarea și extragerea trăsăturilor relevante din seturile de date privitoare la ECG	38
4.1.2	Prelucrarea și extragerea trăsăturilor relevante din setul de date PPG.....	38
4.1.3	Prelucrarea și extragerea trăsăturilor relevante din RGP	39
4.1.4	Prelucrarea și extragerea trăsăturilor relevante din ritmul respirator	39
4.2	Evoluția unor parametri calculați	39
4.2.1	Evoluția parametrilor în funcție de scenarii pe un singur subiect	39
4.2.2	Comparație între metode de calcul al parametrilor în domeniul timp și domeniul frecvență	41
4.2.3	Evoluția parametrilor pe subiecți și scenarii	43
4.3	Model bazat pe învățare profundă multivariată pentru recunoașterea activităților umane	47
4.3.1	Arhitectura modelului	47
4.3.2	Performanțele modelului.....	49
	Concluzii generale, contribuții și perspective de dezvoltare	52
	Bibliografie selectivă.....	59

Introducere

În ultimele decenii, ingineria biomedicală a cunoscut un salt semnificativ în dezvoltarea și perfecționarea tehnologiilor de achiziție și procesare a indicatorilor biologici, precum electrocardiograma (ECG), fotopletismograma (PPG), răspunsul galvanic al pielii (RGP) și a altor astfel de indicatori. Acești indicatori, care pot fi considerați “ferestre” către activitatea internă a organismului, oferă date importante pentru investigarea, diagnosticarea și monitorizarea diverselor afecțiuni medicale. În plus, progresele în tehnologiile de comunicație wireless și miniaturizarea senzorilor au făcut posibilă integrarea acestor soluții în dispozitive portabile (Internet of Medical Things – IoMT), ușor de folosit atât de personalul medical, cât și de pacienți în mediul casnic.

Teza este structurată în patru capitole, și anume:

Capitolul 1 prezintă o sinteză a tehnicilor și tendințelor actuale referitoare la achiziția și procesarea indicatorilor fiziologice în biomedicină. Se evidențiază relevanța clinică a acestor semnale și integrarea tehnologică în monitorizarea și diagnosticarea afecțiunilor. Capitolul subliniază rolul semnificativ al senzorilor și dispozitivelor portabile (ECG, PPG, RGP, senzori respiratori, IMU etc.), precum și al metodelor avansate de filtrare și analiză, care contribuie la creșterea calității datelor achiziționate și la analiza lor ulterioară.

În prima secțiune se descriu principalii indicatori fiziologici, de la electrocardiogramă (ECG) și fotopletismogramă (PPG), până la răspunsul galvanic al pielii (RGP), temperatura corporală și ritmul respirator. Sunt expuse conceptele fiziologice și modalitățile neinvazive de măsurare. Secțiunea evidențiază dificultățile practice asociate achiziției, precum zgomotul ambiental, interferențele de rețea și artefactele de mișcare, alături de beneficiile monitorizării continue, care permit diagnosticarea timpurie și evaluarea detaliată a pacienților.

Sunt apoi prezentate metodele și tehnologiile de achiziție, începând cu senzorii biomedicali (electrozi Ag/AgCl, senzori optici, senzori de temperatură, dispozitive IMU, etc.) și continuând cu platformele de achiziție folosite în spitale și clinici (Philips IntelliVue, GE CARESCAPE, Dräger Infinity etc.). De asemenea se pune accent pe analiza echipamentele portabile, concepute pentru telemedicină, reabilitare și monitorizarea pacienților în mediul extra-spitalicesc, precum și câteva referințe din literatura de specialitate.

Ultima secțiunea a acestui capitol este reprezentată de analiza semnalelor, ce include: metode clasice (filtre liniare RII, transformate Fourier) și abordări avansate (transformate Wavelet, separarea surselor, filtrare adaptivă, algoritmi de învățare automată) aplicate indicatorilor fiziologici achiziționați. Procesarea acestor date are ca obiectiv eliminarea artefactelor și zgomotului, menținând totodată integritatea componentelor de interes (unde P, QRS, T la ECG, pulsul arterial din PPG, răspunsurile fazice la RGP, parametrii respiratori etc.). De asemenea, se abordează subiecte privind extragerea trăsăturilor, cum ar fi variabilitatea ritmului cardiac, detecția

frecvenței respiratorii, estimarea posturii și intensității mișcărilor corpului, indispensabile în evaluarea clinică și cercetarea biomedicală.

Capitolul 2 prezintă un sistem experimental de tip IoMT proiectat pentru achiziția și transmiterea în timp real a indicatorilor fiziologici și a celor inerțiali (accelerometru și giroscop). În această secțiune sunt detaliate arhitectura hardware, elementele de comunicație wireless și mecanismele de stocare a datelor, ilustrând modul în care fiecare nod de monitorizare (bazat pe o platforma ESP32 sau pe tehnologia BLE) își îndeplinește rolul de măsurare, preprocesare și transmitere a datelor către serverul de achiziție central.

Capitolul descrie, de asemenea, integrarea modulului Wemos Mini D1 ESP-32S ca element esențial pentru achiziția și transmiterea a datelor, explicând cum s-au configurat interfețele disponibile în fiecare nod specializat (ECG, PPG, RGP, temperatură corporală, postură, ritm respirator). De asemenea se detaliază principiile de funcționare ale circuitelor integrate, modul în care se asigură sincronizarea de timp prin protocolul SNTP și modul de implementare a sistemului de operare în timp real (*FreeRTOS*) pentru gestionarea sarcinilor de achiziție și transmitere la nivel embedded în paralel.

La final capitolului, este prezentat serverul de achiziție, care centralizează și stochează datele sub formă de fișiere CSV, asigurând, totodată, posibilitatea vizualizării indicatorilor fiziologici și de mișcare în timp real și a accesării lor prin rețele Wi-Fi externe. Prin arhitectura modulară și tehnologiile wireless adoptate, soluția propusă poate fi extinsă și adaptată la nevoi variate din mediul medical sau de cercetare, oferind un cadru robust pentru monitorizarea în timp real a mai multor indicatori fiziologici.

În cadrul **Capitolului 3** se prezintă datele experimentale colectate cu sistemul dezvoltat pentru a studia evoluția unor indicatori fiziologici în funcție de scenarii prestabilite. Această secțiune descrie modul în care participanții au fost împărțiți în cinci ipostaze experimentale, fiecare scenariu fiind asociat unei poziții corporale și unui nivel de efort fizic. Se prezintă informațiile antropometrice și demografice ale voluntarilor ce au făcut parte din acest experiment.

Prin analiza semnalelor neprocesată (prin metoda grafică) a ECG, PPG, răspuns galvanic al pielii, temperaturii corporale și posturii corpului în condiții variate (repaus, ortostatic, șezând, alergare ușoară și mers lejer), capitolul evidențiază adaptările organismului la scenarii statice și dinamice, ilustrând modul în care reacțiile fiziologice și mecanice pot fi interpretate în funcție de postură, efort și caracteristicile individuale ale subiecților. Acest nivel de detaliu creează o bază solidă pentru dezvoltarea unor metode mai avansate de analiză și pentru aplicarea concluziilor în contexte clinice sau de cercetare ulterioare.

Capitolul 4 este structurat în trei secțiuni care tratează, în mod aprofundat, prelucrarea indicatorilor fiziologici, extragerea trăsăturilor relevante și integrarea lor într-un model avansat de clasificare a activităților umane (*Human Activity Recognition* – HAR). Pentru implementarea software s-a utilizat aplicația PyCharm, ce reprezintă un ecosistem integrat bazat pe Python și bibliotecile sale specializate (pandas, NumPy, SciPy, BioSPPy, NeuroKit2, hrvanalysis,

Matplotlib), capabil să asigure filtrarea semnalelor, vizualizarea avansată și determinarea trăsăturilor specifice fiecărui indicator.

Prima secțiune cuprinde filtrarea și eliminarea zgomotelor specifice semnalelor electrocardiografice, fotopletismografice, răspunsului galvanic al pielii și a ritmului respirator. Sunt ilustrate criteriile pentru alegerea benzilor de trecere, coeficienților filtrelor de tip *Butterworth* și tehnici de compensare a fazei prin funcții de tip *filtfilt*. S-a urmărit păstrarea componentelor fundamentale (unde P, QRS, T din ECG, variațiile de volum sanguin în PPG, creșterile rapide din RGP și fluctuațiile specifice frecvenței respiratorii), astfel încât semnalul final să ofere acuratețe în etapele ulterioare de analiză.

A doua secțiune prezintă extragerea trăsăturilor fiziologice. În cazul ECG, detectarea vârfurilor R permite calculul intervalelor RR din care se determină ulterior ritmul cardiac și variabilitatea acestuia. Pentru PPG se determină ritmul cardiac, pantele ascendente și descendente și estimarea saturației de oxigen. Răspunsul galvanic al pielii se separă în componenta tonică și componenta fazică pentru a evidenția reactivitatea la stimuli, iar ritmul respirator permite calculul frecvenței și amplitudinii ciclurilor inspirație-expirație. Înregistrările rezultate conferă o imagine extinsă a stării fiziologice, generând parametri care pot fi corelați cu nivelul de efort, stările emoționale sau identificarea poziției corpului în timpul expunerii la diferite scenarii.

Secțiunea finală descrie integrarea acestor fluxuri de date într-un model neuronal de tip Transformer. Fiecărui flux de date de intrare i se alocă un codificator dedicat, iar mecanismul de atenție analizează corelațiile dintre indicatori și învață să diferențieze poziția corpului (nivelul efortului și succesiunea stărilor pot fi ulterior integrate într-o analiză extinsă, pentru a oferi o imagine mai cuprinzătoare asupra adaptării fiziologice). Sunt prezentate valorile de acuratețe, nivelul de sensibilitate și scorul F1 aferente detectării corecte a scenariilor (repaus, stat în picioare, șezut, mers, alergare) și se subliniază eficiența modelului în a oferi predicții robuste chiar și în condiții cu mai multe surse de zgomot sau variații individuale. În acest mod, se conturează un cadru unitar de clasificare, cu aplicații în monitorizarea continuă și în analiza comparativă a unor seturi extinse de date fiziologice.

În concluzie, această teză propune contribuții importante în domeniul ingineriei biomedicale, prin conceperea și validarea unor metode avansate de achiziție și procesare a indicatorilor fiziologici, elemente care pot sprijini dezvoltarea unei asistențe medicale moderne, centrate pe pacient, și pot deschide noi perspective pentru monitorizarea continuă și gestionarea eficientă a afecțiunilor cronice.

Capitolul 1

Stadiul actual privind achiziția și prelucrarea indicatorilor fiziologici cu aplicații în biomedicină

Acest capitol își propune să ofere o analiză detaliată a stadiului actual al cercetărilor în domeniul achiziției și prelucrării semnalelor fiziologice. Vor fi descrise tehnologiile emergente, metodele de prelucrare a semnalelor și provocările existente în integrarea acestora în practica clinică de zi cu zi. În plus, se vor discuta direcțiile viitoare de cercetare, care urmăresc îmbunătățirea fiabilității și accesibilității acestor tehnologii, precum și importanța lor asupra monitorizării continue a pacienților.

1.1 Indicatori fiziologici ai funcțiilor vitale

Indicatorii fiziologici reprezintă parametri esențiali ai stării funcționale a organismului, oferind informații relevante despre o gamă largă de procese fiziologice. Acești indicatori sunt generați de diferite organe și sisteme din corp și pot fi măsurați cu ajutorul unor senzori și metode variate. Indicatorii fiziologici de bază, precum electrocardiograma (ECG), fotopletismograma (PPG), răspunsul galvanic al pielii (RGP) și semnale respiratorii, reflectă activitățile subiacente ale sistemelor cardiovascular, muscular, neural și respirator. Prin analiza acestora, cercetătorii și medicii pot evalua starea de sănătate, pot identifica anomalii și pot urmări în timp real modificările funcțiilor fiziologice.

1.1.1 Electrocardiograma

Electrocardiograma (ECG) constituie o modalitate neinvazivă de monitorizare a modificărilor la nivel cardiac. Aceasta este o înregistrare grafică a potențialelor electrice generate de către fibrele musculare din zona toracică, de-a lungul fiecărui ciclu cardiac [1].

1.1.2 Fotopletismograma

Fotopletismograma (PPG) este o tehnică optică neinvazivă, utilizată pentru a detecta schimbările de volum sanguin în stratul microvascular al țesuturilor. PPG a devenit un instrument esențial atât în mediile spitalicești, cât și în cercetare, datorită simplității, costurilor reduse și capacității de a monitoriza continuu parametri fiziologici, precum ritmul cardiac, saturația de oxigen și frecvența respiratorie [2].

1.1.3 Răspunsul galvanic al pielii

RGP măsoară în principal modificările de conductanță electrică cauzate de variațiile activității glandelor sudoripare, în special ca răspuns la stimuli psihologici. Glandele sudoripare (mai ales cele ecrine) sunt responsabile pentru acest fenomen, producând umiditate care reduce rezistența electrică a pielii [3].

1.1.4 Ritmul respirator

Respirația este procesul fiziologic prin care organismul realizează schimbul de gaze între atmosferă și celule, având un rol esențial în menținerea homeostaziei. Procesul implică absorbția oxigenului (O_2) necesar pentru metabolismul celular și eliminarea dioxidului de carbon (CO_2), un produs al metabolismului [4].

1.1.5 Temperatura corpului

Temperatura corpului constituie un indicator fiziologic esențial, reflectând starea termică a organismului uman. Aceasta rezultă din echilibrul dintre producția de căldură și pierderea acesteia, fiind importantă pentru menținerea proceselor metabolice și biochimice normale. Valoarea medie a temperaturii corporale este în general în jur de $37^\circ C$, dar poate varia ușor în funcție de factori precum vârsta, sexul, momentul zilei și nivelul de activitate [34].

1.2 Metode și tehnici de achiziție a indicatorilor fiziologici

Achiziția indicatorilor fiziologici reprezintă un proces esențial în ingineria biomedicală și în practica clinică modernă, având un rol critic în monitorizarea funcțiilor vitale și în diagnosticarea diverselor afecțiuni.

Acest subcapitol analizează în detaliu tehnicile de achiziție a semnalelor fiziologice, principiile de funcționare, echipamentele folosite și aplicațiile clinice aferente. Înțelegerea acestor concepte este vitală pentru specialiștii din domeniul sănătății în vederea diagnosticării și monitorizării eficiente a pacienților.

1.2.1 Tipuri de senzori utilizați pentru achiziția indicatorilor fiziologici

Senzorii biomedicali permit măsurarea parametrilor vitali și a funcțiilor fiziologice de bază, furnizând informații importante pentru diagnostic, tratament și gestionarea stării de sănătate, dar și pentru conceperea unor soluții de terapie personalizate.

Senzori utilizați pentru achiziția ECG

Măsurarea semnalului electrocardiografic (ECG), presupune integrarea a două componente fundamentale într-o singură structură, denumită senzor ECG: un set de electrozi care asigură contactul direct cu suprafața tegumentară și un circuit dedicat preamplificării și procesării analogice. Aceste elemente conlucrează în vederea captării și amplificării potențialelor electrice de amplitudine redusă, generate de activitatea cardiacă, facilitând ulterior procedurile de filtrare și conversie în semnal numeric.

Senzori pentru achiziția PPG

Senzorii utilizați pentru monitorizarea fotopletismogramei funcționează pe baza principiului fotometriei optice, un mecanism bine descris în literatura de specialitate [5] [6]. Această tehnologie se bazează pe utilizarea a două surse de lumină cu lungimi de undă diferite și a unui fotodetector sensibil pentru a identifica absorbția luminii de către hemoglobina oxigenată (HbO₂) și cea deoxigenată (Hb). Caracteristicile optice ale emițătoarelor includ o sursă în spectrul infraroșu (IR) la 910 nm și o altă sursă în spectrul roșu vizibil la 660 nm, acestea fiind utilizate pentru a evidenția diferențele de absorbție spectrală ale hemoglobinei [7].

Senzori pentru achiziția RGP

Răspunsului galvanic al pielii (RGP) monitorizează variațiile micro-curenților sau micro-tensiunilor electrice generate de schimbările în conductanța pielii. Există o varietate mare de senzori utilizați pentru achiziția acestor semnale [8] [9], iar conform cercetărilor efectuate de Boucsein [10] și Caruelle împreună cu colab. [11], există două metode fundamentale de măsurare a RGP: determinarea conductanței și determinarea rezistenței pielii.

Senzori pentru monitorizarea ritmului respirator

Monitorizarea ritmului respirator are un rol esențial în diagnosticarea și gestionarea unei număr mare de afecțiuni medicale, cum ar fi bolile pulmonare obstructive cronice (BPOC), apneea de somn sau insuficiența respiratorie. Alegerea senzorilor adecvați pentru monitorizarea parametrilor respiratori depinde de scopul și contextul utilizării acestora, precum și de caracteristicile pacientului.

Senzori pentru monitorizarea activității locomotorii și posturii corpului

Senzorii utilizați pentru monitorizarea mișcării și posturii funcționează pe baza unor principii fizice bine definite. Accelerometrele măsoară accelerația liniară utilizând elemente piezoelectrice sau capacitive care detectează variațiile de mișcare. Giroscopurile, pe de altă parte, se bazează pe efectul Coriolis pentru a măsura rata de rotație în jurul axelor. Busolele detectează variațiile câmpului magnetic, oferind informații despre orientarea în raport cu nordul geomagnetic.

Senzori pentru monitorizarea temperaturii corpului

Monitorizarea temperaturii corpului joacă un rol esențial în detectarea modificărilor fiziologice, precum febra, inflamațiile sau răspunsurile la tratamente medicale. Senzorii de temperatură reprezintă componente esențiale în diverse dispozitive medicale utilizate atât în cadrul spitalelor, cât și în monitorizarea la distanță. Aceștia trebuie să fie preciși, rapizi și să permită măsurători continue sau punctuale ale temperaturii, fiind adaptați la diverse zone anatomice și condiții de utilizare.

1.2.2 Sisteme de achiziție și transmisie a indicatorilor fiziologici

Sisteme de achiziții bazate pe dispozitive portabile

Monitorizarea continuă a parametrilor fiziologici cu ajutorul dispozitivelor portabile a devenit un domeniu esențial în cercetarea biomedicală și în telemedicină. Spre deosebire de sistemele clinice, sistemele portabile permit supravegherea în timp real a semnelor fiziologice (precum activitatea cardiacă, ritmul respirator, temperatura corpului sau saturația oxigenului) în afara spitalului [12]. Aceste dispozitive, sunt adesea amplasate pe corp sub formă de centuri, plasturi adezivi sau haine inteligente integrând senzori multipli și module electronice de prelucrare, oferind o imagine complexă asupra stării de sănătate a utilizatorului în condiții de viață cotidiană [13].

Platforme de achiziții de date destinate spitalelor și clinicilor

În România, sunt utilizate numeroase sisteme de monitorizare a pacienților, precum Philips IntelliVue, GE CARESCAPE, Dräger Infinity, Mindray BeneView, Spacelabs Healthcare și altele. Aceste sisteme sunt similare cu cele folosite la nivel internațional în ceea ce privește funcționalitatea și capacitatea de monitorizare a pacienților, însă pot exista diferențe în privința nivelului de actualizare tehnologică și a performanțelor fiecărui sistem.

1.3 Metode de analiză și extragere a trăsăturilor din indicatorii fiziologici

Metodele avansate de analiză a semnalelor, care au ca scop extragerea trăsăturilor, au cunoscut o evoluție semnificativă în ultimele decenii și sunt esențiale în numeroase domenii de cercetare și inginerie, ce presupun analiza complexă a semnalelor fiziologice, precum electrocardiograma (ECG), fotopletismograma (PPG), răspunsul galvanic al pielii (RGP), respirația și, totodată, date de la unități inerțiale de măsură (UIM – Inertial Measurement Units). În context biomedical prelucrarea începe, de regulă, printr-o evaluare atentă a semnalelor în domeniul timp, pentru a identifica trăsăturile fundamentale și de a reduce artefactele de zgomot. Analiza ulterioară în domeniul frecvență, efectuată prin transformări Fourier și alte tehnici de reprezentare spectrală, pot evidenția componente de interes pentru înțelegerea aspectelor ciclice, periodice sau tranzitorii. Atunci când semnalele prezintă o dinamică

pronunțată, analiza timp-frecvență (de exemplu, prin transformări de tip Wavelet) devine importantă pentru descrierea distribuției energetice a semnalului în funcție de timp și frecvență.

1.3.1 Metode de analiză a electrocardiogramei

Analiza semnalului electrocardiografic (ECG) oferă posibilitatea de a extrage automat un număr de caracteristici, cum ar fi: detecția undelor P, QRS, T, determinarea intervalelor (PR, QRS, QT), determinarea ritmului și a ritmului cardiac, precum și analiza variabilității ritmului cardiac (VRC). În plus, metodele avansate permit estimarea indirectă a frecvenței respiratorii din ECG, având în vedere interdependența dintre ritmul cardiac și respirație. În cele ce urmează sunt prezentate principalele etape și metode moderne de procesare a semnalului ECG, de la preprocesare, la detecția caracteristicilor morfologice și analiza ritmului cardiac.

Preprocesarea semnalului ECG

Preprocesarea are ca scop îmbunătățirea calității semnalului ECG prin eliminarea zgomotelor și a artefactelor înainte de analiza propriu-zisă. Cele mai comune surse de perturbare sunt reprezentate de variațiile lente de nivel cauzate de respirație sau mișcarea pacientului și interferența rețelei de alimentare (zgomotul de 50/60 Hz). Fluctuații de foarte joasă frecvență (0,05–3 Hz) se pot atenua prin filtre trece-sus (de exemplu, cu frecvența de tăiere $\sim 0,5$ Hz) sau prin metode de filtrare adaptivă, astfel încât componenta de foarte joasă frecvență să fie eliminată. Zgomotul de înaltă frecvență (mișcări musculare) este redus cu filtre trece-jos (de exemplu, cu o frecvență de tăiere ~ 40 Hz), iar interferența de rețea se elimină cu filtre de tip Notch centrate pe 50/60 Hz [14]. Metodele moderne utilizează și tehnici bazate transformate Wavelet [15] sau filtrare morfologică pentru separarea zgomotului de semnalul util, fără a distorsiona componentele complexului QRS.

Detecția caracteristicilor morfologice

Detecția complexului QRS este un pas esențial, deoarece acesta are o amplitudine mare și marchează bătăile inimii, servind drept reper pentru extragerea altor caracteristici. Un algoritm clasic, introdus de Pan și Tompkins, folosește filtrare digitală în bandă, derivare și un prag adaptiv pentru identificarea în timp real a complexelor QRS [16]. Acest algoritm a devenit unul de referință, atingând precizia de peste 99% pe baze de date standardizate [17]. Ulterior, au apărut numeroase alte metode, bazate pe transformata Wavelet [18], transformata Hilbert sau algoritmi derivați, care îmbunătățesc detecția în prezența zgomotului și a variabilității formei QRS. După identificarea vârfurilor R ai complexelor QRS, se pot calcula intervalele RR (distanța dintre bătăi succesive) pentru determinarea frecvenței și a ritmului cardiac.

Detecția undelor P și T este mai dificilă din cauza amplitudinii mai mici (unda P) sau a variațiilor morfologice (unda T). Metodele moderne abordează segmentarea completă a semnalului ECG: după detecția QRS, se determină poziția precisă a maximelor/minimelor undelor P și T, precum și începutul și sfârșitul acestora (intervalele PR, QT). Algoritmii pe bază de transformate Wavelet au demonstrat performanțe ridicate, identificând punctele caracteristice (început, final, vârf) ale undelor P și T cu erori medii de ordinul unei unități de eșantionare. De exemplu, Martinez și colaboratorii au propus o metodă

de segmentare bazată pe transformată Wavelet, capabil să segmenteze automat fiecare undă din ECG, validat pe baze de date de referință. Măsurarea intervalelor PR (de la începutul P la începutul QRS), a duratei QRS și a intervalului QT (de la începutul QRS la sfârșitul undei T) are o importanță clinică deosebită [17].

Analiza morfologică avansată include evaluarea simetriei undei T, care în mod normal prezintă o asimetrie ușoară, caracterizată printr-o pantă descendentă mai abruptă decât cea ascendentă. O simetrie marcată a acestei unde poate indica prezența ischemiei sau a altor anomalii de repolarizare ventriculară. De asemenea, analiza avansată implică și identificarea fenomenului de alternanță a undei T, definit prin variații alternante ale amplitudinii sau formeii undei de la o bătaie la alta [19].

Determinarea ritmului cardiac

Ritmul cardiac (secvența temporală a bătailor inimii) și frecvența cardiacă (numărul de băți pe minut, băți pe minut – BPM) se obțin direct din pozițiile complexelor QRS detectate. Intervalele RR (denumite și intervale NN – intervale între băți normale succesive) se calculează pe baza momentelor de apariție ale fiecărui complex QRS. Ritmul cardiac instantaneu se determină împărțind 60 la durata ultimului interval RR (în secunde), iar media pe un anumit interval de timp oferă ritmul cardiac mediu. Metodele moderne permit filtrarea artefactelor din seria de intervale RR (de exemplu, se elimină intervalele anormale generate de extrasistole sau de erorile de detecție) pentru a obține o serie RR curată, utilizată ulterior în analiza variabilității ritmului. De asemenea, se poate automatiza detecția unor tipare de ritm (precum aritmii) și se pot identifica episoade de tahicardie, bradicardie sau aritmii complexe (fibrilație atrială etc.).

Analiza variabilității ritmului cardiac (VRC)

Variabilitatea ritmului cardiac reprezintă fluctuațiile în timp ale duratei intervalelor RR și oferă informații despre reglarea autonomă a inimii. Standardele formulate de Task Force (Societatea Europeană de Cardiologie/Asociația Nord-Americană de Stimulare și Electrofiziologie, 1996) au definit indicatori statistici în domeniul timp și frecvență pentru variabilitatea ritmului cardiac. În domeniul timp, abaterea standard a tuturor intervalelor RR (SDNN) și mediei pătratelor diferențelor succesive între intervale RR (RMSSD) [20] sunt cele mai utilizate caracteristici ale VRC. SDNN determină variabilitatea globală a ritmului pe durata înregistrării, în timp ce RMSSD reflectă variabilitatea pe termen scurt, fiind influențată predominant de tonusul parasimpatic (activitatea nervului vag) [21]. Valori scăzute ale SDNN sau RMSSD indică scăderea variabilității (posibil asociată cu stres accentuat sau risc cardiac crescut), pe când valori ridicate sugerează o adaptabilitate bună a sistemului nervos autonom.

Estimarea indirectă a frecvenței respiratorii din ECG

Ritmul respirator influențează în mod fiziologic ECG-ul, fenomen cunoscut ca aritmie sinusală respiratorie: în timpul inspirației, intervalele RR tind să se scurteze ușor, iar în timpul expirației aceste tind să se prelungească, datorită variațiilor tonusului vagal. Acest efect permite estimarea frecvenței respiratorii indirect, din variabilitatea ritmului cardiac. Astfel, componenta HF a spectrului VRC (aproximativ 0,15–0,4 Hz) corespunde frecvenței respirației, permițând deducerea ritmului respirator prin analiza VRC, mai ales la subiecți tineri și sănătoși la care aritmia respiratorie este pronunțată [22].

1.3.2 Metode de analiză a fotopletismogramei

Această secțiune prezintă metodologiile esențiale de analiză a semnalului fotopletismografic (PPG), de la detecția vârfurilor sistolice și analiza morfologică a undei, la determinarea ritmului cardiac și a variabilității acestuia, estimarea timpului de propagare a undei de puls, extragerea frecvenței respiratorii și determinarea saturației de oxigen din sânge.

Detecția vârfurilor sistolice

Identificarea automată a vârfurilor sistolice ale undei PPG constituie punctul de plecare pentru multe analize ulterioare, întrucât permite determinarea ritmului cardiac și a intervalelor de puls consecutive. În absența unei metode robuste de detecție a băților, toate calculele derivate (precum variabilitatea ritmului cardiac sau timpul de propagare) pot fi compromise.

Analiza morfologică a undei PPG

Forma undei fotopletismografice conține informații relevante despre starea sistemului cardiovascular. Analiza morfologică se concentrează pe caracteristicile undei pulsatile: amplitudini, pante, incizuri și relații temporale între componentele sistolice și diastolice. Un prim pas este marcarea punctelor distincte ale undei: vârful sistolic principal, eventuala undă reflectată (vârful diastolic) care apare ca al doilea maxim sau ca incizură dicrotică, precum și panta ascendentă și descendentă. În acest scop, se utilizează frecvent formele derivate ale PPG: derivata întâi evidențiază panta ascendentă și punctul de inflexiune asociat incizurii dicrotice, iar derivata a doua accentuează și mai clar punctele de inflexiune.

Determinarea ritmului cardiac și a variabilității acestuia

Semnalul PPG este folosit frecvent pentru determinarea ritmului (RC) și variabilitatea ritmului cardiac (VRC), mai ales în contextul dispozitivelor portabile și al monitorizării continue, unde electrocardiograma (ECG) convențională poate fi impracticabilă. Ritmul cardiac se obține direct din PPG prin măsurarea intervalului dintre vârfurile sistolice succesive (intervale puls-puls, echivalente cu intervalele RR din ECG). Numeroase studii au validat acuratețea PPG în determinarea ritmului cardiac: încă din anii 1980–1990, dispozitivele portabile de puls pe bază de PPG erau incluse ca unealtă standard în mediul spitalicesc.

Estimarea timpului de propagare a undei de puls (PTT)

Timpul de propagare a undei de puls (*Pulse Transit Time* – PTT) reprezintă intervalul necesar undei pulsatile să parcurgă un anumit segment al arborelui arterial. Măsurarea PTT oferă informații despre rigiditatea arterială și despre tensiunea arterială: o undă de puls ajunge mai rapid la periferie în cazul arterelor rigide și al tensiunii mari.

Extragerea frecvenței respiratorii din PPG

Metodele de bază implică analiza în domeniul timp asupra semnalului PPG sau a derivaților săi: de pildă, transformatele Fourier sau analiza pe ferestre pot releva un maxim spectral la aproximativ 0,2–0,3 Hz, corespunzător respirației normale. Totuși, aceste metode liniare pot eșua în situații de semnal zgomotos sau când frecvența cardiacă și cea respiratorie interacționează prin armonici. O abordare mai avansată este dată de separarea diferitelor tipuri de modulații induse de respirație: variația de frecvență a pulsului (corelată aritmiei sinusale respiratorii – RSA), variația de amplitudine a pulsului (generată de modificările volumului în procesul mecanic de inspirație/expirație) și variația de intensitate sau fluctuațiile de frecvență foarte joasă a semnalului (influențată de modificările de întoarcere venoasă și volum sanguin periferic).

Determinarea saturației oxigenului arterial (SpO_2)

Determinarea saturației oxigenului arterial prin fotopletismografie reprezintă una dintre cele mai aplicate și validate metode neinvazive din practica medicală actuală. Conceptul de bază este dat de diferențele spectroscopice de absorbție ale hemoglobinei oxigenate și neoxigenate, măsurate la două lungimi de undă distincte, de regulă în spectrul roșu (aprox. 660 nm) și infraroșu (aprox. 940 nm).

1.3.3 Metode de analiză a ritmului respirator

Caracteristici precum amplitudinile inspirației/expirației, duratele ciclurilor și ritmul respirator pot varia considerabil de la un moment la altul și între indivizi. Este necesară o abordare complexă, cu etape de preprocesare (filtrare și eliminare a artefactelor), segmentare precisă a ciclurilor respiratorii și extragerea parametrilor morfologici, urmată de determinarea variabilității și a complexității (entropiei) acestor parametri.

Preprocesarea ritmului respirator

Înainte de analiza propriu-zisă, semnalul respirator brut necesită procedee de preprocesare care să atenueze zgomotul și să corecteze fluctuații de frecvență foarte joasă. Înregistrările respiratorii de lungă durată pot prezenta deplasări lente ale nivelului de referință cauzate de mișcări ale senzorului și modificări ale poziției corporale. Pentru remedierea acestor probleme se aplică filtre și tehnici specifice de eliminare a fluctuațiilor de frecvență foarte joasă.

Parametri morfologici ai respirației

După segmentare datelor, se extrag parametri morfologici pentru fiecare ciclu respirator, identificând trăsăturile formei de undă respiratorii. Un prim set de parametri include duratele fazelor respiratorii, de exemplu, durata inspirației (timpul de la începutul până la vârful ciclului) și durata expirației (de la vârf până la minimul următor), precum și durata totală a ciclului respirator (suma inspirației și expirației, eventual incluzând pauze).

Variabilitatea și entropia respirației

Dincolo de valorile medii ale parametrilor morfologici, este esențială evaluarea variabilității respirației, adică măsura în care parametrii respiratori fluctuează de la un ciclu la altul. Un indicator statistic de bază este coeficientul de variație (CV), definit ca raportul dintre deviația standard și media unui șir de valori [23].

Determinarea frecvenței respiratorii

Frecvența respiratorie (numărul de cicluri pe minut) constituie un parametru vital, care trebuie adesea dedus automat din semnal. Există două abordări principale pentru determinarea frecvenței respiratorii: metode în domeniul timp și metode în domeniul frecvență.

1.3.4 Metode de analiză a răspunsului galvanic al pielii

Răspunsul galvanic al pielii (RGP) sau activitatea electrodermală (EDA) au fost studiate intensiv cu precădere în psihologie și neuroștiințe ca măsură a reacției de orientare, stresului și excitației emoționale, având aplicații în domenii variate (de la cercetarea învățării și atenției până la diagnostic clinic în anxietate sau schizofrenie) [24].

Componentele tonice și fazice (SCL și SCR)

Componenta tonică SCL reflectă nivelul de bază al conductanței pielii în absența unor stimuli discreți, fiind influențată de starea generală de activare și de factori individuali și situaționali. Fiecare persoană are un SCL propriu, care poate varia semnificativ între indivizi, de ordinul câtorva μS până la zeci de μS și care se modifică lent în funcție de starea psihologică sau termoreglare. În schimb, componenta fazică constă în creșteri bruște ale conductanței, evocate de stimuli relevanți sau apărute spontan, numite răspunsuri galvanice sau SCR. Aceste răspunsuri se manifestă ca „vârfuri” tranzitorii în semnal: o creștere rapidă a conductanței cauzată de activarea sudomotorie, urmată de o revenire treptată la nivelul tonic de bază (SCL). Un răspuns SCR tipic apare la $\sim 1-3$ secunde după un stimul semnificativ, urcă abrupt până la un maxim, apoi scade lent, având o durată totală de $\sim 10-20$ secunde până revine la bază.

Capitolul 2

Sistem experimental tip IoMT pentru achiziția semnalelor fiziologice

Obiectivul acestui capitol îl constituie prezentarea unui sistem experimental de tip IoMT (Internet of Medical Things) [25], optimizat pentru achiziția indicatorilor fiziologici în diverse scenarii. Cu ajutorul unui astfel de sistem s-au realizat, în cadrul cercetărilor doctorale, o serie de studii privitoare la evoluția unor parametri fiziologici umani în diverse scenarii, după cum va fi prezentat în capitolele următoare.

Sistemul dezvoltat reprezintă o soluție modernă și scalabilă pentru monitorizarea biomedicală, cu aplicabilitate în achiziția și transmiterea în timp real a unui set larg de indicatori fiziologici, de la semnale electrocardiografice și fotopletismografice până la răspunsul galvanic al pielii, temperatura corporală, ritmul respirator și poziția corpului.

Principiul de funcționare al sistemului este ilustrat în Figura 2.1, care prezintă topologia arhitecturii și tehnologiile de comunicație fără fir, evidențiind modul în care nodurile de monitorizare interacționează cu serverul de achiziție prin protocoale wireless Wi-Fi și Bluetooth. Această arhitectură modulară asigură atât colectarea securizată, în timp real, a parametrilor fiziologici, cât și stocarea și procesarea ulterioară a datelor. În acest sens, au fost utilizate șase tipuri de noduri de monitorizare specializate: NMECG (Nod Monitorizare a ECG), NMPPG (Nod Monitorizare a PPG), NMRGP (Nod Monitorizare a Răspunsului Galvanic al Pielii), NMPPGTC (Nod Monitorizare a PPG și a Temperaturii Corpului), NMPC (Nod Monitorizare a Posturii Corpului) și NMRR (Nod Monitorizare a Ritmului Respirator).




Figura 2.1 Schema bloc a sistemului IoMT propus

2.1 Amplasarea sistemului de monitorizare

Sistemul propus, ale cărui noduri și infrastructură vor fi prezentate în această secțiune, este ilustrat în Figura 2.2. Acest sistem integrează o rețea complexă de noduri de monitorizare, dispuse pe suprafața corpului uman, fiecare nod fiind caracterizat de un modul electronic autonom și senzori alături de elementele lor sensibile, având un rol bine definit în achiziția și transmiterea parametrilor fiziologici specifici. Rețeaua cuprinde șase noduri de monitorizare autonome, care comunică independent cu serverul de achiziție a datelor.

Toate nodurile sunt atașate subiectului prin curele elastice și cabluri de interconectare a elementelor sensibile, fiecare nod conținând un modul electronic capabil să achiziționeze și să prelucreze semnalele provenite de la elementele senzitive, pentru ca ulterior să le transmită în timp real către un server central.





Figura 2.2 Amplasarea nodurilor de monitorizare și infrastructura de comunicație a sistemului propus

2.2 Descrierea nodurilor de monitorizare

Cele șase noduri de monitorizare proiectate în cadrul acestei lucrări au caracteristicile sintetizate în Tabelul 2.1, de la parametri fiziologici măsurați și protocoalele de transmisie (Wi-Fi sau Bluetooth), până la tipurile de circuite integrate și intervalele de frecvență de eșantionare.

Fiecare nod este descris individual, incluzând detalii despre arhitectura hardware și software specifică, componentele electronice utilizate, principiile de funcționare și algoritmi embedded implementați. De asemenea, sunt prezentate caracteristicile intrinseci ale senzorilor utilizați, provocările întâmpinate în conversia semnalelor analogice în numerice și aspectele relevante legate de transmiterea datelor prin intermediul rețelelor Wi-Fi sau Bluetooth. Totodată, sunt analizate sursele potențiale de eroare și influențele externe ce pot afecta precizia și stabilitatea datelor achiziționate.

Tabelul 2.1 Prezentarea generală a nodurilor de monitorizare dezvoltate

Nume Nod	Parametri măsurați	Modul de transmisie a datelor	Circuite integrate utilizate	Frecvența de eșantionare
NMPPG 	*Fotopletismograma	Wi-Fi	ESP32, SEN0203	400 Hz
NMECG 	*Electrocardiograma	Wi-Fi	ESP32, AD8232	400 Hz
NMRGP 	*Răspunsul galvanic al pielii	Wi-Fi	ESP32, CJMCU200	400 Hz
NMPPGTC 	*Fotopletismograma (SpO ₂), *Temperatura corpului	Wi-Fi	ESP32, MAX30102, MAX30205	400 Hz
NMPC 	* Poziția corpului	Wi-Fi	ESP32, MPU9250	100 Hz
NMRR 	* Ritm respirator	Bluetooth	Vernier Go Direct	10 Hz

2.2.1 Nodul de monitorizare ECG (NMECG)

Nodul de monitorizare ECG (NMECG) a fost proiectat și integrat pentru a achiziționa și a transmite în timp real activitatea electrică a inimii. În Figura 2.3 sunt prezentate componentele electronice utilizate, după cum urmează:

- un modul **WeMos Mini D1 ESP32**, ce este responsabil de procesarea eficientă a semnalelor și transmiterea lor prin conexiunea Wi-Fi;

- un modul **AD8232** [26] [27], specializat pentru achiziția și prelucrarea semnalelor electrice de amplitudine mică, în special ECG.

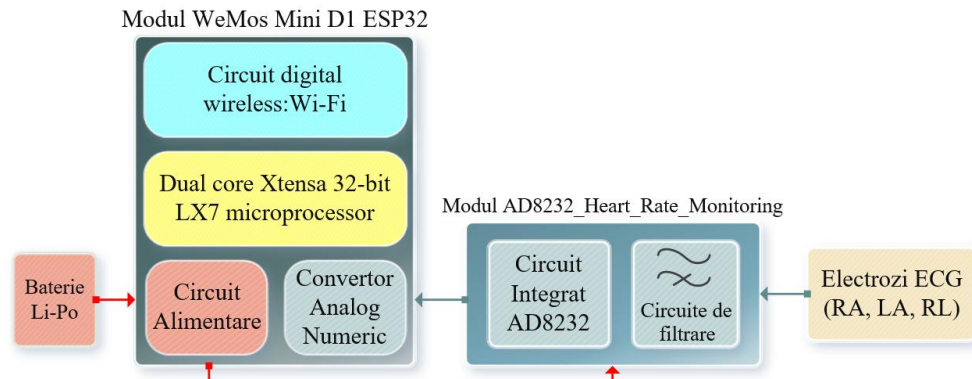


Figura 2.3 Diagrama bloc a nodului NMECG

Amplasarea prototipului nodului NMECG este prezentată în Figura 2.4, unde se observă electrozii atașați în punctele RA (braț drept), LA (braț stâng) și LL (picior stâng), pentru captarea semnalelor electrice ale inimii.




Figura 2.4 Amplasarea nodului NMECG și infrastructura de transmitere, vizualizare și stocare de date

2.2.2 Nodul de monitorizare PPG (NMPPG)

Nodul de monitorizare PPG (NMPPG), a cărui diagramă bloc este redată în Figura 2.5, se bazează pe modulul **SEN0203** [28], care asigură măsurarea pulsului prin detectarea modificărilor de volum sanguin la nivelul pielii.




Figura 2.5 Diagrama bloc a nodului de monitorizare NMPPG

Figura 2.6 prezintă infrastructura completă a nodului de monitorizare PPG, amplasat pe braț. Acesta achiziționează semnalul PPG, pe care îl transmite prin intermediul unei rețele Wi-Fi interne către un server de achiziție.



Figura 2.6 Amplasarea nodului de monitorizare NMPPG și infrastructura de transmitere, vizualizare și stocare de date

2.2.3 Nodul de monitorizare PPG și a temperaturii corpului (NMPPGTC)

Figura 2.7 prezintă diagrama-bloc a nodului NMPPGTC, proiectat în jurul modulului WeMos Mini D1 ESP32 și a două subsisteme secundare:

- Modulul de măsurare a temperaturii (circuitul specializat MAX30205);
- Modulul de pulsoximetrie (circuitul specializat MAX30102), ambele conectate printr-o interfață I²C.




Figura 2.7 Diagrama bloc a nodului NMPPGTC

Figura 2.8 prezintă o schemă conceptuală în care nodul NMPPGTC este plasat pe brațul unui subiect, iar senzorul MAX30102 după cum se observă este plasat pe degetul subiectului utilizând o bandă tip scai și colectează date PPG (fotopletismografie cu LED roșu și LED infraroșu). În ceea ce privește senzorul MAX30205 acesta este plasat pe încheietura mâinii cu o bandă medicală.




Figura 2.8 Amplasarea nodului de monitorizare NMPPGTC și infrastructura de transmitere, vizualizare și stocare de date

2.2.4 Nodul de monitorizare RGP (NMRGP)

Diagrama bloc a nodului NMRGP, destinat monitorizării răspunsului galvanic al pielii și a conductivității acesteia, este prezentată în Figura 2.9 și include modulul WeMos Mini D1 ESP32, un modul de monitorizare a răspunsului galvanic al pielii denumit CJMCU-6701 și un set de electrozi care se aplică la nivelul degetelor prin intermediul unor benzi elastice




Figura 2.9 Diagrama bloc al nodului NMRGP

Figura 2.10 evidențiază modul de amplasare și organizare a nodului de monitorizare RGP, subliniind fluxul de date de la nodul amplasat pe braț până la serverul de achiziție. În primul rând, senzorii colectează semnalele electrice ale răspunsului galvanic al pielii, transmițând aceste informații către nodul de monitorizare RGP.




Figura 2.10 Amplasarea nodului de monitorizare NMRGP și infrastructura de transmitere, vizualizare și stocare de date

2.2.5 Nodul de monitorizare a ritmului respirator (NMRR)

Nodul de monitorizare a ritmului respirator este reprezentat de dispozitivul portabil Vernier Go Direct Respiration Belt [29], conceput pentru monitorizarea variațiilor respiratorii prin măsurarea modificărilor de tensiune ale unei benzi elastice plasate în jurul toracelui sau abdomenului.



Figura 2.11 Nodul NMRR – Go Direct Respiration Belt

În Figura 2.12 prezintă infrastructura necesară pentru monitorizarea respirației: nodul NMRR, sub forma unei centuri montate în jurul toracelui, comunică prin Bluetooth cu un server de achiziție a datelor. Datele primite pot fi afișate în timp real printr-o interfață grafică și salvate în format CSV pentru arhivare și analiză ulterioară. De asemenea, conexiunea la o rețea Wi-Fi externă permite integrarea într-un sistem mai complex, facilitând monitorizarea continuă în diferite scenarii și contexte de cercetare.




Figura 2.12 Amplasarea nodului de monitorizare NMRR și infrastructura de transmitere, vizualizare și stocare de date

2.2.6 Nodul de monitorizare a posturii corpului (NMPC)

Monitorizarea posturii corpului se realizează prin intermediul nodului NMPC, a cărui diagramă bloc și al cărui prototip sunt ilustrate în Figura 2.13. Acest nod este alcătuit dintr-un ansamblu în care modulul MPU9250 [30], utilizat exclusiv pentru accelerometru și giroscop, este conectat la un modul WeMos Mini ESP32 prin intermediul magistralei I²C (cu semnalele SCL, SDA și pinul INT pentru întreruperi).




Figura 2.13 Diagrama bloc a nodului NMPC

Figura 2.14 ilustrează infrastructura necesară pentru monitorizarea poziției corpului, în care nodul de monitorizare NMPC, amplasat în zona taliei, colectează datele de la senzorii inerțiali (accelerometru și giroscop) și transmite informațiile prin intermediul unei rețele Wi-Fi interne către un server de achiziție. Acesta din urmă asigură vizualizarea în timp real a parametrilor înregistrați și totodată stocarea lor în format CSV.




Figura 2.14 Amplasarea nodului de monitorizare NMPC și infrastructura de transmitere, vizualizare și stocare de date

2.3 Serverul de achiziție date

Serverul de achiziție date este constituit din mai multe script-uri Python care sunt executate pe un laptop care are conexiune la internet pentru a facilita sincronizarea datelor prin protocolul SNTP și pentru opțiunea accesării datelor de la distanță. Aceste scripturi sunt instanțe ale codului a cărui

organigramă este ilustrată în Figura 2.17, cu mici diferențe în ceea ce privește configurația port-urilor nodurile TCP/IP.

Figura 2.15 ilustrează organigrama software pentru stabilirea și gestionarea conexiunilor de tip client–server în vederea monitorizării și achiziției de date, evidențiind atât procesele care au loc la nivelul „nodurilor de monitorizare” (clienți TCP/IP), cât și cele desfășurate pe serverul de achiziție (server TCP/IP).




Figura 2.15 Organigrama de interacțiune dintre nodurile NMECG, NMPPG, NMRGP, NMPC, NMPPGTC și serverul de achiziție date

În Figura 2.16 este exemplificată organigrama de distribuție pe sarcini a codului *embedded* încărcat în nodurile NMECG, NMPPG și NMRGP implementate la nivel de RTOS folosind *freeRTOS*. Se evidențiază două sarcini principale, denumite „Conversie_CAN” și „Transmitere_Client_TCP”, fiecare responsabilă de o etapă specifică a prelucrării și transmiterii datelor.




Figura 2.16 Organigrama distribuită pe sarcini *freeRTOS* a codului *embedded* încărcat pe noduri NMECG, NMPPG și NMRGP

Organigrama prezentată în Figura 2.17 ilustrează un flux secvențial și iterativ, structurat în două ramuri principale, care conlucrează pentru a asigura atât inițializarea cât și gestionarea dinamică a datelor primite de la un client printr-o conexiune TCP.




Figura 2.17 Diagrama logică a serverului de achiziție date al nodurilor care comunică prin Wi-Fi (NMECG, NMPPG, NMRGP, NMPPGTC și NMPC)

Capitolul 3

Prezentarea datelor experimentale

3.1 Organizarea studiului

Pentru acest studiu, au fost definite cinci scenarii experimentale, diferențiate în funcție de poziția corporală și de nivelul efortului fizic depus, cu scopul de a facilita o analiză comparativă a răspunsurilor fiziologice și comportamentale. Caracteristicile acestor scenarii sunt sintetizate în Tabelul 3.1.

Cercetarea propune cinci scenarii clar delimitate, menite să evidențieze modul în care parametrii fiziologici (de exemplu, ritm cardiac, frecvență respiratorie, activitate metabolică) și parametrii comportamentali variază în funcție de postura corporală și de intensitatea efortului. O asemenea abordare sprijină analiza și interpretarea sistematică a rezultatelor, oferind totodată posibilitatea identificării factorilor determinanți ai adaptării organismului la diferite niveluri de activitate.

Tabelul 3.1 Scenariile ce au fost propuse în cadrul cercetării

Scenariul 1 – SC1 <i>Poziție de repaus</i>	Subiectul este întins în pat, într-o poziție complet relaxată, care asigură un nivel minim de activare musculară și de consum energetic. Această poziție servește drept „scenariu de referință” pentru reacțiile fiziologice în condiții de repaus absolut.
Scenariul 2 – SC2 <i>Poziție ortostatică</i>	Subiectul stă în picioare, menținând o postură verticală stabilă. În comparație cu repausul complet, ortostatismul presupune un efort fizic modest, necesar pentru menținerea echilibrului și susținerea întregii greutate corporale.
Scenariul 3 – SC3 <i>Poziție șezândă</i>	Subiectul este așezat pe un scaun la masă, desfășurând o activitate de intensitate redusă (de exemplu, lucru la calculator). Acest scenariu permite evaluarea răspunsurilor fiziologice asociate activităților sedentare tipice, cu consum energetic scăzut.
Scenariul 4 – SC4 <i>Alergare ușoară</i>	Subiectul efectuează un efort fizic moderat, sub forma unei alergări de intensitate scăzută. Accentul cade pe dinamica fiziologică indusă de un exercițiu susținut, dar la intensitate moderată, facilitând analiza adaptărilor cardiorespiratorii și metabolice de nivel mediu.
Scenariul 5 – SC5 <i>Mers lejer</i>	Subiectul se deplasează printr-o plimbare lentă, cu intensitate redusă. Acest tip de activitate presupune o activare fizică minimă, dar superioară statului în repaus sau în șezut, fiind reprezentativă pentru activitățile cotidiene care nu necesită un efort muscular semnificativ.

Tabelul 3.2 ilustrează caracteristicile demografice și antropometrice ale voluntarilor incluși în studiul prezent. Sunt sintetizați parametri relevanți precum sexul, vârsta, greutatea corporală și înălțimea fiecărui subiect. Lotul este constituit din 13 participanți, dintre care 8 sunt de sex masculin (61,5%) și 5 de sex feminin (38,5%), reflectând o distribuție relativ echilibrată din perspectiva genului. Vârsta participanților variază între 28 și 60 de ani, acoperind un interval larg care permite analiza influenței acestui factor asupra rezultatelor obținute în cadrul studiului.

Greutatea corporală a voluntarilor variază între 59 kg și 98 kg, în timp ce înălțimea acestora este cuprinsă între 162 cm și 190 cm, indicând o diversitate semnificativă în privința parametrilor antropometrici analizați. Această diversitate oferă un cadru adecvat pentru evaluarea comparativă și identificarea eventualelor influențe pe care caracteristicile fizice individuale le pot avea asupra variabilelor fiziologice măsurate în cursul experimentului. Astfel, prin selecția atentă a subiecților, se urmărește asigurarea unei validități externe și relevanțe generale mărite a concluziilor studiului prezentat.

Tabelul 3.2 Caracteristicile demografice și antropometrice ale voluntarilor implicați în studiu

Nume subiect	Sex (M/F)	Vârsta (ani)	Greutate (kg)	Înălțime (cm)
S1-AA	M	30	85	170
S2-AAI	M	41	72	176
S3-AD	F	34	62	168
S4-AI	M	32	80	177
S5-DI	F	31	67	168
S6-MA	F	31	59	162
S7-VI	M	56	98	190
S8-DC	M	60	90	182
S9-ND	M	42	87	165
S10-LB	F	35	78	177
S11-DDD	M	28	71	174
S12-ST	M	37	78	176
S13-LI	F	56	72	172

Fiecare voluntar a parcurs toate cele cinci scenarii (prezentate în Tabelul 3.1), însă nu în aceeași ordine și pentru intervale de timp diferite, variind de la câteva minute până la câteva zeci de minute. O astfel de abordare repetată, susține acuratețea colectării datelor și permite o comparație longitudinală a reacțiilor fiziologice. De pildă, la persoanele cu o masă corporală mai mare se poate observa un consum energetic relativ mai ridicat sau o creștere mai pronunțată a frecvenței cardiace în situații ce presupun efort fizic (alergare ușoară sau mers lejer), comparativ cu cele cu o masă corporală mai redusă. În mod similar, factorul de vârstă poate influența percepția efortului în diferite posturi (de exemplu, ortostatică vs. repaus) ori în activități (sedentară șezândă vs. activă).

Toți subiecții și-au exprimat în scris acordul pentru efectuarea experimentelor. De subliniat că toate experimentele sunt neinvazive și nu prejudiciază în nici un fel sănătatea și integritatea fizică și morală a subiecților.

În Figura 3.1 este ilustrată amplasarea nodurilor de monitorizare ale sistemului pe subiecți, astfel încât să se asigure achiziția parametrilor fiziologici necesari studiului. Nodurile sunt plasate strategic pe diferite segmente ale corpului (brațe, torace, abdomen), pentru a maximiza precizia și stabilitatea înregistrărilor de-a lungul scenariilor. Amplasarea senzorilor respectă principiile ergonomice și de siguranță și este gândită în așa fel încât să nu împiedice semnificativ mișcările subiecților, de la poziții statice până la alergare ușoară.




Figura 3.1 Amplasarea ansamblului de noduri pe subiecți

3.2 Prezentarea variațiilor indicatorilor fiziologici între subiecți și între scenarii

În cadrul acestei secțiuni se realizează o analiză comparativă a indicatori fiziologici achiziționați de la doi subiecți cu caracteristici distincte: S5-DI (femeie, 31 de ani) și S7-VI (bărbat, 56 de ani). Înregistrările au fost efectuate în cele cinci scenarii: repaus (scenariul 1), poziție ortostatică (scenariul 2), poziție șezând (scenariul 3), efort moderat (scenariul 4) și mers lejer (scenariul 5).

3.2.1 Măsurători ECG

În Figura 3.2 sunt prezentate evoluțiile indicatorilor fiziologici pentru cei doi subiecți, S5-DI și S7-VI. Fiecare dintre cele cinci diagrame corespunde unei ferestre de 30 de secunde aparținând unui scenariu diferit. Graficele ECG ilustrează modul în care ritmul cardiac și amplitudinea undelor QRS se modifică la trecerea de la repaus la poziție ortostatică, poziție șezândă, alergare ușoară și mers lejer.




Figura 3.2 Ferestre de 30 de secunde ale semnalului ECG achiziționate de la nodul NMECG pentru subiecții S5-DI și S7-VI în cele 5 scenarii

3.2.2 Măsurători PPG (Încheietură)

Analiza semnalelor PPG înregistrate la nivelul încheieturii mâinii (Figura 3.3) evidențiază variații semnificative ale amplitudinii undelor și clarității ciclurilor pulsului, influențate de modificările de poziție și de nivelul de efort din cele cinci scenarii.




Figura 3.3 Ferestre de 30 de secunde ale semnalului PPG (Încheietură) achiziționate de la nodul NMPPG pentru subiecții S5-DI și S7-VI în cele 5 scenarii

3.2.3 Măsurători PPG (Deget)

În figurile Figura 3.4 și Figura 3.5 sunt prezentate semnalele PPG-Roșu (PPG-R) și PPG-Infraroșu (PPG-IR), înregistrate la nivelul degetului, pentru subiecții S5-DI și S7-VI, în cele cinci scenarii. Se remarcă variații distincte ale amplitudinii undelor, clarității ciclurilor pulsului și nivelului de zgomot, influențate atât de postura adoptată, cât și de intensitatea efortului.




Figura 3.4 Ferestre de 30 de secunde ale semnalului PPG(Deget)-Roșu achiziționate de la nodul NMPPGTC pentru subiecții S5-DI și S7-VI în cele 5 scenarii




Figura 3.5 Ferestre de 30 de secunde ale semnalului PPG(Deget)-Infraroșu achiziționate de la nodul NMPPGTC pentru subiecții S5-DI și S7-VI în cele 5 scenarii

3.2.4 Măsurători de temperatură a corpului

În Figura 3.6 sunt evidențiate semnalele de temperatură corporală pentru subiecții S5-DI și S7-VI în fiecare dintre cele cinci scenarii, evidențiindu-se atât valorile medii, cât și stabilitatea înregistrărilor, elemente corelate cu poziția corpului, nivelul de efort și caracteristicile individuale (modul de fixare a senzorului, particularități fiziologice).




Figura 3.6 Ferestre de 30 de secunde ale temperaturii corporale achiziționate de la nodul NMPPGTC pentru subiecții S5-DI și S7-VI în cele 5 scenarii

3.2.5 Măsurători RGP

În Figura 3.7 sunt ilustrate răspunsurile galvanice ale pielii (RGP), care evidențiază diferențe notabile ale nivelurilor și fluctuațiilor tensiunii măsurate de la nivelul pielii, corelate cu schimbările de postură și nivelul de efort din cele cinci scenarii.




Figura 3.7 Ferestre de 30 de secunde ale răspunsului galvanic al pielii achiziționate de la nodul NMRGP pentru subiecții S5-DI și S7-VI în cele 5 scenarii

3.2.6 Măsurători ale ritmului respirator

În Figura 3.8 sunt prezentate semnalele ritmului respiratorii pentru cei doi participanți (S5-DI și S7-VI) în cele cinci scenarii, remarcându-se diferențe considerabile în amplitudinea formelor de undă și în regularitatea ciclurilor.




Figura 3.8 Ferestre de 30 de secunde ale respirației achiziționate de la nodul NMRR pentru subiecții S5-DI și S7-VI în cele 5 scenarii

3.2.7 Măsurători privind postura corpului și efort

Figura 3.23 prezintă valorile axelor x, y și z ale accelerometrului (pe axa din stânga) și ale giroscopului (pe axa din dreapta), pentru subiecții S5-DI și S7-VI, în cinci scenarii distincte, fiecare cu o durată de 30 de secunde de înregistrare.




Figura 3.9 Ferestre de 30 de secunde ale posturii corpului achiziționate de la nodul NMPC pentru subiecții S5-DI și S7-VI în cele 5 scenarii

Capitolul 4

Prelucrarea și analiza datelor experimentale

4.1 Tehnici de prelucrare și analiză a datelor experimentale

Acest capitol abordează procesul complet de prelucrare și analiză a patru indicatori fiziologici fundamentali: electrocardiograma (ECG), fotopletismograma (PPG), răspunsul galvanic al pielii (RGP) și ritmul respirator, evidențiind etapele cheie necesare pentru obținerea unor informații relevante și de acuratețe ridicată. Pornind de la metodele de filtrare (pentru eliminarea zgomotelor și menținerea componentelor de interes), sunt descrise tehnicile de detecție a trăsăturilor caracteristice (de exemplu, vârfurile R ale complexului QRS, creșterile pulsatile din PPG, fluctuațiile galvanice rapide și frecvențele respiratorii dominante). Prin coroborarea analizei în domeniul timp cu cea în domeniul frecvență, se estimează cu precizie parametri precum intervalele RR, caracteristicile morfologice ale undelor cardiace, variabilitatea ritmului cardiac și echilibrul simpatic–parasimpatic, dar și amplitudinile și pantele pulsului (PPG), reacțiile pielii induse de activarea nervoasă simpatică (RGP), ori comportamentul respirator asociat efortului ori stărilor emoționale.

4.1.1 Prelucrarea și extragerea trăsăturilor relevante din seturile de date privitoare la ECG

4.1.2 Prelucrarea și extragerea trăsăturilor relevante din setul de date PPG

În cadrul secțiunii următoare sunt descrise etapele esențiale de prelucrare și analiză a semnalului fotopletismografic (PPG), într-o manieră menită să asigure calitatea datelor și să ofere o bază solidă pentru extragerea parametrilor fiziologici relevanți. Introducerea extragerii trăsăturilor relevante din semnalul PPG se bazează pe premisa că acesta reflectă variațiile de volum sanguin în vasele periferice, în concordanță cu principiile fiziologiei cardiovasculare. Înregistrarea neinvazivă a semnalului, guvernată de interacțiunea luminii cu țesutul, este sensibilă la factori interni (ritmul cardiac, presiunea arterială, rigiditatea vasculară) și externi (mișcări, contact imperfect cu senzorul), motiv pentru care sunt necesare etape de preprocesare precum normalizarea, filtrarea mediană și filtrarea trece-bandă, în vederea obținerii unor date fiabile.

4.1.3 Prelucrarea și extragerea trăsăturilor relevante din RGP

În cadrul acestei secțiuni, procesul de prelucrare numerică a semnalului de rezistență galvanică a pielii (RGP) presupune conversia inițială a valorilor măsurate în microsiemens, separarea semnalului în componentele tonică (SCL) și fazică (SCR) folosind filtre specifice, evaluarea parametrilor statistici și analiza tendinței prin regresie liniară, determinarea complexității prin entropia aproximativă și analiza energetică detaliată în domeniul frecvenței utilizând metoda Welch.

4.1.4 Prelucrarea și extragerea trăsăturilor relevante din ritmul respirator

În cadrul acestei secțiuni, procesul de prelucrare numerică a semnalului respirator presupune eliminarea fluctuațiilor lente prin ajustarea unei curbe polinomiale și aplicarea unui filtru Butterworth de tip trece-bandă, detectarea vârfurilor și minimelor pentru identificarea parametrilor morfologici, calcularea raportului inspirație-expirație și determinarea amplitudinilor și pantelor de inspirație și expirație. Analiza variabilității semnalului include evaluarea statistică a parametrilor precum media, abaterea standard, asimetria și curtoza, în timp ce determinarea frecvenței respiratorii se realizează atât prin metode în domeniul timpului, cât și prin analiză spectrală în domeniul frecvenței folosind transformata Fourier rapidă (FFT).

4.2 Evoluția unor parametri calculați

4.2.1 Evoluția parametrilor în funcție de scenarii pe un singur subiect

În cadrul acestei secțiuni, procesul de prelucrare numerică a semnalului respirator presupune eliminarea fluctuațiilor lente prin ajustarea unei curbe polinomiale și aplicarea unui filtru Butterworth de tip trece-bandă, detectarea vârfurilor și minimelor pentru identificarea parametrilor morfologici, calcularea raportului inspirație-expirație și determinarea amplitudinilor și pantelor de inspirație și expirație. Analiza variabilității semnalului include evaluarea statistică a parametrilor precum media, abaterea standard, asimetria și curtoza, în timp ce determinarea frecvenței respiratorii se realizează atât prin metode în domeniul timpului, cât și prin analiză spectrală în domeniul frecvenței folosind transformata Fourier rapidă (FFT).

Analiza evoluției ritmului cardiac și a frecvenței respiratorii a demonstrat o concordanță clară între valorile obținute prin electrocardiogramă (ECG) și fotopletismografie (PPG), atât de la nivelul brățării cât și al degetului, în toate scenariile experimentale. În repaus, ritmul cardiac și frecvența respiratorie au fost stabile, cu valori scăzute, care au crescut semnificativ în scenariul alergării ușoare, revenind ulterior la nivele moderate în etapa de mers lent. Parametrii suplimentari precum saturația de oxigen și răspunsul galvanic al pielii au evidențiat răspunsuri adecvate solicitării fizice, indicând o oxigenare constantă și activarea sistemului nervos simpatic, respectiv adaptarea termică a organismului în funcție de intensitatea activităților.




Figura 4.1 Evoluția parametrilor subiectului S5-DI în toate cele 5 scenarii

4.2.2 Comparație între metode de calcul al parametrilor în domeniul timp și domeniul frecvență

Analiza comparativă a metodelor de calcul ale ritmului cardiac din surse diferite este prezentată în Figura 4.3, unde fiecare din cele 4 reprezentări grafice, corespunde aplicării a doua metode de estimare a ritmului cardiac.




Figura 4.2 Comparația între metodele de calcul ale ritmului cardiac obținute în domeniul timp (D_T) și în domeniul frecvență (D_F) din diferite surse

Se observă, în primul rând, că reprezentările grafice evidențiază evoluția ritmului cardiac (RC) estimat prin două metode de analiză, din domeniul timp (D_T) și din domeniul frecvență (D_F), pentru semnale colectate prin intermediul mai multor noduri de monitorizare: NMECG (ECG) și diverse configurații PPG (încheietură, deget-IR, deget-R). Valorile obținute prin metoda din domeniul timp

urmăresc secvența naturală a evenimentelor cardiace și oferă, în general, o variație lină a ritmului, fiind sensibilă la posibile fluctuații locale generate de artefactele de mișcare sau de variațiile instantanee ale intervalelor dintre bătăi. În schimb, estimarea ritmului cardiac în domeniul frecvență se bazează pe detecția spectrală a componentelor periodice, fapt care asigură o precizie ridicată în condiții de semnal relativ constant, însă poate introduce discrepante în zonele de tranziție rapidă, unde intervalele cardiace nu s-au stabilizat.

Analiza comparativă a metodelor de calcul ale frecvenței respiratorii din surse diferite este prezentată în Figura 4.3, unde fiecare din cele 5 reprezentări grafice, corespunde aplicării a doua metode de estimare a frecvenței respiratorii. Se evidențiază atât concordanța generală a valorilor obținute, cât și particularitățile impuse de tipul de semnal și de modul de procesare.




Figura 4.3 Comparația între metodele de calcul ale frecvenței respiratorii din ECG obținute în domeniul timp (D_T) și în domeniul frecvență (D_F)

Comparația reprezentărilor D_T și D_F în aceleași grafice relevă, în majoritate a intervalelor, o bună suprapunere, fapt ce indică convergența rezultatelor. Totuși, la tranzițiile rapide, de exemplu când subiectul trece de la repaus la efort sau invers, se pot sesiza mici decalaje între cele două abordări. Aceste diferențe nu alterează interpretarea fiziologică fundamentală, deoarece ambele metode permit delimitarea clară a zonelor cu frecvență respiratorie crescută și a celor cu valori reduse, reflectând astfel capacitatea subiectului de a-și adapta ventilația la intensitatea activității. În plus, fiecare sistem de achiziție (electrocardiogramă – ECG sau fotopletismografie – PPG, la încheietură ori la deget) își pune în evidență propriile sensibilități la mișcare și la variațiile locale de puls, existând ușoare fluctuații sau artefacte corelate cu schimbările de postură și efort. Per ansamblu, datele susțin eficiența metodelor de estimare din D_T și D_F, precum și capacitatea subiectului de a-și adapta frecvența raport cu cerințele metabolice. În consecință, alegerea abordării optime (D_T, D_F sau o integrare a acestora) poate fi realizată în funcție de obiectivele specifice ale studiului, fie că se urmărește detectarea rapidă a variațiilor tranzitorii, fie estimarea stabilă a unei frecvențe dominante pe un interval definit.

4.2.3 Evoluția parametrilor pe subiecți și scenarii

În această secțiune sunt analizate în detaliu modificările fiziologice induse de cele cinci scenarii experimentale (SC1–SC5), cu accent pe dinamica ritmului cardiac (RC), frecvenței respiratorii (FR) și nivelului conductanței pielii (SCL). Evaluarea acestor parametri oferă o perspectivă integrată asupra răspunsului organismului în contextul unor niveluri variate de efort fizic și solicitare a posturii corpului. Analiza comparativă a reacțiilor fiziologice individuale, corelată cu datele demografice și antropometrice prezentate în Tabelul 3.2, permite identificarea unor tendințe clare, precum și evidențierea unor diferențe interindividuale notabile.

În Figura 4.4 se prezintă analiza individuală a reacției ritmului cardiac, evidențiind diferențe semnificative între cele cinci scenarii de efort (SC1–SC5), în corelație cu variabile precum masa corporală, vârsta și nivelul de antrenament fizic, conform datelor detaliate din Tabelul 3.2. În SC1, valorile înregistrate la întregul eșantion se înscriu, în general, în intervalul 60–84 bpm, cu o medie de aproximativ 70 ± 5.5 bpm. Participanții tineri, normoponderali, prezintă de obicei ritmuri cardiace spre limita inferioară (circa 60–65 bpm), indicând un grad de relaxare și o capacitate de recuperare optimă în repaus. În schimb, la indivizii cu masă corporală mai mare sau vârstă înaintată, se pot atinge valori de 80–84 bpm, relevând faptul că și în condiții pasive, efortul cardiovascular rămâne mai ridicat.

Trecerea la SC2 este marcată de o creștere moderată a frecvenței cardiace, care la nivelul întregului lot variază între 75 și 95 bpm, cu o medie situată în jur de 82 ± 6.1 bpm. Persoanele cu o condiție fizică bună manifestă creșteri limitate față de SC1 (de numai 10–12 bpm în medie), semn că susținerea greutății corporale nu impune o solicitare excesivă asupra aparatului cardiovascular. La polul opus, participanții cu un indice de masă corporală peste limitele normale înregistrează salturi de peste 15 bpm față de valorile de repaus, ajungând la 90–95 bpm, ceea ce indică o reactivitate cardiovasculară mai pronunțată. În SC3, mediile se stabilizează în jurul a 78 ± 5.8 bpm, însă dispersia valorilor individuale este mai mare. Unii subiecți acuză disconfort la ședere îndelungată și pot prezenta valori similare sau chiar superioare celor observate în ortostatism (85–90 bpm). Prin contrast, indivizii cu antrenament

cardiovascular bun și obiceiul de a lucra la birou pe perioade extinse rămân într-o plajă de 70–75 bpm, apropiată de cea din SC1.




Figura 4.4 Evoluția ritmului cardiac individual pe subiecți în timpul scenariilor (calculat din datele achiziționate de la nodul NMECG ca medie a celor 2 metode de determinare în domeniul timp și în domeniul frecvență)

Figura 4.5 prezintă o analiză detaliată a evoluției frecvenței respiratorii (FR) înregistrate individual pentru fiecare participant în timpul celor cinci scenarii experimentale, respectiv SC1 (repaus în poziție culcată), SC2 (poziție ortostatică statică), SC3 (ședere statică), SC4 (alergare ușoară) și SC5 (mers lejer). Datele au fost obținute prin integrarea valorilor măsurate la nodul NMRR, ca medie a celor două metode distincte de determinare, în domeniile temporal și de frecvență.

În scenariul de repaus (SC1), frecvențele respiratorii individuale se situează predominant în intervalul inferior, reflectând solicitarea metabolică minimă specifică stării de odihnă absolută. Astfel,

valorile FR înregistrate sunt cuprinse între 13 rpm (subiecții S3-AD și S4-AI) și 16 rpm (subiecții S1-AA, S2-AAI, S8-DC și S9-ND). Aceste rezultate indică o relativă omogenitate a răspunsului respirator în condiții de repaus, reflectând cerințele metabolice scăzute și variabilitatea fiziologică redusă a subiecților.

În ultimul scenariu experimental (SC5), ce presupune un efort de intensitate scăzută (mers lejer), frecvența respiratorie prezintă o diminuare față de valorile înregistrate în SC4, însă rămâne semnificativ mai ridicată decât în scenariile statice. Majoritatea participanților prezintă valori situate în intervalul 28–32 rpm, cu exemple notabile precum 32 rpm la subiectul S9-MD și 31 rpm la subiectul S7-VI. Aceste rezultate subliniază faptul că și activitățile fizice cu intensitate redusă implică o solicitare metabolică suficientă pentru a menține ventilația pulmonară peste nivelul bazal, adaptare necesară satisfacerii cerințelor energetice și a consumului crescut de oxigen.




Figura 4.5 Evoluția frecvenței respiratorii individual pe subiecți în timpul scenariilor (calculat din datele achiziționate de la nodul NMRR ca media a celor 2 metode de determinare în domeniul timp și în domeniul frecvență)

Figura 4.6 ilustrează evoluția individuală a nivelului conductanței pielii (SCL) pe parcursul celor cinci scenarii de efort, evidențiind variații substanțiale atât între subiecți, cât și în cadrul diferitelor situații de solicitare fizică.

În scenariul inițial (SC1), caracterizat prin repaus total, valorile SCL sunt relativ reduse, oscilând în jurul valorilor joase pentru majoritatea subiecților (de exemplu, S1-AA: 1,8 μ S, S4-AI: 1,8 μ S, S8-DC: 3,4 μ S). Acest nivel scăzut reflectă activitatea simpatică minimă specifică stării de repaus.

În final, SC5 implică mersul lejer, unde valorile conductanței pielii scad în comparație cu SC4, dar rămân peste cele din scenariile inițiale cu solicitare minimă. Astfel, subiecții prezintă valori intermediare, cum ar fi 4,3 μ S la S7-VI și 3,5 μ S la S8-ND, indicând că, deși solicitarea fizică a scăzut față de alergare, activarea simpatică rămâne semnificativă.




Figura 4.6 Evoluția nivelului conductanței pielii (SCL) individual pe subiecți în timpul scenariilor

4.3 Model bazat pe învățare profundă multivariată pentru recunoașterea activităților umane

Clasificarea activităților umane bazate pe date semnale fiziologice (ex. poziție *stat în picioare* vs *stat pe scaun*, mers, alergare etc.) este o problemă centrală în recunoașterea activităților umane (HAR – *Human Activity Recognition*). Abordările tradiționale folosesc adesea modele de rețele neurale adânci precum rețele neuronale convoluționale multicanal (CNN) sau rețele de tip LSTM (pentru captarea dependențelor temporale) pentru a învăța automat caracteristici din semnalele senzorilor portabili.

4.3.1 Arhitectura modelului

Arhitectura modelului propus folosește un model Transformer multivariat, conform descrierii din Figura 4.7, care primește în total treisprezece fluxuri de date: ECG, semnal PPG în spectrul verde, RGP, respirație, PPG în infraroșu, PPG în roșu, temperatură corporală, accelerație pe trei axe și giroscop pe trei axe. Fiecare dintre aceste fluxuri este ulterior împărțit în ferestre unidimensionale de lungime fixă, pentru a facilita prelucrarea și analiza ulterioară.

Ulterior fiecărui flux de intrare i se asociază un codificator individual (*encoder-embedded*), realizat printr-un strat liniar (*Linear*) cu 256 de neuroni la ieșire, o funcție de activare *ReLU* și un mecanism de reglare a coeficientul de abandon (*Dropout*) cu rata de 0,2. Dimensiunea de 256 reprezintă un compromis între nevoia de a surprinde diversitatea semnalelor și cerința de a menține un număr de parametri rezonabil, evitând supraîncărcarea memoriei și un timp excesiv de antrenare. Fiecare fereastră senzorială este proiectată astfel într-un vector latent de 256, rezultând 13 reprezentări intermediare. Pentru a evidenția identitatea fiecărui senzor și a oferi o pseudo-codificare a „poziției” lor, se adaugă o componentă de antrenare la nivel de canal senzorial, numită codificare pozițională (*positional encoding*).

Partea principală a modelului reprezentată printr-un codificator Transformer (*encoder*) constă în 4 straturi repetate, aspect care asigură o profunzime suficientă pentru a învăța relații complexe între cele 13 intrări senzoriale, fără a extinde exagerat durata de antrenare și fără a crește semnificativ riscul de supraantrenare. În fiecare dintre aceste straturi se regăsește un mecanism de atenție cu cate 8 capete (*Multi-Head*) și un bloc intern de propagare directă (*Feed-Forward*), însoțite de conexiuni reziduale și de un strat de normalizare.

Opțiunea pentru 8 capete de atenție permite exploatarea mai multor „perspective” în procesul de auto-atenție (*self-attention*), fiecare captând tipare și corelații diferite ale semnalelor senzoriale. Acest mecanism pluralist de atenție sporește capacitatea modelului de a integra informații complementare între fluxurile de date fiziologice și de mișcare, maximizând astfel potențialul de fuziune multivariată.

Pentru clasificare, se aplică o operație de mediere pe axa senzorială, conducând la un vector care trece printr-un strat liniar (*Linear*), reducând dimensiunea la cinci neuroni de ieșire, corespunzător celor cinci clase de activitate sau postură. Antrenarea se desfășoară utilizând funcția de cost entropie încrucișată (*CrossEntropyLoss*) și algoritmul de optimizare AdamW (AdamW), cu o rată de învățare inițială de $5e-4$ și o penalizare a ponderilor (*weight decay*) de $1e-4$. Algoritmul de optimizare Adam (Estimare Adaptivă a Momentelor – *Adaptive Moment Estimation*) a fost ales datorită capacității sale de

a ajusta dinamic pasul de învățare pentru fiecare parametru al rețelei, pe baza valorilor curente și trecute ale gradientului. Această caracteristică îmbină avantajele oferite de metodele bazate pe impuls (*Momentum*) și RMSProp, rezultând într-o convergență mai stabilă și mai rapidă în situațiile în care datele prezintă o variabilitate ridicată. În plus, varianta AdamW (AdamW) remediază problemele de reglare L2 prezente în algoritmul Adam tradițional, gestionând penalizarea L2 (*weight decay*) într-un mod care evită acumularea continuă a penalizării pe toată durata antrenării.




Figura 4.7 Diagrama logică a modelului Transformer propus

4.3.2 Performanțele modelului

Figura 4.8 prezintă matricea de confuzie aferentă evaluării modelului propus de clasificare a activităților în cadrul unui set de date ce cuprinde cinci clase experimentale: poziție ortostatică, poziție așezată, decubit dorsal, mers și alergare. Această reprezentare bidimensională permite examinarea distribuției predicțiilor în raport cu valorile de referință, oferind o perspectivă detaliată asupra capacității de discriminare a modelului și a tipologiei erorilor comise.

Distribuția valorilor pe diagonala principală indică o corespondență ridicată între predicțiile modelului și etichetele reale. Se remarcă performanța optimă pentru clasa asociată decubitului dorsal, pentru care toate cele 13 observații au fost corect clasificate. Această fidelitate decizională reflectă un grad înalt de separare în spațiul trăsăturilor extrase, probabil susținut de absența variațiilor dinamice și de specificitatea semnalului aferent acestei stări.

În ceea ce privește erorile de clasificare, matricea evidențiază o singură abatere de la comportamentul ideal: o instanță corespunzătoare scenariului de mers a fost clasificată eronat drept scenariu de alergare. Această eroare punctuală, localizată în proximitatea diagonală, este explicabilă prin similitudinile biomecanice și de ritm dintre cele două activități, ambele caracterizate de secvențe ciclice ale mișcării membrelor inferioare. Importanța acestei confuzii este minoră, întrucât nu se observă redistribuiri semnificative ale predicțiilor în afara acestei relații funcționale.

În ansamblu, configurația matricei de confuzie sugerează un comportament algoritmic coerent și stabil, caracterizat prin precizie ridicată și capacitate de generalizare eficientă. Localizarea erorii într-un domeniu funcțional previzibil întărește ideea că modelul a atins un nivel de maturitate decizională suficient pentru aplicații în contextul recunoașterii automate a activităților umane.




Figura 4.8 Matricea de confuzie a modelului *Transformer* pentru determinarea scenariilor de activitate

Modelul *Transformer* multivariat prezintă performanțe de excepție (Figura 4.9 și Figura 4.10), atingând o precizie finală de 99,32% pe setul de antrenare și 99% pe setul de test. Pe setul de antrenare,

scenariile „stat pe scaun”, „stat orizontal” și „mers” înregistrează precizie, sensibilitate și scor F1 de ~0.99, în timp ce pentru „stat în picioare” și „alergare” scorul F1 este de 0,98, menținând totuși un nivel excelent de clasificare. Precizia globală se situează la 0,99, iar valorile „macro avg” și „weighted avg” pentru precizie, sensibilitate și scorul F1 se mențin și ele la 0,99. Pe setul de test, toate activitățile obțin precizie, sensibilitate și scor F1 de 1,00, indicând o separare perfectă a claselor și o acuratețe globală de 0,99.




Figura 4.9 Raportul de clasificare al modelului *Transformer* aplicat primilor 6 subiecți




Figura 4.10 Raportul de clasificare al modelului *Transformer* aplicat următorilor 7 subiecți

Performanță

Modelul propus în această lucrare a fost proiectat pentru a integra, într-un mod coerent, informația provenită din 13 fluxuri de date înregistrate simultan, fiecare flux corespunzând unui parametru fiziologic sau cinetic (precum electrocardiograma, respirația, accelerațiile pe trei axe, mișcările de rotație sau variațiile termice). Arhitectura a fost structurată pe un ansamblu de codificatoare specializate, câte unul pentru fiecare flux de date, urmate de un model Transformer configurat pentru a surprinde atât relațiile de timp interne fiecărui flux, cât și interdependențele dintre acestea. Conform valorilor prezentate în prima linie din **Error! Reference source not found.**, modelul obține o acuratețe de 99,0%, o sensibilitate de 99,0% și un scor F1 macro de 99,0%, depășind toate celelalte modele analizate în comparația de performanță.

Complexitatea computațională

În ceea ce privește complexitatea computațională a modelelor analizate, evaluarea numărului total de parametri reflectă clar variațiile semnificative în cerințele de resurse, influențând direct scalabilitatea și fezabilitatea implementării lor practice în scenarii reale.

Arhitectura modelului Transformer, include multiple codificatoare și straturi de atenție, conducând la o complexitate computațională semnificativă. Din perspectiva numărului de parametri, arhitectura prezintă aproximativ **6,15 milioane de parametri**, dintre care în jur de 3 milioane sunt alocați celor 13 codificatoare senzoriale (*encoders*), fiecare incluzând o proiecție liniară (*linear projection*) de tip 900×256 , la care se adaugă 256 de parametri de tip deplasare (*bias*). Restul de circa 3,15 milioane de parametri revin straturilor de tip *Transformer*, având dimensiunea modelului de 256 și 4 straturi, în care mecanismul de atenției cu mai multe capete (*multi-head self-attention*) și rețelele de propagare directă (*feed-forward networks*) generează un cost computațional ridicat, menținând totodată o latență (*latency*) relativ scăzută prin aplicarea auto-atenției (*auto-attention*) doar asupra celor 13 fluxuri de date (*tokens*).

Concluzii generale, contribuții și perspective de dezvoltare

În cadrul **primului capitol** s-au evidențiat aspectele esențiale ale achiziției și prelucrării indicatorilor fiziologici, punând-se accent pe evoluția tehnologică și diversitatea metodelor disponibile. S-au abordat diverse categorii de senzori destinați măsurării mai multor indicatori fiziologici (ECG, PPG, RGP, respirație și temperatură), integrați atât în sisteme portabile, cât și clinice. De asemenea s-au prezentând tehnici clasice de filtrare și segmentare, completate de metode avansate (transformate Wavelet, algoritmi de detecție a caracteristicilor, analiză neliniară) care permit extragerea fiabilă a parametrilor esențiali pentru diagnostic și monitorizare. În concluzie, capitolul subliniază convergența progreselor hardware (miniaturizare și optimizare a senzorilor) cu inovațiile software (filtrare adaptivă, inteligență artificială), dovedind potențialul ridicat al sistemelor de monitorizare a mai multor parametri în evaluarea complexă a pacienților. Totodată, este evidențiată necesitatea continuării cercetărilor pentru a gestiona mai eficient zgomotul și artefactele, precum și pentru a facilita accesul larg la soluții de monitorizare în practica medicală.

În Capitolul 2 s-a prezentat un sistem experimental de tip IoMT, construit pe o arhitectură distribuită, în care fiecare nod de monitorizare a fost proiectat pentru a achiziționa, filtra și transmite în timp real datele fiziologice, diminuând astfel necesitatea recurgerii la conexiuni prin cabluri și la configurații complexe. Fiecare nod, de la ECG și PPG până la răspuns galvanic al pielii, temperatură, respirație și postură, integrează o platformă ESP32 și circuite specializate de condiționare analogică, astfel încât preprocesarea să se realizeze local înainte de a fi transmisă către un server de achiziție. Datorită acestei abordări, sistemul se remarcă printr-un grad ridicat de scalabilitate și flexibilitate, putând fi integrate noduri noi fără a aduce modificări majore arhitecturii sistemului.

În plus, sincronizarea de timp între noduri este asigurată prin protocolul SNTP, oferindu-se o precizie de ordinul milisecundelor, suficientă pentru corelarea coerentă a datelor de la diverse surse (ECG, PPG, RGP etc.). De asemenea, este gestionată cu atenție conectivitatea wireless, fie prin TCP/IP (pentru ECG, PPG, RGP și nodurile de postură), fie prin Bluetooth LE (pentru monitorizarea respirației), subliniind capacitatea platformei de a integra diverse protocoale de comunicație.

Un alt aspect important îl reprezintă folosirea unui model producător–consumator în gestionarea fluxului de date la nivelul platformei ESP32. Implementarea freeRTOS pe fiecare nod oferă control strict asupra priorităților sarcinilor de conversie și de transmitere, împiedicând în acest fel pierderea datelor în cazul suprapunerii traficului Wi-Fi cu eșantionarea. În pofida surselor potențiale de interferențe, bruiaje electromagnetice, rezoluția convertoarelor analog-numerice și contactul imperfect cu pielea, erorile observate la nodurile ECG, PPG și RGP se încadrează în

intervalul 1–5%, în timp ce la postura corpului ating 7–10%, valori acceptabile pentru monitorizarea prelungită neinvazivă.

Utilizarea fișierelor CSV ca format standard pentru stocarea datelor facilitează integrarea ulterioară cu instrumente de analiză mai avansate, inclusiv implementări în cloud pentru detectarea automată a anomaliilor. Prin corelarea datelor PPG, ECG și RGP cu parametri care descriu respirația și postura, sistemul se pretează unor aplicații extinse în telemedicină, de la diagnostic timpuriu până la supravegherea pacienților cu afecțiuni cronice sau urmărirea reacțiilor fiziologice în studii de cercetare clinică. În plus, alimentarea nodurilor cu baterii Li-Po 3,7 V și utilizarea unor strategii inteligente de reglare a ratelor de eșantionare măresc mobilitatea și autonomia, menținând în același timp integritatea fluxului de date în situații cu acces limitat la surse de alimentare.

Prin urmare, sistemul IoMT descris în acest capitol oferă un cadru robust pentru dezvoltări ulterioare în domeniul ingineriei biomedicale, permițând o monitorizare continuă, flexibilă și cu un nivel satisfăcător de fiabilitate.

Capitolul 3 oferă o perspectivă amplă asupra felului în care variază parametrii fiziologici în raport cu postura corpului și gradul de efort, prezentând atât detalii despre protocolul experimental, cât și despre modul efectiv în care semnalele au fost colectate și comparate. Au fost înregistrate evoluții semnificative ale indicatorilor cardiaci (ECG, PPG), respiratorii (frecvența și amplitudinea respirației), termici (temperatura corporală) și electrodermali (răspuns galvanic al pielii), completate de date despre postura corpului (accelerometru și giroscop) pe parcursul a cinci scenarii (repaus, ortostatism, poziție șezând, alergare ușoară și mers lejer).

Din analiza rezultatelor, se observă că tranzițiile dintre posturi și activități alterează substanțial dinamica semnalelor. În cazul indicatorului ECG, de pildă, amplitudinea complexelor QRS și distanțele RR se modifică atât la simpla ridicare în picioare (ortostatism), cât și la exercițiile de alergare moderată, evidențiind creșterea frecvenței cardiace și a variabilității ritmului. Similar, semnalul PPG înregistrează atât o creștere a frecvenței pulsului, cât și o scădere a amplitudinii în condiții de efort, fapt asociat adaptărilor vasculare și unei creșteri a zgomotului de mișcare. De remarcat este diferența dintre PPG la încheietură și PPG la deget: la nivelul degetului, semnalul tinde să fie mai clar în absența mișcării, însă devine sensibil la artefacte puternice în scenariile dinamice, când contactul senzorului se modifică frecvent.

Răspunsul galvanic al pielii (RGP) dezvăluie o intensificare a activității simpatice în scenariile de efort, unde amplitudinile cresc, iar variațiile apar mai frecvent, reflectând atât cerințele de termoreglare, cât și posibile reacții emoționale asociate acțiunii. Măsurătorile de temperatură (luate la nivelul încheieturii) pun în evidență atât factori interni, precum creșterea metabolismului în timpul efortului, cât și factori externi legați de mișcarea senzorului și de circulația sângelui în zone periferice, în special la schimbarea posturii din șezut în ortostatism. Parametrii respiratorii, măsurați cu ajutorul centurii elastice, confirmă o ventilație mai intensă în situațiile de efort și o frecvență mai stabilă în pozițiile sedentare, cum ar fi statul pe scaun sau întins.

Comparația subiecților S5-DI și S7-VI evidențiază diferențe individuale notabile. De exemplu, subiectul S5-DI afișează valori ECG cu amplitudini mai reduse, dar reacționează mai rapid la efort, ceea ce se vede într-o accelerare mai mare a ritmului cardiac și în creșterea variabilității PPG. Subiectul S7-VI prezintă amplitudini QRS mai mari, însă tranzițiile dintre poziții produc schimbări mai lente de frecvență cardiacă și de amplitudine PPG, posibil datorate atât masei corporale, cât și altor factori fiziologici (vârstă, nivel de efort fizic). În plus, răspunsul galvanic al pielii poate fi în mod evident superior la unul dintre cei doi, semn al unui tonus simpatic mai ridicat, fapt care nu se poate deduce doar din semnalele cardiace.

Postura corpului, monitorizată prin accelerometru și giroscop, prezintă oscilații minime în repaus și poziții sedentare, însă se remarcă variații ample în alergare și mers, corelate cu frecvența pașilor și cu rotațiile de trunchi. Aceste date sunt relevante nu doar pentru observarea corectă a momentelor de efort, ci și pentru separarea artefactelor de mișcare din semnalele PPG sau ECG, întrucât permite identificarea perioadelor de agitație motorie.

Concluziile evidențiază importanța analizei multiplilor parametri și a unei interpretări personalizate a datelor, având în vedere că fiecare subiect răspunde într-un mod caracteristic la modificările de postură și nivel de efort. În plus, rezultatele sugerează necesitatea unor metode de filtrare și preprocesare diferențiate, care să reducă impactul artefactelor de mișcare, mai ales în condițiile de efort moderat spre intens.

Capitolul 4 include descrierea completă a fluxului de prelucrare și analiză aplicat indicatorilor fiziologici, evidențiind atât etapele cheie de filtrare și detecție, cât și noutățile referitoare la dezvoltarea unui model neuronal de tip *Transformer* pentru identificarea activităților umane bazat pe 13 fluxuri de intrare ce includ atât indicatori fiziologici cât și indicatori de mișcare. În prima fază, sunt prezentate principiile și algoritmii care stau la baza separării și corectării componentelor semnalelor ECG, PPG, RGP și respirator, subliniindu-se în mod special importanța filtrării bidirecționale de tip Butterworth (pentru menținerea fazei semnalului) și a metodelor bazate pe transformate Wavelet (pentru identificarea precisă a evenimentelor, precum vârfurile RR din ECG sau maximul sistolic din PPG). Se arată astfel cum pot fi obținute rezultate robuste chiar și în prezența artefactelor de mișcare și a bruiajelor electromagnetice, fapt esențial pentru monitorizarea subiecților în scenarii dinamice.

Pentru semnalul ECG, capitolul ilustrează, pas cu pas, detecția undelor P, QRS și T, analiza intervalelor (PR, QRS, QT) și calculele variabilității ritmului cardiac (VRC) în domeniul timp și frecvență. De asemenea, se explică modalitatea de estimare a frecvenței respiratorii prin aritmie sinusală respiratorie, oferind argumente pentru folosirea complementară a semnalelor PPG sau centurii toracice. În cazul fotopletismogramei (PPG), sunt detaliate tehnicile de extragere a vârfurilor sistolice și, acolo unde se poate, a incizurii dicrote, astfel se prezintă metodele de normalizare și de analiză a morfologiei undelor, accentuând că PPG se dovedește o sursă practică pentru frecvența cardiacă, dar necesită prelucrări suplimentare atunci când subiectul efectuează mișcări ample. Pentru răspunsul galvanic al pielii (RGP), capitolul demonstrează că separarea componentei tonice (SCL) de cea fazică (SCR) este crucială pentru interpretarea fenomenelor de

reglare simpatică și a răspunsurilor emoționale sau termoreglatoare, iar combinația cu tehnici neliniare (entropie, de exemplu) furnizează parametri suplimentari.

Analiza comparativă între metodele de calcul în domeniul timp și în domeniul frecvență, pentru ritmul cardiac și frecvența respiratorie, arată mici discrepante doar la tranzițiile bruște de efort, confirmând că prelucrarea robustă a fiecărui semnal și ulterior integrarea printr-o rețea de atenție acoperă majoritatea artefactelor.

În a doua parte, lucrarea introduce o noutate metodologică: un model Transformer multivariat, antrenat pentru recunoașterea activităților umane pe baza fuziunii multiplelor fluxuri de date provenite de la indicatori fiziologici. Spre deosebire de abordările tradiționale, în care modele CNN sau LSTM procesează toate canalele într-o manieră unitară, modelul de față alocă fiecărui flux de date (ECG, PPG, RGP, respirație, accelerometru, giroscop) un codificator dedicat. Această arhitectură permite captarea diferențelor de natură și de frecvență între semnale, înainte de a le integra prin mecanismele de atenție (*multi-head attention*). În plus, implementarea unei codificări poziționale învățate (*learnable position encoding*) oferă flexibilitate la variațiile de timp și la potențialele diferențe de latență dintre fluxurile de date, fapt rar întâlnit în recunoașterea activităților umane, unde de obicei se aplică doar concatenări brute de date.

Testele efectuate confirmă că, prin această strategie, se obțin performanțe excepționale, cu confuzii minime între clasele de activitate în scenariile experimentale analizate (repaus, ortostatism, poziție șezând, alergare și mers). Modelul Transformer multivariat a atins o precizie globală de ~99%, depășind astfel standardele cunoscute în literatura de specialitate. În plus, matricea de confuzie indică erori minime, ceea ce demonstrează atât utilitatea fuziunii multivariată, cât și relevanța etapelor de filtrare și preprocesare descrise în prima parte a capitolului.

În concluzie **capitolul 4** dovedește avantajele combinației dintre filtrarea avansată, detecția detaliată a parametrilor (ECG, PPG, RGP, respirație) și modelul Transformer multivariat, care introduce un codificator separat pentru fiecare flux și un mecanism de atenție menite să fuzioneze datele. Acest mod de abordare depășește limitările modelelor anterioare bazate pe CNN și LSTM, fiind în același timp mai compact și mai ușor de antrenat comparativ cu arhitecturi clasice de tip Transformer. Rezultatele extrem de bune în recunoașterea activităților confirmă potențialul acestor tehnici în aplicații de telemedicină, sport sau monitorizare a pacienților, într-un mediu în care subiecții se mișcă și își schimbă periodic activitățile. În plus, precizia ridicată la identificarea scenariilor susține fiabilitatea și versatilitatea modelului neuronal, subliniind că atunci când etapele inițiale de filtrare și segmentare sunt corect adaptate fiecărui semnal, analiza de tip deep learning poate genera concluzii solide și potențial generalizabile.

Contribuții personale ale autorului

- Proiectarea, realizarea practică și testarea unui sistem de tip Internet of Medical Things (IoMT) modular, în care fiecare nod de monitorizare (ECG, PPG, RGP, temperatură, accelerometru, giroscop, respirație) utilizează o unitate de calcul și circuite de condiționare specializate, integrate într-o arhitectură distribuită. Câteva dintre trăsăturile notabile ale sistemului sunt:
 - o Configurarea nodurilor ca entități autonome, care preprocesează local semnalele și transmit datele prin Wi-Fi către un server central, optimizează consumul energetic, extinde durata de viață a bateriilor și facilitează monitorizarea continuă, pe termen lung, în aplicații de telemedicină sau de cercetare.
 - o Sincronizarea nodurilor prin protocolul SNTP (Simple Network Time Protocol) și stocarea unificată a datelor în fișiere CSV permit atât o corelare precisă a parametrilor fiziologici în condiții dinamice, cât și o interfață grafică interactivă pentru vizualizarea în timp real a semnalelor și evaluarea rapidă a calității măsurărilor.
- Conceperea unui flux unitar de prelucrare a semnalelor fiziologice (ECG, PPG, RGP și ritm respirator), în care fiecare tip de semnal beneficiază de filtre și proceduri de detecție specializate, fără a recurge la algoritmi generaliști, asigurând obținerea de rezultate robuste în prezența zgomotului, a artefactelor de mișcare și a diferențelor de latență.
- Comparația sistematică între metodele de estimare a frecvenței cardiace și respiratorii (în domeniul timp vs. domeniul frecvență), validată cu semnale de referință (ECG vs. PPG, centură respiratorie vs. aritmie sinusală). Rezultatele relevă convergența celor două metodologii și argumentează necesitatea unei analize diferențiate la tranzițiile bruște de efort.
- Integrarea și adaptarea bibliotecilor Python (scipy, NeuroKit2, hrvanalysis) pentru extragerea parametrilor morfologici avansați (simetria undei T, amplitudini PPG, separarea în componenta tonică/fazică a răspunsului galvanic, estimarea indirectă a respirației) într-un cadru experimental unificat, care a simplificat analiza de parametri multipli și a crescut nivelul de reproductibilitate.
- Aplicarea pentru datele experimentale colectate cu sistemul realizat a unui model de inteligență artificială de tip *Transformer multivariat* cu codificare pozițională învățată (learnable position encoding), ce oferă un grad suplimentar de flexibilitate în sincronizarea datelor, aspect rar întâlnit în recunoașterea activităților umane bazată pe indicatori fiziologici și de mișcare. Această soluție permite integrarea coerentă a fluxurilor și corectarea eventualelor decalaje de timp, contribuind la obținerea unei acurateți ridicate.
- Separarea și codificarea dedicată a fiecărui flux de date a arhitecturii Transformer dezvoltate, reprezintă de asemenea abordare originală, prin care, în locul unei rețele unificate pentru toate datele, se alocă un codificator integrat (encoder) specializat fiecărui flux de date (ECG, PPG, RGP, respirație, accelerometru, giroscop). Astfel, sunt exploatate

particularitățile semnalelor încă din stadiu incipient, prevenind pierderea informațiilor caracteristice fiecărui flux de date.

- Fuziunea prin utilizarea unui mecanism de atenție cu mai multe capete (*Multi-Head*) a informațiilor provenite atât din indicatorii fiziologici, cât și din senzorii de mișcare, metodă ce evidențiază capacitatea de a detecta corelații subtile între parametrii cardiaci, răspunsul galvanic, respirație și postură. Astfel, se pot elimina confuziile între scenarii aparent similare (de pildă, stat în picioare vs. stat pe scaun), iar scenariile dinamice (alergare, mers) pot fi segmentate fără erori.
- Reducerea complexității, în raport cu modelele clasice de tip CNN+LSTM (care pot atinge 20–30 de milioane de parametri), prin introducerea unui Transformer cu aproximativ 6 milioane de parametri, dar cu atenție distinctă pe fiecare flux senzorial, îmbunătățește viteza de antrenare și stabilitatea.
- Precizia globală se situează la 0,99, iar valorile „*macro avg*” și „*weighted avg*” pentru precizie, sensibilitate și scorul F1 se mențin și ele la 0,99. Pe setul de test, toate activitățile obțin precizie, sensibilitate și scor F1 de 1,00, indicând o separare perfectă a claselor și o acuratețe globală de 0,99.

Perspective de dezvoltare viitoare

- Integrarea unui set mai larg de noduri de monitorizare a indicatorilor fiziologici (EEG, EMG, senzori biochimici) pentru a surprinde procese neurologice, metabolice sau musculare și a extinde aplicabilitatea sistemului la afecțiuni complexe (boli degenerative, tulburări de somn, afecțiuni cardiovasculare severe).
- Dezvoltarea unor metode de prelucrare hibridă local–cloud care să combine microcontrolere avansate (edge computing) cu infrastructuri de tip cloud, permițând analize complexe în timp real și păstrarea unui istoric al parametrilor, utilă pentru studii longitudinale și comparații inter-pacienți.
- Implementarea mecanismelor de auto-calibrare și diagnoză a senzorilor, astfel încât sistemul să poată sesiza în mod autonom situații precum desprinderea electrozilor, uzura contactelor sau variațiile termice, emițând alerte sau ajustând parametrii de filtrare pentru menținerea acurateței datelor.
- Crearea unor algoritmi de detecție a anomaliilor și alertare timpurie (de tip detecție a anomaliilor), care să identifice posibile episoade patologice (scădere bruscă a SpO₂, aritmii cardiace, reacții stresante de intensitate ridicată) și să trimită notificări pacienților ori personalului medical, îmbunătățind îngrijirea preventivă.
- Adăugarea metodelor de filtrare adaptivă în funcție de context, unde parametrii de detecție și banda de frecvență să fie ajustați dinamic pe baza gradului de efort sau a tipului de mișcare, optimizând fiabilitatea detecției undelor ECG/PPG/RGP chiar în condiții de artefacte mari.
- Extinderea setului de date cu scop clinic și validarea modelului în parteneriate cu instituții medicale, pentru a demonstra utilitatea practică a sistemului în situații reale (diagnostic,

urmărirea pacienților cronici, reabilitare fizică) și a obține indicatori de performanță (sensibilitate, specificitate) în contextul unor afecțiuni variate.

- Aprofundarea fuziunii cu rețele neurale alternative (CNN+Transformer, Graph Neural Networks) și studierea comportamentului în scenarii de tip big data.
- Standardizarea și interoperabilitatea sistemului prin integrarea unor protocoale de date recunoscute la nivel internațional (HL7, FHIR), astfel încât informațiile colectate să poată fi transferate și utilizate în mod direct de aplicații medicale deja existente (sisteme EMR, telediagnostic), accelerând adoptarea clinică.
- Implementarea unor mecanisme inteligente de feedback (vibrații, semnale luminoase) pe noduri sau prin intermediul unei interfețe mobile, care să le ofere utilizatorilor alerte și sugestii personalizate (ex. ajustarea efortului, modificarea posturii), măbind gradul de conștientizare și prevenție.

Lista de lucrări publicate

- [1] I. A. Iftode și C. Foșalău, „Wavelet-based Techniques Applied to Digital Processing of ECG Signals,” *2020 International Conference and Exposition on Electrical And Power Engineering (EPE)*, pp. 419-424, 2020. (conferință indexată IEEE)
- [2] C. Foșalău, I. A. Iftode și C. Zet, „A New Respiratory Rate Sensing Principle Based on Magnetic Amorphous Wire Microtransformers,” *2021 International Conference on e-Health and Bioengineering (EHB)*, pp. 1-4, 2021. (conferință indexată WoS)
- [3] I. A. Iftode and C. Fosalau, "Extracting and Determining Respiratory Variation by Processing Force Sensor and PPG Data," *2022 International Conference and Exposition on Electrical And Power Engineering (EPE)*, pp. 063-066, 2022.
- [4] I. A. Iftode și C. Foșalău, „Review on microcontroller platforms and their applicability in IOT embedded systems,” *Buletinul Institutului Politehnic din Iasi, Sectia Electrotehnica, Energetica, Electronica*, 2022. (revistă indexată BDI Index Copernicus și Ulrich's)

Bibliografie selectivă

- [1] D. E. Becker, "Fundamentals of electrocardiography interpretation," *Anesth Prog.*, vol. 53, no. 2, pp. 53-63, 2006.
- [2] Allen J., "Photoplethysmography (PPG) and its various applications in clinical physiological measurement," *Physiological Measurement*, vol. 28, no. 3, pp. R1-R39, 2007.
- [3] M. Sharma, S. Kacker and M. Sharma, "A Brief Introduction and Review on Galvanic Skin Response," *International Journal of Medical Research Professionals*, vol. 2, no. 6, pp. 13-15, 2016.
- [4] J. B. West, *Respiratory Physiology: The Essentials*, Lippincott Williams & Wilkins, 2012.
- [5] "ADS129x Low-Power, 8-Channel, 24-Bit Analog Front-End for Biopotential Measurements Datasheet," 2015. [Online]. Available: <https://www.ti.com/lit/ds/symlink/ads1296r.pdf>.
- [6] M. Nardelli and R. Bailón, "Advances in Wearable Photoplethysmography Applications in Health Monitoring," *Sensors*, vol. 23, p. 7064, 2023.
- [7] T. Pereira, N. Tran, K. Gadhoumi, M. Pelter, D. Do, R. Lee, R. Colorado, K. Meisel and X. Hu, "Photoplethysmography based atrial fibrillation detection: a review," *npj Digital Medicine*, vol. 3, p. 3, 2020.
- [8] M.-Z. Poh, N. C. Swenson and R. W. Picard, "A Wearable Sensor for Unobtrusive, Long-Term Assessment of Electrodermal Activity," *IEEE Transactions on Biomedical Engineering*, vol. 57, pp. 1243-1252, 2010.
- [9] S. Liaqat, K. Dashtipour, A. Rizwan, M. Usman, S. A. Shah, K. Arshad, K. Assaleh and N. Ramzan, "Personalized wearable electrodermal sensing-based human skin hydration level," *Sensors*, vol. 12, no. 2045-2322, p. 3715, 2022.
- [10] W. Boucsein, *Electrodermal Activity*, Springer, 2012.
- [11] D. Caruelle, A. Gustafsson, P. Shams and L. Lervik-Olsen, "The use of electrodermal activity (EDA) measurement to understand consumer emotions—A literature review and a call for action," *Journal of Business Research*, vol. 104, pp. 146-160, 2019.
- [12] V. Randazzo, J. Ferretti and E. Pasero, "A Wearable Smart Device to Monitor Multiple Vital Parameters—VITAL ECG," *Electronics*, vol. 9, no. 2079-9292, p. 300, 2020.

- [13] P. S. Pandian, K. Mohanavelu, K. P. Safeer, T. M. Kotresh, D. T. Shakunthala, P. Gopal and V. C. Padaki, "Smart Vest: wearable multi-parameter remote physiological monitoring system," *Medical engineering & physics*, vol. 30, no. 1350-4533, pp. 466-77, 2008.
- [14] L. Sörnmo and P. Laguna, *Bioelectrical Signal Processing in Cardiac and Neurological Applications*, Elsevier, 2005.
- [15] I. A. Iftode and C. Fosalau, "Wavelet-based Techniques Applied to Digital Processing of ECG Signals," *2020 International Conference and Exposition on Electrical And Power Engineering (EPE)*, pp. 419-424, 2020.
- [16] J. Pan and W. J. Tompkins, "A Real-Time QRS Detection Algorithm," *IEEE Transactions on Biomedical Engineering*, Vols. BME-32, pp. 230-236, 1985.
- [17] M. Llamedo, J. P. Martínez and P. Laguna, "A multilead wavelet-based ECG delineator based on the RMS signal," *Computers in Cardiology*, pp. 153 - 156, 2006.
- [18] L. Cuiwei, Z. Chongxun and T. Changfeng, "Detection of ECG characteristic points using wavelet transforms," *IEEE Transactions on Biomedical Engineering*, vol. 42, pp. 21-28, 1995.
- [19] D. di Bernardo and A. Murray, "Explaining the T-wave shape in the ECG," *Nature*, vol. 403, p. 40, 2000.
- [20] A. Zohar and R. McCraty, "Personality and Heart Rate Variability: Exploring Pathways from Personality to Cardiac Coherence and Health," *Open Journal of Social Sciences*, vol. 1, pp. 32-39, 2013.
- [21] F. Shaffer and J. P. Ginsberg, "An Overview of Heart Rate Variability Metrics and Norms," *Frontiers in public health*, vol. 5, p. 258, 2017.
- [22] L. A. Lipsitz, F. Hashimoto, L. P. Lubowsky, J. Mietus, G. B. Moody, O. Appenzeller and A. L. Goldberger, "Heart rate and respiratory rhythm dynamics on ascent to high altitude," *British heart journal*, vol. 74, pp. 390-6, 1995.
- [23] O. F. C. van den Bosch, R. Alvarez-Jimenez, H.-J. de Grooth, A. R. J. Girbes and S. A. Loer, "Breathing variability—implications for anaesthesiology and intensive care," *Critical Care*, vol. 25, 2021.
- [24] I. R. Kleckner, J. B. Wormwood, R. M. Jones, E. Culakova, L. F. Barrett, C. Lord, K. S. Quigley and M. S. Goodwin, "Adaptive thresholding increases sensitivity to detect changes in the rate of skin conductance responses to psychologically arousing stimuli in both laboratory and ambulatory settings," *International journal of psychophysiology : official journal of the International Organization of Psychophysiology*, vol. 196, p. 112280, 2024.

- [25] G. Joyia, R. Liaqat, A. Farooq and S. Rehman, "Internet of Medical Things (IOMT): Applications, Benefits and Future Challenges in Healthcare Domain," *Journal of Communications*, vol. 12, pp. 240-247, 2017.
- [26] Analog Devices, "AD8232 - Single-Lead, Heart Rate Monitor Front End Datasheet," 2023. [Online]. Available: <https://www.analog.com/media/en/technical-documentation/data-sheets/ad8232.pdf>.
- [27] S. Electronics, "AD8232 Heart Rate Monitor Hookup Guide," SparkFun Electronics, 2024. [Online]. Available: <https://learn.sparkfun.com/tutorials/ad8232-heart-rate-monitor-hookup-guide>.
- [28] DFRobot, "Heart Rate Sensor - SEN0203," [Online]. Available: https://wiki.dfrobot.com/Heart_Rate_Sensor_SKU__SEN0203.
- [29] Vernier Software & Technology, "Go Direct® Respiration Belt," 2023. [Online]. Available: <https://www.vernier.com/product/go-direct-respiration-belt/>.
- [30] TDK InvenSense, "MPU-9250 - Nine-Axis (Gyro + Accelerometer + Compass) MEMS MotionTracking™ Device," [Online]. Available: <https://invensense.tdk.com/products/motion-tracking/9-axis/mpu-9250/>.