



BIMO

Sistem autonom bazat pe AI pentru monitorizarea semnalelor biologice și prevenirea stresului

PROIECT ȘTIINȚIFIC · ROBOTICĂ ȘI INTELIGENȚĂ ARTIFICIALĂ

AUTORI	COORDONATOR
Mititelu Dumitru-Teodor (elev) Hristea Darius (elev)	Prof. Vîrcolici Mihaela

AFILIERE

¹ Clasa a IX-a, Colegiul Tehnic „Dimitrie Ghika”, localitatea Comănești, județul Bacău

² Catedra de Informatică, Colegiul Tehnic „Dimitrie Ghika”, localitatea Comănești, județul Bacău Contact: bimo.assistant@gmail.com

90%	<200 ms	Edge AI
acuratețe pe date simulate și reale	timp de reacție	procesare locală



STRUCTURA LUCRĂRII

Cuprins

Secțiunile sunt ordonate conform structurii proiectului științific BIMO.

Rezumat	3
1. Introducere	3
2. Materiale și metode	4
2.1. Hardware și componente	4
2.2. Mediul software și programarea	4
2.3. Achiziția și procesarea semnalului cardiac	4
2.4. Antrenarea AI-ului și reacția robotului	5
3. Rezultate - evaluarea modelului multimodal	6
3. Rezultate - importanța caracteristicilor	7
4. Concluzii	8
Mulțumiri	9
Bibliografie	9

Rezumat

În acest proiect am analizat cum putem detecta și preveni stresul în mod automat, o problemă din ce în ce mai prezentă în viața de zi cu zi. Ca să trecem peste limitele aplicațiilor obișnuite care doar înregistrează date, am echipat robotul mobil Bimo cu senzori biologici pentru monitorizare în timp real. Am curățat datele de zgomotul cauzat de mișcare și am antrenat un algoritm de învățare automată adaptat să ruleze direct pe microcontroler, fără să depindă de internet. În urma testelor pe date simulate, sistemul a recunoscut semnele de stres cu o acuratețe de 90% și a reacționat pentru reducerea acestuia într-un timp de sub 200 de milisecunde. Rezultatele arată că un robot autonom cu procesare locală poate interveni rapid când apare stresul, garantând totodată intimitatea datelor utilizatorului.

CUVINTE-CHEIE

prevenirea stresului · învățare automată · robotică autonomă · procesare locală · senzori biologici

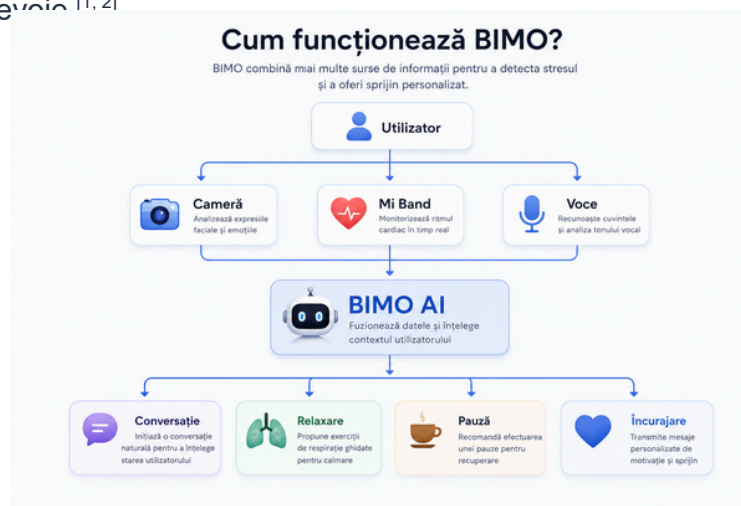
1. Introducere

Am vrut să realizăm un proiect care îmbină robotica și inteligența artificială cu o problemă reală de care ne lovim aproape zilnic: stresul. Analizând soluțiile existente pe piață, am observat că majoritatea gadgeturilor (cum sunt brățările sau ceasurile inteligente) sunt pur pasive. Ele doar înregistrează date, iar la finalul zilei îți arată un grafic și îți spun că ai fost stresat - lucru care nu te ajută prea mult atunci când ai nevoie de sprijin direct în momentul tensionat.

Problema pe care am vrut să o rezolvăm este lipsa unui sistem mobil și autonom capabil să citească semnalele corpului în timp real și să reacționeze pe loc, fără să depindă de conexiunea la internet sau de servere în cloud care pot încetini răspunsul și compromite intimitatea datelor.

Întrebarea noastră a fost: Poate o platformă robotică mobilă dotată cu senzori biologici să detecteze și să ajute la reducerea stresului direct la nivel local? Scopul lucrării este să dezvoltăm și să testăm robotul Bimo, un sistem pe care am integrat senzori de monitorizare și un algoritm de Machine Learning optimizat să ruleze direct pe microcontroler (Edge AI).

Ipoteza de la care am pornit este că procesarea datelor bio-fiziologice direct pe placă ne permite să identificăm stările timpurii de stres cu o acuratețe ridicată și cu o latență de sub 200 de milisecunde, demonstrând că un robot autonom poate interveni proactiv și util în mediul fizic exact când utilizatorul are mai mare nevoie [1, 2]



2. Materiale și metode

Pentru ca oricine să poată înțelege și reproduce proiectul nostru, am împărțit această secțiune în patru pași clari: hardware-ul utilizat, mediul software, modul în care am colectat și curățat datele biometrice, precum și integrarea modelului AI pe robotul Bimo.

2.1. Hardware și componente

Am ales o arhitectură bazată pe o putere mare de procesare locală și pe o conexiune fără fir cu senzorul biometric:

- Creierul robotului (Raspberry Pi 5): Am folosit un Raspberry Pi 5 datorită procesorului său puternic, ideal pentru a rula modele de Machine Learning direct pe robot (Edge AI), fără întârzieri și fără conexiune la internet. (Fig.4 și Fig.5)^[4, 5]
- Senzorul biometric (Xiaomi Mi Band 4): Am utilizat brățara fitness pentru a colecta în timp real datele despre ritmul cardiac și variabilitatea acestuia, comunicând direct cu Raspberry Pi 5 prin Bluetooth Low Energy (BLE).
- Actuatoare și expresivitate (servomotoare): În loc de afișaje luminoase, am dotat capul lui Bimo cu servomotoare. Acestea îi permit să execute animații fizice și mișcări expresive atunci când intervine pentru reducerea stresului. (Fig.3)

2.2. Mediul software și programarea

Pentru dezvoltarea sistemului am folosit exclusiv ecosistemul Python, rulat direct pe Raspberry Pi 5:

- Python 3: Limbajul principal în care am scris întreaga aplicație de pe robot.
- Biblioteci pentru date și AI (Scikit-Learn, NumPy, Pandas): Utilizate pentru procesarea semnalului cardiac, extragerea caracteristicilor și rularea modelului de învățare automată.^[3]
- Gestiunea Bluetooth și GPIO (bleak / RPi.GPIO): Module folosite pentru menținerea conexiunii Bluetooth cu Mi Band 4 și pentru trimiterea semnalelor PWM către servomotoarele capului.^[6]

2.3. Achiziția și procesarea semnalului cardiac

Datele transmise prin Bluetooth pot conține erori de transmisie sau zgomot cauzat de mișcarea mâinii. Pentru a obține date precise, am urmat trei etape:

- 1 Preluarea datelor prin Bluetooth: Raspberry Pi 5 citește valorile pulsului trimise de Xiaomi Mi Band 4.
- 2 Extragerea caracteristicilor: Din semnalul filtrat, am calculat indicatorii de variabilitate ai ritmului cardiac pe ferestre scurte de timp (valoarea medie a pulsului și schimbările rapide de ritm).^[1, 2]



Fig.2-Motor folosit de Bimo




Fig.3 Componente

2.4. Antrenarea AI-ului și reacția robotului

- Modelul de Machine Learning: Am antrenat un clasificator de tip RandomForest capabil să încadreze starea utilizatorului în două categorii: Calm (Normal) sau Stres.[3]
- Rularea locală (Edge AI): Pentru a proteja intimitatea datelor biometrice și pentru a asigura un răspuns rapid, modelul este încărcat și executat direct în memoria RAM a plăcii Raspberry Pi 5.[4, 5]
- Bucla de reacție și animația capului: Sistemul funcționează într-o buclă continuă. Când algoritmul clasifică starea drept Stres, Raspberry Pi trimite comenzi instantanee către servomotoare, iar Bimo execută o serie de animații mecano-robotice ale capului destinate interacțiunii și liniștirii utilizatorului și comunică cu utilizatorul.
- Măsurarea performanței: Am evaluat acuratețea modelului folosind o matrice de confuzie și am contorizat latența totală a sistemului (timpul scurs de la citirea pulsului până la declanșarea mișcării capului)(Fig.6).




Fig.5- Gâtul lui Bimo

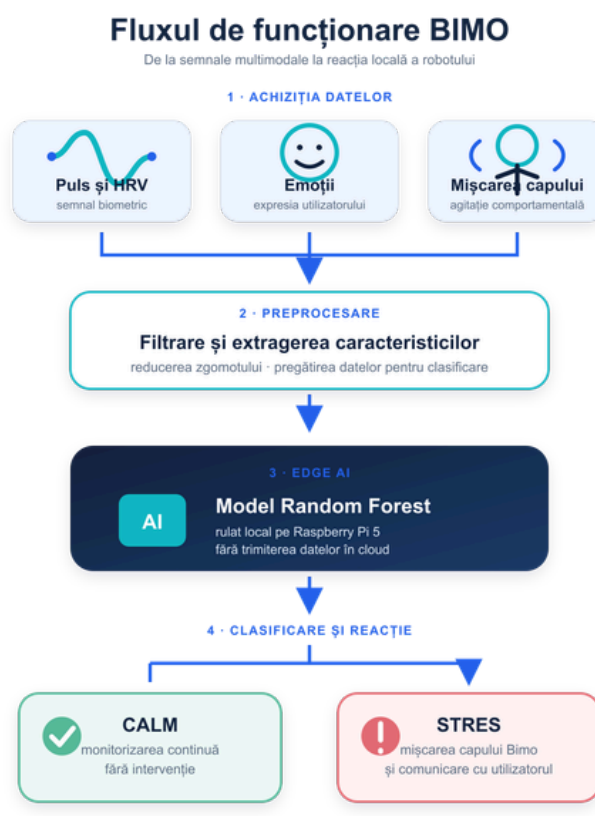


Fig.6-Flux de funcționare

3. Rezultate - evaluarea modelului multimodal

Evaluarea comparativă indică un scor F1 de 0,949 pentru modelul multimodal, față de 0,788 pentru modelul bazat doar pe emoții, 0,787 pentru combinația BPM + emoție și 0,737 pentru modelul bazat doar pe BPM.




Figura 7. Comparația scorurilor F1 pentru cele patru variante ale modelului BIMO.




Figura 8. Matricea de confuzie a modelului Random Forest multimodal: 337 și 666 clasificări corecte.

3. Rezultate - importanța caracteristicilor

Analiza importanței caracteristicilor arată că `head_agitation` are contribuția dominantă în model. Caracteristicile asociate emoțiilor și semnalului cardiac au contribuții mai mici, dar sunt integrate în clasificarea multimodală.




Figura 9. Importanța caracteristicilor utilizate de modelul multimodal.

OBSERVAȚIE

Rezultatele multimodale completează testele simulate descrise inițial în lucrare și permit compararea directă a variantelor de model.

4. Concluzii

- Modelul multimodal a obținut cel mai bun scor F1: 0,949.
- Matricea de confuzie arată 337 clasificări corecte pentru Non-stress și 666 pentru Stress; 38 și 34 de exemple au fost clasificate greșit.
- Caracteristica head_agitation are cea mai mare importanță în modelul multimodal.
- Combinarea informației despre mișcarea capului, emoții și semnalul cardiac oferă performanțe mai bune decât variantele evaluate separat.
- Procesarea locală rămâne importantă pentru un răspuns rapid și pentru protejarea datelor biometrice.

MODEL MULTIMODAL · F1 = 0,949

Semnale combinate pentru detectarea stresului și reacție locală

Mulțumiri

Mulțumim doamnei profesoare Vîrcolici Mihaela pentru coordonare și îndrumare, Colegiului Tehnic „Dimitrie Ghika” pentru susținerea proiectului și Centrului Medical Sanclinic pentru colaborarea și sprijinul oferit în procesul de colectare a datelor necesare antrenării modelului.

Bibliografie

- [1] Shaffer, F., Ginsberg, J.P., „An Overview of Heart Rate Variability Metrics and Norms”, *Frontiers in Public Health*, vol. 5, 2017, pp. 258-275.
- [2] Kim, H. G., Cheon, E. J., Bai, D. S., Lee, Y. H., Koo, B. H., „Stress and Heart Rate Variability: A Meta-Analysis”, *Psychiatry Investigation*, vol. 15, nr. 3, 2018, pp. 235-245.
- [3] Pedregosa, F. et al., „Scikit-learn: Machine Learning in Python”, *Journal of Machine Learning Research*, vol. 12, 2011, pp. 2825-2830.
- [4] Upton, E., Halfacree, G., *Raspberry Pi User Guide*, John Wiley & Sons, 2014.
- [5] Raspberry Pi Foundation, „Raspberry Pi 5 Hardware Documentation”, <https://www.raspberrypi.com/documentation/computers/raspberry-pi.html>, accesat la data de 05.08.2026.
- [6] Bleak Project, „Bleak: Bluetooth Low Energy Platform Agnostic Client for Python”, <https://bleak.readthedocs.io>, accesat la data de 05.08.2026.