

Raport final al grantului AT:

**Complex Bioinstrumental de Evaluare a Stării Biopsihice a
Persoanelor Care Desfășoară Activități Supuse la Stres**

Titular grant: Dobrea Dan Marius

1. Prezentare obiective an 2002 (contractul 33479/2002, tema 104, cod CNCSIS 67):

- *Realizare sistem virtual și eliminare artefacte*
- *Extragere parametri semnal*

2. Prezentare obiective an 2003 (contractul 33557/01.07.2003, tema 47, cod CNCSIS 75):

- *Determinarea metodologiei de punere in evidenta a stării de oboseala și analiza influentelor externe care pot apare.*
- *Construirea clasicatorului.*

Etapa 2002

1. *Realizare sistem virtual și eliminare artefacte*
2. *Extragere parametri semnal*

Această temă de cercetare, **rezolvată**, realizează, printr-o abordare interdisciplinară, două dispozitive de intrare a unui **complex bioinstrumental noncontact de determinarea stării de oboseală** a persoanelor care desfășoară activități supuse la stres. Aceste două dispozitive complexe au fiecare înglobate în ele înafara funcției de bază pe care trebuie să o îndeplinească, de achiziționare a semnal de tremur, mișcare și respirator, fără contact, module pentru înlăturarea artefactelor care perturbă în mod obișnuit orice tip de achiziție. Mai mult pentru pregătirea etapelor următoare s-a extras din semnalul de tremur acei parametri care vor fi utilizați în etapa de clasificare. Plecându-se de la spațiul de semnale, după extragerea caracteristicilor vom obține spațiul trăsăturilor unde un clasificator va determina existența sau nu a stării de oboseală a utilizatorului sistemului. Această temă de cercetare se află la intersecția mai multor domenii precum: realitatea virtuală, sistemele inteligente, algoritmi neconvenționali de calcul și prelucrare de semnale, tehnici de programare etc.

Cercetarea și-a propus să rezolve și a **rezolvat** următoarele obiective:

- creșterea sensibilității sensorului noncontact utilizat de ambele sisteme;
- eliminare artefacte de mișcare din semnalul respirator;
- perfecționare Joystick-ului virtual pentru obținerea unui semnal de tremur care să poată fi folosit pentru a discerne starea utilizatorului sistemului;
- extragere parametri din semnalul de tremur.

Această sinteză reprezintă un raport despre implementarea a două dispozitive de intrare noncontact cât și o parte din sistemul de clasificare (extragerea parametrilor), și **prezintă rezultatele obținute** cu aceste sisteme. Sunt prezentate soluțiile de realizare hard, soft (atât în Visual C++ și în C pentru DSP-uri), algoritmi selectați în versiunea finală cât și justificarea acestei alegeri printr-o comparație între soluțiile inițial candidate.

Senzorul

Modul de funcționare. Deoarece același senzor este folosit pentru ambele sisteme o scurtă prezentare a modului de lucru al acestuia se impune.

Senzorul este de tip rezonant [1], circuit LC (format din componentele 4 și 6, **Figura 1.**), este o spiră planară construită de o așa natură încât să maximizeze capacitatea și inductanța sa parazite. Aceste elemente parazite sunt sensibile la existența obiectelor din imediata proximitate fie că acestea sunt conductive, neconductive, magnetice sau nemagnetice. În acest mod impedanța sensorului este dependentă de obiectele din vecinătate. Pentru sesizarea modificărilor impedanței senzorul (5) este conectat într-o rețea divizoare, împreună cu un rezistor (2) iar ansamblul este excitat cu un semnal de înaltă frecvență (pentru senzorul respirator 16 MHz, iar în cazul Joystick-ului este compus dintr-un ansamblu de trei astfel de senzori, doi dintre ei cu dimensiuni identice, avem 18 MHz și 33 MHz). În momentul modificării impedanței sensorului rezonant, datorată schimbării configurației spațiale ale obiectelor, a mișcării acestora în imediata proximitate sensorului, tensiunea furnizată în punctul median al divizorului rezistiv își modifică valoarea. Repetitorul (7) are rolul de a minimiza încărcarea sensorului prin impedanța sa ridicată a intrării cât și prin capacitatea scăzută a acesteia. Detectorul de anvelopă (8) extrage valoarea medie a

tensiunii rezultate care este ulterior procesată în mod specific funcție de tipul dispozitivului care utilizează senzorul.

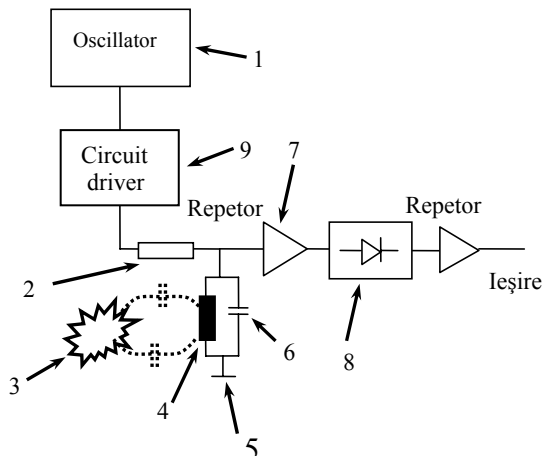


Figura 1. Schema bloc de principiu pentru interfațarea senzorului




Figura 2. Influența factorului de calitate asupra sensibilității senzorului

Creșterea sensibilității senzorului. Factorul de calitate Q al circuitului rezonant, cu frecvența de rezonanță F_R , este componenta cu influență esențială asupra sensibilității senzorului. În **Figura 2.** se prezintă efectul factorului de calitate Q al senzorului rezonant asupra variației impedanței. La frecvența de rezonanță F_R , identică în starea inițială cu frecvența F de excitație a senzorului, circuitul cu factorul de calitate, Q , cel mai ridicat (curba 1) are impedanța Z_{RH} iar cel de al doilea senzor are impedanța Z_{RL} . La apropierea unui obiect de senzor frecvența de rezonanță a acestuia se modifică datorită modificării capacității sau inductanței senzorului. În această situație frecvența de excitație a senzorilor F determină pentru senzorul cu factorul de calitate mai ridicat impedanța Z_H în timp ce senzorul cu pierderi mai mari va avea numai impedanța Z_L . Rezultatele diferențelor între grupurile de impedanțe Z_{RH} , Z_H și Z_{RL} , Z_L sunt net în avantajul senzorului cu factor de calitate ridicat obținându-se în mod respectiv și o variație superioară a tensiunii dată de divizorul rezistiv. În concluzie încărcarea dată de repetorul (7) (**Figura 1.**), modul de realizare fizică a sistemului (cablaj, conexiuni, etc.) influențează factorul de calitate și deci sensibilitatea senzorului.




Figura 3. Schema repetorului și a

Anterior repetorul (7) a fost un simplu etaj de tip colector comun. Chiar în situația în care se folosea un tranzistor cu factor de amplificare mare, rezistoarele care polarizau etajul scădeau impedanța de intrare a repetorului determinând simultan și scăderea factorului de calitate al sensorului. Ulterior s-a folosit configurația prezentată în **Figura 3**. În acest mod, în semnalul sensorului (modelat prin inductanța L și capacitatea C) este conectat direct în baza tranzistorului Q_5 . Rezistența cu care este “încărcat” sensorul de repetor:

$$r_{\pi Q5} + (\beta_{Q5} + 1) R_{echiv C}$$

nu mai este în paralel cu rezistoarele de polarizare a etajului (R_{11} și R_{12}). Chiar și în această situație în care se pot atinge impedanțe în jur de $1 \text{ M}\Omega$, se observă o creștere a sensibilității față de cazul repetorului pe emitor în configurația standard dar nu îndeajuns de mult. Aceasta se datorează parte și rezistenței de intrare a montajului, nu foarte mare, dar și încărcării capacitive a sensorului dată de capacitatea bază emitor a tranzistorului Q_5 în paralel cu capacitatea bază colector al aceluiași tranzistor. În pasul următor s-a încercat folosirea unui amplificator operațional în locul repetorului pe emitor, dar datorită frecvențelor mai de lucru, care ajung până la 33 MHz , puține amplificatoare operaționale pot lucra în acest montaj. Soluția adoptată are la bază amplificatorul operațional LT 1229 cu reacție pe curent care are o lățime de bandă de 100 MHz . Intrarea, conform foii de catalog [3], poate fi modelată cu un rezistor de $25 \text{ M}\Omega$ în paralel cu o capacitate de 3 pF . Încărcarea capacitivă redusă este de dorit deoarece în caz contrar nu numai se încarcă sensorul dar se micșorează semnificativ și sensibilitatea sensorului la obiecte dielectrice.




Figura 4. Prezentare sistem [5]

Joystick-ul virtual

Prezentarea sistemului. Față de prima realizare a sistemului [3], anterioară grantului, noul sistem se prezintă în două versiuni funcționale (prima capabilă să urmărească mișcarea mâinii în plan [4] în timp ce în cea de a doua versiune poate urmări un obiect în spațiul de intrare 3D [5]). În plus față de sistemul prezentat în [3] este posibilă achiziționarea simultană cu semnalul de mișcare și a semnalului de tremur.

Joystick-ul virtual este un ansamblu de trei senzori inductivi comandați de tot atâtea circuite interfațate cu un calculator personal prin intermediul unui DSP de tipul TMS320F240, **Figura 4**. În momentul în care mâna sau alt obiect este deasupra unuia dintre senzori semnalul generat de către sistemul corespondent va fi de amplitudine mare proporțional cu distanța dintre mână/obiect și senzor. Pentru a sesiza deplasarea mâinii în plan, de exemplu o mișcare stânga-dreapta, informația furnizată de un cuplu de doi astfel de senzori este utilizată pentru a evidenția această deplasare. Deoarece grupul de senzori este implicat în determinarea de distanțe în spațiul de intrare 3D cât și în achiziționarea semnalului de tremur suntem obligați să lucrăm în partea liniară a caracteristicii sensorului. Semnalul de mișcare achiziționat este transmis prin portul de Joystick către unitatea centrală în timp ce semnalul de tremur este transmis serial.

Sistemul de control al Joystic-ului și de achiziționare a semnalului de tremur. “Inima” întregului sistem de comanda (schema este prezentată în **anexa 1** iar realizarea practică în **Figura 5.**) este procesorul de semnal TMS320F240 care împreună cu circuitele anexe îndeplinește următoarele funcții: furnizează semnalul de tact pentru filtrele digitale (în acest mod se poate modifica dinamic frecvența de tăiere ale acestora furnizând o informație mai bogată sau mai săracă spectral convertoarelor), achiziționarea simultană (dar la frecvențe de eșantionare diferite) a semnalelor de tremur respectiv mișcare, extragerea informației de mișcare și poziție a obiectelor în




Figura 5. Circuitul de control al Joystic-ului virtual

spațiul 3D de intrare, comandă trei potențiometre digitale care furnizează calculatorului personal poziția mâinii în spațiul de intrare și transmite serial semnalul de tremur al mâinii achiziționat.

Achiziționarea semnalului de tremur se realizează cu un convertor extern conecta la DSP pe portul SPI. În sistemul care urmărea poziția mâinii în plan [4] achiziționarea semnalului de tremur se realiza cu ajutorul unuia dintre convertoarele interne DSP-ului dar datorită faptului că acest convertor este pe 10 biți informația neliniară, haotică existentă în semnalul de tremur era distrusă de zgomotul de cuantizare. Încercări de a rezolva această problemă prin amplificarea semnalului nu au funcționat deoarece se obținea automat și o reducere a domeniului din spațiu în care se putea achiziționa simultan semnalul de tremur cu cel de mișcare. Din acest motiv a fost necesar conectarea unui convertor extern pe 12 biți.

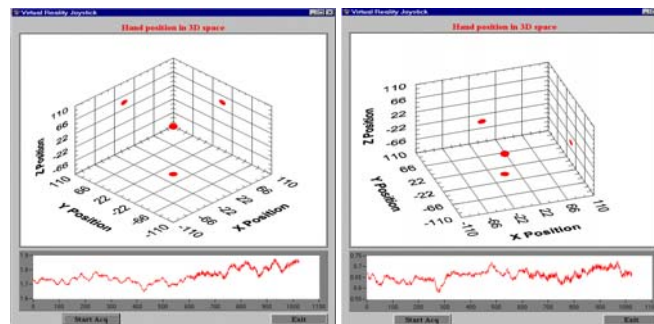


Figura 6. Prezentarea interfeței grafice a sistemului

Softul care afișează poziția mâinii în spațiul de intrare tridimensional, preia și afișează semnalul de tremur achiziționat (**Figura 6.**) este scris în Visual C++. Interogarea portului se realizează prin setul de funcții pus la dispoziție de Microsoft™ prin SDK iar în partea grafică ne folosim de setul de controale aparținând bibliotecii Measurement Studio ComponentWorks++™. Posibilitatea schimbării punctului din care se face observarea spațiului virtual sau salvarea semnalului de tremur sunt facilități oferite de program. Datorită sensibilității crescute a senzorului spațiul de intrare în care se poate urmări prezența mâinii este de 40 x 48 x 20 cm.

În partea inferioară a ferestrei de lucru este afișat un semnal de tremur. Deoarece timpul de transfer între DSP și calculatorul personal este mare, aproape 7.15 secunde, iar în tot acest timp interfața grafică este înghețată am fost obligați să găsim metode alternative de transfer. Problema a fost rezolvată prin crearea unui fir de execuție independent în program, numai pentru transferul serial. În acest mod putem urmări poziția mâinii în spațiul de intrare tridimensional și recepționa datele serial concurrent și fără să facem nici un compromis.

În concluzie putem spune că am obținut un semnal de tremur “curat” fără a face nici o concesie calității acestuia sau procesului de urmărire a mâinii în spațiul de intrare datorită următoarelor măsuri luate și a particularităților sistemului:

- banda de lucru a senzorilor este corespunzătoare achiziționării semnalului de tremur datorită în principal frecvenței înalte la care lucrează;
- senzorului lucrează pe porțiunea liniară a caracteristicii, în acest mod se comportă ca un sistem liniar;
- folosirea tehnicilor de procesare adecvate pe calea semnalului de tremur (de exemplu filtrul antialias este de tipul Bessel, cu răspuns liniar de fază);
- utilizarea unui convertor pe 12 biți;
- transferul datelor între DSP și calculatorul personal este realizat pe un fir separat de execuție.




Figura 7. Semnale de tremur achiziționate

Rezultate practice. Două din rezultatele achiziționării semnalului de tremur cu ajutorul Joystic-ului virtual sunt prezentate în **Figura 7.** Pentru obținerea acestor rezultate utilizatorul sistemului a fost rugat să stea pe un scaun, cu palma într-o poziție fixă deasupra sistemului de senzori, paralelă cu această suprafață. Brațul făcea un unghi de 30° cu planul orizontal.

În prima înregistrare, mâna se afla la 15 cm față de suprafața senzorului în timp ce în cea de a doua distanța era de 6 cm. Aceste date pot fi extrase și din valoarea medie a celor două semnale.

În aceeași figură se observă că în cea de a doua parte a înregistrării semnalul de tremur devine mai “zgomotos”, similar se poate observa și în **Figura 6.** Acest lucru se întâmplă deoarece în ultima parte a înregistrărilor starea de oboseală se instalează. Deoarece pe toată durata înregistrărilor

utilizatorul a fost rugat să-și mențină mâna nemișcată, aproximativ 8.5 secunde, este normal ca semnalul de tremur să-și modifice caracteristicile de-a lungul acestei perioade.

Parametrii semnalului de tremur. Programul extrage din semnalul de tremur achiziționat următorii parametri: frecvența de baza – definită ca frecvența componentei spectrale de amplitudine maximă, raportul dintre energia spectrului de înaltă frecvență și cel de joasă frecvență (se alege limita de 6 Hz între cele două spectre; aceasta frecvență este considerată a fi la mijlocul dintre “tremurul de joasă frecvență” și “tremurul de înaltă frecvență”), perioada minimă și cea maximă, varianța acesteia, valoarea de vârf a amplitudinii, varianța valorii de vârf, valoarea medie, indicele de periodicitate (raportul dintre puterea conținută de componenta spectrală cu amplitudinea cea mai mare și puterea totală a semnalului).

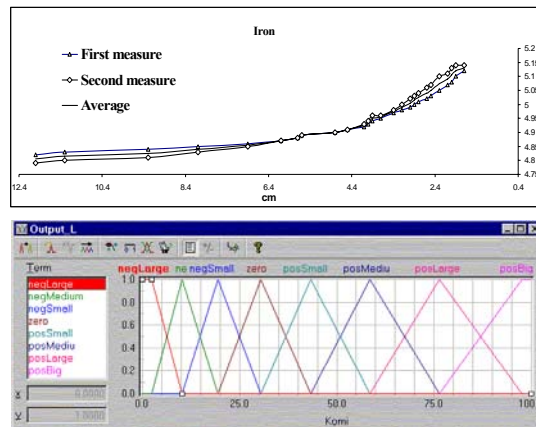


Figura 8. Caracteristica sensorului și forma funcțiilor de ieșire utilizate în corectarea ei.

Îmbunătățirea performanțelor sistemului. Din testele practice [6] efectuate mai multe deficiențe ale sistemului au ieșit în evidență. În primul rând s-a observat că există o influență dată de variabilitatea dimensiunilor mâinii asupra identificării exacte în spațiul de intrare tridimensional a poziției acesteia. Datorită caracteristicii neliniare a sensorului la distanțe foarte mici între obiect/mană și planul senzorilor se obțin estimări cu erori ale poziției. Modul foarte simplu de modelare a calculului distanțelor pe axa y (vezi **Figura 4.**) a determinat apariția altor erori de determinare a poziției mâinii.

Caracteristica distanță/tensiune de ieșire a unui element sensibil inductiv este prezentată în **Figura 8**. Se observă că pentru obiecte situate la distanțe foarte mici caracteristica începe să devină neliniară. Corecția caracteristicii a fost realizată cu un sistem fuzzy cu o intrare și o ieșire. Dacă valorile lingvistice de intrare sunt uniform distribuite, cele de ieșire sunt grupate asimetric spre stânga intervalului unde se află reprezentate în cazul nostru valorile mici ale distanței. Din teste practice s-a constatat că un număr de opt valori lingvistice sunt îndeajuns pentru liniarizarea caracteristicii. Mai mult acest sistem fuzzy este utilizat și pentru filtrarea zgomotului introdus de portul de achiziție al plăcii de sunet (cel care îmi ia valoarea potențioanelor). Pentru atingerea acestui obiectiv funcțiile de apartenență ale intrării sistemului fuzzy sunt de tip trapezoidal.

Modalitate de calcul în interiorul DSP a poziției pe axa Y (conform **figurii 4**) a mâinii în spațiul de intrare utilizată în [4] și [5] nu dădea rezultatele dorite. Din acest motiv s-a luat hotărârea calculării acestei poziții în programul care rulează pe calculatorul personal. În acest mod DSP-ul furnizează prin cele trei potențioetre pe care le comandă, portului de Joystick valorile brute ale

poziției mâinii, achiziționate direct de la senzori. Sistemul fuzzy implementat cu ajutorul mediului de dezvoltare FuzzyTECH™ este prezentat în **anexa 2**, tot în aceeași anexă se prezintă și o suprafață a sistemului fuzzy generată de același program considerând că valorile date de cei doi senzori mici (**Figura 4.**) de formă triunghiulară variază, iar senzorul mare întoarce o valoare zero (mâna este foarte departe față de suprafața acestui senzor). Cu același sistem fuzzy s-a realizat și compensarea variabilității dimensiunilor mâinii, prin realizarea a trei variante de sisteme fuzzy pentru trei tipodimensiuni diferite. La începerea sesiunii de lucru utilizatorul încearcă cele trei versiuni de sisteme și îl selectează pe cel care va reproduce o deplasare cât mai fidelă a mâinii în spațiul de intrare.

Sistemul de achiziționare și prelucrare a semnalului respirator

Prezentarea sistemului. Cu ajutorul acestui sistem achiziționăm semnalul respirator a unei persoane care este așezată pe un scaun fără nici un contact fizic între senzor și aceasta. Sistemul se bazează pe sesizare mișcărilor cavității toracice bazându-ne pe același principiu de funcționare dat de senzorul rezonant anterior prezentat. Senzorul este înglobat în spătarul unui scaun, **Figura 9.** Iar semnalul generat este achiziționat cu ajutorul unei plăci de la National Instruments comandată de un soft scris în LabWindows CVI (C for Virtual Instruments). Problema esențială care apare este generată de artefactele care perturbă semnalul respirator achiziționat. Aceste sunt generate de: mișcările corpului, semnalele mioelectrice, curgerea sângelui sau mișcările inimii. Dintre aceste semnale perturbatoare, mișcările corpului au influența cea mai mare (în **Figura 9.** este prezentat un semnal respirator contaminat cu un artifact generat de o mișcare a mâinii drepte pe lângă corp). Pentru a înlătura aceste artefacte un senzor piezoelectric este plasat pe una dintre barele care susține spătarul scaunului. Acest senzor ne va furniza în principal numai semnal de mișcare (în **Figura 9.** pe panoul softului de achiziție, în partea de jos este prezentat semnalul de mișcare aferent, generat de senzorul piezorezistiv, artefactului care s-a suprapus peste semnalul respirator).

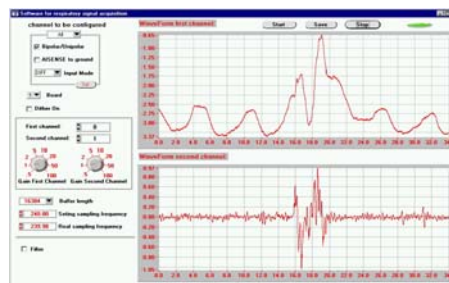



Figura 9. Sistemul și softul de achiziție

Pentru eliminarea artefactelor vom prezenta două metode adaptive. La sfârșit în urma analizei performanțelor furnizate de fiecare metodă în parte o vom alege pe cea care se potrivește cel mai bine scopurilor noastre.

Necesitate utilizării metodelor adaptive este dată în principal de imposibilitatea metodelor clasice (filtrări) de a rezolva această problemă. Deoarece amplitudinea artefactului este de câteva ori mai mare decât semnalul util, artefactul se suprapune atât în domeniul timp cât și în frecvență peste semnalul util iar mecanismul de cuplare între semnalul respirator și artefact este distribuit și foarte complex tehnicile de filtrare nu pot furniza rezultatul dorit. Pentru eliminarea artefactelor de mișcare am utilizat două metode, prima bazată pe metoda nului de zgomot iar cea de a doua bazată pe o tehnică statistică de tipul Blind Source Separation.

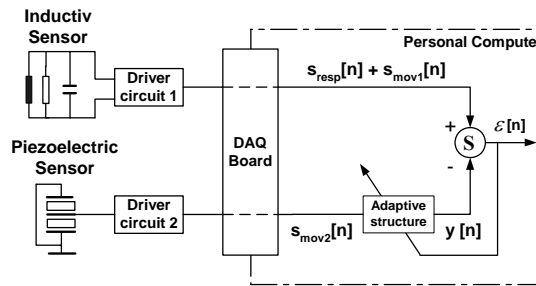


Figura 10. Nulul de zgomot

Nulul de zgomot. Schema bloc de reprezentare a acestei metode este prezentată în **Figura 10**. Ecuațiile care stau la baza funcționării sistemului prezentat în figura alăturată sunt:

$$\begin{aligned} \varepsilon &= (s_{resp} + s_{mov1}) - y_{adapt} \\ \varepsilon^2 &= (s_{resp} + s_{mov1})^2 - 2y_{adapt}(s_{resp} + s_{mov1}) + y_{adapt}^2 = \\ &= (s_{mov1} - y)^2 + s_{resp}^2 + 2s_{resp}s_{mov1} - 2y_{adapt}s_{resp} \end{aligned}$$

Deoarece semnalul de respirație și cel de mișcare sunt necorelate, putem scrie:

$$E[\varepsilon^2] = E[(s_{mov1} - y)^2] + E[s_{resp}^2]$$

în concluzie: $\varepsilon \cong S_{resp}$.



Figura 11. Semnalul respirator afectat de artefacte; Semnalul de mișcare; Integrala semnalului de mișcare.

Pentru eliminarea artefactelor de mișcare o primă structura adaptivă folosită a fost un filtru de tip FIR antrenat cu algoritmul LMS. Rezultatele au fost foarte slabe. Acest fapt s-a datorat în principal existenței unei corespondențe neliniare între ieșirea sistemului și intrare pe care filtrul FIR nu o putea modela.

Înlocuirea acestui filtru cu o rețea neuronală antrenată cu algoritmul de propagare inversă a erorii nu a produs într-o primă etapă rezultatele scontate. La ieșirea sistemului semnalul de eroare devenea zero, rețeaua suprimând simultan atât artefactul de mișcare cât și semnalul respirator. Ecuțiile scrise anterior sunt date pentru situația ideală. Semnalul de la intrarea structurii adaptive în situația reală nu este exclusiv o formă modificată a semnalului de mișcare S_{mov1} – în cazul nostru S_{mov2} . La intrarea rețelei neuronale regăsindu-se și semnal respirator. Existența celor două componente dă posibilitatea rețelei să învețe și semnalul respirator iar la ieșire vom obține un semnal care va minimiza eroarea ε , astfel este eliminat semnalul respirator. Pentru a preîntâmpina acest efect am împărțit cele două semnale de intrare, furnizate de traductori, în segmente și am antrenat rețeaua numai pe acele porțiuni în care artefactul este prezent [8]. Observând similitudinea existentă între porțiunile din semnalul respirator afectate de artefact și integrala semnalului de mișcare dat de senzorul piezoelectric (prima și ultima formă de undă din **Figura 11.**) și introducând această informație în rețeaua neuronală, în urma antrenării rețelei, s-a obținut rezultatul prezentat în **Figura 12.** Semnalul din **Figura 12** este unul de test, diferit de cele care formau setul de antrenare deci unul pe care rețeaua nu l-a văzut niciodată.




Figura 12. Semnalul respirator contaminat de artefacte de mișcare. Rezultatul înlăturării artefactului [7].

Metoda de anulare a artefactelor Blind Source Separation. Schema bloc de implementare a metodei este prezentată în **Figura 13.** Clasa de metode utilizate pentru separare a două sau mai multe surse de semnal, necunoscute, independente, mixate de un sistem liniar fără a avea cunoștințe legate de modul în care s-a realizat mixarea stă la baza celei de a doua abordări utilizată pentru înlăturarea adaptivă a artefactelor de mișcare. În situația noastră noi avem două surse de semnal (semnalul respirator dat de mișcările cavității toracice și cel de mișcare dat de schimbarea poziției corpului, mișcarea mâinii sau a altor părți ale corpului) achiziționate de doi senzori diferiți după ce aceste semnale au fost mixate prin funcția de transfer a corpului omenesc și a scaunului.

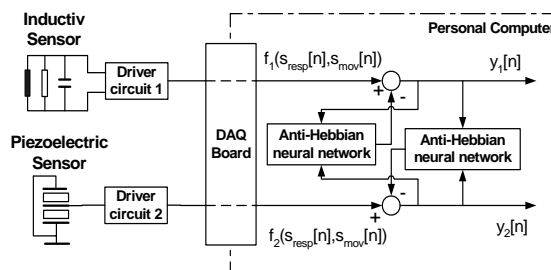


Figura 13. Schema bloc a metodei de separare adaptive

În **Figura 13.** ieșirea primei rețele neuronale, o versiune procesată a ieșirii y_2 , antrenate cu algoritmul anti-Hebbian utilizându-se pentru aceasta informația de corelație între ieșirile y_2 și y_2 , este scăzută din intrarea f_1 . Sistemul astfel construit devine stabil [9] numai în cazul în ieșirea $y_1 = s_{resp}$ iar $y_2 = s_{mov}$ (pentru situația în care semnalul respirator, s_{resp} , și semnalul de mișcare s_{mov} sunt ortogonale între ele).

În **Figura 14.** se prezintă rezultatele separării adaptive a semnalului de mișcare de cel respirator cu ajutorul metodei Blind Source Separation. Prima formă de undă este semnalul de mișcare integrat, cea din mijloc semnalul respirator contaminat cu artefacte de mișcare iar în ultima se observă rezultatul prelucrării.




Figura 14. Integrala semnalului de mișcare; Semnalul respirator contaminat cu un artefact de mișcare; Rezultatul eliminării adaptive a semnalului de mișcare [7].

Concluzii. Caracteristica nestaționară a semnalului de mișcare determină performanțele slabe obținute de către rețeaua neuronală (**Figura 12.**) comparativ cu cea antrenată cu algoritmul anti-Hebbian (**Figura 14.**). Ultima metodă fiind foarte eficientă în separarea semnalelor local nestaționare [9]. Totodată cea de a doua structură adaptivă prezentată este mai simplă iar algoritmul de calcul al ponderilor este mai rapid și mai simplu. În concluzie datorită vitezei de lucru și de adaptare a ponderilor superioară rețelei neurale multistrat, cea de a doua metodă este preferată. Mai mult algoritmul de antrenare este unul nesupervizat. Însușind toate aceste avantaje decizia finală a înclinat net în favoarea algoritmului Blind Source Separation.

Concluzii finale

Cele două sisteme propuse în cadrul grantului, algoritmi realizați cât și soluțiile adoptate conduc la obținerea a două semnale, respirație și tremur, capabile să furnizeze acele trăsături necesare discriminării stărilor utilizatorului.

Circuitele realizate sunt sensibile și au prețul redus iar senzorul este foarte sensibil, ușor de realizat și ieftin. Utilizarea în aceste sisteme a dispozitivelor programabile (DSP-ul TMS320F240) conferă un grad sporit de flexibilitate. Comutarea între sistemul tridimensional de sesizare a poziției și mișcărilor mâinii la cel bidimensional și invers se poate realiza în mai puțin de un minut. Dezvoltările ulterioare ale sistemului sunt foarte ușor de pus în practică datorită arhitecturii foarte flexibile.

În cadrul acestei cercetări **au fost atinse toate obiectivele propuse** pentru a fi realizate de către colectivul de cercetare constând în realizarea unor subrutine pentru înlăturarea artefactelor, extragerea de parametri din semnalul de tremur, implementarea, testarea și perfecționarea unor dispozitive de intrare noncontact care vor fi utilizate în faza a doua a proiectului. Colectivul de cercetare a valorificat rezultatele obținute prin publicarea de lucrări în reviste și volume ale unor conferințe internaționale [4], [5], [6], [7].

Bibliografie

- [1] Horia-Nicolai Teodorescu: *Position and movement resonant sensor*, Patent nr.: 5986549, Statele Unite ale Americii, data publicării: 16 noiembrie 1999
- [2] <http://www.linear.com/pdf/122930fa.pdf>
- [3] Dan-Marius Dobrea, H. N. Teodorescu, Daniel Mlynek, An Interface for Virtual Reality Applications, Romanian Journal of Information Science and Technology, editata de Academia Română, nr. 3, Septembrie 2002
- [4] Dan-Marius Dobrea, Horia-Nicolai Teodorescu, A New Type of Non-Contact 2D Multimodal Interface to Track and Acquire Hand Position and Tremor Signal, BEC' 2002, Baltic Electronics Conference 2002, October 6-9, Tallinn, Estonia
- [5] Dan-Marius Dobrea, A New Type of Non-Contact 3D Multimodal Interface to Track and Acquire Hand Position and Tremor Signal, ECIT'2002, European Conference on Intelligent Technologies 2002, Iulie 20-22, Iasi, Romania
- [6] Dan-Marius Dobrea, Horia-Nicolai Teodorescu, A Fuzzy System Used to Derive Hand Movements for a New Virtual Joystick Interface Device, Buletinul Științific al Universității "POLITEHNICA" din Timisoara, nr. 47 (61), 2002, vol. 1, ISSN1224-6034, pp. 27-31
- [7] Dan-Marius Dobrea, Horia-Nicolai Teodorescu, Monica-Claudia Serban, Method to remove respiratory artefacts from a system used to assess bio-psychic state of a person, Third European Symposium in Biomedical Engineering and Medical Physics, 2002, 30 August – 1 Septembrie, Patras, Greece
- [8] Richard Grieve, Philip A. Parker, Bernard Hudgins, Kevin Englehart, Nonlinear Adaptive Filtering of Stimulus Artifact, IEEE Transactions on Biomedical Engineering, Vol. 47, No. 3, March, 2000, pp. 389-395
- [9] Jose C. Principe, Chuan Wang, Hsiao-Chun Wu, Temporal Decorrelation Using Teacher Forcing Anti-Hebbian Learning and Its Application In Adaptive Blind Source Separation, IEEE Proceeding Workshop on Neural Networks for Signal Processing, 1996, pp. 413-422

Etapa 2003

3. *Determinarea metodologiei de punere în evidență a stării de oboseală și analiza influențelor externe care pot apărea.*

4. *Construirea clasificatorului.*

Introducere, obiective

În cadrul acestui proiect de cercetare s-a continuat, dezvoltat și **finalizat** *Complexul Bioinstrumental de Evaluare a Stării Biopsihice a Persoanelor Care Desfășoară Activități Supuse la Stres*, început în prima etapă a grantului și anterior acesteia, prin analiza stării de oboseală, realizarea părții soft de extragere a trăsăturilor și preprocesare iar în final de construire a clasificatorului.

Cercetarea și-a propus să rezolve și a **rezolvat** următoarele obiective:

- Determinarea unei metodologii coerente de:
 - realizare a protocolului de achiziție a datelor și
 - stabilire, inducere, evidențiere și determinare a stării de oboseală.
- S-a răspuns la următoarele întrebări fundamentale:
 - Există în semnalul de tremur informații care să reflecte starea odihnit/obosit a unui subiect uman?
 - Există vreo deosebire între starea de oboseală indusă forțat când subiectul este odihnit și cea neuro-fizică atinsă la sfârșitul unei zile de muncă? Le putem diferenția între ele prin intermediul semnalului de tremur?
 - Dacă pe fondul unei oboseli neuro/fizice inducem forțat mai multă oboseală fizică am putea să realizăm o diferențiere între starea indusă și cea existentă?
- Analiza alegerii unui tip de clasificator
- Realizarea clasificatorului

Identificarea stării de oboseală din semnalul de tremur este dificilă chiar datorită celor două componente care formează premisele inițiale: **tremurul și starea de oboseală**.

Tremurul este unul dintre cele mai puțin investigate procese ale organismului uman. Din punct de vedere medical evaluarea tremurului este la ora actuală o tehnică aflată la începuturi și, mai mult, o clară caracterizare a acestui semnal nu există. Singurele rezultate existente sunt pentru situațiile patologice (de exemplu în cazul afecțiunii Parkinson) în timp ce pentru subiecți sănătoși mecanismul apariției tremurului, sau a influențelor generate de: stările afective, intoxicații, vârstă, etc. nu sunt cunoscute sau nu sunt complet înțelese.

Studii efectuate asupra **stării de oboseală** corelată cu diferite afecțiuni se regăsesc pe larg în literatura de specialitate, dar din păcate datorită evidențelor care subliniază existența unor diferențe clare între starea de oboseală manifestată de subiecții sănătoși față de starea de oboseală a celor bolnavi

[1], toate aceste cercetări sunt nefolositoare abordării de față. Chiar și în cazul diferitelor afecțiuni însoțite și asociate cu stări de oboseală nu este clar dacă oboseala poate fi considerată o cauză, un mediator sau un rezultat al degradării stării de sănătate a pacienților [2]. Pentru persoanele sănătoase se cunosc destul de puține informații legate sau corelate cu starea de oboseală.

În cadrul acestui raport sinteză se prezintă rezultatele, analizele și concluziile obținute atât în legătură cu posibilitățile de evidențiere în mod neambiguu a stării oboseit/odihnit, a unui subiect, cât și anumite concluzii trase pentru îmbunătățirile viitoare ale sistemului de clasificare.

Subiecții

Pentru acest studiu au fost selectați șase subiecți. Toți aceștia fiind sănătoși fără probleme endocrine, neuronale sau alte afecțiuni acute sau cronice (diabet, SIDA, cancer, diferite alergii, etc.) și fără deficiențe de Ca^{2+} sau Mg^{2+} care ar putea determina și influența tremurul. Toate aceste limitări sunt impuse deoarece, după cum s-a prezentat anterior, starea de oboseală pentru persoanele cu diferite afecțiuni este net diferită față de aceeași stare existentă în subiecții sănătoși [1]. Mai mult, toți cei șase participanți la acest studiu nu au luat medicamente pe toată perioada înregistrărilor cât și pe o perioadă de o săptămână anterioară începerii înregistrărilor.

Doi dintre subiecți au fost de sex feminin. Cinci dintre ei au fost persoane tinere (26.6 ± 3 ani, vârsta medie \pm deviația standard) și numai un singur participant a fost în vârstă – 53 de ani. Toți subiecții au participat voluntar la înregistrări și și-au dat consimțământul în scris.

Protocolul și metodologia înregistrării datelor

Într-o singură sesiune de la fiecare subiect s-au efectuat patru cicluri de înregistrări. Durata unei singure înregistrări din ciclu a fost de 90 de secunde. Cele patru cicluri de înregistrări, pentru un singur subiect, nu au fost executate consecutiv. Fiecare subiect urmând celui anterior până când toate cele patru cicluri au fost terminate. Anterior ultimul ciclu din înregistrare fiecare subiect a fost rugat să țină în mână (de la care se înregistrează tremurul) un obiect în greutate de 4 Kg timp de 4 minute. Brațul a fost ținut întins orizontal, în planul transversal al corpului. Prin această metodă s-a indus forțat starea de oboseală. Într-o singură zi fiecare subiect a fost supus la două sesiuni de înregistrări. Prima sesiune a avut loc la ora 8⁰⁰ dimineața (când s-a presupus că toți subiecții sunt odihniți) în timp ce cea de a doua a avut loc începând cu ora 14³⁰ când s-a considerat că starea de oboseală s-a instalat. În toată perioada dintre cele două sesiuni de înregistrări subiecții au fost rugați să-și desfășoare activitățile lor zilnice, normale. Toate aceste înregistrări au fost efectuate pe durata a 7 zile lucrătoare, consecutive.

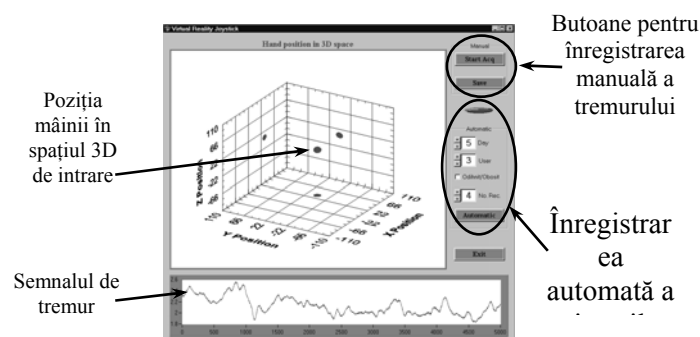


Figura 1. O imagine cu fereastra principală a aplicației care controlează Joystick-ul Virtual

Înregistrările au fost efectuate cu ajutorul Joystick-ul Virtual dezvoltat în prima etapă a acestui grant. În toate ciclurile de înregistrări subiecții au fost rugați să mențină aceeași poziție a mâinii, deasupra sensorului cu cele mai mari dimensiuni. Poziția mâinii a fost indicată la începutul ciclului de înregistrare de către cel care a supervizat înregistrările. Poziția inițială a fost cu palma paralelă cu suprafața sensorului, centrul palmei fiind fix deasupra centrului geometric de greutate al

senzorului planar, cu brațul întins. Distanța pe verticală față de planul senzorului a fost marcată cu o riglă susținută de un suport. În plus poziționarea corectă a mâinii a fost controlată suplimentar și cu ajutorul interfeței grafice, vezi **Figura 1**. Pe toată durata înregistrărilor, subiecții, au stat pe un scaun într-o poziție comodă. Deoarece starea de oboseală este de așteptat să se instaleze în ultima parte a celor 90 de secunde ale unui ciclu de înregistrare numai primele și ultimele 20 de secunde au fost păstrate pentru analiză. Pe toată durata ciclului de înregistrare subiecții nu au avut nici un control vizual al poziției mâinii, direct sau prin interfața grafică a Joystick-ului Virtual. În acest mod orice posibilitate de bio-feedback a fost înlăturată.

Rata de eșantionare a semnalului de tremur a fost de 250 Hz și în total am obținut 10.000 de eșantioane pentru fiecare ciclu de înregistrare: 5.000 din primele 20 secunde în timp ce restul au fost obținute din ultimul segment de 20 de secunde. Fiecare segment de 20 de secunde a fost caracterizat de un vector cu 9 elemente – trăsături ale semnalului. Într-o sesiune 48 astfel de vectori de trăsături au fost obținuți (2 vectori de trăsături/ciclu/subiect x 4 cicluri x 6 subiecți). Astfel la sfârșitul unei zile 96 de serii de timp au fost obținute. În mod corespunzător după 7 zile de înregistrări 672 de vectori de trăsături au fost adunați.

Programul utilizat atât pentru controlul Joystick-ului Virtual cât și pentru gestionarea/salvarea seriilor înregistrate a fost scris în MicrosoftTM Visual C++, utilizându-se controale grafice din pachetul Measurement Studio ComponentWorks++ de la National InstrumentsTM, și este o versiune îmbunătățită a programului prezentat în [3] și [4] dezvoltat în prima etapă a acestui grant.




Figura 2. Un exemplu de semnal de tremur cât și rezultatele preprocesării acestuia

Preprocesarea datelor

În cadrul etapei de preprocesare s-a urmărit în principal eliminarea semnalelor perturbatoare. Preprocesarea este realizată în două etape, diferențiate între ele în principal prin locul unde se execută acestea. În prima etapă realizată la nivelul Joystick-ului Virtual semnalul este filtrat trece jos cu ajutorul unui filtru Bessel cu răspuns liniar în fază, a cărui frecvență de tăiere este de 60 Hz. Semnalul de tremur este în continuare eșantionat și ulterior digitizat pe 12 biți de către DSP-ul component al Joystick-ului Virtual, în Figura 2. (a) este prezentat un astfel de semnal.

Tremurul este o mișcare complexă, compusă din componente care derivă din mișcările respiratorii cât și din alte tipuri de mișcări care nu au nici o legătură cu acesta cum ar fi activitatea inimii. Mișcările respiratorii își aduc aportul mai ales în partea inferioară a spectrului semnalului de tremur. În concluzie aceste componente ale semnalului respirator trebuiesc eliminate ținând cont că

semnalul respirator, pentru o persoană adultă, are frecvența fundamentală în intervalul 0.1 Hz ... 0.3 Hz cu o bandă care începe de la 0.05 Hz și se întinde până la maximum 3 Hz.

După ce semnalul de tremur este recepționat de către PC, în mod serial, de la Joystick-ului Virtual, Figura 2. (a), este ulterior filtrat soft de către un filtru trece sus cu frecvența de tăiere la 1 Hz, obținându-se un semnal similar cu cel din Figura 2.(b). După o reducere a zgomotului cu ajutorul unei ferestre de mediere pe 10 eșantioane se obține un semnal similar cu cel din Figura 2.(c).

În principal deoarece o parte dintre parametrii pe care îi extragem sunt legați de domeniul spectral și deoarece în domeniul frecvență dorim o determinare precisă a componentelor spectrale se aplică o tehnică de tip ferestruire pentru a minimiza problema dispersiei spectrale (spectral leakage). Fereastra de tip Hanning a fost aleasă în principal datorită rezoluției spectrale foarte bune (lățimea lobului principal al ferestrei la -3 dB este de 1.44 linii spectrale) cât și a ratei de atenuare a lobilor secundari (-60 dB/decadă).

Trăsăturile

Nouă trăsături au fost extrase din fiecare serie de timp înregistrată. Trăsăturile utilizate sunt: frecvența „principală”, varianța acesteia, lățimea componentei principale a semnalului de tremur, varianța lățimii componentei principale, puterea semnalului, varianța puterii, raportul dintre puterea componentelor spectrale de joasă frecvență și a celor de înaltă frecvență (denumit high-to-low ratio), varianța acestui raport și deviația standard a semnalului.

Frecvența „principală” este definită ca acea frecvență care corespunde componentei spectrale de amplitudine maximă a spectrului Fourier, Figura 2.(d). În analiza semnalului de tremur frecvența „principală” este un parametru important folosit pe larg [5], [6].

Pentru estimarea frecvenței principale și reducerea fenomenului de dispersie spectrală dat de procesul de eșantionare (picket-fence effect) o mediere ponderată este utilizată în estimarea frecvenței componentei spectrale de amplitudine maximă:

$$f_{\text{estimarea componentei principale}} = \frac{\sum_{i=j-3}^{j+3} (\text{Power}(i) \cdot i \cdot \Delta f)}{\sum_{i=j-3}^{j+3} \text{Power}(i)} \quad (1)$$

în relația (1), $\text{Power}(i)$ este puterea liniei spectrale i , j este indexul liniei spectrale de amplitudine maximă a cărei frecvență dorim să o evaluăm, în timp ce $\Delta f = f_s/N$ (f_s – fiind frecvența de eșantionare iar N – numărul de puncte a secvenței înregistrate). În cazul nostru, pentru $f_s = 250$ Hz și $N = 1024$ rezultă o rezoluție în frecvență $\Delta f = 0.244$ Hz. O fereastră alunecătoare de 1024 de eșantioane a fost folosită numai pentru determinarea frecvenței „principale”, a dispersiei frecvenței principale și a lățimii componentei principale. Această fereastră cu 1024 de puncte a fost aleasă în principal din dorința de a obține o rezoluție spectrală foarte bună. Pentru determinarea celorlalte trăsături ale semnalului de tremur o fereastră de 512 eșantioane a fost utilizată. Alegerea variației indexului i în domeniul ± 3 , în estimarea frecvenței componentei principale, a fost datorită de două constrângeri. În primul rând variația acestui parametru este mai largă decât lățimea lobului principal al ferestrei Hanning și, în al doilea rând, din punctul de vedere al semnalului de tremur această variație este destul de largă, minimizând totodată și probabilitatea de a interfera cu o altă componentă spectrală.

Lăţimea componentei spectrale principale a fost estimată cu relaţia (2) unde parametrul NPBW este lăţimea de bandă a puterii zgomotului ferestrei, ceilalţi parametri şi funcţii fiind similari cu cei din relaţia (1).

$$\Delta f_{width} = \frac{\sum_{i=j-3}^{j+3} Power(i)}{7 \cdot NPBW \cdot Power(j)} \quad (2)$$

Totodată am reconfirmat remarca făcută în [7] unde s-a observat, în mai multe situaţii, că sub efort muscular spectrul semnalului de tremur începe să se modifice în mod substanţial, prin scăderea în amplitudine a frecvenţei principale a semnalului de tremur şi regularizarea mişcărilor de tremur care determină scăderea energiei la frecvenţe „înalte”. Ştiind această trăsătură a procesului am ales un parametru care să reflecte aceste modificări. Astfel raportul dintre puterea regiunii de „joasă” frecvenţă şi a celei de „înaltă” frecvenţă (utilizându-se pragul de 6 Hz pentru a diferenţia cele două regiuni) ar putea să reflecte aceste modificări. În principal acest prag frecvenţial a fost ales de către medici şi este presupus a exista între tremurul de „joasă” frecvenţă şi cel de „înaltă” frecvenţă [8]. Acest prag are relevanţă medicală şi caracterizează, prin compararea cu frecvenţa de bază a semnalului de tremur, diferite stări patologice. În cazul nostru toţi subiecţii sunt persoane sănătoase şi, după o inspecţie vizuală a componentelor spectrale ale semnalului de tremur pentru mai multe serii de timp, am observat că puterea semnalului este în principal concentrată în jurul componentelor spectrale de „joasă” frecvenţă, numai o mică parte depăşind bariera de 6 Hz. Din acest motiv se propune utilizarea unei frecvenţe de 4 Hz şi se va testa utilitatea acestui nou prag.

Analiza stării de oboseală

Într-un studiu [20] efectuat în urmă cu un deceniu a fost evidenţiată existenţa a două componente distincte ale stării de oboseală: cea mentală şi cea fizică. Aceste rezultate au fost confirmate [10] peste câţiva ani când dintre cele cinci dimensiuni evidenţiate ale stării de oboseală două: oboseala fizică şi cea mentală s-au diferenţiat. Într-un studiu foarte recent [11] aceleaşi două manifestări ale stării de oboseală (fizică şi mentală) au fost puse din nou în evidenţă.

Din aceste perspective, determinarea numărului corect de clase existente în setul de date devine o prioritate şi mai mult o necesitate pentru o corectă realizare a sistemului de clasificare. Încă din faza iniţială când s-a dezvoltat metodologia realizării înregistrărilor se pot diferenţia mai multe situaţii distincte. De exemplu setul de date achiziţionat în sesiunea de înregistrări realizate dimineaţa este compus din două subseturi distincte: înregistrările efectuate ulterior inducerii în mod forţat a stării de oboseală (după ce fiecare subiect a ţinut în mână un obiect de 4 Kg) şi restul înregistrărilor. În mod similar în sesiunea de înregistrări efectuată după-amiaza se pot distinge două tipuri diferite de situaţii. În acest context vom încerca să răspundem la următoarele întrebări:

Există în semnalul de tremur informaţii care să reflecte starea odihnit/obosit a unui subiect uman?

Există vreo deosebire între starea de oboseală indusă forţat când subiectul este odihnit şi cea neuro-fizică atinsă la sfârşitul unei zile de muncă? Le putem diferenţia între ele prin intermediul semnalului de tremur?

Dacă pe fondul unei oboseli neuro/fizice inducem forţat mai multă oboseală fizică am putea să diferenţiem între starea indusă şi cea existentă?

Numărul de clase existent într-un set de date poate fi determinat prin mai multe metode:

- în mod apriori, dacă avem informații suplimentare despre problemă,
- în mod automat prin utilizarea unei măsuri de validitate a clasei [9] și
- printr-un proces iterativ de introducere a unor noi centri de clusterizare până când o măsură a validității clasificării [13] începe să scadă, sau se poate utiliza un proces invers de combinare a claselor existente.

Pentru a răspunde la întrebările anterioare prezentate am utilizat algoritmul k-means pe diferite seturi de date pentru a încerca să vedem dacă putem discrimina între posibilele cazuri prezentate anterior și pentru a determina simultan numărul corect de clase existente în setul de date.

Pentru a ne forma o părere a separabilității claselor vom determina pentru fiecare vector de trăsături un parametru numit **silhouette**. Silhouette reprezintă o măsură a similarității unui punct față de punctele din clasa căreia îi aparține pe drept în comparație cu punctele altor clase. Acest parametru ia valori între -1 și $+1$. Dacă un vector de trăsături ia valoarea $+1$, atunci acesta este corect clasificat și este distant față de vectorii de trăsături ai claselor vecine. O valoare egală cu zero simbolizează un punct care nu poate fi atribuit cu certitudine nici unei clase în timp ce o valoare egală cu -1 caracterizează un vector de trăsături prost clasificat.

Să presupunem că am reușit să clasificăm vectorii de trăsături în k grupuri, A este un cluster care conține în mod legitim vectorul de trăsături x_i , în timp ce C_k reprezintă orice altă aglomerare de puncte diferite de A . În aceste condiții parametrul Silhouette pentru un vector este definit:

$$silhouette(x_i) = \frac{b(x_i) - a(x_i)}{\max[a(x_i), b(x_i)]} \quad (3)$$

unde:

$$a(x_i) = \frac{1}{no\{A\} - 1} \sum_{j \in A, j \neq i} d(x_i, x_j) \quad (4),$$

$$b(x_i) = \min_{C_k \neq A} \{d(x_i, C_k)\} \quad (5),$$

$$d(x_i, C_k) = \frac{1}{no\{C_k\}} \sum_{x_j \in C_k} d(x_i, x_j) \quad (6)$$

în timp ce $d(x_i, x_j)$ reprezintă distanța între vectorii de trăsături x_i și x_j iar $no\{A\}$ este numărul de elemente care compune aglomerarea de puncte A .

În [14] a fost propus pentru prima dată ideea utilizării valorii medii a Silhouette pentru estimarea numărului optim de clase. Metoda alege drept număr optim de clase acea valoare care maximizează valoarea medie a lui Silhouette pe întreg setul de date. Din experiență s-au desprins o serie de intervale de apartenență a parametrului care determină diferite grade de coeziune pentru clasele găsite, **Tabelul 1**.

Tabelul 1. Interpretarea valorii medii a siluetei

Valoare Silhouette	Interpretare
0.71 ... 1.00	Setul de date prezintă structuri și clase puternice.
0.51 ... 0.70	Structurile găsite sunt rezonabile
0.26 ... 0.50	Structurile găsite sunt slabe sau pot fi artificiale.
< 0.25	Nu s-a găsit nici o structură coerentă

Deoarece algoritmul k-means prezintă o serie de probleme (sensibilitate la zgomote și la

valorile aberante, clasele trebuie să aibă suprafețe convexe, algoritmul este adesea prins în minime locale) un număr de precauții trebuie avute în vedere. Tot din acest motiv acest algoritm nu va fi utilizat în clasificare ci doar în determinarea numărului de clase.

Rezultatele care sunt prezentate în continuare sunt cele mai bune obținute din 10 rulări consecutive a algoritmului k-means pentru fiecare în parte, alegând de fiecare dată un nou set, generat aleator, de centre ai claselor. În acest mod se încearcă evitarea „agățării” algoritmului în optime locale. Pentru eliminarea valorilor aberante s-au efectuat teste cu două seturi de date, realizându-se la sfârșit o comparație a performanțelor pentru fiecare set în parte. Primul set de date conține întregul număr de vectori de trăsături din care au fost eliminați toți vectorii care au valorile pentru cel puțin o trăsătură în afara intervalului $[-3\sigma, +3\sigma]$ față de media statistică a trăsăturii respective, unde σ reprezintă deviația standard corespunzătoare trăsăturii. Pentru cel de al doilea set domeniul de variație a fost redus la $[-2\sigma, +2\sigma]$. Rezultatele prezentate mai jos sunt obținute pe primul set de date, în principal deoarece: nu s-a observat o îmbunătățire spectaculoasă a performanțelor pentru setul restrâns de date și, mai mult, în pașii următori (în momentul construcției clasificatorului) dorim un set de date cât mai bogat pentru antrenare.

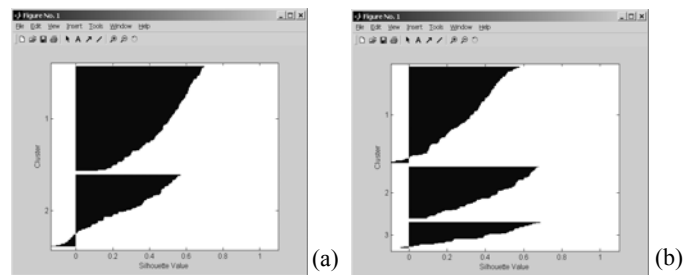


Figura 3. Reprezentarea grafică a silhouette pentru (a) două și (b) trei clase – pentru întreg setul de date înregistrat numai dimineața [17]




Figura 4. Reprezentarea grafică a silhouette pentru (a) două, (b) trei și (c) patru clase [19]

În prima analiză a stării de oboseală utilizăm în mod exclusiv numai seriile de timp achiziționate dimineața și dorim să vedem dacă există posibilitatea de a discrimina între starea de oboseală indusă forțat și cea de odihnă, normală, existentă dimineața. Algoritmul de clusterizare a fost inițializat pentru început în ipoteza existenței doar a două clase. După terminarea procesului iterativ de asociere a vectorilor la clase și recalculare a centrilor claselor, valoarea parametrului silhouette a fost determinată pentru toți vectorii de trăsături și s-a obținut reprezentarea grafică din Figura 3.(a). În figura Figura 3.(a) reprezentarea grafică este dată pentru utilizarea limitei de 6 Hz între raportul spectral de putere de joasă și înaltă frecvență. Valoarea medie a parametrului silhouette, pentru ipoteza existenței doar a două clase în setul de date, a fost de 0.3905. Când numărul de clase a fost crescut, valoarea medie a parametrului silhouette, pentru trei clase, a fost de

0.3539 și a continuat să scadă în continuare odată cu creșterea numărului claselor. În concluzie numărul corect de clase este doi și se poate observa că putem diferenția între stările obosit/odihnit folosindu-ne numai de informația conținută în semnalul de tremur.

Pentru a evalua influența frecvenței care definește raportul între puterea spectrală de joasă și înaltă frecvență, algoritmul k-means a fost utilizat din nou, singura modificare fiind făcută în cadrul vectorilor de trăsături unde pentru raportul de puteri limita este acum de 4 Hz restul condițiilor și constrângerilor fiind păstrate. Valoarea medie a parametrului silhouette a fost de 0.3904, pentru două clase, și de 0.3536, pentru trei clase, continuând să scadă în continuare pentru o creștere continuă a numărului de clase. Aceste rezultate demonstrează că utilizarea limitei de frecvență de 4 Hz nu aduce nici o îmbunătățire spectaculoasă a rezultatelor.

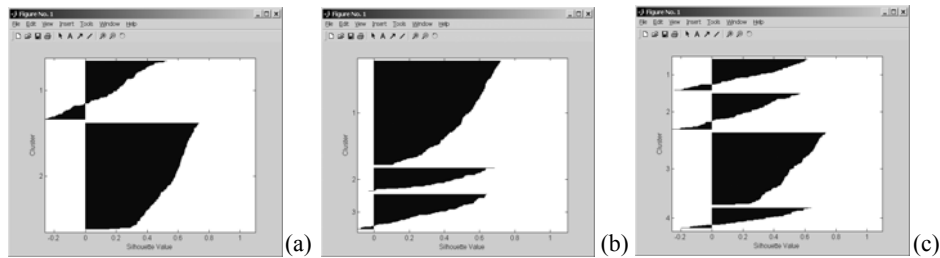


Figura 5. Reprezentarea grafică a silhouette pentru (a) două, (b) trei și (c) patru clase [19]

Abilitatea de a diferenția între starea de oboseală indusă și cea neuro-musculară existentă în subiecți spre sfârșitul programului de lucru a fost investigată în continuare. Setul de date utilizat a fost format din toate înregistrările efectuate dimineața, când starea de oboseală a fost indusă forțat, și din întregul set de serii de timp achiziționat spre sfârșitul zilei de muncă. Valoarea medie a parametrului silhouette a fost de 0.4074 pentru cazul în care s-a presupus existența doar a două clase în setul de date, ulterior crescând la 0.4565 când s-a presupus existența a trei clase și a continuat să descrească ca valoare pentru creșterea continuă a numărului de clase, **Figura 4**. De exemplu pentru trei clase valoarea medie a parametrului a fost de 0.374. Limita de frecvență a fost luată la 6 Hz.

Când limita de frecvență a fost aleasă la 4 Hz valoarea medie a siluetei, conform **Figura 5**., a luat valoarea 0.4074 pentru două clase, 0.4566 pentru trei clase și 0.3738 pentru patru clase. Din nou nu se observă nici o îmbunătățire substanțială.

În concluzie, în semnalul de tremur se regăsesc informații care să reflecte starea de oboseală a subiectului și, mai mult decât atât, putem să diferențiem nu numai între starea de oboseală indusă forțat (care este în principal musculară) și cea care se instalează la sfârșitul unei zile de lucru dar chiar în setul de date înregistrat după-amiaza putem diferenția între cele două stări de oboseală particulare.

După cum se observă din **Tabelul 1**. corelat cu valorile medii ale parametrului silhouette obținute de noi, una dintre posibilele interpretări este aceea că structurile observate sunt artificiale și în concluzie întreaga analiză prezentată anterior este falsă. În principal deoarece pentru fiecare vector de trăsături cunoaștem contextul în care am făcut înregistrarea și deci clasa de apartenență și bazându-ne și pe rezultatele care vor fi prezentat în secțiunea următoare tragem concluzia că ipoteza unei structuri de date slabe este cea corectă.

Analiza claselor și alegerea clasificatorului

Pentru a avea o înțelegere intuitivă a setului de date și a problemelor pe care acesta îl va ridica clasificatorului, informația de la ieșirile unei rețele de tipul PCA a fost utilizată pentru vizualizarea

într-un spațiu 3D a posibilelor structuri existente în noul set de date obținut prin proiecția setului inițial prin rețeaua PCA. Rețeaua PCA a fost implementată utilizându-ne de regula de învățare nesupervizată Hebbiană generalizată propusă în [15]:

$$w_{ij}(n+1) = w_{ij}(n) + \eta(n)y_i(n) \left[x_j(n) - \sum_{k=1}^i w_{kj}(n)y_k(n) \right] \quad (7)$$

suma după k în relația (7) este un termen de ortonormalizare utilizat pentru convergența algoritmului. S-a demonstrat că pentru valori mici ale ratei de învățare η algoritmul converge pentru orice condiții inițiale existente [16]. Rețeaua a fost oprită în momentul în care cantitatea cu care variau ponderile de la un pas la următorul a coborât sub un prag $\varepsilon = 0.0005$. Pentru a fi siguri de corectitudinea alegerii momentului opririi vectorii de ieșire rezultanți au fost testați utilizându-se proprietățile specifice vectorilor proprii, fiind calculată pentru setul de vectori de la ieșirea rețelei PCA.

Weights of hebbianFull									
	0	1	2	3	4	5	6	7	8
0	0.729209	0.000017	0.000030	0.000023	0.000104	0.000004	0.000054	0.000185	-0.000144
1	0.000017	0.364246	-0.000043	-0.000019	0.000015	0.000074	-0.000152	-0.000073	-0.000063
2	0.000030	-0.000043	0.198803	-0.000007	-0.000002	-0.000002	0.000022	-0.000037	0.000130
3	0.000023	-0.000019	-0.000007	0.118694	-0.000002	0.000005	0.000006	-0.000009	-0.000142
4	0.000104	0.000015	-0.000002	-0.000002	0.097688	0.000001	0.000012	-0.000005	0.000241
5	0.000004	0.000074	-0.000002	0.000005	0.000001	0.068099	-0.000006	0.000011	0.000459
6	0.000054	-0.000152	0.000022	0.000006	0.000012	-0.000006	0.025435	0.000104	0.001064
7	0.000185	-0.000073	-0.000037	-0.000009	-0.000005	0.000011	0.000104	0.022828	-0.002937
8	-0.000144	-0.000063	0.000130	-0.000142	0.000241	0.000459	0.001064	-0.002937	0.000795

Figura 6. Matricea de covarianță a ieșirilor rețelei PCA, elementele de pe diagonală sunt valorile proprii [17]

Deoarece am avut posibilitatea de a calcula matricea de corelație a setului de date de ieșire din PCA, în timp real, cu ajutorul unei rețele antrenată cu algoritmul Hebbian forțat, dar eram interesați în determinarea matricii de covarianță, media a fost înlăturată din toți vectorii setului de date de la intrare rețelei PCA. În acest mod matricea de corelație calculată a fost egală cu cea de covarianță. În **Figura 6.** sunt prezentate ponderile rețelei Hebbiene care în cazul nostru reprezintă chiar matricea de covarianță a vectorilor de la ieșirea rețelei PCA. Pe diagonala principală regăsim valorile proprii. Deasemenea se poate observa că elementele care nu se află pe diagonală principală tind către zero.

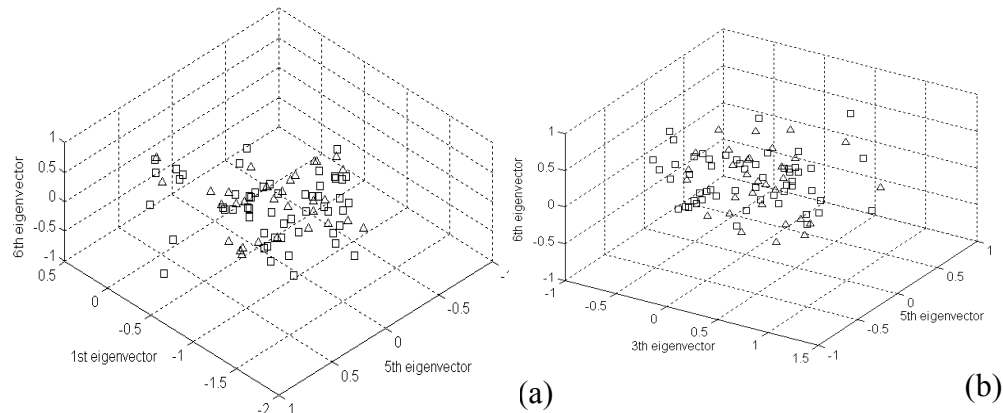


Figura 7. Două distribuții ale vectorilor de trăsături reprezentând starea utilizatorului (odihnit-triunghiuri/obosit-pătrate) vizualizate în (a) prima, a cincea și a șasea ieșire a rețelei PCA și (b) a treia, a cincea și a șasea ieșire a rețelei

Vizualizarea datelor a fost efectuată pe întregul set de date și pe fiecare subiect în parte. Pentru vizualizarea 3D am utilizat combinații doar ale primelor 6 ieșiri ale rețelei PCA. Aceste ieșiri reprezintă 96.983% din puterea tuturor trăsăturilor utilizate. În ciuda faptului că în anumite zone ale spațiului vectorii de trăsături se grupează **Figura 7.(a)** și (b) (datele sunt prezentate numai pentru un singur subiect ales aleator) aspectul general este acela a unor clase împrăștiate și întrepătrunse fără limite clare de demarcație între ele. La această concluzie s-a ajuns după mai multe vizualizări din diferite unghiuri ale spațiului 3D și pentru toate combinațiile posibile ale ieșirilor rețelei PCA. Din acest motiv o rețea neuronală de tip SVM (Support Vector Machines) a fost aleasă pentru clasificare în principal datorită performanțelor acestui tip de clasificator și în ideea că într-un spațiu cu un număr mai mare de dimensiuni setul de date va deveni liniar separabil.

Clasificatorul

Sistemele de tip SVM au fost dezvoltate pentru a realiza un clasificator binar. Cu toate acestea un astfel de clasificator poate fi extins foarte ușor la unul de tip C clase (în cazul nostru particular $C = 4$ pentru a putea diferenția între toate stările puse anterior în evidență). Pentru a realiza acest lucru vom construi C astfel de clasificatoare, de două clase, sub forma {clasa i } versus {clasa $1 \dots C$ /mai puțin clasa i } și apoi vom determina clasa corectă de apartenență selectând acea clasa k a cărei ieșire corespunzătoare are valoarea maximă dintre toate cele C sisteme de clasificare.

Primul dintre cele patru clasificatoare a fost construit și antrenat pentru a diferenția starea de odihnit față de cea de oboseală. Starea odihnit este reprezentată de toate înregistrările efectuate dimineața mai puțin cele în care starea de oboseală a fost indusă în timp ce starea de oboseală este caracterizată de restul înregistrărilor. Performanțele clasificatorului sunt prezentate în **Tabelul 2.** și sunt date pe un set de test distinct față de setul de antrenare al clasificatorului:

Tabelul 2. Performanțele clasificatorului [17], [19]

	Odihnit	Oosit
Odihnit	85.71 %	14.29 %
Obosit	68.42 %	31.58 %

Etichetele de pe liniile tabelului reprezintă clasele reale de apartenență a vectorilor de trăsături în timp ce etichetele de pe coloane reprezintă clasele asociate de către rețea. Cu toate că acestea sunt rezultate preliminare se poate observa o rată a clasificării bună de 31.58% în cazul recunoașterii stării de oboseală și de 85.71% pentru situația persoanelor odihnite. Rezultatele obținute sunt bune în principal datorită recunoașterii stării de oboseală folosindu-ne doar de un singur semnal, semnalul de tremur, și ne utilizării altor tipuri de informații.

Rezultatele obținute cu ceilalți trei clasificatori în încercările de a diferenția diferitele stări de oboseală au condus la obținerea de rezultate foarte slabe. O cauză directă care a determinat obținerea acestor rezultate slabe, a fost dată de nereprezentativitatea statistică a setului de date. De exemplu, dacă considerăm numai starea de oboseală indusă forțat, pe setul de înregistrări achiziționate dimineața, vom observa că tot setul de date este de 11.86% din întregul set de vectori de trăsături, adică doar 69 de vectori de trăsături. Dacă repartajăm acest set de date, de doar 69 de vectori de trăsături, în setul de antrenare, cros-validare și cel de test avem o imagine clară a cauzei care determină obținerea acestor rezultate.

Din vizualizări succesive ale setului de date (prin proiecția acestuia în spațiul 2D și 3D dat de vectorii proprii) și din analiza parametrilor statistici pentru fiecare subiect în parte am observat că pentru unul dintre subiecți caracteristicile statistice ale stării de oboseală (în principal pentru starea de oboseală indusă forțat) sunt diferite în mod substanțial comparativ cu restul grupului avut sub analiză. Pentru a clarifica această problemă o analiză amănunțită și un interviu suplimentar a avut loc. După eliminarea diferitelor posibile cauze patologice sau a deficiențelor de înregistrare/analiză a setului de date a reușit să se determine că subiectul respectiv este un sportiv de performanță practicând Tai Kuando câte două-trei ore de antrenament în fiecare zi, acest factor fiind unul ne luat în calcul inițial. Din acest caz particular o întrebare mai generală apare. *Cât de relevantă este starea de oboseală presupusă de noi în a reflecta starea reală a subiectului ?* Deoarece starea de oboseală este influențată de o multitudine de factori (cum ar fi: suprasolicitările la lucru, stresul, lipsa sau insuficiența somnului, diferitele responsabilități suplimentare – de ex. copii sub îngrijire, dietă, etc.), o altă cauză a rezultatelor obținute poate fi dată de neconcordanța între presupunerile făcute asupra stării subiecților și starea lor reală.

Concluzii

În acest raport de cercetare am prezentat abilitatea unui nou dispozitiv, fără contact, introdus de echipa noastră, Joystick Virtual, de a discrimina între stările de oboseală și cea de odihnă. Prin utilizarea adecvată a acestui dispozitiv comunicarea între om și mașină poate deveni mai naturală și mai ușoară, cu aplicații în: învățare asistată, realitate virtuală, căutare pe web, etc.

Cu toate dificultățile existente la ora actuală date de lipsa de informații asupra cauzelor, mecanismelor și caracteristicilor semnalului de tremur în cadrul acestui grant am evidențiat existența în semnalul de tremur a informațiilor necesare discriminării între starea de oboseală și cea de odihnă și chiar mai mult între diferitele tipuri de stări de oboseală existente.

Analiza semnalului de tremur nu este o sarcină ușoară. Existența în acest semnal a diferitelor alte tipuri de semnale și influențe externe complică și mai mult procesul de analiză și clasificare. Pentru identificarea corectă și cu acuratețe a stării de oboseală multe lucruri mai trebuie făcute. Găsirea unei modalități de cuantizare a stării de oboseală care să reflecte în mod corect starea subiecților, de tip chestionar [18], [20], și utilizarea acestora numai în faza de antrenare a rețelei ar putea reprezenta o posibilă soluție. Implicarea mai multor sisteme și semnale biologice în procesul de clasificare, îmbunătățirea clasificatorilor existenți și dezvoltarea altora noi ar putea contribui la perfecționarea acestor tehnici de recunoaștere a stărilor subiecților umani.

În concluzie în acest proiect de cercetare finalizat am prezentat un număr de rezultate noi în domeniile analizei și clasificării tremurului cu aplicații în domeniile interfețelor inteligente și comunicării om-mașină.

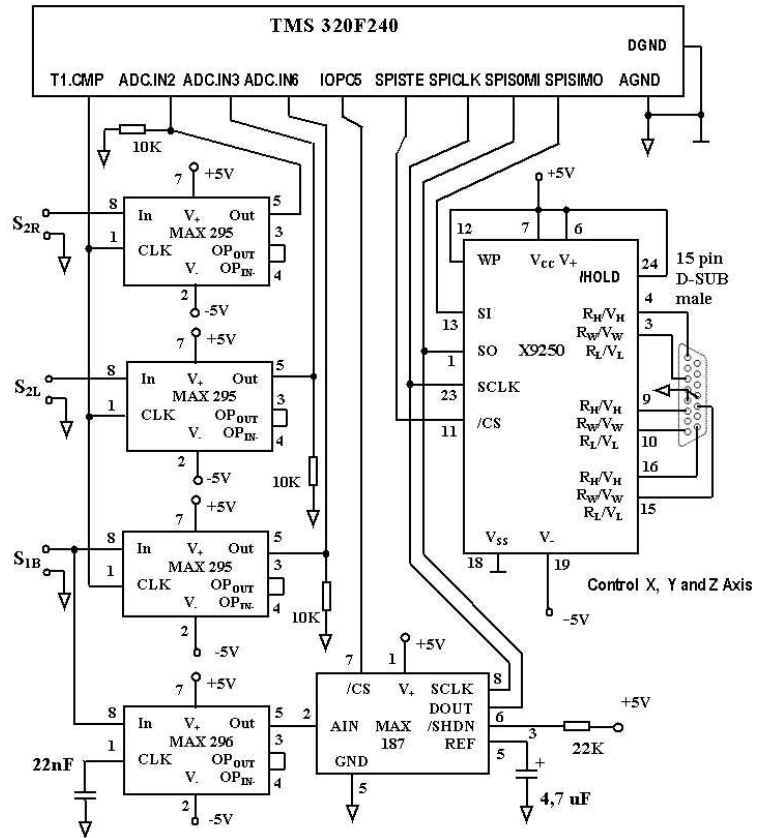
Bibliografie

- [1] A. Glaus, Assessment of fatigue in cancer and non-cancer patients and in healthy individuals, *Supportive Care in Cancer*, vol. 1, pp. 305-315, 1993
- [2] L. Dzurec, Fatigue and relatedness experiences of inordinately tired women, *Journal of Nursing Scholarship*, vol. 32, pp. 339-345, 2000
- [3] D. M. Dobrea, A New Type of Non-Contact 3D Multimodal Interface to Track and Acquire Hand Position and Tremor Signal, *Proceedings of European Conference on Intelligent Technologies*, July 20-22, Iasi, Romania, 2002
- [4] D. M. Dobrea, H.N. Teodorescu, A Fuzzy System Used to Derive Hand Movements from a New Virtual Joystick Interface Device, *Scientific Bulletin of The "POLITEHNICA" University of Timisoara*, Vol. 1, No. 47, pp. 27 – 31, 2002
- [5] H.N. Teodorescu, M. Chelaru, A. Kandel, I. Tofan, M. Irimia, Fuzzy methods in tremor assessment, prediction, and rehabilitation, *Artificial Life in Medicine*, Vol. 21, pp. 107-130, 2001
- [6] J. Timmer, M. Lauk, W. Pflieger, G. Deuschl, Cross-spectral analysis of physiological tremor and muscle activity. I: Theory and application to unsynchronized EMG, *Biological Cybernetics*, Vol. 78, pp. 349-357, 1998
- [7] H.N. Teodorescu, A. Kandel, Nonlinear Analysis of Tremor and Applications, *Japanese Journal of Medicine Electronic Biomedical*, Vol. 13, No. 5, pp. 11-20, 1999.
- [8] A.W. Anouti, C. Koller, Tremor disorders. Diagnosis and management, *West J. Med*, Vol. 162, No. 6, pp. 510-513, 1995
- [9] N.R. Pal, J.C. Bezdek, On cluster validity for the fuzzy c-means model, *IEEE Transaction on Fuzzy Systems*, vol. 3, no. 3, pp. 370-379, 1995
- [10] E. M. Smets, B. Garssen, B. Bonke, J. C. De Haes, The Multidimensional Fatigue Inventory (MFI) psychometric qualities of an instrument to assess fatigue, *Journal of Psychosomatic Research*, vol. 39, no. 3, pp. 315-325, April 1995
- [11] L. S. Aaronson, L. Pallikkathayil, F. Crighton, A Qualitative Investigation of Fatigue Among Healthy Working Adults, *Western Journal of Nursing Research*, vol. 25, no. 4, pp. 419-433 , Jun 2003
- [13] I. Gath, B. Geneva, Unsupervised Optimal Fuzzy Clustering, *IEEE Transaction on Pattern Analysis And Machine Intelligence*, vol. 11, no. 7, pp. 773-781, 1989.
- [14] L. Kaufman, P. Rousseeuw, *Finding Groups in Data: An Introduction to Cluster Analysis*, John Wiley & Sons Inc., New York, 1990.
- [15] T. D. Sanger, Optimal Unsupervised Learning in a Single-Layer Linear Feedforward Neural Network, *Neural Networks*, vol. 2, no. 7, pp. 459-473, 1989.
- [16] W. Y. Yan, U. J. Helmke, B. Moore, Global Analysis of Oja's Flow for Neural networks, *IEEE Transaction on Neural Networks*, Vol. 5, no. 5, pp. 674–683, September 1994
- [17] Dan-Marius Dobrea, Horia-Nicolai Teodorescu, Pattern Classification For Fatigue State Identification, *Fuzzy Systems and Artificial Intelligence (Reports and Letters) Journal*, Romanian Academy Publishing House, Iasi, Romania, ISSN 1016-2127, 2003 (accepted)
- [18] Toru Okuyama, Tatsuo Akechi, Akira Kugaya, Hitoshi Okamura, Yasuo Shima, Misae Maruguchi, Takashi Hosaka, Yosuke Uchitomi, Development and Validation of the Cancer Fatigue Scale - A Brief, Three-Dimensional, Self-Rating Scale for Assessment of Fatigue in Cancer, *Patients Journal of Pain and Symptom Management*, vol. 19, no. 1, pp. 5-14, January 2000

- [19] Dan-Marius Dobreă, Horia-Nicolai Teodorescu, Classifying and Assessing Tremor Movements for Applications in Man-Machine Intelligent User Interfaces, International Conference on Intelligent User Interfaces and Computer-Aided Design of User Interfaces, Madeira, Portugal, January 13-16, 2004 (accepted)
- [20] T. Chalder, G. Berelowitz, T. Pawlikowska, L. Watts, S. Wessely, D. Wright, E. P. Wallace, Development of a fatigue scale, Journal of Psychosomatic Research, vol. 37, 147-153, 1993

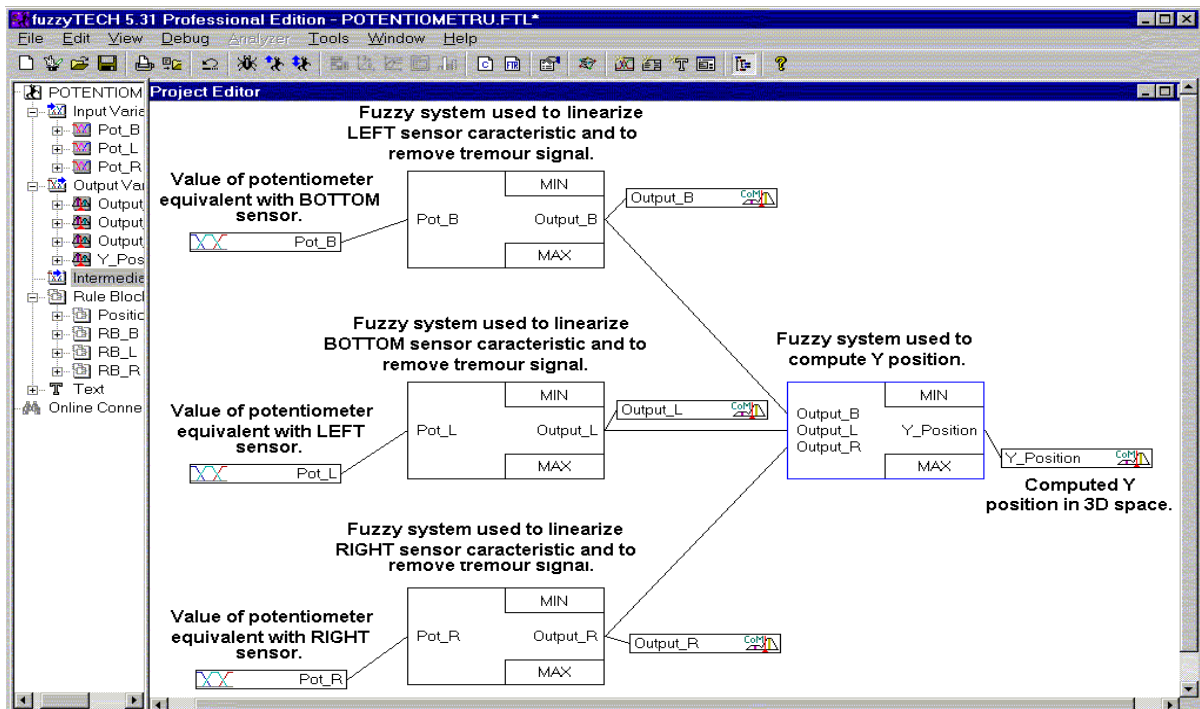
Anexa 1.

Schema sistemului de comandă a Joystick-ului virtual [5].



Anexa 2.

Structura sistemului fuzzy [6] pentru calcularea poziției mâinii pe y, conform cu Figura 4.



Suprafața caracteristică a sistemului fuzzy pentru valoare nulă a semnalului dat de senzorul cu dimensiunile cele mai mari, poziționat în partea de jos a plăcii [6].

