

CONTRIBUȚII PRIVIND PRELUCRAREA SEMNALULUI MIOELECTRIC PENTRU COMANDA SISTEMELOR PROTETICE

Teză destinată obținerii
titlului științific de doctor inginer
la
Universitatea "Politehnica" din Timișoara
în domeniul Inginerie Electronică și Telecomunicații
de către

Gavrincea Ciprian George

Conducător științific: prof.univ.dr.ing Virgil Tiponut
Referenți științifici: prof.univ.dr.ing. Adrian Graur
prof.univ.dr.ing. Gavril Todorean
prof.univ.dr.ing. Ivan Bogdanov

Ziua susținerii tezei: 06 februarie 2009

BIBLIOTECA CENTRALĂ
UNIVERSITATEA
"POLITEHNICA" TIMIȘOARA



00226729

UNIV. "POLITEHNICA"	
TIMIȘOARA	
BIBLIOTECA CENTRALĂ	
№. volum	660.652
Dulap	lit.

Cuvânt înainte

Teza de doctorat a fost elaborată pe parcursul activității mele în cadrul Departamentului de Electronică Aplicată al Universității „Politehnica” din Timișoara.

Mulțumiri deosebite se cuvin conducătorului de doctorat prof.dr.ing. Virgil Tiponut, ale cărui sfaturi, încurajări și expertiză științifică arătate de-a lungul studiilor doctorale au fost cruciale pentru finalizarea cu succes a acestei lucrări. Mulțumiri deosebite aduc și colectivului catedrei de Electronică și Calculatoare din cadrul Universității de Nord din Baia Mare pentru sprijinul acordat și încrederea manifestată. În special doresc să îi mulțumesc domnului conf. dr. ing. Ștefan Oniga pentru îndrumarea și ajutorul permanent acordate de-a lungul studiilor doctorale. Mulțumirile mele se îndreaptă către domnul șl. dr. ing Alin Tisan pentru sprijinul generos și pentru sfaturile colegiale oferite pe durata elaborării tezei. Mulțumesc comisiei pentru reviziile făcute și pentru observațiile de îmbunătățire aduse pe marginea acestui material.

În final, dar nu în ultimul rând, mulțumesc familiei mele, soției mele Oana și fiului meu Darius care m-au sprijinit și încurajat de-a lungul acestor ani și m-au ajutat să duc la bun sfârșit studiile mele doctorale.

Timișoara, 2009

ing Ciprian George Gavrincea

În memoria tatălui meu,
Mihai Gavrinca

CUPRINS

Introducere	1
1 Originea și natura semnalului mioelectric.....	5
1.1. Anatomia și structura mușchiului scheletic	6
1.1.1. Structura macroscopică.....	6
1.1.2. Structura microscopică	8
1.2. Unitatea motorie	11
1.3. Conexiunea cu sistemul nervos	12
1.3.1. Căile motricității voluntare.....	14
1.3.2. Căile motricității automate	14
1.4. Con tracția musculară.....	15
1.5. Semnalul mioelectric	18
2 Măsurarea și procesarea semnalului mioelectric.....	21
2.1. Măsurarea semnalului mioelectric	21
2.1.1. Factori perturbatori	23
2.1.2. Mioelectrodul.....	26
2.1.3. Condiționarea semnalului mioelectric	29
2.2. Platformă hardware-software pentru achiziționarea semnalului mioelectric.....	29
2.2.1. Mioelectrodul Z03	30
2.2.2. Sistem de achiziție NI USB-6009	33
2.2.3. Platforma software pentru achiziționarea semnalului mioelectric.....	33
2.3. Concluzii.....	37
3 Stadiul actual al sistemelor protetice cu comandă mioelectrică	39
3.1. Sisteme protetice comerciale cu comandă mioelectrică	40
3.1.1. Sisteme mioelectrice de comandă cu două canale	41
3.1.2. Sisteme mioelectrice de comandă cu un singur canal.....	42
3.1.3. Dispozitive terminale	44
3.2. Proteze mioelectrice mână-braț comerciale	45
3.2.1. Otto Bock Healthcare.....	45
3.2.2. Hosmer Dorrance Company	47
3.2.3. Centri AB	49
3.2.4. Liberating Technologies.....	49
3.2.5. Motion Control	51
3.2.6. RSL Steeper	52
3.2.7. Variety Ability Systems	53
3.3. Sisteme protetice experimentale cu comandă mioelectrică	54
3.3.1. Sistem de comandă mioelectrică pentru proteze mână dezvoltat de universitatea din Lund	54
3.3.2. Sistem de comandă mioelectrică pentru proteze mână dezvoltat de universitatea din New Brunswick	56
3.3.3. Southampton – Remedi hand.....	58

3.4.	Concluzii	60
4	Analiza semnalului mioelectric în domeniul frecvență-timp	61
4.1.	Analiza semnalelor nestaționare în domeniul frecvență-timp	62
4.2.	Transformata Fourier scurtă	63
4.3.	Transformata Wavelet continuă	66
4.4.	Transformata Wavelet discretă	68
4.5.	Soluții pentru implementarea hardware a algoritmului de descompunere wavelet	76
4.5.1.	Implementarea unui modul de descompunere wavelet utilizând principiul decimatorului polifazic	81
4.5.2.	Implementarea unui modul de descompunere wavelet utilizând multiplicatoare bazate pe aritmetica distribuită	85
4.6.	Studiu privind evaluarea funcțiilor wavelet optime pentru analiza semnalului mioelectric	89
4.7.	Concluzii	96
5	Rețele neuronale artificiale.....	99
5.1.	Neuronul artificial	100
5.2.	Arhitecturi de rețele neuronale	104
5.3.	Algoritmi de învățare	106
5.4.	Implementări hardware de rețele neuronale artificiale	107
5.4.1.	Implementarea analogică a rețelelor neuronale artificiale	108
5.4.2.	Implementarea digitală a rețelelor neuronale artificiale	109
5.4.3.	Implementări hardware hibride de rețele neuronale	114
5.4.4.	Implementarea în FPGA a unui neuroprocesor	115
5.5.	Concluzii	129
6	Sisteme de recunoaștere a tiparelor pentru comanda sistemelor protetice	131
6.1.	Sisteme de recunoaștere a tiparelor	131
6.1.1.	Noțiuni generale	132
6.1.2.	Structura unui sistem de recunoaștere a tiparelor	133
6.1.3.	Extragerea trăsăturilor	141
6.2.	Soluții pentru extragerea vectorului de trăsături din semnalul mioelectric de suprafață	143
6.2.1.	Analiza componentelor principale.....	143
6.2.2.	Rețele neuronale pentru analiza componentelor principale.....	146
6.2.3.	Extragerea componentelor principale din semnalul mioelectric de suprafață achiziționat la nivelul antebrațului	149
6.2.4.	Analiza componentelor independente	151
6.3.	Concluzii.....	156
7	Sistem de clasificare a semnalului mioelectric al membrului superior bazat pe rețele neuronale.....	159
7.1.	Modulul de achiziție a datelor	160
7.2.	Modulul de extragerea a vectorului de trăsături	164
7.3.	Modulul de analiză a componentelor principale	165
7.4.	Modulul de clasificare.....	166
7.5.	Sisteme mioelectrice de clasificare pentru poziția mâinii – 4 clase	167
7.5.1.	Sistem de clasificare cu două canale EMG bazat pe PCA	168
7.5.2.	Sistem de clasificare cu două canale EMG bazat pe PCA-ICA	170
7.5.3.	Sistem de clasificare cu patru canale EMG.....	173

7.6.	Sistem mioelectric de clasificare pentru poziția mâinii – 6 clase...	177
7.7.	Implementarea FPGA a sistemelor de clasificare a semnalului EMG	182
7.8.	Concluzii.....	183
8	Concluzii și contribuții.....	187
8.1.	Concluzii structurate pe capitole.....	187
8.2.	Contribuții personale ale autorului	190
	Lista completă a referințelor bibliografice consultate.....	193

Introducere

Necesitatea unor proteze care să înlocuiască mâna umană este o problemă veche. Încă din antichitate s-au creat proteze de lemn menite să readucă mai mult estetic integritatea corpului uman. Datorită războaielor, armurierii au devenit principalii fabricanți de proteze, menite să înlocuiască atât estetic cât și funcțional lipsa membrilor superioare. În secolul XIX s-au adus o serie de îmbunătățiri sistemelor protetice, dar cele mai importante îmbunătățiri au fost aduse după cel de-al doilea război mondial.

Primul sistem protetic cu comandă mioelectrică a fost realizat de către Reinhold Reiter, student fizician la universitatea din Munich. Lucrarea a fost patentată în anul 1945 și constituie prima atestare scrisă a unui sistem protetic cu comandă mioelectrică. Sistemul protetic creat de Reiter era un sistem protetic pentru braț destinat muncitorilor din fabrici. Funcționarea unui prototip a fost demonstrată la Târgul Internațional de la Hannover în 1945. Prototipul creat nu era portabil și necesita o legătură la rețeaua electrică de alimentare. Acest sistem protetic se asemena mai degrabă cu un stand de lucru pentru persoanele cu handicap. Ideea de bază consta în comanda unui braț artificial de lemn prin intermediul unui semnal mioelectric amplificat, obținut în urma unor contracții musculare. Semnalul mioelectric provenea de la o singură grupare musculară și era folosit atât pentru comanda de deschidere cât și pentru comanda de închidere a brațului artificial. Pentru a diferenția cele două operații se foloseau ca și comandă semnale mioelectrice de frecvență diferită generate în urma unor contracții musculare repetate. Prin generarea unui semnal mioelectric de intensitate mare de scurtă durată dar cu o frecvență mare se comanda deschiderea mâinii artificiale, iar prin generarea unui semnal mioelectric de mică intensitate și de frecvență mică se comanda închiderea protezei. Închiderea protezei putea fi realizată atât activ cât și pasiv după trecerea unui anumit interval de timp.

După cel de-al doilea război mondial, mai multe țări au încurajat financiar cercetările în domeniul proteticii pentru a ajuta victimele de război. Astfel după anii 50 s-au înregistrat o serie de succese în domeniul sistemelor protetice. Primul sistem protetic portabil pentru braț cu comandă mioelectrică a fost realizat de către un grup de cercetători ruși de la Academia de Științe URSS, conduși de A.Y. Kobrinski. Acest sistem protetic folosea pentru comandă două semnale mioelectrice provenite de la două grupe diferite de mușchi, unul din semnale comanda deschiderea protezei iar cel de-al doilea semnal comanda închiderea protezei. Sistemul a avut succes și a fost comercializat atât în Rusia cât și în alte țări.

La începutul anilor 70 majoritatea sistemelor protetice cu comandă mioelectrică foloseau electrozi ce necesitau regular injectarea unei paste pentru a asigura un bun contact electric cu pielea. Pe la sfârșitul anilor 70 s-a început utilizarea electrozilor uscați fapt ce a permis crearea unor sisteme protetice mai ușor de întreținut. Tot în acest timp s-au obținut îmbunătățiri legate de performanțele acumulatorilor folosiți pentru alimentarea sistemelor protetice. Acumulatorii folosiți aveau încă dimensiuni mari și erau montați extern.

Până la mijlocul anilor 70 majoritatea sistemelor protetice erau proiectate pentru adulți, iar majoritatea dispozitivelor terminale erau produse de Otto Bock. Lipsa

sistemelor protetice pentru copii se datora în special lipsei unui producător de dispozitive terminale de dimensiuni reduse. La mijlocul anilor 70 Systemteknik din Suedia a introdus pe piață primul dispozitiv terminal comercial destinat copiilor. În următorii ani piața protezelor destinate copiilor a fost ocupată treptat și de celelalte firme producătoare de sisteme protetice.

În anii 90 s-a început utilizarea produselor electronice programabile în industria protezelor cu comandă mioelectrică. Astfel au fost dezvoltate sisteme programabile de comandă ce puteau fi ajustate direct pe pacient sau care permiteau un control multifuncțional al sistemului protetic. De asemenea au fost aduse îmbunătățiri sistemelor de alimentare, noile tipuri de acumulatori permițând introducerea lor în interiorul protezelor și asigurarea unui timp de operare mai îndelungat. Sistemele de comandă au trecut de la sistemul de comandă digital ce asigura maxim 3 stări de operare (On, Off, Idle) la sistemele cu comandă proporțională ce permiteau ajustarea vitezei de acționare în funcție de intensitatea semnalului mioelectric. În această perioadă apar primele soluții de comandă bazate pe rețele neuronale artificiale. Soluțiile erau bazate pe extragerea unor trăsături din semnalul mioelectric și identificarea tipului de mișcare realizat prin utilizarea unui sistem de recunoaștere a tiparelor. Performanțele de clasificare a acestor sisteme au fost destul de scăzute, principalul motiv fiind datorat vectorului de trăsături extras.

În ultimii 10 ani sau dezvoltat sisteme de comandă bazate pe microprocesoare. Prin utilizarea a două procesoare a fost dezvoltat un sistem protetic ce permite acționarea simultană a brațului și a mâinii. Sistemul protetic era configurabil de către pacient prin intermediul unei interfețe PC. Sistemele protetice au devenit mai ușoare datorită noilor tipuri de materiale folosite în construcția protezelor și datorită noilor tipuri de acumulatori de dimensiuni reduse. De asemenea au fost realizate progrese în cazul soluțiilor de comandă bazate pe rețele neuronale artificiale. Datorită faptului că semnalul mioelectric este un semnal nestaționar, au fost propuse soluții bazate pe extragerea vectorului de trăsături în urma analizei în domeniul timp-frecvență a semnalului mioelectric. Astfel s-a demonstrat posibilitatea realizării unor sisteme de comandă, bazate pe recunoașterea de tipare, cu performanțe de clasificare ridicate. Sistemele astfel dezvoltate necesită o putere mare de procesare. Principala problemă care se ridică este legată de găsirea unei soluții viabile de implementare hardware a acestor sisteme.

Direcția de cercetare în această teză o va constitui dezvoltarea unui sistem performant de clasificare a semnalului mioelectric achiziționat de pe antebraț, și găsirea unei soluții pentru implementarea hardware a acestui sistem astfel încât să fie posibilă integrarea sistemului într-un modul de comandă al unui sistem protetic. Având în vedere direcțiile de cercetare din domeniul procesării semnalului mioelectric din ultimii 10 ani, autorul își propune analizarea unor soluții de procesare bazate pe analiza în domeniul timp-frecvență a semnalului mioelectric. Se încearcă găsirea unor soluții optime de implementarea a unui modul de analiză a semnalului mioelectric în domeniul timp-frecvență, și de realizarea a unui sistem de clasificare a semnalului mioelectric de suprafață bazat pe extragerea unui vector de trăsături obținut în urma analizei în domeniul timp-frecvență. Dezvoltarea unei astfel de platforme presupune implementarea hardware în circuite FPGA a unor module de analiză bazate pe descompunerea wavelet a semnalului mioelectric și a unor rețele neuronale artificiale destinate operației de clasificare. Autorul a ales utilizarea circuitelor FPGA ca și soluție de implementare hardware datorită gradului mare de paralelism pe care îl oferă acest tip de implementare și totodată datorită dezvoltării puternice din ultimii ani a acestor circuite. Avantajul mare a implementărilor bazate pe circuite FPGA

constă în reprogramabilitatea lor, ceea ce permite dezvoltarea unor sisteme de comandă mioelectrice ce pot fi ajustate în funcție de nevoile pacientului.

Lucrarea de față este structurată pe 7 capitole. În continuare se va face o scurtă prezentare a structurii fiecărui capitol.

Capitolul 1 prezintă informații cu privire la natura și modul de generare a semnalului mioelectric. Sunt prezentate noțiuni referitoare la structura sistemului muscular și anatomia mușchilor membrului superior. De asemenea sunt prezentate fenomenele fizice și chimice ce stau la baza producerii contracției musculare.

În capitolul 2 se prezintă modalitățile de achiziție a semnalului mioelectric. Metodele de achiziție a semnalului mioelectric pot fi împărțite în metode invazive și metode neinvazive. Deoarece metodele invazive de achiziție presupun condiții speciale de realizare și necesitatea supravegherii procesului de achiziție de către un personal medical calificat, se va pune accentul pe metodele neinvazive de achiziție. De asemenea se prezintă o soluție de achiziție dezvoltată de autor, care are la bază utilizarea unor electrozi mioelectrici activi de ultimă generație.

În capitolul 3 se prezintă o analiză a metodelor de procesare a semnalului mioelectric utilizate în sistemele protetice actuale precum și o analiză a unor metode experimentale de procesare. De asemenea este realizată o trecere în revistă a sistemele protetice comerciale existente la ora actuală.

Capitolul 4 prezintă modalitățile de analiză a semnalelor în domeniul timp-frecvență. Se pune accent pe analiza wavelet și sunt propuse soluții de implementare hardware a unor module de descompunere wavelet.

Capitolul 5 prezintă o sinteză referitoare la rețelele neuronale artificiale și la modul de implementarea hardware a acestora. Sunt prezentate soluții de implementarea hardware a rețelelor neuronale în circuite FPGA, dezvoltate de autor. Soluțiile au în vedere atât implementarea unor rețele neuronale artificiale cu învățare software cât și implementarea unor rețele cu învățare hardware.

Capitolul 6 abordează probleme legate de realizarea unui sistem de recunoaștere a tiparelor. Se pune accentul pe modul de extragere a vectorului de trăsături și pe modalitățile de reducere a dimensiunii acestuia. Sunt prezentați diverși algoritmi pentru analiza componentelor principale cât și pentru analiza componentelor independente.

Capitolul 7 are ca obiectiv elaborarea unor soluții pentru realizarea unui sistem de clasificare a semnalului mioelectric achiziționat de la antebraț. Sunt prezentate soluții pentru clasificarea a 4 respectiv 6 posturi ale mâinii utilizând semnal mioelectric achiziționat pe 2 sau 4 canale. De asemenea este analizată posibilitatea de implementare a acestor sisteme în circuite FPGA.

Elaborarea acestei lucrări s-a realizat sub îndrumarea generoasă, competentă și exigentă a conducătorului științific prof. dr. ing. Virgil Tiponuț, pentru care îmi exprim întreaga stimă și considerație și de asemenea îi adresez cele mai respectuoase mulțumiri. Realizarea sistemelor experimentale a fost posibilă datorită finanțării obținute de autor în urma câștigării unui proiect de cercetare pentru tineri doctoranzi în cadrul competiției lansată de CNCSIS în iunie 2007.

4 Introdúcere

1 ORIGINEA ȘI NATURA SEMNALULUI MIOELECTRIC

Termenul de mioelectric provine din cuvântul grecesc mys - mușchi și cuvântul electric ce definește natura electrică a semnalului. Astfel, semnalul mioelectric poate fi definit ca fiind activitatea electrică produsă prin contracțiile mușchiului. În principiu, în momentul în care un mușchi se contractă, în structura internă a mușchiului se generează un curent ionic ce poate fi detectat, din exterior, cu ajutorul unor electrozi. Amplitudinea și forma semnalului mioelectric detectat este influențat de o serie de factori cum ar fi: adâncimea la care este situat mușchiul, mărimea mușchiului, intensitatea contracției musculare, straturile de țesuturi intermediare, tipul electrozilor utilizați pentru detecție etc. Semnalul mioelectric poate fi detectat și cu electrozi ac, detecția făcându-se în acest caz în interiorul mușchiului reducându-se astfel influența factorilor perturbatori. Semnalul mioelectric își are originea în interiorul mușchiului, astfel prin intermediul electrozilor ac putem să ne apropiem mai mult de locul de origine al semnalului putând astfel obține mai multe informații legate de semnalul mioelectric generat de un anumit mușchi. Metoda de detecție cu electrozi ac este o metodă invazivă și ridică o serie de alte probleme, cea mai importantă în cazul protezelor fiind disconfortul pacientului și riscul producerii unor infecții nedorite.

Fiecare mișcare a corpului, de la o clipire a unei pleoape până la un salt în aer, este posibilă datorită mușchilor și tendoanelor - extensii ale mușchilor care joacă un rol crucial în transmiterea forțelor de contracție a mușchiului la osul asupra căruia acționează. În spatele activității musculare există mecanisme sofisticate care fac dintr-o acțiune aparent simplă, cum ar fi mișcarea capului, un proces complicat, ce implică creierul, nervii și organele de simț.

Totalitatea mușchilor din organism formează sistemul muscular. Mușchii reprezintă o componentă importantă a organismului, reprezentând aproximativ 40-45% din greutatea totală a corpului. Mușchii reprezintă un țesut înalt specializat, având ca principală funcție realizarea mișcării. Corpul uman conține peste 650 de mușchi. Toate celulele musculare se contractă prin convertirea energiei chimice în energie mecanică, utilizată pentru a realiza mișcarea.

Există trei tipuri diferite de mușchi în organism. Primul tip este reprezentat de mușchii scheletici sau voluntari. Împreună cu oasele și tendoanele, ei sunt responsabili pentru toate formele de mișcări conștiente, cum ar fi urcarea scării, și sunt de asemenea implicați în reacțiile automate denumite reflexe. Al doilea tip este mușchiul neted (denumit așa datorită aspectului său microscopic), implicat în mobilitatea organelor interne, cum ar fi intestinele sau vezica urinară. Al treilea tip este mușchiul cardiac, care reprezintă constituentul principal al inimii.

Mușchii scheletici constituie componente active ale sistemului locomotor. Sunt mușchi striati voluntari. Contractia acestora se efectuează la comanda directă a sistemului nervos central. Mușchii scheletici mențin poziția corpului prin contracții tonice (tonus muscular) și asigură deplasarea prin contracții rapide determinate de impulsurile provenite de la sistemul nervos.

1.1. Anatomia și structura mușchiului scheletic

Mușchii scheletici se numesc striați datorită faptului că, la examinarea microscopică, aranjamentul fibrilar care îi formează le dă un aspect dungat. Ei își exercită acțiunea prin scurtarea lungimii, un proces denumit contracție. Acești mușchi trebuie să fie capabili să producă o contracție rapidă, explozivă, de tipul celei pe care o efectuează mușchii membrelor inferioare în timpul unei sărituri, și de a menține un tonus constant pentru a păstra corpul într-o postură normală. Mușchii voluntari se găsesc în întreg organismul, reprezentând o proporție de 25 la sută din greutatea corpului, chiar și la un nou născut. Se comportă ca resorturi atașate de diferite puncte ale scheletului, determinând mișcarea anumitor oase, de la micul mușchi stapedius, care acționează asupra scăriței, un os mic al urechii medii, până la mușchiul gluteus maximus (marele fesier), care formează majoritatea masei fesiere și controlează mișcările articulației șoldului.

Mușchii scheletici sunt alcătuiți, în mare, din fibre musculare striate și țesut conectiv. Sunt mușchi voluntari, care se inseră pe oase și care realizează mișcarea corpului. Aceste fibre musculare au un aspect striat, văzute la microscop (vezi fig. 1.1)[165]. Acest aspect este dat de distribuția miofibrilelor (filamentele de actină și miozină) din structura fibrei musculare, dispuse astfel încât, între unitățile funcționale ale celulei musculare (sarcomere) apar benzi întunecate.




Figura 1.1 Imagine microscopică a mușchiului striat [165]

Executând funcții complexe, mușchiul striat dezvoltă un metabolism activ, ceea ce necesită o irigare sanguină bogată. Rețeaua capilară din jurul fibrelor musculare are o suprafață de 4 – 6 ori mai întinsă decât cea tegumentară. Culoarea roșie a mușchilor se datorează rețelei sanguine aflate în structura mușchiului. Această rețea sanguină are rolul de a asigura energia necesară pentru realizarea contracției musculare și totodată rolul de a elimina „resturile metabolice” produse în urma procesului de contracție musculară. Vasele sanguine aflate în compoziția mușchilor scheletici prezintă un grad ridicat de flexibilitate pentru a-și putea adapta dimensiunile la schimbările de formă ale mușchilor. În continuare va fi prezentată structura macroscopică și structura microscopică a mușchilor scheletici. Totodată vor fi prezentate și fenomenele care stau la baza efectuării contracțiilor musculare.

1.1.1. Structura macroscopică

Mușchii scheletici se inseră pe oase, pe care le pun în acțiune. Un mușchi are două sau mai multe puncte de inserție, dintre care unul este de origine, iar celelalte

sunt de inserție. Punctul de inserție este reprezentat, de cele mai multe ori printr-un tendon. Între ele se găsește masa (corpul) mușchiului.

După dispoziția fibrelor masei musculare în raport cu tendonul, mușchii scheletici se împart în:

- mușchi fuziformi, cu fibre lungi, paralele pe lungime, permițând mișcări diverse, dar cu forță scăzută (sternocleidomastoidian, croitor etc.);
- mușchi penaji, cu tendonul în centru sau lateral și fibrele musculare dispuse oblic pe acesta și pe lungime, executând mișcări cu forță crescută (brahial etc.);
- mușchi cu mai multe origini și un singur tendon terminal (biceps, triceps, cvadriiceps, sternocleidomastoidian). Sunt mușchi mari, puternici;
- mușchi cu intersecții tendinoase (dreptii abdominali).

În raport cu modul de funcționare, mușchii pot fi:

- agoniști, care realizează aceeași mișcare (apropie două oase),
- antagoniști, care participă la mișcări pe aceeași direcție, dar în sensuri opuse (unul apropie două oase, celălalt le depărtează; de exemplu, bicepsul și tricepsul).

La exterior, mușchii prezintă o teacă membranoasă, numită epimisium. Ea îi separă de organele învecinate, făcând însă corp comun cu țesutul conjunctiv subdermic, periost, aponevroze, tendoane etc.

În interior, mușchiul prezintă o structură fasciculată, fiecare fascicul fiind delimitat de o teacă colagenică – conjunctivă, perimisium. Fasciculele sunt împărțite în fibre acoperite de o teacă conjunctivă, endomisium. Aceste trei teci au legătură între ele, fiind mai bine vizibile la mușchii biceps, triceps, cvadriiceps etc. Ele sunt constituite din fibre colagenice, reticulare, elastice, celule fibroblastice, histiocite, adipocite etc. Fibrele musculare ocupă volumetric în jur de 70 – 85% din mușchi, iar tecile conjunctive cam 15 – 30%[112].

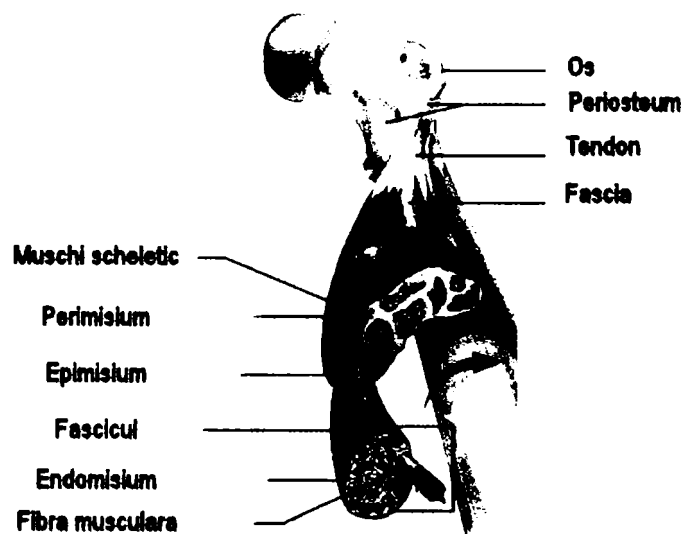


Figura 1.2 Imagine macroscopică a mușchiului striat [112]

Fibrele pot traversa longitudinal întreg mușchiul, sau se pot opri undeva în masa acestuia. În general, circa 98% din fibre sunt inervate de o singură placă neuro-musculară, situată la mijlocul acestora

1.1.2. Structura microscopică

Fibra musculară este o celulă alungită, cu fibrile contractile în citoplasmă. Ea este unitatea morfo-funcțională a mușchiului. Are o formă fusiformă, conică, cvasicilindrică și dimensiuni de ordinul a 1mm (mușchiul scăriței) – 34 cm (mușchiul croitor) lungime și 10 – 100 micrometri diametru. De obicei, fibrele musculare sunt mai groase la bărbat decât la femeie și la persoanele cu o structură musculară dezvoltată față de persoanele cu structură musculară mai slab dezvoltată. Dezvoltarea mușchiului se face prin îngroșarea fibrelor, ca urmare a creșterii cantității de sarcoplasmă și a conținutului fibrilar.

Fibra musculară este alcătuită din: membrană, numită sarcolemă, citoplasmă (sarcoplasma), și aparat fibrilar.

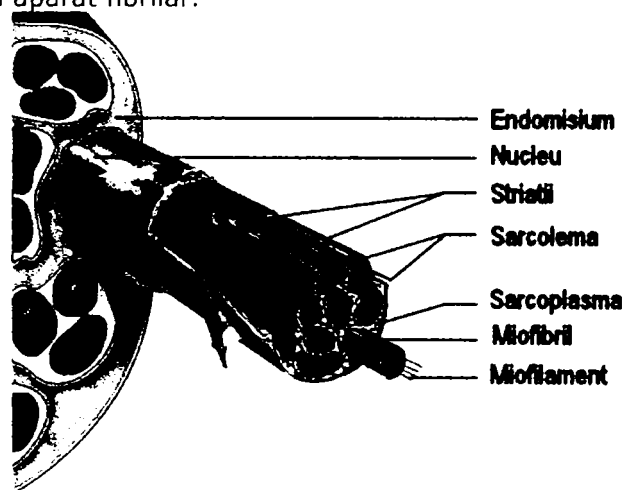


Figura 1.3 Structura internă a fibrei musculare [165]

Sarcolemă este o membrană aproape continuă, ce prezintă un orificiu de intrare a fibrei nervoase. Se constituie dintr-un complex elastic, subțire, bistratificat. Stratul intern, mai subțire, se numește membrană plasmatică, iar cel extern, mai gros, numit membrană externă, are o elasticitate foarte mare.

Sarcolemă se continuă cu țesutul conjunctiv dintre fibrele musculare, iar în interior se conectează cu membranele Z ale miofibrilelor. Funcțional, sarcolemă stabilește legătura dintre interiorul și exteriorul celulei, prin intermediul sistemului de canalicule T, importantă cale pentru schimburile de substanțe cu lichidul intercelular. De asemenea, sistemul T deține rolul primordial de transmisie a impulsului nervos de la placa neuro-musculară la miofibrile. Sarcoplasma este citoplasma celulară, formată din miofibrile și citoplasmă necontractilă.

Miofibrilele formează ionoplasma. Ele ocupă cam 60 – 80% din masa și volumul fibrei, prezentându-se ca filamente de 1 – 3 micrometri diametru și de lungime egală cu cea a fibrei. Miofibrilele nu posedă membrană proprie. Spațiul dintre ele este ocupat de citoplasmă, mitocondrii și reticul endoplasmatic. Într-o fibră se

găesc în jur de 1000 - 1100 de miofibrile, care se dispun paralel pe axul lung al acesteia. Astfel, fibra capătă un aspect striat longitudinal[112].

Structura lor este compusă din succesiuni de discuri formate din material proteic cu indice de refracție diferit (luminos sau întunecat) de-a lungul fibrelor, ceea ce le conferă aspectul striat transversal. Discurile sau benzile luminoase, clare, izotrope, monorefringente în lumină polarizată sunt mai subțiri și poartă denumirea de benzi I, iar cele anizotrope, întunecate, birefringente, mai groase, se numesc benzi A.

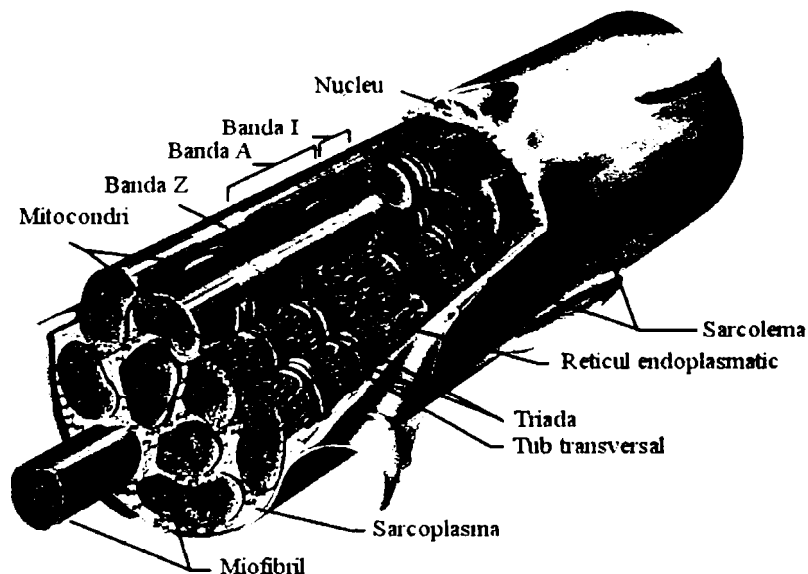


Figura 1.4 Structura internă a fibrei musculare [165]

Benzile A sunt împărțite în două segmente egale de o bandă clară, H (Hensen), iar cele I de o bandă întunecată Z (Zwischenscheibe, numită și Stria Amici). Aceasta traversează toate miofibrilele, atașându-se la sarcolemă. Rolul său este de a menține raporturile interfibrilare. În timpul relaxării exagerate a fibrelor, în centrul zonei H, clare, apare membrana M, întunecată, unde se prind filamentele de miozină. De-o parte și de alta se găsesc două arii mai luminoase, numite liniile L.

Între două membrane Z (între centrul zonelor luminoase I) se găsește un sarcomer. El este unitatea morfo-histo-funcțională a miofibrilelor. În general, lungimea sarcomerilor ajunge până la 2,5 micrometri. Într-o fibră sunt cam 10 - 20 de milioane de astfel de unități.

Filamentele de miozină participă la formarea discului întunecat A, având în mijloc o umflătură (membrana M). Au circa 140 - 160 de Angstromi în diametru și lungimi de 1,6 micrometri. Sunt constituite din câte 200 de molecule de miozină, aranjate într-o rețea hexagonală, densă.

Filamentele de actină formează discul clar I, inserându-se cu un capăt pe membrana Z, iar cu celălalt intercalându-se printre filamentele de miozină, oprindu-se în apropierea zonei H. Diametrul lor ajunge până la 50 - 70 de Angstromi, iar lungimea la 2,05 micrometri. Sunt mai puțin dense decât filamentele de miozină. Pe sarcomer, se găsesc circa 1200 molecule, provenind din două filamente.

Fiecare miofibrilă are în componență aproape 1500 de filamente de miozină și 3000 de filamente de actină, fiecare filament de miozină având în jur 6 filamente de actină, iar unul de actină 3 de miozină. Raportul numeric este de 1/2.

Cu excepția zonei H, discul A este constituit din filamente groase de miozină și subțiri de actină. Zona clară H constituie elementul elastic al miofilamentului, unde are loc extensia acestuia. Este formată din filamente de miozină și unul extensibil, proteic, S, ce pare a unii filamentele de actină între ele.




Figura 1.5 Structura internă a fibrei musculare [165]

Discul A este mai bogat în substanțe minerale comparativ cu discul I; astfel, primul conține în special Ca^{2+} , Mg^{2+} , K^+ , iar cel de-al doilea creatinfosfat (CP, CF), acid adenozintrifosforic (ATP), acid adenozindifosforic (ADP), lipoide etc. Glicogenul, principala substanță de conversie energetică a mușchiului, atinge concentrații considerabile în sarcoplasmă și discul A, care, se pare, exercită o acțiune ATP-azică (de descompunere asupra ATP), generând energia necesară contracției[47].

Sarcoplasma nediferențiată se prezintă sub forma unui gel amorf, roșu. Biochimic, constituie un amestec de ioni: K^+ , Na^+ , Ca^{2+} , Mg^{2+} dizolvați în apă, substanțe organice, necesare metabolismului celular: enzime proteice și mitocondrii, aflate în strânsă legătură cu filamentele de actină. Sarcoplasma nediferențiată ocupă cam 20 - 30% din masa celulară. Ea cuprinde două fracțiuni:

- sarcoplasma interfibrilară, bogată în organite celulare (mitocondrii, fragmente de reticul endoplasmatic, incluziuni organice: proteine, aminoacizi liberi, acizi grași liberi, miogen, globuline, glicogen, enzime etc.)
- sarcoplasma periferică, unde se găsesc mitocondrii, nucleu, aparat Golgi, reticul endoplasmatic, glicogen, lipopigmenți, ATP etc.

Reticulul endoplasmatic are doi componenți: reticulul sarcoplasmatic (RS), identic cu al celorlalte celule, și sistemul T, tubular transversal, ca o continuare a membranei și a spațiului intercelular înăuntrul celulei.

Tuburile sistemului T învâluie fiecare miofibrilă printr-o formațiune inelară la nivelul membranei Z, sau la nivelul joncțiunii discului I cu discul A, cu câte două inele pe fibră. Tuburile au conductanțe scăzute pentru Cl^- , Na^+ , K^+ , comparativ cu membrana celulară.

După cantitatea de sarcoplasmă, mioglobină („hemoglobina musculară”), rezerva de oxigen, avem următoarele tipuri de fibre musculare:

- fibre roșii, cu un conținut mai ridicat în mioglobină, cu contracții lente (peste 3,5 ms), puternice, funcționând aproape continuu și obosind

greu (mușchii antigravitaționali, cu metabolism preponderent oxidativ);

- fibre albe, cu numeroase miofibrile, mai sărace în mioglobină; au contracții rapide (sub 3,5 ms) și obolesc ușor. Au metabolism preponderent glicolitic, anaerob.

Nu există mușchi alcătuit doar din fibre roșii sau albe, dar există mușchi constituiți predominant din fibre roșii sau albe. Astfel, extensorii au în special fibre roșii, iar flexorii mai multe fibre albe.

1.2. Unitatea motorie

Fibrele musculare sunt inervate de motoneuronii din măduva spinării. Filetele nervoase (axonii) a acestor motoneuroni se pot ramifica de mai multe ori și vor inerva mai multe fibre musculare. Un singur α -motoneuron și toate fibrele musculare pe care le inervează formează o unitate motorie (UM).

Omul are aproximativ 250 milioane fibre musculare dar numai aproximativ 420000 motoneuroni. Un calcul simplu va arăta că un neuron motor va inerva în medie 600 fibre musculare. La nivelul mușchilor mari unitatea motorie conține până la 2000 fibre musculare, în timp ce la nivelul mușchilor oculari doar aproximativ 10 fibre musculare. Primordial în mărimea unității motoare este funcția mușchiului respectiv. Mușchii a căror activitate necesită forță mare dar coordonare fină redusă sunt organizați în unități motorii mai mari. Mușchii ce realizează mișcări foarte fine sunt organizați în unități motorii mai mici. Deși fibrele musculare aferente unei unități motorii tind să fie localizate aproape una de cealaltă, întotdeauna există suprapuneri între unitățile motorii [165].

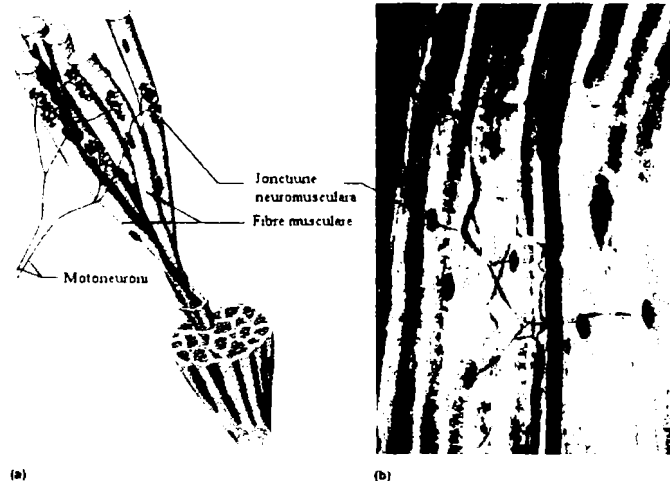


Figura 1.6 Structura unei unități motorii [165]

Activarea unei unități motorii produce contracția tuturor fibrelor musculare aferente și astfel unitatea motorie reprezintă unitatea funcțională cea mai mică pe care sistemul nervos o mai poate comanda separat. Suma activității electrice create de toate unitățile motorii activate reprezintă semnalul mioelectric.

Principalele mecanisme de reglare a forței musculare ale unui singur mușchi sunt:

- creșterea numărului de unități motorii active (recrutare spațială)
- creșterea frecvenței de descărcare (recrutare temporală)

Recrutarea spațială reprezintă principalul mecanism de creștere a forței musculare. Unitățile motorii dintr-un mușchi nu sunt recrutate aleator ci pe baza „principiului de mărime”. Unitățile motorii mici (cele care conțin mai puține fibre musculare inervate) au un neuron motor cu potențial de prag mai apropiat de cel de repaus. Din această cauză ele vor fi recrutate inițial. Pe măsură ce forța necesară crește, în mod progresiv, tot mai multe unități motorii vor fi racolate. Acest sistem are o semnificație aparte. În cazul în care mișcarea implică forță mică dar coordonare mare abilitatea de a recruta doar câteva fibre musculare permite această mișcare fină (scris, jocul la pian, etc.). Pe măsură ce crește necesarul de forță vor fi recrutate și unități motorii mai mari.

Recrutarea temporală apare de obicei doar atunci când aproape toate unitățile motorii au fost recrutate. Unitățile lente (de obicei cele mici) operează într-un interval de frecvență mai joasă. În cadrul acestui interval de frecvență, forța generată de unitatea motorie crește odată cu creșterea frecvenței stimulării. Dacă un potențial de acțiune stimulează aceeași fibră musculară înainte ca aceasta să se relaxeze apare fenomenul de sumație. Altfel spus, prin această metodă, frecvența de stimulare afectează forța musculară a fiecărei unități motorii în parte.

Pentru un mușchi intensitatea efortului este determinată prin forță (contractie) și apoi prin frecvență (număr de contracții pe minut). În mușchiul încă neobosit întotdeauna vor fi recrutate numărul minim suficient de unități motorii pentru a produce forța necesară. Inițial aceasta poate fi atinsă fără activarea unităților motorii mari. Totuși, pe măsură ce apare oboseala musculară la nivelul unităților motorii mici și acestea nu mai pot realiza necesarul de forță, tot mai multe unități motorii mari vor fi racolate. Consecutiv pentru realizarea aceleiași forțe în mușchiul obosit vor fi activate un număr mai mare de unități motorii. Foarte interesantă este și adaptarea la efort a atleților. Atleții care participă la sporturi ce necesită forță explozivă (sprint, ridicarea greutății, etc.) au abilitatea de a recruta aproape simultan toate unitățile motorii. La atleții care participă la probe de efort susținut (maraton) recrutarea devine asincronă. Deși efortul este continuu, în timp ce unele unități motorii lucrează celelalte sunt în repaus, prin aceasta se realizează o perioadă de recuperare ce permite un efort pe o perioadă mai susținută.

1.3. Conexiunea cu sistemul nervos

Placa motorie reprezintă “sinapsa” dintre terminațiile axonale ale neuronilor motori și membrana fibrei musculare. Mediatorul chimic caracteristic plăcii motorii este acetilcolina. În sarcolemă există receptori de acetilcolină (canale de sodiu) care vor iniția depolarizarea membranei și declanșarea potențialului de acțiune. Potențialul de acțiune difuzează prin membrană, prin tubulii T și activează canalele de Ca^{2+} . În prezența ionilor de Ca^{2+} este inițiată contracția musculară.

La nivelul plăcii neuromotoare, sarcolema unei fibre musculare prezintă mai multe adâncituri în care pătrund butonii ramificațiilor axonice ale unui singur motoneuron. Butonii terminali conțin vezicule cu acetilcolină. Între membrana butonului terminal și sarcolemă există un spațiu foarte îngust numit fantă sinaptică.

Controlul mișcării este realizat de sistemul nervos somatic sau al vieții de relație. Neuronul este unitatea anatomo-funcțională a sistemului nervos și este alcătuit din corpul celular și prelungirile acestuia: axonul (prelungire prin care influxul

nervos pleacă de la celulă) și dendrite (prelungiri scurte prin care influxul vine la celulă). Fibra nervoasă este continuarea axonului și este alcătuită dintr-un fascicul de neurofibrile numit cilindru care poate fi învelit sau nu într-o teacă de mielină. Prin intermediul fibrelor se realizează legătura dintre neuroni și poartă denumirea de sinapsă.




Figura 1.7 Structura plăcii neuromotoare [165]

Circulația informației nervoase la nivelul sinapsei se realizează într-o singură direcție: de la cilindru spre dendrite și corpul celular. Energia care circula de-a lungul fibrelor nervoase poartă denumirea de influx nervos. După sensul impulsului se deosebesc două tipuri de neuroni: neuron aferent care conduce impulsul de la periferie către centru și neuron eferent care conduce impulsul nervos de la centrul nervos către periferie.

Prelucrarea informației și obținerea semnificației mesajului rămân procesele cele mai obscure ale funcției sistemului nervos central. De multe ori, creierul nu poate stabili cu exactitate gradul de adevărat sau de fals al informațiilor de care dispune și devine obligat să lucreze, pe lângă aceste valori, și cu valoarea de posibil, trecând de la logica bivalentă la o logică trivalentă. Pentru a funcționa astfel, sistemul nervos central este constituit din rețele și centri neuronali în care se leagă tot ce se poate lega și în care totul se leagă de tot. Rețelele sunt concepute ca o populație uniformă, îndeplinind aceeași funcție, dar pe căi multiple și diferite. Complexitatea funcției rețelelor reiese din multitudinea conexiunilor fiecărui neuron. Așadar, informațiile excitatorii sau inhibitorii circulă printr-un ansamblu de căi nervoase, realizându-se numeroase tipuri de rețele, al căror element fundamental este neuronul. Existența neuronilor intercalari (de asociație) interpuși între neuronul senzitiv (locul de captare a informațiilor) și neuronul motor (locul de răspuns) sugerează faptul că semnalul care intră în sistemul nervos central este supus unui proces de dispersie, înainte de a atinge neuronul motor. Prin acest fenomen de dispersie, informația intră în diverse rețele neuronale, este prelucrată din puncte de vedere diverse și diferite, conducând la emiterea comenzii optime.

Există două tipuri de rețele neuronale :

- rețele paucineuronale, care sunt alcătuite din 2 neuroni, se găsesc la nivelul măduvei spinării și a sistemului nervos vegetativ ;
- rețele multineuronale, alcătuite din mai mulți neuroni, se găsesc în special la nivelul scoarței cerebrale, conțin, de regulă, un număr imens de neuroni, iar activitatea lor se poate studia numai probabilistic (statistic).

Calea nervoasă este în esență o înlanțuire de neuroni. Căile nervoase sunt de două tipuri: ascendente (senzitive) și descendente (motoneuronii). Căile ascendente conduc sensibilitatea tactilă fină și grosieră, termică, dureroasă, proprioceptivă conștientă, inconștientă, visceroreceptivă. Căile descendente sunt cele ale motricității voluntare (inițiază mișcări fine, voluntare) și involuntare (reglează și controlează tonusul postural, mișcări automate, atitudini automate)

Căile descendente sau motorii cuprind: un centru cortical care elaborează influxul nervos; o succesiune de neuroni interconectați și plăcile neuromotorii. Succesiunea de neuroni care intră în componența căii descendente este formată dintr-un neuron motor central din scoarța cerebrală de unde pornește calea efortivă și un neuron motor periferic care poate fi localizat în trunchiul cerebral sau în măduva spinării. Plăcile neuromotorii reprezintă locul la nivelul căruia influxul nervos este transformat în incitație motorie producătoare de mișcare.

Căile motorii sunt de două categorii:

- căi ale motricității voluntare;
- căi ale motricității automate sau extrapiramidale

Neuronul motor periferic este supus influențelor centrilor superiori. Prin control direct este influențat neuronul motor alfa, iar prin control indirect este influențat neuronul motor gamma, care prin intermediul buclei gamma întreține starea de excitabilitate a motoneuronului alfa.

1.3.1. Căile motricității voluntare

Căile motricității voluntare conțin numai doi neuroni: central și periferic. În funcție de localizarea neuronului motor periferic, acestea sunt:

- calea motricității voluntare pentru musculatura gâtului, trunchiului și membrilor;
- calea motricității voluntare pentru musculatura capului și a unor părți ale mușchilor gâtului.

Neuronii motorii centrali sunt reprezentați, în proporție de 40%, de celulele piramidale gigante Betz din aria motorie principală 4, de neuronii din pătura piramidală internă a ariilor 6, 10, 45, și 46 ale lobului frontal, dar și din neuroni din pătura piramidală internă a lobilor occipital și parietal. Neuronii motorii periferici sunt situați în cornul anterior al măduvei spinării. Axonii acestora, prin intermediul rădăcinii anterioare a nervului spinal ajung la mușchii striați. Neuronii somatomotori α și β sunt situați în capul cornului anterior. Axonii acestora se termină în plăcile motorii ale mușchilor striați. Acești neuroni primesc aferențe din fasciculul piramidal, din fasciculele extrapiramidale și de la ganglionii spinali. Neuronii γ sunt așezați în capul cornului anterior. Axonii acestora se termină în plăcile motorii ale porțiunilor contractile ale fusurilor neuromusculare. Primesc aferenți de la fasciculele extrapiramidale (mai ales reticulospinale) și de la ganglionii bazali.

1.3.2. Căile motricității automate

Căile motricității automate sau extrapiramidale reprezintă un sistem de reglaj sau de control al mișcării care asigură execuția precisă, armonioasă a mișcării comandate voluntar. Pentru realizarea acestui scop, sistemul extrapiramidal intervine în reglarea tonusului muscular, a automatismului muscular și a reflexelor somatice.

Originea căilor extrapiramidale este în scoarța cerebrală. De aici pleacă fascicule descendente care fac legătura cu o serie de stații de releu subcorticeale, de la

care pleacă fascicule spre zonele de origine și spre neuronii periferici. Periferic, căile extrapiramidale se descarcă atât pe neuronul somatomotor alfa, cât și gama.

Tonusul muscular este de origine reflexă și are rolul de a pune la dispoziția organismului, în cele mai bune condiții, o modalitate de expresie somatică precisă și eficace. Tonusul muscular asigură statica de ansamblu a corpului și adaptează în permanență poziția corpului în funcție de activitatea motorie comandată. Acesta susține în permanență acțiunea în diferitele sale faze de execuție, adică în fazele de stabilizare, de desfășurare și de menținere a atitudinii finale. Așadar, există trei categorii de tonus muscular, strâns împletite în cursul executării unei activități: tonusul de fond, tonusul de execuție și tonusul postural.

1.4. Contrakția musculară

Mecanismul contracției a fost succesiv obiectul a numeroase ipoteze. Cea mai unanim recunoscută explicație este dată de așa zisa teorie a „mecanismului glisant”, care, emisă într-o formă inițială de H.E. Huxley în 1964, a fost ulterior completată cu numeroase îmbunătățiri. În emiterea teoriei sale, Huxley a plecat de la câteva observații electrono-optice efectuate pe mușchi la diferite grade de contracție. Astfel, s-a observat că între filamentele groase de miozină și cele subțiri de actină se formează în timpul contracției punții transversale, la care participă proiecțiile laterale ale miozinei ce își modifică poziția și se fixează pe actină. Astfel de punți transversale nu apar în zonele în care actina și miozina nu se suprapun. Scurtarea sarcomerului se realizează prin alunecarea treptată a filamentului de actină spre interiorul discului întunecat. Forța ce determină această alunecare se aplică repetitiv la locul de interacțiune a punții transversale cu actina. Deplasarea se realizează prin tracțiuni și desprinderi succesive de mică amploare care, prin sumare, determină mișcarea de ansamblu.

Există două tipuri de contracție musculară, și anume :

- contracția izometrică: modifică tensiunea mușchiului, dar lungimea rămâne constantă. Caracterizează musculatura posturală. Nu produce lucru mecanic, dar produce căldură.
- contracția izotonică: este aceea în care tensiunea rămâne constantă, dar variază lungime. Este caracteristică majorității mușchilor scheletici. Realizează lucru mecanic și produce mișcare.

În activitatea obișnuită, mușchiul trece prin faze de contracție izometrică și izotonică, inițierea oricărei contracții fiind, de obicei, izometrică. Oboseala musculară se manifestă prin diminuarea capacității de lucru muscular. Se datorează scăderii randamentului energetic, acumulării de acid lactic, lipsei de O₂, epuizării substanțelor macroergice și a mediatorilor chimici la nivelul plăcilor motorii.

Energia chimică eliberată în timpul contracției este convertită circa 30% în lucru mecanic și circa 70% în energie calorică. Mușchii sunt principalii generatori de căldură, atât prin tonusul muscular, cât și prin contracții mici și frecvente numite frisoane, declanșate în mod reflex la expunerea la frig. Deosebim o căldură de repaus, componentă a termogenezei, degajată tot timpul de mușchi, și o căldură de activitate, eliberată în timpul contracției[47].

Tonusul muscular este starea de contracție permanentă, dar parțială, a musculaturii. În fiecare moment, un mic număr de fibre musculare din totalul fibrelor unui mușchi se află în contracție și determină o stare de ușoară tensiune a musculaturii, caracteristică pentru stare de veghe. Prin contracția succesivă a unor grupe de fibre se asigură permanența tonusului muscular, cu rol esențial în

menținerea posturii normale, în mimică, în termoreglare etc. Tonusul muscular, fenomen de natură reflexă, este menținut de impulsuri provenite de la sistemul nervos central prin nervii motorii, pe baza informațiilor primite de la proprioceptori.

Fibra musculară se supune legii "totul sau nimic", dar mușchiul are contracție gradată. Gradarea se realizează prin creșterea numărului unităților motorii activate, în funcție de intensitatea și frecvența stimulilor. Forța de contracție este maximă când intră în activitate toate fibrele mușchiului respectiv și variază între 3,6 - 10 kg/cm².




Figura 1.8 Exemplificarea fenomenului de transmitere a impulsului electric prin mușchi [165]

Declanșarea procesului contractil propriu-zis este precedată de o serie de fenomene:

- generarea mesajului contractil prin acțiunea unor factori endogeni (neuro-umoral-metabolici) sau exogeni (diversi stimuli somato-senzitivo-senzoriali) pe cale reflexă sau voluntară;
- conducerea lui pe caile motorii la ansamblul unităților motorii;
- traversarea barierei neuro-musculare prin fenomenele de transmisie colinergică;
- depolarizarea sarcolemei musculare, cu generarea unui potențial de acțiune propagat.

Ulterior, prin mecanismul de cuplare a excitației cu contracția se antrenează o serie de fenomene mecano-chimice ale ciclului contractie-relaxare, care utilizează energia furnizată de sistemul energogen contractil în prezența ionilor de calciu. Aceste fenomene sunt însoțite de modificări ultrastructurale ale proteinelor contractile miofibrilare, manifestări energetice, mecanice, termice și acustice.

Faza postcontractilă de relaxare este însoțită de fenomene legate de : pomparea ionilor de Ca în reticulul sarcoplasmatic; eliminarea interacțiunilor proteinelor contractile; refacerea rezervelor energetice fosfat-macroergice; plățirea unei datorii de oxigen contractate în suprasolicități epuizante.

Atât fibrele musculare cât și cele nervoase prezintă o serie de caracteristici comune. Din punct de vedere electric, ambele pot fi considerate ca fiind structuri tubulare ce conțin în structură, o membrană cu permeabilitate selectivă. Permeabilitatea sarcolemei asigură o repartiție ionică particulară în compartimentele

intra și extracelulare, conferind polaritatea electrică ce caracterizează majoritatea structurilor excitabile.

Consecința directă a permeabilității membranei selective și întreținută de pompele ionice biologice de Na și K, este polaritatea electrică, care stă la baza genezei potențialului membranar de repaus de aproximativ -90 mV , precum și la impunerea unui anumit grad de excitabilitate a fibrei musculare.

Impulsul nervos ajuns în membrana butonului terminal determină descărcarea de mici cantități de acetilcolină în fanta sinaptică. Acetilcolina se fixează pe sarcolemă și o depolarizează, generând un potențial local terminal pe placa neuromotorie. Când acest potențial atinge un nivel critic, apare potențialul de acțiune (aprox. $+35\text{ mV}$) care se propagă în sarcolemă în toate direcțiile, determinând excitarea simultană a tuturor fibrelor ce alcătuiesc unitatea motorie.

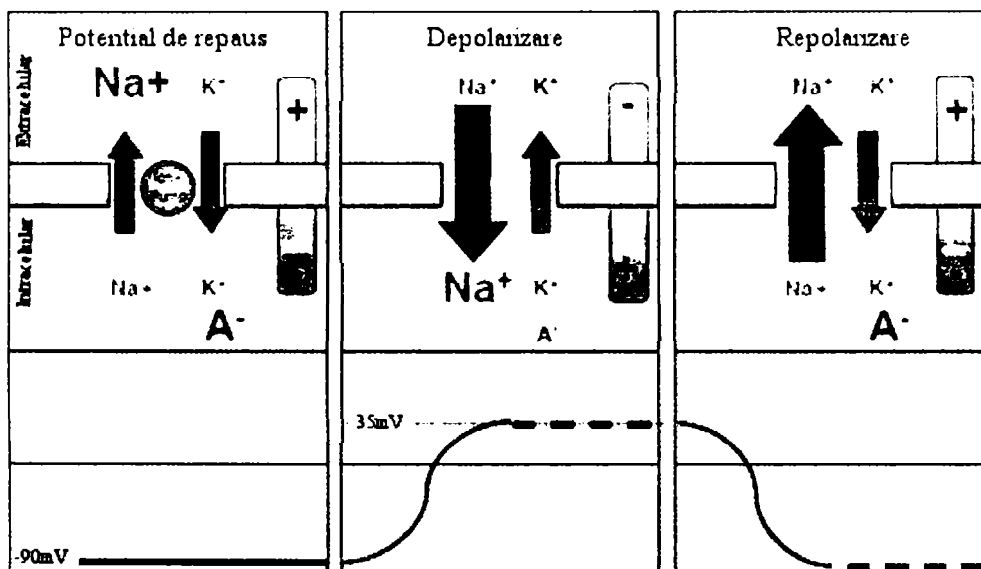


Figura 1.9 Exemplificarea grafică a fenomenelor ce intervin în procesul de generare a potențialului de acțiune [196]

Microscopia electronică arată că între capetele tubilor T și cisternele terminale există un spațiu foarte mic (5 nm). Chandler și Schneider (1976) au sugerat că atunci când potențialul de acțiune ajunge la nivelul tubilor T se produce un transfer de sarcini, care determină modificări conformaționale ale cisternelor terminale și deschiderea canalelor ionice cu eliberarea masivă a ionilor de calciu din cisterne în sarcoplasmă. În momentul depolarizării tubului în T are loc un transfer de sarcină cu modificări de conformație și deschiderea canalelor. Sunt generați curenți ionici ce permeabilizează membrana cisternei și determină eliberarea de Ca depozitat.

Creșterea concentrației ionilor de Ca antrenează punerea în joc a unor procese mecano-chimice care stau la baza activării aparatului contractil și a sistemului energogen: legarea Ca de troponina C, mobilizarea moleculei de tropomozina la nivelul filamentelor subțiri, interacțiunea actinei cu miozina și contractia propriu-zisă. Acest fenomen poartă numele de pompa de Ca²⁺.

Lipsa complexului calciu – troponina C și, deci, prezenta poziției inhibitorii a tropomiozinei de actină blochează interacțiunea actină-miozină, aspect caracteristic

660.652
UNIV. "POLITEHNICA"
TIMIȘOARA
BIBLIOTECA CENTRALA

stării de relaxare. Prezența calciului drept cuplant al excitației la contracție este explicată prin intervenția sa mediată de troponina C via tropomiozina în declanșarea interacțiunilor ciclice actina-miozina, care au făcut obiectul unor mult - controversate teorii ale contracției musculare (teoria vâsco-elastică, teoria corpului elastic, teoria filamentului continuu, teoria glisării filamentelor sau cea a punților transversale – model Huxley-Simmons).

Odată ce concentrația ionilor de Ca în afara reticulului sarcoplasmatic a scăzut sub un nivel prag, interacțiunea chimică dintre actină și miozină încetează, prin interferarea punților transversale de către tropomiozina, favorizând astfel relaxarea mușchiului.

1.5. Semnalul mioelectric

Semnalul mioelectric poate fi definit ca fiind activitatea electrică produsă prin contracțiile mușchiului. În principiu, în momentul în care un mușchi se contractă, în structura internă a mușchiului se generează un curent ionic ce poate fi detectat, din exterior, cu ajutorul unor electrozi. Amplitudinea și forma semnalului mioelectric detectat este influențat de o serie de factori cum ar fi: adâncimea la care este situat mușchiul, mărimea mușchiului, intensitatea contracției musculare, straturile de țesuturi intermediare, tipul electrozilor utilizați pentru detecție etc.

Electromiografia (EMG) constituie o metodă modernă de investigație paraclinică prin intermediul căreia se studiază activitatea bioelectrică la nivelul mușchiului striat, în stare de repaus și de contracție, respectiv în condiții normale și patologice.

Contracțiile mușchilor scheletici sunt controlate voluntar de către sistemul nervos. Unitatea centrală a sistemului nervos trimite impulsuri electrice scurte (de ordinul milisecundelor) către plăcile motoare ale fibrelor musculare prin intermediul motoneuronilor. Sistemul nervos stimulează fibrele musculare prin intermediul joncțiunilor neuromusculare. Impulsurile sunt transmise de-a lungul membranei musculare provocând eliberarea unei concentrații de calciu în interiorul fibrei musculare. Concentrația ridicată de calciu provoacă la rândul ei diferite procese chimice și mecanice care conduc în cele din urmă la contracția fizică a fibrei musculare. În esență, în interiorul celulei musculare a mușchiului aflat în repaus se stabilește un echilibru ionic între ioni de K^+ , Na^+ , Ca^{2+} , Mg^{2+} aflați în compoziția sarcolemiei. Acest echilibru ionic determină potențialul de repaus al fibrei musculare, potențial care este de aproximativ 80 – 90 mV. Acest potențial privit din exteriorul mușchiului este un potențial negativ. În cazul în care un impuls nervos ajunge la placa motorie a unei fibre musculare, acesta va declanșa o depolarizare a membranei musculare urmată de o repolarizare datorată mecanismului de pompă ionică, care restabilește echilibru ionic în interiorul membranei.

Dacă presupunem că membrana celulară este permeabilă numai pentru ionii de K^+ , putem descrie matematic fenomenul de transfer al ionilor. În starea de echilibru fluxul ionilor prin membrană este nul, ceea ce poate fi descris prin ecuația 1.1.

$$J_{KD} + J_{KE} = 0 \quad (1.1)$$

unde:

- J_{KD} este densitatea de flux de difuzie chimică
- J_{KE} este densitatea de fluxul de electric

Conform primei legi a lui Fick, densitatea de flux prin difuziune este:

$$J_{KD} = -D_K \cdot \frac{d[K^+]}{dx} \quad (1.2)$$

unde:

- D este coeficientul de difuzie chimică

Densitatea de flux a ionilor transferați de câmpul electric E este proporțională cu mobilitatea și numărul ionilor de K^+ :

$$J_{KE} = -\mu_K \cdot [K^+] \cdot E = -\mu_K \cdot [K^+] \cdot \frac{du_{MK}}{dx} \quad (1.3)$$

unde:

- μ_K este coeficientul de mobilitate

Înlocuind ecuațiile 1.2 și 1.3 în ecuația 1.1 se obține:

$$D_K \cdot \frac{d[K^+]}{dx} = -\mu_K \cdot [K^+] \cdot \frac{du_{MK}}{dx} \quad (1.4)$$

Relația lui Einstein pentru coeficientul de difuzie al unei particule încărcate electric (în acest caz ionul de K^+) este:

$$D_K = \frac{KT}{z_K q} \cdot \mu_K \quad (1.5)$$

unde:

- z_K este valența ionului de K^+

Din ecuațiile 1.4 și 1.5 rezultă prin substituție ecuația:

$$du_{MK} = -\frac{KT}{q} \cdot \frac{d[K^+]}{[K^+]} \quad (1.6)$$

care prin integrare între două limite aflate în vecinătatea membranei ne conduce la ecuația lui Nerst.

$$u_{MK} = V_i - V_e = -\frac{KT}{q} \cdot \ln \frac{[K^+]_i}{[K^+]_e} \quad (1.7)$$

În urma unor cercetări de laborator efectuate asupra celulelor musculare s-a observat că relația de echilibru între ionii de o parte și de alta a membranei este:

$$\begin{aligned} [K^+]_i &\approx 30 \cdot [K^+]_e \\ [Na^+]_e &\approx 10 \cdot [Na^+]_i \end{aligned} \quad (1.8)$$

Înlocuind relațiile 1.8 în ecuația 1.7 se pot obține valorile potențialului de repaus corespunzătoare ionilor de K^+ și Na^+ :

$$\begin{aligned} V_{K^+} &= -\frac{1,38054 \cdot 10^{-23} \text{ J/K} \cdot 310K}{1,602189 \cdot 10^{-19} \text{ C}} \cdot \ln 30 = -26,71 \text{ mV} \cdot \ln 30 \approx -91 \text{ mV} \\ V_{Na^+} &= -\frac{1,38054 \cdot 10^{-23} \text{ J/K} \cdot 310K}{1,602189 \cdot 10^{-19} \text{ C}} \cdot \ln \frac{1}{10} = -26,71 \text{ mV} \cdot \ln \frac{1}{10} \approx 62 \text{ mV} \end{aligned} \quad (1.9)$$

Toate aceste schimbări ale concentrațiilor de ioni din interiorul fibrei musculare au ca efect modificarea potențialului membranei celulare. Dacă impulsul nervos este destul de puternic, depolarizarea membranei celulare va avea ca rezultat producerea unui „potențial de acțiune” care modifică brusc (0.5ms) potențialul membranei de la -80 mV la $+30$ mV. În momentul în care potențialul membranei devine pozitiv, permeabilitatea membranei la sodiu scade și totodată crește permeabilitatea membranei la potasiu. Astfel se restabilește echilibru ionic în interiorul celulei musculare. Permeabilitate membranei celulare la potasiu revine la valorile inițiale la scurt timp după stabilirea echilibrului ionic, ceea ce are ca rezultat o scădere, de scurtă durată, a potențialului membranei după etapa de repolarizare, fenomen numit hiperpolarizare. Repolarizarea se face prin creșterea bruscă a permeabilității pentru ionii de K^+ , iar echilibrul chimic se reface după refacerea echilibrului electric (cca 80 ... 200ms)




Figura 1.10 Evoluția potențialului membranar în timpul proceselor de depolarizare și repolarizare membranei celulare

Semnalul mioelectric rezultat în urma măsurării potențialului de acțiune prin intermediul electrozilor de suprafață este semnalul generat de activitate electrică a mai multor unități motorii învecinate plus un semnal de zgomot datorat de mediul în care se efectuează măsurarea.

Semnalul mioelectric este considerat a fi un semnal de natură stohastică care poate fi reprezentat prin intermediul unei funcții de distribuție gaussiană. Amplitudinea semnalului mioelectric poate varia între 0 - 10 mV vârf la vârf sau 0 - 1,5mV RMS. Energia utilă a semnalului mioelectric este concentrată în domeniul de frecvență cuprins între 0 - 500 Hz ,iar energia dominantă este cuprinsă între 50 -150 Hz.

2 MĂSURAREA ȘI PROCESAREA SEMNALULUI MIOELECTRIC

Înainte de producerea efectivă a unei contracții musculare, fibrele musculare generează un curent electric de valori reduse. Acest curent este generat de schimbul de ioni ce se produce de-a lungul membranei fibrelor musculare. Semnalul electric generat de fibrele musculare poartă numele de semnal mioelectric (myos-muschi) și poate fi măsurat cu ajutorul unor electrozi de suprafață (noninvazivi) sau cu ajutorul unor electrozi invazivi. Mioelectrozii sunt electrozi utilizați pentru măsurarea curentului produs de mușchi prin contractarea fibrelor musculare. Curentul achiziționat de la mioelectrozi poate fi reprezentat grafic, această reprezentare grafică poartă numele de electrocardiogramă dacă reprezintă activitatea mușchilor inimii sau electromiogramă dacă reprezintă activitatea mușchilor scheletici. Datorită faptului că măsurarea semnalului mioelectric cu ajutorul electrozilor de suprafață constituie o metodă non-invazivă de măsurare determină utilizarea frecventă acestor tip de electrozi în sistemele de analiză și procesare a semnalului mioelectric.

Contracțiile musculare sunt controlate de către corpul omenesc prin intermediul celulelor nervoase. Un neuron motor este conectat prin intermediul axonului la mai multe fibre musculare. Fibrele musculare se vor contracta de fiecare dată când axonul neuronului este activ. Grupul format din neuronul motor și fibrele musculare pe care le controlează formează o unitate motoare. Unitățile motoare destinate controlului fin al mușchiului conțin un număr mic de fibre musculare (de exemplu unitățile motoare destinate pentru controlul mișcării pleoapelor conțin 1-10 fibre musculare), iar unitățile motoare destinate controlului brut conțin un număr mare de fibre musculare (exemplu unitățile motoare destinate pentru controlul extensiei piciorului conțin peste 1000 de fibre musculare)[27].

2.1. Măsurarea semnalului mioelectric

Curentul ionic generat la contracția mușchilor are ca efect direct modificarea potențialului electric din imediata vecinătate a mușchiului în cauză. Această modificare de potențial poate fi detectată din exterior sau din interiorul mușchiului prin intermediul unor electrozi.

Semnalul mioelectric este semnalul electric rezultat în urma măsurării potențialului electric al membranei fibrei musculare în timpul proceselor de depolarizare și repolarizare. Această modificare de potențial poate fi detectată din exterior sau din interiorul mușchiului prin intermediul unor electrozi. În starea de repaus valoarea potențialului membranei este constantă. Deoarece electrozi de suprafață formează un sistem diferențial de măsurare, potențialul de repaus nu poate fi detectat cu ajutorul electrozilor de suprafață. În cazul în care fibra musculară este stimulată de un impuls nervos se va forma o zonă depolarizată. Mărimea zonei de depolarizare este menționată în literatură ca fiind de aproximativ 1 -3 mm² [122]. După depolarizarea inițială, zona de depolarizare se deplasează de-a lungul fibrei musculare cu o viteză de aproximativ 2-6 m/s. Deplasarea zonei

de depolarizarea de-a lungul fibrei musculare poate fi detectată cu ajutorul electrozilor de suprafață.




Figura 2.1 Detectia semnalului mioelectric [122]

În figura 2.1 b este ilustrată modalitatea de măsurare a potențialului de acțiune cu ajutorul electrozilor de suprafață. Electrozi de suprafață au o structură bipolară, iar semnalul electric generat este amplificat cu amplificatoare diferențiale. În momentul T1 este generat un potențial de acțiune. Zona de depolarizare se va deplasa către electrozii de măsură. Pe măsură ce zona de depolarizare se apropie de primul electrod, crește amplitudinea semnalului măsurat, și atinge valoarea maximă în momentul în care zona de depolarizare ajunge în dreptul primului electrod. Semnalul măsurat scade pe intervalul de timp în care zona de depolarizare se deplasează între cei doi electrozi, atingând valoarea de 0V la mijlocul distanței dintre cei doi electrozi și valoare minimă în dreptul celui de-al doilea electrod. Acest model demonstrează de ce potențialul de acțiune monopolar rezultat în urma contracției musculare este prezentat ca și un potențial bipolar în urma măsurătorii.

Cu ajutorul electrozilor de suprafață nu se poate măsura potențialul de acțiune al unei fibre musculare ci mai degrabă potențialul de acțiune al unui grup de unități motorii învecinate. Dacă presupunem că poate fi măsurat potențialul de acțiune al unei unități motorii, valoare măsurată va reprezenta suma ponderată a potențialelor generate de fiecare fibră musculară aflată în componența unității motorii. Ponderele potențialului generat de o fibră musculară depinde în cea mai mare măsură de mărimea fibrei musculare și de poziția ei față de electrozii de măsură. În figura 2.2 este prezentat cazul în care ar fi posibilă măsurarea potențialului unei singure unități motoare, dar în realitate acest lucru nu este posibil deoarece fibrele musculare a unităților motoare învecinate se întretes.




Figura 2.2 Potențialul de acțiune al unei unități motoare [122]

Prin intermediul electrozilor de suprafață se poate detecta activitatea unui grup învecinat de unități motoare iar amplitudinea semnalului mioelectric înregistrat este dependentă de adâncimea la care este situat mușchiul și implicit de numărul de țesuturi intermediare ce se regăsesc între mușchi și electrodul de măsură.

Intensitatea contracției musculare totale poate fi controlată prin două modalități:

- Recrutare spațială – pentru a crește intensitatea contracției musculare sunt activate unități motoare adiționale
- Recrutare temporală – pentru a crește intensitatea contracției musculare se crește frecvența de activare a unităților motoare




Figura 2.3 Metode de control a intensității contracției musculare [122]

2.1.1. Factori perturbatori

Semnalul mioelectric este influențat de mediul în care se efectuează măsurarea. În general, zgomotul este definit ca fiind semnale electrice care nu fac parte din semnalul electric studiat. Semnalele de zgomot ce influențează măsurarea semnalului mioelectric pot fi clasificate astfel:

- Zgomot de ambient - este produs de dispozitivele electromagnetice ce se află în imediata apropiere a subiectului (calculatoare, linii de tensiune etc). Orice aparat ce este alimentat de la rețeaua electrică emite semnal perturbator. În general acest semnal de zgomot se întinde pe un domeniu larg de frecvență, dar componenta de frecvență dominantă este frecvența rețelei de alimentare 50-60 Hz.
- Zgomot de echipament – toate echipamentele electronice generează un semnal de zgomot. Domeniul de frecvență al acestui tip de zgomot este în general cuprins între 0Hz și câteva mii de herți. Zgomotul de echipament nu poate fi eliminat, dar poate fi diminuat prin utilizarea dispozitivelor electronice de înaltă calitate și prin proiectarea corectă a circuitelor electronice.
- Zgomotul de traductor este generat la nivelul de contact dintre electroz și piele. Electrozi sunt folosiți pentru a converti curentul ionic generat la nivelul membranei fibrei musculare în curent electric care

poate fi procesat cu ajutorul dispozitivelor electronice. Există două tipuri de surse de zgomot care rezultă din procesul de transformare a curentului ionic în curent electric:

- Perturbații de curent continuu – cauzat pe de o parte de diferența de impedanță dintre piele și electrod, iar pe de alta parte de reacțiile chimice de oxidare și reducere ce au loc între electrod și gelul conductiv folosit pentru îmbunătățirea contactului dintre electrod și piele.
- Perturbații de curent alternativ – generat de factori cum ar fi fluctuațiile de impedanță ce apar la zona de contact dintre electrod și piele. Efectele produse de fluctuațiile de impedanță pot fi reduse prin utilizare electrozilor din Ag-AgCl. Acești electrozi sunt electrozi din argint cu suprafața de contact placată cu straturi subțiri de clorură de argint.

În cadrul sistemelor de măsurarea a semnalului mioelectric se urmărește maximizarea raportului semnal zgomot. Maximizarea raportului semnal zgomot trebuie realizat astfel încât să nu se altereze semnalul mioelectric. De aceea este indicat ca dispozitivele de înregistrare și detecție a semnalului folosite să proceseze liniar semnalul mioelectric. Vârfurile de amplitudine a semnalului mioelectric nu trebuie trunchiate, iar semnalul nu trebuie filtrat abuziv. Rețeaua de alimentare cu energie electrică reprezintă sursa dominantă de zgomot ce afectează calitatea semnalului mioelectric măsurat. Teoretic, acest tip de zgomot poate fi eliminat prin utilizarea unui filtru de rejecție acordat pe frecvența rețelei de alimentare. Deoarece energie dominantă a semnalului mioelectric este concentrată în domeniul 20 – 150 Hz, nu este indicată utilizarea filtrelor de rejecție de 50-60 Hz în cadrul circuitelor de procesare a semnalului mioelectric. O soluție în acest caz o reprezintă măsurarea bipolară a semnalului mioelectric. Tehnica de măsurare bipolară a semnalului mioelectric constă în utilizarea a doi electrozi și a unui amplificator diferențial. În esență, prin amplificarea diferențială a semnalelor furnizate de cei doi electrozi se va elimina componenta comună a celor două semnale. Semnalul de zgomot generat de sursele electromagnetice exterioare și semnalul mioelectric generat de mușchi aflați la distanță mare de zona activă de măsurare sunt două dintre elementele ce formează componenta comună a celor două semnale.

2.1.1.1. Efectul de crosstalk

Semnalul mioelectric măsurat cu ajutorul electrozilor de suprafață conține o sumă ponderată a semnalele unităților motoare din mușchiul supus măsurării și a unităților motoare din mușchii învecinați. Crosstalk-ul este definit ca fiind perturbația adusă de activitatea mușchilor învecinați asupra semnalului mioelectric măsurat. În cazul în care mușchiul a cărui activitate urmează a fi înregistrată se află la o distanță mică de electrodul de măsură, perturbațiile de crosstalk vor avea o influență mică asupra semnalului mioelectric înregistrat. Perturbațiile de crosstalk se manifestă mai puternic cu cât distanța dintre electrod și mușchiul studiat este mai mare. Aria de măsurare efectivă a electrodului este definită ca fiind aria din jurul electrodului unde amplitudinea semnalului de măsurat este mai mare decât deviația standard a semnalului de zgomot. Amplitudinea semnalului mioelectric măsurat scade exponențial cu creșterea distanței dintre sursa de semnal și electrod, datorită efectului de filtrare (filtru trece jos) al țesuturilor biologice ce se regăsesc între sursa de semnal și electrod.

Efectul de crosstalk poate fi redus prin alegerea corespunzătoare a tipului de electrod (mărimea ariei de conductivitate) și a distanței dintre electrozi utilizați pentru măsurare.

2.1.1.2. Artefacte de mișcare

O altă problemă asociată cu utilizarea electrozilor de suprafață este legată de stabilitatea acestora. Este imposibil de a elimina deplasarea electrozilor pe suprafața pielii. Această deplasare a electrozilor are ca efect generarea unui semnal fals la ieșirea electrodului, numit artefact. Comparând semnalul artefact cu semnalul mioelectric se poate observa că semnalul artefact poate fi interpretat de sistemul de procesare ca și o contracție musculară de intensitate redusă.

Electrodul de suprafață funcționează ca și un traductor ce convertește activitatea ionică generată, de activitatea musculară, în curent electric. Între electrod și piele se formează un contact capacitiv, iar această capacitate de contact este direct influențată de deplasarea electrodului pe suprafața pielii sau de ridicarea electrodului de pe suprafața pielii. Această variație a capacității are ca rezultat apariția artefactelor. Amplitudinea acestor artefacte este dependentă în mare parte de natura materialului folosit la fabricarea electrodului.




Figura 2.4 Deteriorarea semnalului EMG datorită mișcării electrozilor [165]

Un alt gen de semnal artefact este generat de contracțiile pielii. În momentul în care pielea se întinde sau se contractă, în straturile epidermice se generează o activitate ionică, similară cu cea produsă la contracțiile musculare, ce va avea ca efect producerea de artefacte. Amplitudinea acestor artefacte este de aproximativ 5mV și sunt independente de natura materialului din care este confecționat electrodul.

În cadrul testelor de laborator, efectul artefactelor poate fi redus prin utilizarea unor tehnici de pregătire ale pielii, care implică abraziuni mecanice ale epidermei în zona de fixare a electrodului sau folosirea unor paste puternic ionizate. Aceste metode de eliminare a artefactelor sunt valabile pentru situații în care semnalul mioelectric este achiziționat pentru o scurtă perioadă de timp, iar pacientul execută o serie de mișcări bine stabilite. În cazul protezelor, semnalul mioelectric trebuie achiziționat continuu, iar pacientul execută mișcări diversificate. În această situație trebuie asigurat și menținut un contact ferm între electrod și piele.

Un caz extrem de deplasare al electrozilor îl constituie ridicarea acestora de pe suprafața pielii. În acest caz semnalul perturbator generat de rețeaua electrică nu mai este eliminat, iar proteza va fi controlată de semnalul perturbator. Această

situație trebuie eliminată prin intermediul unității de comandă, astfel încât la apariția unui semnal de amplitudine foarte mare unitatea de comandă să blocheze acționarea protezei [40].

2.1.2. Mioelectrodul

Cea mai importantă componentă a unui sistem de achiziție a semnalului mioelectric este electrodul. Calitatea semnalului furnizat de electrod influențează toate procesele la care este supus semnalul achiziționat. Raportul semnal zgomot al întregului sistem de achiziție și procesare depinde în cea mai mare parte de raportul semnal zgomot al electrodului utilizat. De aceea este de preferat utilizarea unui electrod care să asigure un raport semnal zgomot ridicat.

Activitatea mioelectrică poate fi măsurată invaziv, folosind mioelectrozi de tip ac, sau neinvaziv folosind mioelectrozi de suprafață. Electrozii de tip ac sunt folosiți cu precădere în teste clinice având ca scop diagnosticarea unor probleme legate de aparatul locomotor. Electrozii de suprafață sunt utilizați pentru analiza și procesarea semnalului mioelectric în vederea utilizării acestui semnal în diferite aplicații cum ar fi: analiza mișcării, comanda sistemelor protetice, medicină sportivă etc.

2.1.2.1. Mioelectrod tip ac

Măsurarea semnalului mioelectric se poate realiza invaziv prin utilizarea electrozilor tip ac, sau neinvaziv prin utilizarea electrozilor de suprafață. Electrozii tip ac sunt introduși direct în mușchiul a cărui activitate urmează a fi măsurată. Prin intermediul lor se poate măsura activitatea unei singure unități motoare, dar datorită faptului că metoda de măsurare este o metodă invazivă care produce un disconfort evident a pacientului, electrozi ac sunt folosiți doar în teste de laborator.




Figura 2.5 Electrode mioelectric de tip ac [114]

Mioelectrozi de tip ac pot fi clasificați după tipul constructiv în:

- mioelectrozi monopolari
- mioelectrozi concentrici
- mioelectrozi bipolari

Măsurarea semnalului mioelectric prin intermediul electrozilor de suprafață nu este la fel de exactă deoarece mioelectrozii de suprafață măsoară suma ponderată a activităților fibrelor musculare aflate sub mioelectrod. Cu toate că măsurarea prin intermediul electrozilor de suprafață nu este cea mai bună soluție din punct de vedere calitativ este cea mai utilizată metodă datorită modului neinvaziv de măsurare.

2.1.2.2. Mioelectrod de suprafață

Electrozii mioelectrici de suprafață pot fi catalogați, după modul de lucru, în două grupe:

- Electrozi uscați
- Electrozi cu gel

Electrozi uscați sunt utilizați în general în cazurile în care geometria sau mărimea electrozilor nu permit utilizarea gelului. Datorită faptului că electrozii se află în contact direct cu pielea, iar impedanța de contact nu poate fi îmbunătățită prin utilizarea unui gel conductiv, electrozi uscați se fabrică cu circuitul de amplificare inclus în corpul electrodului.




Figura 2.6 Tipuri de electrozi de suprafață [114]

Electrozii cu gel utilizează un gel electrolitic ca și interfață chimică între piele și partea metalică a electrodului. În zona de contact dintre suprafața metalică a electrodului și gel au loc o serie de reacții chimice de oxidare și reducere. Materialul cel mai des utilizat pentru realizarea suprafeței metalice a acestor tip de electrozi este un argintul presărat cu straturi de clorură de argint. Straturile de clorură de argint permit trecerea mai ușoară a curentului la suprafața de joncțiune dintre electrolit și electrod. Există electrozi cu gel de unică folosință și refolosibili. În ultimul timp, electrozii de unică folosință au devenit cei mai utilizați datorită dimensiunilor geometrice și a greutății reduse. Există o gamă diversificată de electrozi de unică folosință care diferă ca formă, mărime, material în funcție de producător și de domeniul de utilizare.

Contactul dintre electrod și piele este definit cantitativ prin rezistența pielii și țesuturilor subcutanate și prin capacitatea parazită a electrozilor, adică prin impedanța electrod-piele. Amplificatoarele folosite în sistemele de măsurarea a semnalului mioelectric au o impedanță mare de intrare, astfel că nu este necesar a se asigura o impedanță electrod-piele de valori foarte reduse. Este important a se asigura o impedanță electrod -piele constată în tip cât și o impedanță relativ similară a celor doi electrozi ce constituie electrodul bipolar. Dacă impedanțele de contact a celor doi electrozi diferă prea mult, atunci și semnalele furnizate amplificatorului diferențial de către cei doi electrozi vor diferii mult. Ca și rezultat, amplificatorul diferențial nu va mai elimina corespunzător semnalul de zgomot. Semnalul de

zgomot generat de sursele electromagnetice înconjurătoare are o amplitudine mult mai mare decât ce a semnalului mioelectric, iar în cazul în care acesta nu este eliminat de către amplificatorul diferențial semnalul rezultat va avea un raport semnal zgomot foarte mic.

De asemenea este importantă asigurarea unei impedanțe de contact constate pe timpul măsurării. Raportul semnal zgomot și rezoluția spațială a semnalului rezultat în urma măsurării sunt puternic influențate de variațiile de impedanță. Studiile recente au demonstrat că valoarea impedanței de contact are influență directă asupra energiei semnalului mioelectric măsurat. De exemplu, prin utilizare unor electrozi cu impedanță de contact mică ($< 10k\Omega$) se obține un semnal mioelectric cu energie mai mare pentru componentele spectrale de până la 100 Hz. Pentru componentele spectrale ale semnalului mioelectric cuprinse între 100-150 Hz este indicată utilizarea unor electrozi cu impedanță mare de contact.

2.1.2.3. Poziționarea mioelectrozilor

Semnalul mioelectric descrie activitatea electrică a unui mușchi în timpul contracției musculare. Calitatea semnalului mioelectric depinde în mare măsură de poziția electrodului de măsură față de mușchiul a cărui activitate electrică este urmărită. Dacă se dorește a se urmări activitatea unei grupe musculare de-a lungul unei perioade mari de timp, sau dacă se urmărește activitatea musculară pe un anumit număr de pacienți, este indicată utilizarea aceleași poziționări a electrodului.

Prin poziționarea electrodului se urmărește găsirea zonei în care semnalul mioelectric poate fi detectat cel mai clar. În urma studiilor efectuate s-a ajuns la concluzia că pentru a se obține un semnal cât mai curat, electrodul trebuie poziționat central, de-a lungul fibrei musculare. Din punct de vedere transversal, electrodul trebuie plasat la egală distanță față de marginile mușchiului pentru a se diminua efectul de crosstalk. Din punct de vedere longitudinal cu cât ne apropiem mai tare de tendon, fibrele musculare devin mai subțiri și mai puține, deci semnalul detectat din această zonă va avea o amplitudine mai mică.

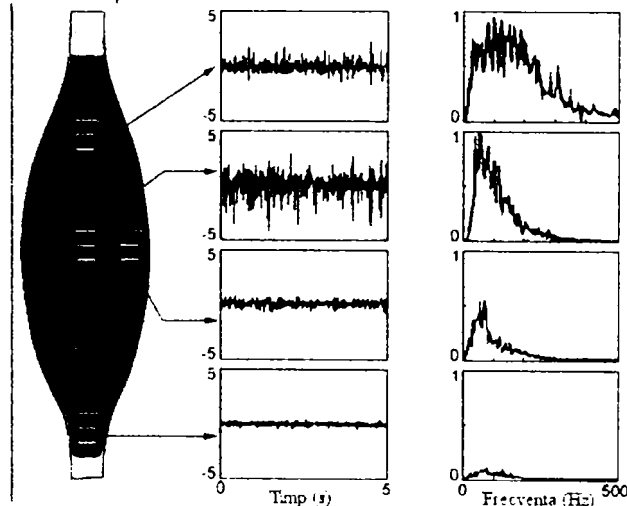


Figura 2.7 Poziționarea electrodului în raport cu mușchiul și efectele asupra semnalului mioelectric [114]

2.1.3. Condiționarea semnalului mioelectric

Semnalul mioelectric achiziționat prin intermediul electrozilor de suprafață este contaminat, în timpul procesului de măsurare, de o serie surse de zgomot. Dezvoltarea electronicii moderne și mai ales dezvoltarea amplificatoarelor diferențiale permit realizarea unor sisteme de achiziție performante având un raport semnal zgomot foarte ridicat. O parte din sursele de zgomot care influențează măsurarea semnalului mioelectric pot fi eliminate prin operația de filtrare, astfel perturbațiile produse de mișcarea electrozilor pot fi eliminate prin filtrarea componentelor spectrale cu o frecvență mai mică de 10-15Hz, iar prin filtrarea componentelor spectrale cu frecvență mai mare de 500 Hz se elimină efectul de aliasing care poate să apară în urma operației de discretizare a semnalului mioelectric. În trecut se utilizau și filtre de rejecție care să elimine perturbațiile produse de rețeaua electrică de alimentare, dar prin utilizarea filtrelor de rejecție se elimină și o parte utilă din semnalul mioelectric. Pentru a evita deteriorarea semnalului mioelectric este indicată evitarea utilizării filtrelor de rejecție și este indicată utilizarea preamplificatoarelor diferențiale cu factor de rejecție al modului comun ridicat.

Apariția electrozilor activi au condus la îmbunătățirea calității semnalului mioelectric măsurat. Acest tip de electrozi au încorporat un amplificator diferențial, astfel interferențele ce pot să apară pe traseul de legătură dintre electrod și intrarea amplificatorului sunt reduse la minim. Distanța dintre cele două puncte de măsură este relativ mică ceea ce duce la apariția artefactelor de mișcare simultan pe cele două puncte de măsură, iar perturbația produsă va fi ușor eliminată prin intermediul amplificării diferențiale a semnalului.

2.2. Platformă hardware-software pentru achiziționarea semnalului mioelectric

În această parte a capitolului va fi prezentată soluția hardware-software aleasă pentru achiziționarea unor eșantioane de semnal mioelectric. După cum s-a menționat și în capitolele anterioare, obiectivul acestei teze este de a aduce o contribuție la modul de procesare a semnalului mioelectric astfel încât acest semnal să poată fi utilizat la comanda unor sisteme protetice. Evident, pentru a realiza obiectivul propus, prima dată este necesară achiziționarea unor eșantioane de semnal mioelectric. Având în vedere că majoritatea lucrărilor în domeniu au studiat procesarea semnalului mioelectric generat de mușchii brațului [57][58][99][100], mi-am propus ca în cadrul acestei teze să studiez semnalul mioelectric generat de mușchii antebrațului (flexor și extensori ai mâinii, pronatori și supinatori).

Structura bloc a sistemului de achiziționare și preprocesare a semnalului mioelectric generat de mușchii antebrațului este în general identică cu a oricărui sistem de achiziție a semnalului mioelectric. Structura este compusă dintr-un ansamblu de doi sau mai mulți mioelectrozi conectați la un circuit de condiționare care asigură amplificare și eventual filtrarea semnalului mioelectric, un circuit de eșantionare și memorare și o platformă software care asigură controlul sistemului de achiziție și mediul de stocare a datelor achiziționate. Am ales o soluție de implementare software pentru modulul de control și stocare a datelor deoarece pentru analiza semnalului mioelectric intenționez să utilizez mediul Matlab. În cazul în care se dorește procesarea semnalului achiziționat cu platformă hardware, modulul de control și stocare a datelor poate fi implementat hardware.

Semnalul mioelectric achiziționat va fi utilizat pentru identificarea a șase mișcări realizate de ansamblu antebraț-mână, și anume flexare – extensie mână, pronare-supinare mână, închidere-deschidere pumn. Pentru aceasta se va utiliza semnalul mioelectric achiziționat de la doi respectiv patru electrozi așezați pe mușchii antebrațului.

2.2.1. Mioelectrodul Z03

Semnalul mioelectric poate fi detectat atât cu electrozi de suprafață cât și cu electrozi de tip ac. Cu toate că electrozii de tip ac pot realiza o detecție foarte bună a semnalului mioelectric generat de o anumită grupă musculară, datorită faptului că este o metodă invazivă de detecție nu reprezintă o soluție viabilă în cadrul lucrării de față. Astfel s-a recurs la utilizarea unor electrozi mioelectrici de suprafață pentru detecția semnalului mioelectric.

Deoarece semnalul mioelectric detectat cu ajutorul electrozilor de suprafață are valori reduse, este implicit necesară amplificarea lui. În paragrafele anterioare am prezentat modalitățile de amplificare a semnalului mioelectric și principalele caracteristici ale mioelectrozilor de suprafață. Soluția aleasă pentru realizarea obiectivului acestei teze constă în utilizarea unor electrozi de suprafață activi, care includ în structura lor și circuitul de condiționare. Deși există o gamă variată de electrozi de suprafață, majoritatea sunt comercializați doar împreună cu sistemul de achiziție aferent.

Pentru sistemul de achiziție propus în această lucrare am ales un mioelectrod de suprafață activ realizat de Motion Labs Systems (vezi figura 2.11). Mioelectrodul Z03 prezintă o intrare diferențială și încorporează un preamplificator diferențial ce asigură o amplificare de 300 de ori a semnalului mioelectric detectat. Contactul dintre cei doi senzori ai mioelectrodului și epidermă se realizează prin două discuri sferice cu un diametru de 12mm dispuse la o distanță de 18mm una de alta. Între cele două discuri de contact se află contactul de masă realizat sub formă de bară cu dimensiunile de 12x13 mm.



Figura 2.8 Mioelectrodul Z03 [233]

Utilizarea unei structuri diferențiale cât și implementarea etajului de preamplificare în structura mioelectrodului au ca efect reducerea perturbațiilor ce pot afecta calitatea semnalului mioelectric detectat. Astfel, conform afirmațiilor celor de la Motion Labs, acest mioelectrod este capabil să furnizeze un semnal mioelectric de înaltă calitate într-un interval de temperatură de 0 – 40°C, chiar și în cazul unor condiții minime de preparare a pielii. Pe lângă circuitul de preamplificare, mioelectrodul Z03 include și un circuit de filtrare a interferențelor radio și un circuit de protecție contra descărcărilor electrostatice.

2.2.1.1. Poziționarea electrozilor pentru măsurarea semnalului mioelectric al antebrațului

Semnalul mioelectric studiat în cadrul acestei lucrări este semnalul mioelectric generat de mușchii antebrațului. Mai exact se dorește identificarea, prin intermediul analizei semnalului mioelectric, a 3 grupe de mișcare, și anume: extensie – flexare încheietură, deviere radială – deviere ulnară încheietură, închidere – deschidere mână. Pentru aceasta este necesară analizare semnalului mioelectric generat de grupe antagoniste de mușchi ce sunt implicate în efectuarea acestor mișcări.

Antebrațul este o zonă care conține un număr mare de grupe musculare. Aceste grupe musculare pot fi împărțite în grupe musculare de suprafață și grupe musculare de adâncime. Datorită faptului că semnalul mioelectric urmează a fi captat cu ajutorul unor electrozi de suprafață, vom încerca să găsim grupe musculare de suprafață ce contribuie la realizarea mișcărilor pe care dorim să le studiem. În figura 2.12 sunt prezentate grupele musculare de suprafață ale antebrațului. După cum se poate observa unele grupe musculare sunt foarte apropiate între ele ceea ce înseamnă că semnalul mioelectric receptat în acele puncte va fi o combinație între semnalele mioelectrice generate de grupele musculare respective.

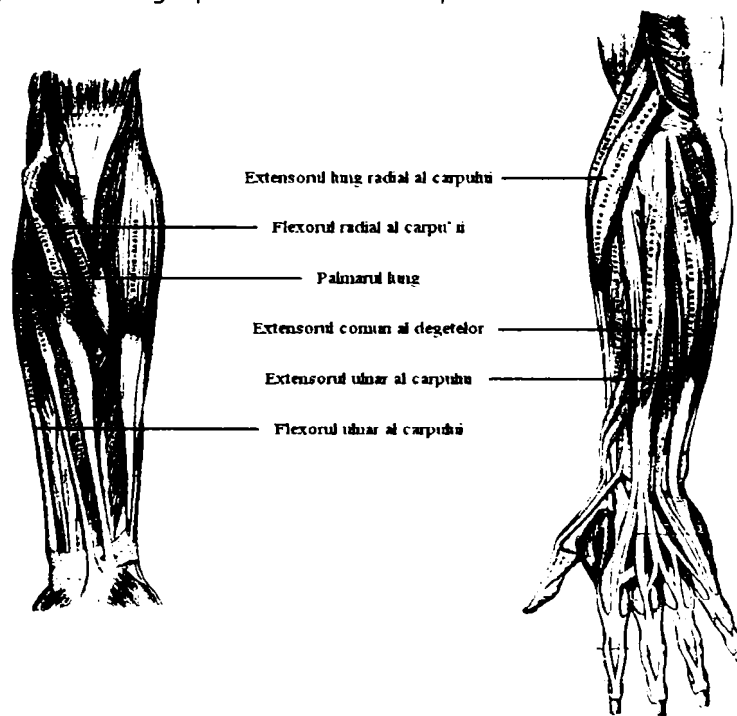


Figura 2.9 Grupele musculare de suprafață ale antebrațului [228]

În tabelul 2.1 sunt prezentate principalele grupe musculare ale antebrațului, nervii corespunzători pentru acționarea lor și mișcările produse de aceste grupe musculare. După cum se poate observa toate grupele musculare de suprafață sunt implicate în mișcarea de flexare-extensie a încheieturii, dar pentru închiderea și deschiderea mâinii este implicată doar perechea de mușchi palmar lung – extensorul comun al degetelor. Deci o pereche de electrozi vor fi amplasați pe aceste grupe musculare.

Tabel 2.1 Principalele grupe musculare ale antebrațului

Denumire grupă musculară	Compartiment	Inervație	Mișcare efectuată
Flexorul radial al carpului	anterior suprafață	Nervul median (C6.C7)	Flexare încheietură Deviere radială încheietură
Flexorul ulnar al carpului	anterior suprafață	Nervul ulnar (C8.T1)	Flexare încheietură Deviere ulnară încheietură
Palmarul lung	anterior suprafață	Nervul median (C7.C8)	Flexare încheietură Tensionare mână
Extensorul lung radial al carpului	posterior suprafață	Nervul radial (C6.C7)	Extensie încheietură Deviere radială încheietură
Extensorul comun al degetelor	posterior intermediar	Nervul radial (C6,C8)	Extensie încheietură Extensie degete
Extensorul ulnar al carpului	posterior suprafață	Nervul radial (C6.C7.C8)	Extensie încheietură Deviere ulnară încheietură

Deoarece aceste grupe musculare sunt apropiate foarte apropiate de altă grupă antagonistă (flexorul radial al carpului – extensorul ulnar al carpului) semnalul mioelectric va fi influențat și de semnalul generat de acești mușchi. De fapt prin amplasarea electrozilor astfel încât să recepționeze semnalele de la ambele grupe musculare se poate realiza o achiziție pe doar două canale, care să permită clasificarea mișcărilor amintite anterior. Totuși, pentru a se putea realiza o mai bună diferențiere între mișcările ce urmează a fi identificate se va folosi o a doua pereche de electrozi amplasate pe gupa musculară antagonistă flexorul ulnar al carpului – extensorul radial lung al carpului. In figura 2.13 este prezentată așezarea celor patru electrozi.




Figura 2.10 Poziționarea electrozilor pentru achiziția semnalului EMG [228]

2.2.2. Sistem de achiziție NI USB-6009

Partea de achiziție propriu-zisă a datelor este realizată cu sistemul de achiziție NI USB 6009 produs de National Instruments. Acesta este un sistem de achiziție de date multifuncțional ce asigură achiziționarea datelor cu o frecvență de până la 48000 eșantioane/secundă, și cu o rezoluție de 14 biți. Având în vedere faptul că banda de frecvență a semnalului mioelectric este cuprinsă între 20-500 Hz, o frecvență de eșantionare de 1000 eșantioane/secundă este suficientă pentru un sistem de achiziție EMG.

În figura 2.14 se prezintă sistemul de achiziție NI USB 6009. Sistemul permite achiziționarea semnalului analogic unipolar sau diferențial. Prezintă 8 porturi analogice de intrare și două porturi analogice de ieșire. În cazul achiziționării unui semnal diferențial, acesta poate fi achiziționat pe 4 canale cu o rezoluție de 14 biți. Semnalul analogic unipolar poate fi achiziționat pe 8 canale cu o rezoluție de 13 biți. Pe lângă porturile analogice de intrare/ieșire, sistemul mai este dotat cu 12 porturi digitale de intrare/ieșire și cu un numărător pe 32 biți. Sistemul poate fi conectat la un calculator prin intermediul unei conexiuni USB.




Figura 2.11 Sistemul de achiziție NI USB 6009 [234]

Programele software pentru controlul acestui sistem de achiziție pot fi realizate în C, C++, .NET, Visual Basic sau LabView. Programele software trebuie dezvoltate în jurul drivere-ului NI-DAQmx care este furnizat odată cu sistemul de achiziție. Un mare avantaj constă în posibilitatea utilizării mediului de programare grafică LabView. Prin intermediul acestuia pot fi realizate rapid diverse configurații de sisteme de achiziție. Prin utilizarea mediului LabView, National Instruments pune la dispoziția utilizatorilor o bibliotecă de aproximativ 3000 de soluții software gratuite.

2.2.3. Platforma software pentru achiziționarea semnalului mioelectric

O soluție software pentru controlul sistemului de achiziție și pentru stocarea datelor achiziționate, poate fi realizată utilizând mediul de programare grafică LabView. LabView este un produs al firmei National Instruments care constă într-un mediu de programare grafic utilizat mai ales pentru realizarea măsurărilor și monitorizarea unor procese automatizate. Pentru scrierea programelor în LabView, se utilizează limbajul grafic G, mediul LabView conținând mai multe biblioteci de funcții predefinite pentru achiziția, prelucrarea, afișarea și transmiterea datelor. S-a recurs la

utilizarea mediului de programare LabView în primul rând pentru că este un mediu de programare grafic, facilitând astfel utilizarea sa, iar în cel de-al doilea rând deoarece atât mediul de programare cât și sistemul de achiziție sunt produse de același producător asigurând astfel o bună compatibilitate.

Programele realizate în LabView se numesc instrumente virtuale (Virtual Instruments - VIs), la baza acestora stând conceptele de modularizare și ierarhie arborescentă. Când se proiectează și se implementează un VI, trebuie să se țină cont de natura modulară a acestuia : să poată fi utilizat atât ca program principal cât și ca subrutină în componența unui alt VI. Un VI folosit la realizarea unui alt VI se numește subVI, având rolul unei subrutine. Prin crearea și utilizarea de subVI la realizarea altor VI, utilizatorul definește ierarhii de VI.

Mediul de programare LabView oferă un suport complet pentru utilizarea sistemului de achiziție NI USB 6009. O soluție rapidă de implementare a unei componente software pentru controlul și gestionarea datelor achiziționate poate fi realizată prin intermediul modulului DAQ Assistant. Acest modul permite recunoașterea automată a sistemelor de achiziție produse de National Instruments și permite configurarea parametrilor acestora. Prin intermediul lui pot fi create canale virtuale de achiziție și pot fi configurate și salvate diferite activități (task-uri) de achiziție. Cu ajutorul acestor task-uri poate fi configurat modulul VI Logger, care va efectua achiziția datelor conform setărilor prevăzute și va salva datele într-un fișier.

Dezavantajul acestei metode constă în faptul că nu permite modificarea tuturor parametrilor sistemului de achiziție și nu permite nici modificarea lor în timp real. Pentru a putea avea acces în timp real la toți parametrii sistemelor de achiziție și pentru a putea realiza un modul de achiziție mai personalizat este indicată realizarea unui VI particular.

În cazul de față se dorește crearea unui VI care să permită achiziționarea și filtrarea semnalului EMG pe două sau patru canale. Eșantioanele astfel achiziționate vor fi stocate într-un fișier pentru a putea fi ulterior utilizate pentru analiza în Matlab a semnalului mioelectric. Interfața grafică trebuie să permită vizualizarea semnalului achiziționat și posibilitatea controlării parametrilor modulului de filtrare în timp real. Pentru a ușura utilizarea datelor achiziționate în mediul Matlab, fișierul de stocare a datelor va fi structurat pe coloane, fiecare coloană conținând datele achiziționate de la un anumit canal. În figura 2.12 este prezentată interfața grafică a modulului realizat pentru achiziționarea semnalului mioelectric pe 4 canale. VI-ul realizat permite selectarea canalelor de achiziție, setarea frecvenței de eșantionare respectiv setarea numărului de eșantioane ce vor fi achiziționate între două accesări consecutive ale fișierului în care se stochează eșantioanele achiziționate. Totodată permite setarea parametrilor filtrului de intrare și activarea sau dezactivarea unui filtru de rejecție a frecvenței de 50Hz. Având în vedere faptul ca acest modul va fi utilizat pentru achiziționarea unui semnal mioelectric ce va fi folosit pentru recunoașterea mișcărilor ansamblului antebraț-mână, modulul include indicatoare vizuale prin intermediul cărora să comunice subiectului momentul în care trebuie să execute o anumită mișcare. Deoarece mișcările studiate sunt grupate în grupe antagoniste, pentru un anumit gen de mișcare există 3 stări posibile. Intervalul de timp dintre două mișcări poate fi controlat interactiv.




Figura 2.12 Interfață modul de achiziție VI EMG

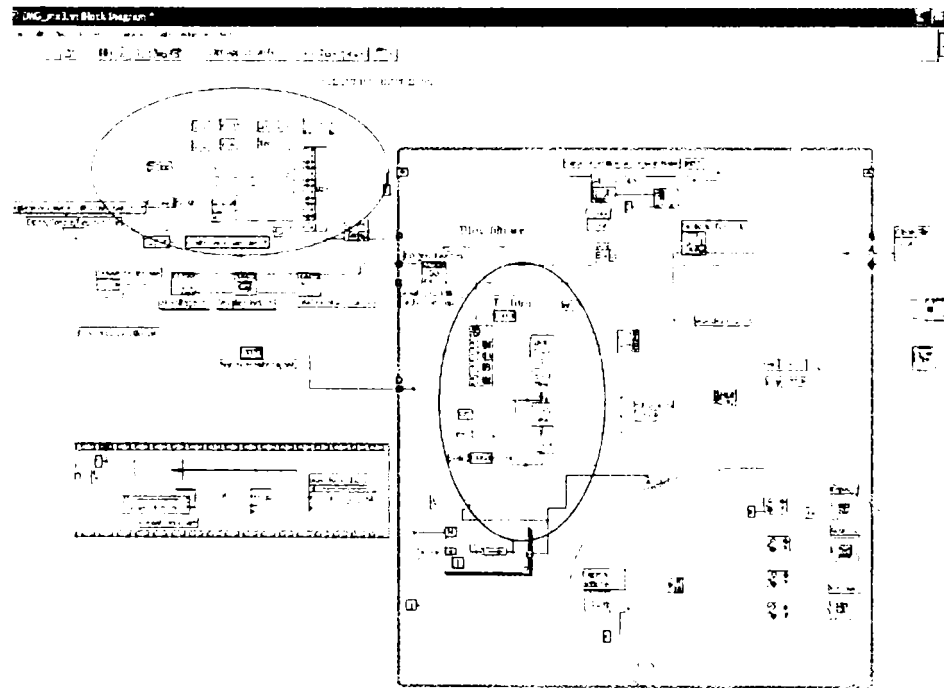


Figura 2.13 Diagramă bloc a modulului de achiziție VI EMG

În figura 2.17 este prezentată diagrama bloc a modului VI creat. În figură sunt evidențiate elementele principale ce alcătuiesc această diagramă. Configurarea parametrilor sistemului de achiziție este realizată prin intermediul blocului de achiziție. Acesta este compus din 5 elemente principale și anume: canalele de intrare fizice, canalul de intrare virtual, blocul de eșantionare, blocul de start achiziție și blocul de citire achiziție. Fiecare din acest bloc este parametrizabil permițând setarea parametrilor sistemului de achiziție. Fișierul în care se face scrierea datelor achiziționate conține un antet care denumește coloanele fișierului. Fișierul va conține 6 coloane: index, timp, ch1, ch2, ch3, ch4. Blocul „indicator acțiune” conține logica necesară controlării indicatorilor de acțiune. Cele trei acțiuni posibile sunt: repaus, acțiune 1 respectiv acțiune 2. Blocul de filtrare permite setarea parametrilor filtrului de intrare. Blocul de filtrare are în componență un subVI prin intermediul căruia se implementează operația de filtrare propriu-zisă.

Unele dintre sistemele de achiziție au în componență circuite de filtrare și circuite de amplificare ce pot fi parametrizate din mediul LabView. Sistemul de achiziție utilizat în lucrarea de față nu este dotat cu astfel de circuite. Din această cauză s-a recurs la realizarea unui circuit de filtrare în mediul de programare. Filtrul ales pentru circuitul de filtrare este de tipul Butterworth. Blocul de filtrare conține și un filtru de rejecție pentru frecvența rețelei de alimentare cu energie electrică. Prezența unui astfel de filtru nu este neapărat necesară, mai ales dacă circuitul de preamplificare este realizat diferent.




Figura 2.14 Sistem portabil de achiziție a semnalului mioelectric

Avantajul utilizării mediului grafic de programare constă în principal în faptul că nu sunt necesare cunoștințe avansate de programare pentru realizarea unei interfețe între calculator și un sistem de achiziție de date. Logica în sine este realizată prin interconectarea unor blocuri ce implementează diferite funcții, iar interfața

grafică poate fi ușor realizată utilizând modelele de indicatori și controale prezente în biblioteca programului.

2.3. Concluzii

În acest capitol s-a realizat un studiu cu privire la modalitățile de achiziționare a semnalului mioelectric. Semnalul mioelectric poate fi achiziționat prin două metode: prima metodă este o metodă invazivă și presupune utilizarea unor electrozi de tip ac, iar cea de a doua metodă este o metodă neinvazivă ce presupune utilizarea unor electrozi de suprafață. Calitatea semnalului mioelectric achiziționat prin intermediul electrozilor de tip ac este net superioară dar necesită supravegherea procesului de achiziție de către personal medical autorizat. Achiziționare semnalului mioelectric cu ajutorul electrozilor de suprafață nu necesită condiții speciale dar nu poate realiza achiziția semnalului generat de o singură unitate motoare. Semnalul mioelectric de suprafață este constituit din suma ponderată a activității unităților motoare învecinate aflate în aria acoperită de electrod. Semnalul achiziționat prin această metodă este puternic influențat de o serie de factori perturbatori.

Autorul prezintă o serie de modalități de reducere a efectelor datorate factorilor perturbatori. Se arată ce cea mai bună metodă de achiziție a semnalului mioelectric de suprafață constă în utilizare mioelectrozilor activi, un tip de electrozi ce au incorporat în structura lor un modul de amplificare diferențială. Se prezintă o soluție hardware și software pentru un sistem de achiziționare a semnalului mioelectric. Componenta software a fost dezvoltată de autor utilizând mediul grafic de programare LabView. Cu ajutorul acestui sistem au fost achiziționate toate semnalele mioelectrice utilizate în cadrul acestei teze de doctorat.

3 STADIUL ACTUAL AL SISTEMELOR PROTETICE CU COMANDĂ MIOELECTRICĂ

Semnalul mioelectric conține o serie de informații legate de activitatea neuromusculară în urma căreia a fost produs. Aceste informații pot fi utilizate pentru diferite diagnosticări medicale legate de activitatea neuromusculară a unei anumite grupe musculare sau pot fi utilizate pentru comanda unor dispozitive protetice menite să înlocuiască, într-o oarecare măsură, deficiențele survenite în urma unei amputări. În cadrul proteticii, este utilizat cel mai frecvent semnalul mioelectric achiziționat cu ajutorul electrozilor de suprafață. Semnalul mioelectric este un semnal nestaționar complex influențat de o serie de factori perturbatori. Complexitatea semnalului a oferit cercetătorilor idei și uneori soluții pentru dezvoltarea unor strategii de comandă inovatoare în domeniul proteticii.

În ultimul timp din ce în ce mai multe persoane care au suferit o amputare recurg la utilizarea unui sistem protetic activ. Aceste persoane caută un înlocuitor acceptabil pentru membru amputat, care să le permită un stil de viață asemănător cu cel avut înainte de amputarea sau apropiat cu cel al persoanelor fără handicap. Dacă un sistem protetic activ este o soluție bună pentru substituirea membrului amputat depinde în mare măsură de așteptările pacientului, de motivația pacientului de a încorpora acest dispozitiv în stilul său de viață și nu în ultimul rând de funcționalitatea dispozitivului protetic. Unele persoane sunt dispuse să învețe să controleze un sistem protetic complex pe când alte persoane nu au aceeași motivație sau din motive economice recurg la sisteme mai puțin complexe. Dacă sistemul protetic trebuie să înlocuiască o funcție simplă, cum ar fi deschiderea - închiderea mâinii, sistemul de comandă aferent are o logică simplă și poate fi învățată cu ușurință. Astfel de sisteme au avut un mare succes datorită costului redus și a simplității în utilizare, dar suferă de numărul redus de operațiuni pe care le pot efectua. Tendința actuală este de a găsi noi modalități de comandă destinate sistemelor protetice complexe, prin intermediul cărora să se ușureze activitate depusă de pacient pentru controlul dispozitivului protetic.

Majoritatea sistemelor de comandă protetice actuale sunt capabile să controleze un număr redus de dispozitive dintr-un sistem protetic, cum ar fi: mână, cot, umăr sau încheietură. Aceste sisteme extrag informația necesară pentru comandă din semnalul mioelectric prin estimarea amplitudinii și/sau a frecvenței. Informația extrasă este folosită pentru stabilirea operației care urmează a fi efectuată. După alegerea operației, sistemul protetic poate fi acționat cu viteză constantă sau proporțională cu intensitatea semnalului mioelectric. Cu toate acestea sistemele au succes pe piața proteticii, sistemul de comandă utilizat nu oferă suficiente informații pentru a comanda mai mult de un dispozitiv la un moment dat.

În ultimul timp au fost dezvoltate o serie de sisteme protetice experimentale prin care s-a încercat extragerea unui număr mai mare de stări din semnalul mioelectric. Unele sisteme se bazează pe aceeași metodă de extragere a informației ca și sistemele clasice dar prin utilizarea unui număr mai mare de canale de achiziție, alte metode se bazează pe măsurători statistice. Indiferent de metoda folosită, din semnalul mioelectric se extrage un vector de caracteristici cu ajutorul căruia, prin intermediul unui algoritm de recunoaștere de tipare, se

selectează o anumită stare de funcționare. În cazul utilizării a mai multor canale de achiziție apare probleme legate de localizarea și menținerea integrității semnalului mioelectric. În cazul măsurărilor statistice se încearcă extragerea unui set de caracteristici ale semnalului mioelectric prin utilizarea unor modele serii de timp. Rezultate obținute sunt promițătoare dar sunt sensibile la schimbările de amplitudine ale semnalului mioelectric.

3.1. Sisteme protetice comerciale cu comandă mioelectrică

Procesarea semnalului mioelectric constă în extragerea unor trăsături din semnalul mioelectric achiziționat și utilizarea lor pentru comanda dispozitivelor de acționare ale protezei. Deoarece valoarea medie a semnalului mioelectric, furnizat de către electrozi, este zero este indicat redresarea sa. Astfel, partea negativă a semnalului mioelectric se oglindește peste partea sa pozitivă, rezultând un semnal pozitiv, având o valoare medie pozitivă. În urma filtrării acestui semnal, prin utilizarea unui filtru trece jos, se obține un semnal continuu a cărui amplitudine reflectă variațiile semnalului mioelectric inițial. Acest semnal poartă denumirea de semnal mioelectric procesat. Toate protezele cu comandă mioelectrică comerciale folosesc acest semnal pentru comanda dispozitivelor de acționare.

Primele proteze mână cu comandă mioelectrică aveau ca scop înlocuirea funcției de bază a mâinii, adică funcția de prindere. Dispozitivul terminal al acestor proteze consta într-un cârlig acționat electric ce putea realiza operația de prindere. Cu timpul aceste proteze au evoluat, iar în zilele noastre protezele cu comandă mioelectrică pot acționa diferite dispozitive protetice cum ar fi: mână, cot, încheietură, umăr [43].




Figura 3.1 Preprocesarea semnalului EMG prin redresare [165]

Există mai multe moduri în care pot fi comandate dispozitivele terminale folosind semnalul mioelectric procesat. De exemplu operațiile de deschidere închidere ale unei mâini electrice pot fi comandate prin intermediul unui semnal mioelectric procesat provenit de la un singur electrod. Pentru a diferenția mai bine cele două operații, se pot folosi două semnale mioelectrice provenite de la doi electrozi amplasați pe două grupe de mușchi complementare. Unul din semnale va comanda

operația de deschidere iar cel de-al doilea semnal va comanda operația de închidere a mâinii. Totodată dispozitivele terminale pot fi acționate cu viteză constantă sau cu viteză variabilă controlată de pacient. Toate aceste modalități de utilizare ale semnalului mioelectric procesat poartă denumirea de strategii de comandă. Rolul de a alege cea mai bună strategie pentru fiecare pacient revine personalului specializat de la clinicile ce oferă servicii protetice. Zi de zi se dezvoltă și se testează noi strategii de comandă pentru a acoperii cât mai mult din nevoile persoanelor cu handicap.

3.1.1. Sisteme mioelectrice de comandă cu două canale

Sistemele cu comandă mioelectrică care folosesc două semnale mioelectrice provenite de la două grupe musculare distincte poartă denumirea de sisteme mioelectrice de comandă cu două canale. Sistemul necesită achiziționarea a două semnale mioelectrice, deci folosirea a doi electrozi. De obicei, pentru comanda acestor sisteme se folosesc semnale mioelectrice provenite de la două grupe musculare antagoniste. De exemplu, este foarte des întâlnită situația în care cele două grupe musculare sunt grupele musculare biceps și triceps. Operația de închidere a mâinii sau operația de flexare a brațului sunt controlate de semnalul mioelectric provenit de la biceps, iar operația de deschidere a mâinii sau operația de extensie a brațului sunt controlate de semnalul mioelectric provenit de la triceps.

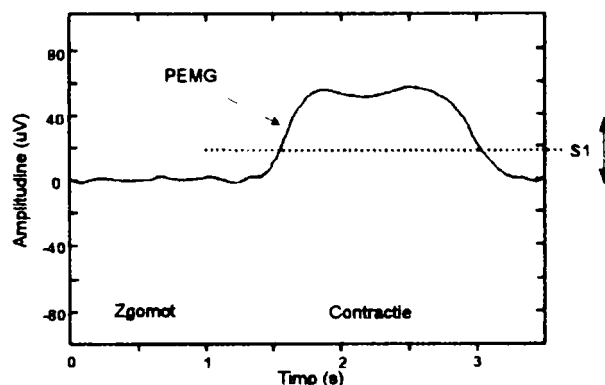


Figura 3.2 Modul de estimare a amplitudinii semnalului EMG [165]

Semnalul mioelectric obținut de la electrozi este afectat de zgomot. Pentru a elimina într-o oarecare măsură, influențele negative ale semnalului de zgomot, se fixează o valoare de prag sub care semnalul mioelectric nu este procesat. Dacă semnalul mioelectric depășește valoarea de prag stabilită, se activează funcția protetică asociată aceluia semnal mioelectric. Nivelul de prag pentru cele două canale este ajustabil pentru fiecare canal în parte, în funcție de nivelul maxim de semnal mioelectric ce poate fi achiziționat de pe grupul muscular respectiv. Această strategie de comandă poartă denumirea și de comandă cu două stări [165].

Majoritatea companiilor producătoare de produse protetice folosesc această strategie de comandă. În practică, nivelul de prag pentru fiecare canal este fix, ajustările necesare se fac prin modificarea factorului de amplificare pentru circuitele de amplificare ale fiecărui electrod. Creșterea factorului de amplificare va genera implicit și un semnal mioelectric mai puternic pentru un anumit nivel de contracție. Astfel acest tip de sistem poate fi adaptat unui număr mai variat de pacienți, atât pacienților ce pot efectua contracții puternice ale ambelor grupe musculare cât și pacienților ce pot efectua contracții puternice doar pentru o grupă musculară.

Unul dintre dezavantajele acestei strategii de comandă, ce a afecta în general primele sisteme de acest gen, este contracția simultană. În cazul în care pacientul efectuează o contracție simultană a ambelor grupe musculare, sistemul protetic primește două comenzi complementare. Una dintre soluțiile actuale pentru situația contracțiilor simultane se bazează pe faptul că totuși există un decalaj de timp între cele două semnale mioelectrice generate. Sistemul va răspunde primei comenzi venite și va bloca ce de-al doilea canal pe durata procesării primei comenzi [53].

3.1.2. Sisteme mioelectrice de comandă cu un singur canal

Sistemele mioelectrice de comandă cu un singur canal utilizează informațiile furnizate de un singur semnal mioelectric, provenit de la un singur senzor amplasat pe o grupă musculară ce furnizează un semnal mioelectric cât mai curat. Aceste sisteme sunt cel mai des întâlnite la protezele pentru copii, datorită faptului că zona reziduală a membrului este foarte mică și nu permite amplasarea a doi electrozi sau datorită faptului că pacientul nu poate controla două grupe musculare.

Datorită faptului că se utilizează un singur semnal mioelectric, procesarea acestuia trebuie să asigure efectuarea tuturor funcțiilor protetice. Strategiile de comandă pentru sistemele mioelectrice cu un singur canal se împart în două categorii: sisteme de comandă cu codare în amplitudine sau sisteme de comandă cu codare în frecvență.

3.1.2.1. Sisteme de comandă cu codare în amplitudine

În cazul sistemelor mioelectrice de comandă cu codare în amplitudine, operația ce va fi executată de către sistemul protetic se alege în funcție de amplitudinea semnalului mioelectric. Diferența dintre valoare maximă și valoarea minimă a semnalului mioelectric definește intervalul de amplitudine disponibil. Acest interval este divizat în trei regiuni, ceea ce implică setarea a două nivele de prag. Cele trei regiuni corespund funcțiilor de repaus, închidere și deschidere a protezei. Primul nivel de prag este identic cu nivelul de prag utilizat în sistemele de comandă cu două canale și delimitează zona pasivă de repaus de zonele active. Acest sistem de comandă poartă denumirea de comandă cu trei stări [147].

La prezența semnalului de zgomot sau în cazul unei contracții involuntare de mică intensitate proteza se află în stare de repaus. Pentru o contracție musculară care are ca rezultat generarea unui semnal mioelectric de amplitudine mai mică decât valoarea prag S2, sistemul protetic efectuează operația de închidere a mâinii. Pentru un semnal mioelectric a cărui amplitudine depășește valoarea de prag S2, sistemul protetic va efectua operația de deschidere a mâinii.

După cum se poate observa și din descrierea funcționării acestui sistem de comandă, unul dintre dezavantaje îl constituie trecerea prin starea de închidere a protezei. Trecerea protezei direct în starea de deschidere nu se poate efectua fără a trece prin starea de închidere. Pentru a rezolva această problemă se introduce o întârziere în strategia de comandă astfel încât să fie acoperită perioada tranzitorie ce survine în cazul unei contracții puternice. Această soluție are ca efect negativ scăderea vitezei de răspuns a sistemului protetic.

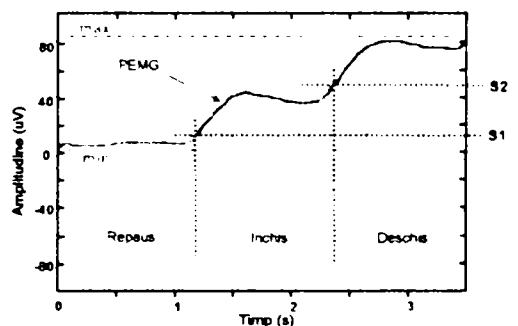


Figura 3.3 Principiul codării în amplitudine a semnalului EMG [165]

O variație a acestei metode o constituie metoda cookie crusher. Această metodă este aplicată copiilor cu vârste foarte mici, și constă în divizarea intervalului de amplitudine în două regiuni. Prima regiune comandă închiderea protezei și corespunde situației unui semnal mioelectric de mică intensitate, iar cea de-a doua regiune corespunde situației unui semnal mioelectric de mare intensitate ce comandă deschiderea protezei. În această situație pot fi folosite și proteze cu arc, la care operație de închidere se execută automată în lipsa unui semnal mioelectric [178].

Cele două nivele de prag pot fi ajustate în funcție de necesități. În practică sunt folosite atât proteze cu nivele de prag direct reglabile cât și proteze cu reglare indirectă, adică cu reglarea factorului de amplificare al circuitului de amplificare la electrodului.

3.1.2.2. Sisteme de comandă cu codare în frecvență

Sistemul de comandă cu codare în frecvență utilizează o strategie de comandă secvențială. În prima fază se selectează funcția dorită, iar în cea de-a doua fază se controlează funcție selectată. Funcția ce se dorește a fi executată se selectează prin contracții repetate ale grupului muscular. Frecvența acestor contracții va determina alegerea funcției dorite. În continuare nivelul semnalului mioelectric va determina modul de efectuare al funcției selectate. De exemplu, o contracție repetată de mică frecvență determină alegerea operației de închidere iar o contracție repetată de mare frecvență determină alegerea operației de deschidere a protezei.




Figura 3.4 Principiul codării în frecvență a semnalului EMG [165]

În general, pentru selecția funcției se urmărește panta semnalului mioelectric procesat pe o perioadă fixă de timp. Se utilizează o perioadă de decizie fixă pentru a

avea o viteză constantă de răspuns a sistemului protetic. Pentru a ajusta nivelele de selecție se folosește și în acest caz modificarea factorului de amplificare a circuitului de amplificare al electrozului.

Unul dintre avantajele acestei strategii de comandă este faptul că numărul funcțiilor ce pot fi selectate este, teoretic, nelimitat. Din acest motiv această strategie de comandă este indicată pentru sistemele protetice multi-funcționale în care cu un semnal mioelectric pot fi comandate mai multe dispozitive terminale. Un alt avantaj îl constituie faptul că pentru efectuarea funcției selectate se poate folosi tot intervalul de amplitudine al semnalului mioelectric putându-se realiza astfel o comandă proporțională a operației alese.

3.1.3. Dispozitive terminale

Strategia de comandă determină operația ce va fi efectuată, pe baza analizei semnalului mioelectric, dar operația în sine este efectuată de către dispozitivul terminal. Pentru a comanda acest dispozitiv terminal este necesară utilizarea unui circuit de interfațare.

Majoritatea dispozitivelor terminal, ce echipează sistemele protetice cu comandă mioelectrică aflate pe piață, sunt antrenate de motoare de curent continuu. Pentru a produce cuplul necesar antrenării sistemului protetic, motoarele sunt prevăzute cu reductoare care antrenează mai departe părțile mobile ale sistemului protetic. Proiectarea unor reductoare de mici dimensiuni care să permită efectuare setului de operații start – stop – înapoi – stop este destul de dificilă. Pentru a controla direcția de rotire a angrenajului este mult mai simplu și mai rentabil să se recurgă la o soluție electronică de comandă a motorului.

Direcția de rotire a unui motor de curent continuu poate fi controlată prin simpla schimbarea a sensului curentului prin statorul motorului de curent continuu. Sensul curentului poate fi controlat prin utilizare a patru comutatoare electronice amplasate într-un circuit punte. Prin comanda în pereche a celor patru comutatoare electronice se poate stabili sensul de curgere al curentului prin motorul de curent continuu. Circuitele punte sunt amplasate în dispozitivele terminale cât mai aproape de motorul de curent continuu.

Pentru a prelungi durata de funcționare a acumulatorilor ce alimentează motoarele din sistemele protetice au fost dezvoltate o serie de strategii de reducere a consumului de curent electric. Strategiile sunt specifice fiecărui producător de proteze, dar în principiu au ca scop oprirea alimentării motoarelor pe durata perioadei de repaus a protezei sau pe durata pe care sistemele protetice mențin o anumită stare. Astfel se pot implementa circuite de temporizare în care se prestabilesc timpii necesari efectuării unei anumite operații, motoarele fiind alimentate doar pe durata efectuării operațiilor, sau se pot implementa întrerupătoare care să sesizeze efectuare completă a unei operații (de exemplu întrerupător ce semnalizează deschiderea completă a mâinii).

În primele sistem protetice, cât și în unele sisteme actuale, nu era posibilă controlarea de către pacient a vitezei de antrenare a protezei. Sistemul protetic funcționa pe principiul ON/OFF, adică era sau nu era antrenat de motorul electric. Antrenarea motorului se făcea la o viteză constantă. Timpul necesar efectuării unei operații complete de deschidere a mâinii era relativ mare (aprox. 2 sec).

Sistemele protetice moderne au introdus strategii de comandă proporțională a vitezei de antrenare a sistemului protetic. În acest caz viteza de antrenare este direct proporțională cu nivelul semnalului mioelectric. Cu ajutorul acestor strategii de

comandă, timpul necesar pentru o operație completă de deschidere a mâinii s-a redus la aproximativ 0.5 sec.

3.2. Proteze mioelectrice mână-braț comerciale

Protezele mioelectrice au la bază un concept simplu. Semnalul electric, generat natural prin contractare mușchilor reziduali, este amplificat, procesat și utilizat pentru comanda unuia sau a mai multor actuatore folosite pentru acționarea unei proteze. Cu toate că protezele mioelectrice au la bază un concept simplu, proiectarea unei proteze cu aplicabilitate clinică este extrem de dificilă. O proteză comercială trebuie să fie confortabilă, ușoară, să aibă stabilitate în funcționare, să aibă un aspect natural atât în timpul funcționării cât și în momentele de repaus. Mai mult, după cum menționează Weiner, o proteză ideală nu trebuie să înlocuiască doar funcții mecanice ci și senzațiile kinestetice și cutanate [165]. Realizarea unei proteze confortabile și cu o funcționalitate cât mai apropiată de cea a organului pe care îl înlocuiește are ca dezavantaj direct creșterea în greutate și în dimensiuni a protezei. Îmbunătățire aparentă în timpul funcționării (traiectorii de mișcare, zgomot mecanic) duce la creșterea complexității protezei. În final, pe lângă constrângerile de proiectare descrise, trebuie controlat costul de fabricare al protezei. Fabricarea în masă este un mod de a reduce costurile de fabricare, dar piața protezelor este mică ca și număr și mare ca și complexitate. Datorită faptului că costurile de cercetare și dezvoltare sunt ridicate și a faptului că posibilitățile de producere în masă sunt limitate, costul final al protezelor este destul de ridicat, limitând astfel numărul clienților posibili. Toate aceste constrângeri au redus totodată și numărul firmelor ce au ca activitate fabricare protezelor sau a componentelor pentru proteze cu comandă mioelectrică [44].

În momentul actual există șapte firme producătoare de componente pentru proteze mână-braț cu comandă mioelectrică. Aceste companii sunt: Centri AB; Hosmer; Liberating Technologies; Motion Control; Otto Bock Healthcare; RSL Steeper și Variety Ability Systems. În continuare sunt prezentate aceste companii împreună cu principalele lor produse existente pe piață cât și produsele aflate în dezvoltare.

3.2.1. Otto Bock Healthcare

Compania Otto Bock Healthcare a fost înființată în anul 1919 la Berlin de către Otto Bock. A început ca și o organizație familială, având inițial un număr de 20 de angajați. În momentul de față compania continuă să fie condusă de membrii familiei Bock, devenind o organizație cu peste 3000 de angajați. Principalul obiect de activitate al companiei este fabricarea și distribuirea de componente ortopedice și protetice, fiind unul dintre liderii acestui domeniu având sucursale în peste 30 de țări.



Figura 3.5 Sistemul protetic Electrohand [235]

În domeniul protezelor mioelectrice pentru mână, Otto Bock Healthcare oferă 4 tipuri de produse distincte. Produsul de bază îl constituie seria Electrohand, care oferă proteze pentru adulți. Protezele sunt dotate cu trei degete funcționale care asigură operația de prindere. Pentru aspectul estetic sunt prevăzute încă două degete pasive. O particularitate a protezelor de mână fabricate de Otto Bock Healthcare o constituie parte de comandă a circuitelor punte folosite pentru acționarea motorului ce antrenează proteza. Selecția metodei de comandă se reduce la alegerea unui modul de circuit punte corespunzător. Modulele de circuit punte includ atât circuitul punte cât și circuitele electronice de comandă. Modulele disponibile oferă comandă în funcție de nivel sau în funcție de frecvența semnalului mioelectric, controlul putând fi proporțional sau de stare (On/OFF). Modul de comandă dinamic (DMC) este un mod de comandă proporțională care oferă o comandă, a vitezei de acționarea a protezei, proporțională cu intensitatea semnalului mioelectric prelucrat. Pentru acest mod sunt necesare 2 semnale mioelectrice distincte, unul pentru comanda de deschidere și unul pentru comanda de închidere a mâinii. Modul DMC Plus oferă aceeași metodă de comandă dar deschiderea protezei după, ce sa efectuat o operație de prindere, se comandă cu un impuls mioelectric de intensitate mai mare, adică este comandat de o contracție musculară mai puternică, eliminându-se astfel deschiderea protezei datorate unor contracții musculare involuntare.



Figura 3.6 Sistemul protetic Sensorhand [235]

O serie mai avansată din punct de vedere tehnologic o constituie seria SensorHand. Această serie oferă tot terminale pentru proteze braț, dotate cu senzori de forță și alunecare. Senzorii sunt încorporați în degetul mare al protezei și oferă o buclă de reacție sistemului protetic. Această tehnologie a fost dezvoltată împreună cu compania de asigurări Schweizerische Unfall Versicherungs Anstalt, iar uneori este întâlnită în literatura de specialitate sub denumirea de mână SUVA. Funcția AutoGrasp permite pacientului să țină un obiect un timp îndelungat în mână fără efort fizic suplimentar și fără a fi nevoit să supravegheze starea de stabilitate a obiectului. Proteza este dotată cu un microprocesor care prelucrează datele primite de la senzorul de alunecare și controlează independent forța de strângere. Pacientul poate comanda terminarea modului de operare Autograsp printr-un impuls mioelectric de scurtă durată și poate comanda deschiderea mâinii printr-un impuls mioelectric de durată mai mare. Funcția FlexiGrip permite pacientului să re poziționeze un obiect în mână fără a fi necesară deschiderea mâinii prin comandă mioelectrică. Noua generație a seriei, SensorHand Speed, aduce îmbunătățiri ale vitezei de acționare a protezei. Viteza de acționare este controlată proporțional, gama de variație a vitezei fiind cuprinsă între 15-300 mm/sec, rezultând o viteză maximă de două ori mai mare decât a protezelor din generația precedentă.

Pentru persoanele cu amputări scurte ale mâinii (în zona încheieturii) care nu au nevoie de proteză braț ci numai de proteză mână, Otto Bock Healthcare oferă seria Transcarpal Hand. Motorul care acționează această proteză este de trei ori mai mic și este poziționat astfel încât să ocupe un spațiu cât mai redus. O inovație adusă de compania Otto Bock Healthcare este legată de modul de conectare al protezei la brațul pacientului. Conectarea nu se mai face prin inele laminate ci prin intermediul unor bucle de cabluri. Performanțele acestei serii sunt comparabile cu cele ale protezelor din seria ElectroHand, iar modulele de comandă disponibile sunt cu comandă proporțională (DMC) sau cu comandă de stare (ON/OFF).



Figura 3.7 Sistemul protetic Transcarpalhand [235]

3.2.2. Hosmer Dorrance Company

Hosmer Dorrance Company a fost înființată în anul 1912 de către D.W. Dorrance. Principalul produs al acestei companii a fost terminalul cârlig pentru proteze. Recent, în urma unor lucrări de cercetare efectuate împreună cu Institutul de

Reabilitări din Chicago, compania a început să se ocupe cu proteze comandate mioelectric.



Figura 3.8 Sistemul protetic Synergetic Prehensor [231]

Produsul principal al firmei Hosmer de pe piața protezelor cu comandă mioelectrică este Synergetic Prehensor. Acesta este un cârlig electric, acționat de două motoare, unul dedicat mișcărilor rapide iar ce de-al doilea dedicat mișcărilor de precizie. Comanda se realizează proporțional cu intensitatea semnalului mioelectric, operațiile de închidere deschidere fiind comandate independent de două semnale mioelectrice provenite de la două grupe de mușchi complementare. Electrozii au o unitate de preprocesare externă care poate fi fixată în interiorul protezei.




Figura 3.9 Electrocul mioelectric și dispozitivul terminal al sistemul protetic Synergetic Prehensor [231]

Hosmer Company se axează pe fabricarea unor proteze cu performanțe în funcționare ne ținând prea mult seama de estetica produsului. Datorită faptului că

proteza este acționată de două motoare este necesară utilizarea unei baterii de putere mai mare ceea ce duce la creșterea în greutate a protezei.

3.2.3. Centri AB

Centri AB este o companie familială înființată în anul 1948 în Suedia. La început compania a fost recunoscută pentru mănușile cosmetice și protezele pasive fabricate. În momentul actual continuă să fie principalul furnizor de mănuși cosmetice folosite la echiparea protezelor electrice sau mecanice de pe piață.

Pe la mijlocul anilor '90, Centri AB a lansat pe piață prima serie de proteze mână cu comandă mioelectrică. Seria UltraLite avea un modul de comandă dezvoltat de Centri AB dar folosea electrozi mioelectrici fabricați de Otto Bock Healthcare. Modul de proiectare al seriei UltraLite este unic din anumite puncte de vedere. Greutatea protezei este mică în comparație cu cea a celorlalte proteze de pe piață, proteza fiind construită din aluminiu și nylon. Un alt aspect unic constă în traiectoria degetelor, mișcarea efectuată fiind mult mai apropiată de mișcarea naturală a mâinii.



Figura 3.10 Sistemul protetic MyoElectric Hand [230]

Noua serie MyoElectric Hand este îmbunătățită. În primul rând sunt folosiți electrozi mioelectrici de fabricație proprie, care au incorporat modul de amplificare și modul de rejecție al perturbațiilor introduse de rețeaua electrică. Proteza este dotată cu două motoare de precizie unul dedicat acționării protezei, iar cel de-al doilea destinat menținerii stării de închidere. Modulul de comandă utilizează o comandă proporțională a vitezei și a forței de închidere. După efectuare închiderii, proteza este blocată în această poziție pentru a reduce consumul de energie. Modulul de comandă prezintă și o funcție de autoreglare ce reglează amplificarea semnalului mioelectric în funcție de nivelul de zgomot prezent.

3.2.4. Liberating Technologies

Liberating Technologies este compania care a proiectat popularul sistem protetic Boston Elbow. În momentul actual compania se ocupă cu fabricarea diverselor componente destinate proteticii membrilor superioare. Sunt recunoscuți pentru unitățile de comandă create cât și pentru bateriilor respectiv acumulatorii de mare capacitate.

Noul lor produs Boston Digital Arm System este o variantă îmbunătățită a produsului lor de succes Boston Elbow. Îmbunătățirile aduse constau în: o nouă unitate de comandă programabilă, baterii de mare capacitate, sisteme de reîncărcare a bateriilor mai rapide și un nou sistem de blocare pe poziție a brațului. Sistemul cuprinde cinci motoare și o serie de canale de reacție (feedback) care contribuie la un mai bun control al forței și vitezei de acționare al protezei. Toate cele cinci motoare de acționare pot lucra simultan și sunt destinate acționării umărului, cotului, încheieturii și al mâinii. De remarcat este faptul că sistemul nu posedă o proteză mână realizată de Liberating Technologies, dar în schimb acestui sistem îi poate fi atașată majoritatea protezelor mâna realizată de celelalte firme din domeniu. Astfel sistemul Boston Digital Arm poate conlucra cu proteze mână ce necesită surse de alimentare cuprinse între 6-12 V și care pot fi comandate atât cu comandă de stare (ON/OFF) cât și cu comandă proporțională.



Figura 3.11 Sistemul protetic Boston Digital Arm [229]

Un alt produs foarte comercializat al firmei Liberating Technologies îl constituie unitatea de comandă VariGrip. Aceasta este o unitate de comandă programabilă compatibilă cu majoritatea componentelor protetice de pe piață. Aceasta unitate poate comanda simultan unități protetice diferite. Unitatea de comandă acceptă date de intrare de la diferite surse externe cum ar fi : senzori de forță rezistivi (FSR), servo-mecanisme, electrozi etc. Unitate de comandă are 10 moduri de comandă presetate, destinate atât sistemelor cu un singur electrod cât și sistemelor cu doi electrozi, dar are și opțiunea de reprogramare prin soft.



Figura 3.12 Unitatea de comandă VariGrip [229]

Liberating Technologies produce diverse componente și subansamble protetice pentru trei dintre cei mai mari producători de sisteme protetice: RSL

Steeper, VASI , CentriAB. În același timp comercializează sisteme protetice hibride construite cu componente proprii și componente provenite de la cele trei firme menționate anterior.

3.2.5. Motion Control

Motion Control Inc. a fost înființată în anul 1974 în Salt Lake City, de către un grup de cercetători de la Universitatea Utah, cu scopul de a comercializa noile tehnologii, din domeniul proteticii, dezvoltate de institutul de cercetarea al universității. Principalul produs al acestui parteneriat a fost sistemul Utah Artificial Arm.

Primul sistem Utah Arm a fost comercializat în anul 1981 și consta într-un sistem protetic complet pentru membrul superior dotat cu un sistem de comandă mioelectrică ce permitea acționarea cotului și a mâinii. Terminalul mână erau un terminal produs de Otto Bock Healthcare, iar sistemul de comandă proporțională avea nevoie de semnal mioelectric de la doi electrozi. Un mare dezavantaj al acestui sistem erau numărul mare de ajustări ce trebuiau să fie realizate la clinică de către un personal autorizat .




Figura 3.13 Sistemul protetic Utah Arm [232]

În 1997 a fost introdus pe piață sistemul Utah Arm 2, un sistem ce păstra toate funcțiile existente în sistemul anterior și în plus dispunea de un sistem de comandă proporțională îmbunătățit destinat atât acționării cotului cât și acționării mâinii. Sistemul este comandat prin semnal mioelectric provenit de la doi electrozi. Electrozii sunt plasați pe două grupe de mușchi complementare, de obicei pe biceps respectiv pe triceps. Unitatea de comandă are ca mod implicit modul de comandă al mâinii. Trecerea în modul de comandă al cotului se realizează printr-o contracție scurtă a ambelor grupe musculare, iar cotul va fi comandat în continuare de semnalul diferențial provenit de la cei doi electrozi. În momentul relaxării mușchilor cotul devine blocat pe poziție și unitatea de comandă revine pe modul implicit.




Figura 3.14 Sistemul protetic Utah Arm 2 [232]

O altă îmbunătățire adusă sistemului este folosirea acumulatorilor NiMH în locul acumulatorilor NiCad. Acest tip de acumulatori oferă o capacitate de stocare mai mare la dimensiuni mai mici ale acumulatorului. Sistemul Utah Arm 2 poate avea ca și unitate terminală unități produse atât de Otto Bock Healthcare sau unități produse de Hosmer cât și unitatea Motion Control Hand de producție proprie.

Începând cu anul 2004, Motion Control a introdus pe piața produselor protetice sistemul Utah Arm 3. Noutatea adusă de acest sistem este utilizarea microprocesoarelor ca și unitate de comandă. Sistemul este controlat de două microprocesoare realizându-se astfel un control simultan al mâinii și al cotului. Ajustările fine pot fi realizate de către pacient, sistemul dispunând de un modul de interfață PC. Semnalele mioelectrice sunt captate tot de la doi electrozi, dar se află în stadiu de cercetare și un sistem cu un singur electrod.




Figura 3.15 Sistemul protetic Utah Arm 3 [232]

3.2.6. RSL Steeper

RSL Steeper este o companie britanică care a luat naștere prin fuziunea a două companii: Reheabilitation Services Ltd și Hugh Steeper. Reheabilitation Services a fost o companie tânără înființată în 1987 de către patru proteticieni, iar Hugh Steeper a fost o companie cu experiență înființată în 1921.



Figura 3.16 Sistemul protetic SCAMP [236]

RSL Steeper produce o gamă variată de proteze mecanice și estetice. În domeniul protezelor mioelectrice, compania produce terminale pentru copii și adulți, acumulatori, electrozi și cârlige electrice (grippers). SCAMP este o proteză destinată copiilor. Este comandată de un semnal mioelectric provenit de la un singur electrod, care comandă operația de deschidere, operația de închidere realizându-se prin intermediul unui arc. Protezele pentru adulți sunt comandate de semnale mioelectrice provenite de la doi electrozi iar modul de comandă poate fi selectat prin intermediul unui comutator rotativ situat la încheietura mâinii. Pot fi selectate patru moduri de operare: mono semnal, semnal dual, semnal dual cu acționare la viteză maximă, semnal dual cu acționarea proporțională.

3.2.7. Variety Ability Systems

Variety Ability Systems este o firmă canadiană înființată în 1970 în Ontario. Firma a fost înființată cu scopul de a produce produse protetice pentru copii. Inițial s-a început cu proteze pasive iar mai târziu s-a început și fabricarea de proteze electrice și mecanice. În momentul actual firma produce 4 mărimi de proteze mână cu acționare mioelectrică. Modul de marcare al mărimii se face în funcție de vârsta pentru care e destinată proteza și nu în funcție de mărimile fizice ale protezei (W0-3,W2-6,W5-9,W7-11).



Figura 3.17 Sistemul protetic Variety Systems [237]

Protezele sunt comandate de un modul de comandă programabil de fabricație proprie (Single Programmable Microcomputer). Comanda se face în funcție de semnalul mioelectric provenit de la electrozi și de semnalul de reacție provenit de la senzori rezistivi sau de la microîntrerupătoare. Sunt acoperite mai multe strategii de comandă, cum ar fi: comandă de stare (On/Off) cu semnal de la unul sau doi electrozi, comandă proporțională. În plus protezele sunt dotate cu un întrerupător de control ce permite deschiderea protezei de către o altă persoană (în general de către părinte).

Un alt produs al firmei este proteza braț pentru copii. Variety Ability Systems produce acest tip de proteză în două mărimi. Proteza folosește subansamble produse de Otto Bock Healthcare și de către Liberating Technologies.

3.3. Sisteme protetice experimentale cu comandă mioelectrică

Mâna umană este un sistem complex ce posedă un număr mare de grade de libertate de mișcare, un sistem senzorial cu peste 17000 de unități senzoriale, un sistem de acționare bazat pe mușchi și tendoane și nu în ultimul rând un sistem de comandă complex. Cu toate că mâna umană este un sistem complex, efortul depus de un individ pentru a efectua diverse operații cu ajutorul mâinii este destul de redus. Sistemele protetice actuale sunt doar o replică simplă a mâinii umane, reușind să ajute un individ cu handicap să efectueze operații simple de prindere fără a fi capabile să furnizeze informații senzoriale de reacție. Deși există o diversitate de soluții protetice, majoritatea sunt capabile să ofere doar 2 grade de libertate, datorită utilizării unor metode simple de procesare a semnalului mioelectric. Datorită acestui fapt sistemele protetice sunt departe de a replica mișcările mâinii umane.

Pentru majoritatea sistemelor protetice comerciale procesarea semnalului mioelectric se reduce la redresarea și filtrarea semnalului achiziționat și stabilirea unor nivele de tensiune pentru a defini anumite stări de comandă ale sistemului protetic. Începând cu ani 70, semnalul mioelectric a fost modelat ca și un semnal zgomot Gaussian modulat în amplitudine a cărui frecvență de variație depinde de forța dezvoltată de mușchi [23][25]. Singuri parametri ai acestui semnal, folosiți pentru comanda sistemelor protetice comerciale sunt: frecvența de variație pentru sistemele cu comandă proporțională respectiv valoarea medie absolută pentru sistemele cu comandă de stare. O serie de alți parametri pot fi folosiți pentru comanda sistemelor protetice, dar la momentul actual există doar încercări experimentale.

3.3.1. Sistem de comandă mioelectrică pentru proteze mână dezvoltat de universitatea din Lund

În 1998 universitatea din Lund a realizat un sistem mioelectric de comandă pentru proteze mână bazat pe procesarea a semnalului mioelectric cu ajutorul unei rețele neuronale artificiale [62][63]. Semnalul mioelectric a fost achiziționat, de la o persoană cu handicap, prin intermediul a opt electrozi de suprafață, preprocesat și aplicat unei rețele neuronale cu autoorganizare cu ajutorul căreia s-a realizat o clasificare pe categorii a semnalului achiziționat. Categoriilor astfel obținute li s-au

asociat activității motorii cu ajutorul datelor furnizate de la brațul sănătos al pacientului prin intermediul unei mânuși de date.




Figura 3.18 Sistemul mioelectric de comandă Lund [62]

Semnalul mioelectric achiziționat este amplificat și trecut printr-un filtru de rejecție de 50 Hz. Semnalul astfel obținut este digitizat folosind o frecvență de eșantionare de 8 kHz. În continuare semnalul este trecut printr-un bloc de preprocesare. În figura 3.21 este prezentată structura bloc a sistemului de preprocesare folosit. Sistemul de preprocesare este compus dintr-un redresor, un bloc de corelare pentru eliminarea interferențelor dintre canale, un filtru trece bandă realizat din două filtre trece jos. În final, pentru a reduce spațiul de stocare, informația redundantă este eliminată.




Figura 3.19 Structura bloc a sistemul mioelectric de comandă Lund [62]
Pentru a reduce interferențele dintre canale s-a folosit următorul algoritm:

$$g(t) = (1 - \alpha)g(t-1) + \alpha \sum_{k=0}^K f_k(t-1)$$

(3.7)

$$h_k(t) = f_k(t) \left[\sum_{k=0}^K f_k(t) \right]^{-1} g(t)$$

unde K este numărul de canale, α este o constantă iar $g(t)$ reprezintă valoarea medie instantanee a activității totale a semnalului.

Filtrul trece bandă este realizat din două filtre trece jos de ordinul 3. Diferența dintre semnalele de la ieșirea celor două filtre reprezintă semnalul de ieșire al filtrului trece bandă.

Clasificarea semnalului se face prin utilizarea unei rețele neuronale cu autoorganizare și cu mecanism de conștiință conform mecanismului de conștiință

propus de DeSieno. În acest caz se monitorizează pentru fiecare neuron de câte ori a ieșit câștigător. Noțiunea de conștiință constă în faptul că neuronul care a ieșit de cele mai multe ori câștigător „se simte vinovat” și își micșorează șansele de a ieși câștigător. Pentru a calcula de câte ori a ieșit un anumit neuron câștigător se folosește formula :

$$f_i(t-1) = f_i(t)(1-\beta) - \beta z_i(t) \quad (3.8)$$

unde $z_i(t)$ este 1 când neuronul i câștigă la momentul t , iar pragul de activare al neuronului i se calculează astfel:

$$bias_i(t) = \lambda_i \left\{ \frac{1}{N} - f_i(t-1) \right\} \quad (3.9)$$

unde λ este o constantă iar N este numărul de neuroni al rețelei.

În acest mod fiecare neuron va hotărî ce pondere are fiecare intrare a rețelei.

Acest sistem a fost testat pe un pacient de 24 de ani, născut fără mâna stângă. Pacientului i s-a cerut să își imagineze ca execută anumite mișcări cu mâna stângă și au fost înregistrate semnalele mioelectrice corespunzătoare. Categoriile de tipare obținute au fost asociate cu activități motoare folosind datele obținute de la o mânășă de date aplicată pe mâna dreaptă a pacientului. Activitățile motoare au constat în mișcarea individuală a degetelor mâinii. Experimentul a demonstrat că rețelele neuronale pot fi folosite cu succes pentru clasificarea de tipare ale semnalului mioelectric și totodată a demonstrat că semnalul mioelectric furnizat de senzorii de suprafață conține suficiente informații pentru a comanda o proteză.

3.3.2. Sistem de comandă mioelectrică pentru proteze mână dezvoltat de universitatea din New Brunswick

Institutul de inginerie biomedicală al universității New Brunswick, Canada, este unul dintre centrele de cercetare cu multe realizări în domeniul sistemelor protetice cu comandă mioelectrică. Cercetările realizate de acest grup de cercetători sau axat în special pe sistemele de comandă cu trei stări și pe sistemele de feedback senzoriale. O mare parte din sistemele protetice comerciale sunt echipate cu sistemul de comandă cu trei stări dezvoltat de UNB.

UNB în colaborare cu Hugh Steeper Ltd au dezvoltat un sistem mioelectric de comandă pentru sistemele protetice cu 3 grade de libertate. Pentru selecția unei anumite operații ale sistemului protetic, sistemul de comandă analizează tiparele existente într-un semnal mioelectric de scurtă durată [127][128][131][132].

În general, pentru comanda sistemelor protetice se folosește un semnal mioelectric stabil, adică generat de sistemul muscular în cazul unui efort constant. În cazul unui efort constant, datorită reacțiilor neuromusculare, semnalul mioelectric este foarte activ datorită modificării continue a frecvenței de activare a mușchilor și a fenomenului de recrutare, măsuri necesare luate de sistemul neural pentru a menține o contracție constantă. Pe de altă parte contracțiile de scurtă durată generează o serie de semnale mioelectrice caracteristice pentru diferite activități musculare.

Grupul de cercetători de la UNB a efectuat o serie de măsurători în cazul efectuării unor contracții musculare de scurtă durată. Măsurătorile au fost efectuate cu o singură pereche de electrozi bipolari amplasați pe grupele musculare biceps și

triceps. Această amplasare a electrozilor are rol de a permite unui număr mare de mușchi să influențeze măsurătorile efectuate. Subiectul a executat o serie de contracții distincte de scurtă durată. În urma măsurătorilor au fost observate în semnalul mioelectric înregistrat o serie de tipare specifice diferitelor activități musculare.

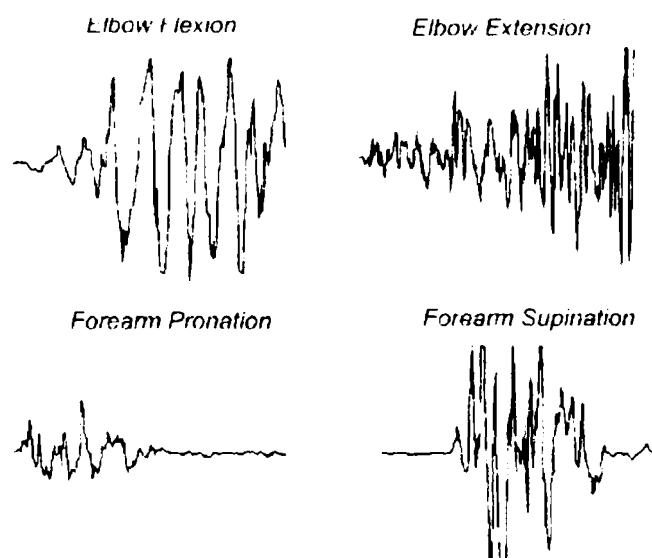


Figura 3.20 Exemple de semnale EMG tranzitorii [100]

În înregistrările efectuate în mod repetat pentru același tip de activitate musculară s-au observat similitudini dar și modificări pentru o serie de caracteristici locale ale semnalului. Pentru a diminua efectul factorilor variabili s-a recurs la alegerea unui prag de activare și la divizarea în segmente a primelor 240ms din semnalul mioelectric ce depășește pragul de activare stabilit.

Din semnalul astfel obținut s-au extras o serie de parametri caracteristici cum ar fi: valoarea medie absolută, panta semnalului, lungimea semnalului, trecerile prin zero etc. Acești parametri au fost folosiți pentru antrenarea unei rețele neuronale artificiale de tip perceptron multistrat. Prin utilizarea acestei rețele neuronale artificiale la procesarea semnalului mioelectric s-a reușit identificarea a patru tipuri de mișcări independente. Această metodă de procesare a semnalului mioelectric poate realiza un control multifuncțional al unui sistem protetic cu un singur canal. Datorită faptului că metoda prezentată identifică contracțiile musculare efectuate de pacient, controlul efectuat va fi un control natural.

Metoda a fost îmbunătățită și pusă în practică. Sistemul de comandă dezvoltat prezintă două canale de achiziționare a semnalului mioelectric și este folosit pentru comanda sistemelor protetice multifuncționale cu trei grade de libertate. Sistemul de comandă are mai multe moduri de operare. Inițial, sistemul de comandă este antrenat folosind semnale mioelectrice distincte furnizate de pacient. Datele obținute sunt folosite pentru a configura rețeaua neuronală artificială, ponderile rețelei neuronale fiind înscrise într-o memorie EPROM. După configurare sistemul poate fi folosit pentru comanda unui sistem protetic cu trei grade de libertate sau pentru comanda unui braț virtual.

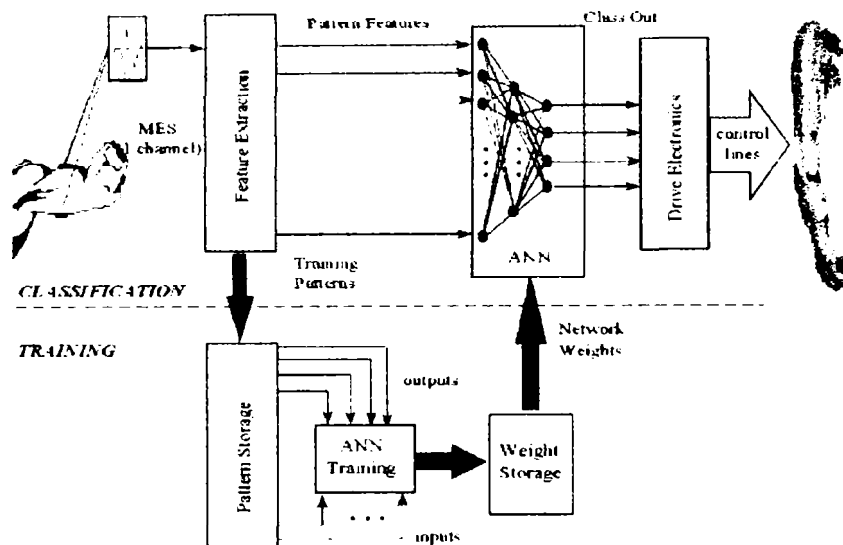


Figura 3.21 Structura bloc a sistemului de procesare a semnalului EMG propus de Hudgins [100]

Dezavantajele acestui sistem de comandă constau în faptul că sistemul necesită o fază de antrenare și calibrare efectuată în laborator, Pacientul nu poate recalibra ponderile rețelei artificiale, iar performanțele acestora sunt direct legate de diferențele dintre stările de oboseală ale pacientului în momentul antrenării rețelei neuronale și în momentul utilizării acesteia.

3.3.3. Southampton – Remedi hand

Principalul dezavantaj al protezelor comerciale este că posedă unul sau două grade de libertate. Un sistem protectic cu trei grade de libertate necesită o strategie de comandă multifuncțională. Sistemele protetice cu trei grade de libertate existente folosesc pentru selecția unei anumite funcții o combinație de contracții musculare. Acest tip de comandă este destul de incomod pentru pacient, el fiind supus unui efort fizic suplimentar. Pe lângă efortul fizic depus, pacientul trebuie să își amintească combinațiile necesare pentru selecția unei anumite funcții și pierde timp pentru executarea combinației respective. Pacientul nu poate executa tot timpul corect combinația de selecție, iar în cazul unei erori, pacientul trebuie să execute o combinație de resetare. Deși acest tip de proteze oferă efectuarea unor operații mai complexe ele nu prea sunt agreate de pacienți datorită complexității operațiilor de comandă pe care aceștia trebuie să le efectueze.

Un alt dezavantaj al sistemelor protetice comerciale constă în dificultatea de a menține o forță constată în cadrul operațiilor de prindere. Forța de prindere poate fi comandată proporțional cu intensitatea semnalului mioelectric recepționat, dar în cazul în care este necesară menținerea unei forțe constante un timp îndelungat acest sistem de comandă nu mai dă rezultate. Soluțiile comerciale constau în activarea unui întrerupător care să blocheze proteza pe poziția respectivă.

La universitatea din Southampton, în anii 1960, s-a început dezvoltarea unui sistem protectic care să elimine aceste dezavantaje [127][128]. Acționarea acestui sistem protectic se bazează pe o strategie de comandă ierarhică. Pacientul menține un control superficial al protezei, ca și în cazul protezelor cu două canale, în timp ce un

sistem de comandă bazat pe microprocesor și un sistem senzorial asigură controlul forței de acționare în funcție de operația efectuată.

Sistemul ierarhic de comandă dezvoltat de universitatea din Southampton (Southampton Adaptive Manipulation Scheme) permite comanda unor sisteme protetice cu multifuncționale fără a crește complexitatea controlului exercitat de pacient. Ideea de bază a acestei strategii de comandă provine de la comanda asigurată de sistemul nervos uman care este tot un sistem ierarhic de comandă.

În cazul comenzi oferite de sistemul nervos uman pentru acționarea brațului, cel mai mic nivel ierarhic asigură poziționarea degetelor și forța necesară operațiilor de prindere. O mare parte din informațiile senzoriale sunt procesate direct la acest nivel ierarhic nemaifiind transmise la creier. În general operațiile efectuate direct la acest nivel ierarhic sunt operațiile de tip reflex cum ar fi: ajustarea forței de prindere pentru a asigura o prindere stabilă, ajustarea poziției degetelor pentru a asigura o prindere stabilă, reflexul datorat unor factori externi etc.

SAMS încearcă să copieze sistemul ierarhic de comandă uman. Pacientul controlează operațiile de bază, iar un sistem bazat pe microcontroler asigură forța de acționare, poziționarea degetelor etc. ca răspuns la informațiile provenite de la un sistem senzorial. Sistemul de comandă propus are cinci stări de comandă: POSITION - poziție, TOUCH - atingere, HOLD - menținere, SQUEEZE - strângere și RELEASE - eliberare.




Figura 3.22 Principiul de comandă al sistemului SAMS [127]

În starea POSITION sistemul de comandă asigură o poziție corectă de prindere. Mâna artificială se deschide proporțional cu intensitatea semnalului mioelectric de comandă asigurat de pacient. Deschiderea este urmată de operația de închidere comandată de către microprocesor. Mâna artificială se va închide automat până ce senzorii din fiecare deget detectează prezența obiectului supus operației de prindere. În acest moment sistemul de comandă asigură o prindere minimală și trece în următoarea stare de comandă.

Din starea TOUCH sistemul poate trece înapoi în starea POSITION dacă pacientul efectuează o scurtă contracție a mușchilor extensor. Dacă se execută o contracție a mușchilor flexori sistemul va trece în starea HOLD. În starea HOLD sistemul de comandă asigură menținerea unei forțe de prindere optimă. Pentru a împiedica alunecare obiectului, forța de prindere este reglată automat în funcție de informațiile primite de la senzorii de alunecare.

Din starea HOLD se poate trece în starea SQUEEZE prin efectuarea unei scurte contracții a mușchilor flexori. În această stare forța de prindere este controlată de către pacient proporțional cu amplitudinea semnalului mioelectric de comandă. Atât din starea de HOLD cât și din starea de SQUEEZE se poate trece în starea de repaus prin efectuare unei contracții a mușchilor extensori.

3.4. Concluzii

În acest capitol se prezintă o analiză a metodelor de procesare a semnalului mioelectric utilizate în sistemele protetice actuale precum și o analiză a unor metode experimentale de procesare. De asemenea este realizată o trecere în revistă a sistemelor protetice comerciale existente la ora actuală. Sunt prezentate principalele soluții protetice a celor mai importante companii din industria protetică. Deși există o serie de soluții noi pentru comanda mioelectrică a sistemelor protetice, sistemele protetice actuale folosesc variațiuni ale unei soluții dezvoltată în perioada 1950-1960. Această soluție presupune redresarea semnalului mioelectric achiziționat și compararea amplitudinii cu un nivel prag. Prin utilizarea soluțiilor bazate pe estimarea amplitudinii semnalului mioelectric pot fi comandate sisteme protetice ce pot realiza un număr de 2-3 acțiuni. În general acțiunile ce pot fi realizate sunt antagoniste. O variație a acestei metode presupune o metodă de codare în frecvență pentru selectare unei perechi de acțiuni antagoniste, urmată de comandă acțiunilor prin metoda estimării amplitudinii. În anii 80-90 au fost dezvoltate metode ce permit acționarea sistemelor protetice cu o viteză proporțională cu intensitatea semnalului mioelectric. Metodele de comandă ale acestor sisteme protetice nu sunt naturale, aceste metode presupun ca utilizatorul să învețe de la zero metoda de comandă. În ultimii 15 ani au fost dezvoltate o serie de metode experimentale ce propun metode naturale de comandă. Aceste metode constau în analiza semnalului mioelectric și identificare operației de mișcare ca și cum s-ar fi realizat în cazul în care utilizatorul nu ar avea membrul respectiv amputat. O astfel de soluție o reprezintă sistemele bazate pe clasificarea semnalului EMG cu ajutorul unor sisteme de recunoaștere a tiparelor bazate pe rețele neuronale artificiale. Au fost obținute rezultate notabile, dar datorită faptului că aceste soluții nu se reflectă și în sistemele protetice comerciale sugerează faptul că performanțele obținute nu sunt suficient de ridicate.

4 ANALIZA SEMNALULUI MIOELECTRIC ÎN DOMENIUL FRECVENȚĂ-TIMP

Semnalul mioelectric este un semnal nestaționat. Acest lucru se datorează modului în care sunt recrutate unitățile motoare în cazul unei contracții. Pentru realizarea unei contracții de intensitate mai ridicată sunt recrutate din ce în ce mai multe unități motoare și totodată este mărită frecvența cu care aceste unități motoare sunt activate. Deci ca urmare, frecvența semnalului mioelectric de suprafață este variabilă în timp. Pentru analiza acestui tip de semnal nu sunt suficiente metodele de analiză pentru semnalele staționare, care pot fi analizate separat în domeniul timp respectiv în domeniul frecvență.

Analiza unui semnal nestaționat presupune o analiză a semnalului în domeniul frecvență-timp, analiză ce poate fi realizată prin intermediul transformatei wavelet sau a transformatei Fourier scurtă. Avantajul transformatei wavelet față de transformata Fourier scurtă constă în faptul că prin intermediul transformatei wavelet se poate realiza o mai bună localizare în timp a componentelor spectrale datorită modului de divizare a spațiului frecvență-timp. Totodată transformatele wavelet pot fi realizate prin utilizarea a unor tipuri diferite de funcții wavelet ceea ce permite adaptarea analizei în funcție de natura semnalului analizat.

Acest capitol va trata diferite modalități de analiză în domeniul frecvență-timp a semnalului mioelectric. Scopul urmărit este de a găsi o modalitate optimă de extragere a unui vector de trăsături din semnalul mioelectric, care să poată fi utilizat ca și vector de intrare pentru un sistem de comandă mioelectrică bazat pe recunoașterea tiparelor. Autorul va încerca să identifice modalități de implementare hardware, în circuite FPGA, a unui modul de extragere a vectorului de trăsături utilizând analiza wavelet a semnalului mioelectric. În prima parte a acestui capitol vor fi prezentate noțiuni generale legate de analiza în domeniul frecvență-timp a semnalelor nestaționare. Dintre metodele de analiză în domeniul frecvență-timp existente, autorul se axează pe două metode, și anume: analiza semnalelor utilizând transformata Fourier scurtă și analiza semnalelor utilizând transformata wavelet. Principalele surse bibliografice studiate de autor pentru elaborarea primei părți a acestui capitol sunt: [20][38]-[39][45][46][140]-[142][141][149][150][166][211].

În partea a doua a acestui capitol autorul propune o serie de soluții pentru implementarea hardware, în circuite logice programabile, a unui modul de descompunere wavelet. Soluțiile prezentate aduc îmbunătățiri în ceea ce privește numărul de resurse utilizate pentru implementare sau aduc îmbunătățiri legate de timpii de procesare. De asemenea, în această parte, autorul propune o metodă de evaluare a funcțiilor wavelet optime pentru analiza semnalului mioelectric. Sursele bibliografice studiate de autor pentru elaborarea acestei părți sunt: [3][8][12][18][19][36][37][40][52][115][118][138][163][173].

4.1. Analiza semnalelor netaționare în domeniul frecvență-timp

Semnalele pe care le întâlnim în jurul nostru sunt semnale analogice pe care le percepem în reprezentare în domeniul timp. O reprezentare a unui semnal în domeniul timp se oglindește prin ridicarea caracteristicii valori momentane – timp a semnalului. În cele mai multe cazuri această reprezentare nu este cea mai bună soluție pentru caracterizarea unui semnal, deoarece nu dezvăluie nici o informație privitoare la componența spectrului de frecvențe a semnalului. Componența spectrală a unui semnal poate fi studiată utilizând analiza în domeniul frecvență a semnalului. Analiza în domeniul frecvență se face utilizând transformata Fourier. Prin utilizarea transformatei Fourier se poate obține o reprezentare amplitudine frecvență a semnalului studiat. În cazul semnalelor staționare, analiza în domeniul timp și în domeniul frecvență furnizează destule informații pentru studiul semnalului. În cazul semnalelor netaționare informațiile obținute în urma analizei separate în cele două domenii nu este suficientă.

Analiza în domeniul frecvență prin utilizarea transformatei Fourier ne dă informații cu privire la componența spectrului de frecvențe a semnalului dar nu și despre momentul în timp la care apar componente de anumită frecvență în structura semnalului studiat. Pentru a înlătura acest neajuns s-a recurs la aplicarea transformatei Fourier pe anumite porțiuni din semnalul studiat. Astfel prin alegerea unei funcții fereastră și aplicarea transformatei Fourier asupra semnalului de studiat prin intermediul acestei funcții fereastră se obțin informații referitoare la componența spectrală pe durata de timp egală cu lungimea funcției fereastră. Prin alegerea unei funcții fereastră scurte se poate obține informații temporale legate de componentele de frecvență înaltă ale semnalului, iar prin utilizarea unei funcții fereastră de lungime mare se pot obține informații temporale legate de componentele de frecvență joasă ale semnalului. După cum se poate observa, dezavantajul transformatei Fourier fereastră este legat de faptul că poate furniza informații temporale doar pentru un anumit domeniu de frecvențe. Prin utilizarea unei funcții fereastră de lățime variabilă s-ar putea elimina acest neajuns. Acest lucru se poate realiza prin utilizarea transformatelor undișoară (wavelet). Transformatele wavelet împart planul frecvență-timp în mod variabil, astfel pentru componentele de joasă frecvență să se obțină o bună localizare a frecvenței iar pentru componentele de înaltă frecvență să se obțină o bună rezoluție de timp. În figura 4.1 se prezintă modul de partiționare planului frecvență – timp pentru transformata Fourier scurtă, transformata wavelet și transformata wavelet pachet.

Funcțiile wavelet sunt unelte relativ noi în domeniul prelucrărilor de semnale. La ora actuală interesul față de aceste funcții este mare atât din partea teoreticienilor cât și din partea inginerilor care investighează posibilele utilizări eficiente ale acestora în domenii foarte variate. Teoria funcțiilor wavelet caută, în general, reprezentarea eficientă a unor funcții (semnale), de diferite categorii cu caracteristici foarte diferite, în termenii unor componenți de bază, cu caracterizare simplă, cu caracteristici de localizare timp-frecvență bune. Impactul major al acestei teorii s-a cristalizat în urma unor lucrări de referință din domeniul analizei armonice semnale Grossmann, Morlet sau Meyer, cu mai mult de un deceniu în urmă [141][140][150][149]. De atunci acest subiect a constituit tema unei activități de cercetare vaste în mai toate domeniile de interes.




Figura 4.1 Modul de partiționare al planului frecvență-timp pentru
 a) transformata Fourier scurtă b) transformata wavelet c) transformata wavelet pachet

Aplicabilitatea acestora în diverse faze de prelucrare a semnalelor a fost analizată atât de matematicieni cât și de ingineri. S-au analizat proprietățile unor clase foarte variate de funcții wavelet, s-au implementat algoritmi eficienți de calcul, s-au propus căi alternative de soluționare a unor probleme matematice complexe (cum ar fi soluționarea numerică a ecuațiilor diferențiale etc.). De asemenea, au fost dezvoltate noi metode de filtrare în subbenzi, au fost concepute scheme piramidale deosebit de eficiente în prelucrarea imaginilor, au fost concepute metode noi de îmbunătățire a raportului semnal/zgomot din diverse domenii (radar, sonar, ecografie, tomografie, geologie, astronomie etc.), au fost propuși noi algoritmi de compresie etc. Mallat și Meyer [140] au introdus noțiunea de analiză multirezoluție ce oferă un cadru general de studiu pentru dezvoltarea semnalelor în baze de funcții wavelet ortogonale și neortogonale. Ei au făcut, de asemenea, conexiunea acestor tehnici cu metodele de filtrare în cuadratură și de filtrare în subbenzi. Daubechies a propus metode eficiente de construcție a unor funcții wavelet cu suport compact și cu o regularitate arbitrară, impusă.

4.2. Transformata Fourier scurtă

Pentru semnalele nestaționare, al căror spectru se modifică în timp, se poate considera că pe intervale scurte de timp spectrul acestora este constant. Dacă vom aplica transformata Fourier doar unei porțiuni a semnalului, vom obține un spectru local, iar transformata astfel definită se numește transformată Fourier scurtă (STFT). Această abordare a analizei unui semnal a fost realizată de Dennis Gabor în 1946. Datorită acestui fapt acest tip de transformată se numește și transformata Gabor. În unele cărți de specialitate prin transformata Gabor se face referință doar la transformata Fourier scurtă în care funcția fereastră utilizată este funcția gaussiană.

Transformata Fourier scurtă poate fi interpretată ca o transformată Fourier care se modifică în timp. Ea se aplică unei funcții văzute printr-o fereastră de timp glisantă care se deplasează pe axa timpului. Astfel, datorită translației în domeniul t , STFT dă o imagine despre conținutul în domeniul frecvență al funcției f , la un moment definit de fereastra temporală [166].

Pentru un semnal $f(t)$, transformata Fourier scurtă se definește ca fiind o funcție de două variabile $T_f(\omega, \tau)$ dată de relația:

$$STFT\{f(t)\} \equiv T_f(\omega, \tau) = \int_R f(t) \cdot w(t - \tau) e^{-i\omega t} dt \quad (4.1)$$

unde $w(t)$ reprezintă fereastra de observare. De obicei se consideră ca fereastră de

observare este un semnal de energie unitară $\|w(t)\|^2 = 1$.

Pe baza relației (4.1) se constată faptul că la momentul τ , funcția $T_f(\omega, \tau)$ reprezintă spectrul semnalului $f(t)w(t-\tau)$, obținut prin localizarea în timp, în jurul momentului considerat, a semnalului de analizat. Modificând τ de la $-\infty$ la ∞ , fereastra temporală glisează pe forma de undă a întregului semnal analizat.

Funcția fereastră poate avea mai multe forme dintre care amintim:

- Fereastra rectangulară

$$w(t) = \begin{cases} 1 & t \in [-T, T] \\ 0 & t \notin [-T, T] \end{cases} \quad (4.2)$$

$$W(\omega) = 2T \operatorname{sinc}(\omega T)$$

Acest tip de fereastră asigură o bună localizare temporală, dar o slabă localizare în frecvență (funcția sinc prezintă lobi laterali mari).

$$T_f(\omega, \tau) = \int_R f(t) \cdot w(t-\tau) e^{-j\omega t} dt = \int_{\tau-T}^{\tau+T} f(t) e^{-j\omega t} dt \quad (4.3)$$

La limită, pentru $T \rightarrow \infty$, se obține:

$$\lim_{T \rightarrow \infty} T_f(\omega, \tau) = \lim_{T \rightarrow \infty} \int_{\tau-T}^{\tau+T} f(t) e^{-j\omega t} dt = \int_{-\infty}^{\infty} f(t) e^{-j\omega t} dt = F(\omega) \quad (4.4)$$

$$\lim_{T \rightarrow \infty} W(\omega) = \delta(\omega)$$

Se observă că o localizare ideală în domeniul frecvenței (o fereastră $W(\omega)$ de tip distribuție Dirac), determină pierderea totală a informației temporale, obținându-se la limită cazul transformatei Fourier clasice.

- Fereastra triunghiulară

$$w(t) = \begin{cases} 1 - \frac{|t|}{T} & t \in [-T, T] \\ 0 & t \notin [-T, T] \end{cases} \quad (4.5)$$

$$W(\omega) = T \operatorname{sinc}^2(\omega T / 2)$$

$$T_f(\omega, \tau) = \int_R f(t) \cdot w(t-\tau) e^{-j\omega t} dt = \int_{\tau-T}^{\tau+T} f(t) \left(1 - \frac{|t-\tau|}{T}\right) e^{-j\omega t} dt \quad (4.6)$$

La fel ca și în cazul ferestrei rectangulare, la limită se obține:

$$\lim_{T \rightarrow \infty} T_f(\omega, \tau) = \lim_{T \rightarrow \infty} \int_{\tau-T}^{\tau+T} f(t) \left(1 - \frac{|t-\tau|}{T}\right) e^{-j\omega t} dt = \int_{-\infty}^{\infty} f(t) \left(1 - \frac{|t-\tau|}{T}\right) e^{-j\omega t} dt = F(\omega) \quad (4.7)$$

- Fereastra gaussiană

$$w(t) = \frac{1}{\sqrt{2\pi}} \cdot e^{-\frac{t^2}{2}} \quad (4.8)$$

$$W(\omega) = e^{-\frac{\omega^2}{2}}$$

Transformata Fourier scurtă care utilizează ca și funcție fereastră o funcție gaussiană cu $\sigma = 1$, se numește transformată Gabor.

$$G_f(\omega, \tau) = \int_R f(t) \cdot \frac{1}{\sqrt{2\pi}} e^{-\frac{(t-\tau)^2}{2}} e^{-j\omega t} dt = \int_R f(t) \cdot \frac{1}{\sqrt{2\pi}} e^{-\left[\frac{(t-\tau)^2}{2} + j\omega t\right]} dt \quad (4.9)$$

Utilizarea acestui tip de fereastră conferă avantajul optimizării din punct de vedere al principiului incertitudinii, având aria minimă.

Dacă se discretizează frecvența $\omega = n\omega_0$ și întârzierea $\tau = m\tau_0$ se obține transformata Gabor discretă.

$$G_f(n, m) = \int_R f(t) \cdot \frac{1}{\sqrt{2\pi}} e^{-\frac{(t-m\tau_0)^2}{2}} e^{-jn\omega_0 t} dt \quad (4.10)$$

pentru $\tau_0 = 1$ și $\omega_0 = \pi$ obținem:

$$G_f(n, m) = \int_R f(t) \cdot \frac{1}{\sqrt{2\pi}} e^{-\frac{(t-m)^2}{2}} e^{-jm\pi} dt = \int_R f(t) \cdot \Psi_{n,m}(t) dt \quad (4.11)$$

În cele mai multe cazuri, procesarea semnalului se face cu echipamente digitale, deci este nevoie de transformata Fourier scurtă discretă. Aceasta este dată de relația:

$$STFT\{f[n]\} \equiv T_f(\omega, m) = \sum f[n] \cdot w(n-m) e^{-j\omega m} \quad (4.12)$$

Localizarea bună atât în timp cât și în frecvență poate fi asigurată în limitele principiului incertitudinii al lui Heisenberg-Gabor. Acest principiu afirmă că nu există nici o posibilitate ca o analiză timp-frecvență să se facă cu o precizie arbitrar de bună simultan atât în domeniul timp cât și în domeniul frecvență. Precizia ce se poate obține se numește rezoluție de localizare (temporală sau frecvențială), iar egalitate este valabilă doar în cazul funcției gaussiene.

$$\Delta\omega\Delta\tau \geq \frac{1}{2} \quad (4.13)$$

Inegalitatea Heisenberg pune în evidență imposibilitatea localizării simultane (în același spațiu de reprezentare), cu o precizie arbitrar de bună, atât în domeniul timp, cât și în domeniul frecvență. În mod similar se poate arăta că este imposibil ca un semnal să-și concentreze toată energia pe suporturi compacte în cele două domenii.

4.3. Transformata Wavelet continuă

Transformata wavelet, ca și STFT, mapează o funcție de timp $f(t)$ într-o alta funcție, bidimensională, de variabile ν și τ (în loc de ω și τ). Parametrul ν este denumit scală, el scalează funcția prin "compresia" și, respectiv, "alungirea" ei iar τ este un factor de deplasare care descrie translatarea funcției wavelet în lungul axei timpului. Se presupune că $f(t)$ este un semnal de pătrat integrabil, $f(t) \in L^2[\mathbb{R}]$,

$$\int f^2(t) dt < \infty$$

Trebuie făcută observația că un semnal continuu sau unul sinusoidal nu sunt de pătrat integrabil. În schimb, toate funcțiile cu suport compact și de amplitudine finită satisfac relația anterioară

Se definește Transformata wavelet continuă (CWT) ca fiind:

$$CWT(\nu, \tau) = \frac{1}{\sqrt{\nu}} \int f(t) \Psi^* \left(\frac{t - \tau}{\nu} \right) dt \quad (4.14)$$

unde ν și τ sunt constante reale iar $\Psi(t)$ este funcția wavelet de bază, numită mother wavelet, iar setul $\left\{ \frac{1}{\sqrt{\nu}} \Psi \left(\frac{t - \tau}{\nu} \right) \right\}$ este format din funcțiile bazei, denumite baby wavelets.

Introducând notația:

$$\Psi_{\nu, \tau}(t) = \frac{1}{\sqrt{\nu}} \Psi \left(\frac{t - \tau}{\nu} \right) \quad (4.15)$$

definiția CWT se poate rescrie sub forma:

$$CWT(\nu, \tau) = \int f(t) \Psi_{\nu, \tau}^*(t) dt \quad (4.16)$$

Este ușor de observat că definiția CWT presupune calculul produsului scalar dintre semnalul de analizat și semnalele $\Psi_{\nu, \tau}(t)$. Factorul de normalizare $\frac{1}{\sqrt{\nu}}$ asigură păstrarea energiei semnalelor $\Psi_{\nu, \tau}(t)$ indiferent de valorile particulare ale parametrilor ν și τ :

$$\int |\Psi_{\nu, \tau}(t)|^2 dt = \int |\Psi(t)|^2 dt \quad (4.17)$$

Interpretarea intuitivă a semnalelor $\Psi_{\nu, \tau}(t)$ este imediată: aceste semnale reprezintă versiuni translatare și scalate (dilatate sau comprimate de-a lungul axei timpului) ale semnalului prototip $\Psi(t)$, de unde și denumirea sugestivă a celui din urmă: mother wavelet. Scalarea se poate face prin dilatare (când $\nu > 1$) sau comprimare (pentru $\nu < 1$) (vezi figura 4.2).




Figura 4.2 Versiuni scalate ale semnalului wavelet de tip Coiflet.
a) dilatarea b) comprimarea

Atât în cazul transformatei wavelet cât și în cazul transformatei Fourier, evaluarea transformatei presupune efectuarea unui produs scalar dintre semnalul de analizat și un set de semnale care formează o bază particulară în spațiul vectorial al semnalelor cu energie finită. Dacă în cazul transformatei Fourier baza este formată întotdeauna de aceleași semnale, în cazul transformatei wavelet avem la dispoziție o paletă largă de forme de undă, existând și posibilitatea construirii unei baze noi, optimă în raport cu semnalul de analizat. Baza în raport cu care se face reprezentarea Fourier este o bază ortogonală, dar în cazul reprezentării wavelet există posibilitatea de a utiliza și baze formate din vectori liniar independenți care sunt ortogonali, cum este și cazul reprezentării biortogonale.

Pornind de la definiția produsului scalar al semnalelor de energie finită rezultă ca evaluarea CWT presupune calcularea unui set de produse scalare între semnalul de analizat și setul de funcții wavelet.

$$CWT(\nu, \tau) = \langle f(t), \Psi_{\nu, \tau}(t) \rangle \quad (4.18)$$

Definiția produsului scalar permite și introducerea noțiunii de funcție de intercorelație dintre 2 semnale, care exprimă intuitiv gradul lor de asemănare:

$$R_{x,y}(\tau) = \int x(t)y^*(t-\tau)dt = \langle x(t), y(t-\tau) \rangle \quad (4.19)$$

în care τ desemnează valoarea întârzierii care separă semnalele considerate. Conform relației (4.19), definiția CWT poate fi rescrisă sub forma:

$$CWT(\nu, \tau) = \langle f(t), \Psi_{\nu, 0}(t-\tau) \rangle = R_{f, \Psi_{\nu, 0}}(\tau) \quad (4.20)$$

Conform relației (4.20) se poate afirma că: transformata CWT reprezintă rezultatul evaluării repetate a intercorelației dintre semnalul considerat și versiunile translatale ale unui ansamblu de semnale de tip wavelet afectate de diverse grade de dilatare sau contracție.




Figura 4.3 Reprezentarea grafică a transformatei CWT unor semnale elementare.

Spre deosebire de transformata Fourier, care depinde doar de un singur parametru, transformata wavelet depinde de doi parametri v și τ . Astfel reprezentarea grafică a spectrului de frecvențe este diferită față de reprezentarea utilizată în cadrul transformatei Fourier. Reprezentarea grafică a transformatei wavelet poartă numele de scalogramă. În figura 4.3 exemplifică reprezentarea grafică a transformatei wavelet pentru două funcții elementare. Valorile extreme reprezintă momentul în timp în care în semnalul analizat apar impulsuri bruște de durată scurtă sau momentul în care semnalul analizat prezintă salturi bruște.

Pornind de la definiția produsului de convoluție a două semnale analogice:

$$h(t) * x(t) = \int h(\tau)x(t - \tau)d\tau \quad (4.21)$$

definiția CWT se poate rescrie astfel:

$$CWT(v, \tau) = f(\tau) * \Psi_{\tau,0}^*(-\tau) \quad (4.22)$$

altfel spus, pentru o valoare dată a parametrului v , mărimea $CWT(v, \tau)$ reprezintă ieșirea unui filtru având funcția pondere $\Psi_{\tau,0}(t)$ și semnalul de intrare $f(\tau)$.

4.4. Transformata Wavelet discretă

Există câteva elemente care fac dificilă utilizarea practică a transformatei wavelet continue. Un prim aspect se referă la gradul ridicat de redundanță al setului de valori $CWT(v, \tau)$, după cum s-a arătat anterior, evaluarea acestora presupune calculul intercorelației dintre semnalul analizat și un continuum de versiuni translate și scalate ale unei aceleiași funcții. Cum aceste versiuni nu sunt ortogonale (altfel spus, astfel de versiuni afectate de translații mici vor fi încă suficient de asemănătoare), devine evident că vor apare subseturi de coeficienți $CWT(v, \tau)$ foarte apropiați ca valoare, situație care este inefficientă în practică. Al doilea motiv îl reprezintă faptul că definiția (4.16) presupune folosirea unui număr infinit de valori ale parametrilor v și τ , deși am prefera să lucrăm numai cu un număr limitat al acestora. Un dezavantaj major îl reprezintă inexistența unor soluții analitice capabile

să furnizeze expresia transformatei CWT pentru semnale oarecare, astfel încât suntem nevoiți, exact ca în cazul transformatei Fourier, să facem apel la metode numerice de calcul. Din acest punct de vedere, vom fi interesați de elaborarea unor algoritmi rapizi, așa cum în cazul transformatei Fourier avem la dispoziție varianta FFT.

Transformata wavelet discretă (DWT) se obține din transformata CWT prin discretizarea parametrilor v și τ . Semnalul de analizat poate fi scris astfel:

$$f(t) = \sum_{k=-\infty}^{\infty} \sum_{l=-\infty}^{\infty} d[k,l] 2^{-k} \Psi(2^{-k}t - l) \quad (4.23)$$

Setul de coeficienți $d(k,l)$ definește transformata wavelet discretă. Acest tip de descompunere seamănă cu seria Fourier asociată unui semnal periodic, în care apar numai componentele ale căror frecvențe sunt multiplii întregi ai frecvenței fundamentale. Discretizarea bazată pe un raport egal cu 2 între valorile succesive ale parametrilor v și τ poartă numele de eșantionare diadică. Scalarea se produce prin factori de forma $v = 2^k$, iar translația prin valori $\tau = 2^k l$, cu l număr întreg. Eșantionarea diadică ar putea rata informații relevante despre semnalul de analizat. Discretizarea parametrilor v și τ implică caracterul variabil în timp al reprezentării wavelet, adică dacă avem la dispoziție două semnale identice, care diferă numai printr-o întârziere relativă, reprezentările lor bazate pe relația (4.23) nu vor fi identice.

Modalitatea intuitivă de analiză a unui semnal prin aplicarea sa la intrarea unui ansamblu de filtre având frecvențe centrale și lărgimi de bandă adecvate este tipică pentru un algoritm de procesare denumit codare în subbandă. În cazul tehnicii de codare în subbandă semnalul este trecut printr-o serie de filtre trece-jos și trece-sus pentru a analiza componentele de diferite frecvențe ale semnalului. Rezoluția semnalului este modificată prin operația de filtrare, iar scara semnalului este modificată prin operația de subeșantionare. Ideea care stă la baza acestei tehnici poate fi reprezentată grafic ca și în figura 4.4.

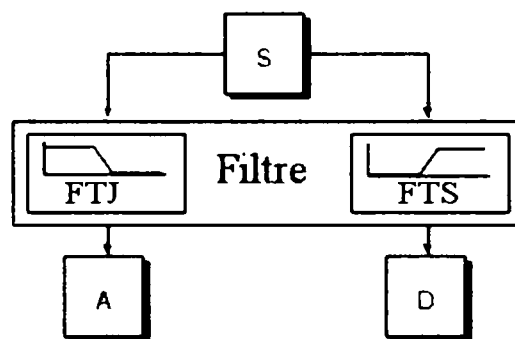


Figura 4.4 Principiul de descompunere pentru transformata wavelet discretă

Semnalul s poate fi reprezentat printr-un semnal aproximativ, obținut în urma operației de filtrare prin intermediul unui filtru trece jos, și un semnal detaliat obținut în urma operației de filtrare prin intermediul unui filtru trece sus. În urma acestor operații obținem două semnale, A și D , ce conțin același număr de eșantioane ca și semnalul original s , deci în total avem de două ori mai multe eșantioane. Numărul de eșantioane al semnalului original depinde de frecvența de eșantionare care la rândul ei depinde de banda de frecvență a semnalului analogic suspus eșantionării. Conform

teoremei lui Nequist, frecvența de eșantionare trebuie să fie cel puțin de două ori mai mare decât limita superioară a bandei de frecvență. Semnalul aproximativ obținut are o bandă de frecvență de două ori mai mică decât semnalul original, deci conform teoremei lui Nequist jumătate din eșantioane sunt redundante. Astfel eliminând tot la doilea eșantion se poate reduce la jumătate dimensiune semnalului aproximativ. În mod similar, semnalul detaliat conține un număr de eșantioane redundante care pot fi eliminate și ele prin subeșantionare.

Procesul de descompunere se poate continua obținându-se astfel un arbore de descompunere, semnalul original putând fi reconstruit prin însumarea semnalului de aproximare și a fiecărui semnal de detaliu. Procesul de descompunere a unui semnal poartă denumirea de analiză iar procesul de reconstrucție a unui semnal prin operația inversă, se numește sinteză.




Figura 4.5 Structura unui sistem de descompunere wavelet

În figura 4.5 se prezintă un nivel de descompunere pentru un sistem de codare în subbandă, iar răspunsul în frecvență ale celor două filtre utilizate este prezentat în figura 4.6. Semnalele prezente la ieșirea celor două filtre pot fi descrise, folosind transformata Z, astfel:

$$\begin{aligned} U(z) &= X(z)H(z) \\ V(z) &= X(z)G(z) \end{aligned} \quad (4.24)$$




Figura 4.6 Răspunsul în frecvență a filtrelor de analiză wavelet

Conform definiției transformatei Z avem:

$$A(z) = \sum_n a[n]z^{-n} = \sum_n u[2n]z^{-n} \quad (4.25)$$

$$\begin{aligned} U(z) &= \sum_n u[n]z^{-n} = \sum_n u[2n]z^{-2n} + \sum_n u[2n+1]z^{-(2n+1)} \\ U(-z) &= \sum_n u[2n]z^{-2n} - \sum_n u[2n+1]z^{-(2n+1)} \end{aligned} \quad (4.26)$$

Se poate scrie:

$$\frac{1}{2}[U(z) + U(-z)] = \sum_n u[2n]z^{-2n} = \sum_n u[2n](z^2)^{-n} = A(z^2) \quad (4.27)$$

În acest caz, relația (4.25) devine:

$$A(z) = \frac{1}{2} \left[U(z^{1/2}) + U(-z^{1/2}) \right] = \frac{1}{2} \left[X(z^{1/2})H(z^{1/2}) + X(-z^{1/2})H(-z^{1/2}) \right] \quad (4.28)$$

În mod analog se poate demonstra că:

$$D(z) = \frac{1}{2} \left[X(z^{1/2})G(z^{1/2}) + X(-z^{1/2})G(-z^{1/2}) \right] \quad (4.29)$$

Pentru a calcula spectrele semnalelor $a[n]$ și $d[n]$ se folosește notația: $X(z) = X(e^{j\Omega})$, iar relațiile (4.28) și (4.29) devin:

$$A(\Omega) = \frac{1}{2} \left[X\left(\frac{\Omega}{2}\right)H\left(\frac{\Omega}{2}\right) + X\left(\frac{\Omega}{2} + \pi\right)H\left(\frac{\Omega}{2} + \pi\right) \right] \quad (4.30)$$

$$D(\Omega) = \frac{1}{2} \left[X\left(\frac{\Omega}{2}\right)G\left(\frac{\Omega}{2}\right) + X\left(\frac{\Omega}{2} + \pi\right)G\left(\frac{\Omega}{2} + \pi\right) \right] \quad (4.31)$$

Luăm spre exemplu un semnal al cărui spectru este reprezentat în figura 4.7. În urma descompunerii în subbenzi, după primul nivel vom avea semnalele $a[n]$ și $d[n]$ ale căror spectru este prezentat în figura 4.7.

Se constată că spectrul $A(\Omega)$ este același cu spectrul $X(\Omega)$ în banda $[-\pi/2, \pi/2]$. De asemenea se poate observa că porțiunea din spectrul $D(\Omega)$ în banda $[-2\pi, -\pi] \cup [\pi, 2\pi]$ este asemenea cu spectrul $X(\Omega)$ în banda $[-\pi, \pi] - [-\pi/2, \pi/2]$. Se poate deci afirma că semnalul $x[n]$ a fost codat în două subbenzi, componentele sale de joasă frecvență regăsiindu-se în semnalul $a[n]$ iar componentele sale de înaltă frecvență, în semnalul $d[n]$. Pentru a crește numărul de subbenzi se poate utiliza o structură arborescentă.




Figura 4.7 Exemplu de descompunere wavelet. Reprezentare spectrală

Dacă se analizează în mod similar componentele spectrale ale fiecărui nivel de descompunere se va constata că spectrul $A_M(\Omega)$ este asemenea cu spectrul $X(\Omega)$ din banda $[-\pi/2M, \pi/2M]$ și că spectrul $D_M(\Omega)$ este asemenea cu spectrul $X(\Omega)$ din banda $[-\pi/(2M-1), \pi/(2M-1)] - [-\pi/2M, \pi/2M]$. Cu alte cuvinte fâșii din banda spectrului $X(\Omega)$ au fost puse în corespondență cu semnalele $s_k[n]$ și $d_k[n]$. Această corespondență este evidențiată în figura 4.8. Folosind acest sistem de descompunere se poate observa că banda spectrului semnalului $x[n]$ este divizată în octave.




Figura 4.8 Corespondența dintre spectrele semnalului de intrare și spectrele coeficienților wavelet

În cazul procesului de sinteză se pune problema refacerii semnalului $x[n]$ pornind de la semnalele $a[n]$ și $d[n]$. Se consideră în acest scop sistemul din figura 4.9.

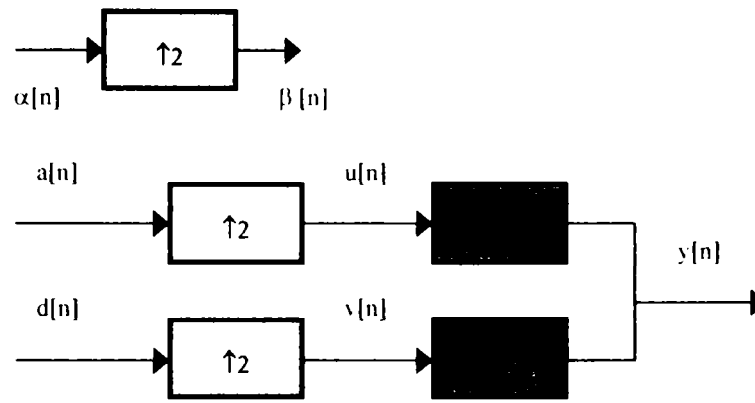


Figura 4.9 Structura unui sistem de reconstrucție wavelet
Semnalul $\beta[n]$ este definit astfel:

$$\beta[n] = \begin{cases} \alpha\left[\frac{n}{2}\right] & n - \text{par} \\ 0 & n - \text{impar} \end{cases} \quad (4.32)$$

Se calculează transformata Z a semnalului $\beta[n]$ pe baza transformatei Z a semnalului $\alpha[n]$:

$$\alpha(z) = \sum_n \alpha[n] z^{-n}$$

$$\beta(z) = \sum_n \beta[n] z^{-n} = \sum_n \beta[2n] z^{-2n} + \sum_n \beta[2n+1] z^{-(2n+1)} = \sum_n \alpha[n] z^{-2n} = \alpha(z^2) \quad (4.33)$$

Aplicând relația (4.33) pentru sistemul din figura 4.12. se obține:

$$U_1(z) = A(z^2)$$

$$V_1(z) = D(z^2) \quad (4.34)$$

sau, ținând cont de relațiile (4.29) și (4.28) avem:

$$Y(z) = H(z) \frac{1}{2} [X(z)H(z) + X(-z)H(-z)] + G(z) \frac{1}{2} [X(z)G(z) + X(-z)G(-z)] \quad (4.35)$$

Pe baza acestei relații se determina spectrul semnalului $y[n]$ ca fiind:

$$Y(\Omega) = H(\Omega) \frac{1}{2} [X(\Omega)H(\Omega) + X(\Omega + \pi)H(\Omega + \pi)]$$

$$+ G(\Omega) \frac{1}{2} [X(\Omega)G(\Omega) + X(\Omega + \pi)G(\Omega + \pi)] \quad (4.36)$$

Dacă se folosesc filtrele cu răspunsurile în frecvență cu caracteristicile de modul din figura 4,6, atunci sunt valabile relațiile:

$$H(\Omega)H(\Omega + \pi) = G(\Omega)G(\Omega + \pi) = 0$$

$$H^2(\Omega) = G^2(\Omega) = 1 \quad (4.37)$$

Pe baza acestor relații, ecuația (4.36) devine:

$$Y(\Omega) = \frac{1}{2} X(\Omega)H^2(\Omega) + \frac{1}{2} X(\Omega)G^2(\Omega) = \frac{1}{2} X(\Omega) [H^2(\Omega) + G^2(\Omega)] = \frac{1}{2} X(\Omega) \quad (4.38)$$

Deci cu excepția unei constante semnalele $x[n]$ și $y[n]$ sunt identice. Se poate spune că acest sistem de analiză – sinteză cu funcții wavelet este un sistem cu reconstrucție perfectă.

Trebuie subliniat faptul că reconstrucția perfectă depinde de performanțele filtrelor utilizate. Considerăm în continuare că filtrele $h[n]$ și $g[n]$ sunt filtre realizabile. În acest caz sistemul de reconstrucție corespunzător unui codor în două subbenzi poate fi reprezentat schematic ca și în figura 4.10.




Figura 4.10 Sistem de reconstrucție corespunzător unui codor în două subbenzi

După cum se poate observa în figura 4.10, semnalul de ieșire este o variantă întârziată cu d a semnalului de intrare. Se pune problema determinării răspunsurilor la impuls $h_r[n]$ și $g_r[n]$ precum și condițiile pe care trebuie să le îndeplinească răspunsurile la impuls a filtrelor $h[n]$ și $g[n]$ pentru ca la ieșirea sistemului să se poată obține semnalul $x[n-d]$.

Relația (4.35) poate fi scrisă astfel:

$$z^{-d}X(z) = H_r(z)\frac{1}{2}[X(z)H(z) + X(-z)H(-z)] + G_r(z)\frac{1}{2}[X(z)G(z) + X(-z)G(-z)] \quad (4.39)$$

sau, regrupând în membrul drept:

$$z^{-d}X(z) = X(z)\frac{1}{2}[H_r(z)H(z) + G(z)G_r(z)] + X(-z)\frac{1}{2}[H_r(z)H(-z) + G(-z)G_r(z)] \quad (4.40)$$

Egalitate (4.40) este satisfăcută dacă:

$$\begin{cases} H_r(z)H(z) + G(z)G_r(z) = 2z^{-d} \\ H(-z)H_r(z) + G(-z)G_r(z) = 0 \end{cases} \quad (4.41)$$

Considerând cunoscute transformatele Z notate cu $H(z)$ respectiv $G(z)$. Determinantul sistemului este:

$$\Delta = \begin{vmatrix} H(z) & G(z) \\ H(-z) & G(-z) \end{vmatrix} = H(z)G(-z) - H(-z)G(z) \quad (4.42)$$

Determinantul corespunzător lui $H_r(z)$ este:

$$\Delta = \begin{vmatrix} 2z^{-d} & G(z) \\ 0 & G(-z) \end{vmatrix} = 2z^{-d}G(-z) \quad (4.43)$$

Determinantul corespunzător lui $G_r(z)$ este:

$$\Delta = \begin{vmatrix} H(z) & 2z^{-d} \\ H(-z) & 0 \end{vmatrix} = -2z^{-d}H(-z) \quad (4.44)$$

Soluțiile sistemului (4.41) sunt date de relațiile:

$$H_r(z) = \frac{2z^{-d}G(-z)}{H(z)G(-z) - H(-z)G(z)} \quad (4.45)$$

$$G_r(z) = \frac{-2z^{-d}H(-z)}{H(z)G(-z) - H(-z)G(z)} \quad (4.46)$$

O condiție care trebuie impusă filtrelor de reconstrucție este ca ecuația $H(z)G(-z) - H(-z)G(z) = 0$ să nu aibă nici o rădăcină diferită de rădăcinile ecuației: $z^{-d} = 0$, deci condiția potrivită ar fi:

$$H(z)G(-z) - H(-z)G(z) = 2z^{-d} \quad (4.47)$$

În acest caz, relațiile (4.45) și (4.46) devin:

$$H_r(z) = G(-z) \quad (4.48)$$

$$G_r(z) = -H(-z)$$

În concluzie, răspunsurile în frecvență ale filtrelor de reconstrucție depind de răspunsul în frecvență ale filtrelor de descompunere conform relațiilor:

$$H_r(\Omega) = G(\Omega + \pi) \quad (4.49)$$

$$G_r(\Omega) = -H(\Omega + \pi)$$

iar răspunsurile în frecvență ale filtrelor de descompunere satisfac condiția:

$$H(\Omega)G(\Omega + \pi) - H(\Omega + \pi)G(\Omega) = 2e^{-j\Omega d} \quad (4.50)$$

Filtrele care satisfac condițiile (4.49) și (4.50) poartă numele de „Quadrature Mirror Filters” (QMF). Prin utilizarea filtrelor de reconstrucție QMF se poate obține o reconstrucție perfectă dacă filtrele de reconstrucție satisfac condițiile (4.49), iar filtrele de analiză satisfac relația (4.50). Relația (4.50) este o relație generală, nefurnizând informații despre modul în care se proiectează filtrele.

Smith și Barnwell au determinat o clasă de filtre de sinteză cu răspunsuri la impuls reale. Această clasă de filtre poartă numele de filtre în cuadratură conjugate (CQR), și satisfac următoarea condiție:

$$G(\Omega) = -e^{-j\Omega d} H^*(\Omega + \pi) \quad (4.51)$$

Folosind condiția din relația (4.51), membrul drept al relației (4.50) devine:

$$\begin{aligned} H(\Omega)G(\Omega + \pi) - H(\Omega + \pi)G(\Omega) &= -H(\Omega) \left[e^{-j(\Omega + \pi)d} H^*(\Omega) \right] + \\ + H(\Omega + \pi) \left[e^{-j\Omega d} H^*(\Omega + \pi) \right] &= e^{-j(\Omega + \pi)d} \left\{ -|H(\Omega)|^2 + |H(\Omega + \pi)|^2 \right\} = 2e^{-j\Omega d} \end{aligned} \quad (4.52)$$

Astfel că relația (4.50) pentru d impar devine:

$$|H(\Omega)|^2 + |H(\Omega + \pi)|^2 = 2 \quad (4.53)$$

În acest caz răspunsurile în frecvență ale filtrelor de reconstrucție devin:

$$\begin{aligned} H_r(\Omega) &= e^{-j\Omega d} H^*(\Omega) \\ G_r(\Omega) &= -H(\Omega + \pi) \end{aligned} \quad (4.54)$$

4.5. Soluții pentru implementarea hardware a algoritmului de descompunere wavelet

În paragraful anterior s-a demonstrat că transformata wavelet discretă poate fi determinată utilizând tehnica de codare în subbenzi. Astfel, un semnal $s[n]$ ce urmează a fi analizat poate fi descompus, prin operația de analiză wavelet, într-un set de coeficienți $d_k[n]$ numiți coeficienți de detaliu, plus un coeficient $a[n]$, numit coeficient de aproximare. În ipoteza utilizării a unui set de filtre ideale cu răspunsurile în frecvență din figura 4.6, semnalul de intrare poate fi reconstruit perfect pe baza coeficienților obținuți în urma analizei wavelet. În figura 4.11 este reprezentat schematic un sistem de analiză și sinteză wavelet.

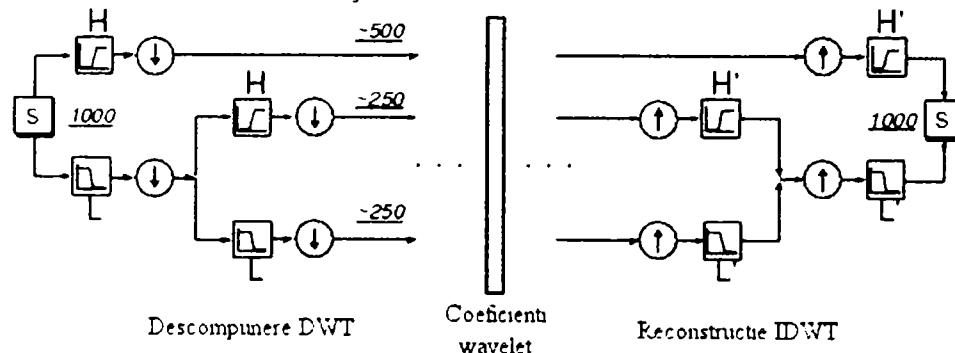


Figura 4.11 Structura unui sistem complet de analiză wavelet

În literatura de specialitate [211] se arată că pentru calculul coeficienților de detaliu și aproximare, corespunzători fiecărui nivel de descompunere, se poate utiliza relația:

$$DWD T_{x(n)} = \begin{cases} d_{j,k} = \sum s(n)h_j^*(n-2^j k) \\ a_{j,k} = \sum s(n)g_j^*(n-2^j k) \end{cases} \quad (4.55)$$

unde $h[n]$ și $g[n]$ reprezintă coeficienții filtrelor de descompunere.

Pentru implementarea hardware a algoritmului de descompunere wavelet este suficientă implementarea unei structuri arborescente de filtre $h[n]$ și $g[n]$ urmate de câte un modul de decimare. Principala componentă a unui astfel de sistem este unitate de filtrare. Această unitate este în general realizată ca și un filtru FIR. Pentru implementarea în circuite FPGA a unui filtru FIR se poate utiliza structura prezentată în figura 4.12.

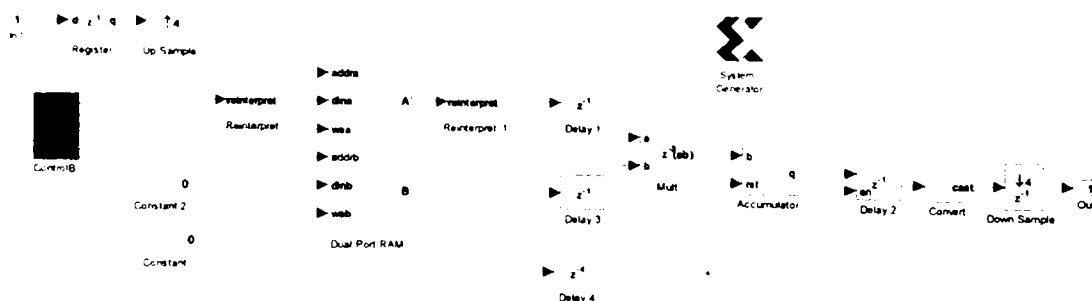


Figura 4.12 Structura FIR pentru un filtru dintr-un etaj de descompunere wavelet

Modulul FIR este constituit dintr-un multiplicator și un acumulator care împreună formează o unitate MAC, și un bloc de memorie pentru stocarea coeficienților și a eșantioanelor. Blocul de memorie este de tip dual, adică permite citirea și scrierea datelor pe două magistrale. Memoria este împărțită în două regiuni: una pentru stocarea coeficienților și una pentru stocarea temporară a eșantioanelor. Pentru stocarea temporară a eșantioanelor, primele $l+1$ locații de memorie (unde n reprezintă ordinul filtrului) sunt configurate ca o memorie ciclică. Următoarele $l+1$ locații sunt destinate stocării coeficienților filtrului. Mărimea blocului de memorie poate fi calculată astfel:

$$\text{Nr locatii} = 2 * l \quad (4.56)$$

unde l reprezintă lungimea filtrului.

Blocul de memorie este inițializat cu zero pentru locațiile corespunzătoare eșantioanelor și cu valorile coeficienților pentru locațiile corespunzătoare coeficienților filtrului. Prin intermediul logicii de comandă se comandă adresarea celor două zone de memorie și înscrierea eșantioanelor în memorie. Pentru adresarea memoriei se utilizează două numărătoare. Numărul de biți pe care se efectuează numărarea depinde de numărul de coeficienți necesari pentru implementarea filtrului. Numărătorul corespunzător pentru adresarea zonei de date a memoriei numără de la 0 la $l-1$, iar numărătorul corespunzător pentru adresarea zonei în care sunt stocați coeficienții numără de la l până la $2 * l - 1$.

În momentul în care numărător_coef atinge valoarea maximă se generează un impuls pentru semnalul de scriere și se dezactivează numărătorul de date pentru un clock. Astfel se permite scrierea datelor în memorie la locația dorită. În figura 4.13 este prezentată simularea funcționării circuitului ce asigură logica de comandă. La intrarea de date a fost introduse valori consecutive pentru a ușura urmărirea funcționării circuitului. În figură sunt ilustrate formele de undă de la ieșirea numărătoarelor, de la cele două ieșiri ale blocului de memorie și forma de undă de la intrarea blocului de memorie.




Figura 4.13 Formele de undă pentru comanda blocului de memorie

Modulul FIR funcționează la o frecvență de l ori mai mare (l – lungimea filtrului) decât frecvența cu care sunt aduse datele de intrare, astfel se asigură obținerea datelor de ieșire la aceeași frecvență cu cea a datelor de intrare. Se poate

observa corespondența dintre coeficienți și eșantioane. Coeficienții se repetă ciclic, dar numărătorul care generează adresele pentru memoria de date este dezactivat pe durata unui tact de fiecare dată când numărătorul care adresează memoria de coeficienți ajunge la valoare maximă. Astfel după fiecare parcurgere a memoriei de coeficienți, datele vor fi decalate cu o poziție. În acest mod fiecare eșantion va fi înmulțit cu fiecare coeficient. Prima formă de undă corespunde numărătorului care adresează memoria de date, a doua formă de undă corespunde numărătorului care adresează memoria de coeficienți, a treia formă de undă corespunde ieșirii memoriei de coeficienți, a patra formă de undă corespunde ieșirii memoriei de date, iar ultima formă de undă corespunde datelor de intrare.

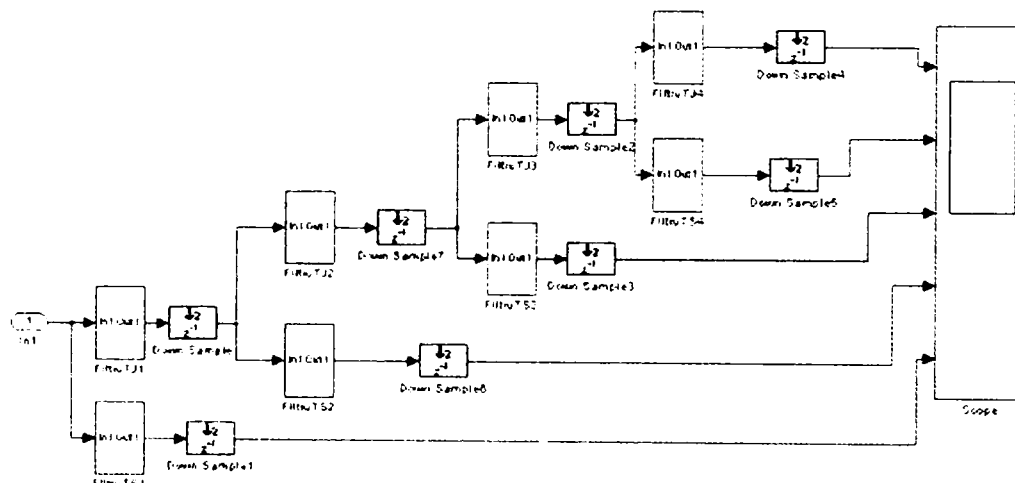


Figura 4.14 Modul de descompunere wavelet pe 4 nivele

Schema bloc pentru un modul de descompunere pe 4 nivele este prezentată în figura 4.14. Pentru acest algoritm este necesară utilizarea a două blocuri de memorie și a două multiplicatoare pentru fiecare nivel de descompunere. Datorită faptului că circuitele FPGA noi au un număr fix blocuri de memorie și multiplicatoare dedicate, aceste unități pot fi considerate ca elemente de comparație între două implementări diferite

Tabelul 4.1 prezintă resursele hardware necesare implementării unui modul de descompunere pe 4 nivele utilizând structura FIR prezentată anterior. Implementarea a fost făcută într-un circuit XILINX Spartan3E XC3S500E. Acest circuit prezintă în structura sa un număr de 20 unități de multiplicare hardware. În tabel este prezentat consumul de resurse atât în cazul utilizării unităților de multiplicare dedicate cât și în cazul utilizării modulelor de multiplicare generate de unitate de sinteză. Se poate observa că în cazul utilizării multiplicatoarelor dedicate consumul de resurse este mai redus cu aproximativ 20%. Dezavantajul unei astfel de implementări constă în faptul că depinde de numărul de multiplicatoare dedicate existente în circuitul FPGA.

Tabel 4.1 Resursele hardware necesare implementării unui modul de descompunere pe 4 nivele

Resurse	Spartan3 multiplicatoare dedicate	%	Spartan3	%
Slice-uri	1254	26.93	2170	46.61
FFs	1826	19.61	3504	37.63
Block RAM	8	40	8	40
LUT	1104	11.86	3320	35.65
Multiplicatoare	8	40	0	0.0

În concluzie se poate spune că această implementare, din punct de vedere al vitezei de calcul este dependentă de lungimea filtrelor utilizate și implicit de tipul și ordinul funcției wavelet utilizate în descompunere. Din punct de vedere al resurselor, soluția este dependentă de numărul de multiplicatoare dedicate existente în FPGA.

Luând în considerare timpii necesari pentru efectuare operațiilor dintr-un etaj de descompunere și numărul de eșantioane ce formează semnalul supus analizei, se poate estima timpul necesar pentru efectuarea descompunerii wavelet până la un anumit etaj de descompunere. Intervalul de timp dintre două eșantioane consecutive ce apar la ieșirea unui etaj de descompunere poate fi determinat astfel:

$$t_{\Delta} = 2 \left[l(t_{\text{fatch}} + t_{\text{mult}}) + t_{\text{stoc}} \right] \quad (4.57)$$

unde :

- l este lungime filtrului,
- t_{fatch} timpul necesar pentru aducerea operanzilor la intrarea multiplicatorului,
- t_{mult} timpul necesar efectuării operației de înmulțire,
- t_{stoc} timpul necesar pentru stocarea rezultatului

Pentru a determina timpul necesar pentru calcularea tuturor coeficienților de la nivelul j se poate utiliza relația:

$$t_j = \frac{N}{2^j} t_{\Delta} \cdot 2^{j-1} = \frac{1}{2} N t_{\Delta} \quad (4.58)$$

unde N reprezintă numărul de eșantioane al ferestrei de procesare.

În cazul în care se utilizează multiplicatoare dedicate pentru implementare, timpul necesar efectuării operației de înmulțire este de 5 perioade de tact, iar pentru aducerea operanzilor și stocarea datelor este necesară câte o perioadă de tact. În acest caz ecuația 4.57 devine:

$$t_{\Delta} = 2 \cdot t_{\text{clk}} (6l + 1) \quad (4.59)$$

Timpul necesar pentru calcularea tuturor coeficienților wavelet de la nivelul j poate fi determinat în acest caz astfel:

$$t_j = \frac{1}{2} N (2 \cdot t_{\text{clk}} (6l + 1)) = N (6l + 1) t_{\text{clk}} \quad (4.60)$$

Rezultă că pentru un interval de timp de descompunere impus, frecvența sistemului poate fi determinată astfel:

$$f_{clk} = \frac{N(6l+1)}{t_{desc}} \quad (4.61)$$

Se poate observa că frecvența sistemului depinde direct proporțional cu numărul de eşantioane ale semnalului de procesat și cu lungimea filtrului, adică cu tipul de funcție wavelet ales pentru descompunere.

Pentru a îmbunătăți consumul de resurse hardware, o soluție alternativă constă în utilizarea unui singur multiplicator pentru fiecare nivel de descompunere. În figura 4.15 este prezentată o soluție hardware ce utilizează un singur bloc de memorie și o singură unitate de multiplicare pentru fiecare nivel de descompunere.

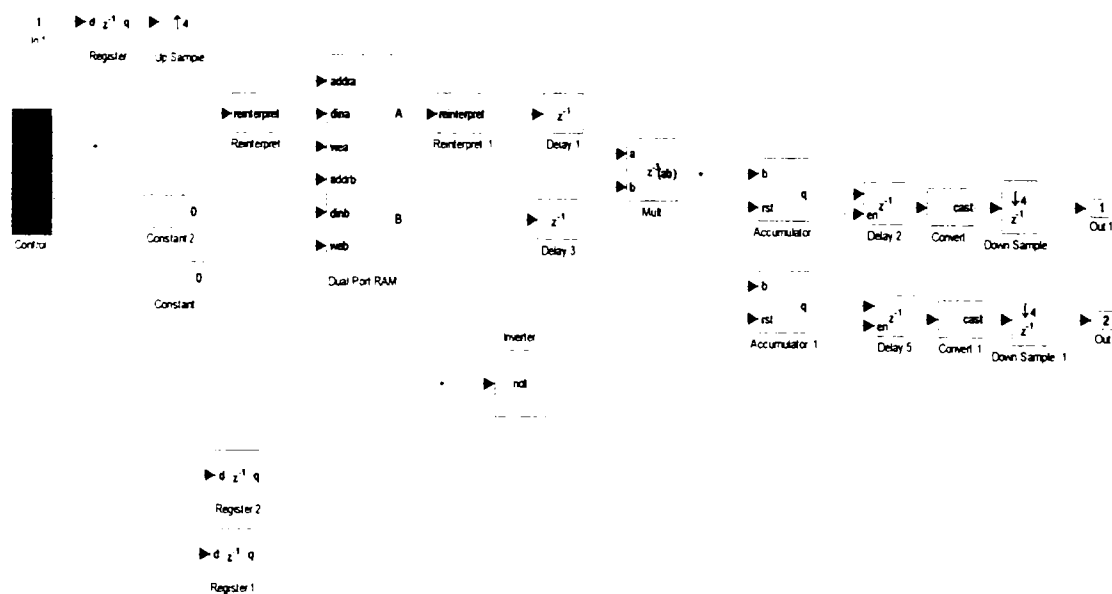


Figura 4.15 Structura unui etaj de descompunere wavelet utilizând un singur multiplicator

Pentru a putea implementa această soluție, blocul de memorie conține coeficienții filtrului trece jos urmat de coeficienții filtrului trece sus. În acest caz mărimea blocului de memorie este de două ori mai mare decât în cazul soluției anterioare. Acest lucru nu constituie un dezavantaj, deoarece în circuitul FPGA în care se face implementarea blocurile RAM dedicate pot avea o maxim 16384 kbiți. În cazul în care datele sunt reprezentate pe 32 de biți, blocurile RAM pot avea maxim 512 locații, ceea ce este mai mult decât suficient în cazul implementării filtrelor de descompunere corespunzătoare unor funcții wavelet. Structura unității de comandă este mai complexă în acest caz trebuind să asigure și demultiplexarea datelor de ieșire.

Tabel 4.2 Resursele hardware necesare implementării unui modul de descompunere pe 4 nivele cu o singura unitate de multiplicare pe nivel

Resurse	Spartan3 multiplicatoare dedicate	%	Spartan3	%
Slice-uri	978	21.01	1720	36.94
FFs	1236	13.27	2718	29.19
Block RAM	4	20	4	20
LUT	1047	11.24	2552	27.41
Multiplicatoare	4	20	0	0.0

În tabelul 4.2 sunt prezentate resursele hardware necesare pentru implementarea unui sistem de descompunere wavelet pe patru nivele folosind metoda cu o singura unitate de multiplicare pe nivel. Se poate observa că în acest caz consumul de resurse este redus cu aproximativ 10% în cazul logicii utilizate și cu 20% în cazul blocurilor RAM și a multiplicatoarelor dedicate, comparativ cu cazul precedent. Resursele hardware sunt economisite în detrimentul vitezei de execuție. Comparativ cu cazul anterior, timpul de execuție este de două ori mai mare, respectiv frecvența sistemului necesară pentru a obține același timp de execuție ca și în cazul anterior, este de 2 ori mai mare.

$$f_{clk} = \frac{2N(6l+1)}{t_{desc}} \quad (4.62)$$

4.5.1. Implementarea unui modul de descompunere wavelet utilizând principiul decimatorului polifazic

Unul dintre principalele dezavantaje a implementării directe a algoritmului de descompunere wavelet constă în faptul că după fiecare filtrare semnalul trebuie decimat cu 2. Cu alte cuvinte jumătate din eșantioanele de la ieșirea filtrului sunt eliminate. Astfel reiese că pentru fiecare unitate de filtrare, jumătate din operații sunt efectuate fără ca rezultatele obținute să aibă vreo utilitate. Prin găsirea unei modalități de eliminare a acestor operații s-ar pute obține un modul de descompunere wavelet ce necesită jumătate din puterea de calcul corespunzătoare implementării clasice.

Conform definiției decimării, între un semnal $x[n]$ și semnalul rezultat în urma decimării cu un factor M se poate scrie relația:

$$y[n] \equiv x[n] \downarrow M = x[Mn] \quad (4.63)$$

Între spectrele celor două semnale are loc relația:

$$Y(\omega) = \frac{1}{M} \sum_{l=0}^{M-1} X\left(\frac{\omega + 2l\pi}{M}\right) \quad (4.64)$$

Se poate observa că pentru o frecvență ω fixată, spectrul semnalului decimat cu factorul M este o sumă de M valori ale spectrului semnalului inițial. Mai precis, pentru a obține $Y(\omega)$ pe intervalul $[-\pi, \pi]$ se ia spectrul $X(\omega)$ pe fiecare interval $[(2l-1)\pi/M, (2l+1)\pi/M]$, se deplasează la stânga pentru a coincide cu $[-\pi/M, \pi/M]$, se

expandează în frecvență cu factorul M , după care se adună cele M spectre astfel obținute. Se disting două situații importante:

- Dacă semnalul inițial are spectrul limitat la banda $[-\pi/M, \pi/M]$, deci $X(\omega) = 0$ pentru $\pi/M < |\omega| \leq \pi$, egalitatea (4.64) se reduce la:

$$Y(\omega) = \frac{1}{M} X\left(\frac{\omega}{M}\right), \omega \in [-\pi, \pi] \quad (4.65)$$

După cum se poate observa și din figura 4.16, spectrul semnalului decimat are aceeași formă ca și spectrul semnalului inițial, dar expandată pe întreg intervalul $[-\pi, \pi]$,

- Dacă spectrul semnalului inițial se întinde dincolo de frecvența π/M , atunci spectrul semnalului decimat un mai are aceeași formă ca și spectrul semnalului inițial, apare fenomenul de aliere.




Figura 4.16 Spectrul unui semnal decimat cu un factor de decimare M

Pentru a evita alierea se utilizează un filtru trece-jos care taie frecvențele superioare lui π/M . Schema de reducere a frecvenței de eșantionare cu factorul M are atunci aspectul din figura 4.17.



Figura 4.17 Structura bloc a unui sistem decimare cu factor M

Dacă se consideră un filtru de decimare cu un factor de 2, funcția de transfer a filtrului $H(z)$ poate fi scrisă:

$$\begin{aligned} H(z) &= \sum_{n=0}^{N-1} h(n)z^{-n} = \sum_{n=0}^{(N-1)/2} h(2n)z^{-2n} + \sum_{n=0}^{(N-1)/2} h(2n+1)z^{-(2n+1)} \\ &= \sum_{n=0}^{(N-1)/2} h(2n)z^{-2n} + z^{-1} \sum_{n=0}^{(N-1)/2} h(2n+1)z^{-2n} = H_0(z^{-2}) + z^{-1}H_1(z^{-2}) \end{aligned} \quad (4.66)$$

Conform ecuației (4.66), structura sistemului de decimare devine ca și cea prezentată în figura 4.18.b. Utilizând identitățile lui Noble (figura 4.18a) putem transforma structura filtrului astfel încât în final se obține structura prezentată în figura 4.18.b Se poate observa că în acest caz prima dată se execută decimare și pe urmă operația de filtrare. În cazul în care unitatea de filtrare este implementată printr-o unitate MAC, numărul de cicluri de execuție este redus cu un factor egal cu factorul de decimare.

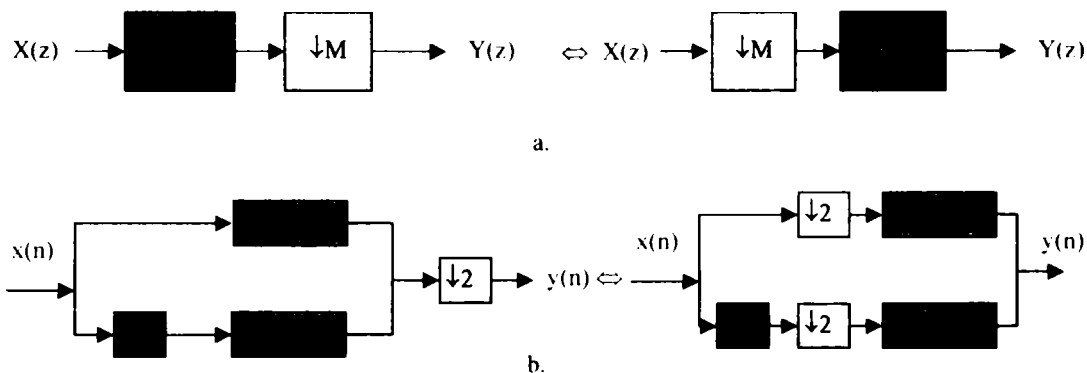


Figura 4.18 a) Identitatea Noble b) Transformarea unui sistem de decimare folosind identitate Noble

Aplicând același procedeu în cazul descompunerii wavelet, structura unui nivel de descompunere se modifică astfel:




Figura 4.19 Structura bloc a unui etaj de analiza wavelet cu decimare polifazică

Structura din figura 4.19 poate fi implementată hardware folosind câte o structură cu un singur multiplicator pentru eşantioanele pare respectiv pentru cele impare. Astfel resursele hardware utilizate vor fi aproximativ aceleași ca și în cazul unei implementări directe dar timpul de răspuns al sistemului va fi înjumătățit.



Figura 4.20 Structura hardware a unui etaj de analiza wavelet cu decimare polifază

În tabelul 4.3 sunt date resursele hardware necesare pentru implementarea unui sistem de descompunere wavelet utilizând principiul decimării polifazice. Se poate observa că în cazul utilizării multiplicatoarelor dedicate consumul de resurse a crescut doar cu aproximativ 5% față de implementarea directă a sistemului de analiză wavelet. În cazul în care nu se utilizează multiplicatoare dedicate consumul de resurse crește cu aproximativ 10 %.

Tabel 4.3 Resursele hardware necesare implementării unui modul de descompunere pe 4 nivele cu decimare polifază

Resurse	Spartan3 multiplicatoare dedicate	%	Spartan3	%
Slice-uri	1316	28,26	2355	50,58
FFs	2122	22,79	4128	44,33
Block RAM	8	40	8	40
LUT	2086	22,4	4615	49,56
Multiplicatoare	8	40	0	0,0

Avantajul acestei implementări constă în timpul redus de execuție. Dacă se impune aceeași restricție pentru timpul de execuție ca și în cazul anterior, adică intervalul de timp dintre două eșantioane consecutive obținute la ieșirea unui etaj de descompunere, frecvența semnalului de tact necesară pentru această implementare poate fi determinată astfel:

$$f_{clk} = \frac{N(\frac{6l}{2} + 1)}{t_{desc}} = \frac{N(3l + 1)}{t_{desc}} \quad (4.67)$$

unde N reprezintă numărul de eșantioane al ferestrei de procesare.

După cum se poate observa, prin utilizarea acestei metode se poate utiliza un semnal de tact de frecvență dublă cea ce conduce la obținerea unui timp de procesare de două ori mai mic. Din punctul de vedere al autorului această metodă este cea mai indicată în cazul în care nu există o limitare importantă în cea ce privește consumul de resurse hardware.

4.5.2. Implementarea unui modul de descompunere wavelet utilizând multiplicatoare bazate pe aritmetica distribuită

În cazul implementării modulelor de descompunere wavelet, unitate care necesită cele mai multe resurse hardware și totodată cel mai mare timp de procesare este unitatea FIR. O unitate de filtrare realizează în mod repetat operațiile de multiplicare și acumulare. În cazul modulelor de descompunere wavelet, fiecare etaj de descompunere presupune implementarea a două unități FIR. Deoarece timpul necesar efectuării operațiilor unei unități FIR este direct proporțională cu lungimea filtrului. Este evident că prin optimizarea unități FIR se va obține o optimizarea a întregului modul de descompunere wavelet.

Un filtru FIR este caracterizat de ecuația:

$$H(z) = \sum_{n=0}^{N-1} h(n)z^{-n} \quad (4.68)$$

O soluție pentru optimizare implementării unităților FIR o constituie utilizarea aritmeticii distribuite. Aceasta profită de avantajul oferit de faptul că operațiile filtrului se realizează între eșantioanele semnalului de analizat și coeficienții filtrului. În general, aritmetica distribuită necesită includerea unei constante fixe de intrare în hardware, făcând astfel posibilă precalcularea eficientă a tuturor ieșirilor posibile. În cazul unităților FIR, coeficienții filtrului vor constitui aceste constante.

Presupunem o operație de multiplicare acumulare descrisă de ecuația:

$$Y = \sum_{i=0}^{N-1} a_i x_i \quad (4.69)$$

unde x este variabila de intrare.

Dacă exprimăm variabila x într-o reprezentare booleană ecuația (4.68) poate fi rescrisă astfel:

$$Y = \sum_{i=0}^N a_i \left[-x_{i,0} + \sum_{j=1}^{B-1} x_{i,j} 2^{-j} \right] \quad (4.70)$$

unde x_{ij} reprezintă al j-lea bit al reprezentării booleene a variabilei x_i , iar B reprezintă numărul de biți pe care se face reprezentarea.

Ecuția (4.69) poate fi rearanjată astfel încât să se obțină:

$$Y = \sum_{j=1}^{B-1} \left[\sum_{i=0}^N a_i x_{ij} \right] 2^{-j} + \sum_{i=1}^N a_i (-x_{i0}) = \sum_{j=1}^{B-1} F_j 2^{-j} - F \quad (4.71)$$

Aritmetica distribuită se bazează pe observația că funcția F_j poate lua doar 2^N valori diferite, valori ce pot fi precalculate și stocate într-o tabelă de valori. Bitul j al fiecărei variabile x_i va fi utilizat pentru adresarea acestei tabeli de valori. După cum se poate observa și în ecuația (4.70), rezultatul operației de multiplicare acumulare poate fi obținut prin realizarea a trei operații distincte și anume: obținerea valorii F_j din tabela de valori, o operație de adunare și o operație de divizare cu 2, care este echivalentă cu o operație de deplasare.

Utilizând aritmetica bit-serială, o unitate FIR de ordinul 4 poate fi implementată printr-o structură asemănătoare cu cea din figura 4.21. Prima dată se execută multiplicarea variabilelor de intrare după care rezultatele sunt adunate folosind o structură de sumare arborescentă.




Figura 4.21 Modul FIR bit-serial

Prin rearanjarea operațiilor această structură poate fi transformată în structura prezentată în figura 4.22. În acest caz, prima dată se efectuează produsele parțiale, după care aceste produse sunt combinate prin intermediul unei structuri arborescente de sumare iar în cele din urmă se efectuează operația de acumulare folosind un acumulator pe 1 bit. În acest mod cele 4 unități MAC de 1 bit au fost înlocuite cu un acumulator de 1 bit și 4 porți logice SI.




Figura 4.22 Modul FIR aritmetică distribuită

Dacă coeficienții C_n sunt constanți, structura arborescentă ce calculează suma produselor intermediare poate fi înlocuită cu o tabelă de valori. Tabela va fi adresată de fiecare bit al variabilelor de intrare. Tabela de valori va conține toate combinațiile de sumare posibile dintre coeficienți.

Tabel 4.4

Adresă	Data
0000	0
0001	C_1
0010	C_2
1110	$C_4+C_3+C_2$
1111	$C_4+C_3+C_2+C_1$

În cazul prezentat există 16 combinații de sumare între cei 4 coeficienți. În cazul în care avem N coeficienți există 2^N combinații posibile. În acest caz implementarea unei tabele de valori de dimensiuni mari nu pare a fi o soluție convenabilă. Acest inconvenient poate fi eliminat prin combinarea unor tabele de valori de dimensiuni mai mici utilizând o structură arborescentă. În figura 4.24 este prezentată structura unui filtru de ordinul 4 utilizând o tabelă de valori.




Figura 4.23 Modul FIR aritmetică distribuită și LUT

În figura 4.24 este prezentată soluția hardware implementabilă în circuite FPGA ale unui modul de filtrare care utilizează aritmetica distribuită. Semnalul de intrare este trecut printr-un lanț de registre de deplasare. Ieșirile fiecărui registru de deplasare sunt utilizate pentru a adresa memoria ROM în care este stocată tabela de valori.

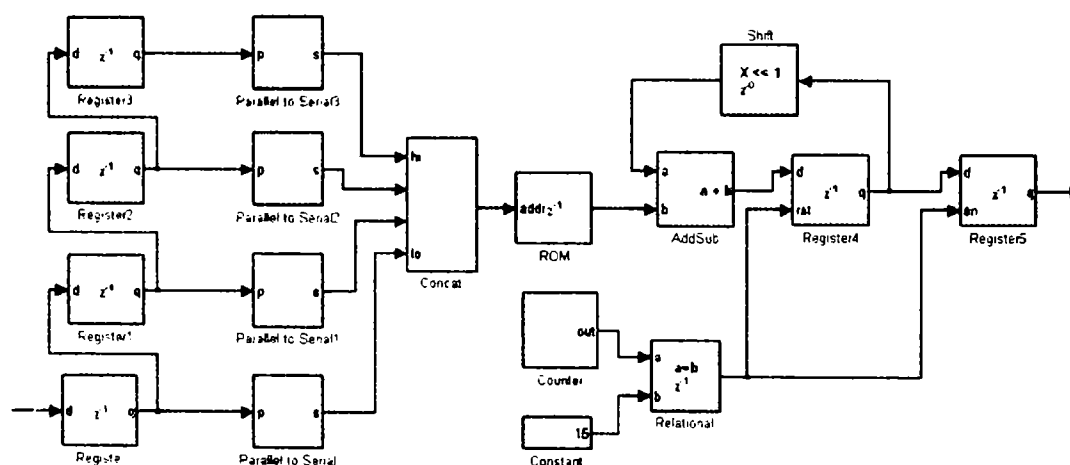


Figura 4.24 Structura FPGA a unui modul FIR bazat pe aritmetică distribuită

Principalul avantaj al acestei implementări constă în faptul că timpul de execuție nu mai depinde de ordinul filtrului. În acest caz timpul de execuție depinde de numărul de biți pe care este reprezentat semnalul de intrare. În cazul în care se impune o limitare în ceea ce privește timpul dintre două eșantioane consecutive prezente la ieșirea unui etaj de descompunere, frecvența maximă semnalului de tact poate fi determinată cu relația:

$$f_{\text{clk}} = \frac{N(b+3)}{t_{\text{desc}}} \quad (4.72)$$

unde: - N reprezintă numărul de eșantioane al ferestrei de procesare
 - b reprezintă numărul de biți pe care se face reprezentarea datelor.

În cazul implementării unor module de filtrare de ordin superior, această metodă de implementare oferă performanțe superioare față de metodele clasice de implementare a modulelor FIR. Performanțele unui sistem de descompunere wavelet bazat pe logică distribuită sunt evident superioare, față de soluțiile prezentate anterior, în cazul în care descompunerea wavelet se face utilizând funcții wavelet de ordin superior. Acest lucru se datorează faptului că pentru implementarea sistemelor de analiză wavelet care utilizează funcții de ordin superior, este necesară implementarea unor module FIR de ordin egal cu ordinul funcțiilor de descompunere.

4.6. Studiu privind evaluarea funcțiilor wavelet optime pentru analiza semnalului mioelectric

Analiza wavelet a unui semnal presupune evaluare produsului scalar dintre semnalul studiat și o funcție wavelet. Prin aceasta se arată de fapt gradul de asemănare dintre funcția de analizat și diverse versiuni scalate și translate ale funcției wavelet.

O primă concluzie ce poate fi trasă este legată de tipul funcției wavelet. Analiza wavelet va avea rezultate mai satisfăcătoare cu cât funcția wavelet aleasă poate aproxima mai bine semnalul studiat. În cazul semnalului mioelectric de suprafață știm că acesta este format din semnalele mioelectrice de diferite frecvențe ale unităților motoare învecinate. Deci putem concluziona că prin alegerea unei funcții wavelet care să fi asemănătoare cu semnalul mioelectric generat de o unitate motoare vom obține rezultate mai bune.

În continuare se va încerca să se determine care ar fi cele mai bune funcții wavelet pentru analiza semnalului mioelectric. Pentru aceasta se va analiza eroarea de reconstrucție obținută prin descompunerea și reconstruirea semnalului mioelectric utilizând diferite funcții wavelet existente. Semnale supuse analizei vor fi semnalele mioelectrice obținute cu ajutorul sistemului de achiziție prezentat în capitolul 2. Semnalele provenite de la fiecare din cele patru canale de achiziție și corespunzătoare fiecărui tip de mișcare studiat vor fi analizate și se va calcula o eroare medie de reconstrucție.

Pentru analiza wavelet a semnalului mioelectric se va evalua transformata wavelet discretă. Pentru acesta se va utiliza tehnica de codare în subbandă a semnalului. Un semnal $x[n]$ ce urmează a fi analizat poate fi descompus, prin operația de analiză wavelet, într-un set de coeficienți $d_k[n]$ numiți coeficienți de detaliu, plus un coeficient $a[n]$, numit coeficient de aproximare. În ipoteza utilizării a unui set de filtre ideale semnalul de intrare poate fi reconstruit perfect pe baza coeficienților obținuți în urma analizei wavelet. Reconstrucția perfectă depinde de performanțele filtrelor utilizate, iar coeficienții filtrelor depind de tipul funcției wavelet utilizate.

Numărul de coeficienți wavelet obținuți în urma analizei unui semnal depinde de numărul de eșantioane al semnalului studiat. Astfel un semnal poate fi descompus

în maxim $\log_2 N$ nivele, unde N reprezintă numărul de eşantioane al semnalului analizat. Gradul de corectitudine al semnalului reconstruit depinde și de numărul de nivele pe care s-a făcut descompunerea. Teoretic se presupune că semnalul poate fi perfect reconstruit utilizând coeficienții de aproximare de la un anumit nivel și toți coeficienții de detaliu de la nivelul respectiv și nivelele superioare. Se va încerca să se analizeze modul de variație al erorii de reconstrucție în funcție de nivelele pe care se face descompunerea wavelet.

Pentru analiza propusă se va determina eroarea medie pătratică pentru fiecare operație de descompunere-reconstituire conform relației:

$$\sigma_{err_j}^2 = \frac{\sum_{k=0}^{p-1} (x_{k,j} - \bar{x}_j)^2}{p}, k = 1 \dots 256, j = 1 \dots 24 \quad (4.73)$$

Pentru fiecare tip de mișcare și pentru fiecare canal de măsură se va efectua operația de descompunere-reconstituire wavelet. Se va calcula media erorilor pătratice astfel obținute. Algoritmul va fi aplicat pentru mai multe tipuri de funcții wavelet și pentru diferite grade de descompunere. Rezultate obținute vor fi comparate și se vor alege funcțiile wavelet care vor da rezultatele cele mai bune.

Având în vedere faptul că semnalul mioelectric supus analizei este segmentat pe segmente de 256 eşantioane lungime, rezultă că o descompunere wavelet completă va avea 8 nivele. Ținând cont de faptul că semnalul mioelectric nu are prea multe informații utile sub frecvența de 20Hz, descompunerea se va face pe 3,4,5 nivele.

Funcțiile Wavelet ale lui Daubechies, DB-N, sunt funcții cu N momente nule și cu suport temporal de lungime minimă. Cu alte cuvinte, ele corespund la cele mai scurte filtre care asigură numărul de momente nule ale funcțiilor Wavelet impuse. Din acest considerent ele se pretează la utilizarea în aplicațiile de compresie a unei clase largi de semnale, ce prezintă o anumită regularitate, deoarece, pe lângă faptul că permit o aproximare bună a semnalului pe baza unui număr redus de coeficienți ai descompunerii, ele oferă și o implementare eficientă a dezvoltării. Funcțiile Daubechies pe de altă parte sunt puternic asimetrice introducând distorsiuni mari de fază. În cazul funcțiilor Daubechies, pentru o regularitate N va rezulta un filtru de lungime (minimă) $2N$.

În figura 4.25 se prezintă erorile de reconstrucție obținute în urma operației de descompunere-reconstrucție a semnalului mioelectric folosind diverse funcții wavelet Daubechies și diverse nivele de descompunere. Se poate observa că nu există o diferență prea mare prin utilizarea unui număr diferit de nivele de descompunere, dar există diferențe notabile în cazul utilizării unor funcții Daubechies de ordin diferit. Datorită faptului că funcția wavelet de ordin 2 nu prezintă un grad prea mare de asemănare cu forma semnalului mioelectric nu voi lua în considerare rezultate obținute pentru această funcție. Următoare funcție ce oferă cea mai mică eroare de reconstrucție este funcția Daubechies de ordin 6. În continuare se va utiliza această funcție pentru analiza semnalului mioelectric.




Figura 4.25 Eroarea de reconstrucție a semnalului mioelectric obținute în urma analizei wavelet pentru diferite nivele de descompunere și funcții Daubechies de ordin diferit

Rezultatul descompunerii semnalului mioelectric corespunzător acțiunii de flexare a încheieturii mâinii este prezentat în figura 4.26. Semnalul analizat este semnalul achiziționat de la mioelectrodul amplasat în dreptul mușchiului flexor radial al carpalului. Descompunerea a fost realizată pe 5 nivele utilizând funcția wavelet Daubechies de ordinul 6.




Figura 4.26 Descompunerea pe 5 nivele, utilizând funcția db6, a semnalului mioelectric corespunzător acțiunii de flexare.

În urma descompunerii se obțin 5 coeficienți wavelet de detaliu și un coeficient de aproximare. Acești coeficienți constituie semnalul de intrare reprezentat

în domeniul timp-frecvență. Semnalul de intrare a fost constituit din 256 eşantioane și a fost transformat în urma descompunerii wavelet în 256 de coeficienți wavelet. Putem afirma că rezultatul descompunerii este de fapt o altă reprezentare a semnalului de intrare. În figura 4.27 sunt prezentate semnalele provenite de la cei 4 mioelectrozi, corespunzătoare acțiunii de flexare, reprezentate în domeniul timp-frecvență. Semnalul este obținut reprezentă de fapt coeficienții wavelet obținuți în urma descompunerii, și aranjați astfel: $a_5, d_5, d_4, d_3, d_2, d_1$.




Figura 4.27 Semnalul mioelectric corespunzător acțiunii de flexare reprezentat în domeniul timp-frecvență, descompus cu db6

Pentru a putea evidenția diferența dintre semnalele mioelectrice în cazul celor 6 acțiuni diferite, în figura 4.28 se prezintă reprezentarea în domeniul timp-frecvență a semnalelor mioelectrice corespunzătoare celor 6 clase de posturi. Reprezentarea este obținută în urma analizei wavelet cu ajutorul funcției db6. Se poate observa diferența dintre coeficienții wavelet corespunzători fiecărei clase de posturi. Problema care se ridică, în cazul utilizării acestor coeficienți ca și vector de trăsături pentru un sistem de clasificare, este legată de dimensiunea mare a unui astfel de vector. Pentru a putea construi un sistem de clasificare eficient trebuie redusă dimensiunea vectorului de trăsături. Aceasta se poate realiza prin aplicarea analizei componentelor principale și extragerea componentelor cu valori proprii mari.




Figura 4.28 Semnalul mioelectric corespunzător celor 6 posturi, reprezentare în domeniul timp-frecvență, db6

Funcțiile wavelet Symmlet, SYM-N, sunt o versiune modificată a funcțiilor Daubechies care asigură cel mai mare număr de momente nule și asimetrie minimă. Datorită faptului că asigură un grad de asimetrie minimă, și distorsiunile de fază vor fi minime. O funcție Symmlet de ordinul N va avea N momente nule iar lungimea filtrului va fi de $2N$.

Erorile de reconstrucție obținute în urma operației de descompunere-reconstrucție a semnalului mioelectric folosind diverse funcții wavelet Symmlet sunt prezentate în figura 4.29. Din figura 4.29 se poate observa că prin utilizarea unor funcții Symmlet de ordin superior (8,9,10) se obține cea mai mică valoare pentru eroarea de reconstrucție a unui semnal mioelectric.




Figura 4.29 Eroarea de reconstrucție a semnalului mioelectric obținute în urma analizei wavelet pentru diferite nivele de descompunere și funcții Symmlet de ordin diferit




Figura 4.30 Semnalul mioelectric corespunzător celor 6 posturi, reprezentare în domeniul timp-frecvență, sym9

În figura 4.30 se prezintă reprezentarea în domeniul timp-frecvență a semnalelor mioelectrice corespunzătoare celor 6 clase de mișcare folosind o descompunerea wavelet cu ajutorul unei funcții Symmlet de ordin 9

Familia de funcții Coifman a fost creată de Daubechies la cererea lui R. Coifman. Funcțiile sunt astfel concepute încât să asigure cel mai mare număr de momente nule atât pentru funcția wavelet mamă cât și pentru funcția de scalare. O funcție Coiflet, COIF-N, de ordinul N are un filtru de lungime $6N$, o lățime suport de $6N-1$ și $2N$ momente nule.

În urma analizei performanțelor de reconstrucție a semnalului mioelectric cu ajutorul prin intermediul analizei wavelet cu ajutorul funcțiilor Coifman s-a ajuns la concluzia că funcția Coifman de ordinul 3 este cea mai indicată pentru analiza semnalului mioelectric. În figura 4.31 sunt prezentate erorile de reconstrucție obținute în urma procesului de descompunere-reconstrucție a semnalului mioelectric prin intermediul funcțiilor Coifman.




Figura 4.31 Eroarea de reconstrucție a semnalului mioelectric obținute în urma analizei wavelet pentru diferite nivele de descompunere și funcții Coiflet de ordin diferit

Pentru a putea analiza diferențele de performanță în cazul utilizării în cadrul descompunerii a unor funcții wavelet diferite, în figura 4.32 sunt prezentate cele mai bune rezultate obținute pentru fiecare din cele trei familii de funcții. Se poate observa că valorile obținute pentru eroarea de reconstrucție sunt în general foarte mici (10^{-12}) pentru toate cele 3 familii de funcții wavelet studiate. Cele mai bune performanțe sunt obținute în cazul utilizării funcțiilor din familia Symmlet, dar în acest caz este necesară utilizarea unui număr mai mare de etaje de descompunere. Pentru a putea realiza o analiză obiectivă a performanțelor unui modul de analiză wavelet în cadrul unui sistem de clasificare a semnalului mioelectric, autorul a decis să utilizeze câte o funcție wavelet din fiecare familie de funcții studiată. Ținând cont de rezultatele obținute pentru erorile de reconstrucție, reprezentarea în domeniul timp-frecvență a semnalului mioelectric se va face în continuare utilizând coeficienții wavelet obținuți în urma descompunerii prin intermediul funcțiilor wavelet db6, sym9 și coif 3.




Figura 4.32 Eroarea de reconstrucție a semnalului mioelectric obținute în urma analizei wavelet pentru 3 nivele de descompunere

4.7. Concluzii

În acest capitol autorul a prezentat un studiu referitor la posibilitățile de analiză în domeniul frecvență-timp a semnalului mioelectric. Având în vedere faptul că semnalului mioelectric este un semnal nestaționar, cea mai recomandată metodă de a extrage informații care să descrie cel mai bine natura acestui semnal este analiza în domeniul frecvență-timp. În prima parte a capitolului au fost prezentate noțiuni teoretice referitoare la analiza în domeniul timp-frecvență a semnalelor. S-a insistat pe analiza timp-frecvență efectuată cu ajutorul descompunerii wavelet. În continuare autorul a prezentat câteva soluții practice de implementare hardware eficientă a unui modul de analiză wavelet. Soluțiile propuse au fost implementate și testate cu ajutorul unei plăci de dezvoltare realizată de Digilent Inc., dotată cu un circuit FPGA XILINX Spartan3E XC3S500E. Trei dintre soluțiile prezentate pornesc de la noțiuni teoretice existente, contribuția autorului remarcându-se în modul de implementarea hardware. Soluția bazată pe un singur multiplicator reprezintă o îmbunătățire adusă de autor algoritmului de implementare directă astfel încât să se obțină un consum de resurse cât mai redus. Toate soluțiile prezentate duc în final la același rezultat, și anume obținerea coeficienților wavelet, dar fiecare soluție prezintă anumite avantaje și dezavantaje. În tabelul 4.5 sunt prezentate performanțele soluțiilor propuse din punct de vedere al resurselor hardware utilizate și al frecvenței semnalului de tact necesar pentru a obține aproximativ același timp de procesare. În cazul soluției bazată pe aritmetica distribuită nu s-a estimat frecvența semnalului de tact deoarece aceasta depinde în mod direct de numărul de biți pe care se face reprezentarea datelor analizate. Soluțiile de implementare propuse de autor au fost prezentate la diverse manifestări științifice [80][81], sau au fost publicate în reviste de specialitate.

Tabel 4.5 Comparație între soluțiile de implementare hardware a modului de descompunere wavelet

Metoda de implementare	Resurse utilizate (multiplicatoare dedicate)	Resurse utilizate (fără multiplicatoare dedicate)	Frecvență semnal tact
Directă	23.22	42.1	F_s
Decimator polifazic	25.45	47.4	$2F_s$
Aritmetică distribuită	-	32.4	-
1 multiplicator pe nivel	17.1	33	$F_s/2$

În ultima parte a acestui capitol autorul a realizat un studiu referitor la funcțiile wavelet optime pentru analiza semnalului mioelectric. Coeficienții obținuți în urma descompunerii wavelet a unui semnal pot fi utilizați pentru reconstrucția „perfectă” a semnalului analizat. Autorul a analizat performanțele de reconstrucție a semnalului mioelectric utilizând funcții wavelet din 3 familii diferite. Deoarece coeficienții wavelet descriu gradul de asemănare dintre funcția de analizat și diverse versiuni scalate și translatate ale funcției wavelet, autorul a propus utilizarea criteriului erorii medii pătratice de reconstrucție ca și măsură obiectivă de evaluare a funcțiilor wavelet optime pentru analiza semnalului mioelectric al membrului superior. Funcțiile wavelet cu cele mai bune performanțe de reconstrucție, din fiecare familie de funcții, vor fi utilizate pentru extragerea coeficienților wavelet a semnalului mioelectric, coeficienți ce vor servi ca și vector de trăsături pentru sistemului de clasificare a semnalului mioelectric propus de autor și descris în ultimul capitol al acestei lucrări.

5 REȚELE NEURONALE ARTIFICIALE

Rețelele neuronale artificiale sunt utilizate adeseori pentru a îndeplini funcția de clasificator în sistemele de recunoaștere a tiparelor. În acest capitol autorul va realiza un studiu mai aprofundat referitor la rețelele neuronale artificiale și al modalităților de implementarea hardware ale acestora. În cadrul sistemului de comandă mioelectrică propus de autor în această lucrare, rețelele neuronale artificiale vor fi utilizate pentru implementarea modului de clasificare a sistemului de recunoaștere a tiparelor și al modulelor de analiză ale componentelor principale și ale componentelor independente, module descrise în capitolul 6. Din această cauză, autorul a considerat că este necesară realizarea unei introduceri în domeniul rețelilor neuronale artificiale precum și studierea unor modalități de implementarea hardware ale acestora. Soluțiile de implementarea hardware a rețelilor neuronale artificiale sunt concentrate pe implementarea acestora prin intermediul circuitelor logice programabile. Principalele resurse bibliografice studiate de autor pentru realizarea acestui capitol sunt: [5][11][14][15][49][86][90][117][125][120][121][139][160][171][180][188][194][202][219][221][225]

Deși nu există o definiție general acceptată a rețelilor neurale artificiale, majoritatea cercetătorilor sunt de acord că acestea reprezintă ansambluri de elemente de procesare simple, interconectate prin canale de comunicații prin care se propagă informație numerică. Multe dintre ideile vehiculate în acest context sunt motivate de dorința de a construi sisteme capabile să rezolve cu succes sarcini uzuale pentru creierul uman precum înțelegerea vorbirii sau recunoașterea formelor.

Deși se aseamănă în funcționare cu creierul uman, rețelele neuronale au o structură diferită de cea a creierului. O rețea neurală este mult mai simplă decât corespondentul uman, dar la fel ca și creierul uman, este compusă din unități puternice de calcul, mult inferioare însă corespondentului uman. Cu toate că nu sau obținut rezultate excepționale în ceea ce privește crearea unui sistem care să simuleze funcționarea creierului uman, această abordare s-a dovedit utilă în special pentru probleme dificil de formalizat sub forma unui algoritm (adică a unei "rețete" care să garanteze rezultatul), situație care presupune o înțelegere profundă a aplicației considerate. Majoritatea rețelilor neurale utilizează mecanisme pe baza cărora intensitatea legăturilor dintre neuroni sunt ajustate în funcție de calitatea răspunsului la stimuli externi. Ajungem astfel la principala trăsătură a acestor sisteme, anume capacitatea de a învăța pe bază de exemple, folosind "experiența" anterioară pentru a-și îmbunătăți permanent performanțele, dar și de a oferi un anumit grad de generalizare, care se traduce printr-un răspuns adecvat la informații de intrare care nu au fost folosite în faza de "antrenare" [121].

Teuvo Kohonen de la Helsinki University of Technology din Finlanda definește rețelele neuronale artificiale ca fiind: " ansambluri de elemente de procesare simple (de regulă, adaptive), puternic interconectate și operând în paralel, care urmăresc să interacționeze cu mediul înconjurător într-un mod asemănător creierelor biologice" [120]. În opinia lui Kohonen următoarele aspecte sunt comune atât rețelilor neurale artificiale cât și celor biologice:

- reprezentarea și procesarea informației în formă analogică (care permite desfășurarea în paralel a mai multor procese în mod asincron

- abilitatea de a efectua operațiuni de natură statistică asupra datelor de lucru (operațiuni de mediere, de regulă condiționată)
- corecție de erori și degradare graduală a performanțelor la apariția acestora
- capacitate de adaptare la un mediu în continuă schimbare

Rețelele neuronale artificiale s-au impus ca instrumente puternice de analiză a unor volume mari de date experimentale, generate de procese fizice ghidate de legi necunoscute, pentru care aceste sisteme pot oferi modele adecvate. Această tehnologie nu își propune ca obiectiv principal obținerea unor circuite motivate anatomic, ci funcțional, astfel încât să beneficiem de metode de procesare eficiente complementare celor tradiționale, disponibile sub formă de algoritmi de calcul și componente hard și soft.

5.1. Neuronul artificial

“Cărămida” elementară din structura creierului o reprezintă celula nervoasă, denumită pe scurt neuron. În figura 5.1 este schițată o astfel de celulă, care include corpul celulei (soma), dendritele și axonul.

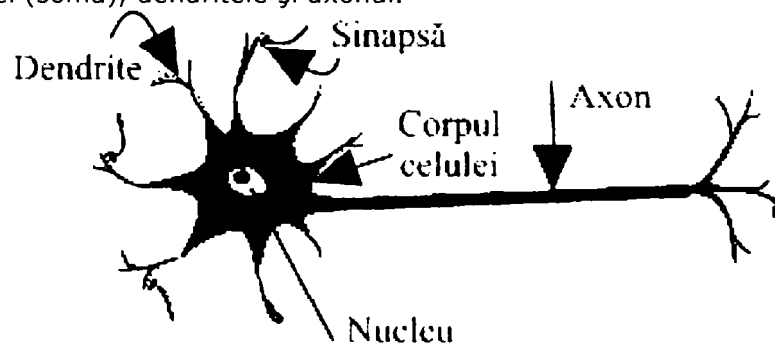


Figura 5.1 Neuronul elementar [28]

Dendritele recepționează semnalele provenind de la axonii altor neuroni și le conduc spre corpul celulei. Spațiul dintre un axon și o dendrită se numește sinapsă. În creierul uman se găsesc aproximativ 10^{11} neuroni (adică de ordinul de mărime al numărului de stele din Calea Lactee!), iar fiecare neuron poate primi semnale de la 1000-10000 de “vecini”. În funcție de forma acestora se disting 34 de tipuri diferite de neuroni, iar din punct de vedere funcțional regăsim 100 de tipuri. Atunci când semnalul total recepționat de un neuron prin dendritele sale (denumit activitatea celulei) depășește o anumită valoare de prag se emite un așa-numit potențial de acțiune (action potential), sub forma unui puls electric cu amplitudinea de 70 mV, cu durata de 1 ms, care se propagă de-a lungul axonului cu o viteză de 120 m/s. Când impulsul ajunge în dreptul unei sinapse acesta se transformă într-un set de “semnale” chimice (neurotransmițători) care se propagă prin spațiul care separă cei 2 neuroni, iar la contactul cu membrana “destinatarului” semnalul este reconvertit la forma electrică. Sinapsele pot fi excitatoare, atunci când conduc la creșterea nivelului de activitate intern al celulei, sau inhibitoare în cazul în care reduc acest nivel. Studiile au arătat o comportare binară (de tip comparator) a celulei nervoase: sub un anumit prag de activitate neuronul nu produce nici un semnal, iar peste acest prag emite potențialul de acțiune, după care se “resetează”. Pe măsură ce crește nivelul de activitate potențialul de acțiune își mărește frecvența, nu însă și amplitudinea. La

valori foarte ridicate ale activității nu se mai observă creșteri nici ale frecvenței și nici ale amplitudinii. Din punct de vedere matematic, dependența dintre nivelul de activitate și frecvența de emisie a potențialului de acțiune poate fi modelată printr-o funcție denumită sigmoid:

$$f(x) = \frac{1}{1 + e^{-a(x-T)}} \quad (5.1)$$

în care x desemnează activitatea totală, T este valoarea de prag, iar constanta a controlează derivata în origine a funcției $f(x)$. Este important de subliniat că valoarea interconexiunii dintre doi neuroni este "modulată" de comportarea ansamblului acestora. Astfel, o regulă celebră elaborată de către cercetătorul american D. Hebb indică faptul că legătura dintre neuroni devine mai puternică dacă aceștia tind să emită simultan potențialul de acțiune. O observație fundamentală este cea potrivit căreia memorarea informațiilor se face nu prin stocarea la nivelul neuronului elementar, ci chiar în valorile interconexiunilor.

Multe dintre caracteristicile creierului uman nu se regăsesc la calculatoarele digitale actuale. Acestea sunt fără îndoială rezultatul îndelungatei evoluții naturale și includ capacitatea de a învăța din experiență și de a folosi cunoștințele acumulate în contexte noi, procesarea paralelă și reprezentare distribuită a informației, toleranța "defecțiunilor" și consumul energetic redus [93]. În Tabelul 5.1 se prezintă o analiză comparativă a celor două principii de calcul în funcție de principalii factori de interes:

Tabelul 5.1: Comparație între calculatoarele digitale și rețelele neurale

Criteriul	Calculatoare digitale	Rețele neurale
Procesor	Complex, de viteză ridicată, utilizat în arhitecturi care includ un număr redus de astfel de componente	Simplu, de viteză scăzută, prezent în număr foarte mare
Principiu de operare	<i>Deducție</i> : se aplică reguli cunoscute asupra datelor de intrare pentru a obține răspunsul	<i>Inducție</i> : se utilizează datele de intrare și de ieșire pentru a identifica regulile care le unesc
Mod de calcul	Centralizat, sincron și serial	Colectiv, asincron și paralel
Memoria:	Separată de procesor, centralizată și adresabilă prin locație	Integrată în procesor, distribuită și adresabilă prin conținut
Fiabilitate:	Nu tolerează defecțiunile	Tolerează defecțiunile datorită redundanței și a "dispersării" sarcinilor
Viteză de operare	Ridicată (microsecunde).	Scăzută (fracțiuni de milisecundă).
Aplicabilitate	Utilizabile numai dacă există algoritmi ("rețete" de rezolvare) bine definiți și datele de intrare sunt precise	Utilizabile chiar în absența unor algoritmi, sau folosind date incomplete, zgomotoase sau distorsionate

Este important să subliniem diferențele care separă principiile de funcționare ale creierelor naturale de cele ale calculatoarelor digitale clasice :

- rețelele neurale biologice nu utilizează principiile de calcul ale calculatoarelor digitale. După cum se știe calculul digital poate fi sincron sau asincron. Dacă creierul ar funcționa asincron ar trebui ca durata impulsurilor emise de neuroni să fie variabilă, pentru ca nivelele logice să poată fi menținute pe durate nedefinite de

timp, fapt care nu se observă în practică. Dacă funcționarea ar fi sincronă ar fi necesar un "ceas" global, care de asemenea nu a fost pus în evidență. Observația fundamentală este că funcționarea neuronilor reali nu oferă precizia și stabilitatea necesare pentru a defini funcții logice, deci creierul este de fapt un "calculator" analogic.

- rețelele neurale biologice nu utilizează algoritmi de calcul sau coduri de control. Un algoritm exprimă în mod uzual un calcul recurent, care presupune menținerea definiției unor funcții pentru o perioadă oarecare de timp. Datorită problemelor de stabilitate amintite anterior asemenea instrucțiuni sau coduri nu ar putea fi menținute pe durate de timp mari. Rezultă de aici că principiile de calcul inspirate de funcționarea creierului pot constitui o alternativă la calculul algoritmic actual.

Neuronul artificial denumit uneori procesor elementar încearcă să imite structura și funcționarea neuronului biologic. Există numeroase modele prezentate în literatură, dar cel mai răspândit are la bază modelul elaborat de McCulloch-Pitts în 1943. Conform acestui model se poate considera că neuronul artificial este format dintr-un număr de intrări, fiecare dintre acestea fiind caracterizată de propria pondere sinaptică [202].




Figura 5.2 Neuronul artificial

Modelul prezentat poartă denumirea de model aditiv deoarece componenta prin care se realizează legătura dintre cele n intrări ale neuronului este un sumator. Prin intermediul sumatorului se realizează o însumare ponderată a intrărilor.

$$u_k = \sum_{j=1}^N w_{kj} \cdot x_j \quad (5.2)$$

Pentru limitarea amplitudinii semnalului de ieșire al neuronului se utilizează o funcție de activare .

$$y_k = \varphi(u_k - \theta_k) \quad (5.3)$$

În ceea ce privește tipul funcției de activare, aceasta este de regulă o funcție neliniară; în cele ce urmează se va face o prezentare a celor mai răspândite tipuri de funcții de activare (fig.5.3):

- Funcția prag:

$$\varphi(v) = \begin{cases} 1 & \text{daca } v \geq 0 \\ 0 & \text{dacal } v < 0 \end{cases} \quad (5.4)$$

- Funcția prag simetrică sau funcția signum:

$$\varphi(v) = \begin{cases} 1 & \text{daca } v \geq 0 \\ -1 & \text{daca } v < 0 \end{cases} \quad (5.5)$$

- Funcția sigmoid:

$$\varphi(v) = \frac{1}{1 + e^{-av}} \quad (5.6)$$

- Funcția tangentă hiperbolică:

$$\varphi(v) = \frac{1 - e^{-2v}}{1 + e^{-2v}} \quad (5.7)$$

- Funcția liniară:

$$\varphi(v) = v \quad (5.8)$$

- Funcția liniară cu saturație:

$$\varphi(v) = \begin{cases} 0, & \text{daca } v < 0 \\ v, & \text{daca } 0 \leq v \leq 1 \\ 1, & \text{daca } v > 1 \end{cases} \quad (5.9)$$

- Funcția liniară cu saturație, simetrică:

$$\varphi(v) = \begin{cases} -1, & \text{daca } v < 0 \\ v, & \text{daca } 0 \leq v \leq 1 \\ 1, & \text{daca } v > 1 \end{cases} \quad (5.10)$$

- Funcția gaussiană:

$$\varphi(v) = \exp(-v^2) \quad (5.11)$$




Figura 5.3 Funcții de activare

Analizând comparativ modelele neuronului real (biologic) și neuronului artificial se pot face următoarele observații [202]:

- Din punct de vedere al implementării este practic imposibil și chiar ineficient ca modelul artificial al neuronului să copieze exact comportamentul și structura celui biologic.
- RNA sunt proiectate pentru rezolvarea unor probleme specifice și deci arhitectura și trăsăturile RNA depind de problema pe care trebuie să o rezolve.
- Un neuron real produce la ieșire o secvență de impulsuri și nu o anumită valoare cum este cazul celui artificial. Reprezentarea ratei de activare printr-un singur număr (y_k) ignoră informația care ar putea fi conținută de exemplu în faza impulsurilor.
- Unele celule nervoase biologice efectuează o însumare neliniară a intrărilor. Pot exista chiar operații logice (ȘI, SAU, NU) efectuate la nivelul dendritelor.
- Ieșirile neuronilor nu se modifică în mod sincron și nu toți au același tip de întârziere.
- Cantitatea de substanță transmițătoare (mediator chimic) eliberată la nivelul sinapsei poate să varieze într-un mod imprevizibil. Fenomenul este aproximat grosier prin intermediul funcției de activare.

5.2. Arhitecturi de rețele neuronale

Există numeroase modalități de interconectare a neuronilor elementari, care conduc la o evoluție specifică a rețelei și care se utilizează în aplicații dintre cele mai diverse. Pot fi identificate 2 clase distincte de arhitecturi:

- rețele de tip feedforward (cu propagare a informației numai dinspre intrare spre ieșire. O particularitate constructivă a acestora o constituie posibilitatea de a identifica seturi de neuroni elementari grupați în așa-numite "straturi", care oferă similitudini de conexiune. Există trei tipuri de straturi : un strat de intrare, un strat de ieșire, iar toate celelalte sunt denumite straturi ascunse. Definitiv pentru acest tip de RNA este faptul că un neuron primește semnale doar de la neuroni aflați în stratul/straturi precedent/precedente.




Figura 5.4 Rețea neuronală de tip feedforward

- rețele recurente (cu reacție). se individualizează prin existența unui semnal de reacție, din partea neuronilor de ordin superior, pentru cei de ordin inferior sau

chiar pentru propriile lor intrări. Au fost introduse recent și arhitecturi "mixte", al căror aspect global este feedforward, dar care prezintă reacție locală.




Figura 5.5 Rețea neuronală recurentă

Modalitatea de interconectare este diversă, mergând de la interconectarea neuronilor dintr-un strat numai spre stratul următor (în rețelele de tip feedforward multistrat) până la rețele complet interconectate (recurente). Între aceste 2 extreme sunt cuprinse o multitudine de soluții intermediare, dintre care enumerăm rețele feedforward generalizate, care permit și conexiuni între neuroni aflați în straturi neînvecinate, rețele feedforward la care apar legături de reacție între neuronii de pe același strat (rețele cu inhibiție laterală) și rețele la care legăturile de reacție sunt prezente numai între neuronii elementari strict învecinați (rețele neurale celulare).




Figura 5.6 Diverse tipuri de rețele neuronale [28]

În general, neuronii elementari sunt dispuși într-un șir unidimensional în cadrul unui strat. Unele arhitecturi, de exemplu rețelele celulare și cele cu autoorganizare de tip Kohonen, pot avea straturi bidimensionale.

Din considerente legate de volumul de calcul necesar, dar și ca urmare a existenței unor rezultate teoretice riguroase, rareori se utilizează în practică rețele neurale cu mai mult de 3 straturi.

O problemă fundamentală o constituie modalitatea de a alege arhitectura adecvată pentru o aplicație dată. Lipsa unor teoreme constructive care să precizeze tipul rețelei și numărul de neuroni elementari împreună cu modalitatea de interconectare dintre aceștia în vederea rezolvării unei anumite sarcini constituie în continuare una dintre principalele limitări ale utilizării rețelelor neurale artificiale și totodată câmpul unor intense cercetări. Există aplicații pentru care au fost formulate condiții minimale referitoare la arhitectură. În literatură se prezintă modalități de construcție sistematică urmând un proces iterativ, grupate în 2 categorii:

- tehnici de tip pruning, în care se pleacă de la sisteme de dimensiuni suficient de mari și se elimină pe rând neuronii elementari și legăturile care se dovedesc neimportante (cele care nu se modifică semnificativ în procesul de învățare). Decizia de eliminare este de regulă bazată pe un calcul de senzitivitate al funcției de eroare în raport cu diversele ponderi ale sistemului. Un exemplu binecunoscut îl reprezintă metoda Optimal Brain Damage .
- tehnici de tip learn and grow, în care se pleacă de la rețele de dimensiuni reduse și se adaugă neuroni și conexiuni până când performanțele sistemului sunt suficient de bune. Ca exemple putem cita algoritmul cascade-correlation și metoda denumită projection pursuit .

5.3. Algoritmi de învățare

Unul dintre aspectele care diferențiază rețelele neurale față de alte sisteme de prelucrare a informației îl constituie capacitatea acestora de a învăța în urma interacțiunii cu mediul înconjurător și, ca urmare, de a-și îmbunătăți în timp performanțele (conform unui criteriu precizat). Învățarea este un proces prin care parametrii unei rețele neurale se adaptează în urma interacțiunii continue cu mediul de lucru. Tipul mecanismului de învățare este determinat de modalitatea concretă prin care se produce ajustarea valorilor parametrilor sistemului.

Un aspect fundamental îl constituie modul de reprezentare internă a informațiilor care să permită interpretarea, predicția și răspunsul corect la un stimul provenit din mediul înconjurător. O reprezentare corectă îi va permite sistemului, în particular rețelei neurale, să construiască un model al procesului analizat în stare să se comporte satisfăcător în condițiile în care la intrare i se vor aplica stimuli care nu au fost utilizați în procesul prealabil de învățare.

Informațiile utilizate în etapa de învățare sunt de 2 tipuri:

- informații disponibile a priori referitoare la particularitățile și, eventual, restricțiile cărora le este supusă aplicația considerată. Astfel de considerente conduc, în general, la sisteme specializate de dimensiuni reduse, mai ușor de antrenat și mai ieftine.
- informații sub forma unor perechi intrare-ieșire care surprind o relație de tip cauză-efect. Setul de date disponibil se împarte în două părți, una fiind folosită în procesul de modificare a ponderilor, deci de învățare propriu-zisă, iar cealaltă pentru a testa performanțele sistemului rezultat, oferind o imagine a așa-numitei capacități de generalizare a rețelei.

Procesul de reprezentare internă respectă câteva reguli de bază, care sunt enumerate în continuare [5]:

Regula 1: Date de intrare similare trebuie să capete reprezentări interne asemănătoare. Există mai multe moduri de a măsura "asemănarea" dintre 2 intrări distincte. Cea mai des folosită este cea bazată pe distanța Euclidiană dintre intrări

(văzute ca vectori reali multidimensionali). Uneori se utilizează produsul scalar sau funcția de intercorelație dintre cele 2 mărimi.

Regula 2: Intrări aparținând unor categorii distincte trebuie să aibă reprezentări interne cât mai diferite.

Regula 3: În reprezentarea internă a unei caracteristici importante a datelor de intrare trebuie să fie implicați un număr mare de neuroni elementari. Această regulă asigură un grad mare de încredere în luarea unei decizii și toleranță sporită în cazul funcționării incorecte a unora dintre neuronii implicați în reprezentare.

Regula 4: Orice informație disponibilă a priori, precum și eventuale invarianți trebuie folosite în etapa de configurare (stabilirea arhitecturii și a modului de interconectare) a rețelei.

Există o mare diversitate de opinii în ceea ce privește modul de clasificare al algoritmilor și tipurilor de învățare, figura 5.7 încearcă să sintetizeze principalele direcții [202].

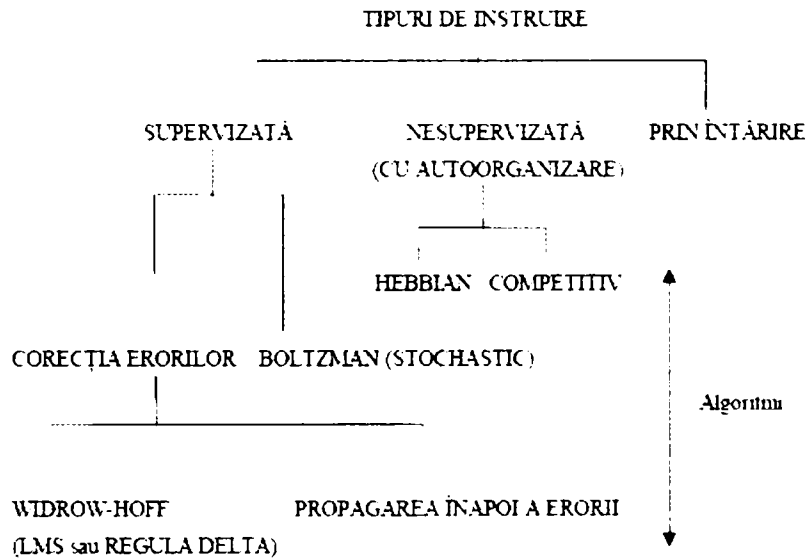


Figura 5.7 Tipuri și algoritmi de instruire [202]

5.4. Implementări hardware de rețele neuronale artificiale

Unul din cele mai active domenii de cercetare a zilelor noastre este cel al implementării software sau hardware a rețelelor neuronale. Încă de la începutul cercetărilor din domeniul rețelelor neuronale s-a constatat necesitatea dezvoltării unor metode eficiente de implementare hardware a rețelelor neuronale artificiale pentru ca acestea să poată fi utilizate la adevărata lor valoare. În urma cercetărilor, efectuate în acest domeniu, în ultimele două decenii s-au obținut multe cunoștințe noi cu privire la implementarea și utilizarea practică a rețelelor neurale artificiale. Cunoștințele legate de rețelele neurale artificiale au fost îmbogățite prin dezvoltarea unui cadru matematic mai solid, prin elaborarea unor algoritmi mai eficienți și prin

dezvăluirea misterelor rețelelor neurale naturale atât la nivelul claselor ierarhice cât și la nivelul neuronului individual [88].

În anii precedenți mulți cercetători au încercat să exploateze caracteristicile proprii rețelelor neuronale (cum ar fi structura regulată, adaptabilitatea, toleranța la defecte) pentru a realiza implementări hardware eficiente, care erau considerate mai performante decât implementările realizate folosind tehnica de calcul.

Datorită creșterii vitezei de calcul a procesoarelor utilizate în calculatoarele personale (PC), în stațiile grafice și a procesoarelor digitale de semnal, din ultimii zece ani, performanțele oferite de implementările hardware (cost, viteză, etc.) depășesc rareori pe cele ale implementărilor software pe un procesor de uz general. Din acest motiv implementările hardware nu sunt atât de atractive cum păreau la început și aceasta explică utilizarea lor redusă în aplicațiile practice precum și insuccesul circuitelor neuronale comerciale.

Se pune deci întrebarea dacă mai are rost să se realizeze implementări hardware de rețele neuronale artificiale? Dacă răspunsul este pozitiv care sunt aplicațiile pentru care o implementare hardware este mai eficientă. Există o serie de aplicații în care implementările hardware oferă beneficii importante la un preț mult mai scăzut decât alte tehnici de implementare disponibile, și anume:

- ca blocuri componente ale sistemelor dedicate (embedded systems);
- în sistemele pe un chip (system-on-a-chip), unde toate componentele sistemului, deci și circuitele neuronale și fuzzy, sunt implementate pe același chip;
- în aplicațiile unde este necesară o viteză foarte mare,
- în aplicațiile unde este necesar un consum de putere foarte scăzut
- în aplicațiile unde este necesară o toleranță crescută la defecte

5.4.1. Implementarea analogică a rețelelor neuronale artificiale

Implementarea analogică este caracterizată de viteza mare de procesare dar și de precizia scăzută. Una din problemele majore ale implementărilor analogice este stocarea nevolatilă (sau pe termen lung) a ponderilor sinaptice.

Circuitele electronice analogice au câteva caracteristici care pot fi utilizate direct pentru implementarea rețelelor neuronale. Astfel amplificatoarele operaționale pot implementa ușor funcții neuronale precum integrarea și funcția sigmoid. Aceste calcule, altfel foarte complexe, sunt efectuate prin proces fizice cum ar fi însumarea curenților sau a sarcinilor. Rețele neuronale simple cum ar fi de exemplu memoriile asociative (fără antrenare) pot fi implementate într-un chip care poate conține 1000 neuroni cu câte 1000 intrări fiecare, având o viteză de calcul de 100 GCPS.

Dezavantajele implementărilor analogice constau în sensibilitatea la zgomote și variațiile parametrilor ceea ce duce la o precizie limitată a calculelor. Circuite construite după același proiect nu vor funcționa la fel, dar același lucru se poate spune și despre creierul biologic. Pe lângă dificultățile legate de proiectarea circuitelor analogice problema reprezentării ponderilor adaptabile limitează aplicabilitatea circuitelor analogice. Ponderile pot fi reprezentate prin rezistoare, dar acestea nu sunt adaptabile după producerea circuitului. Circuitele cu ponderi fixe pot fi utilizate numai în faza de propagare. Tehnicile care permit implementarea ponderilor variabile utilizează capacitățile, tranzistoarele cu poartă flotantă, dispozitivele cu cuplare prin sarcină (CCD), etc. Principalele probleme care apar legate de aceste tehnici de implementare apar datorită variațiilor parametrilor procesului, volatilitatea, și slaba compatibilitate cu procesul tehnologic VLSI standard. Setul de ponderi pentru aceste

circuite antrenabile se obțin prin antrenare pe un calculator și apoi sunt încărcate în chip.

Pentru a beneficia de viteza implementărilor analogice și de proprietatea de adaptabilitate a rețelelor neuronale ar fi necesară implementarea procesului de antrenare pe chip, dar implementarea majorității regulilor de învățare circuitele VLSI analogice este foarte dificilă.

Cu toate că circuitele analogice nu vor atinge niciodată flexibilitatea ce poate fi obținută cu circuitele digitale, viteza lor și spațiul mai mic ocupat pe chip le fac atractive pentru implementarea rețelelor neuronale. Un alt avantaj îl reprezintă posibilitatea mai directă de interfațare cu lumea reală, preponderent analogică, în timp ce implementările digitale vor necesita întotdeauna convertoare analog digitale și digital analogice rapide pentru a prelua informații din lumea reală, respectiv pentru a trimite date înapoi.

În continuare sunt prezentate câteva neurochip-uri pur analogice adaptive.

- ETANN, Electrically Trainable Analog Neural Network (Intel Inc., CA, USA), a fost primul neurochip disponibil comercial care permite încărcarea ponderilor în urma antrenării dar nu permite învățarea on-board. Ponderile analogice sunt stocate ca diferența de tensiune între două porți flotante. Chip-ul conține 64 de neuroni și 1024 sinapse și are o viteză de 2GCPS.
- The Mod2 Neurocomputer (Naval Air Warfare Center Weapons Division, CA) Arhitectura acestui circuit este inspirată de structura sistemului olfactiv, auditiv și vizual biologic. Mod2 este realizat cu circuite ETANN într-o arhitectură extensibilă care permite implementarea a diverse tipuri de rețele neuronale. O implementare inițială constă în 12 chip-uri ETTAN cu o viteză de calcul de 1,2 GCPS fiecare.
- Fully analog chip (Kansai University, Japan). Circuitul prototip constă într-un unitate neuronală, o unitate de antrenare și o unitate de control.

5.4.2. Implementarea digitală a rețelelor neuronale artificiale

Motivația implementării digitale a neurosistemelor este dată de posibilitatea exploatării atât a avantajul conferit de un sistem programabil și modular cât și de faptul că printr-o implementare masiv paralelă a rețelele neuronale în circuitele VLSI se pot atinge viteze mari de procesare a semnalelor (100 GCPS). În afara avantajelor prezentate anterior se mai pot enumera și următoarele :

- sensibilitatea scăzută la perturbații electrice;
- precizia ridicată;
- ușurința proiectării;
- repetabilitatea;
- stocarea facilă a ponderilor;
- raport performanță cost mai bun față de implementările analogice.

Dintre dezavantajele implementării digitale a neurosistemelor se pot enumera:

- aria mare de siliciu ocupată;
- consumul ridicat de putere.

Cele mai importante neurosisteme implementate în circuite neuronale digitale realizate până în prezent [5], [86]-[90], [109], [219] sunt:

- SYNAPSE-1, SYNthesis of Neural Algorithms on a Parallel Systolic Engine este un neurocomputer construit de Siemens AG, care constă dintr-o arie sistolică de procesoare, aranjate pe două rânduri și 4 coloane. Aceste procesoare sunt circuite neuronale speciale MA16 care implementează direct funcții comune rețelelor neuronale, cum ar fi multiplicarea matricială sau determinarea maximului. Toate celelalte calcule care nu sunt critice se realizează folosind circuite comerciale. Ponderile sunt stocate în afara chip-ului în memorii locale. Fiecare chip conține o arie sistolică de 4 module de procesare, conținând multiplicatoare de 16x16 biți. Configurația standard pentru SYNAPSE-1 constă în 8 neurochip-uri MA16, două procesoare CISC MC68040, și o memorie DRAM de 128 Mocteți. Prototipul atinge viteza de 5,1 GCPS (și 33 MCUPS), la o frecvență de ceas de 40 MHz.
- CNAPS, Connected Network of Adaptive Processors, (Adaptive Solutions, Inc., USA) este o arie de procesoare SIMD (Single Instruction, Multiple Data) cu 64 elemente de procesare pe chip.
- SNAP, SIMD Neurocomputer Array Processor, (HNC, CA, USA), se bazează pe chip-urile HNC 100 NAP (Neural Array Processor), fiecare constând într-o arie uni-dimensională de 4 celule aritmetice. Organizarea elementelor de procesare este similară cu cea a sistemului CNAPS. O placă SNAP conține patru chip-uri HNC 100 NAP. O configurație standard de 2 plăci SNAP boards (32 procesoare) atinge 500 MCPS și 128 MCUPS (backpropagation).
- CNS Connectionist Supercomputer (ICSI, Berkeley, CA, USA), compus din 1024 noduri de procesare, care dau capacitate de calcul de 2 TeraOps (integer operations per second) și 32 Goctet de RAM. Un capăt al rețelei este rezervat pentru cuplarea dispozitivelor de Intrare/Iesire, permițând o lățime de bandă de până la 8 Gocteți/s. Performanța este de: 1011 CPS și 310 CUPS, care este de aproximativ 10.000 mai mare decât a unui stații RISC.
- Hitachi WSI (Hitachi Central Research Laboratory, Kokubinji Tokyo, Japan). Prototipul a fost lansat în 1990 fiind cea mai rapidă implementare a algoritmului backpropagation. Performanțe: 1152 noduri, 2,3 GCUPS.
- LNeuro 1.0, Learning Neurochip, (Neuromimetic Chip, Philips, Paris, France), este un circuit neuronal digital de uz general care implementează o rețea cu 32 neuroni de intrare și 16 neuroni de ieșire. Performanțe: 16 circuite LNeuro pe 4 plăci dedicate ajung la 19 MCPS, 4,2 MCUPS.
- Mantra I (Swiss Federal Institute of Technology) Performanțe: 400 MCPS, 133 MCUPS (backpropagation).

5.4.2.1. Implementări de rețele neuronale utilizând DSP

Principalele cerințe pentru implementările hardware ale rețelelor neuronale sunt necesitatea operării în timp real și posibilitatea adaptării la schimbarea datelor de intrare, respectiv a condițiilor de calcul. figura 5.8 prezintă o comparație între principalele tipuri de implementări din perspectiva celor două cerințe.




Figura 5.8 Spectrul implementărilor hardware a RNA

Prima cerință este cel mai bine satisfăcută de circuitele ASIC proiectate și realizate special pentru a răspunde aplicației sau domeniului. Dezvoltarea unor circuite specifice duce însă de obicei la costuri prea mari. Cea de a doua cerință este de obicei adresată de circuitele programabile de tipul DSP. Cu toată flexibilitatea procesoarelor DSP la implementarea unei rețele neuronale arhitectura rețelei trebuie adaptată la resursele procesorului. Avantajul flexibilității se plătește printr-o reducere a performanțelor și un consum de putere mai ridicat.

După cum se poate vedea din figura 5.8 circuitele reconfigurabile (FPGA) oferă un compromis între performanțele unui circuit specific și flexibilitatea unui circuit programabil prin soft. Ca și circuitele ASIC, acestea se remarcă prin abilitatea de a implementa direct circuite specializate în hardware. În plus, la fel ca și circuitele DSP pot fi ușor modificate în funcție de modificarea condițiilor de operare și a setului de date.

Procesoarele DSP convenționale utilizează o arhitectură de procesor care prin natura ei este serială. Blocurile de multiplicare – acumulare (MAC) sunt de obicei resurse partajate. Rețelele neuronale folosesc intensiv blocurile MAC deoarece fiecare intrare a neuronului trebuie multiplicată cu un coeficient și apoi rezultatele însumate. Cu cât rețeaua neuronală conține mai mulți neuroni și cu cât fiecare neuron are mai multe intrări, crește și numărul de blocuri MAC necesare pentru calculul rezultatului. Astfel în cazul unei rețele simple cu un singur strat de 15 neuroni cu câte 15 intrări sunt necesare un număr de 225 operații de multiplicare acumulare pentru calculul ieșirii rețelei pentru un singur vector de date aplicat la intrare. Folosirea unui procesor cu frecvență de lucru ridicată creează în plus dificultăți suplimentare.




Figura 5.9 Implementarea unei RNA folosind un singur bloc MAC

Implementarea RNA folosind procesoare DSP este foarte eficientă doar în cazul unor semnale cu frecvență mică și medie. În cazul utilizării unui procesor cu un singur bloc MAC, relația dintre rata de eșantionare și complexitatea rețelei (număr de operații MAC necesare) este dată de raportul dintre frecvența procesorului și numărul de operații pe eșantion.

Odată cu creșterea complexității rețelei neuronale ceea ce duce la creșterea numărului de operații MAC, și în consecință la un timp mai mare pentru calculul răspunsului rețelei pentru fiecare eșantion de date de intrare, este necesară scăderea ratei de eșantionare (figura 5.10).




Figura 5.10 Procesarea secvențială limitează performanțele sistemului

În cazul funcționării în timp real, pentru semnale de frecvență foarte ridicată este necesară utilizarea tehnicii de procesare în paralel utilizând mai multe blocuri MAC.

5.4.2.2. Implementări de rețele neuronale utilizând circuite programabile

Ariile de porți programabile de către utilizator FPGA (Field Programmable Gate Arrays) sunt dispozitive ce pot fi configurate pentru implementarea aproape oricărui circuit digital deci și a rețelelor neuronale digitale. Ele prezintă avantajul unei foarte mari flexibilități deoarece pot fi reprogramate ușor. FPGA-urile sunt ideale pentru aplicațiile prototip, în care trebuie să se producă versiuni numeroase ale proiectului, până la obținerea variantei finale, optime. Acestea sunt, de asemenea, ideale pentru lansarea rapidă a produselor și pentru aplicațiile de volum redus.

Tabel 5.2 Comparație între FPGA și ASIC

	FPGA	ASIC
Eșantioane prototip	50-1000 \$	>100.000 \$
Software PC	100-5000 \$	>25.000 \$
Software stații de lucru	10.000 \$	>50.000 \$

Circuitele FPGA permit o reconfigurare software rapidă a circuitului hardware pentru a adapta hardware-ul la o gamă largă de aplicații. Pe măsură ce legea lui Moore continuă, FPGA-urile cresc în densitate și viteză în aceeași măsură ca și procesoarele. Cu toate că FPGA-urile plătesc un preț în ceea ce privește viteza și densitatea (aria) datorită flexibilității lor, pentru anumite aplicații cu un număr suficient de operații paralele ele pot oferi un raport performanță/preț mai bun și putere disipată mai mică decât procesoarele actuale sau DSP.

Datorită arhitecturii sale circuitele FPGA sunt potrivite pentru calculul paralel ele fiind intens folosite în aplicațiile de procesare a imaginii și încep să fie folosite în implementarea rețelelor neuronale.

Circuitele cu FPGA pot fi proiectate cu aceleași unelte și limbaje de programare ca și circuitele ASIC dar reprogramabilitatea lor reduce în mod semnificativ timpul de lansare pe piață și costurile nerepetitive (NRE, non-recurrent engineering), care includ: costurile proiectării, simulării, amortizarea programelor de proiectare, fabricarea măștilor și a tiparelor de testare, documentația, marketingul, etc. În același timp costurile repetitive (RE, recurrent engineering) care includ fabricarea, testarea, încapsularea, asamblarea chip-ului, suportul tehnic aferent, etc., sunt mai mari. De aceea ele sunt preferate pentru producția în serie mică și medie.

Complexitatea circuitelor FPGA este exprimată în numărul porți logice echivalente (unde o poartă = 4 tranzistoare) sau în numărul de celule logice care reprezintă un bloc component al unui FPGA. Există circuite de la câteva sute de porți până la câteva milioane de porți, astfel ele permit implementarea de rețele neuronale cu un singur neuron până la câteva sute de neuroni cu o capacitate de memorare câteva sute de Kb pentru memorarea ponderilor. Rețelele neuronale trebuie să fie de dimensiuni mari deci pot ușor depăși capacitatea unui singur FPGA din ziua de azi. O soluție posibilă este stocarea parametrilor rețelei într-o memorie externă de tipul SDRAM sau DDRAM, conectată direct la FPGA. Performanța circuitelor FPGA poate atinge 500 miliarde de MAC pe secundă într-un Virtex II XC2V8000 care este cu mult mai mult decât ceea ce poate realizat cu un procesor DSP convențional.

Tabel 5.3 Comparație între performanțele DSP și FPGA

Funcția	Cel mai rapid procesor DSP	Virtex-II	Virtex-II Pro	Spartan-3
8 x 8 MAC	5,7 miliarde MAC/s	0,5 Tera MAC/s	1 Tera MAC/s	0,27 Tera MAC/s
Filtru FIR - 256 date/coeficienți - 16-biți	11.16 MSPS 720 MHz	180 MSPS 180 MHz	300 MSPS 300 MHz	140 MSPS 140 MHz
FFT Complex - 1024 puncte. date 16-biți	8,5 μs 720 MHz	0,914 μs* 140 MHz	0,853 μs** 150 MHz	0,914 μs*** 140 MHz

* Folosind 96 de multiplicatoare dedicate și 24 blocuri RAM din Vitex-II (XC2V3000)

** Folosind 96 de multiplicatoare dedicate și 24 blocuri RAM din Vitex-II Pro (XC2VP30)

*** Folosind 96 de multiplicatoare dedicate și 24 blocuri RAM din Spartan-3 (XC3S4000)

Procesorul DSP cu care s-a făcut comparația este TMS320C64x care are patru blocuri MAC de 16x16 biți care pot lucra în paralel la o frecvență maximă de 720 MHz. Fiecare bloc MAC poate fi folosit ca două blocuri separate de 8x8 astfel încât rezultă:

$$8 \times 720 \text{ MHz} = 5,76 \text{ miliarde MAC/s}$$

Circuitul FPGA XC2V8000 are 46.592 celule logice elementare (slice-uri), care permit efectuarea a aproximativ 461 miliarde MAC/s și de asemenea 168 multiplicatoare dedicate care lucrează la frecvența de ~ 180 Hz (pentru 8x8) astfel încât:

$$168 \times 180 \text{ MHz} = 30 \text{ miliarde MAC/s,}$$

deci un total general de $461 + 30 = 491$ miliarde MAC/s.

5.4.3. Implementări hardware hibride de rețele neuronale

Atât implementările analogice cât și cele digitale ale rețelelor neuronale au avantaje cât și dezavantaje. Prin crearea unor implementări hibride se pot realiza o serie de compromisuri astfel încât să se îmbine avantajele celor două tipuri de implementări.

În această categorie intră implementările bazate pe procesarea trenurilor de impulsuri (pulse stream) inspirate de comportamentul neuronilor reali. Ele reprezintă o abordare promițătoare a implementărilor hibride. În tehnica procesării impulsurilor starea analogică a neuronului este reprezentată ca o secvență de impulsuri. Aceasta oferă o serie de avantaje cu privire la consumul de putere, calcul și propagare. Există mai multe tehnici de modulare a impulsurilor:

- ANNA, Analog Neural Network Arithmetic and logic unit, (AT&T Bell Labs, NJ, USA), este un chip care poate fi folosit pentru implementarea unei game largi de arhitecturi de rețele neuronale dar este optimizat pentru rețele neuronale conectate local și cu ponderi partajate. Ponderile sunt învățate în afara chip-ului, cuantificate la rezoluția chip-ului, și apoi încărcate în memoria ponderilor. Acestea sunt reprezentate de tensiuni. Interfața cu chip-ul este pur digitală cu

două convertoare DA care fac conversia valorii ponderilor reprezentate pe 6 biți în tensiunile corespunzătoare. Placa conține un procesor DSP în virgulă mobilă DSP-32C pentru faza de învățare și calculul ieșirii a rețelei backpropagation. Chip-ul ANNA are 4096 sinapse și 8 neuroni. Performanțe: 5000 MCPS (valoare de vârf), 1000 la 2000 MCPS (în medie).

- Epsilon, Edinburgh Pulse Stream Implementation of a Learning Oriented Network, (Dept. of Electrical Engineering, Edinburgh University, UK), este un bloc constructiv generic care constă în 30 de noduri și 3600 ponderi sinaptice. Chip-ul are un singur strat dar poate fi legat în cascadă pentru a forma o rețea mai mare. Performanțe: 360 MCPS

5.4.4. Implementarea în FPGA a unui neuroprocesor

Neuronul, unitatea de procesare a unei rețele neuronale este transpus hardware prin intermediul unui model ce va cuprinde un sistem compus în principal dintr-un sumator, un multiplicator, regiștrii de stocare a datelor de intrare, ieșire și a ponderilor.

Principiul de procesare a datelor mimează modelul rețelelor neuronale biologice. În cazul neuronilor biologici, transmisia semnalelor se face prin intermediul sinapselor ce folosesc un proces chimic complex de emisie de substanțe purtătoare de informație (neurotransmițători) cu efect de creștere sau scădere a potențialului din interiorul unei celule receptoare. Dacă potențialul atinge un anumit prag, neuronul este excitat și produce impulsuri nervoase care sunt transmise prin intermediul axonilor spre alți neuroni.

Modelul prezentat în figura 5.11, cu mici variații, este modelul neuronal cel mai des folosit în rețelele neuronale artificiale.




Figura 5.11 Modelul neuronului artificial

Neuronul artificial prezentat în figura de mai sus are N intrări fiecare având asignată o pondere w_i ($i=1..N$). Componenta principală a neuronului este sumatorul ponderat care calculează intrarea netă a neuronului conform relației:

$$net = \sum_{i=1}^N w_i x_i - b \quad (5.12)$$

unde b reprezintă valoarea biasului.

Semnalul de ieșire a neuronului este dată de valoarea funcției aplicate intrării nete a neuronului:

$$y(x) = f(\text{net}) = f\left(\sum_{i=1}^N w_i x_i - b\right) \quad (5.13)$$

Funcția f poartă numele de funcție de activare. Inițial funcția propusă de modelul McCulloch Pitts era funcția prag dar sunt larg utilizate și alte funcții cum ar fi funcția liniară, saturație, sigmoid, etc.

O analiză a implementărilor hardware a rețelelor neuronale propuse în literatură conduce la diagrama bloc din figura 5.12, [194].




Figura 5.12 Schema bloc a neuronului artificial

Blocul de calcul al intrării nete realizează produsul $w_i \times x_i$ și însumarea acestor produse. Apoi ieșirile sunt obținute în blocul de memorare a stării neuronului în urma aplicării funcției de activare asupra sumei de produse.

Un element de procesare neuronal trebuie să fie compus din următoarele blocuri principale: buffer de intrare (memorie date), memorie ponderi, multiplicator – acumulator, funcția de activare, buffer de ieșire și blocul de comandă.

Datele de intrare și ponderile trebuie să fie stocate în memorii și apoi introduse sub controlul unității de comandă în blocul multiplicator-acumulator. Modelul unui bloc MAC împreună cu memoriile de date și ponderi aferente este prezentat în figura 5.13.

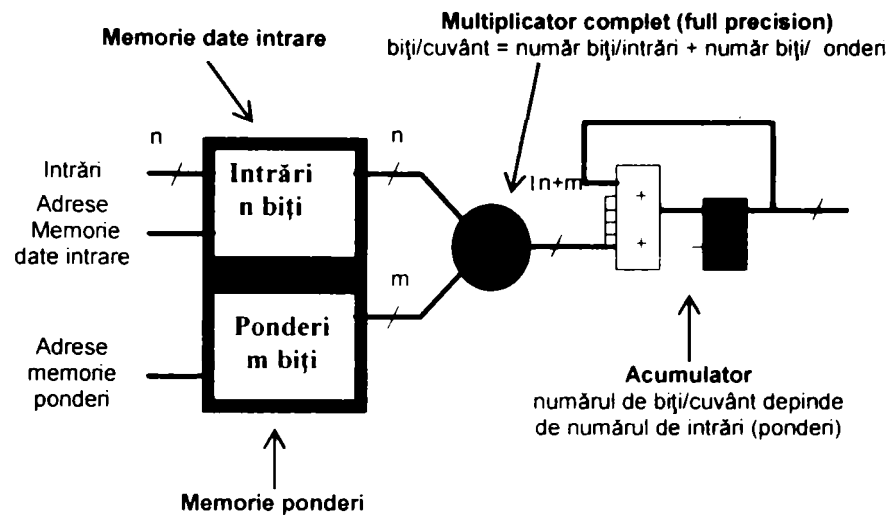


Figura 5.13 Modelul unui bloc de MAC

Blocul multiplicator - acumulator acceptă date de intrare și ponderi cu sau fără semn pe n respectiv m biți. Toți acești parametri pot fi modificați direct din interfața utilizator a blocul MAC. Ponderile și datele trebuie stocate în memorii.

5.4.4.1. Modelul neuroprocesorului cu învățare software

Pentru implementarea în FPGA a neuroprocesorului cu învățare software este necesară construirea software a rețele neuronale într-un program, de exemplu în toolbox-ul NNTool al Matlab-ului, ce permite simularea acesteia ținând cont de o anumită regulă de învățare, în vederea găsirii valorilor ponderilor asociate intrărilor fiecărui neuron ce răspund cel mai bine algoritmului de calcul ales. Odată găsite, aceste valori sunt stocate în memoria RAM de ponderi și vor fi implementate în circuitul FPGA împreună cu celelalte componente ale neuroprocesorului. În figura 5.14 este prezentat modelul unui neuroprocesor implementabil în FPGA, dezvoltat cu ajutorul uneltelor Xilinx System Generator ale mediului MatLab.

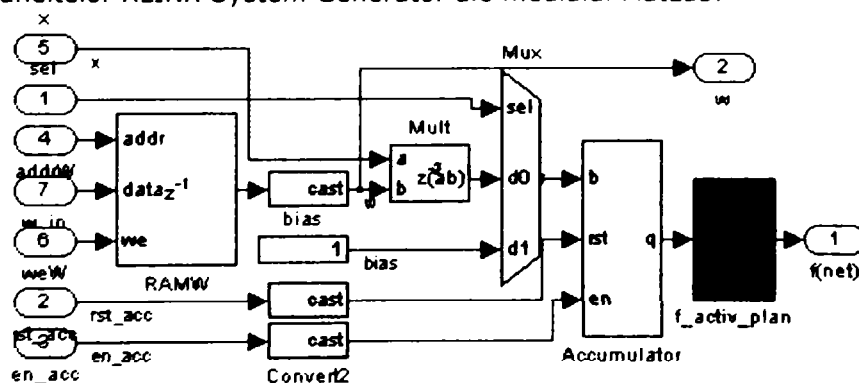


Figura 5.14 Structura unui neuroprocesor implementabil în FPGA

A. Unitatea MAC

Deoarece nu există un bloc MAC în biblioteca Xilinx Blockset, acesta trebuie creat folosind blocurile Xilinx existente, o soluție posibilă este prezentată în figura 5.15. Multiplicatorul poate fi implementat foarte eficient folosind blocurile multiplicatoare dedicate care există în circuitele FPGA de tipul Virtex-II, Virtex-II Pro sau Spartan-3. De exemplu în circuitul Virtex-II XC2V250 (echivalent cu 250.000 porți logice) există 24 de multiplicatoare dedicate pe 18 biți, în XC2V1000 (echivalent cu un milion porți logice), 40, iar în Virtex-II Pro XC2VP125, 556 de astfel de multiplicatoare.




Figura 5.15 Blocul MAC realizat cu blocuri Xilinx

Acumulatorul se implementează folosind blocul acumulator din biblioteca Xilinx. Precizia acumulatorului depinde de numărul de operații de acumulare deci de numărul de intrări ale neuronului și trebuie să fie suficient de mare pentru a nu apărea situații de depășire. Astfel, numărul de biți ai acumulatorului este dat de relația:

$$nr.bit_i_ac = ceil(\log_2(p)) + (n + m) + 1 \quad (5.14)$$

unde p reprezintă numărul de operații de acumulare, iar $n+m$ reprezintă numărul de biți ai datelor de intrare în acumulator.

După "reset" acumulatorul nu se reinițializează cu zero ci cu valoarea curentă a intrării, ceea ce permite blocului MAC o funcționare continuă. Un registru asigură memorarea temporară a datelor pe parcursul operațiilor de acumulare. Resursele folosite pentru implementarea unui MAC depind de următorii factori: numărul de biți ai intrărilor, ai ponderilor, precizia multiplicatorului, numărul de biți ai acumulatorului, și nu în ultimul rând de modul de implementare a multiplicatorului (cu multiplicatoare dedicate sau folosind resurse logice CLB).

De exemplu, pentru o reprezentare a datelor de intrare pe 8 biți fără semn (UFix_8_0), a ponderilor pe 12 biți cu semn (Fix_12_12), un multiplicator de precizie maximă (Fix_20_12), precizia acumulatorului calculată după formula 5.14 (Fix_23_12) și un neuron cu 8 intrări resursele utilizate sunt prezentate în tabelul 5.4. Tabelul prezintă „cazul cel mai defavorabil” pentru implementările, cu și fără multiplicatoare dedicate, în trei familii de dispozitive FPGA (primele două fiind folosite în experimentele efectuate).

Aceste resurse depind în foarte mare măsură de parametrii de mai sus și de aceea în funcție de aplicație, aceștia trebuie modificați pentru un raport optim între resurse și performanță.

Tabelul 5.4. Resursele consumate pentru implementarea unui bloc MAC

RESURSE CONSUMATE	MAC IMPLEMENTAT CU UN MULTIPLICATOR DEDICAT VIRTEX-II				MAC IMPLEMENTAT CU UN MULTIPLICATOR XILINX LOGICORE			
	MAC	Mult.	Acu.	Reg.	MAC	Mult.	Acu.	Reg.
Slice-uri	58	20	26	12	93	55	26	12
Bistabile	87	40	24	23	156	109	24	23
Memorii Block RAM	0	0	0	0	0	0	0	0
Tabele de memorii (LUT)	50	0	50	0	154	104	50	0
Multiplatoare dedicate	1	1	0	0	0	0	0	0
% dintr-un Spartan-II, 50.000 porți	--				12,10 %			
% dintr-un Virtex-II, 1.000.000 porți	1,13 %				1,81 %			
% dintr-un Virtex-II Pro, XC2VP125	0,1 %				0,16 %			

Între acumulator și ieșire se poate introduce un bloc convertor care reduce numărul de biți pe care este reprezentată cuvântul de ieșire, astfel scade și numărul de bistabile necesare pentru implementarea registrului de ieșire. Resursele consumate se modifică astfel: 54 slice-uri, 64 bistabile, 61 LUT-uri, 1 multiplicator dedicat. Parametrii pot fi modificați direct din interfața grafică a blocului MAC.

B. Memoriile de date și de ponderi

Stocarea datelor și a ponderilor poate fi făcută fie într-o memorie distribuită (SelectRAM) fie într-o memorie bloc (block SelectRAM). Utilizarea memoriei distribuite este recomandată numai în cazul în care nu sunt disponibile memoriile bloc sau cantitatea de date sau ponderi de memorat este mică.

Numărul cuvintelor de date memorate este determinat de numărul perechilor date-ponderi care intră în procesul de multiplicare-acumulare pentru a produce un rezultat. Numărul de biți pe cuvânt depinde de precizia de reprezentare a datelor de intrare.

Pentru memorarea ponderilor se poate folosi o memorie ROM distribuită dacă numărul intrărilor neuronului nu este mare, pentru a păstra memoriile de tip bloc pentru memorarea datelor.

Precizia de reprezentare a ponderilor este una din cele mai importante alegeri la implementarea RNA în FPGA. O precizie mai mare înseamnă mai puține erori de cuantizare în implementarea finală, în timp ce o precizie mai redusă conduce la un circuit mai simplu, viteză mai mare și reducerea resurselor necesare implementării și a puterii consumate. O modalitate de a rezolva acest compromis este de a determina precizia minimă necesară pentru rezolvarea problemei date. În mod tradițional precizia minimă este determinată prin încercări succesive, simulând soluțiile înainte de implementare. Mai mulți autori au studiat problema preciziei minime concluziile fiind diferite în funcție de tipul rețelei și a aplicației. Holt și Baker [96] au determinat că o reprezentare pe 16 biți a ponderilor este în general suficientă pentru o rețea de tip perceptron cu mai multe straturi și algoritm de învățare cu propagare înapoi a erorii.

Recent s-au făcut progrese mai importante în determinarea preciziei minime din punct de vedere teoretic. Draghici [54] a demonstrat că în cazul cel mai defavorabil domeniul necesar pentru ponderi $[-p, p]$ este estimat prin distanța minimă între tipare din clase diferite:

$$d = (\sqrt{n})/(2p) \quad (5.15)$$

unde p este un număr întreg și n este dimensiunea intrării.

C. Funcția de activare

Implementarea directă a unor funcții neliniare cum este și funcția sigmoid este foarte costisitoare. Există două abordări practice posibile pentru aproximarea unor astfel de funcții pentru a putea fi implementate în FPGA [225]. Aproximarea prin liniarizare pe porțiuni este o metodă de aproximare a unei funcții neliniare prin funcții de gradul I de forma:

$$y = ax + b \quad (5.16)$$

Dacă coeficienții sunt aleși să fie puteri ale lui 2, atunci funcția sigmoid poate fi obținută printr-o serie de operații de deplasare și adunare. Multe implementări ale funcției sigmoid folosesc o astfel de aproximare [89].

Implementarea folosind tabele de memorii este cea de a doua metodă uzuală folosită pentru implementarea funcției de activare. Pentru aceasta se pot folosi memoriile Single-Port ROM. Conținutul memoriei este determinat în Matlab și înscris în memorie prin intermediul unui fișier.

Cu toate că ambele implementări reprezintă doar aproximări (de ordinul 1 respectiv de ordinul 0) ale funcțiilor de transfer, este de preferat o îmbunătățire a performanțelor de viteză, cost, mărime, în detrimentul unei ușoare scăderi a preciziei. Aceste implementări se numesc hardware prietenoase. Figura 5.16 [14] prezintă capacitatea memoriei necesare pentru implementarea prin tabele de memorii în funcție de precizia echivalentă pentru aproximarea de ordinul 0 și 1 a funcției sigmoid.

$$f(x) = \frac{1}{1 + e^{\lambda x}} \quad (5.17)$$

unde λ este o constantă.

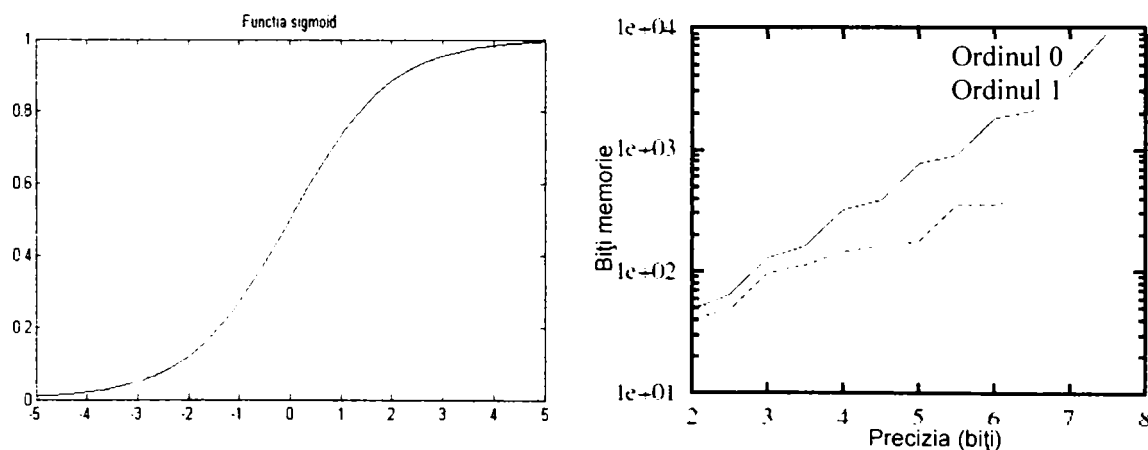


Figura 5.16 Funcția sigmoid și capacitatea memoriei necesare implementării [14]

D. Blocul de comandă

Blocul de comandă controlează fluxul de date de intrare și ieșire din memoria de date, citirea ponderilor și furnizează semnalele de control pentru MAC.

Înscriserea datelor în memoria de date de tip dual port are loc la viteza cu care acestea sunt furnizate la intrare. După ce și ultimul eșantion, reprezentând ultima intrare a neuronului, a fost memorat, extragerea datelor din memorie în vederea multiplicării cu ponderile aferente se face la o rată de $n+1$ ori mai mare, unde n reprezintă numărul de sinapse ale neuronului. Astfel pe durata ultimului eșantion de intrare, la portul B a memoriei de date sunt disponibile cele n date de intrare la care se adaugă factorul de deplasare a scării (bias).

Concomitent cu extragerea datelor de la portul B a memoriei de date blocul de comandă furnizează adresele pentru memoria de ponderi pentru extragerea ponderilor cu care trebuie să se multiplice intrările. Multiplicatorul introduce un timp de latență de 3 perioade de eșantionare iar memoria 1 perioadă. Astfel după $4/(n+1)$ din durata unui eșantion de intrare procesul de multiplicare-acumulare pentru un set de date de intrare este complet și blocul de comandă furnizează semnalul de enable pentru registrul de ieșire care memorează starea neuronului și de reset pentru acumulator.

Implementarea logicii de comandă prezentată mai sus se poate face cu ajutorul circuitului din figura 5.17 folosind numărătoare pentru generarea adreselor pentru memorii.

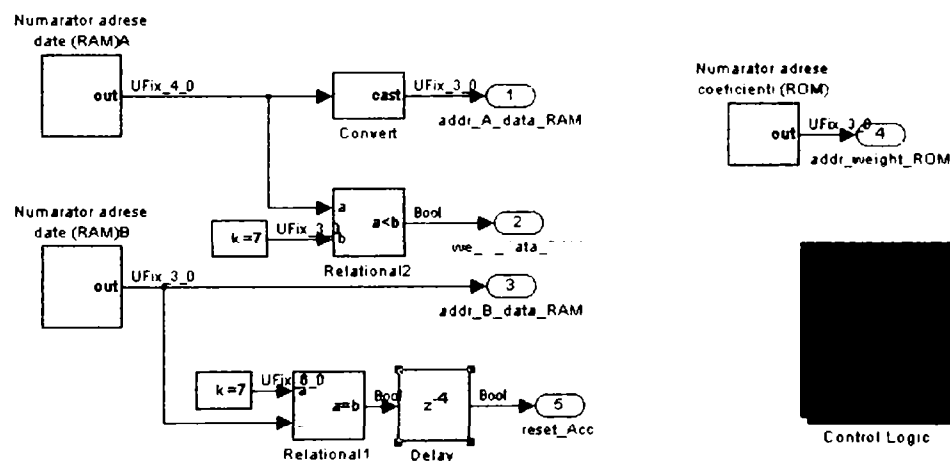


Figura 5.17 Simbolul și structura blocului de comandă

5.4.4.2. Modelul neuroprocesorului cu învățare hardware

O metodă ce conferă rețelei neuronale implementate în FPGA o autonomie mai mare față de soluțiile software de găsire a ponderilor aplicând o anumită regulă de învățare, constă în antrenarea hardware direct în FPGA a rețelei neuronale. În acest scop, modelul neuroprocesorului cu învățare software va trebui modificat astfel încât acesta să permită implementarea hardware a regulii de învățare adoptate.

În continuare sunt prezentate câteva soluții ce se pot adopta pentru implementarea hardware a unui neuroprocesor ce utilizează a regulă de învățare, regula Hebbiană. Acesta presupune ca ponderile să fie modificate după fiecare aplicare a unui vector de intrare după formula:

$$W_{ij}^1 = W_{ij}^0 + \Delta W_{ij} \quad (5.18)$$

unde

$$\Delta W_{ij} = \eta y_i x_j \quad (5.19)$$

unde η este rata de învățare, x_j este vectorul de intrare, y_i valoarea de ieșire corespunzătoare iar W^1 este valoarea modificată a ponderii W^0 .

A. Neuroprocesorul NeuroHebb_2R_3M

Un prim model analizat constă în folosirea unei memorii ROM pentru datele de intrare, două memorii RAM, una pentru inițializarea ponderilor iar cealaltă pentru rescrierea în memorie a ponderilor obținute în urma calcului de update-are, unui bloc de calcul a valorilor de ieșire ale fiecărui neuron, blocul „calc_y”, un bloc pentru calculul ponderilor, blocul update_w, și trei multiplicatoare. Modelul este denumit NeuroHebb_2R_3M, figura 5.18.

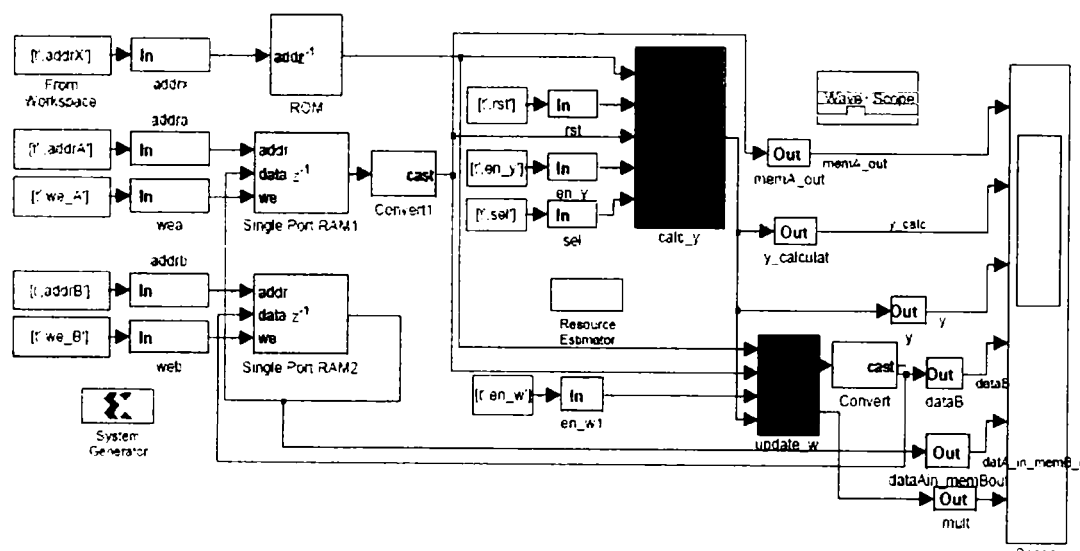


Figura 5.18 Modelul unui neuroprocesor cu învățare hardware „NeuroHebb_2R_3M”

În faza de testare, logica de control a fost aplicată prin intermediu unui fișier de tip *.m din mediul de programare Matlab. Formele de undă, rezultate în urma aplicării logicii de control care demonstrează update-rea ponderilor conform regulii de învățare Hebbiană, sunt prezentată în figura 5.19.




Figura 5.19 Formele de unda corespunzătoare neuroprocesorului NeuroHebb_2R_3M

B. Neuroprocesorul NeuroHebb_1R_3M

Modelul neuroprocesorului NeuroHebb_1R_3M presupune folosirea doar a unei memorii RAM pentru update-aria ponderilor din faza de învățare. Modelul folosește de asemenea câte un bloc pentru calculul a valorilor de ieșire ale neuronului în faza de propagare și un bloc pentru calcul ponderilor în faza de antrenare, figura 5.20.

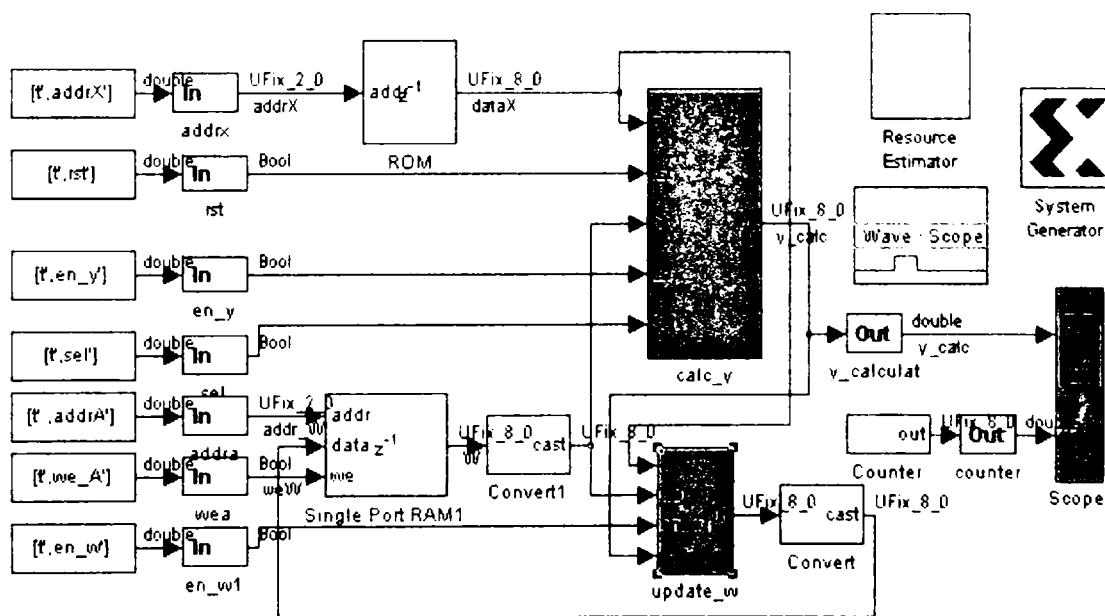


Figura 5.20 Modelul neuroprocesorului NeuroHebb_1R_3M

Modelul neuroprocesorului NeuroHebb_1R_3M folosește resurse mai puține față de modelul NeuroHebb_2R_3M: o memorie RAM față de două memorii RAM și are un timp de calcul mai mic: 16 perioade de timp față de 18 perioade de timp în cazul modelului NeuroHebb_2R_3M.

C. Neuroprocesorul NeuroHebb_1R_2M

Modelul neuroprocesorului NeuroHebb_1R_2M folosește un singur multiplicator atât pentru calculul valorilor de ieșire ale neuronului în faza de propagare cât și pentru calculul ponderilor în faza de antrenare, figura 5.21.

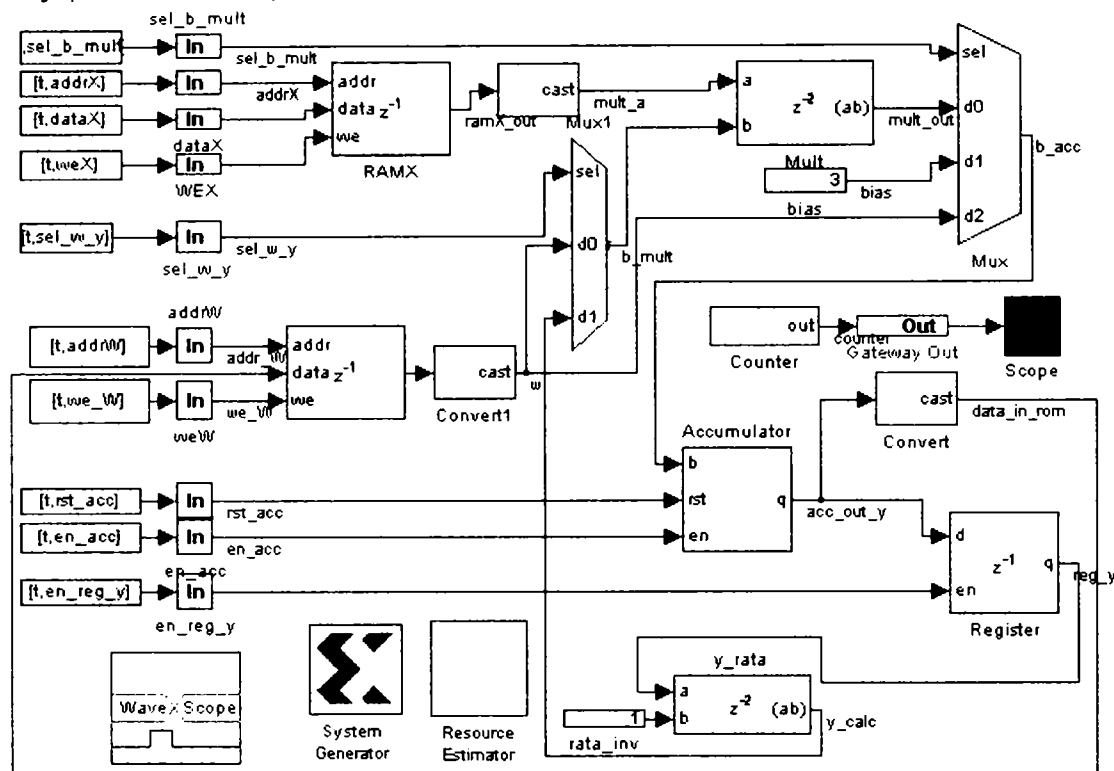


Figura 5.21 Modelul neuroprocesorului NeuroHebb_1R_2M

D. Neuroprocesorul NeuroHebb_1R_1M

Modelul neuroprocesorului NeuroHebb_1R_1M folosește un singur multiplicator pentru determinarea tuturor valorilor parametrilor implicați în algoritmul de calcul a ieșirii neuronului în faza de propagare și de update-are a ponderilor în faza de învățare, figura 5.22.

Avantajul acestui model față de modelele propuse mai sus, constă în consumul mai mic de resurse pentru implementarea hardware la aceeași viteză de calcul și implicit un consum mai mic de putere. O altă caracteristică importantă a modelelor propuse derivă din faptul că odată ce neuroprocesorul este implementat, acesta, în urma antrenării cu o anumită regulă de învățare își va putea modifica ponderile în mod continuu. Practic neuronul va învăța în mod continuu prin acumularea de cunoștințe noi, corespunzătoare variațiilor parametrilor externi.

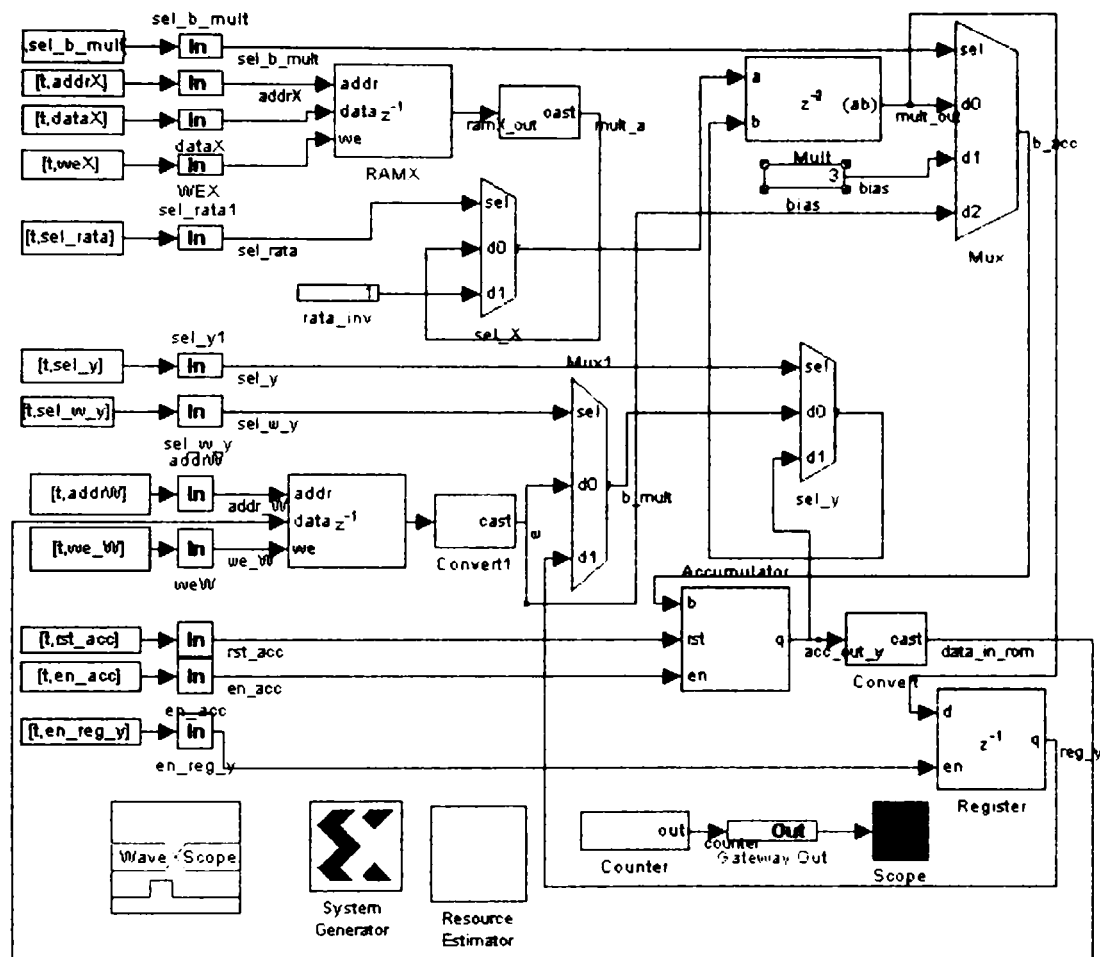


Figura 5.22 Modelul neuroprocesorului NeuroHebb_1R_1M

5.4.4.3. Implementarea unei rețele neuronale MLP cu învățare onchip

Implementarea unei rețele neuronale Multy Layer Perceptron cu învățare onchip ridică probleme mai complexe legate de tipul și modul de implementare a algoritmului de învățare și mai ales de modul de control a diferitelor blocuri ce intră în componența unei astfel de rețele. În continuare se va prezenta modul de implementare a unei rețele MLP cu învățare prezentându-se doar blocurile cele mai importante corespunzătoare unei astfel de implementări.

În general o rețea neuronală MLP este constituită dintr-un strat de intrare, un strat de ieșire și unul sau mai multe straturi intermediare denumite straturi ascunse. Fiecare strat primește semnale doar de la stratul imediat inferior și trimite semnale doar spre stratul imediat superior. Nu există conexiuni între neuronii din același strat. Stratul de intrare servește doar la propagare înainte a datelor, iar straturile următoare, pe lângă propagare înainte a datelor trebuie să îndeplinească și funcția de propagare înapoi a erorii și de ajustare a ponderilor conform erorii primite. Nu există

o regulă care să stabilească numărul de straturi ai unei rețele neuronale și nici numărul de neuroni pe strat, aceștia se stabilesc de obicei experimental. Ca o regulă generală este bine ca rețeaua să fie cât mai simplă. În majoritatea cazurilor un strat ascuns este suficient pentru a rezolva orice problemă. Numărul de straturi ascunse nu este în general mai mare decât doi. Numărul de neuroni din straturile de intrare și de ieșire depind de aplicație, în timp ce numărul de neuroni din stratul (straturile) ascunse se determină prin încercări.

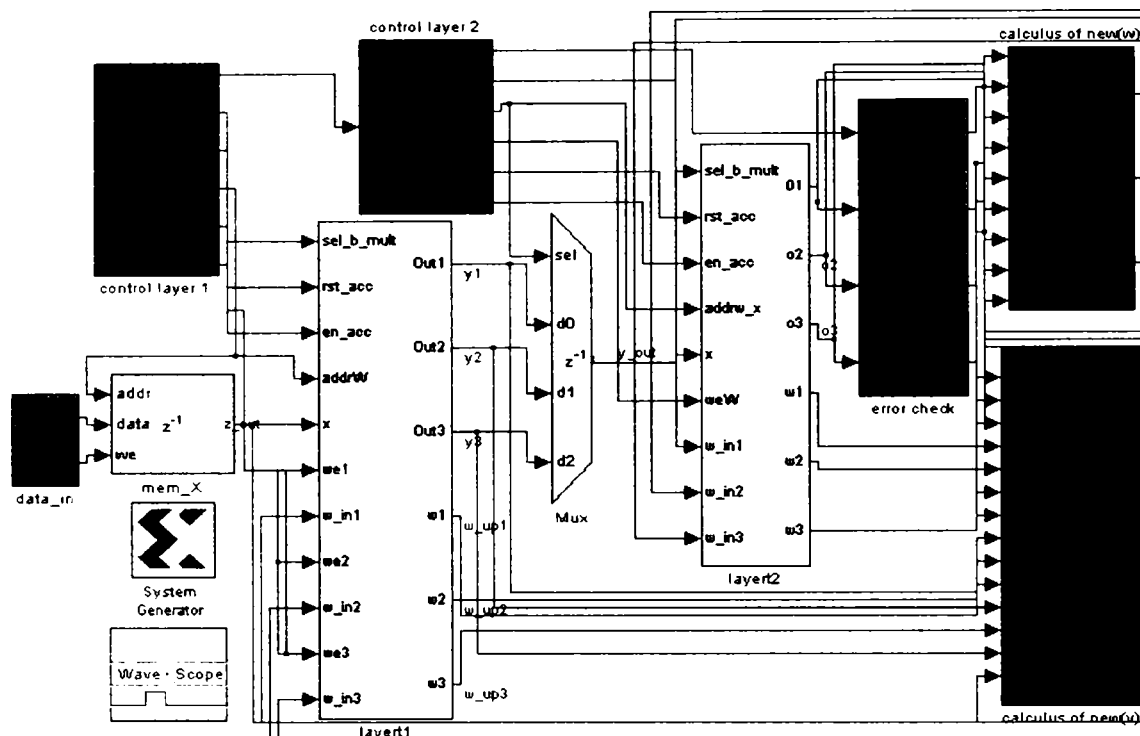


Figura 5.23 Rețea neuronală MLP cu un singur strat ascuns

O astfel de rețea este antrenată utilizând algoritmul de propagare înapoi a erorii. Acest algoritm constă în calcularea erorii fiecărui neuron din stratul de ieșire, prin compararea vectorului de ieșire cu un vector de test, și propagarea erorii înapoi în straturile precedente. Eroarea aplicată fiecărui neuron va fi proporțională cu contribuția neuronului respectiv în formarea vectorului de ieșire. Pe baza acestor erori fiecare neuron își va modifica ponderile astfel încât să conducă la minimizarea erorii de ieșire.

În figura 5.23 este prezentată structura bloc a unei rețele MLP cu învățare onchip și cu un singur strat ascuns. Blocurile de calcul a erorii și de ajustare a ponderilor sunt blocurile suplimentare ce fac diferența dintre o rețea MLP normală și una cu învățare onchip.

Blocul de control prezentat în figura 5.24 se ocupă cu controlul unități de procesare a stratului ascuns. Controlează modul de acces a memoriei de date și a memoriei de ponderi și semnalele de control pentru selecția căilor de acces a datelor și eventualele semnale de reset local. Elementele ce intră în componența unui astfel de modul de control sunt formate, în general, din numărătoare și unități de comparație.

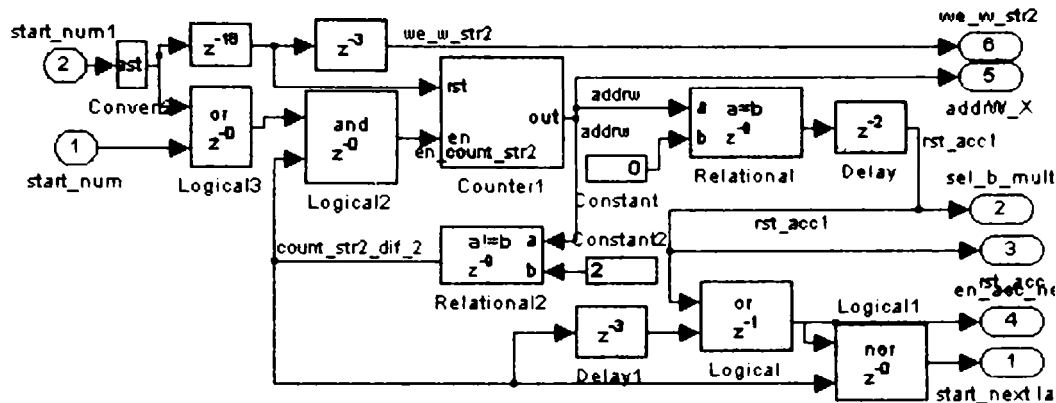


Figura 5.24 Blocul de control al stratului ascuns

În cazul algoritmului cu propagare înapoi a erorii o atenție deosebită trebuie acordată funcției de activare de la ieșirea fiecărui neuron. Acest lucru se datorează faptului că pentru minimizarea erorii este necesară calcularea derivatei funcției de activare. Cea mai des utilizată funcție de activare este funcția sigmoid deoarece este o funcție neliniară a cărei derivată poate fi calculată direct din valoarea curentă a funcției .

$$y(n) = \frac{1}{1 + e^{-n}} \tag{ 5.20}$$

$$y'(n) = y(n)(1 - y(n))$$

Funcția sigmoid , fiind o funcție neliniară, poate fi implementată hardware fie printr-o tabelă de memorie fie printr-o funcție liniară de aproximare. O astfel de funcție de aproximare este funcția PLAN (Piecewise Linear Approximation of a Nonlinear function) propusă de Amin, Curtis și Hayes-Gill. Modul prin care această funcție realizează aproximarea funcției sigmoid este descris în tabelul 5.5.

Tabel 5.5 Aproximarea PLAN a funcției sigmoid

PLAN(X)	CONDITIE
1	$ x \geq 5$
$0,03125 \cdot x + 0,84375$	$2,375 \leq x < 5$
$0,0125 \cdot x + 0,625$	$1 \leq x < 2,375$
$0,25 \cdot x + 0,5$	$0 \leq x < 1$

Principalul avantaj pe care îl oferă acest tip de aproximare constă în resursele hardware necesare pentru implementarea funcției de aproximare. Funcția PLAN poate fi implementată hardware cu ajutorul unor registre de deplasare. În figura 5.25 este

prezentată arhitectura hardware necesară pentru implementarea funcției PLAN într-un circuit FPGA.

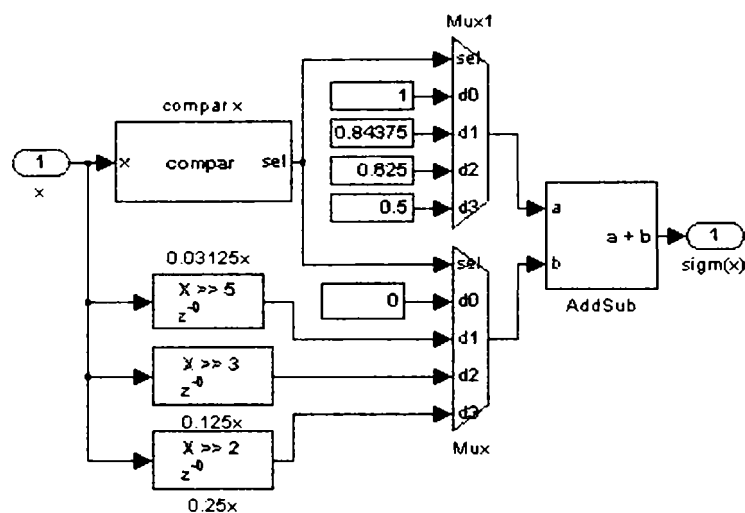


Figura 5.25 Arhitectura hardware a funcției PLAN pentru aproximare funcției sigmoide

În figura 5.26 este prezentată structura blocului de calcul al erorii. Acest bloc are sarcina de a calcula eroarea totală a stratului de ieșire, de a compara eroarea calculată cu o valoare de prag și de a calcula, genera, semnalul de eroare pentru fiecare neuron.

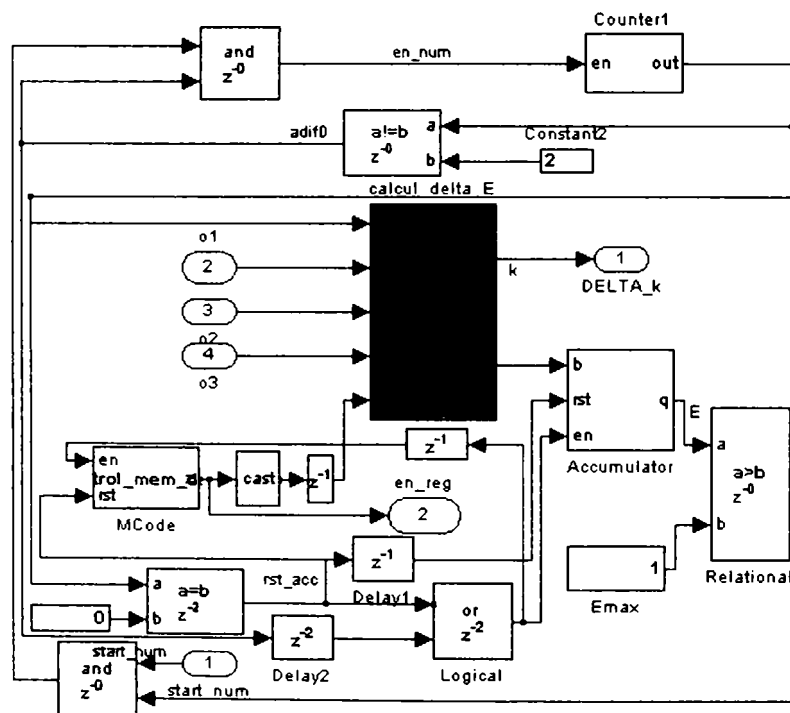


Figura 5.26 Blocul de calcul și de verificare a erorii

O altă componentă importantă a rețelei neuronale cu învățare onchip este blocul de calculare și ajustare a ponderilor neuronilor. Schema bloc a acestui modul este prezentată în figura 5.27. Modulele componente sunt descrise în limbaj VHDL. Codul din aceste blocuri implementează în hardware ecuațiile ce descriu matematic algoritmul de ajustare al ponderilor.

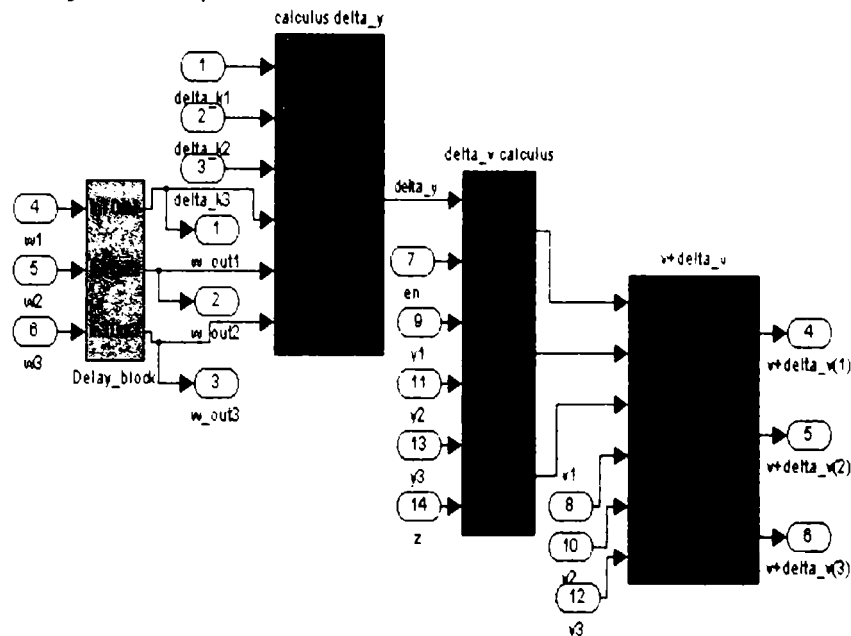


Figura 5.27 Blocul de calcul al ponderilor stratului ascuns

Deși este posibilă implementarea unei rețele neuronale MLP cu învățare onchip, consumul mare de resurse pe care îl implică implementarea hardware a modului de antrenare justifică utilizarea unei astfel de soluții doar în cadrul unor sisteme portabile autoconfigurabile care nu au acces la alte modalități de antrenare.

5.5. Concluzii

Utilizarea unei rețele neuronale artificiale ca și clasificator este o soluție des întâlnită în sistemele de recunoaștere a tiparelor actuale. Majoritatea sistemelor de recunoaștere a tiparelor utilizează ca și clasificator o rețea neuronală artificială. În cadrul acestui capitol au fost prezentate noțiuni generale cu privire la rețelele neuronale artificiale cât și modalități de implementarea a acestora în hardware. Autorul a realizat un studiu cu privire la modalitățile de implementare hardware a rețelelor neuronale artificiale, punând accentul pe modalitățile de implementare digitală a acestora. În ultima parte a capitolului autorul prezintă soluții proprii de implementare în circuite FPGA a rețelelor neuronale artificiale. Autorul a dezvoltat o bibliotecă Simulink menită să ușureze implementarea unor astfel de rețele în circuite FPGA prin intermediul mediului MatLab. Rezultatele cercetării sunt valorificate prin publicarea lor la diferite conferințe de specialitate, naționale și internaționale [176][177].

Autorul dorește să utilizeze o rețea neuronală ca și clasificator în cadrul unui sistem de clasificare a semnalului mioelectric. Cercetările efectuate în acest domeniu au arătat că o problemă majoră a unei astfel de rețele constă în adaptarea ei la

condiții noi de funcționare, mai exact la adaptarea performanțelor rețelei în raport cu gradul de oboseală al musculaturii. În cazul depășirii unui anumit grad de oboseală, performanțele de clasificare sunt slabe drept urmare sistemul necesită o reantrenare a rețelei neuronale. În cazul implementării unui astfel de modul într-un sistem protetic, pacientul va fi obligat fie să oprească utilizarea sistemului protetic fie să execute o reantrenare a rețelei neuronale. În mod clasic antrenarea rețelei neuronale se face offline, pacientul fiind obligat, în cel mai bun caz, să se conecteze la un PC și să efectueze algoritmul de antrenare a rețelei. Autorul a încercat să găsească o soluție pentru a întâmpina această problemă, prin implementarea în hardware a algoritmului de antrenare. În ultima parte a acestui capitol, autorul a arătat că este posibilă implementarea unei rețele neuronale MLP cu învățare onchip. Acest mod de implementare hardware al unei rețele neuronale ar putea fi util pentru rețelele neuronale adaptabile, în cazul în care nu există acces la o unitate de antrenare software. Datorită faptului că acest mod de implementare consumă un număr mare de resurse nu este indicată utilizarea lui pentru rețele neuronale de uz general. În cazul sistemelor protetice o astfel de abordare ar putea realiza recalibrarea unei rețele neuronale pentru controlul sistemului protetic în cazul în care parametri semnalului mioelectric se modifică foarte mult. Având în vedere faptul că în general parametrii semnalului mioelectric se modifică datorită apariției oboselii sau datorită schimbărilor de mediu, ar fi de preferat utilizarea unei rețele neuronale cu ponderi reconfigurabile. Acest lucru nu necesită neapărat implementarea unei rețele cu învățare onchip ci mai degrabă implementarea unei rețele cu seturi de ponderi precalculate. Autorul a participat la dezvoltarea unor soluții pentru implementarea de rețele neuronale cu învățare onchip alături de grupul de cercetare în domeniul sisteme dedicate inteligente de la Universitatea de Nord din Baia Mare. Soluțiile propuse au fost publicate la diferite conferințe de specialitate [204]-[209].

6 SISTEME DE RECUNOAȘTERE A TIPARELOR PENTRU COMANDA SISTEMELOR PROTETICE

În domeniul proteticii, în ultimii 15 ani, au fost realizate o serie de cercetări legate de implementarea unor module de comandă bazate pe recunoașterea tiparelor. Acestea se doresc a fi o alternativă pentru sistemele de comandă actuale bazate pe estimarea amplitudinii semnalului mioelectric, prin intermediul cărora să se încerce realizarea unor sisteme protetice cu comandă cât mai „naturală”. Prin comandă „naturală” se înțelege un mod de comandă care să se apropie cât mai mult de modul de comandă biologic al sistemului nervos uman. După cum se știe, sistemul nervos central realizează comanda membrelor prin intermediul unor trenuri de impulsuri nervoase. Aceste impulsuri determină contracții musculare care au ca rezultat acționarea membrelor. Modulele de comandă bazate pe recunoaștere tiparelor încearcă să extragă, din semnalul biologic analizat, anumite tipare pe baza cărora să se poată identifica tipul de acțiune comandat de către sistemul nervos central. Cu ajutorul unor astfel de sisteme protetice, pacienții nu vor mai fi nevoiți să învețe cum să controleze proteza deoarece sistemul protetic se va adapta modului de comandă al pacientului.

Ideal ar fi ca semnalul biologic analizat să fie semnalul nervos [62][63][159]. Problema care se ridică în acest caz este legată de modul de achiziționare a semnalului nervos. În momentul de față există cercetări în această direcție care folosesc neurosenzori de tip regenerativ[123][56][17][1]. Datorită faptului că acești senzori presupun o metodă invazivă de implantarea în structura sistemului nervos, cercetările sunt realizate doar pe animale. O altă soluție este de a analiza semnalul mioelectric rezultat în urma înervării mușchiului de către semnalul nervos ce se dorește a fi studiat. Și în acest caz există două abordări: analiza semnalului mioelectric intramuscular [61][169][170][185][186] sau analiza semnalului mioelectric de suprafață [32][34][59][91][153].

Cu toate că există cercetări în acest domeniu, încă la ora actuală nu există nici o soluție practică care să se reflecte în sistemele protetice actuale. În opinia autorului, soluțiile bazate pe analiza semnalului mioelectric de suprafață sunt cele care au cele mai mari șanse de a fi implementate în sistemele protetice actuale. Aceasta se datorează faptului că sunt soluții neinvazive care pe de o parte oferă un confort mai ridicat pacientului față de metodele invazive, iar pe de altă parte necesită cheltuieli și eforturi de cercetare mult mai mici. În acest capitol vor fi prezentate noțiuni generale despre sistemele de recunoaștere a tiparelor cât și soluții pentru extragerea unui vectori de trăsături din semnalul mioelectric de suprafață.

6.1. Sisteme de recunoaștere a tiparelor

Prin recunoașterea tiparelor se înțelege în mod obișnuit acel ansamblu de metode și tehnici cu ajutorul căruia se poate realiza o clasificare în cadrul unei mulțimi de obiecte, procese sau fenomene. Sistemele de recunoaștere a tiparelor sunt atât în analiza semnalelor deterministe cât și în analiza semnalelor de natură

stohastică, în general fiind folosite în cazurile în care abordările directe sunt imposibile sau când referințele teoretice lipsesc [2]. Sistemele de recunoaștere de tipare își găsesc aplicație într-o varietate de domenii dintre care amintim:

- medicină – sisteme automate de diagnosticare pe baza simptomelor prezentate și a rezultatelor analizelor, analiza și interpretare electrocardiogramelor, encefalogramelor, analiza radiografiilor
- industrie – detectare defectelor de fabricație ale produselor, sisteme de viziune artificială pentru roboți industriali
- procesarea semnalelor și a imaginilor – recunoașterea vorbirii, recunoașterea caracterelor, recunoașterea amprentelor, recunoaștere facială etc.
- analiza diferitelor fenomene economice și luarea unor decizii de natură financiară, analiza fenomenelor sociale etc.

O aplicație standard de recunoaștere a formelor cuprinde următoarele etape:

- codificare – folosirea unei metode de reprezentare a datelor de prelucrat compatibilă cu cerințele sistemelor numerice de calcul.
- preprocesarea – eliminarea eventualelor zgomote care pot afecta datele de intrare, efectuarea de prelucrări în vederea reducerii dimensiunii datelor, normalizări, transformări liniare și neliniare etc.
- învățarea – construirea unui model de clasificator, plecând de la o mulțime de exemple și împărțirea acestora într-un anumit număr de clase
- analiza și decizia – stabilirea clasei din care face parte un tipar
- postprocesare – eventuala validare a deciziei luate, având ca suport o anumită bază de cunoștințe.

Din aceste etape se desprinde obiectul general al recunoașterii tiparelor: pe de o parte descrierea și reprezentarea obiectelor și fenomenelor într-o manieră standard de „formă” astfel încât să poată fi supuse unor prelucrări matematice și algoritmice și pe de altă parte luarea unei decizii privind clasificarea unui tipar necunoscut la o clasă deja „învățată”. Un rol foarte important în procesul de recunoaștere de tipare îl joacă metoda de reprezentare a informațiilor caracteristice. Datele supuse spre clasificare trebuie să conțină suficiente informații pentru a putea asigura o bună precizie a clasificării, dar totodată trebuie să fie condensate pentru a evita un timp de calcul exagerat în momentul luării deciziei.

6.1.1. Noțiuni generale

Prin tipar sau formă se înțelege modelarea matematică a obiectelor sau fenomenelor sub forma unui vector de caracteristici. Vectorul trăsăturilor caracteristice (VTC), definit în spațiul euclidian cu n dimensiuni R_n , numit și spațiul caracteristicilor, este dat de:

$$X = \begin{pmatrix} x_1 \\ x_2 \\ \dots \\ x_n \end{pmatrix} = (x_1 \ x_2 \ \dots \ x_n)^T \quad (6.1)$$

Fiecare x_i reprezintă o trăsătură caracteristică a tiparului.

Prin spațiul tiparelor se înțelege populația tiparelor care urmează a fi analizate, deci o submulțime a spațiului caracteristicilor.

$$T_x = \{X_i\}_{i=1,m} \quad (6.2)$$

O problemă este aceea a raportului dintre numărul de tipare luate în considerare, m , și numărul de dimensiuni al spațiului caracteristicilor, n , adică raportul m/n dintre numărul maxim de obiecte din setul respectiv, m , și numărul de caracteristici, n , aferent fiecăruia dintre obiecte. Dacă numărul de forme, m , este mai mic, egal sau numai puțin mai mare decât numărul de caracteristici atunci discriminarea dintre tipare și atribuirea lor la diferitele clase posibile este un proces pur aleator.

În general, se consideră că acest raport m/n , pentru orice aplicație de recunoașterea a tiparelor, trebuie să îndeplinească următoarele condiții:

$$\begin{aligned} \text{(i)} \quad & \frac{m}{n} \geq 3, \\ \text{(ii)} \quad & \frac{m}{n} > 10. \end{aligned} \quad (6.3)$$

unde m reprezintă numărul de tipare, iar n este numărul de caracteristici independente (număr de dimensiuni). Condiția (i) reprezintă minimum necesar pentru o clasificare binară, în timp ce condiția (ii) este de dorit în aplicațiile concrete ale tehnicilor de recunoașterea a tiparelor.

Spațiul claselor C desemnează o categorie de etichete care servește la clasificarea tiparelor date. Prin clasificator se înțelege o funcție K definită pe spațiul formelor ce asociază fiecărui tipar X din T un identificator aparținând spațiului claselor:

$$K : T \rightarrow C, K(X) = c \quad (6.4)$$

Se numește set de învățare o mulțime de forme a căror clasificare este cunoscută:

$$S = \{(X, c) \mid X \in T, c \in C\} \quad (6.5)$$

Metoda de învățare utilizată va influența performanțele și precizia clasificării. Se pot distinge două modalități generale de învățare [124]:

- învățare supravegheată – presupune construirea clasificatorului general pe baza unui set de învățare S , se cunoaște deci clasa de apartenență a fiecărui tipar
- învățare nesupravegheată – presupune realizarea unei partiționări a spațiului tiparelor ținând cont de asemănările tiparelor furnizate (sunt construite grupuri de forme asemănătoare fără nici o informație inițială privind clasele de apartenență ale acestora).

6.1.2. Structura unui sistem de recunoaștere a tiparelor

Un sistem de recunoaștere a tiparelor trebuie să asigure, corect și eficient observarea, transformarea, prelucrarea preliminară (selectarea) și clasificarea eșantionului de date. Elementele esențiale ale unui sistem general de recunoaștere a tiparelor sunt următoarele: translatorul, selectorul de trăsături (care realizează o

prelucrare preliminară) numit și preprocesor, sau extractor de trăsături și clasificatorul (figura 6.1).




Figura 6.1 Structura bloc a unui sistem de recunoaștere a tiparelor

6.1.2.1. Translatorul

Translatorul transformă și transferă informațiile din lumea reală în spațiul tiparelor într-o formă compatibilă cu modul de reprezentare din calculatoarele electronice. În consecință datele primare, rezultat al observației, sunt transformate într-un șir de mărimi scalare care formează vectorul de tipare n-dimensional. Fiecare componentă x_i a vectorului de tipare X reprezintă o cantitate fizică măsurabilă; este foarte important ca ea să surprindă esența datelor primare.

Modul de implementare al translatorului depinde exclusiv de natura datelor primare. Dacă acestea sunt constituite dintr-o succesiune de valori măsurate la intervale de timp, cum sunt semnalele EMG, atunci sunt necesare procedee de eșantionare în timp, pe când dacă ele sunt funcție de frecvență, cum sunt de exemplu spectrele în infraroșu ale compușilor chimici, atunci trebuie dezvoltate procedeele de eșantionare a frecvenței (respectiv numerelor de undă). În cazul imaginilor sunt luate în considerare suprafețele mai luminoase sau mai întunecate, muchiile sau formele geometrice. Aceasta este o problemă ceva mai complicată și, de aceea, au fost propuse o serie de metode pentru reducerea complexității imaginilor la un șir de măsurători.

O situație fericită, în care translatorul nu mai este necesar, apare atunci când informațiile din lumea reală sunt exprimate numeric. Vectorii de formă dezvoltăți de translator constituie mărimile de intrare pentru selectorul de caracteristici.

6.1.2.2. Selectorul de trăsături

Scopul selectorului de trăsături constă în prelucrarea vectorilor de tipare în așa fel încât procedeul de clasificare să fie optimizat. Selectorul de trăsături (denumit și extractor de trăsături sau preprocesor) acceptă ca mărimi de intrare vectorii de tipare produși de translator și operează asupra lor transformându-i pentru a elimina sau, cel puțin, pentru a reduce cantitatea de informație irelevantă sau ambiguă menținând în vectori suficientă informație pentru a putea discerne între diferitele clase de tipare și a descoperi invarianțele dintre formele aceleiași clase.

Pentru realizarea acestor deziderate au fost propuse și utilizate o mare varietate de metode. Una dintre cele mai simple metode pentru prelucrarea vectorilor de tipare constă în normarea acestora. O astfel de normare implică egalarea sumei

componentelor fiecărui vector de tipare (respectiv suma pătratelor componentelor lor) cu o constată arbitrară convenabil aleasă. Un alt procedeu, mult mai sofisticat, care utilizează matricea de covarianță duce, în final, la o ecuație matricială din care se obțin vectorii proprii și valorile proprii (procedeu numit analiza componentelor principale sau analiza Karhuneu-Loeve).

Pentru prelucrarea vectorilor de formă și selectarea celor mai reprezentative trăsături caracteristice au fost utilizate și o serie de transformări mult mai complexe, cum ar fi transformata Fourier, transformata Fourier scurtă sau transformata wavelet

Pentru identificarea trăsăturilor mai importante au fost utilizate tipare model sau prototip, s-au dezvoltat și implementat tehnici interactive, implicând reprezentări grafice și rutine speciale de comparare, s-au calculat parametrii statistici, cum sunt momentele sau histogrammele direct din forme.

Această etapă este esențială, de ea depinde succesul sau insuccesul oricărui studiu de recunoaștere a formelor.

6.1.2.3. Clasificatorul

Sarcina oricărui clasificator este, în general, următoarea: având dată o mulțime de vectori de tipare prelucrați corespunzător, numită set de formare, se pune problema determinării unei funcții de decizie $D(X)$ astfel încât dacă:

$$\begin{cases} D(X) < 0 & X \in C_1 \\ D(X) \geq 0 & X \in C_2 \end{cases} \quad (6.6)$$

Această etapă în care este determinată funcția de decizie $d(X)$ este cunoscută sub numele de fază de formare (formarea), de adaptare sau uneori de învățare. Scopul urmărit este minimalizarea probabilității de eroare în procesul de clasificare.

Conceptul de clasificare a tiparelor poate fi înțeles ca o partiționare a spațiului tiparelor, $T_x = \{X\}$ prin atribuirea fiecărui vector X sau punct $X(x_1, \dots, x_n)$ la o clasă de tipare corespunzătoare în regiuni reciproc exclusive, fiecare regiune corespunzând unei clase de tipare particulară. Din punct de vedere matematic problema clasificării poate fi formulată sub forma funcțiilor de decizie discriminate [137].

Fie c_1, c_2, \dots, c_p cele p clase distincte posibile care urmează a fi recunoscute cu

$$\begin{aligned} T_x &= c_1 \cup c_2 \cup \dots \cup c_p \\ F_d &= c_1 \cap c_2 \cap \dots \cap c_p \end{aligned} \quad (6.7)$$

și fie $X = |x_i|$, $i=1, n$ vectorul de tipare, x_i reprezentând a i -a trăsătură reprezentativă. Atunci funcția de decizie discriminant $D(X) = D_j(X)$ asociată clasei de forme c_j , $j=1, \dots, p$, astfel încât dacă tiparul de intrare reprezentat prin vectorul X , respectiv punctul X , este în clasa c_i , fapt pe care-l vom nota prin $X \sim c_i$, valoarea lui $D_i(X)$ trebuie să fie cea mai mare, adică pentru toți $X \sim c_i$ vom avea satisfăcută relația:

$$D_i(X) > D_j(X), \quad i, j = 1, \dots, p. \quad (6.8)$$

În felul acesta, în spațiul tiparelor T_x , frontiera partiției, denumită limita de decizie, dintre regiunile corespunzând claselor c_i și respectiv, c_j , poate fi definită prin următoarea relație:

$$F_d = D_i(X) - D_j(X) = 0 \quad (6.9)$$

În figura 6.2. este reprezentat modelul unui clasificator care utilizează funcțiile discriminant. Tiparul de intrare este analizat conform relației (6.8), clasificatorul furnizând drept ieșire indicele k aparține $\{1,2,\dots,p\}$ corespunzător clasei c_k din care face parte tiparul respectiv X .




Figura 6.2 Modelul unui clasificator ce utilizează funcția discriminant

Pentru determinarea funcțiilor discriminant neparametrice setul de formare trebuie să fie mare și, de asemenea, reprezentativ pentru a permite estimarea acestora din funcțiile de probabilitate.

Sunt cunoscute două moduri de abordare a procesului de recunoaștere a tiparelor. Primul mod cunoscut sub numele de recunoaștere controlată (supravegheată), presupune existența unui set de tipare a căror apartenență la clasă este cunoscută. Acest set este împărțit în două părți: setul de formare utilizat pentru a dezvolta un clasificator (ce utilizează, de exemplu, matricea distanțelor dintre tipare) care să recunoască cât mai bine apartenența tiparelor din set la clasele corespunzătoare și setul de predicție pe care clasificatorul format este evaluat (testat). Clasificatorul astfel dezvoltat este utilizat în continuare pentru stabilirea apartenenței unui tipar necunoscut la o clasă.

Cel de-al doilea mod cunoscut sub numele de recunoaștere necontrolată (nesupravegheată), nu face apel la o cunoaștere prealabilă a apartenenței tiparelor la o clasă. Metoda dezvoltă algoritmi care permit în cursul execuției acestora construirea claselor pe măsură ce tiparele analizate sunt luate în considerare [51].

Un caz particular al metodelor teoretice decizionale îl constituie tehnicile de învățare. Acestea utilizează un set de tipare a căror apartenență la clase este cunoscută. Setul este utilizat în mod iterativ de un algoritm care construiește coeficienții clasificatorului, corespunzător tipului de problemă (fără a utiliza matricea distanțelor dintre tipare).

Clasificatori liniari

Clasificatorii liniari sunt acei clasificatori pentru care funcția de decizie este o funcție liniară. În cazul în care avem de clasificat tipare în două clase folosind două seturi de trăsături, atunci funcția de decizie este dată de ecuația unei drepte în plan. În cazul în care numărul de trăsături respectiv numărul de clase crește, funcția de decizie va fi dată de ecuația unui hiperplan.

În figura 6.3 este prezentată situația în care datele de intrare sunt clasificate în 2 clase folosind două seturi de trăsături. Se poate observa că cele două seturi de trăsături pot fi separate printr-o dreaptă.




Figura 6.3 Principiul clasificatorului liniar [130]

Limita de decizie în acest caz este de forma:

$$u = mx + n \quad (6.10)$$

sau putem scrie:

$$a_1x + a_2y + a_3 = 0 \quad (6.11)$$

unde: $a_1 = -m$; $a_2 = 1$; $a_3 = -n$

Funcțiile discriminant pentru cele două clase pot fi construite de forma:

$$\begin{aligned} D_A(x, y) &= a_1x + a_2y + a_3 \\ D_B(x, y) &= -a_1x - a_2y - a_3 \end{aligned} \quad (6.12)$$

Generalizând, o funcție discriminant liniară pentru spațiul n-dimensional al formelor este dată de:

$$D_i(X) = w_{i1}x_1 + w_{i2}x_2 + \dots + w_{in}x_n + w_{i(n+1)} = \sum_{j=1}^n w_{ij}x_j + w_{i(n+1)} \quad (6.13)$$

Dacă se notează $x_{n+1} = 1$ atunci ecuația 6.13 devine:

$$D_i(X) = \sum_{j=1}^{n+1} w_{ij}x_j \quad (6.14)$$

Ecuația 6.14 definește prin $D_i(X) = 0$ ecuația unui hiperplan. Această ecuație poate fi scrisă matriceal astfel:

$$D_i(X) = [w_{i1} \quad w_{i2} \quad \dots \quad w_{in} \quad w_{i(n+1)}] \cdot X \quad (6.15)$$

Sintetizând pentru toate valorile lui i obținem:

$$\begin{bmatrix} D_1(X) \\ D_2(X) \\ \dots \\ D_K(X) \end{bmatrix} = \begin{bmatrix} w_{11} & w_{12} & \dots & w_{1n} & w_{1(n+1)} \\ w_{21} & w_{22} & & w_{2n} & w_{2(n+1)} \\ \dots & & & & \\ w_{K1} & w_{K2} & & w_{Kn} & w_{K(n+1)} \end{bmatrix} \cdot X \Leftrightarrow D = WX \quad (6.16)$$

Limitele de decizie dintre oricare două clase pot fi deduse astfel:

$$D_i(X) - D_j(X) = 0 \Leftrightarrow \sum_{m=1}^{n+1} (w_{im} - w_{jm}) x_m = 0 \quad (6.17)$$

Ecuția 6.17 reprezintă ecuația unui hiperplan care trece prin originea spațiului extins al trăsăturilor, spațiu a cărui utilizare simplifică mult studiul clasificatorilor liniari.

Pentru cazul a două clase este suficient o singura funcție de decizie astfel încât:

$$\begin{cases} D(X) < 0 & X \in C_1 \\ D(X) \geq 0 & X \in C_2 \end{cases} \quad (6.18)$$

Cazul a mai multe clase se poate reduce la clasificarea cu două clase, dacă se adoptă una din următoarele strategii de construcție a clasificatorilor multicategorice, strategii valabile pentru orice tip de clasificator (nu numai pentru cei liniari) [55]:

- Strategia I - Se construiește, corespunzător fiecărei clase, un clasificator care să împartă spațiul trăsăturilor în două regiuni, astfel încât una să conțină clasa respectivă, iar cealaltă restul claselor. Decizia de clasificare se ia folosind regula:

$$X \in C_j \Leftrightarrow D_j(X) > D_i(X), \forall i \neq j, i = 1 \dots K \quad (6.19)$$




Figura 6.4 Clasificator linear multicategorie, strategia I [130]

Se remarcă apariția unei regiuni de nedeterminare (gri) pentru care nu se poate lua o decizie.

- Strategia II - Se construiește, corespunzător fiecărei perechi de clase, un clasificator care să împartă spațiul trăsăturilor în două regiuni, astfel încât una să conțină clasele respective, iar cealaltă restul claselor. În acest caz se construiesc funcții de decizie de forma:

$$X \in C_i \text{ sau } X \in C_j \Leftrightarrow D_{ij}(X) > 0, \forall i \neq j, j = 1 \dots K \quad (6.20)$$




Figura 6.5 Clasificator liniar multicategorie, strategia II [130]

- Strategia III - Fiecare funcție discriminant separă doar două clase între ele, caz în care zona de nedeterminare se reduce foarte mult. În acest caz se construiesc funcții de decizie de forma:

$$D_{ij}(X) = D_i(X) - D_j(X) \quad (6.21)$$

Regula de decizie folosită în acest caz este:

$$X \in C_i \Leftrightarrow D_{ij}(X) > 0, \forall i \neq j, j = 1 \dots K \quad (6.22)$$




Figura 6.6 Clasificator liniar multicategorie, strategia III [130]

Dacă clasele pot fi separate utilizând strategia 1 de clasificare, regiunile în care sunt prezente clasele vor fi mai compacte, fapt care conduce la o mai bună identificare a claselor decât în cazul utilizării strategiei 2 sau 3 de clasificare. În schimb, însă, regiunea de nedeterminare este mare. Dacă în aplicația practică apar tipare în regiunea de nedeterminare rezultate în urma aplicării tipului 1 de clasificare, poate fi încercată utilizarea strategiei 2 de clasificare, în care regiunea de nedeterminare este mai mică sau a strategiei 3 (strategia 3 de clasificare are dezavantajul că timpul de calcul este mare).

Clasificatorul de distanța minimă

O importantă clasă de clasificatori se bazează pe valoarea distanțelor dintre tiparul de intrare și un set de vectori de referință sau puncte prototip din spațiul caracteristicilor (prototipurile sunt forme a căror apartenență la clase este cunoscută).

Pentru fiecare clasă se definesc vectorii prototip care reprezintă centrul de greutate (media) tiparelor care alcătuiesc setul de antrenament (învățare, formare) al clasei C_i :

$$R_i = \frac{1}{M_i} \sum_{j=1}^{M_i} X_j, i = 1 \dots K \quad (6.23)$$

Funcțiile discriminant se construiesc în acest caz pe baza distanței de la un vector oarecare de intrare la vectorii prototip, distanță notată $d(X, R_i)$. Decizia se ia conform regulii:

$$\begin{aligned} X \in C_i &\Leftrightarrow d(X, R_i) < d(X, R_j), \forall i \neq j, j = 1 \dots K \\ X \in C_i &\Leftrightarrow d^2(X, R_i) < d^2(X, R_j), \forall i \neq j, j = 1 \dots K \end{aligned} \quad (6.24)$$

Pe baza acestei distanțe se construiește funcția discriminant, punând, mai întâi, distanța precedentă sub forma:

$$d(X, R_i) = \|X - R_i\|^2 = \|X\|^2 - 2R_i^T X + \|R_i\|^2 \quad (6.25)$$

Se poate observa ca termenul X^2 este un termen independent de clasă care, prin urmare poate fi eliminat. Termenul R_i^2 este un termen relativ constant ce va fi calculat doar în faza de construcție a clasificatorului. Funcția discriminant devine astfel:

$$\begin{aligned} D_i(X) &= -2R_i^T X + \|R_i\|^2 \\ \text{sau:} & \end{aligned} \quad (6.26)$$

$$D_i(X) = R_i^T X - 0.5\|R_i\|^2$$

Decizia de apartenență la o anumită clasă se ia astfel:

$$X \in C_i \Leftrightarrow R_i^T X - 0.5\|R_i\|^2 = \min im \quad (6.27)$$

Din cele spuse anterior rezultă că un clasificator de distanță minimă este un clasificator liniar. Performanța unui astfel de clasificator depinde evident de modul cum sunt aleși vectorii de referință dar și de felul cum sunt evaluate distanțele. Cele mai frecvente distanțe utilizate sunt cele derivate de distanța generală Minkovski.

$$d_{Minkovski} = \left[\sum_{i=1}^n (x_i - r_i)^k \right]^{1/k} \quad (6.28)$$

Astfel, pentru $k = 2$ se obține binecunoscuta distanță Euclidiană.

$$d_{Euclid} = \left[\sum_{i=1}^n (x_i - r_i)^2 \right]^{1/2} \quad (6.29)$$

Pentru $k = 1$ se obține distanța Manhattan.

$$d_{\text{Manhattan}} = \sum_{i=1}^n |x_i - r_i| \quad (6.30)$$

Dacă toate caracteristicile x_i și r_i , $i = 1, \dots, n$ sunt codificate binar, atunci distanța Manhattan poartă numele de distanța Hamming. Distanța Hamming este echivalentă cu numărul de caracteristici care sunt diferite în X și R . Aplicarea lui SAU EXCLUSIV, simbolizat aici prin XOR, permite calculul foarte rapid al distanței Hamming conform relației:

$$d_{\text{Hamming}} = \sum_{i=1}^n \text{XOR}(x_i, r_i) \quad (6.31)$$

Clasificatorul celor mai apropiați vecini

Clasificatorul celor mai apropiați vecini este un clasificator de distanță minimă în raport cu mai mulți vectori de referință. O generalizare a metodei vecinului cel mai apropiat este clasificatorul celor mai apropiați "k" vecini. În acest caz apartenența unui tipar la o clasă este decisă examinând un număr de "k" vecini (cei mai apropiați) ai tiparului respectiv, vecini a căror apartenență la clase este cunoscută.

Pentru găsirea celor mai apropiați "k" vecini se utilizează cel mai des distanța euclidiană. Metoda se poate aplica cu succes și pentru forme neseperabile liniar, și pentru clasificări multicategorie. Pentru clasificarea formelor binare se utilizează distanțele Hamming sau Tanimoto.

Regula de decizie cea mai simplă folosită este cea a numărului maxim de voturi: $X \in C_k$, dacă între cei "k" vecini, cei mai mulți aparțin clasei C_k . Cazurile cu număr egal de voturi se elimină.

Rezultate eronate pot apare dacă clasele sunt definite prin vectori prototip în număr foarte diferit de la o clasă la alta, clasa definită prin mai puțini vectori prototip fiind dezavantajată. În acest caz se mărește numărul de voturi pentru fiecare vector prototip al clasei dezavantajate cu raportul între numărul de vectori prototip ai clasei dezavantajate și numărul de vectori prototip pentru cealaltă clasă.

Această metodă este laborioasă dacă numărul de forme prototip este mare. O variantă a acestei metode duce la clasificarea cu ajutorul funcțiilor de potențial, în care potențialul unui punct (unei forme) este estimat prin superpoziția potențialelor celor mai apropiați "k" vecini.

6.1.3. Extragerea trăsăturilor

Sistemele de recunoaștere a tiparelor nu realizează operația de clasificare direct pe datele de intrare, ci pe un vector de trăsături extrase din datele de intrare. Abordarea statistică a problemei clasificării tiparelor are în vedere clasificarea tiparelor având la bază măsurarea unor proprietăți sau trăsături specifice ale acestora. Astfel un tipar poate fi reprezentat ca și un ansamblu de caracteristici sau trăsături. Trăsăturile utilizate în cadrul operației de recunoaștere a tiparelor pot fi clasificate în funcție de natura lor în:

- trăsături cantitative

- trăsături calitative

Etapa de alegere a trăsăturilor este esențială, influențând rezultatele viitoare ale clasificatorului și deci ale sistemului de recunoaștere. Se impune o analiză a valorilor care pot fi luate de aceste trăsături. Analiza trăsăturilor cantitative se realizează cu ajutorul unei serii de indicatori statici cum ar fi: media aritmetică, mediana, abaterea medie liniară, abaterea medie pătratică, dispersia etc.

Un indicator al corelației dintre trăsături este reprezentat de covarianță. Covarianța dintre două trăsături i și j este definită ca media aritmetică a produselor dintre abaterile valorilor fiecărei trăsături de la valorile medii:

$$\text{cov}(i, j) = \frac{\sum_{k=0}^{p-1} (x_{k,i} - m_i)(x_{k,j} - m_j)}{p} \quad (6.32)$$

Acest indicator reflectă dependența dintre cele două trăsături astfel:

- $\text{cov}(i,j) > 0$ – dependența dintre cele două trăsături este directă (cresc sau descresc împreună)
- $\text{cov}(i,j) < 0$ – dependența dintre cele două trăsături este indirectă
- $\text{cov}(i,j) = 0$ – trăsăturile sunt independente

Etapa de alegere a trăsăturilor reprezentative care vor descrie un tipar este de o importanță majoră, influențând atât precizia și calitatea clasificatorului cât și timpul de execuție al algoritmului de clasificare. Ansamblul trăsăturilor alese trebuie deci să se supună unor cerințe de ordin calitativ și cantitativ.

Adesea, multe trăsături au relativ puțină importanță în discriminarea dintre clase. De exemplu, putem avea 50 de trăsături, dar tiparele pot fi clasificate corect utilizând doar 5 sau 6 dintre aceste trăsături. Includerea unui număr mare de trăsături slabe sau irelevante nu numai că încetinește procesul de decizie dar poate să conducă și la diminuarea performanțelor acestuia.

Există o serie de abordări care au ca rezultat eliminarea sau diminuarea trăsăturilor cu importanță relativ redusă, și anume [156]:

- utilizarea unor algoritmi de tipul backtracking - bazați pe forță brută care vor alege un subset de trăsături care conferă cea mai mică rată de eroare a clasificării
- utilizarea unor algoritmi de tip greedy - există două variante ce pot fi aplicate și anume pornind de la o submulțime formată dintr-o singură trăsătură, se adaugă progresiv o nouă trăsătură care îmbunătățește performanțele clasificării sau, pornind de la o mulțime inițială de trăsături se elimină treptat trăsătura ce reduce cu cel mai puțin performanța totală
- combinarea trăsăturilor – această operație conduce la obținerea unor trăsături noi pe baza combinării trăsăturilor existente, care pot determina performanțe sporite ale clasificării
- analiza corelației dintre trăsături – această abordare este utilă în cazul în care pot exista trăsături corelate. Metodele de analiză a corelației dintre trăsături se regăsesc în metodele generale utilizate în statistică, cum ar fi:
 - metode parametrice sau analitice – calcularea raportului de corelație, coeficientul de corelație etc.
 - metode neparametrice – coeficientul de asociere, coeficientul Pearson, raportul de corelație empirică etc.

Metodele prezentate nu asigură întotdeauna obținerea celui mai bun subset de trăsături pentru un anumit proces de clasificare însă pot contribui la creșterea performanțelor acestuia și au avantajul de a fi ușor de implementat.

6.2. Soluții pentru extragerea vectorului de trăsături din semnalul mioelectric de suprafață

Semnalul mioelectric de suprafață este un semnal care reflectă activitatea ponderată a grupelor musculare aflate sub zona de achiziție. Ponderarea este datorată pe de-o parte poziției mușchilor față de zona de achiziție iar pe de altă parte de intensitatea diferită de contracție a grupelor musculare. Pentru a utiliza acest semnal într-un modul de comandă pentru un sistem protetic este necesară extragerea unui vector de trăsături care să caracterizeze cât mai bine activitatea musculară. Având în vedere natura nestaționară a semnalului mioelectric, autorul este de părere că extragerea unui vector de trăsături în urma analizei în domeniul frecvență-timp constituie cea mai indicată soluție în cazul semnalului mioelectric. În literatură există informații referitoare la utilizarea coeficienților wavelet ca și vector de trăsături pentru un sistem de clasificare a semnalului mioelectric [58][60][97][170][215]. Prin utilizarea directă a coeficienților wavelet ca și vector de trăsături rezultă un vector multidimensional de ordin foarte mare. De aceea, în opinia autorului, este indicată găsirea unor metode de reducere a dimensionalității vectorului de trăsături. O soluție pentru reducerea dimensionalității vectorului de trăsături o poate constitui extragerea componentelor principale. Prin această metodă vor fi identificate și extrase variabilele cele mai semnificative din vectorul analizat.

Semnalul mioelectric de suprafață reflectă activitatea a mai multor grupe musculare. Prin extragerea componentelor principale se poate obține un vector de trăsături redus care să reflecte această activitate dar nu se poate discrimina activitate fiecărei grupe musculare în parte. Analiza componentelor independente este o generalizare a analizei componentelor principale care ia în considerare și dependențele neliniare dintre datele de intrare. Aplicând o analiză combinată PCA-ICA este posibilă obținerea unui vector de trăsături care să reflecte mult mai bine activitatea musculară a fiecărei grupe musculare.

6.2.1. Analiza componentelor principale

Analiza componentei principale (PCA) reprezintă o tehnică statistică de reducere a numărului de variabile din setul de date supus analizei fără pierdere de informație și, de asemenea, ca un proces de identificare de noi variabile cu semnificație mai importantă. Un neajuns al metodei este acela că noile variabile create nu sunt, de cele mai multe ori, ușor de interpretat. PCA s-a aplicat cu cele mai bune rezultate în aplicații cum ar fi compresia de imagine, caz în care este mai importantă reducerea volumului de date decât interpretarea acestora.

În multe alte aplicații, PCA este folosită în special pentru a furniza dimensiunile reale ale setului de date. Cu alte cuvinte, se caută răspunsul la următoarele întrebări:

- Dacă setul de date include m variabile, este nevoie de toate aceste m variabile pentru a reprezenta informația sau variabilele se pot recombina într-un număr mai mic care să conțină, în continuare, informațiile esențiale?
- Dacă ultima ipoteză este corectă, atunci care este cea mai potrivită dimensiune pentru noul set de date?"

PCA operează prin transformarea unui set de variabile corelate într-un set nou de variabile, de data aceasta, necorelate, denumite componente principale. Cu alte cuvinte prin intermediul PCA se poate transforma un set de informații reprezentate prin vectori N dimensionali într-un set de vectori M dimensionali astfel încât noile componente ale vectorilor să exprime cât mai bine variabilitatea datelor analizate. Pentru a exemplifica putem considera cazul în care informația este reprezentată printr-un set de vectori de dimensiune $N=2$. Inițialii vectorii sunt reprezentați în sistemul de coordonate x_1, x_2 (vezi figura 6.7). Se poate observa că prin înlocuirea sistemului de coordonate cu un nou sistem y_1, y_2 se poate surprinde structura setului de date reținând doar componenta corespunzătoare axei $0y_1$. Axa $0y_1$ este direcția de-a lungul căreia datele variază cel mai mult, astfel că pentru realizarea unei clasificări ar fi suficient să se rețină doar componenta corespunzătoare acestei axe. În practică, setul de vectori care reprezintă informația de analizat, are o dimensiune foarte mare. Determinarea componentelor principale permite eliminarea redundanței sau a zgomotului, permițând ca informația relevantă să poată fi reprezentată printr-un set de vectori de dimensiune redusă.




Figura 6.7 Exemplu de extragere a componentelor principale dintr-un set de date bidimensional

Soluția matematică pentru determinarea componentelor principale constă în determinarea vectorilor și valorilor proprii corespunzătoare matricei de covarianță a setului de vectori. Matricea de covarianță poate fi descrisă astfel:

$$S = \begin{bmatrix} \sigma_{11} & \sigma_{12} & \dots & \sigma_{1N} \\ \sigma_{21} & \sigma_{22} & & \sigma_{2N} \\ \dots & & & \dots \\ \sigma_{N1} & \sigma_{N2} & \dots & \sigma_{NN} \end{bmatrix} \quad (6.33)$$

Se caută o soluție pentru a reduce matricea de covarianță S la o matrice diagonală D care, pe diagonala principală prezintă valorile proprii (λ_i) ale matricei S . Matricea D poate fi determinată prin pre și post multiplicarea matricei S cu o matrice ortonormată astfel:

$$W' S \cdot W = D \quad (6.34)$$

Coloanele matricei W sunt formate din vectorii proprii ai matricei S . Valorile proprii prezente în matricea D corespund vectorilor proprii prezenți în matricea W , numiți și componente principale. Valorile proprii reprezintă ponderea pe care o are fiecare componentă principală în varianța totală. Această pondere poate fi interpretată ca și o măsură a importanței a unei componente principale.

Valorile proprii pot fi determinate cu ajutorul următoarei ecuații:

$$\det|S - \lambda I| = 0 \quad (6.35)$$

unde I este matricea unitară.

După calculul valorilor proprii, vectorii proprii se pot determina cu ajutorul ecuației:

$$\det|S - \lambda I| b_i = 0 \quad (6.36)$$

unde vectorii proprii se obțin din b_i , astfel:

$$u_i = \frac{b_i}{\sqrt{b_i' b_i}} \quad (6.37)$$

Algoritmul de extragere a componentelor principale dintr-un set de vectori N dimensionalii poate fi reprezentat astfel:

- Construirea matricei vectorilor de date X , unde fiecare vector reprezintă o linie din matricea X
- Extrage din fiecare element al unui vector de date media elementelor vectorului

$$Y_{i,j} \cdot y_{i,j} = x_{i,j} - \bar{x}_i$$

- Calculează matricea de covarianță $S = \text{cov}(Y)$
- Calculează vectorii și valorile proprii a matricei de covarianță
- Alege primele M componente principale care au cea mai mare valoare proprie

În cazul a două sau cel mult trei variabile procedura prezentată poate fi efectuată cu ușurință, dar pentru un număr mai mare de variabile calculul devine greoi. Este mult mai ușor de a folosi descompunerea în valori singulare care are avantajul de a lucra direct pe datele matriciale și poate fi făcută într-o singură etapă.

Prin descompunerea unei matrice A în valori singulare se obține o matrice diagonală D_{svd} de aceeași dimensiune cu și matricea A având elementele de pe diagonală în ordine descrescătoare, și două matrice unitare W_{svd} și V_{svd} astfel încât este satisfăcută relația:

$$A = W_{svd} \cdot D_{svd} \cdot V_{svd} \quad (6.38)$$

În cazul unui set de vectori de intrare X , dacă se descompune în valori

singulare matricea $Y = \frac{1}{\sqrt{n-1}} X^T$, se va obține:

$$Y = W \cdot D^{1/2} \cdot W^T \quad (6.39)$$

unde W este matricea componentelor principale iar D matricea valorilor proprii.

6.2.2. Rețele neuronale pentru analiza componentelor principale

În paragraful anterior am prezentat două metode de extragere a componentelor principale dintr-un set de date. Principala problemă în aplicarea acestor algoritmi este determinarea matricei vectorilor proprii ai matricei de covarianță. În cazul în care se dorește determinarea on line a matricei W , ce conține vectori componentelor principale, prin ajustarea ei pentru fiecare realizare a vectorului aleatoriu de intrare sau în cazul în care dimensiunea vectorilor de intrare este foarte mare, o metodă alternativă o constituie utilizarea unui algoritm iterativ de învățare nesupervizată aplicat unei rețele neuronale cu arhitectură simplă.

Pentru determinarea componentelor principale sunt utilizate rețele neuronale cu autoorganizare [4][15]. Acestea sunt rețele neuronale cu o structură simplă, care au la bază neuroni artificiali liniari.




Figura 6.8 Modelul unui neuron liniar

Modelul unui neuron liniar, prezentat în figura 6.8, descrie semnalul de ieșire ca fiind o combinația liniară a intrărilor, și poate fi exprimat matematic astfel:

$$y = \sum_{i=0}^{N-1} w_i x_i \quad (6.40)$$

În [174], Oja a arătat ca un neuron liniar la care ponderile sinaptice se adaptează într-o manieră hebbiană va duce la determinarea componentelor primei componente principale. Algoritmul de învățare propus de Oja realizează adaptarea ponderilor conform relației:

$$w_i(n+1) = w_i(n) + \eta y(n) [x_i(n) - y(n) w_i(n)] \quad (6.41)$$

În ecuația (6.41) pot fi evidențiate două forme de reacție internă:

- reacție pozitivă ce determină creșterea ponderilor în conformitate cu intrarea
- reacție negativă prin care se obține un control al creșterii ponderilor

Dezavantajul algoritmului propus de Oja constă în faptul că permite extragerea doar a vectorului primei componente principale. Acest dezavantaj a fost remediat de Sanger [188] care a propus un algoritm pentru extragerea primelor M componente principale. O rețea neuronală capabilă să extragă primele M componente principale ale unui set de date poate fi construită folosind M neuroni liniari. Primul neuron oferă o aproximare pentru prima componentă principală, pe urmă se extrage din fiecare vector de intrare proiecția acestuia pe prima componentă principală. Rezultatul reprezintă datele de intrare pentru al doilea neuron care va extrage a doua componentă principală. Se consideră analogia pentru toate cele M componente principale.




Figura 6.9 Rețea neuronală pentru extragerea a primelor 3 componente principale

În figura 6.9 este prezentată structura unei astfel de rețele neuronale destinate extragerii primelor trei componente principale. Dacă considerăm vectorul de intrare de forma:

$$X = [x_1, x_2, \dots, x_n]^T \quad (6.42)$$

și vectorii componentelor principale furnizați de coloanele matricei ponderilor ca fiind de forma:

$$W_j = [w_{j1}, w_{j2}, \dots, w_{jn}]^T, j = 1..M \quad (6.43)$$

putem scrie ecuație de adaptare a ponderilor, conform algoritmului propus de Sander, astfel:

$$W_j(n+1) = W_j(n) + \eta(n) y_j(n) \left[X(n) - y_j(n) W_j(n) - \sum_{i < j} y_i(n) W_i(n) \right] \quad (6.44)$$

Ecuția (6.44) poate fi scrisă sub formă matricială astfel:

$$W(n+1) = W(n) + \eta(n) \{ Y(n) X^T(n) - LT[Y(n) Y^T(n)] W(n) \} \quad (6.45)$$

unde LT este un operator matricial care are ca rezultat o matrice cu elementele diagonalei principale și elementele din partea superioară a diagonalei principale nule.

În [125], Kung și Diamantoros au propus un nou algoritm pentru extragerea componentelor principale folosind rețele neuronale. Ei au propus o rețea neuronală

liniară, care pe lângă conexiunile feedforward prezintă și conexiuni laterale. Prin intermediul conexiunilor laterale neuronii interacționează într-o manieră antihebbiană. Fiecare neuron influențează doar neuronii următori astfel încât primul neuron influențează toți neuroni, cel de-al doilea neuron influențează toți neuroni în afară de primul neuron etc. În figura 6.10 este prezentată structura unei astfel de rețele neuronale.




Figura 6.10 Structura unei rețele neuronale APEX

Algoritmul propus a fost denumit algoritm pentru extragerea adaptivă a componentelor principale (APEX). Ecuație ce descrie ieșirea rețelei neuronale poate fi descrisă matematic astfel:

$$Y = WX - CY \quad (6.46)$$

unde W reprezintă matricea ponderilor direct iar C reprezintă matricea ponderilor laterale.

Matricea ponderilor laterale este descrisă astfel:

$$C = \begin{bmatrix} 0 & 0 & 0 \\ c_{21} & 0 & 0 \\ \dots & & \dots \\ c_{m1} & \dots & c_{m,m-1} & 0 \end{bmatrix} \quad (6.47)$$

Algoritmul APEX presupune adaptarea ponderilor astfel:

$$\begin{aligned} W_j(n+1) &= W_j(n) + \eta [y_j(n)X(n) - y_j^2(n)W_j(n)] \\ C_j(n+1) &= C_j(n) + \eta [y_j(n)Y_{j-1}(n) - y_j^2(n)C_j(n)] \end{aligned} \quad (6.48)$$

Extragerea componentelor principale dintr-un set de date poate fi realizat simplu prin trecerea datelor printr-o rețea liniară cu un singur strat. Soluțiile oferite în literatura de specialitate se deosebesc prin algoritmi de antrenare propuși pentru rețeaua neuronală. Există mai mulți algoritmi care pot extrage mai multe componente

principale, multe dintre soluții fiind doar îmbunătățiri aduse algoritmilor APEX [71][72][216] sau algoritmului hebian generalizat [105][169]. În cadrul tezei de doctorat, autorul a realizat în mediul Matlab module pentru determinarea componentelor principale bazate atât pe metodele clasice cât și bazate pe rețele neuronale. Aceste module vor fi utilizate pentru extragerea componentelor principale din vectorul de trăsături extras din semnalul mioelectric.

6.2.3. Extragerea componentelor principale din semnalul mioelectric de suprafață achiziționat la nivelul antebrățului

Utilizarea coeficienților wavelet ca și vector de trăsături pentru un sistem de clasificare a tiparelor este, în opinia autorului, o soluție ineficientă datorită dimensiunii mari a vectorului de trăsături. Prin analiza wavelet a unui semnal discret se obține un număr de coeficienți wavelet egal cu numărul de eșantioane din fereastra de analiză plus ordinul funcției wavelet utilizată pentru descompunere. În lucrarea de față, autorul a utilizat o fereastră de analiză de 256 eșantioane pentru a analiza semnalul mioelectric de suprafață achiziționat în zona antebrățului. Deci ca și urmare se vor obține aproximativ 256 de coeficienți wavelet. După cum se poate observa este evidentă necesitate utilizării unui algoritm de reducere a dimensionalității vectorului de trăsături.

După cum s-a prezentat în capitolul 4, analiza wavelet se realizează folosind un algoritm de codare în subbandă. Astfel, spectrul semnalului de analizat este divizat într-un număr de subbenzi și pentru fiecare subbandă se extrage un anumit număr de coeficienți, care vor constitui coeficienții wavelet. Un semnal poate fi descompus în maxim $\log_2 N$ nivele, unde N reprezintă numărul de eșantioane al semnalului analizat. Având în vedere faptul că semnalul mioelectric supus analizei este segmentat pe segmente de 256 eșantioane lungime, rezultă că o descompunere wavelet completă va avea 8 nivele. În tabelul 6.1 sunt prezentate subbenzile pe care se efectuează analiza precum și numărul de coeficienți corespunzător.

Tabel 6.1

Banda de frecvențe	Număr coeficienți
250-500 Hz	256+M
125-250 Hz	128+M
62,5-125 Hz	64+M
31,25-61,5 Hz	32+M
15,625-31,25 Hz	16+M
7,812-15,625 Hz	8+M
0-7,812 Hz	4+M

Valoarea lui M reprezintă numărul de eșantioane suplimentar datorat dimensiunii filtrelor utilizate în procesul de descompunere wavelet și poate fi determinată astfel:

$$M = \frac{2^{j+1} - 1}{2^j} L \quad (6.49)$$

unde L reprezintă ordinul filtrului FIR

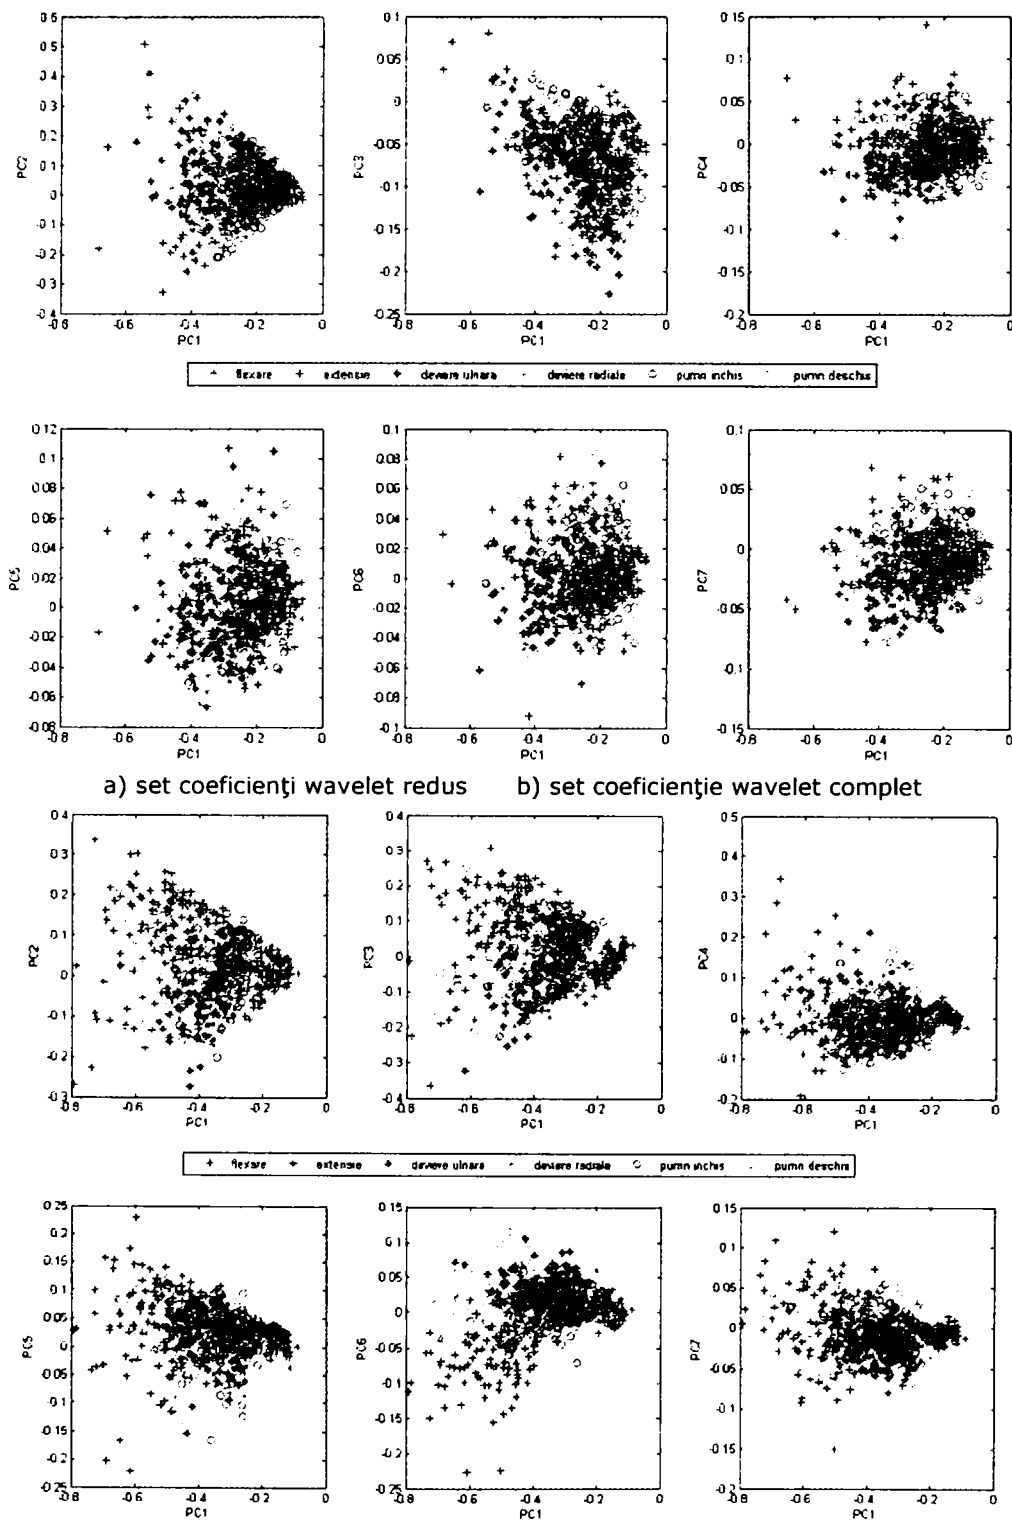


Figura 6.11 Dependența dintre prima componentă principală și următoarele 6 componente principale

O metodă de reducere a dimensiunii vectorului de trăsături constă în eliminarea unor coeficienți care nu conțin informații utile. Deoarece spectrul semnalului mioelectric este cuprins între 20-500Hz, descompunerea wavelet a semnalului se poate efectua doar pe 5 nivele eliminându-se astfel coeficienții corespunzători nivelelor 6 și 7. În literatura de specialitate este prezentată și eliminarea coeficienților de detaliu ai primului nivel de descompunere, argumentându-se că pe intervalul 250-500 MHz raportul semnal zgomot este foarte mic.

Soluțiile prezentate anterior au ca rezultat eliminarea a aproape jumătate din numărul de coeficienți rezultați în urma descompunerii wavelet a semnalului mioelectric. Cu toate acestea, dimensiunea vectorului rezultat este încă foarte mare. O soluție mai eficientă ar fi aplicarea algoritmului de analiză a componentelor principale asupra semnalului mioelectric. Astfel vor fi extrase doar informațiile cele utile din setul de coeficienți wavelet. Numărul de componente principale, și în mod implicit dimensiunea finală a vectorului de trăsături, pot fi determinate empiric în funcție de aplicație.

În figura 6.11 este prezentată dependența dintre prima componentă principală și următoarele 6 componente principale extrase dintr-un semnal mioelectric achiziționat la nivelul antebrațului. Semnalul mioelectric a fost supus analizei wavelet după care au fost eliminați coeficienții de detaliu ai primului nivel de descompunere. Semnalul mioelectric a fost achiziționat pentru 6 tipuri de posturi diferite ale mâinii. Fiecare punct din figură corespunde unei anumite măsurători. Se poate observa un anumit grad de grupare a datelor în funcție de postura mâinii.

În continuare este prezentată aceeași analiză asupra întregului set de coeficienți wavelet, fără a elimina coeficienții de detaliu ai primului nivel de descompunere. De această dată se poate observa o mai bună diferențiere a grupelor de date. Date corespunzătoare posturii de flexare a mâinii sunt foarte bine separate față de restul norului de date. Și în cadrul norului de date rămas se pot observa grupele corespunzătoare celorlalte posturi. Se poate astfel concluziona că deși raportul semnal zgomot al semnalului mioelectric în banda 250-500Hz este foarte mic, semnalul mioelectric prezintă informații foarte importante în această bandă. Astfel se poate demonstra că nu este justificată eliminarea coeficienților wavelet ai primului nivel de descompunere în cazul analizei semnalului mioelectric.

În urma extragerii componentelor principale din coeficienții wavelet ai semnalului mioelectric se poate obține un vector de trăsături de dimensiuni reduse care descrie foarte bine activitatea mușchilor analizați. În cazul prezentat, dimensiunea vectorului de trăsături a fost redusă de aproximativ 100 de ori păstrându-se informațiile cele mai importante din punct de vedere al discriminării acțiunilor mușchilor. Numărul optim de componente principale va fi determinat empiric în funcție de performanțele de clasificare a sistemului de clasificare dezvoltat de autor și prezentat în capitolul 7 al acestei lucrări.

6.2.4. Analiza componentelor independente

Metoda analizei componentelor independente propune transformarea datelor de intrare într-un set de variabile independente. Motivația acestei transformări este de a descoperi din setul de date un set de variabile cu ajutorul cărora în urma unei operații de mixare să se poată obține setul de date inițial. Aceste variabile vor descrie cel mai bine sursele de semnal cu ajutorul cărora a fost generat semnalul de analizat.

Baza celor mai multor abordări ale metodei analizei componentelor independente o reprezintă un model generativ care descrie cum sunt produse semnalele măsurate. Modelul presupune că semnalele măsurate sunt produsele combinațiilor liniare ale surselor independente. Un asemenea model poate fi exprimat analitic sub forma următoare:

$$x_i(t) = a_{i1}s_1(t) + a_{i2}s_2(t) + \dots + a_{in}s_n(t) \quad (6.50)$$

Ecuția (6.50) poate fi pusă sub forma matricială astfel:

$$x = As \quad (6.51)$$

unde s este vectorul compus din toate sursele de semnal, A este matricea de mixare formată din elementele constante a_{ij} , iar x este vectorul semnalelor măsurate.

Algoritmii de analiză a componentelor independente se folosesc pentru a rezolva problema matricei de mixare A , din care, se pot obține ulterior componentele independente s printr-o inversiune a matricei.

$$s = A^{-1}x \quad (6.52)$$

Pentru estimarea matricei de mixare, în cadrul algoritmilor de determinare a componentelor independente se fac trei ipoteze:

- sursele de semnal s sunt statistic independente
- sursele de semnal sunt nongausiene
- numărul semnalelor măsurate să fie cel puțin egal cu numărul surselor

Două variabile y_1 și y_2 sunt considerate a fi independente dacă informațiile extrase din valorile variabile y_1 nu ne dă nici o informație despre valorile variabilei y_2 . Din punct de vedere statistic acest lucru poate fi descris folosind funcția de densitate a probabilității. Dacă notăm cu $p(y_1, y_2)$ funcția comună de densitate a probabilității pentru variabilele y_1 și y_2 , și dacă notăm cu $p_1(y_1)$ funcția marginală de densitate a probabilității definită astfel [105]:

$$p_1(y_1) = \int p(y_1, y_2) dy_2 \quad (6.53)$$

Atunci putem afirma că cele două variabile sunt independente statistic dacă:

$$p(y_1, y_2) = p_1(y_1)p_2(y_2) \quad (6.54)$$

În cadrul algoritmilor de determinare a componentelor independente se utilizează momente statistice de ordin superior. Pentru variabilele cu distribuție gaussiană, momentele statistice de ordin superior sunt nule, din această cauză este necesar să se facă ipoteză că sursele de semnal au o distribuție negaussiană. De fapt gradul de independență a surselor de semnal este cu atât mai mare cu cât sursele de semnal au o distribuție cât mai negaussiană. Din acest caz este necesară găsirea unor modalități de măsurare a gradului de independență sau de „negaussineitate” a surselor de semnal.

O modalitate de a estima gradul de independență o reprezintă estimarea funcției kurtosis sau a momentului statistic de ordin 4. Acesta poate fi definit prin relația:

$$kurt(y) = E\{y^4\} - 3(E\{y^2\})^2 \quad (6.55)$$

Deoarece în cazul analizei componentelor independente se presupune că variația este unitară, ecuația (6.55) poate fi simplificată astfel:

$$kurt(y) = E\{y^4\} - 3 \quad (6.56)$$

Pentru semnalele cu distribuție gaussiană funcția kurtosis este nulă. Variabilele aleatoare pentru care funcția kurtosis este negativă se spune că au o distribuție subgaussiană, iar cele pentru care funcția este pozitivă se spune că au o distribuție supergaussiană.

O altă metodă pentru determinarea gradului de independență constă în determinarea funcției de entropie. Entropia unei variabile aleatoare poate fi interpretat ca și o măsură a cantității de informație pe care o deține variabila respectivă. Cu cât variabila este mai aleatoare și mai greu de prezis cu atât este mai mare entropia sa. Entropia unei variabile Y este definită astfel:

$$H(Y) = -\sum_i P((Y = a_i)) \log P((Y = a_i)) \quad (6.57)$$

unde a_i reprezintă valorile pe care le poate lua variabila Y .

În [41] s-a demonstrat că variabilele cu distribuție gaussiană au cea mai mare valoare a entropiei. Din această cauză entropia poate fi utilizată pentru a estima gradul de independență. Pentru a estima cu cât este mai diferită entropia unei variabile aleatoare față de entropia unei variabile cu distribuție gaussiană se utilizează negentropia. Negentropia este definită astfel:

$$J(Y) = H(Y_{gauss}) - H(Y) \quad (6.58)$$

După cum se poate observa din ecuația (6.58), negentropia poate avea valori negative sau zero. Negentropia este nulă doar în cazul variabilelor cu distribuție gaussiană.

Problema utilizării negentropiei constă în faptul că este foarte greu de determinat. Din această cauză se utilizează funcții de aproximare a negentropiei. În [103] se propune o funcție de aproximare a negentropiei definită astfel:

$$J(y) \approx \frac{1}{12} E\{y^3\}^2 + \frac{1}{48} kurt(y)^2 \quad (6.59)$$

unde variabile z se presupune a avea medie 0 și varianță unitară.

O altă metodă de aproximare descrisă în [103] se bazează pe principiul maximizării entropiei. Metoda presupune utilizarea unei funcții de aproximare și este definită astfel:

$$J(y) \approx [E\{G(y)\} - E\{G(v)\}]^2 \quad (6.60)$$

unde y este variabila aleatoare a cărei negentropie dorim să o estimăm, iar v este o variabilă cu distribuție gaussiană. Prin alegerea unei funcții G cu o variație lentă se poate obține o aproximare foarte bună a negentropiei. Pentru funcția G se pot utiliza:

$$G(u) = \frac{1}{a} \log \cosh(au) \quad (6.61)$$

$$G(u) = -e^{-\frac{u^2}{2}}$$

unde a este o constantă din intervalul $[1,2]$

Ca și în cazul analizei componentelor principale, datorită puterii mari de calcul necesară pentru determinarea componentelor independente, implementările hardware a unui astfel de algoritmi este greu de realizat. O soluție mai convenabilă o constituie utilizarea unei rețele neuronale. Pentru rezolvarea problemei de separare în surse independente, din punct de vedere al rețelelor neuronale, au fost propuse soluții bazate în general pe rețele de tip feedforward [33][222], dar au fost propuse și unele soluții bazate pe rețele neuronale recurente [7][35][113][145].




Figura 6.12 Structura unei rețele neuronale destinată analizei componentelor independente [164]

În figura 6.12 este prezentată structura unei rețele neuronale destinată analizei componentelor independente. În general, în exploatare, rețeaua este o rețea liniară, dar în cadrul procesului de învățare sunt necesare introducerea unor funcții de activare neliniare, deci va fi o rețea neliniară. Conform ecuației (6.50), pentru semnalul de intrare $x(n)$ se poate scrie [164]:

$$x(n) = \tilde{A}y(n) + z(n) = \tilde{x}(n) + z(n) \quad (6.62)$$

unde matricea \tilde{A} (NxM) reprezintă o estimare a matricei de mixare A a surselor independente, iar $z(n)$ reprezintă semnalul de zgomot aflat în structura semnalului de intrare. Referitor la rețeaua prezentată pot fi enunțate două probleme:

- determinarea matricei B(MxN) prin intermediul căreia se pot obține componentele $y=Bx$, cât mai independente posibil
- determinarea matricei de mixare \tilde{A} (NxM) care minimizează eroarea:

$$E\{\|z(n)\|^2\} = E\{\|x(n) - \tilde{A}v(n)\|^2\} \quad (6.63)$$

În cazul în care se urmărește doar extragerea componentelor independente, structura ce formează matricea \tilde{A} poate fi omisă. Matricea B este compusă din două părți. Partea care realizează propriu-zis separarea surselor independente este matricea W. Vectorii de intrare nu pot fi aplicați direct matricei W, fiind necesară o preprocesare a acestora. Această preprocesare constă în centrarea față de valoare medie urmată de o procedură de obținere a unor date albe și o eventuală reducere a dimensiunii datelor de intrare. Aceasta poate fi realizată prin utilizarea unei metode de extragere a componentelor principale, care efectuează simultan o compresie optimă a informației în sensul erorii pătratice medii și o filtrare a zgomotului gaussian [202]. Matricea acestei transformări este dată de relația:

$$V = D^{\frac{1}{2}} E^T \quad (6.64)$$

unde D este o matrice diagonală ce conține valorile proprii ale matricei de covarianță $E\{x(n)x^T(n)\}$ ordonate descrescător, iar E este o matrice ce conține vectorii proprii ai matricei de covarianță.

Matricea W este matricea a căror valori vor fi determinate de către algoritmul de analiză a componentelor independente. Pentru aceasta au fost propuși o serie de algoritmi care pot fi clasificați în două categorii și anume algoritmi adaptivi și algoritmi batch. Algoritmii de tip adaptiv sunt bazați pe metoda gradientului [161][104][6][145] sau o metodă de optimizare a unei funcții de cost bazată pe momente statistice de ordin superior [113][13][21]. Această clasă de algoritmi prezintă o convergență lentă care depinde foarte mult de alegerea ratei de învățare.

În continuare vor fi prezentați o serie de algoritmi adaptivi implementabili în rețele neuronale. Pentru fiecare algoritm autorul a realizat un modul de analiză utilizând limbajul Matlab.

Algoritmul Herault-Jutten (HJ)

Acest algoritm a fost dezvoltat de Herault și Jutten [113], și are la bază supoziția că matricea de separare B este de forma:

$$B = (I + S)^{-1} \quad (6.65)$$

iar matricea S este calculată astfel:

$$S(n+1) = S(n) + \mu(n)g[y(n)]h[y^T(n)] \quad (6.66)$$

Termenii de pe diagonala principală a matricei S sunt nuli, $g[y(n)] = \{g[y_i(n)]\}$ este un vector coloană iar $h[y^T(n)] = \{h[y_i(n)]\}$ este un vector linie. Pentru funcțiile $g(y)$ și $h(y)$ pot fi utilizate diverse funcții impare cum ar fi: y , y^3 , $\text{sign}(y)$, $\tanh(y)$.

Algoritmul EASI

Algoritmul EASI (Equivariant Adaptive Separation via Independence) a fost introdus de Laheld și Cardoso [129][22] și constă într-o metodă de decorelare neliniară. Algoritmul propus poate fi utilizat atât pentru analiza componentelor independente cât și ca și algoritm de învățare pentru o rețea neuronală destinată analizei neliniare a componentelor principale.

Ecuția pentru adaptarea ponderilor este exprimată astfel:

$$B(n+1) = B(n) - \mu(n) \left[y(n)y^T(n) - I + g[y(n)]h[y^T(n)] - h[y(n)]g[y^T(n)] \right] B(n) \quad (6.67)$$

Soluțiile propuse pentru funcțiile g și h sunt $g(y)=y$, $h(y)=\tanh(y)$ pentru surse subgausiene și $g(y)=\tanh(y)$, $h(y)=y$ pentru surse supergausiene. În continuare este prezentat codul Matlab dezvoltat de autor pentru implementare unui modul de analiza bazat pe algoritmul EASI.

Algoritmul INFOMAX

Acest algoritm a fost propus de Bell și Sejnowski [13] și are la bază principiul de maximizare a entropiei. Algoritmul aplică metoda gradientului pentru minimizare informației mutuale dintre datele de intrare și cele de ieșire. Ecuția pentru estimarea ponderilor este :

$$B(n+1) = B(n) + \mu(n) \left(I - 2g(y(n))y^T(n) \right) B(n) \quad (6.68)$$

O variantă modificată a fost propusă de Amari [6] în care se utilizează metoda gradientului natural îmbunătățind astfel viteza de convergență a algoritmului.

6.3. Concluzii

În ultimi ani, sistemele de recunoaștere tiparelor și-au găsit aplicativitate în diferite domenii printre care se numără și electronica medicală. În cazul semnalului analizei semnalului mioelectric cele mai multe cercetări au fost realizate în domeniul de diagnosticare a unor probleme de deficiență motorie. În acest capitol autorul a încercat să analizeze utilitatea unor astfel de sisteme pentru comanda sistemelor protetice. Principala problemă care se ridică în acest caz este legată de extragerea unui vector de trăsături care să caracterizeze foarte bine semnalul mioelectric și în același timp să aibă dimensiuni cât mai reduse. Având în vedere natura nestaționară a semnalului mioelectric, autorul propune utilizarea coeficienților wavelet ca și vector de trăsături și reducerea dimensiunii acestuia utilizând analiza componentelor principale. Din punct de vedere al implementării hardware, un modul de analiză a componentelor principale poate fi implementat ca și o structură de rețea neuronală liniară.

În prima parte a capitolului sunt prezentate noțiuni generale legate de sisteme de recunoaștere a tiparelor. Unul dintre modurile cele mai utile de

implementare a modului de clasificare, în cazul în care nu se cunosc probabilitățile apriorice de apartenență a datelor de intrare la o anumită clasă, constă în utilizarea rețelelor neuronale artificiale. Performanțele sistemelor de recunoaștere a tiparelor depinde atât de clasificatorul ales cât și de modul de extragere a trăsăturilor. Datele supuse spre clasificare trebuie să conțină suficiente informații pentru a putea asigura o bună precizie a clasificării, dar totodată trebuie să fie condensate pentru a evita un timp de calcul exagerat în momentul luării deciziei. În cazul în care vectorul de trăsături, extras din datele de intrare, are o dimensiune prea mare este necesară utilizarea unei metode de reducere a dimensionalității. O metodă de reducere a dimensiunii spațiului vectorului de trăsături constă în analiza componentelor independente. Analiza componentei principale reprezintă o tehnică statistică de reducere a numărului de variabile din setul de date supus analizei fără pierdere de informație și, de asemenea, ca un proces de identificare de noi variabile cu semnificație mai importantă. Autorul prezintă diverși algoritmi de extragere a componentelor principale printre care se numără și soluții bazate pe rețele neuronale artificiale. Analiza componentelor principale este o metodă de interpretare a momentelor statistice de ordinul doi din datele supuse analizei, prin rotirea axelor de coordonate în direcția maximizării covarianței dintre variabile [164]. Analiza componentelor independente este o generalizare a analizei componentelor principale care ia în considerare și dependențele neliniare dintre datele de intrare. Autorul prezintă o sinteză referitoare la analiza componentelor independente, diferite modalități de determinare a gradului de independență, precum și diverși algoritmi utilizați pentru extragerea componentelor independente. Modulele de extragere a componentelor independente pot fi implementate cu ajutorul rețelelor neuronale liniare a căror etapă de antrenare se face utilizând funcții neliniare.

7 SISTEM DE CLASIFICARE A SEMNALULUI MIOELECTRIC AL MEMBRULUI SUPERIOR BAZAT PE REȚELE NEURONALE

În acest capitol se vor prezenta două soluții propuse de autor pentru clasificare semnalului mioelectric provenit de la mușchii antebrăului. Sistemele propuse au ca scop identificarea poziției mâinii analizând doar semnalul mioelectric achiziționat cu ajutorul unor electrozi de suprafață. Clasificare și o parte din procesarea semnalului se face cu ajutorul rețelelor neuronale.

Ideea de clasificare a semnalului mioelectric cu ajutorul rețelelor neuronale artificiale nu este o idee nouă. În ultimii 15 ani au fost propuse mai multe soluții pentru clasificarea semnalului mioelectric utilizând rețele neuronale. Primele soluții [126][107] propuse aveau la bază extragerea unui vector de trăsături bazate pe analiza în domeniul timp a semnalului mioelectric și au reușit clasificare a două posturi diferite ale brațului. Soluția propusă de Hudgins [100][101], este bazată tot pe analiza în domeniul timp al semnalului mioelectric și propune extragerea unui număr de 6 trăsături cu ajutorul cărora reușește să identifice 4 posturi diferite ale brațului. Soluțiile bazate pe analiza în domeniul timp a semnalului mioelectric oferă o precizie de clasificare scăzută. Cea mai performantă este soluția propusă de Hudgins, caz în care eroare de clasificare este de aproximativ 18%. Performanțele scăzute obținute se datorează faptului că semnalul mioelectric este un semnal nestaționar și nu poate fi complet caracterizat folosind parametrii obținuți doar în urma analizei în domeniul timp. În ultimii 8 ani au apărut soluții noi de clasificare bazate pe analiza spectrală sau pe analiza în domeniul timp-frecvență a semnalului mioelectric. În [60], Englehart propune o soluție de clasificare bazată pe analiza wavelet a semnalului mioelectric în urma căreia obține performanțe ridicate de clasificare. În ultimii ani s-au adus îmbunătățiri sistemelor de clasificare bazate pe analiza în domeniul timp-frecvență [34][29][58][98] dar datorită faptului că aceste soluții nu se oglindesc și în aplicații comerciale (cum ar fi sistemele protetice), sugerează faptul că performanțele sau modul de implementare a acestor sisteme de clasificare pot fi încă îmbunătățite.

În cadrul acestei teze de doctorat, în urma analizei soluțiilor propuse în literatură, autorul propune două noi soluții pentru implementarea unui sistem de clasificare a semnalului mioelectric bazat pe analiza în domeniul timp-frecvență. Sistemele propuse oferă îmbunătățirea performanțelor de clasificare față de soluțiile existente. Scopul urmărit este de a analiza semnalul mioelectric achiziționat la nivelul antebrăului și de a determina până la 6 posturi diferite ale mâinii. Sistemele propuse pot fi reprezentate schematic folosind structura bloc prezentată în figura 7.1. La baza sistemelor stă analiza în domeniul timp-frecvență a semnalului mioelectric prin intermediul funcțiilor wavelet. Vectorul de trăsături ce caracterizează semnalul mioelectric analizat va fi obținut în urma descompunerii în coeficienți wavelet a semnalelor fiecărui canal de măsură. Datorită faptului că dimensiunea vectorului de trăsături obținut este foarte mare, se va recurge la reducerea dimensiunii folosind algoritmul de analiză a componentelor principale. Primul sistem propus va încerca să realizeze operația de clasificare utilizând ca date

de intrare, în blocul de clasificare, primele N componente principale extrase. Autorul va determina experimental numărul optim de componente principale necesar pentru clasificare a 4 sau 6 posturi ale mâinii. Totodată se va căuta soluția cea mai optimă privitoare la funcția wavelet utilizată pentru analiza semnalului mioelectric.

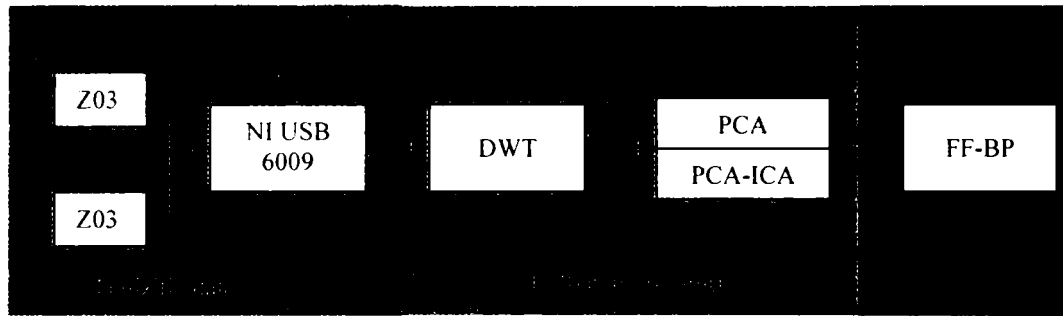


Figura 7.1 Structura bloc a unui sistem de clasificare a semnalului mioelectric bazat pe analiza în domeniul timp-frecvență

Cel de-al doilea sistem propus caută să aducă îmbunătățirea performanțelor prin utilizarea analizei componentelor independente. Analiza componentelor principale asigură reprezentare vectorilor de trăsături într-un spațiu mai restrâns evidențiind totodată variabilele cu semnificație mai importantă. Cu toate acestea acest mod de analiză nu asigură un grad ridicat de discriminare. Prin analiza componentelor independente se caută o nouă reprezentare a vectorului de trăsături astfel încât variabilele obținute să fie cât mai independente. Astfel, variabilele obținute vor avea un grad mai ridicat de discriminare, ușurând munca clasificatorului.

Modulele de analiza a componentelor independente și de analiza a componentelor independente pot fi ușor implementate folosind rețele neuronale liniare. Deoarece și clasificatorul este bazat tot pe o rețea neuronală, putem afirma că sistemele de analiză propuse sunt bazate pe rețele neuronale.

În continuare se va face o scurtă prezentare a fiecărui modul ce intră în componența sistemelor de clasificare propuse.

7.1. Modulul de achiziție a datelor

Primul modul din cadrul sistemului de analiză al semnalului mioelectric îl constituie modulul de achiziție a semnalului. Acesta este format dintr-un set de electrozi mioelectrici activi prin intermediul cărora se achiziționează semnalul mioelectric, un modul hardware de conversie analog-digitală și un modul software prin care se poate gestiona procesul de achiziție a semnalului mioelectric.

Achiziționarea semnalului mioelectric se face prin intermediul a 4 electrozi mioelectrici Z03 produși de firma MotionLab. Aceștia includ în structura lor un preamplificator diferențial ce asigură o amplificare de x1000 a semnalului achiziționat cu o rejecție de mod comun de peste 100dB la frecvența de 60Hz. Semnalul provenit de la electrozi este digitizat prin intermediul unui modul de achiziție USB-6009 produs de National Instruments. Pentru a controla procesul de achiziție, autorul a dezvoltat, cu ajutorul mediului de programarea LabView, un modul software. Informațiile referitoare la modulul software dezvoltat, precum și informații suplimentare referitoare la modulul hardware de achiziție sunt prezentate în capitolul 2.

Pentru a putea evalua performanțele sistemului de analiză, semnalului mioelectric a fost prelevat de la 4 persoane diferite. Fiecărei persoane i s-a cerut să execute câte un set de 25 de posturi pentru fiecare dintre cele 6 clase de posturi. Pentru fiecare măsurătoare, pacientul a efectuat câte două posturi separate de câte o perioadă de repaus. Durata de menținere a unei posturi respectiv durata unei perioade de repaus este de 5s. Posturile au fost separate în serie de câte două, astfel încât într-o serie să fie executate două mișcări antagoniste. Cele trei serii sunt flexare-relaxare a încheieturii mâinii, deviere ulnară-radială a încheieturii mâinii respectiv închidere deschidere pumn.

În figura 7.2 sunt prezentate cele 4 semnalele mioelectrice corespunzătoare mișcării de flexare-extensie. Este reprezentată evoluția în timp și componenta spectrală corespunzătoare fiecărui canal de măsură.

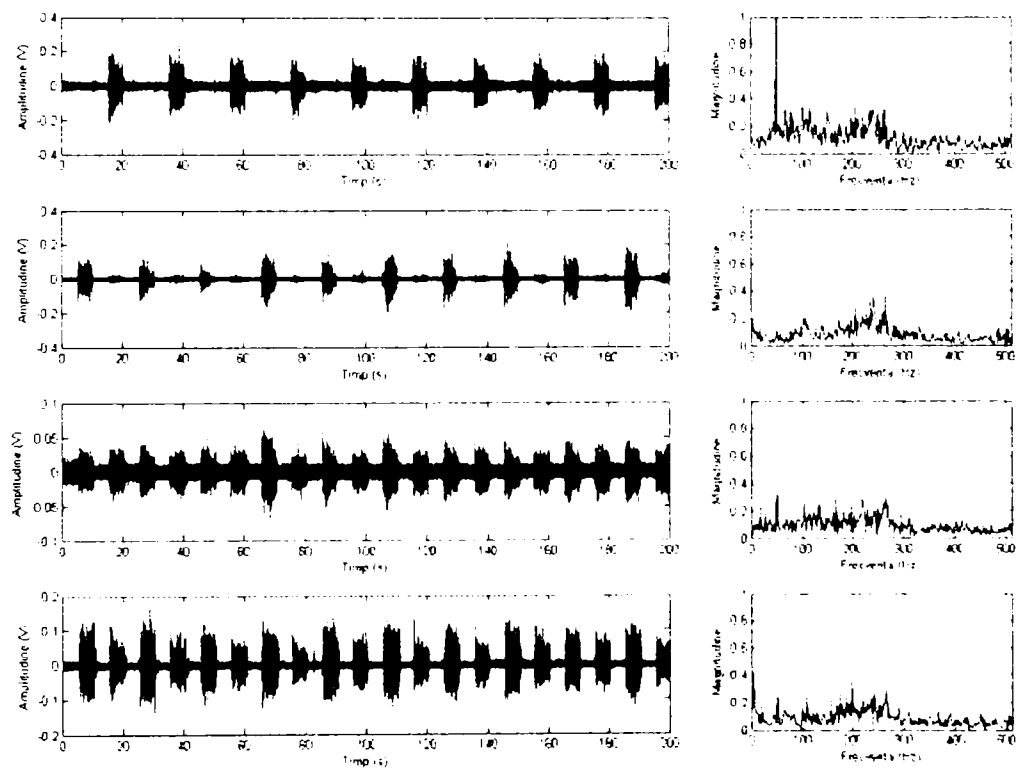


Figura 7.2 Semnalele mioelectrice achiziționate pentru acțiunile de flexare-extensie încheietură, deviere ulnară-radială încheietură, închidere-deschidere pumn.

În figura 7.3 sunt prezentate semnalele mioelectrice corespunzătoare celor 3 serii de acțiuni, corespunzătoare canalului 1 de măsură, pe o perioadă de 20s. Acest interval de timp cuprinde două perioade de repaus și câte o perioadă de 5s corespunzătoare fiecărei posturi. Se poate observa că semnalul mioelectric provenit de la canalul 1 are o contribuție importantă la realizarea mișcărilor de extensie și deviere ulnară a încheieturii și în realizarea mișcării de închidere și deschidere a pumnului.




Figura 7.3 Semnalele mioelectrice provenite de la canalul1, corespunzătoare celor 6 posturi.

În figura 7.4 sunt prezentate semnalele mioelectrice corespunzătoare canalului 2 de măsură. Se poate observa că semnalul mioelectric provenit de la canalul 2 are o contribuție importantă la realizarea mișcărilor de flexare și deviere radială a încheieturi și în realizarea mișcării de închidere a pumnului.




Figura 7.4 Semnalele mioelectrice provenite de la canalul2, corespunzătoare celor 6 posturi

În figura 7.5 sunt prezentate semnalele mioelectrice corespunzătoare canalului 3 de măsură. Se poate observa că semnalul mioelectric provenit de la canalul 3 are o contribuție importantă la realizarea mișcărilor de flexare - extensie și deviere ulnară a încheieturi și în realizarea mișcării de deschidere a pumnului.




Figura 7.5 Semnalele mioelectrice provenite de la canalul3, corespunzătoare celor 6 posturi.

În figura 7.6 sunt prezentate semnalele mioelectrice corespunzătoare canalului 4 de măsură. Se poate observa că semnalul mioelectric provenit de la canalul 4 are o contribuție importantă la realizarea mișcărilor de flexare, extensie și deviere radială a încheieturi și în realizarea mișcării de închidere și deschidere a pumnului.




Figura 7.6 Semnalele mioelectrice provenite de la canalul4, corespunzătoare celor 6 gesturi.

În final se poate concluziona că pentru clasificarea gesturilor corespunzătoare a acțiunilor de flexare-extensie respectiv închidere-deschidere pumn, sunt suficiente semnalele mioelectrice provenite de la canalele 3 și 4. Pentru a clasifica toate cele 6 gesturi sunt necesare semnalele mioelectrice provenite de la toate cele 4 canale de măsură.

Pentru a asigura o aplicabilitate practică a acestui sistem de clasificare, sistemul trebuie să ofere un răspuns în timp util. După cum se menționează și în [57], timpul de răspuns al sistemului trebuie să fie de maxim 400ms. Din această cauză

semnalul supus analizei va fi segmentat în ferestre de 250ms, rămânând astfel o perioadă de 150ms pentru analiza propriu-zisă a semnalului.

7.2. Modulul de extragerea a vectorului de trăsături

Semnalul mioelectric este un semnal netaționar. Acest lucru se datorează modului în care sunt recrutate unitățile motoare în cazul unei contracții. Pentru realizarea unei contracții de intensitate mai ridicată sunt recrutate din ce în ce mai multe unități motoare și totodată este mărită frecvența cu care aceste unități motoare sunt activate. Deci ca urmare, frecvența semnalului mioelectric de suprafață este variabilă în timp. Pentru analiza acestui tip de semnal nu sunt suficiente metodele de analiză pentru semnalele staționare, care pot fi analizate separat în domeniul timp respectiv în domeniul frecvență.

Analiza wavelet a unui semnal presupune evaluare produsului scalar dintre semnalul studiat și o funcție wavelet. Prin aceasta se arată de fapt gradul de asemănare dintre funcția de analizat și diverse versiuni scalate și translatate ale funcției wavelet.




Figura 7.7 Coeficienții wavelet rezultați în urma descompunerii semnalului mioelectric.

Semnalul mioelectric a fost descompus în coeficienți wavelet folosind o descompunere pe 5 nivele. Datorită mărimii ferestrei de analiză, semnalul mioelectric poate fi descompus pe un număr maxim de 8 nivele. Datorită faptului că semnalul mioelectric este puternic influențat de perturbații în banda 0-20Hz, se pot elimina

coeficienții ultimelor 3 nivele deoarece nu conțin informații utile. Astfel o descompunere pe 5 nivele este suficientă pe analiza semnalului mioelectric în aplicația de față.

În figura 7.7 sunt prezentați grafic coeficienții wavelet rezultați în urma descompunerii semnalului mioelectric achiziționat în timpul efectuării a 6 posturi diferite ale mâinii. Se poate observa că informația furnizată de acești coeficienți poate fi utilizată pentru discriminarea posturilor efectuate. Singurul inconvenient constă în dimensiunea mare a unui vector de trăsături format din acești coeficienți .

7.3. Modulul de analiză a componentelor principale

Coeficienții transformatei wavelet a semnalului mioelectric vor constitui trăsăturile ce caracterizează semnalul mioelectric. O fereastră de 250ms din semnalul mioelectric achiziționat conține 256 de eșantioane. În urma descompunerii wavelet se obțin un număr de $256+n$ coeficienți, unde n reprezintă ordinul filtrului folosit în procesul de descompunere. Astfel spațiul trăsăturilor extrase va avea o dimensiune de aproximativ 256. Pentru a realiza o clasificare folosind această dimensiune a spațiului trăsăturilor va fi necesară o putere de calcul foarte mare și implicit un timp mare de procesare. Găsirea unei modalități de reducere a dimensiunii spațiului trăsăturilor va scădea puterea de calcul necesară procesului de clasificare și va îmbunătăți considerabil timpul de procesare. În capitolul 6, autorul a prezentat și a demonstrat că analiza componentelor principale constituie o modalitate bună de reducere a dimensiunii spațiului unui set de vectori.

Pentru a reduce dimensiunea spațiului vectorilor de trăsături se va aplica analiza componentelor principale (PCA) pentru fiecare canal în parte. Prin PCA se caută un nou sistem de coordonate care explică cel mai bine modul de variație al datelor, astfel că prin PCA se pot elimina datele nerelevante. Dimensiunea optimă la care se face reducerea dimensiunii spațiului vectorilor de trăsături a fost determinată experimental pentru fiecare sistem de clasificare și pentru fiecare funcție wavelet utilizată.

După cum s-a arătat și în capitolul 6, algoritmul de analiză a componentelor principale are ca scop extragerea vectorilor proprii corespunzători matricii de covarianță a vectorilor analizați. Vectorii proprii aranjați în ordine descrescătoare, în funcție de valorile proprii corespunzătoare, vor constitui matricea prin intermediul căreia se vor extrage componentele principale. Pentru determinarea vectorilor proprii se poate folosi algoritmul de descompunere în valori singulare sau se poate utiliza unul din algoritmi bazați pe rețele neuronale (algoritmul hebbian generalizat, algoritmul APEX). Indiferent de metoda utilizată în final se va obține matricea de transformare. Componentele principale pot fi extrase utilizând o rețea neuronală cu un singur strat format dintr-un număr de neuroni egal cu numărul componentelor principale ce se doresc a fi extrase. Matricea de transformare va constitui ponderile acestei rețele neuronale. În figura 7.8 sunt prezentate dependența dintre prima componentă principală și următoarele 4 componente principale corespunzătoare semnalului mioelectric înregistrat de la primul canal de achiziție.

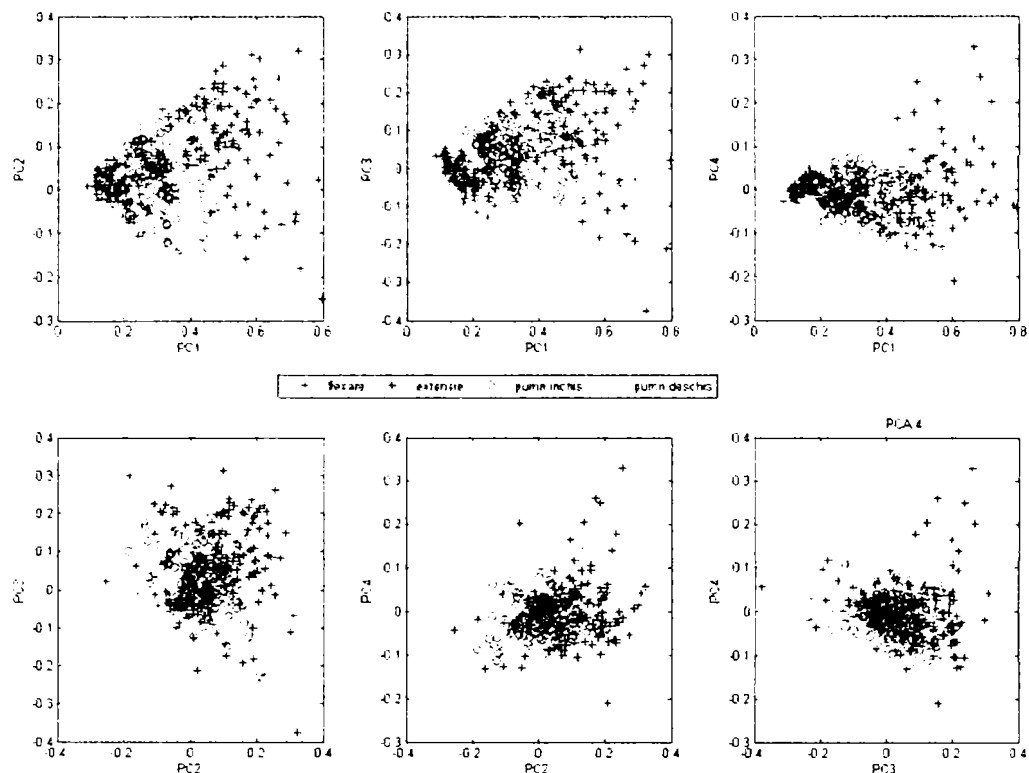


Figura 7.8 Dependența dintre primele 4 componente principale extrase din semnalul mioelectric (canalul 1).

Numărul de componente principale extrase trebuie să fie suficient de mare pentru a permite o clasificare corectă a gesturilor, dar în același timp trebuie să fie cât mai redus posibil pentru a reduce timpul de procesare. Autorul a determinat experimental numărul optim de componente principale necesar fiecărui sistem de clasificare prezentat în lucrarea de față. Pentru aceasta s-au analizat performanțele de clasificare a fiecărui sistem utilizând un număr de componente principale extrase cuprins între 1 și 10.

7.4. Modulul de clasificare

Cea mai importantă componentă a unui sistem de clasificare este evident modulul de clasificare. În [57][100] se utilizează pentru clasificare semnalului mioelectric provenit de la mușchii brațului, o rețea neuronală multiperceptron și un clasificator bayesian bazat pe analiza discriminantului liniar. În [34][29] se utilizează doar clasificarea bazată pe rețea neuronală multiperceptron pentru clasificarea semnalului mioelectric provenit de la mușchii antebrațului și de la mușchii piciorului.

Datorită faptului că soluția cea mai des utilizată pentru clasificarea semnalului mioelectric constă în utilizarea rețelelor neuronale multiperceptron, în lucrarea de față, s-a optat pentru utilizarea unei rețele neuronale feed forward antrenată cu algoritmul back propagation. Performanțele de clasificare a rețelei depind de dimensiunea rețelei și de parametrii de antrenare aleși. În cazul de față dimensiunea stratului de intrare depinde de dimensiunea vectorului de trăsături, iar dimensiunea stratului de ieșire depinde de numărul de clase pe care se face clasificarea.

Dimensiunea stratului ascuns a fost determinată experimental de către autor, astfel încât să se minimizeze eroarea de clasificare. Antrenarea rețelei neuronale și analiza performanțelor a fost realizată cu ajutorul toolbox-ului Neural Network prezent în mediul de programare Matlab.

Pentru antrenarea și testarea performanțelor rețelei neuronale utilizate pentru clasificare, datele de intrare au fost împărțite în 3 seturi: set de antrenare, set de validare, set de testare. Setul de antrenare trebuie să fie suficient de mare pentru a permite antrenarea completă a clasificatorului. Autorul a determinat, în mod empiric, că a dimensiune de 300 de vectori de antrenare este suficient pentru etapa de antrenare. Setul de testare trebuie să fie suficient de mare pentru a oferi o rezoluție bună pentru estimarea erorii de clasificare. Pentru setul de test autorul a ales o dimensiune de 150 de vectori care asigură o rezoluție de 0,67% pentru estimarea erorii de clasificare. Dimensiunea setului de validare este identică cu cea a setului de test. Setul de validare este utilizat pentru a determina criteriul de oprire a fazei de antrenare. Criteriul de oprire ales urmărește atât evoluția erorii pătratice cât și evoluția ponderilor.

În total s-a colectat un set de 600 de vectori de la fiecare persoană. Pentru fiecare postură a fost colectat un număr egal de vectori. Astfel pentru clasificare s-a colectat câte un set de 150 de vectori pentru fiecare postură a mâinii. Pentru clasificarea a patru posturi s-a utilizat câte un set de 150 de vectori pentru fiecare postură, iar pentru clasificarea a 6 posturi s-a utilizat câte un set de 100 de vectori pentru fiecare postură.

7.5. Sisteme mioelectrice de clasificare pentru poziția mâinii – 4 clase

În continuare se va prezenta structura și performanțele a două sisteme de clasificare, bazate pe analiza semnalului mioelectric înregistrat la nivelul antebrățului, capabile să clasifice 4 clase de mișcare a mâinii. Toate sistemele se bazează pe analiza în domeniul timp-frecvență a semnalului mioelectric. Diferența dintre cele două sisteme constă, în principal, în modul de selectare a vectorului de trăsături. Performanțele sistemelor sunt analizate pentru cazurile în care semnalul mioelectric este achiziționat pe 4 sau 2 canale de achiziție.

Se dorește clasificare a 4 clase de mișcare și anume flexarea-extensia încheieturii mâinii respectiv închiderea și deschiderea pumnului. În figura 7.19 sunt prezentate posturile mâinii corespunzătoare claselor de mișcare. Anterior s-a arătat că pentru clasificare acestor mișcări sunt suficiente achiziționarea a două semnale mioelectrice de la doi mioelectrozi amplasați deasupra mușchiului flexor radial al carpalului respectiv extensor radial al carpalului. Evident că prin analiza semnalului mioelectric provenit de la acești mușchi se poate identifica mișcarea de flexare-extensie a încheieturii mâinii. Deoarece în imediata vecinătate a acestor mușchi se află și grupele musculare răspunzătoare pentru mișcarea de închidere și deschidere a pumnului va fi posibilă și identificarea acestor mișcări. Se va arăta că performanțele de clasificare pot fi îmbunătățite prin utilizarea a doi electrozi suplimentari situați deasupra mușchilor flexor ulnar al carpalului respectiv extensor ulnar al carpalului.



Figura 7.9 Posturile mâini pentru flexare-extensie încheietură, deschidere-închidere pumn.

Performanțele de clasificare vor fi evaluate prin compararea erorilor medii pătratice de clasificare. Datele de intrare ale sistemelor provin de la 4 persoane diferite. Analiza comparativă se face utilizând media erorilor medii pătratice provenite în urma clasificării semnalelor mioelectrice achiziționate de la cele 4 persoane.

Primul sistem obține vectorul de trăsături în urma extragerii componentelor principale ale vectorului de trăsături obținut în urma analizei wavelet a semnalului mioelectric. Principiul acestui sistem a fost utilizat și de alți cercetători [57][58][34] pentru clasificare semnalului mioelectric provenit de la alte grupe musculare. Al doilea sistem este un sistem propus de autor pentru îmbunătățirea performanțelor de clasificare ale primului sistem. Sistemul utilizează, pe lângă modulul de extragere a componentelor principale, un modul de extragere a componentelor independente. Pentru analiza celui de-al doilea sistem s-au utilizat trei algoritmi diferiți de extragere a componentelor independente.

7.5.1. Sistem de clasificare cu două canale EMG bazat pe PCA

Acest sistem de clasificare se bazează pe extragerea componentelor principale din vectorul de trăsături obținut în urma descompunerii wavelet a semnalului mioelectric provenit de la doi electrozi mioelectrici. Structura bloc a sistemului este prezentată în figura 7.10.




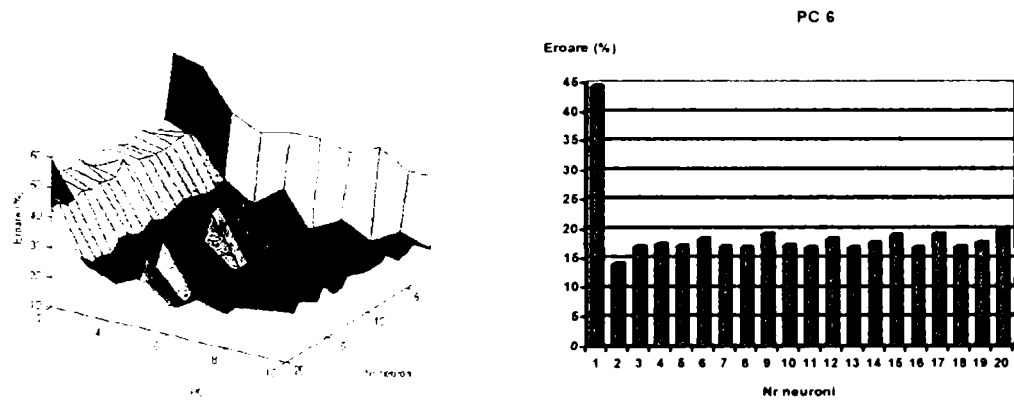
Figura 7.10 Structura bloc a sistemului de clasificare cu 2 canale EMG

Semnalul mioelectric provenit de la fiecare mioelectrod este supus descompunerii wavelet folosind 3 funcții wavelet diferite. Pentru fiecare caz, din vectorul de trăsături provenit de la fiecare canal de măsură, sunt extrase un număr de componente principale și este antrenat clasificatorul. Clasificatorul constă într-o rețea neuronală FF-BP. Dimensiunea optimă stratului ascuns este determinată în parte pentru fiecare număr de componente principale extrase. Algoritmul de lucru poate fi sumarizat astfel:

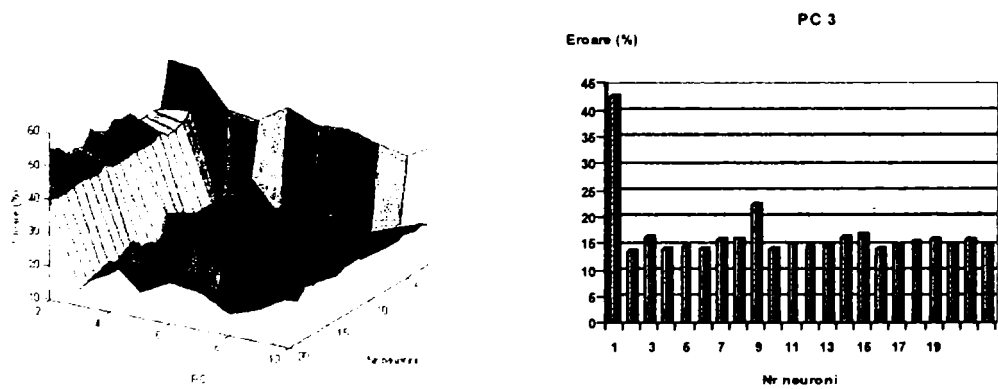
1. Alegerea funcției wavelet
2. Descompunerea wavelet a semnalului mioelectric – determinarea coeficienților wavelet
3. Extragerea primelor N componente principale

4. Determinarea performanțelor de clasificare utilizând M neuroni în stratul ascuns
5. Reluarea pasului 4 pentru $M = 1 \div 20$
6. Reluarea pașilor 2,3,4 pentru $N = 1 \div 10$
7. Reluare pașilor 1÷6 pentru 3 funcții wavelet: db6,sym9,coif3


În continuare sunt prezentate rezultatele obținute pentru fiecare caz în parte. În cazul descompunerii semnalului cu ajutorul funcțiilor wavelet db6 și coif3, cele mai bune performanțe se obțin în cazul utilizării a 6 componente principale, iar în cazul utilizării funcției sym9 cele mai bune performanțe se obțin în cazul utilizării doar a 3 componente principale. În figura 7.11 este prezentată evoluția erorii de clasificare în funcție de numărul de componente principale extrase și în funcție de numărul de neuroni ascunși prezenți în structura clasificatorului.



a. Descompunere db6



b. Descompunere sym9



c. Descompunere coif3

Figura 7.11 Performanțele de clasificare pentru clasificare a 4 posturi utilizând 2 canale

În figura 7.12 sunt prezentate cele mai bune rezultate obținute pentru fiecare tip de descompunere. Cea mai bună performanță, cu o eroare de 13,4%, a fost obținută în cazul utilizării funcției sym9. Pentru descompunerea prin intermediul funcției db6 s-a obținut, în cel mai bun caz, o eroare de 13,9%, iar pentru descompunerea prin intermediul funcției coif3 s-a obținut o eroare de 16,6%. De fiecare dată, cele mai bune rezultate au fost obținute în cazul utilizării unui număr mic de neuroni în stratul ascuns.




Figura 7.12 Numărul optim de componente principale extrase pentru diferite funcțiile wavelet utilizate pentru clasificare a 4 posturi utilizând 2 canale

7.5.2. Sistem de clasificare cu două canale EMG bazat pe PCA-ICA

Sistemul de clasificare prezentat anterior se bazează pe extragerea componentelor principale din vectorul de trăsături. Prin aceasta se obține o transformare a spațiului vectorului de trăsături într-un nou spațiu care evidențiază direcțiile de variație maximă a variabilelor vectorului de trăsături. Prin utilizarea algoritmului de extragere a componentelor principale se poate obține un nou vector

ale cărui componente sunt cât mai independente posibil. Astfel, vectorul format are un grad mai mare de discriminare între variabilele sale, ușurând operația de clasificare.

Datorită faptului că mușchii ale căror activitate este urmărită sunt inervați de 4 nervi diferiți, autorul propune extragerea a 4 componente independente. Pentru analiza componentelor independente, semnalul trebuie preprocesat astfel încât să se obțină un set de date albe. Acest lucru se poate obține prin aplicarea analizei PCA. Din semnalul mioelectric achiziționat sunt extrasi coeficienții wavelet, care pe urmă sunt supuși analizei PCA, extrăgându-se astfel un număr de 4 componente principale. Datele obținute reprezintă datele de intrare pentru modulul ICA. Cele 4 componente independente extrase de pe fiecare canal de achiziție vor fi prezentate unei rețele neuronale FF-BB pentru a fi clasificate. Structura bloc a acestui sistem de clasificare este prezentată în figura 7.13.




Figura 7.13 Structura bloc a sistemului de clasificare PCA-ICA cu 2 canale EMG

Pentru antrenarea rețelei neuronale responsabilă cu extragerea componentelor independente, autorul a folosit doi algoritmi diferiți, și anume algoritmul INFOMAX respectiv algoritmul EASI, algoritmi ce au fost prezentați de autor în capitolul 6. Pentru antrenarea rețelei neuronale conform algoritmului INFOMAX, ponderile rețelei vor fi modificate conform ecuației (6.67). Performanțele rețelei și convergența algoritmului de antrenare depind de modul de alegere a ratei de învățare și a funcțiilor de activare utilizate. Experimental, autorul a demonstrat că în cazul aplicației de față, pentru modificarea ponderilor rețelei, cea mai bună soluție este dată de ecuația:

$$B(n+1) = B(n) + 0,005 \cdot \left(I - 2 \tanh[y(n)] e^{-[y^T(n)]^2} \right) B(n) \quad (7.1)$$

În cazul utilizării algoritmului EASI pentru antrenarea rețelei neuronale responsabilă cu extragerea componentelor independente, ecuația de modificare a ponderilor este dată de relația (6.68). În urma rezultatelor obținute, autorul a dedus empiric, ecuația de modificare a ponderilor pentru aplicația prezentată în această teză:

$$B(n+1) = B(n) - 0,019 \left[y(n)y^T(n) - I + \tanh[y(n)] \left[y^T(n) \right] - [y(n)] \tanh \left[y^T(n) \right] \right] B(n) \quad (7.2)$$

În figura 7.14 sunt prezentate dependențele dintre primele componente principale și primele componente independente. Se poate observa existența unui grad mai mare de independență și evidențierea mai clară în norul de date a datelor corespunzătoare unei anumite acțiuni.

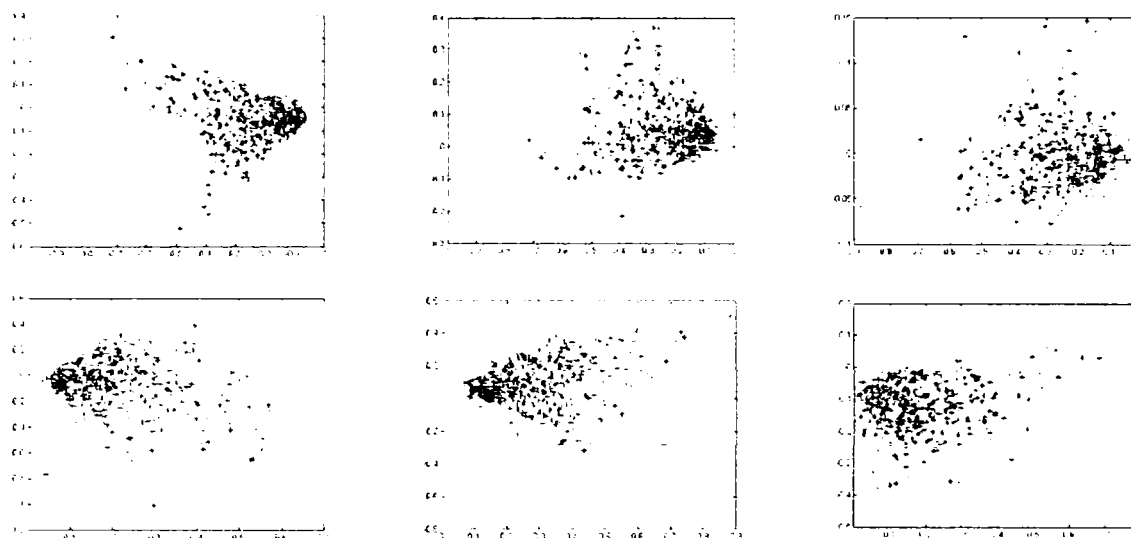


Figura 7.14 Dependența dintre prima componentă principală și următoarele 3 comparativ cu dependența dintre prima componentă independentă și următoarele 3 componente independente pentru canalul 1.

Pentru analiza performanțelor de clasificare a acestui sistem, autorul a analizat comportarea sistemului pentru date obținute în urma descompunerii wavelet folosind funcțiile wavelet db6, sym9, coif3, și a determinat experimental, pentru fiecare caz, numărul optim de neuroni ai stratului ascuns al rețelei neuronale utilizate pentru clasificare. Algoritmii de testare poate fi sumarizat astfel:

1. Alegerea funcției wavelet
2. Descompunerea wavelet a semnalului mioelectric – determinarea coeficienților wavelet
3. Extragerea a primelor 4 componente principale
4. Extragerea a 4 componente independente
5. Determinarea performanțelor de clasificare utilizând M neuroni în stratul ascuns
6. Reluarea pasului 5 pentru $M = 1 \div 10$
7. Reluarea pașilor 4,5,6 pentru algoritmul INFOMAX respectiv EASI
8. Reluare pașilor 1÷7 pentru 3 funcții wavelet: db6,sym9,coif3

În cazul utilizării algoritmului INFOMAX, performanțele de clasificare ale sistemului sau îmbunătățit cu aproximativ 5% față de sistemul care utilizează doar extragerea componentelor principale. Cele mai bune rezultate au fost obținute în cazul utilizării unei rețele neuronale FF-BP cu 4 neuroni în stratul ascuns. Rezultate obținute sunt prezentate grafic în figura 7.15




Figura 7.15 Performanțele de clasificare în cazul ICA cu antrenare bazată pe algoritmul INFOMAX

În figura 7.16 sunt prezentate grafic, performanțele de clasificare pentru cazul în care rețeaua neuronală pentru extragerea componentelor independente este antrenată conform algoritmului EASI. În acest caz, performanțele de clasificare se îmbunătățesc cu aproximativ 4%, dar numărul de neuroni al stratului ascuns depinde de funcția wavelet folosită pentru descompunere.




Figura 7.16 Performanțele de clasificare în cazul ICA cu antrenare bazată pe algoritmul EASI

7.5.3. Sistem de clasificare cu patru canale EMG

Performanțele de clasificare pot fi crescute prin utilizarea unui număr mai diversificat de tipare. Pentru acest caz, autorul a testat performanțele de clasificare în cazul în care semnalul mioelectric este achiziționat prin intermediul a 4 canale. În figura 7.17 este prezentată structura bloc a acestui sistem.


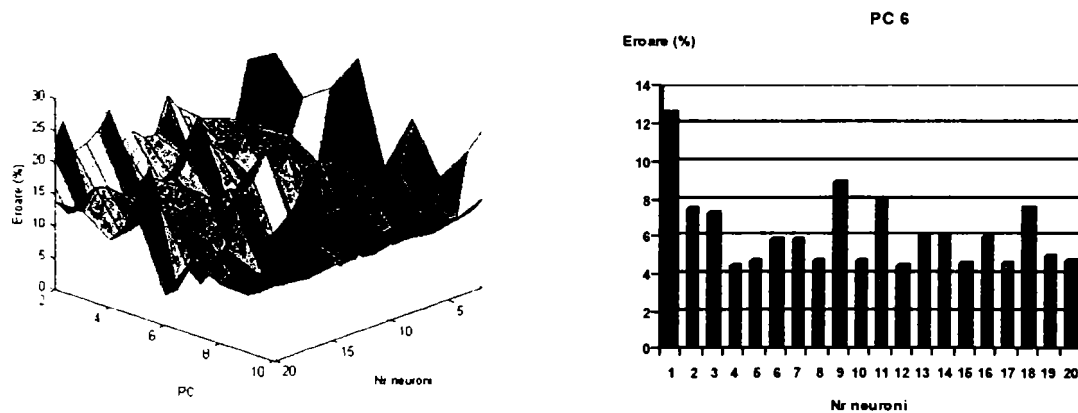


Figura 7.17 Structura bloc a sistemului de clasificare cu 4 canale EMG

După cum era de așteptat s-a obținut o îmbunătățire a performanțelor de clasificare. Algoritmii de lucru este același ca și în cazul anterior. În figura 7.18 sunt prezentate grafic rezultatele obținute. De această dată, numărul optim al componentelor principale este de 6 pentru descompunerea prin intermediul funcției db6, 8 pentru descompunerea prin intermediul funcției sym9, respectiv 10 pentru descompunerea prin intermediul funcției coif3. După cum se poate observa, numărul optim de componente principale diferă pentru fiecare caz în funcție de funcția wavelet aleasă pentru descompunere. Nu s-au făcut teste care să dovedească dacă acest număr depinde și de alți factori cum ar fi condițiile de temperatură și umiditate din camera în care s-au efectuat testele, sau de condițiile de contact dintre senzori și piele, etc. Singura metodă viabilă de a determina numărul optim de componente principale rămâne metoda empirică.



a. Descompunere db6

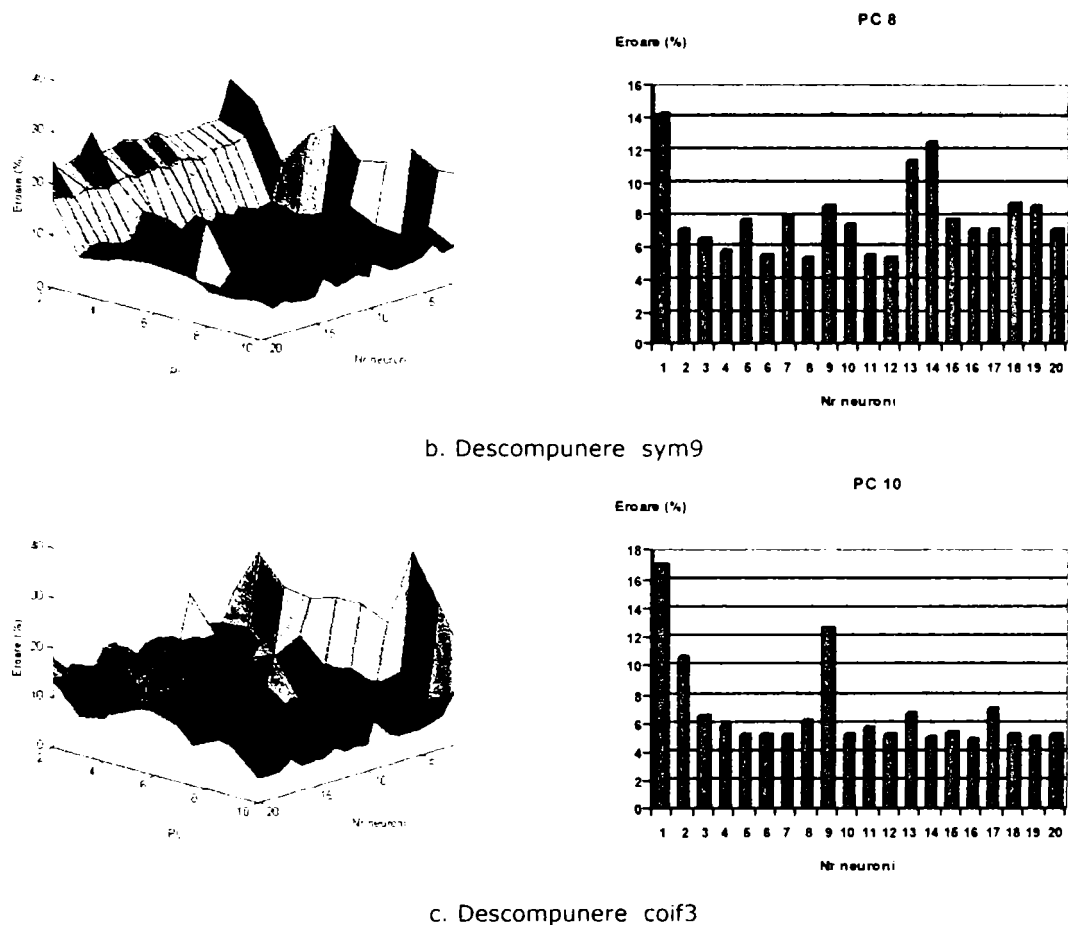


Figura 7.18 Performanțele de clasificare pentru clasificare a 4 posturi utilizând 4 canale

În figura 7.19 sunt prezentate cele mai bune rezultate obținute pentru fiecare tip de descompunere. Cea mai bună performanță, cu o eroare de 4,4%, a fost obținută în cazul utilizării funcției db6. Pentru descompunerea prin intermediul funcției sym9 s-a obținut, în cel mai bun caz, o eroare de 5,3%, iar pentru descompunerea prin intermediul funcției coif3 s-a obținut o eroare de 5,1%. Cazurile cele mai favorabile sunt obținute în cazul utilizării unui număr mai mare de neuroni în stratul ascuns. Utilizarea unui număr mai mic de neuroni în stratul ascuns este o concluzie îmbucurătoare a acestui test deoarece aceasta oferă o relaxare a consumului de resurse în cadrul unei implementări hardware a aceste metode. Pe lângă faptul că în cazul utilizării funcției db6 s-a obținut cel mai bun rezultat, restul rezultatelor obținute pentru această funcție au o evoluție stabilă, fără fluctuații majore.





Figura 7.19 Numărul optim de componente principale extrase pentru diferite funcțiile wavelet utilizate pentru clasificare a 4 posturi utilizând 4 canale

În figura 7.20 sunt prezentate performanțele de clasificare obținute în urma utilizării unui sistem de clasificare bazat pe combinația PCA-ICA. Și de această dată se obține o îmbunătățire a performanțelor de clasificare de aproximativ 2%. Analizând cele patru cazuri prezentate se poate spune că, din punct de vedere al erori de clasificare, cea mai bună soluție ar fi utilizarea descompunerii wavelet prin intermediul funcției sym9. Dar din punct de vedere al puterii de calcul necesar putem afirma că cea mai convenabilă soluție este utilizarea descompunerii wavelet prin intermediul funcției db6. În cazul utilizării modulului de extragerea a componentelor independente cresc performanțele de clasificare ale sistemului, dar totodată crește și tipul de procesare necesar. În cazul sistemului de clasificare cu două canale EMG, datorită faptului că performanțele de clasificare cresc în medie cu 5%, putem afirma că se justifică utilizarea unui sistem de clasificare bazat pe analiza PCA-ICA.






Figura 7.20 Performanțele de clasificare în cazul ICA cu antrenare bazată pe algoritmilor INFOMAX și EASI

7.6. Sistem mioelectric de clasificare pentru poziția mâinii – 6 clase

În cazul în care pentru achiziția semnalului mioelectric se utilizează un sistem de achiziție pe 4 canale pot fi clasificate un număr mai mare de posturi ale mâinii. Utilizând algoritmi de analiză prezentați anterior, autorul a analizat performanțele unui sistem care să permită clasificare a 6 posturi ale mâinii. Posturile mâinii ce se doresc a fi clasificate sunt prezentate în figura 7.21.



Figura 7.21 Posturile mâini pentru deschidere-închidere pumn, flexare-extensie încheietură, deviere ulnară-radială încheietură.

Prin utilizarea unui sistem de clasificare bazat pe analiza componentelor independente, autorul a obținut performanțe de clasificare ridicate, eroare medie de clasificare fiind în cele mai bune cazuri de aproximativ 2%. Prin utilizarea unui sistem de clasificare bazat pe analiza PCA-ICA nu s-a obținut o îmbunătățire considerabilă a performanțelor de clasificare, astfel, datorită timpului de procesare mai mare necesar în acest caz, autorul a concluzionat că utilizarea unui astfel de sistem nu se justifică în acest caz.

În figurile 7.22, 7.23 sunt prezentate performanțele de clasificare obținute în cazul utilizării unui sistem de clasificare bazat pe analiza componentelor principale. Și de această dată cele mai bune rezultate au fost obținute în cazul în care descompunerea în coeficienți wavelet a fost realizată utilizând funcția sym9. În opinia autorului, creșterea performanțelor de clasificare se datorează diversificării setului de date de intrare, astfel că, în urma analizei componentelor principale, se obține un set de date care reflectă mai bine variația datelor prezente la intrare.

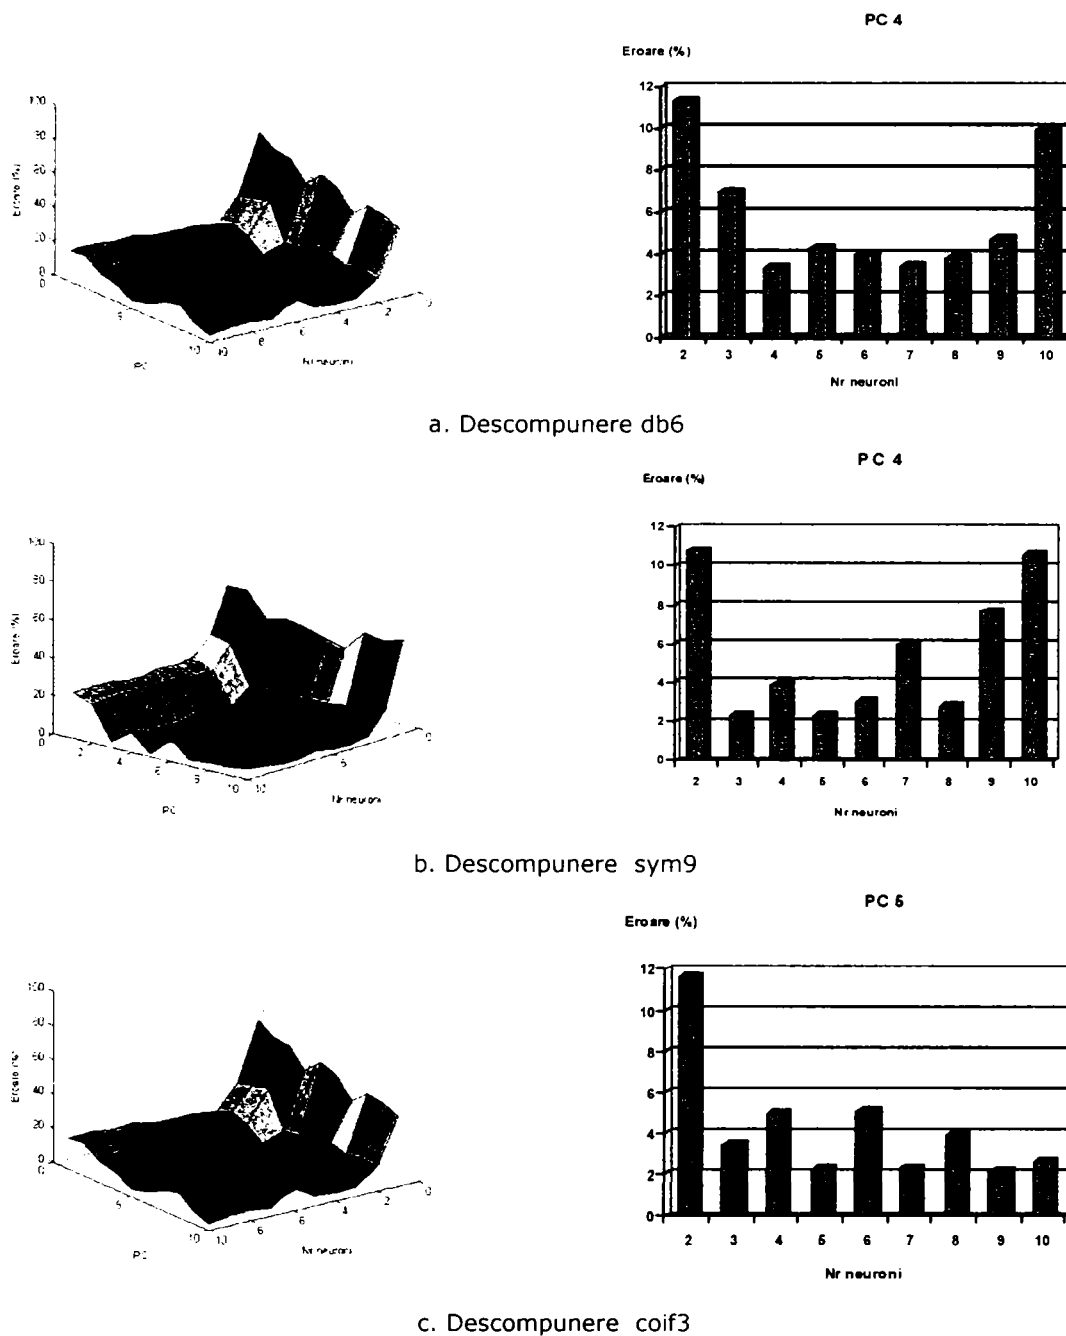


Figura 7.22 Performanțele de clasificare pentru clasificare a 6 posturi utilizând 4 canale

Cele mai bune performanțe de clasificare au fost obținute în cazul în care, prin analiza componentelor principale, au fost extrase un număr de 4 componente principale. O excepție de la această regulă se observă în cazul descompunerii wavelet prin intermediul funcției *coif3*, caz în care cele mai bune performanțe au fost obținute prin utilizarea a 5 componente principale. Erorile de clasificare obținute sunt de aproximativ 2%.




Figura 7.23 Numărul optim de componente principale extrase pentru diferite funcții wavelet utilizate pentru clasificare a 6 posturi

Pe lângă performanțele de clasificare, o problemă majoră a sistemelor de clasificare a semnalului EMG este legată de timpul de procesare. Acest parametru este foarte important în cazul în care se dorește realizarea unui modul de control EMG al unui sistem protetic. În literatură se afirmă că în cazul sistemelor protetice trebuie să se asigure un timp de procesare de maxim 400ms. Această limitare se răsfrânge și asupra mărimii ferestrei de analiză utilizată pentru achiziționarea semnalului EMG. În cazul experimentelor prezentate, autorul a utilizat o fereastră de analiză ce cuprinde un număr de 256 de eșantioane. Având în vedere faptul că semnalul EMG a fost eșantionat cu o frecvență de 1024Hz, mărimea în timp a ferestrei de analiză este de 250ms, rămânând astfel 150ms pentru procesarea propriu-zisă a semnalului. Prin reducerea dimensiunii ferestrei de analiză se permite utilizarea unui interval de timp mai mare pentru procesare. Întrebarea care se ridică este legată de modul de variație a performanțelor de clasificare în cazul utilizării unei ferestrei de analiză de dimensiuni mai reduse. În figura 7.30 se prezintă modul de variație a performanțelor de clasificare în raport cu dimensiunea ferestrei de analiză, pentru sistemul prezentat anterior. Se observă o variație mare a performanțelor de clasificare în cazul în care se utilizează sistemul de clasificare antrenat cu vectori de trăsături obținuți prin utilizarea unei ferestrei de analiză de 250ms. În cazul în care se utilizează aceeași dimensiune a ferestrei de analiză atât pentru faza de antrenare cât și pentru faza de testare, performanțele de clasificare a sistemului au o variație mult mai mică. În ambele cazuri se poate observa că prin utilizarea unei ferestrei de 125ms performanțele de clasificare nu au o variație considerabilă (8% în cazul sistemului antrenat cu 256 eșantioane, 1% în cazul sistemului antrenat cu 128 eșantioane). În concluzie se poate afirma că prin utilizarea unei ferestrei de analiză de 128 eșantioane se poate obține o dublare a timpului de procesare în schimbul unei scăderi cu 2% a performanțelor de clasificare.




Figura 7.24 Numărul optim de componente principale extrase pentru diferite funcții wavelet utilizate pentru clasificare a 6 posturi

În general, sistemele de clasificare a semnalului EMG prezentate în literatură au fost antrenate și testate folosind semnal EMG achiziționat la momente diferite de timp, în care subiectul realizează o anumită acțiune. Se pune problema comportării unui astfel de sistem în cazul achiziționării semnalului EMG în mod continuu. Principala problemă care apare în acest caz este legată de perioada de tranziție dintre două acțiuni diferite realizate de subiect.




Figura 7.25 Rezultatele obținute în urma analizei continue a semnalului EMG

Folosind semnalele EMG achiziționate, autorul a realizat un nou semnal care cuprinde câte 4 seturi de posturi complementare achiziționate în mod continuu. În

figura 7.25 este prezentată comportarea sistemului pentru analiza continuă a semnalului EMG folosind un pas de incrementare de 250ms. Se poate observa că sistemul are o comportare foarte bună, excepție făcând momentele de tranziție.

În figura 7.26 sunt prezentate rezultatele obținute în urma clasificării în mod continuu a semnalului EMG utilizând pași de incrementare diferiți. Un pas de incrementare se referă la intervalul de timp cu care este deplasată fereastra de analiză de-a lungul semnalului analizat. Se observă că rezultatele obținute sunt mai bune în cazul utilizării unui pas de 125ms. Măriminimă a pasului de incrementare este limitată de timpul necesar sistemului pentru a oferi un răspuns. Performanțele obținute pot fi cuantificate doar dacă se stabilește un criteriu pentru clasificarea semnalului achiziționat în momentele tranzitorii. În funcție de momentul în care apare o tranziție în fereastra de analiză trebuie să se ia o decizie legată de clasa din care face parte semnalul analizat. În cazul de față ar trebui să se decidă dacă semnalul analizat este datorat realizării unei posturi sau corespunde unui interval de repaus. Datorită faptului că este dificil a se stabili un astfel de criteriu, autorul sugerează că ar fi indicat realizarea unui modul care să detecteze ferestrele ce conțin astfel de tranziții și etichetarea lor ca și cazuri de nedeterminare.

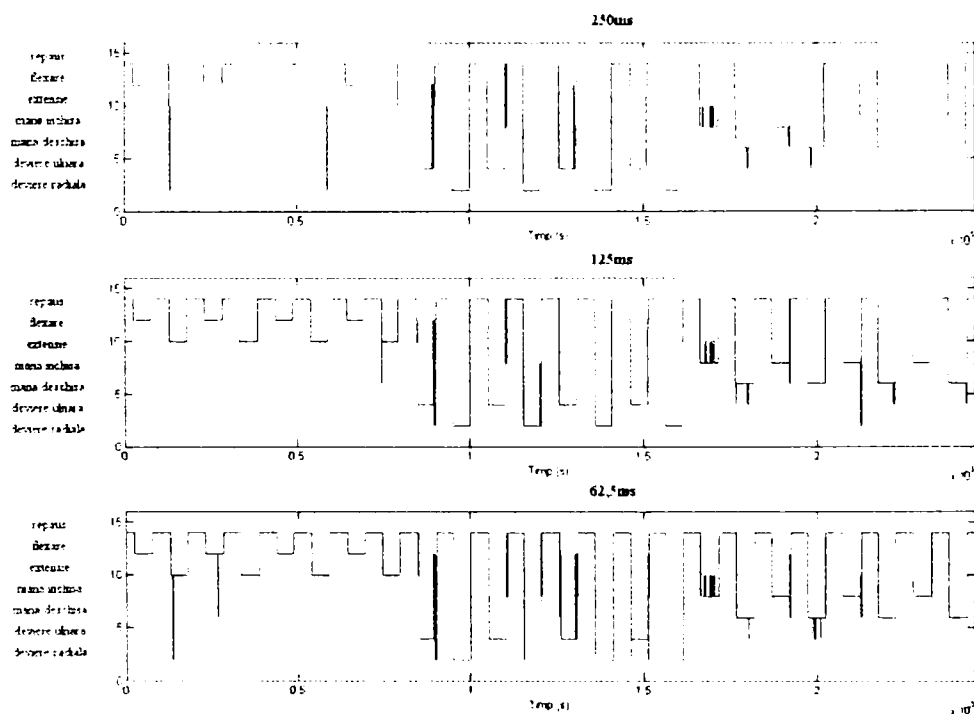


Figura 7.26 Rezultatele obținute în urma analizei continue a semnalului EMG folosind pași de incrementare diferiți

7.7. Implementarea FPGA a sistemelor de clasificare a semnalului EMG

Toate rezultatele prezentate în acest capitol au fost obținute în urma analizei semnalului EMG cu ajutorul modulelor MATLAB dezvoltate de autor. Pentru a putea estima timpul real de procesare a soluțiilor propuse este necesară implementarea hardware a acestora. În capitolele anterioare, autorul a propus diferite soluții de implementare FPGA a modulelor ce intră în componența sistemelor de clasificare prezentate. Utilizând aceste soluții, autorul a reușit să implementeze în FPGA sistemele de clasificare prezentate anterior. În tabelul 7.1 sunt prezentate resursele hardware necesare pentru implementarea sistemelor de clasificare bazate pe analiza semnalului EMG achiziționat pe 4 canale. În tabel se prezintă gradul de ocupare a resurselor în cazul implementării într-un circuit FPGA VIRTEX4 XC4VLX200. Resursele consumate în cazul sistemului de clasificare a 6 posturi sunt mai reduse deoarece rețeaua neuronală utilizată pentru clasificare are un număr mai mic de neuroni.

Tabelul 7.1 Estimarea consumului de resurse pentru implementarea în circuitul XC4VLX200

Resurse	PCA-4	%	PCA-ICA-4	%	PCA-6	%
Slice-uri	76780	86.18	87260	97.95	65710	73.76
FFs	154180	86.53	165220	92.73	133800	75.09
Block RAM	70	20.83	86	25.6	68	20.24
LUT	115100	64.6	170348	95.61	108174	60.71
Multiplatoare	70	72.92	86	89.58	68	70.83

Sistemul de clasificare a 6 posturi ale mâinii poate fi implementat și într-un circuit FPGA VIRTEX4 XC4VLX160, al cărui preț de piață este cu 50% mai mic decât cel al circuitului VIRTEX4 XC4VLX200. Și sistemele de clasificare a 4 posturi ar putea fi implementate în circuitul FPGA VIRTEX4 XC4VLX160 în cazul în care se optează pentru implementarea unei rețele neuronale de dimensiuni mai mici, caz în care se vor diminua ușor performanțele de clasificare. În tabelul 7.2 este prezentat gradul de ocupare al resurselor în cazul implementării sistemului de clasificare a 6 posturi în diferite circuite FPGA.

Vectorul de trăsături utilizat este alcătuit din coeficienții wavelet extrași în urma descompunerii wavelet pe 5 nivele a semnalului EMG. În cazul utilizării a unui semnal de clock de 20MHz (respectiv 180MHz pentru modulul de descompunere wavelet), timpii de procesare pentru aceste implementări sunt de aproximativ 165ms. Acești timpi, cât și consumul de resurse pot fi îmbunătățiți prin utilizarea unui vector de trăsături mai mic, obținut prin eliminarea coeficienților de detaliu obținuți din primul nivel de descompunere. Performanțele de clasificare sunt apropiate de cele din cazul anterior datorită faptului că informația utilă conținută de acești coeficienți este afectată de zgomot. În urma eliminării acestor coeficienți, timpii de procesare scad la valori de aproximativ 120ms.

Tabelul 7.2 Estimarea consumului de resurse pentru implementarea sistemului PCA6 în diferite circuite FPGA din familia Virtex4

Resurse	PCA-6	XC4VLX200 %	XC4VLX160 %	XC4VLX100 %
Slice-uri	65710	73.76	97.23	133.69
FFs	133800	75.09	98.99	136.11
Block RAM	68	20.24	23.61	28.33
LUT	108174	60.71	80.03	110.04
Multiplatoare	68	70.83	70.83	70.83

În cazul în care dimensiunea ferestrei de analiză este de 128 eşantioane se obțin timpi de procesare mult mai mici în detrimentul scăderii performanțelor de clasificare cu aproximativ 2%. Din punct de vedere al implementării hardware a sistemului de clasificare este indicată realizarea acestui compromis, dar efectele secundare pot fi evaluate doar prin experimentarea sistemului în condiții de lucru reale, adică prin includerea lui într-un sistem protetic și evaluarea performanțelor sale în cazul unui număr mai mare de subiecți.

7.8. Concluzii

În cadrul acestui capitol autorul a prezentat două soluții, bazate pe rețele neuronale, pentru realizarea unui sistem de clasificare a semnalului mioelectric al membrului superior. Performanțele de clasificare ale soluțiilor prezentate sunt analizate pentru 3 cazuri diferite de operare, și anume: pentru clasificarea a 4 posturi ale mâinii în cazul achiziției semnalului mioelectric pe 2 sau 4 canale și pentru cazul clasificării a 6 posturi ale mâinii în cazul achiziției semnalului mioelectric pe 4 canale. Diferența dintre cele două soluții constă în modul de extragere a vectorului de trăsături. Prima soluție utilizează ca și trăsături componentele principale extrase din coeficienții obținuți în urma analizei wavelet a semnalului mioelectric. Cea de-a doua soluție este de fapt o îmbunătățire a primului caz, prin aplicarea analizei componentelor independente. În ambele cazuri clasificarea se face utilizând o rețea neuronală de tip feed-forward, iar modulele pentru analiza PCA, respectiv ICA sunt implementate cu ajutorul unor rețele neuronale liniare.

Pentru sistemul de clasificare a 6 posturi ale mâinii, autorul a realizat o analiză a performanțelor sistemului în cazul utilizării unor ferestre de analiză de dimensiuni diferite. De asemenea, autorul a analizat performanțele acestui sistem în cazul achiziționării semnalului EMG în mod continuu. S-a arătat că prin utilizarea unui pas de incrementare de 125ms se pot obține rezultate foarte bune pentru clasificarea continuă a semnalului EMG. În cele din urmă, autorul a estimat resursele hardware necesare implementării sistemului în circuite FPGA. Conform analizei rezultatelor obținute autorul a concluzionat că acest sistem poate fi implementat în circuitele FPGA VIRTEX4 XC4VLX200 și XC4VLX160. Datorită prețului mare a acestor circuite și datorită fondurilor reduse de care a dispus autorul, nu a fost posibilă implementare fizică și testarea postimplementare a soluțiilor propuse.




Figura 7.27 Performanțele de clasificare a sistemelor propuse

Este foarte greu de comparat performanțele sistemelor propuse de autor cu alte sisteme deoarece majoritatea cercetărilor au fost concentrate pe analiza semnalului mioelectric achiziționat la nivelul brațului. În [100][101], Hudgins propune un sistem de recunoaștere a tiparelor pentru analiza semnalului mioelectric al brațului. Vectorul de trăsături este format dintr-un set de parametri extrasi în urma analizei în domeniul timp a semnalului mioelectric. Clasificatorul folosit constă într-o rețea neuronală feed-forward iar performanțele de clasificare sunt relativ scăzute (eroare de 20%). În [57][58][59], Englehart propune o soluție de clasificare bazată pe analiza în domeniul frecvență-timp a semnalului mioelectric al brațului. Analizează performanțele de clasificare utilizând achiziția semnalului mioelectric pe 2 respectiv 4 canale. Concluzionează că cea mai bună soluție este bazată pe analiza semnalului mioelectric folosind pachete de funcții wavelet. În [34], Chu, Moon și Kim realizează un sistem de control pentru un braț de robot utilizând un modul de comandă mioelectric. Modulul de comandă este bazat pe un sistem de recunoaștere a tiparelor în care vectorul de trăsături constă în coeficienții wavelet ai semnalului mioelectric. Pentru a reduce dimensionalitatea vectorului de trăsături, autorii propun o soluție bazată pe o combinație dintre analiza componentelor independente (PCA) și hărți cu autoorganizare (SOM). Implementarea hardware se face utilizând procesoare de semnal digitale. În figura 7.28 se prezintă o comparație între soluțiile amintite și soluțiile propuse de autor. Se poate observa că soluțiile propuse de autor au performanțe mai bune, doar în cazul analizei semnalului mioelectric achiziționat pe 4

canale diferențele sunt relativ mici, în comparație cu soluția propusă de Chu. Soluțiile propuse de autor și Chu se diferențiază de celelalte și prin faptul că acestea propun și o soluție de implementarea hardware. Totuși, trebuie avut în vedere faptul că pentru a realiza o comparație corectă sistemele trebuie supuse unui set de teste identice. Acest lucru nu a fost posibil, deci comparație trebuie luată în considerare doar cu scop informativ.

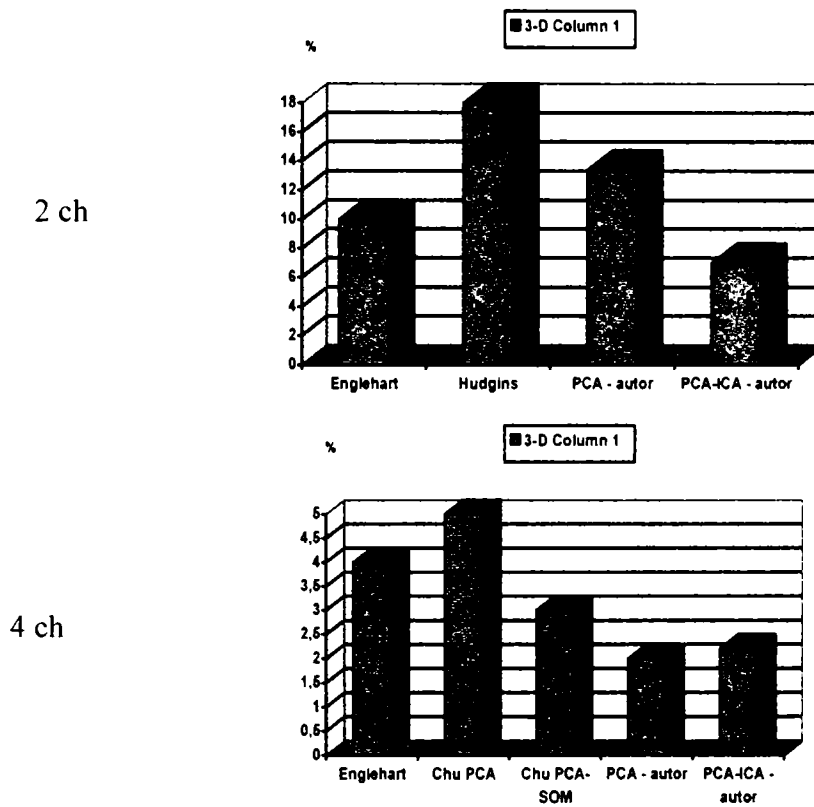


Figura 7.28 Comparație între performanțele de clasificare a sistemelor propuse și sisteme de clasificare dezvoltate de alți autori

Performanțele ridicate de clasificare obținute în cazul sistemului de clasificare a 6 posturi indică faptul că realizarea unui sistem de clasificare bazat pe analiza în domeniul timp-frecvență a semnalului mioelectric poate fi o soluție viabilă pentru realizarea unui modul de control a unui sistem protetic multifuncțional. Un astfel de sistem ar putea cu ușurință selecta modul de acționare a unei mâini protetice și ar permite executarea a 3 mișcări distincte. Viteza de acționare a dispozitivului terminal ar putea fi controlată prin metodele clasice, proporțional cu intensitatea contracției musculare. Performanțele reale ale unui astfel de sistem pot fi determinate doar pe baza unui studiu realizat pe un număr suficient de mare de subiecți. O altă aplicație a acestui sistem de clasificare ar putea fi în robotică, unde acest sistem ar putea constitui modulul de control a unui braț artificial destinat realizării unor activități într-un mediu izolat. Sistemul ar putea fi îmbunătățit astfel încât să poată controla și acționarea independentă a degetelor. În acest caz ar fi necesară achiziționarea unui număr mai mare de semnale EMG, o soluție fiind utilizarea unei matrice de mioelectrozi de suprafață.

8 CONCLUZII ȘI CONTRIBUȚII

Subiectul abordat în lucrarea de față este cel al sistemelor protetice cu comandă mioelectrică. Sistemele protetice comerciale cu comandă mioelectrică utilizează module de comandă bazate pe estimarea amplitudinii semnalului mioelectric. Deși există o diversitate de soluții protetice, majoritatea sunt capabile să ofere doar 2 grade de libertate, datorită utilizării unor metode simple de procesare a semnalului mioelectric. În lucrarea de față, autorul studiază modalități noi de analiză a semnalului mioelectric cu scopul de a realiza un modul de comandă pentru un sistem protetic capabil de a replica mișcările mâinii umane. În cele din urmă, autorul propune un sistem de comandă bazat pe analiza în domeniul frecvență timp a semnalului mioelectric, implementabil cu ajutorul circuitelor logice programabile FPGA. Sistemul propus este capabil să identifice 6 posturi ale mâinii, cu o precizie de clasificare de 98%, analizând semnalul mioelectric achiziționat la nivelul antebrățului. Un astfel de sistem ar putea fi utilizat ca și modul de comandă pentru un sistem protetic destinat persoanelor cu handicap, care prezintă o amputare a membrului superior până la nivelul antebrățului. Autorul propune mai multe soluții de implementarea hardware pentru diferite module ale sistemului, soluția finală aleasă de autor asigurând un timp de răspuns a sistemului de 370 ms. Timpul de răspuns poate fi îmbunătățit prin alegerea unei ferestre de analiză mai redusă, prin alegerea unei alte funcții wavelet sau prin alegerea unei alte soluții de implementare dintre soluțiile de implementare propuse de autor. Trebuie avut în vedere faptul că fiecare sistem protetic este dimensionat pentru fiecare pacient în parte în funcție de gradul de amputare și de calitatea semnalului mioelectric achiziționat. Având în vedere faptul că un sistem protetic trebuie să asigure un timp de răspuns mai mic de 400ms, soluția propusă de autor ar putea fi utilizată cu succes în cadrul unui sistem protetic.

8.1. Concluzii structurate pe capitole

În capitolul 1 s-a realizat o documentare aprofundată, bazată pe un număr consistent de referințe bibliografice, cu privire la natura semnalului mioelectric. Au fost prezentate noțiuni referitoare la structura sistemului muscular și anatomia mușchilor membrului superior. De asemenea au fost prezentate fenomenele fizice și chimice ce stau la baza producerii contracției musculare. Contracția musculară este rezultatul unor procese chimice ce apar în fibra musculară în momentul în care este escitată de un impuls nervos. Un nerv inervează mai multe fibre musculare, totalitatea acestora formând o unitate motorie. Activarea unei unități motorii produce contracția tuturor fibrelor musculare aferente și astfel unitatea motorie reprezintă unitatea funcțională cea mai mică pe care sistemul nervos o mai poate comanda separat. Suma activității electrice create de toate unitățile motorii activate reprezintă semnalul mioelectric. Sistemul nervos reglează intensitatea contracției musculare prin creșterea numărului de unități motorii activate sau prin creșterea frecvenței de activare. În ambele cazuri, efectele se reflectă în semnalului mioelectric ce poate fi achiziționat prin intermediul unor electrozi de suprafață. Prin procesarea acestui semnal putem afla informații referitoare la starea de contracție a mușchilor aflați în apropierea punctului de măsură.

În capitolul 2 s-a realizat un studiu cu privire la modalitățile de achiziționare a semnalului mioelectric. Semnalul mioelectric poate fi achiziționat prin două metode: prima metodă este o metodă invazivă și presupune utilizarea unor electrozi de tip ac, iar cea de a doua metodă este o metodă neinvazivă ce presupune utilizarea unor electrozi de suprafață. Calitatea semnalului mioelectric achiziționat prin intermediul electrozilor de tip ac este net superioară dar necesită supravegherea procesului de achiziție de către personal medical autorizat. Achiziționare semnalului mioelectric cu ajutorul electrozilor de suprafață nu necesită condiții speciale dar nu poate realiza achiziția semnalului generat de o singură unitate motoare. Semnalul mioelectric de suprafață este constituit din suma ponderată a activității unităților motoare învecinate aflate în aria acoperită de electrod. Semnalul achiziționat prin această metodă este puternic influențat de o serie de factori perturbatori. Autorul prezintă o serie de modalități de reducere a efectelor datorate factorilor perturbatori. Se arată că cea mai bună metodă de achiziție a semnalului mioelectric de suprafață constă în utilizare mioelectrozilor activi, un tip de electrozi ce au incorporat în structura lor un modul de amplificare diferențială. Se prezintă o soluție hardware și software pentru un sistem de achiziționare a semnalului mioelectric. Componenta software a fost dezvoltată de autor utilizând mediul grafic de programare LabView. Cu ajutorul acestui sistem au fost achiziționate toate semnalele mioelectrice utilizate în cadrul acestei teze de doctorat.

În capitolul 3 se prezintă o analiză a metodelor de procesare a semnalului mioelectric utilizate în sistemele protetice actuale precum și o analiză a unor metode experimentale de procesare. De asemenea sunt prezentate și sistemele protetice comerciale existente la ora actuală. Deși există o serie de soluții noi pentru comanda mioelectrică a sistemelor protetice, sistemele protetice actuale folosesc variațiuni ale unei soluții dezvoltată în perioada 1950-1960. Această soluție presupune redresarea semnalului mioelectric achiziționat și compararea amplitudinii cu un nivel prag. Prin utilizarea soluțiilor bazate pe estimarea amplitudinii semnalului mioelectric pot fi controlate sisteme protetice ce pot realiza un număr de 2-3 acțiuni. În general acțiunile ce pot fi realizate sunt antagoniste. O variație a acestei metode presupune o metodă de codare în frecvență pentru selectare unei perechi de acțiuni antagoniste, urmată de controlul acțiunilor prin metoda estimării amplitudinii. În anii 80-90 au fost dezvoltate metode ce permit acționarea sistemelor protetice cu o viteză proporțională cu intensitatea semnalului mioelectric. Metodele de control ale acestor sisteme protetice nu sunt naturale, aceste metode presupun ca utilizatorul să învețe de la zero metoda de control. În ultimii 15 ani au fost dezvoltate o serie de metode experimentale ce propun metode naturale de control. Aceste metode constau în analiza semnalului mioelectric și identificare operației de mișcare ca și cum s-ar fi realizat în cazul în care utilizatorul nu ar avea membrul respectiv amputat. Au fost obținute rezultate notabile, dar datorită faptului că aceste soluții nu se reflectă și în sistemele protetice comerciale sugerează faptul că performanțele obținute nu sunt suficient de ridicate.

Semnalul mioelectric este un semnal nestaționar. Pentru analiza semnalelor nestaționare este indicată utilizarea reprezentării semnalelor în domeniul timp-frecvență. În capitolul 4 este prezentată o analiză a metodelor de reprezentare a semnalelor în domeniul timp-frecvență. Una dintre metodele de reprezentare a unui semnal în domeniul timp-frecvență o reprezintă transformata wavelet a semnalului. Prin utilizarea transformatei wavelet se caută, în general, reprezentarea eficientă a unui semnal, în termenii unor componente de bază, cu caracterizare simplă, cu caracteristici de localizare timp-frecvență bune. De asemenea se prezintă metoda de

analiză wavelet a semnalelor prin tehnica de codare în subbandă. În a doua parte a capitolului, autorul prezintă soluții pentru implementarea hardware a unui modul de analiză wavelet. Este prezentată o analiză comparativă a soluțiilor din punct de vedere a resurselor consumate și a timpului necesar pentru procesare. Soluțiile prezentate au fost realizate și testate de autor cu ajutorul circuitelor programabile FPGA.

Sistemele experimentale de procesare a semnalului mioelectric bazate pe rețele neuronale artificiale au obținut cele mai notabile rezultate. În prima parte a capitolului 5 este prezentată o sinteză cu privire la rețelele neuronale artificiale. Este prezentat conceptul de neuron artificial, diverse structuri de rețele neuronale și diverși algoritmi de învățare. În cea de a doua parte, autorul prezintă o analiză a modalităților de implementare hardware a rețelelor neuronale artificiale. Soluțiile cele mai flexibile de implementare constau în implementarea digitală a rețelelor neuronale cu ajutorul procesoarelor de semnal și cu ajutorul circuitelor programabile FPGA. În continuare, autorul prezintă soluții proprii de implementare optimă a rețelelor neuronale artificiale în circuite FPGA. Autorul prezintă atât soluții de implementare a rețelelor neuronale cu învățare offline cât și o soluție pentru implementarea unei rețele neuronale cu învățare online. Deși, în cele mai multe cazuri, resursele consumate și puterea de calcul necesară nu justifică implementarea online a algoritmului de învățare, rețelele neuronale cu învățare online pot fi o soluție pentru sistemele de procesare ce necesită o adaptare a parametrilor în funcție de anumite condiții. Printre ele se numără și sistemele de procesare a semnalului mioelectric bazate pe rețele neuronale, ale căror performanțe scad odată cu apariția oboselii musculare.

În capitolul 6 se prezintă un studiu asupra sistemelor de recunoaștere a tiparelor. În prima parte a capitolului sunt prezentate noțiuni generale legate de sisteme de recunoaștere a tiparelor. Unul dintre modurile cele mai utile de implementare a modului de clasificare, în cazul în care nu se cunosc probabilitățile apriorice de apartenență a datelor de intrare la o anumită clasă, constă în utilizarea rețelelor neuronale artificiale. Performanțele sistemelor de recunoaștere a tiparelor depinde atât de clasificatorul ales cât și de modul de extragere a trăsăturilor. Datele supuse spre clasificare trebuie să conțină suficiente informații pentru a putea asigura o bună precizie a clasificării, dar totodată trebuie să fie condensate pentru a evita un timp de calcul exagerat în momentul luării deciziei. În cazul în care vectorul de trăsături, extras din datele de intrare, are o dimensiune prea mare este necesară utilizarea unei metode de reducere a dimensionalității. O metodă de reducere a dimensiunii spațiului vectorului de trăsături constă în analiza componentelor independente. Analiza componentei principale reprezintă o tehnică statistică de reducere a numărului de variabile din setul de date supus analizei fără pierdere de informație și, de asemenea, ca un proces de identificare de noi variabile cu semnificație mai importantă. Autorul prezintă diverși algoritmi de extragere a componentelor principale printre care se numără și soluții bazate pe rețele neuronale artificiale. Analiza componentelor principale este o metodă de interpretare a momentelor statistice de ordinul doi din datele supuse analizei, prin rotirea axelor de coordonate în direcția maximizării covarianței dintre variabile. Analiza componentelor independente este o generalizare a analizei componentelor principale care ia în considerare și dependențele neliniare dintre datele de intrare. Autorul prezintă o sinteză referitoare la analiza componentelor independente, diferite modalități de determinare a gradului de independență, precum și diverși algoritmi utilizați pentru extragerea componentelor independente. Modulele de extragere a componentelor

independente pot fi implementate cu ajutorul rețelelor neuronale liniare a căror etapă de antrenare se face utilizând funcții neliniare.

În capitolul 7, autorul prezintă două soluții proprii, bazate pe rețele neuronale, pentru realizarea unui sistem de clasificare a semnalului mioelectric al membrului superior. Performanțele de clasificare ale soluțiilor prezentate sunt analizate pentru 3 cazuri diferite de operare, și anume: pentru clasificarea a 4 posturi ale mâinii în cazul achiziției semnalului mioelectric pe 2 sau 4 canale și pentru cazul clasificării a 6 posturi ale mâinii în cazul achiziției semnalului mioelectric pe 4 canale. Diferența dintre cele două soluții constă în modul de extragere a vectorului de trăsături. Prima soluție utilizează ca și trăsături componentele principale extrase din coeficienții obținuți în urma analizei wavelet a semnalului mioelectric. Cea de-a doua soluție este de fapt o îmbunătățire a primului caz, prin aplicarea analizei componentelor independente. În ambele cazuri clasificarea se face utilizând o rețea neuronală de tip feed-forward, iar modulele pentru analiza PCA, respectiv ICA sunt implementate cu ajutorul unor rețele neuronale liniare. Analiza este făcută, realizând descompunerea wavelet a semnalului de intrare cu ajutorul a 3 funcții diferite. Funcțiile au fost alese, din familii diferite, astfel încât să se minimizeze eroare de reconstrucție a semnalului analizat. Se arată că în cazul clasificării a 4 posturi ale mâinii, soluția bazată pe analiza PCA-ICA prezintă cele mai bune performanțe de clasificare. În cazul clasificării a 6 posturi, se arată că cea mai optimă soluție este cea bazată pe analiza PCA. Îmbunătățirile aduse de soluția bazată pe analiza PCA-ICA nu sunt notabile în acest caz, și nu se justifică astfel consumul suplimentar de resurse și creșterea timpului de procesare pe care le implică utilizarea acestei soluții. Pentru sistemul de clasificare a 6 posturi ale mâinii, autorul a realizat o analiză a performanțelor sistemului în cazul utilizării unor ferestre de analiză de dimensiuni diferite. De asemenea, autorul a analizat performanțele acestui sistem în cazul achiziționării semnalului EMG în mod continuu. S-a arătat că prin utilizarea unui pas de incrementare de 125ms se pot obține rezultate foarte bune pentru clasificarea continuă a semnalului EMG.

8.2. Contribuții personale ale autorului

În opinia autorului, prezenta teză aduce contribuții, în principal, cu privire la următoarele aspecte:

- Sistematizarea informațiilor legate de sistemele protetice actuale cu comandă mioelectrică. Prezentare și analizarea soluțiilor existente pentru modulul de control al sistemelor protetice. Pe baza acestui studiu se scot în evidență avantajele și dezavantajele sistemelor protetice cu control mioelectric și prezintă soluții alternative de realizare a modulelor de control.
- Realizarea unui studiu comparativ al posibilităților de implementare a rețelelor neuronale artificiale. Rezultatele studiului conduc la concluzia că varianta de implementare hibridă, hardware-software, este mai eficientă deoarece combină avantajul flexibilității implementării software a fazei de antrenare, cu cea de viteză, portabilitate și consum mic de putere specifice implementării hardware a fazei de propagare

- Propunerea unor soluții hardware pentru implementarea unei rețele neuronale artificiale cu învățare onchip. Deși acest mod de implementare implică un consum mai ridicat de resurse, putere și timp de procesare, poate constitui o soluție viabilă pentru sistemele ce necesită o adaptare a parametrilor și care nu au un acces permanent la unități de procesare externe pentru realizarea offline a procesului de învățare sau recalibrare.
- Realizarea unui studiu aprofundat privind modalitățile de implementare a modulelor de analiză wavelet în circuite programabile FPGA. Studiul scoate în evidență principalele probleme ce trebuie urmărite în cazul unor asemenea implementări și scoate în evidență câteva criterii pentru evaluarea performanțelor implementărilor realizate.
- Propunerea unei soluții pentru realizarea unui sistem de clasificare a semnalului mioelectric, bazat pe analiza wavelet și analiza componentelor principale. Implementarea soluției propuse prin utilizarea rețelelor neuronale artificiale. Evaluarea performanțelor de clasificare pentru diferite funcții wavelet utilizate în procesul de descompunere wavelet a semnalului. Determinarea experimentală a numărului optim de componente principale necesare pentru o funcționare optimă a sistemului de clasificare.
- Propunerea unei soluții de îmbunătățire a performanțelor sistemului de clasificare prin utilizarea analizei componentelor independente. Determinarea empirică a ecuațiilor optime pentru antrenarea unei rețele neuronale destinate analizei componentelor independente a semnalului mioelectric cu scopul de a îmbunătăți performanțele de clasificare ale sistemului propus.
- Analizare performanțelor de clasificare a soluțiilor propuse pentru clasificare semnalului mioelectric în 4 respectiv 6 clase utilizând module de achiziție a semnalului mioelectric pe 2 sau 4 canale.
- Analiza performanțelor de clasificare în raport cu mărimea ferestrei de analiză a semnalului mioelectric. Analiza comportării sistemului de clasificare în cazul achiziției în mod continuu a semnalului mioelectric
- Propunerea utilizării criteriului erorii medii pătratice de reconstrucție ca și măsură obiectivă de evaluare a funcțiilor wavelet optime pentru analiza semnalului mioelectric al membrului superior.
- Conceperea și realizare unui modul hardware pentru achiziția pe 4 canale a semnalului mioelectric de suprafață. Sistemul a fost utilizat pentru achiziționarea semnalului mioelectric provenit de la mușchii antebrațului, semnal care a constituit datele de intrare ale sistemelor de clasificare prezentate în această lucrare.

- Conceperea și realizarea programului de achiziție de date cu ajutorul mediului de programare LabView, astfel încât achiziția de date să permită prelucrarea și vizualizarea în timp real a datelor măsurate și a mărimilor derivate din acestea care interesează din punct de vedere al achiziției de date.

Lista completă a referințelor bibliografice consultate

- [1] Akin T., Najafi K., - A Micromachined Silicon Sieve Electrode for Nerve Regeneration Applications. IEEE, 1991
- [2] Alder Michael, - An introduction to pattern recognition, HeavenForBooks.com, 2001
- [3] Alemu M., Kumar D., Bradley A., - Time-frequency analysis of SEMG with special consideration to the interelectrode spacing, IEEE Transaction on Neural Systems and Rehabilitation Engineering, vol. 11, nr. 4, p 341-345, 2003
- [4] Ali A.H., - Neural network principal component using adaptive principal component extractor, International Symposium on Computational Intelligence for measurement systems and applications, p 101-106, Switzerland, 2003
- [5] Almeida, P., Franca, E., - Digitally programmable analog building blocks for the implementation of artificial neural networks, IEEE Transaction on neural networks, Vol. 7, no. 2, 1996
- [6] Amari S., Cichocki A., Yang H., - A new learning algorithm for blind source separation, Advances in Neural Information Processing Systems, vol. 8, 1996
- [7] Amari S., Cichocki A., Yang H., - Recurent neural networks for blind separation of sources, Interantional Symposium on Nonlinear Theory and Applications, p 37-42, 1995
- [8] Andrade A., Nasuto S., Kyberd P., - The application of the hilbert spectrum to the analysis of electromyographic signals, Information Sciences, Elsevier Science Ltd., p 2176-2193, 2007
- [9] Andrade A., Nasuto S., Kyberd P., Van Kanijn F.R., - EMG signal filtering on empirical mode decomposition, Biomedical Signal Processing and Control, Elsevier Science Ltd., p 44-55, 2006
- [10] Andraka R., Berkun A., - FPGAs make a radar signal processor on a chip a reality, IEEE Proceedings of Asilomar Conference on Signals, Systems and Computers, Monterey , 1999
- [11] Baladi P.F, Hornik K., - Learning in neural networks: A survey, IEEE Transaction on Neural Networks, vol. 6, nr. 4, p 837-858, 1995
- [12] Balestra, G., Frassinelli, S., Knaflitz, M., Molinari, F., - Time-frequency analysis of surface myoelectric signals during athletic movement. IEEE Eng Med Biol Mag 20: 106-115, 2001.
- [13] Bell A.J., Sejnowski T.J., - An information maximization approach to blind separation and blind deconvolution, , Neural Computing , p1129-1159, 1995
- [14] Bernatzki, A., Eppler, W., Gemmeke, H., - Interpretation of Neural Networks for Classification Tasks. Proceedings of EUFIT 1996, Aachen, Germany, 2005
- [15] Bishop, C.M., - Neural networks for pattern recognition. New York Oxford University Press, 1996.

- [16] Bogdan M., A. Babanine, J. Kaniecki, W. Rosenstiel - Nerve signal processing using artificial neural nets, *Information Processing in Cells and Tissues*, Liverpool, 1995.
- [17] Bogdan M., Babanine A., Kaniecki J., Rosenstiel W., - Nerve Signal Processing using Artificial Neural Nets. *Information Processing in Cells and Tissues*, Liverpool, Seiten 55–68, 1995.
- [18] Bonato, P., Cheng, M.S., Gonzalez-Cueto, J., Leardini, A., O'Connor, J., Roy, S.H., - EMG-based measures of fatigue during a repetitive squat exercise. *IEEE Eng Med Biol Mag* 20: 133–143, 2001.
- [19] Bonato, P., Roy, S.H., Knaflitz, M., DeLuca, C.J., - Time-frequency parameters of the surface myoelectric signal for assessing muscle fatigue during cyclic dynamic contractions. *IEEE Trans Biomed Eng* 48: 745–753, 2001.
- [20] Burrus C. S., Gopinath R. A., - *Introduction to Wavelets and Wavelet Transforms*, Prentice Hall Inc., Upper Saddle River, New Jersey, 1998.
- [21] Cardoso J., Belouchrani A., Lahed B., - A new composite criterion for adaptive and iterative blind source separation, *Proceedings of ICASSP*, vol. 4, p 273-276, 1994
- [22] Cardoso J., Lahed B., - Equivariant adaptive source separation. , *IEEE Transaction on Signal Processing*, vol 44, p3017-3030, 1996
- [23] Carrozza M., Dario P., Lazzarini R., Massa B., Zecca M., Roccella S., Sacchetti R. - An actuating system for a novel biomechatronic hand, *Proc. of the 7th Intl Conf on New Actuators, Actuator 2000*, Bremen, Germany, June 19–20 2000.
- [24] Carrozza M., Massa B., Dario P., Lazzarini R., Zecca M., Micera S., Pastacaldi P. - A two DOF finger for a biomechatronic artificial hand, *Technol Health Care* 2002.
- [25] Carrozza M., Micera S., Massa B., Zecca M., Lazzarini R., Canelli N., Dario P. - The development of a novel biomechatronic hand ongoing research and preliminary results, *Advanced Intelligent Mechatronics AIM 2001*, Como, Italy, July 8–11 2001.
- [26] Ceanga E., Munteanu I., Bratcu A., Culea M., - *Semnale circuite și sisteme*, Ed Academica, Galati, 2001
- [27] Cesar Torres-Huitzil, - Real-time Image Processing with a Compact FPGA-based systolic Architecture, *Journal on Real-Time Imaging*, Elsevier, Vol. 10, pp. 177-187, 2004.
- [28] Ciocoiu I.B., - *Rețele neuronale artificiale*, Editura Cantes, Iasi, 2001, ISBN 973-8173-16-7
- [29] Chan A., Englehart K.,- Continuous myoelectric control for powered prostheses using hidden markov models, *IEEE Transactions on Biomedical Engineering*, vol. 52, nr. 1, 2005
- [30] Chen W., Wang Z., Ren X., - Characterization of surface EMG signals using improved approximate entropy, *Journal of Zhejiang University*, p 844-848, 2006
- [31] Childress D.S, Weir R.F. - Quantitative assessment of direct muscle attachment to act as a control input for externally powered prostheses, *Proc. 8th World Cong Intl Soc Prosthetics Orthotics*, Melbourne, Australia, April 2–7 1995.
- [32] Chiou Y.H., Luh J., Chen S., Lai J., Kuo T., - The comparison of electromyographic pattern classifications with active and passive electrodes,

- Journal of Medical Engineering and Physics, Elsevier Science Ltd., p 605-610, 2004
- [33] Chitroub S., - PCA-ICA neural network model for polsar images analysis, IEEE ICASSP, p 757 - 760, 2004
- [34] Chu J., Moon I., Kim S., - Control of multifunction myoelectric hand using a real time EMG pattern recognition, , IEEE Transactions on Biomedical Engineering, vol. 47, nr. 3, 2005
- [35] Cichocki A., Amar S., - Adaptive blind signal and image processing, John Wiley & Sons, 2002
- [36] Clancy E.A., Bertolina M., Merletti R., Farina D., - Time and frequency domain monitoring of the myoelectric signal during a long duration, cyclic, force-varying, fatiguing hand-grip task, Journal of Electromyography and Kinesiology, Elsevier Science Ltd., p 315-324, 2007
- [37] Clancy E.A., Farina D., Merletti R., - Cross-comparison of time and frequency domain methods for monitoring the myoelectric signal during a cyclic, force-varying, fatiguing hand-grip task, Journal of Electromyography and Kinesiology, Elsevier Science Ltd., p 256-265, 2005
- [38] Cohen A., Kovacevic J., - Wavelets: The mathematical background, Proceedings of IEEE, vol 84, nr 4, p 514-521, 1996
- [39] Cohen, L., - Time-frequency distributions Review. Proc IEEE 1989;77(7):941-81.
- [40] Conforto S., D'Alessio T., Pignatelli S., - Optimal rejection of movement artefacts from myoelectric signals by means of a wavelet filtering procedure, Journal of Electromyography and Kinesiology, Elsevier Science Ltd., p 47-57, 1999
- [41] Cover T.M., Thomas J.A., - Elements of information theory, Wiley, 1991
- [42] Craelius W., Abboudi R.L., Newby N.A. - Control of a multifinger prosthetic hand, ICORR'99: Int Conf Rehab Rob, Stanford University, Stanford, California, July 1-2 1999.
- [43] Cupo M.E, Sheredos S.J. - Clinical evaluation of a new, above elbow, body powered prosthetic arm: a final report, J Rehab Res Dev 1998.
- [44] Dario P., Cocco M. - Technologies and applications of microfabricated implantable neural prostheses, IARP Workshop on Micromachine & Systems 1993, Tokyo, 1993.
- [45] Daubechies I, - Orthonormal bases of compactly supported wavelets, SIAM, vol 24, p 499-519, 1993
- [46] Daubechies I, - Ten lectures on wavelets, SIAM, Philadelphia 1992
- [47] DeLuca C, - Muscle alive: Their functions revealed by electromyography, Williams & Wilkins, 1985
- [48] DeLuca C.J., - Surface electromyography: detection and recording, 1996.
- [49] Demuth H.- Neural Network Toolbox, User's Guide, <http://www.mathworks.com>.
- [50] Derde, M.P., Massart, D.L., - Supervised pattern recognition: the ideal method Analytical Chimica Acta, 1986, 191, 1-16.
- [51] Devroye L., Lugosi G., - A probabilistic theory of pattern recognition, Springer, New York, 1996
- [52] Disselhorst, C., Silny, J., Rau, G., - Improvement of spatial resolution in surface-EMG: a theoretical and experimental comparison of different spatial filters. IEEE Trans Biomed Eng 44: 567-574, 1997.
- [53] Doshi R., Yeh C., LeBlanc M., - The design and development of a gloveless endoskeletal prosthetic hand, J. Rehab. Res. Dev. 35, 1998.

- [54] Draghici, S., - On the capabilities of neural networks using limited precision weights. *Neural Networks*, 2002. 15: pp. 395-414.
- [55] Duda R.O., Hart P.E., Stork D.G., - *Pattern classification*, John Wiley & Sons, 2002
- [56] Edell D. J., - A Peripheral Nerve Information Transducer for Amputees: Long-Term Multichannel Recordings from Rabbit Peripheral Nerves. *IEEE Transactions on Biomedical Engineering*, Vol. BME-33, No. 2, pp. 203 - 213, 1986.
- [57] Englehart K., Hudgins B.,- A robust, real-time control scheme for multifunction myoelectric control, *IEEE Transactions on Biomedical Engineering*, vol. 50, nr. 7, 2003
- [58] Englehart K., Hudgins B., Parker P.,- A wavelet based continuous classification scheme for multifunction myoelectric control, *IEEE Transactions on Biomedical Engineering*, vol. 48, nr. 3, 2001
- [59] Englehart, K., Hudgins, B., Parker, P.A., Stevenson, M., - A dynamic feedforward neural network for subset classification of myoelectric signal patterns. *Proceedings of IEEE-EMBC Conference on Signal Processing*, 1995
- [60] Englehart, K., Hudgins, B., Parker, P.A., Stevenson, M., - Classification of the myoelectric signal using time-frequency based representations. *Proceedings of Medical Engineering and Physics Conference*, Iulie 1999
- [61] Englehart, K.B., Parker, P.A., - Single motor unit myoelectric signal analysis with nonstationary data. *IEEE Trans Biomed Eng* 41: 168-180, 1994.
- [62] Eriksson L., Sebelius F. - Pattern recognition of nerve signals using artificial neural networks. M.Sc. thesis, Department of Solid State Physics, Lund University, 1996.
- [63] Eriksson L., Sebelius F., Balkenius C. - Neural control of a virtual Prosthesis, *ICANN 98, Perspectives in Neural Computing*, Springer-Verlag, 1998.
- [64] Fahlman S.E.,- Faster learning variations on back propagation: An empirical study, *Proceedings of the 1988 Connectionist Models Summer School*, p38-52.
- [65] Farina, D., Merletti, R., - Comparison of algorithms for estimation of EMG variables during voluntary isometric contractions. *J Electromyogr Kinesiol* 10: 337-350, 2000.
- [66] Farina, D., Cescon, C., Merletti, R., - Influence of anatomical, physical and detection-system parameters on surface EMG. *Biol Cybern* 86: 445-456, 2002.
- [67] Farina, D., Fosci, M., Merletti, R., - Motor unit recruitment strategies investigated by surface EMG variables. *J Appl Physiol* 92: 235-247, 2002.
- [68] Farina, D., Merletti, R.R., - A novel approach for precise simulation of the EMG signal detected by surface electrodes. *IEEE Trans Biomed Eng* 48: 637-646, 2001.
- [69] Farina, D., Muhammad, W., Fortunato, E., Meste, O., Merletti, R., Rix, H., - Estimation of single motor unit conduction velocity from surface electromyogram signals detected with linear electrode arrays. *Med Biol Eng Comput* 39: 225-236, 2001.
- [70] Filligoi, G., Felici F., - Detection of hidden rhythms in surface EMG signals with a non-linear time-series tool. *Med Eng Phys* 21: 439-448, 1999.
- [71] Fiori S., Piazaa F., - A comparison of three PCA neural technique, *European Symposium on Artificial Neural Networks*, Bruges, p.275-280, 21-23 aprilie 1999

- [72] Fiori S., Uncini A., Piazza F., - A new class of APEX like PCA algoritms, Proceedings of International Symposium on Circuits and Systems, p 66-69, 1998
- [73] Folgheraiter M., Gini G. - Blackfingers an artificial hand that copies human hand in structure, size, and function, Proc. IEEE Humanoids 2000, MIT, Cambridge, Mass, September 2000.
- [74] Folgheraiter M., Gini G. - Simulation of reflex control in an anthropomorphic artificial hand, Proc. VIII ISCSB 2001 Milano, Italia, July 2001
- [75] Folgheraiter, M., Gini, G. - Human-like hierarchical reflex control for an artificial hand, Proc. IEEE Humanoids 2001, Waseda University, Tokyo, 2001.
- [76] Fukunaga, K., - Introduction to statistical pattern recognition. 2nd ed. Academic Press: San Diego, CA, 1990.
- [77] **Gavrincea C.**, Buchman A., Mic D., Oniga St., Tisan A., - Survey of FIR filter design using windowing tehnique, Buletinul Științific, Seria C, Volumul X, Fascicola Electronică, Electrotehnică, Automatizări, Simpozionul Științific Național, Baia Mare, pp. 23- 34, 2003
- [78] **Gavrincea C.**, Tisan A., - FPGA based discrete wavelet using distributed arithmetic, Carpathian Journal of Electronic and Computer Engineering, vol 1, nr 1, 2008
- [79] **Gavrincea C.**, Tisan A., - Real time EMG pattern recognition system for hand postures, Carpathian Journal of Electronic and Computer Engineering, vol 1, nr 1, 2008
- [80] **Gavrincea C.**, Tisan A., Buchman A., Oniga St., - Survey of wavelet based denoising filter design, Proceedings of the 30th International Spring Seminar on Electronics Technology, Cluj Napoca, Romania, May 9-13, 2007, ISBN 978-973-713-174-4, pag 72-74.
- [81] **Gavrincea, C.**, Tisan, A., Mic, D., - A survey of upper-limb prosthesis myoelectric control systems, International Symposium for Design and Technology of Electronic Packages, SIITME 2007, pag. 93-98, 2007
- [82] **Gavrincea, C.**, Tisan, A., Oniga, S., Buchman, A., - FPGA-based discrete wavelet transforms design using, matlab/simulink, International Symposium for Design and Technology of Electronic Packages, SIITME 2007, pag. 98-101, 2007
- [83] Gerdle, B., Henriksson-Larsen, K., Lorentzon, R., Wretling, ML., - Dependence of the mean power frequency of the electromyogram on muscle force and fibre type. Acta Physiol Scand 142: 457-465, 1991.
- [84] Girau, B., Castellanos, C., - Digital implementation of a bio-inspired neural model for motion estimation, IEEE Transaction on. neural networks,, vol. 5, 2005.
- [85] Hagan M. T. and M. Menhaj, - Training feedforward networks with the Marquardt algorithm, IEEE Transactions on Neural Networks, vol. 5, no. 6, pp. 989-993, 1994.
- [86] Hammerstrom, D. - A Digital VLSI Architecture for Real-World Applications, An Introduction to Neural and Electronic Networks. S. F. Zornetzer, J. L. Davis, C. Lau and T. McKenna, San Diego, CA, Academic Press, pp.335-358, 1995.
- [87] Hammerstrom, D. - Implementation of Neuro-Fuzzy Algorithms Using Field Programmable Gate Arrays (FPGAs). Lecture Notes, ECE Department OGI School of Science and Engineering Oregon Health and Science University.

- [88] Hammerstrom, D. - Working with neural networks. IEEE Spectrum July 1993. pp. 45-53.
- [89] Hammerstrom, D., Gao, C., Zhu, S.- FPGA Implementation of Very large Associative Memories. ECE Department OGI School of Science and Engineering Oregon Health and Science University. 2003.
- [90] Hammerstrom, D. - Neural networks at Work. IEEE Spectrum July 1993. pp. 26-32.
- [91] Han J.S., Song W.K., Kim J.S., Bang W.C., Lee H., Bien Z. - New EMG pattern recognition based on soft computing techniques and its application to control a rehabilitation robotic arm, IIZUKA 2000 Int Conf Soft Comput, Iizuka, Fukuoka, Japan, October 1-4 2000.
- [92] Hayashi, Y., "Oscillatory neural network and learning of continuously transformed patterns", Neural Networks, vol. 7, pag. 219-231, 1994
- [93] Haykin, S., Neural Networks - A Comprehensive Foundation, IEEE Press, 1994
- [94] Heemskerk, J. N. H. - Overview of neural hardware. in: Neurocomputers for Brain-Style Processing. Design, Implementation and Application. PhD thesis, Unit of Experimental and Theoretical Psychology Leiden University, The Netherlands. 1995.
- [95] Hogrel J.Y., - Clinical applications of surface electromyography in neuromuscular disorders, Journal of Neurophysiology, Elsevier Science Ltd., p 59-71, 2005
- [96] Holt, J. L., Baker, T.E., - Back propagation simulations using limited precision calculations, in Proceedings of International Joint Conference on Neural Networks. vol. 2, pp 121-126, 1991,
- [97] Hu X., Yu Q., Liu W., Qin J., - Feature extraction of surface EMG signal based on wavelet coefficient entropy, The 2nd International Conference on Bioinformatics and Biomedical Engineering, p 1758-1760, 2008
- [98] Huang Y., Englehart K., Hudgins B., - A gaussian mixture model based classification scheme for myoelectric control of powered upper limb prostheses, IEEE Transactions on Biomedical Engineering, vol. 52, nr. 11, 2005
- [99] Hudgins, B., Englehart, K., Parker, P.A., Scott, R.N., - A microprocessorbased multifunction myoelectric control system, 23rd Canadian Medical and Biological Engineering Society Conference, Toronto, Mai, 1997.
- [100] Hudgins, B., Parke, P.A., Scott, R.N.,- A new strategy for multifunction myoelectric control. IEEE Trans Biomedical Engineering 1993;40(1):82-94.
- [101] Hudgins, B.S.,- A New Approach to Multifunction Myoelectric Control, Ph.D. Dissertation, University of New Brunswick, Fredericton, N.B., Canada, 1991.
- [102] Hyvarinen A., - Independent component analysis in the presence of gaussian noise by maximizing joint likelihood, IEEE Transaction on Neural Networks, p 49-69, 1998
- [103] Hyvarinen A., - New approximations of differential entropy for independent component analysis and projection pursuit, Advances in Neural Information Processing Systems, vol. 10, p 273-279, 1998
- [104] Hyvarinen A., Oja E., - A neuron that learns to separate one independent component from a linear mixtures International Conference on Neural Networks, p 62-67, Washington, 1996
- [105] Hyvarinen A., Oja E., - Independent component analysis: Algorithms and applications, IEEE Transaction on Neural Networks, vol. 13, p 411-430, 2000

- [106] Ienne, P., Thiran, P., Vassilas, N., - Modified self organizing feature map algorithms for efficient digital hardware implementation, IEEE Transaction on neural networks, Vol. 8, no. 2, 1997
- [107] Ito K., Tsuji T., Kato A., -EMG pattern classification for a prosthetic forearm with three degrees of freedom, IEEE International Workshop on Robot and Human Communication, pag 69-74, 1992,
- [108] Jensen, C., Vasseljen, O., Westgaard, R.H., - The influence of electrode position on bipolar surface electromyogram recordings of the upper trapezius muscle. Eur J Appl Physiol 67: 266–273, 1993
- [109] Jin Liu, Brooke. M. Hirotsu, K. - A CMOS feedforward neural network chip with on chip parallel learning for oscillation cancellation, IEEE transaction on neural networks, Vol.13, no. 5, 2002
- [110] Johanson E., Radtka S., - Amplitude threshold criteria improve surface electrode specificity during walking and functional movements, Elsevier Science Ltd., p 429 - 434, 2006
- [111] Jolliffe I., - Principal component Analysis, Springer Verlag, New York, 1986
- [112] Junqueira L.C., Carneiro J., O'Kelley R., - Basic histology, McGraw-Hill, 1998
- [113] Juten C., Herault J., - Blind separation of sources: An adaptive algorithm based on neuromimetic architecture, IEEE Transaction on Signal Processing, vol. 24, p 1-10, 1991
- [114] Kampas, P., - The optimal use of myoelectrodes. Proceedings of Medical Orthopedics Tech Conference, Stuttgart, 2001
- [115] Karlsson, S., Yu J, Akay, M., - Time-frequency analysis of myoelectric signals during dynamic contractions: a comparative study. IEEE Trans Biomed Eng 47: 228–238, 2000.
- [116] Kenney L., Lisitsa I., Bowker P., Heath G., Howard D. - Dimensional change in muscle as a control signal for powered upper limb prostheses: A pilot study, Med Eng Physics 1999.
- [117] Khalid, M., Omatu, S.- A neural-network based control scheme with an adaptive neural model reference structure, Proc. IJCNN 91, Singapore, Nov. 1991
- [118] Kilby J., Hosseini G., - Wavelet analysis of surface electromyography signals, Proceedings of the 26th International Conference of the IEEE EMBS, San Francisco, p 384-387, 2004
- [119] Kilner, J.M., Baker, S.N., Lemon, R.N., - A novel algorithm to remove electrical cross-talk between surface EMG recordings and its application to the measurement of short-term synchronisation in humans. J Physiol 538: 919–930, 2002.
- [120] Kohonen, T., - An Introduction to Neural Computing, Neural Networks, vol.1, pag.3-16, 1988
- [121] Kohonen, T., Self-Organization and Associative Memory, 3rd ed., New-York: Springer-Verlag, 1988
- [122] Konrad P., - ABC of EMG – A Practical Introduction to Kinesiological Electromyography, Naraxon Inc. USA, www.naraxon.com, 2005
- [123] Kovacs G.T.A., Stormont C.W., and Rosen J.M., - Regeneration Microelectrode Array for Peripheral Nerve Recording and Stimulation. IEEE Transactions on Biomedical Engineering, Vol. 39, No. 9, 1992.
- [124] Kulkarni S.R, Lugosi G., Venkatesh S, - Learning pattern classification – a survey, IEEE Transactions on Information Theory, v. 44, nr. 6, 1998

- [125] Kung H., Diamantaras C., - A neural network learning algorithm for adaptive principal component extraction, International Conference in Acoustic Speech and Signal Processing, vol. 2, p 861-864, 1990
- [126] Kuribayashi K., Shimizu S., Okimura K., - A discrimination system using neural network for EMG controlled prostheses, Proceedings of IEEE/RSJ International Conference on Intelligent Robots and Systems, Yokoma, pag 1750-1755, 1993,
- [127] Kyberd P.J., Chappell P.H. - The Southampton hand: an intelligent myoelectric prosthesis, Journal of Rehabilitation Research and Development, 1994.
- [128] Kyberd P.J., Evans M., Winkel S. - An intelligent anthropomorphic hand, with automatic grasp, Robotica 1998.
- [129] Laheld B., Cardoso J., - Adaptive source separation with uniform performance, Proceedings of EUSIPCO, p 183-186, 1994
- [130] Leon F., - Inteligența artificială - principii, tehnici, aplicații, Tehnopress, Iasi, ISBN 978-973-702-423-7, 2006
- [131] Light C.M., Chappell P.H. - Development of lightweight and adaptable multiple-axis hand prosthesis, Medical Engineering and Physics, 2001.
- [132] Light C.M., Chappell, Englehart K., Hudgins B. - Intelligent multifunction myoelectric control of hand prostheses, Journal of Medical Engineering & Technology, Volume 4, Number 4, 2002.
- [133] Lindstrom, L., Magnusson, R., - Interpretation of myoelectric power spectra: a model and its applications. Proc IEEE 65: 653-662, 1977.
- [134] Liu Y.H., Huang H.P., Weng C.H., - Recognition of electromyographic signals using cascaded kernel learning machine, IEEE Transaction on Mechatronics, vol. 12, nr. 3, p 253-264, 2007
- [135] Lowery M., Stoykov S., Taflove A., Kuiken T., - A multiple-layer finite-element model of the surface EMG signal, IEE Transaction on Biomedical Engineering, vol. 40, nr. 5, p 446-454, 2002
- [136] Lowery, M.M., Stoykov, N.S., Kuiken T.A., - A simulation study to examine the use of cross-correlation as an estimate of surface EMG crosstalk. J Appl Physiol 94: 1324-1334, 2003.
- [137] Lugosi Gabor, - Pattern classification and learning theory, Proceedings of the 19th Annual Conference on Learning Theory, COLT 2006, Pittsburgh, PA, USA, June 22-25, 2006,
- [138] MacIsaac D., Parker P., Scott R., - The short time Fourier transform and muscle fatigue assessment in dynamic contractions, Journal of Electromyography and Kinesiology, Elsevier Science Ltd., p 439-449, 2001
- [139] Macq, D., Verleysen, M., Jesper, P., - Analog implementation of a Kohonen map with on-chip learning, IEEE transaction on neural networks, vol. 4, nr 3, 1993
- [140] Mallat S., - A theory for multiresolution signal decomposition: The wavelet representation, IEEE Transaction on Pattern Analysis and Machine Intelligence, vol 2, nr 7, p 674-693, 1989
- [141] Mallat S., - A wavelet tour of signal processing, New York, 1998
- [142] Mallat S., - Multifrequency channel decomposition, IEEE Transaction on ASSP, vol 37, nr 12, p 2091-2110, 1989
- [143] Massa B., Roccella S., Carrozza M.C., Dario P. - Design and development of an under actuated prosthetic hand, Intl Conf on Robotics and Automation (ICRA) 2002, Washington DC, May 2002.

- [144] Masud S., McCanny J.V., - Rapid design of biorthogonal wavelet transforms, IEEE Proceedings of Circuits, Devices and Systems, Volume: 147 Issue: 5, pp: 293 -296, 2000
- [145] Matsuoka K., Ohya M., Kawamoto M., - A neural net for blind separation of nonstationary signals, IEEE Transaction on Neural Networks, vol 8, p 411-419, 1995
- [146] Meier R.H., Atkins D.J. - Comprehensive Management of the Upper Limb Amputee, New York, Springer-Verlag, 1989.
- [147] Merletti R, Farina D, Granata A., - Non-invasive assessment of motor unit properties with linear electrode arrays. Electroencephalogr Clin Neurophysiol 50: 293-300, 1999.
- [148] Merletti R., Lo Conte L., - Surface EMG signal processing during isometric contractions. J Electromyogr Kinesiol 7: 241-250, 1997.
- [149] Meyer Y, - Wavelets and operators, Proceedings of Symposium of Applied Mathematics, vol. 47, 1993
- [150] Meyer Y. - Ondelettes et algorithmes cocurrents, Herman, Paris, 1993
- [151] Mic D., **Gavrincea C.**, Oniga St., Tisan A., Buchman A., - Survey of digital techniques and circuits employed in motion control, Buletinul Științific, Seria C, Volumul X, Fascicola Electronică, Electrotehnică, Automatizări, Simpozionul Științific Național, Baia Mare, , p. 39 - 44, 2003
- [152] Micera S., Sabatini A., Dario P. - On automatic identification of upper limb movements using small sized training sets of EMG signal, Med Eng Phys 2000.
- [153] Micera S., Sabatini A., Dario P., Rossi B. - A hybrid approach for EMG pattern analysis for classification of arm movements using statistical and fuzzy techniques, Med Eng Phys 1999.
- [154] Micera S., Sabatini A.M., Dario P. - An algorithm for detecting the onset of muscle contraction by EMG signals processing, Med Eng Phys 1998.
- [155] Micera S., Vannozzi G., Sabatini A.M., Dario P., - Improving detection of muscle activation intervals, IEEE Engineering in Medicine and Biology, p 38-46, 2001
- [156] Micheli-Tzanakou E. - Supervised and unsupervised pattern recognition: feature extraction and computational intelligence, Boca Raton, Florida: CRC Press, 2000.
- [157] Miguelez J.M. - Critical factors in electrically powered upper extremity prosthetics, J Proc Am Acad Orthot Prosthet Online (AAOP) 1999.
- [158] Montalvo, A. J. ,. Gyurcsik, R. S., Paulos, J. J , - Toward a general-purpose analog VLSI neural network with on-chip learning, IEEE Transaction on. neural networks, vol. 8, 1997.
- [159] Montelius L., Sebelius F., Eriksson L., Holmberg H., Schouenbourg J., Danielsen N., Wallman L., Laurell T., Balkenius C. - Pattern recognition of nerve signals using an artificial neural network, Proceedings of the 18th Annual International Conference of the IEEE Engineering in Medicine and Biology Society , 1996.
- [160] Moon, S.W., Kong, S.G, - Block based neural networks, IEEE Transaction on neural networks, Vol. 12, no 2, 2001
- [161] Moreau O., Macchi O., - New self adaptive algorithms for source separation base don contrast functions, Proceedings of IEEE Signal Processing Workshop on Higher Order Statistics, pp 215 -219, 1993
- [162] Moretti D.V., Babiloni F., Carducci F., -Computerized processing of EEG-EOG-EMG artifacts for multicentric studies in EEG oscillations and event-related

- potentials, International Journal of Psychophysiology, Elsevier Science Ltd., p 199-216, 2003
- [163] Moshou D., Hostens I., Papaioannou G., Ramon H., - Wavelets and self-organising maps in electromyogram analysis, ESIT 2000, Aachen, Germany, 14-15 September 2000
- [164] Mutihac R., Van Hulle M., - A comparative survey on adaptive neural network algorithms for independent component analysis, Romanian Reports in Physics, v. 55, p 43-67, 2003
- [165] Muzumdar A. - Powered upper limb prostheses. Control, implementation and clinical application, Springer-Verlag, 2004.
- [166] Nafornita M., Isar A., - Reprezentari timp-frecventa, Ed Politehnica Timisoara, 1998
- [167] Nagai K., Eto Y., Asai D., Yazaki M. - Development of a three-fingered robotic hand-wrist for compliant motion, Proc. Int. Conf. Intelligent Robots and Systems, 1998.
- [168] Nagata K., Adno K., Yamada M., Magatani K., - A classification method of hand movements using multi-channel electrode, Proceedings of the 2005 IEEE Engineering in Medicine and Biology 27th Conference, Shanghai, 2005
- [169] Nakamura H., Nagai K., Yoshida M., - Application of independent component analysis and expansion matching filter for automatic detection of mototr unit action potetial trains, Proceedings of the 2005 IEEE Engineering in Medicine and Biology 27th Conference, Shanghai, 2005
- [170] Nazarpour K., Sharafat A., Firoozabadi M., - A novel feature extraction scheme for myoelectric signals classification using higher order statistics, Pceedings of the 2nd International IEEE EMBS Conference on Neural Engineering, Virginia, 2005
- [171] Newcomb, R., Lohn, J., - Analog VLSI for neural networks, Bradford Books, MIT Press, 1995
- [172] Nikolay S. Stoykov, Madeleine M. Lowery, Charles J. Heckman, Allen Taflove - Recording intramuscular EMG signals using surface electrodes, Proceedings of the 2005 IEEE 9th International Conference on Rehabilitation Robotics June 28 - July 1, 2005.
- [173] Norris J., Englehart K., Lovely D., - Myoelectric signal compression using zero-trees of wavelet coefficients, Journal of Medical Engineering and Physics, Elsevier Science Ltd., p 739-746, 2003
- [174] Oja E, - A simplified neuron model as principal component analyzer, Journal of Mathematical Biology, nr. 15, p 267-273, 1982
- [175] Oniga St., Tisan A., Buchman A., Mic D., **Gavrincea C.**, - Sistemul senzorial experimental pentru o mina artificiala, Buletinul Științific, Seria C, Volumul X, Fascicola Electronică, Electrotehnică, Automatizări, Simpozionul Științific Național, Baia Mare, p 79 - 84, 2003,
- [176] Oniga St., Tisan A., **Gavrincea C.**, Mic D., - Digital implementation of Artificial Neural Networks, Symposium of Electronics and Telecommunications, - Fifth Edition - ETc 2002, Timisoara, 2002
- [177] Oniga, S., Tisan, A., Mic, D., Buchman, A., **Gavrincea, C.**, Vida, A., - Hardware implementation of simple competitive neural networks with layer parallelism, International Symposium for Design and Technology of Electronic Packages, SIITME 2007, p. 193-198, 2007
- [178] Oskoei A., Hu H., - Myoelectric control systems- a survey, Journal of Biomedical Signal Processing and Control, Elsevier Science Ltd., p 275-294, 2007

- [179] Ota, Y., Wilamowski, M. – Analog implementation of pulse coupled neural networks, IEEE Transaction on neural networks, Vol. 10, no. 3, 1999
- [180] Palmieri F., Zhu J., Chang C., - Anti-hebbian lerning in topologically constrained linear networks: A tutorial, IEEE Transaction on Neural Networks, vol.4 , nr. 5, 1993
- [181] Parker P.A., Scott R.N. – Myoelectric control of prostheses, CRC Crit Rev Biomed, 1986.
- [182] Perl J., - A neural network approach to movement pattern analysis, Human Movement Science, Elsevier Science Ltd., p 605-620, 2004
- [183] Ponca, M., Scarbata, G., - Implementation of artificial neurons using programmable hardware, SNUG Europe 2001
- [184] Popa R., - Electronica medicală, Matrixrom, București,2006
- [185] Ren X., Wang Z., Hu X., - Independent Component Analysis and wavelet decomposition technique for the detection of motor unit action potentials, Proceedings of the 2005 IEEE Engineering in Medicine and Biology 27th Conference, Shanghai, 2005
- [186] Ren X., Yan Z., Wang Z., Hu X., - Noise reduction base don ICA decomposition and wavelet transform for the extraction of motor unit action potentials, Journal of Neuroscience Methods, Elsevier Science Ltd., p 313-322, 2006
- [187] Sanger T.D., - Bayesian filtering of myoelectric signal, Journal of Neurophysiology, Rockville Pike, p 1839-1845, 2007
- [188] Sanger T.D., - Optimal unsupervised learning in a single layer neural network, IEEE Transaction on Neural Networks, vol. 2 , p 459-473, 1989
- [189] Satyanarayana, S. , Tsividis, Y. P., Graf, H. P. - A reconfigurable VLSI neural network, IEEE J. Solid-state Circuits, vol. 27, no. 1, 1992.
- [190] Schoenauer, T., Jahnke, A., Roth, - Digital Neurohardware: Principles and Perspectives. Neuronal Networks in Applications - NN'98 - Magdeburg 1998.
- [191] Schwartz,B., Howard, E. , Hubbard, E. - Programmable analog neural network chip, J. Solid-state Circuits, vol. 24, no. 2, pp. 313-319, Apr.1989.
- [192] Sears H.H., Shaperman J. - Proportional myoelectric hand control: an evaluation, American Journal of Physical Medicine and Rehabilitation, 1991.
- [193] Shaffer, R., E., Rose-Pehrsson, S., L. and McGill, R., A., - A comparison study of chemical sensor array pattern recognition algorithms, Analytica Chimica Acta, 384 (3), pp. 305-317, 1999
- [194] Singh, A. P., - Design & Implementation of Neural Hardware. University School of Information Technology, GGS Indraprastha University, Delhi http://www.geocities.com/aps_ipu/papers/synopsis.pdf, 2005
- [195] Solomonow M., Baten C., Smith J., Baratta R., Hermens H., D'Ambrosia R., and Shoji H., - Electromyogram power spectra frequencies associated with motor unit recruitment strategies. J Appl Physiol 68: 1177-1185, 1990.
- [196] Staude G., Flachenecker C., Daumer M., Wolf W. - Onset detection in surface electromyographic signals: a systematic comparison of methods, EURASIP J Appl Signal Proc 2001.
- [197] Staude G., Wolf W. - Objective motor response onset detection in surface myoelectric signals, Med Eng Phys 1999
- [198] Stoykov N., Lowery M., Kuiken T., - A finite-element analysis of the effect of muscle insulation and shielding on the surface EMG signal, IEEE Transactions on Biomedical Engineering, vol. 52, nr. 1, p 117- 121 ,2005

- [199] Stylianou A.P., Luchies C., Insana M., - EMG onset detection using the maximum likelihood method, Summer Bioengineering Conference, Florida, p 1075-1077, 2003
- [200] Tarata M., - Electronica medicală, Sitech, Craiova, 1999
- [201] Tebelskis, J.- Speech Recognition using Neural Networks, PhD Thesis, Carnegie Mellon University, 1995.
- [202] Tiponuț, V., Căleanu, C.D., - Rețele neuronale. Arhitecturi și algoritmi, Editura Politehnica, Timisoara, 2002
- [203] Tisan A., Buchman A., Oniga St., **Gavrincea C.**, - A Generic Block for Feedforward Neural Network with On-Chip Delta Rule Learning Algorithm , Proceedings of the 30th International Spring Seminar on Electronics Technology, Cluj Napoca, p 274-276, 2007
- [204] Tisan, A., **Gavrincea, C.**, Oniga, S., - A Generic Building Block for Hebbian Neural Network with On-Chip Learning, Buletin Științific al Universității Politehnica din Timișoara, Seria Electronică și Telecomunicații, p. 5-8, 2006
- [205] Tisan, A., **Gavrincea, C.**, Oniga, S., Buchman, A., - Methods for embedded systems design with on-chip learning neural networks, International Symposium for Design and Technology of Electronic Packages, SIITME 2007, p. 283-286, 2007
- [206] Tisan, A., Oniga, S., Buchman, A., **Gavrincea, C.**, - Architecture and algorithms for syntetizable neural networks with on-chip learning, International Symposium on Signals, Circuits and Systems, ISSCS 2007, p. 265-268, 2007
- [207] Tisan, A., Oniga, S., Buchman, A., **Gavrincea, C.**, - Hardware/software codesign of a pattern recognition system with on-chip learning, Regional Conference on Embedded and Ambient Systems, RCEAS 2007, Budapest, Hungary, November 25-26, 2007
- [208] Tisan, A., Oniga, S., **Gavrincea, C.**, - Hardware Implementation of Various Neural Network with On-Chip Learning, WSEAS TRANSACTIONS on SIGNAL PROCESSING, Issue 10, Volume 2, , p. 1357-1364 , 2006
- [209] Tisan, A., Oniga, S., **Gavrincea, C.**, - Hardware implementation of a MLP network with on-chip learning, Proceedings of the 5th WSEAS International Conference on DATA NETWORKS, COMMUNICATIONS & COMPUTERS, Bucharest, Romania, October 16-17, 2006
- [210] Tura A., Lamberti C., Davalli A., Sacchetti R. - Experimental development of a sensory control system for an upper limb myoelectric prosthesis with cosmetic covering, Journal of Rehabilitation Research and Development, 1998.
- [211] Valeans C, - A really friendly guide to wavelets, Valens, 1999
- [212] Van Ooyen A., Nienhuis B., - Improving the convergence of the back propagation algorithm, Neural Networks, vol. 5, 1992, p465-472.
- [213] Vinet R., Lozac'h Y., Beaundry N., Drouin G., - Design methodology for a multifunctional hand prosthesis, J. Rehab. Res. Dev. 32, 1995.
- [214] Waly M., Asfour S., Khalil T., - Effects of window size and load on estimated myoelectric signal power spectrum, Journal of Computers and Industrial Engineering, Elsevier Science Ltd., p 595-610, 2003
- [215] Wang S.Y., Liu X., Yianni J., Aziz T., Stein J., - Extracting burst and tonic components from surface electromyograms in dystonia using adaptive wavelet shrinkage, Journal of Neuroscience Methods, Elsevier Science Ltd., p 177-184, 2004

- [216] Weingessel A., Hornik K., - SVD algorithms: APEX like versus subspace methods, IEEE Transaction on Neural Networks, vol. 5, p 177-184, 1997
- [217] Wilamowski B. M. - Neuro-Fuzzy Systems and its applications, 24th IEEE International Industrial Electronics Conference - IECON'98 August 31 - September 4, 1998
- [218] Wilamowski B. M. and R. C. Jaeger, - Neuro-Fuzzy Architecture for CMOS Implementation, IEEE Transaction on Industrial Electronics vol. 46, no.6, Dec. 1999.
- [219] Wilamowski, B., Binfet, J., Kaynak, O., - VLSI implementation of neural networks, IEEE transaction on neural networks, vol. 2, nr 3, 1999
- [220] X. Yao, - A new evolutionary system for evolving artificial neural networks, IEEE Transaction on. neural networks,, vol. 8, 1997.
- [221] Yihua Liao. - Neural Networks in Hardware: A Survey. Department of Computer Science, University of California, Davis
- [222] Yu S.N., Chou K., - Combining independent component analysis and backpropagation neural network for ECG beat classification, Proceedings of the 28th IEEE EMBS International Conference, New York, p 3090- 3093, 2006
- [223] Zennaro D., Wellig P., Koch V., - A software package for decomposition of long term multichannel EMG signal using wavelet coefficients, IEEE Transaction on Biomedical Engineering, vol 50, nr. 1, p 58-69 , 2003
- [224] Zhou P., Rymer W., - Factors governing the form of the relation between muscle force and the EMG, Journal of Neurophysiology, p 2878 - 2886, 2004
- [225] Zhu, J., Sutton, P., - FPGA Implementations of Neural Networks – a Survey of a Decade of Progress. Proceedings of 13th International Conference on Field Programmable Logic and Applications (FPL 2003), Lisbon, Sep 2003
- [226] Zwarts MJ, Drost G., and Stegeman DF., - Recent progress in the diagnostic use of surface EMG for neurological diseases. J Electromyogr Kinesiol 10: 287–291, 2000.
- [227] Zwarts MJ., Stegeman DF., - Multichannel surface EMG: basic aspects and clinical utility. Muscle Nerve 28: 1–17, 2003.
- [228] *** <http://en.wikipedia.org>
- [229] *** <http://www.liberatingtech.com>
- [230] *** <http://www.centri.se>
- [231] *** <http://www.hosmer.com>
- [232] *** <http://www.motioncontrol.com>
- [233] *** <http://www.motionlabs.com>
- [234] *** <http://www.ni.com>
- [235] *** <http://www.ottobock.com>
- [236] *** <http://www.rslsteeper.com>
- [237] *** <http://www.vasi.on.ca>