

SISTEM ROBOTIC INTELIGENT - CU AUTO-ORGANIZARE SI BIO-INSPIRAT

Director de proiect: Conf. Dr. Ing. Dan Marius Dobra

I. Introducere

Prezentul proiect de cercetare interdisciplinară urmărește să aducă contribuții semnificative în cadrul (i) sistemelor de interfațare de tipul BCI (*brain computer interface*), și al (ii) sistemelor cu auto-organizare, de tip robotic, bio-inspirat (SrBio). În vederea dezvoltării unui sistem BCI performant trebuie luate în considerare cel puțin două aspecte: capacitățile de lucru în timp real ale sistemului, precum și performanțele de clasificare ale acestuia. Între aceste două aspecte constructive ale sistemului întotdeauna suntem constrânși să facem un compromis. Astfel, dacă se dorește o rată de clasificare mai mare, atunci sistemul BCI va deveni mai lent datorită, în general, complexității crescute a algoritmilor implementați în fazele de extragere și de clasificare a trăsăturilor; reciproc, o procesare mai rapidă implică rate de clasificare mai mici.

Performanțele de clasificare, în prezent, ale unui sistem BCI variază foarte mult, respectiv, între 70% și 95% [7], [8], [9]; în general, diversele performanțe raportate în literatură depind de: numărul subiecților, al canalelor, al task-urilor și de tipurile task-urilor mentale folosite, de tipul de sistem BCI, tehnicile de procesare și de eliminare a artefactelor, complexitatea și puterea discriminativă a algoritmilor de clasificare etc. Azi, multe sisteme BCI folosesc task-uri motorii imaginate (TMI) pentru a comanda sistemul global pornind de la semnalele EEG. Un progres major în această direcție a fost înregistrat în ultimii 15 ani. Astfel, dacă în 1998 TMI ale degetelor puteau fi distinse pe baza semnalelor EEG, cu o acuratețe în jur de 70% [10], în prezent (în 2009), în medie, acuratețea clasificării este în jur de 80% - 86% [8]. În acest sens, noi îmbunătățiri trebuie aduse pentru a obține o acuratețe medie de cel puțin 95%. Rezultatele diverselor cercetări raportate în literatură au arătat că acuratețea clasificării mai depinde și de: caracteristicile creierului subiectului investigat și de existența sau nu a unor sesiuni speciale, preliminare, de antrenare/învățare (*biofeedback*). În cazul TMI, acuratețea clasificării în cazul investigării unui singur subiect variază, în medie, între 75% și 95% [8], [11]. Aceste performanțe nu se regăsesc însă în cazul tuturor subiecților supuși analizei, rate de clasificare între 60% și 70% fiind posibil de obținut în alte câteva cazuri individuale de subiecți investigați [8], [11]. Datorită dificultății subiecților de a-și controla propriile semnale EEG, un protocol adecvat de antrenare/învățare, care să dureze câteva săptămâni sau luni [8] bazat pe un feedback vizual îl regăsim adesea implementat în multe studii [8], [12].

Lucrul în timp real. Performanțele *online* ale tehnologiilor BCI, măsurate în rata de transfer a informației (*bit rate*), sunt modeste. În prezent se poate vorbi atât de sisteme pentru care rata medie de comunicare este de 5.45 biți/min cât și de sisteme care lucrează undeva în jur de 10 biți/min [8]. Însă, chiar și în condiții optime [12], niciunul dintre sistemele BCI existente nu atinge mai mult de 25 biți/min. Rata de transfer a informației este limitată de **doi factori majori: abilitatea subiectului de a se interfața** cu sistemul BCI (tradusă în performanțele de clasificare) și de **performanțele în domeniul timp ale algoritmilor implementați** în sistemul BCI; de exemplu, în general, în TMI subiecții trebuie să execute mental un task motor sau altul un interval de timp de cel puțin 7 – 8 s astfel încât puterea ritmului mu să fie detectată cu acuratețe [8]. Dintre factorii limitativi enunțați anterior factorul uman este, de departe, factorul cel mai limitativ. În susținerea acestei idei vin diversele rezultate raportate în literatura de specialitate, iar dintre acestea menționăm aici doar rezultatele unui studiu [8] făcut pe 10 subiecți umani pentru care rata de transfer obținută a fost, în medie, în jur de 7 biți/min; excepție de la acest rezultat a făcut doar un singur subiect pentru care rata obținută a fost cea mai ridicată, respectiv de 22 biți/min.

În concluzie, pentru a avea simultan, atât o rată de transfer a informației mai mare, cât și o acuratețe a clasificării task-urilor mentale, de asemenea, mare, se impune definirea, implementarea și testarea unui nou concept pentru sistemele de tip BCI.

Considerații biologice. Sistemul motor uman (SMU) are o organizare ierarhică foarte complexă [13], cu diferite niveluri de control, iar fiecare dintre acestea primește informații senzoriale specifice funcționării sale. Astfel, proprioceptorii din tendoane, mușchi, articulații și ligamente, precum și receptorii din sistemul vestibular oferă creierului informațiile necesare ajustării posturii și a mișcării [14]. Acest tip de informații, de monitorizare a detaliilor, este necesar în special funcționării nivelurilor inferioare ale controlului motor, în timp ce informația senzorială dată de exteroceptorii din piele, ochi și urechi informează creierul cu privire la localizarea obiectelor în spațiu și poziția relativă a corpului subiectului în raport cu aceste obiecte. Acest din urmă tip de informație (informația senzorială) este una utilizată în special la nivelurile superioare ale controlului ierarhic al mișcării – niveluri implicate în elaborarea strategiilor legate de mișcare. Un aspect cheie legat de aceste **niveluri ierarhice superioare** constă în aceea că aceste niveluri de control al mișcării **nu implică o monitorizare pas cu pas a informațiilor de detaliu.**

La oameni, **comanda dinamică a mișcării (DM) ia naștere în centrul nervos superior (cortical), în timp ce detaliile privind execuția fiecărei mișcări se află sub controlul atât a ariilor corticale cât și a ariilor sub-corticale** [15]. Reflexele spinale sunt integrate, practic, cu comenzile motorii generate central în vederea producerii unor mișcări adaptive prin, pe de o parte, ajustarea ieșirii motorii pe

parcursul unei mișcări aflată în evoluție și, pe de altă parte, prin compensarea variabilității intrinseci a ieșirii motorii. Corespunzător gradului de complexitate și a tipului de control (voluntar sau nu), mișcările generate de către SMU pot fi clasificate în următoarele trei clase: *mișcări voluntare, răspunsuri reflexe și pattern-uri motorii ritmice*. Dintre aceste categorii ale mișcării, mișcările voluntare sunt, de departe, cele mai complexe, ele fiind caracterizate de: faptul că au un anumit scop, pot fi învățate și îmbunătățite în timp. **În pattern-urile de mișcare doar inițierea și sfârșitul sunt procese voluntare, ele combinând astfel caracteristicile atât ale actelor voluntare cât și pe cele ale actelor reflexe.** În plus, s-a descoperit că circuitul neuronal spinal la oameni are capacitatea de a genera o activitate de tip locomotor (cum este, de exemplu, *pattern-ul de pășire*) chiar și atunci când el este izolat, fără control neuronal superior (cortical) și fără *feedback* aferent periferic [16]. Acești generatori spinali de *pattern-uri* s-au dovedit a juca un rol major în organizarea activității locomotorii prin producerea unei ieșiri motorii coordonate. În condiții normale, acești generatori spinali se află sub control cortical și, în plus, intrările periferice senzoriale pot modula activitatea lor.

Conceptele sistemului. Luând în considerare soluția biologică prezentată mai sus, conceptul fundamental al sistemului iBiAoRS (*intelligent, bio-inspired and with auto-organization robotic system*) rezidă în construirea unui astfel de sistem capabil să exercite un control dinamic al mișcării, similar cu cel uman. **Sistemul va respecta principiul subordonării ierarhice – el reprezentând, de altfel, și elementul de noutate, central, al propunerii de grant.** În particular, sistemul va consta din trei niveluri de control (bucle de *feedback*) pentru DM. Cele 3 niveluri ale structurii ierarhice de control ale sistemului iBiAoRS (vezi Fig. 1) vor fi, după cum urmează:

(1) La primul nivel de control al DM, viteza de rotație a fiecăruia dintre cele două motoare ale sistemului implementat va fi ajustată adecvat, cu ajutorul a două bucle. Fiecare buclă va fi compusă din 2 controlere de tip PI – necesare ajustării curentului și a vitezei de rotație a motorului. Acest nivel de control este echivalent cu căile spinale reflexe existente în sistemele umane vii.

(2) Al doilea nivel de control al DM va fi compus dintr-un sistem adaptiv ce va permite sistemului iBiAoRS să evite obstacolele din imediata proximitate; acest proces adaptiv cu auto-organizare va folosi doar o reprezentare locală a lumii externe, obținută cu ajutorul informațiilor primite de la senzorii sistemului. Acest nivel va putea fi implementat folosind, de exemplu, o rețea neuronală ce va avea ca obiectiv minimizarea erorii dată de suma distanțelor relative obținute de la ieșirile senzorilor, $E = \sum_i (\Delta d_i)^2 - \Delta d_i$ reprezintă gradientul informației de distanță de la senzorul i . Într-o primă etapă, sistemul iBiAoRS se va comporta asemeni unei ființe umane (copil) care învață să meargă – lucru realizabil doar printr-un proces continuu de exersare și învățare. Deci, cel de-al doilea nivel de control al DM este echivalent cu ariile corticale și sub-corticale care controlează detaliile de execuție ale fiecărei mișcări, **printr-un proces continuu de ajustare a actelor reflexe.**

(3) Ultimul nivel de control al DM, implementat cu ajutorul componentei de tip BCI, va consta, ca și în cazul SMU, în generarea unei

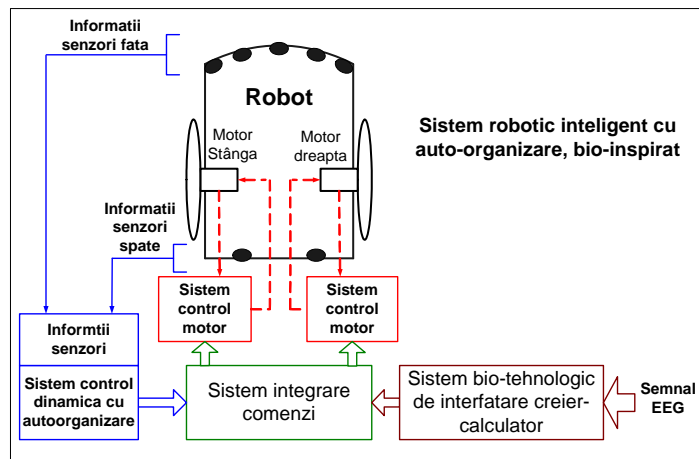


Figura 1. Sistem robotic inteligent cu auto-organizare, bio-inspirat

comenzi similare comenzii motorii voluntare dată la nivel central superior (cortical). În cazul nostru, DM a sistemului iBiAoRS va fi dictată de către activitatea cerebrală a unui subiect uman care va evalua vizual, grosier, traiectoria pe care sistemului iBiAoRS va trebui să o urmeze și, ulterior, va da mental o comandă globală (înainte, înapoi, stânga, dreapta).

Datorită autonomiei sale locale sistemul iBiAoRS va executa comanda globală, generată la nivel mental de către subiectul uman, fără a avea nevoie de alte comenzi de detaliu în vederea evitării obstacolelor locale. Sistemul iBiAoRS trebuie să fie capabil să facă o dublă integrare: aceea a comenzii globale cu controlul local al DM. În acest mod, autonomia locală, oferită de modul constructiv al sistemului global, va degreva componenta de tip BCI a sistemului de toate acele comenzi legate de detaliile DM; acest aspect va conferi componentei BCI posibilitatea de a-și crește, în mod semnificativ, performanțele. Mai exact, pentru o rată de transfer a informației dată a

componentei BCI, datorită autonomiei locale a sistemului global iBiAoRS (care nu presupune generarea de către componenta BCI și a comenzilor de detaliu ale DM) timpul dintre două comenzi ale mișcării, generate de sistemul BCI va crește; din această perspectivă, comportamentul dinamic al mișcării globale în timp real ar urma să se îmbunătățească. Mai mult chiar, acuratețea clasificării va putea fi crescută (prin implementarea unor algoritmi mai complecși care, în general, sunt mai mari consumatori de timp sau/și printr-o fereastră mai mare de timp a semnalului EEG pe care se va face analiza în vederea clasificării) – și toate acestea fără efecte secundare asupra operării în timp real a sistemului propus.

Urmând această abordare se vor atinge ambele obiective propuse, respectiv, cel de operare în timp real a sistemului, precum și cel de obținere a unei rate ridicate de clasificare.

În continuare, sinteza cercetărilor prezentate în acest raport va fi compusă din două secțiuni majore (ce se reflectă în obiectivele și activitățile planului de realizare al proiectului pe anul 2009):

1. prezentarea sistemului de tip BCI, și
2. prezentarea rezultatelor obținute în proiectarea, dezvoltarea, implementarea și testarea controler-ului cu auto-organizare.

II. Sistemul (bio)tehnologic de tip BCI

Platforma de dezvoltare pentru aplicația de tip BCI utilizată în cadrul acestui proiect de cercetare a fost realizată în cadrul unui alt grant anterior [17]. Un prim pas în cadrul prezentului grant l-a reprezentat îmbunătățirea (optimizarea) acestui sistem (bio)tehnologic. Procesul de îmbunătățire/optimizare a sistemului a urmat trei direcții prioritare: (a) **creșterea vitezei de lucru a acestui sistem**, (b) **flexibilizarea lui** și (c) **creșterea performanțelor de clasificare**.

Creșterea vitezei de lucru a sistemului (bio)tehnologic de tip BCI poate fi obținută operând,

fie pe rând, fie simultan, la mai multe niveluri operaționale (de ex. selectarea cu atenție a intrărilor acestui sistem, căutarea unor metode de procesare eficiente și cu un cost computațional redus sau la nivelul soluțiilor tehnologice de implementare a sistemului). Datorită apariției sistemelor PC104+ de tip dual core s-a impus schimbarea modului liniar de procesare a datelor, existent anterior și rezultat din schema bloc a sistemului vezi Fig. 2. Astfel, noul sistem a fost implementat sub forma unui pipeline în care fiecare bloc funcțional execută în paralel procesarea informațională, simultan cu toate celelalte blocuri, iar parte din blocuri pot fi pe un alt *core* al procesorului. Sincronizarea blocurilor cu aplicația cadru se implementează de această dată cu ajutorul evenimentelor (cu ajutorul funcțiilor de tipul *WaitForSingleObject*). De asemenea, în cadrul cercetării de față o atenție deosebită a fost acordată intrărilor sistemului BCI, dată fiind importanța pe care o au datele de intrare în calitate de purtătoare de informație utilă în procesul de clasificare. În acest sens, date de intrare cu un conținut informațional ridicat privind caracterul discriminativ al *task*-urilor mentale folosite pot conduce la o creștere a vitezei de lucru a sistemului prin folosirea unor metode simple, de complexitate computațională redusă în cadrul fiecărui bloc.

Creșterea **flexibilității sistemului (bio)tehnologic** a fost realizată prin introducerea unui bloc nou, de extragere a trăsăturilor, bloc inexistent anterior [17]. De asemenea modulele de comunicație existente anterior au fost înlăturate din sistem [17].

Creșterea performanțelor de clasificare ale sistemului BCI reprezintă o altă direcție de cercetare a prezentului grant, materializată prin abordarea unor probleme cum ar fi: (a) *selecția celor mai discriminative task-uri mentale*, (b) *găsirea unor noi trăsături ale semnalului EEG*, purtătoare a unui cât mai ridicat conținut informațional, util pentru clasificare și, respectiv, (c) *găsirea (prin folosirea unor metode de optimizare) a combinației optime de trăsături ale semnalului EEG dintr-un set mai larg de trăsături, specificat a priori*.

(a) Task-uri mentale discriminative. Se știe că, pentru a comanda mental, în timp real, un sistem/echipament, componenta de tip BCI necesită la intrare *task*-uri mentale cât mai discriminative. Azi, majoritatea aplicațiilor BCI folosesc în analiză un *task* de referință (în general, *task*-ul de relaxare) sau seturi de *task*-uri fie numai motorii, fie numai non-motorii, și doar o mică parte dintre aceste aplicații analizează un set combinat de *task*-uri imaginate motorii și non-motorii. În plus, adesea, pentru același set de *task*-uri cognitive, în diferite lucrări și pentru subiecți diferiți întâlnim raportate performanțe diferite de clasificare, funcție și de metodele de procesare folosite. Cu toate acestea, indiferent cât de performante sunt aceste metode, ele nu pot conduce la rezultate excelente dacă *task*-urile mentale utilizate nu dau naștere, în mod fundamental, la *pattern*-uri EEG de activare, cât mai distincte, cel puțin în raport cu metodologia de procesare folosită. Din acest punct de vedere, problema găsirii celor mai discriminative *task*-uri – apare ca fiind una chiar mai importantă decât metodele de procesare în sine.

În general, în domeniul BCI, alegerea unui set de *task*-uri cognitive se face având în minte presupusa existență a unor *pattern*-uri EEG de activare diferite, generate de *task*-urile folosite. Astfel, spre exemplu, specializarea emisferică, sincronizări în fază, locale sau la distanță, în diverse arii corticale și în diferite benzi de frecvență etc. sunt tot atâtea criterii larg exploatate în faza preliminară de selecție a *task*-urilor. Cu toate acestea, **relația task – pattern de activare corticală nu este întotdeauna foarte predictibilă, fapt datorat probabil specificităților legate de individ ale substraturilor neuronale, diferențelor ce țin de abilitățile personale, gradul de lateralitate, de**

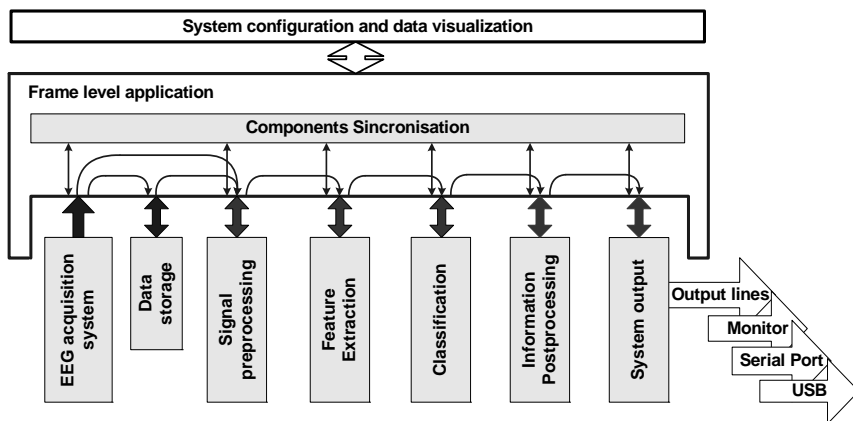


Figura 2. Schema bloc a sistemului BCI [1]

vigilență a fiecărui subiect și, nu în cele din urmă, datorat interpretării personale dată de fiecare individ în parte task-ului executat.

În cadrul acestui grant, pentru a evidenția importanța alegerii, pentru fiecare subiect în parte, a unui set specific de *task*-uri mentale (aplicație BCI dedicată) și, în plus, pentru a cuantiza câștigul net reflectat în performanțele de clasificare ale sistemului BCI, un set de 12 *task*-uri mentale imaginate au fost analizate în raport cu 4 subiecți diferiți [2].

Tabel 1. Seturile de *task*-uri determinate pentru fiecare subiect [2]

Subiect	Task 1	Task 2	Task 3	Task 4	Performanța medie
S1	num	degetD	brațS	nume	88.72
S2	brațD	relaxare	rotire	poezie	79.12
S3	num	degetD	scrisoare	poezie	92.14
S4	num	brațS	nume	poezie	91.99

Task-urile imaginate folosite au fost: 8 non-motorii (de numărare (num), de *compunere mentală a unei scrisori* (scrisoare), aritmetic, de *adunare* (adun), de *relaxare* (relax), de *rotire a unui obiect 3D* (rotire), de *generare de cuvinte* (cuvinte), de *generare de nume* (nume), de

recitare mentală a unei poezii (poezie)) și 4 motorii (de mișcare a degetelor mâinii stânga (degetS), de mișcare a degetelor mâinii drepte (degetD), de mișcare a brațului stâng (brațS), de mișcare a brațului drept (brațD)). Condițiile, parametrii și sistemul de înregistrare a semnalelor EEG sunt cele prezentate în [2].

Metodologia de procesare a semnalului EEG utilizată a fost una standard. Astfel, metodele utilizate în faza de selecție a task-urilor au inclus modelarea autoregresivă (AR) a semnalului EEG și folosirea unui clasificator Bayes iar cele utilizate în faza de comparare a rezultatele obținute cu rezultate similare raportate în literatură, au inclus modelarea autoregresivă (AR) și un clasificator de tip perceptron multistrat. Pentru a găsi setul celor mai bune patru task-uri din cele 12 propuse spre a fi discutate, o analiză exhaustivă, automată, a fost realizată pentru fiecare subiect în parte [2]. Specificitatea legată de subiect (inter-variabilitatea privind modul particular în care pattern-urile EEG sunt activate la diferiți subiecți în timpul executării de către aceștia a unor task-uri cognitive) este evidențiată de combinațiile particulare de 4 task-uri pe care le-am găsit ca oferind cele mai bune rezultate de clasificare pentru fiecare din cei 4 subiecți ca și de ratele de clasificare medii aferente acestor seturi de task-uri – rate care variază în mod considerabil de la subiect la subiect (vezi **Tabelul 1**).

Tabel 2. Matricile de confuzie pentru cele două seturi de task-uri (cel selectat, respectiv, cel de referință), pentru fiecare subiect

Setul selectat de task-uri							
S1		S2		S3		S4	
num	78.48	brațD	62.69	nume	79.03	num	83.46
degetD	73.92	relaxare	59.09	degetD	95.65	brațS	74.44
brațS	73.47	rotire	82.50	scrisoare	87.02	nume	91.74
nume	82.02	poezie	75.00	poezie	85.22	poezie	92.08
Setul de referință							
num	35.77	num	21.64	num	81.16	num	56.93
scrisoare	60.47	scrisoare	34.55	scrisoare	67.20	scrisoare	40.98
adun	48.06	adun	30.00	adun	56.45	adun	46.22
rotire	59.06	rotire	46.53	rotire	85.12	rotire	43.85

În **Tabelul 2**, performanțele obținute cu seturile astfel selectate sunt prezentate în comparație cu performanțele

Tabel 3. Performanțele de clasificare obținute pentru S4 folosind primul și, respectiv, cel de-al doilea set de task-uri [3]

	Primul set de date EEG				Al doilea set de date EEG			
	num	brațS	nume	poezie	num	brațS	nume	poezie
num	83.46	11.02	3.94	1.58	81.24	5.69	9.66	3.41
brațS	15.04	74.44	3	7.52	7.29	76.23	8.36	8.12
nume	1.84	2.75	91.74	3.67	1.91	4.89	89.33	3.83
poezie	0	4.32	3.6	92.08	0.25	4.1	4.64	91.01

atînse în cazul folosirii unui set de referință constând în 4 din cele 5 task-uri cognitive propuse de Keirn și Aunon [20]. **Rezultatele prezentate în Tabelul 2 ne oferă, practic, o măsură a importanței foarte ridicate pe care o poate avea selectarea, într-o fază preliminară, a celor mai adecvate task-uri pentru un subiect, reflectată la nivelul creșterii semnificative a rezultatelor clasificării, și asta în condițiile non-intervenției (în sensul îmbunătățirii) în partea algoritmică a unui sistem BCI.** Consistența rezultatelor acestui tip de analiză a fost testată în cazul subiectului S4 pentru care s-a realizat o a doua sesiune de înregistrări. Performanțele de clasificare obținute de S4 pe primul set de date, la fel ca și pe cel de-al doilea set de date (seturi de date înregistrate în zile diferite) diferă foarte ușor (vezi **Tabelul 3**) ceea ce susține ideea consistenței setului de task-uri selectat, specific subiectului – un aspect important în orice aplicație BCI.

În continuare au fost realizate cercetări ce vizează găsirea acelor trăsături ale semnalului EEG cele mai adecvate pentru aplicațiile de clasificare de task-uri cognitive. În cadrul acestei etape a proiectului am utilizat o nouă metodă, denumită ANAPP (*Adaptive Nonlinear Amplitude and Phase Process*); metoda a fost propusă de noi în [1] și ea modelează semnalul EEG ca o combinație de cinci „oscilații corticale spontane” (OCS) specificate *a priori*; amplitudinile și fazele acestor OCS sunt determinate printr-un algoritm adaptiv. Frecvențele celor 5 OCS au fost determinate folosind funcția de coerență [1], [4]. Mai departe, parametrii estimați ai modelului ANAPP (amplitudinea și faza) au fost utilizați ca date de intrare într-o rețea neuronală artificială (RNA) de tip perceptron multistrat (MLP). Datele EEG utilizate în această cercetare au fost achiziționate de la 4 subiecți în timp ce aceștia executau cinci task-uri mentale diferite (T1-relaxare, T2 - scriere, T3 - numărare, T4 - aritmetic, T5 – rotire 3D), vezi [1] și [4].

Utilizând doar parametrii de amplitudine ai modelul ANAPP al semnalelor EEG, un clasificator de tip MLP (cât mai specific acestei probleme) precum și metodologiile prezentate în lucrările [1] și [4], am obținut în final rezultatele prezentate în **Tabelul 4**.

(b) Găsirea unor noitrăsături. În analiza următoare s-a testat capacitatea numai a trăsăturilor de fază de a conține informații utile,

Tabel 4. Matricea confuziilor, rezultatele clasificării celor 4 task-uri pentru S2 [1]

		Clase atribuite			
		T2	T3	T4	T5
Clase reale	T2	79.6%	3.2%	6.3%	10.9%
	T3	2.9%	84.1%	5.7%	7.3%
	T4	6.1%	13.6%	77.3%	3%
	T5	14.7%	10.3%	2.9%	72.1%

capabile să conducă la rate de clasificare superioare. În final, s-a concluzionat că utilizarea doar a informației de fază din modelul ANAPP a condus la obținerea unor performanțe de clasificare net inferioare celor considerate drept rezultate de referință (**Tabelul 4**), [4]. Într-o altă analiză, s-a testat capacitatea ambelor tipuri de informații furnizate de modelul ANAPP (întreg setul de parametri, de fază și de amplitudine, la un loc) de a obține un efect sinergic, reflectat în rate de clasificare mai mari decât cele obținute folosind fie doar informația de fază, fie doar pe cea de amplitudine. În ciuda tuturor așteptărilor, rezultatele obținute de această dată s-au dovedit a fi chiar mai mici decât cele obținute atunci când s-au utilizat doar parametrii de fază [4].

(c) Optimizarea setului de trăsături. În continuare s-a încercat găsirea unei metode de selecție doar a acelor trăsături (de fază și de amplitudine) din întregul set de trăsături, cu adevărat utile, capabile să îmbunătățească considerabil performanțele clasificării. Pentru a rezolva această problemă s-a folosit un algoritm genetic (GA). Această metodă selectează dintr-un set dat de trăsături (în cazul nostru acesta poate fi dat fie doar de setul

trăsăturilor de fază, fie doar de cel al amplitudinilor, fie de ambele tipuri de trăsături) doar acele trăsături care sunt importante pentru procesul de clasificare (acele intrări care conțin informații ce asigură cea mai mare discriminare între clase). Costul mediu (costul pătrat mediu al ieșirii rețelei), calculat pe setul de crosvalidare, a fost folosit în calitate de criteriu de *fitness* pentru GA, minimizarea lui fiind un obiectiv al GA.

Am utilizat această nouă abordare în cazul problemei de clasificare de mai sus, în care s-au folosit atât informațiile de fază cât și cele de amplitudine; dar chiar și în această situație performanțele de clasificare au fost, în continuare, inferioare celor prezentate în **Tabelul 4**. În acest context, ținând cont și de performanțele foarte slabe obținute în cazul trăsăturilor de fază, un pas firesc l-a reprezentat optimizarea doar a setului trăsăturilor de amplitudine; rezultatele obținute în urma selecției optime a trăsăturilor de amplitudine sunt cele prezentate în **Tabelul 5**. Dacă comparăm aceste rezultate cu ratele de referință din **Tabelul 4**, observăm doar o ușoară îmbunătățire a performanțelor. Îmbunătățirea înregistrată la nivelul ratelor de clasificare pare să fie una ne semnificativă și, în consecință, inconsistentă, însă această ușoară îmbunătățire este susținută și de o altă paradigmă. În urma procesului de optimizare, doar un număr de 80 de trăsături au fost selectate din setul complet de 104 trăsături de amplitudine. O consecință directă a acestui rezultat a fost și scăderea complexității sistemului de clasificare de la un număr de

Tabel 5. Matricea confuziilor obținută în cazul trăsăturilor de amplitudine optimizate cu GA [4]

		Clase atribuite			
		T2	T3	T4	T5
Clase reale	T2	82.81%	6.25%	4.68%	6.26%
	T3	2.9%	79.71%	7.25%	10.14%
	T4	6.06%	7.58%	86.36%	0%
	T5	11.76%	13.24%	8.82%	66.18%

4320 de ponderi pentru rețeaua ANN de referință, la doar 1932 de ponderi pentru rețeaua optimizată ANN. În acest mod, complexitatea noului sistem de clasificare a fost redus aproape la jumătate (55.27%) din ANN de referință [4]. Reducerea complexității noului sistem de clasificare prezintă un număr de avantaje [4]: (a) sistemul este mai rapid (datorită scăderii încărcăturii computaționale), (b) utilizând același set de date de antrenare, capacitățile de generalizare a noii RNA mai „suple” au crescut.

III. Controlerul cu auto-organizare

Pentru construirea sistemului global iBiAoRS a trebuit implementat și testat fiecare nivel al sistemului de control al DM prezentat anterior. În continuare prezentăm controler-ul inteligent, cu auto-organizare și bioinspirat. Acest al doilea nivel de control al DM este cel care trebuie să învețe (într-o manieră adaptivă, printr-un proces de auto-organizare continuă) să se deplaseze evitând obstacolele – lucru posibil prin utilizarea doar a reprezentării locale a mediului înconjurător, oferită de către senzori.

Implementarea conceptelor acestui nivel al DM a fost realizată cu ajutorul unui mic sistem robotic, vezi **Fig. 3**, de tip TekBots. Acesta a trebuit să învețe, într-o manieră adaptivă, să minimizeze valoarea erorii propusă mai sus. Produs de Universitatea de stat din Oregon, sistemul robotic este format dintr-o parte mecanică, două punți H și un sistem logic, combinațional, de comandă a punților H.

Sistemul robotic inteligent, cu auto-organizare și bioinspirat (SrBio) a fost construit în două versiuni: (a) cu ajutorul microcontroler-ului MCF5213 (implementare prezentată în **Fig. 3**), și (b) cu ajutorul unei plăci de tipul TMS320C6713DSK (DSP Starter Kit) având DSP-ul TMS320C6713 drept element central.

$$err = \frac{1}{4} \sum_{i=1}^4 (s_i[n] - s_i[n-1])^2 \quad (1)$$

Pentru a avea o reprezentare a lumii externe s-au folosit 2 sisteme senzoriale diferite. Primul sistem a utilizat un număr de patru senzori IR de măsurare a distanței (GP2D120XJ00F), dintre care 3 plasați în față și unul în spate, conform **Fig. 3** [5]. Acest sistem senzorial a fost integrat în ambele versiuni constructive prezentate anterior ale robotului. Cel de-al doilea sistem este un sistem optic bazat pe un senzor laser (SL) non-contact de măsurare a distanțelor [6]. SL este format dintr-un dispozitiv ce generează un plan laser la un anumit unghi față de un plan orizontal și dintr-un senzor optic (webcam), ce achiziționează două imagini video consecutive [6]. Prima imagine este achiziționată cu planul laser activ, în timp ce, cea de a doua imagine este achiziționată cu planul laser inactiv. Prin realizarea „diferenței” (comparației) dintre cele două imagini rezultă o nouă imagine care va conține, practic, numai proiecția planului laser pe obiectele din imediata vecinătate. Distanțele existente, calculate între diversele proiecții ale planului laser ce apar pe imaginea rezultantă și marginea inferioară a aceleiași imagini sunt proporționale cu adâncimea spațială de poziționare a obiectelor în universul real tridimensional [6]. Acest sistem video de determinare a distanțelor a fost implementat doar pe versiunea SrBio ce utilizează placa TMS320C6713DSK (datorită necesității existenței unei puteri mai mari de calcul, dar, în principal, și datorită necesității existenței unui sistem de achiziționare a informației video care în cazul nostru particular a fost IDC (imaging daughter card) parte componentă a kit-ului TMS320C6000TM IDK (Imaging Developer’s Kit)). Fiecare motor de curent continuu al robotului este controlat de către microcontroler/DSP prin intermediul a două canale (linii de tipul I/O). Unul dintre canale, de tip PWM, controlează viteza robotului iar cel de-al doilea controlează sensul de rotație.

Algoritmul inteligent, cu auto-organizare, folosit în controlul robotului a constat, într-un **prim pas**, într-o rețea neuronală de tip perceptron multistrat (MLP), cu două straturi ascunse. Pe primul strat ascuns, RNA a avut 5 neuroni, în timp ce, al doilea strat ascuns a avut 3 neuroni. RNA MLP a avut 4 intrări (respectiv, valorile normalizate obținute de la senzorii de distanță) și două ieșiri (ce au furnizat comanda către motoare). Fiecare ieșire a putut lua valori doar în intervalul [-1,1] (1 – putere maximă înainte, -1 – putere maximă înapoi și 0 – oprirea motorului). Termenul de eroare utilizat a fost cel dat de relația (1). În relația (1) s_i este valoarea senzorului i iar n este momentul de timp. Între momentele n și $n-1$ de timp există o întârziere de 0.4 s. Această întârziere este una necesară sistemului robotic

inteligent în sensul că oferă timpul necesar deplasării acestuia și, în consecință, schimbării valorilor senzorilor. Pentru a fi siguri de funcționarea corectă a rețelei MLP s-a realizat, anterior testării acesteia pe SrBio, un simulator în mediul de programare vizual LabWindows CVI. Acest simulator este capabil să testeze regimul dinamic al structurii neuronale și să prezinte, în mod grafic, informația din diferite puncte de interes ale rețelei MLP. Într-un **al doilea pas** s-a testat și o structură neuronală de tip RBF (*radial basis function*).

Un **ultim pas** a vizat o implementare genetică a controller-ului. În cadrul algoritmului genetic s-a lucrat cu o populație mică de 10 cromozomi, fiecare cromozom fiind o concatenare a două valori de tip *signed char* pe 8 biți ([-128, 127] – cu semnificația de [viteză maximă înapoi, viteză maximă înainte] pentru fiecare motor). Funcția de *fitness*, necesară a fi minimizată, a fost dată tocmai de valoarea relației (1). În fiecare nouă generație algoritmul genetic a deplasat robotul conform informației existente în fiecare nou cromozom; ulterior s-a calculat valoarea *fitness*-ului funcție de informația senzorială, iar în final robotul a revenit la poziția inițială, acest ciclu continuându-se apoi cu următorul cromozom. Deplasarea care se realizează într-o anumită generație este cea corespunzătoare cromozomului cu *fitness* minim. Această comandă se stochează într-un tabel împreună cu informația senzorială existentă anterior deplasării. Dacă se constată că *fitness*-ul unei noi reprezentări senzoriale este superior uneia existente în tabel (pentru o nouă reprezentare senzorială situată la o distanță euclidiană mai mică decât o anumită reprezentare anterioară) aceasta este înlocuită de noua reprezentare. Algoritmul genetic este oprit după atingerea unui număr maxim de generații (500). După terminarea procesului de învățare valorile stocate în tabel sunt folosite drept bază de cunoștințe și utilizate mai departe în deplasarea SrBio. Astfel, din 0.4 s în 0.4 s noua informație senzorială este utilizată în calcularea distanțelor euclidiene față de informațiile senzoriale stocate în tabel. Comenzile celor două motoare asociate cu acea informație senzorială de distanță minimă față de informația senzorială actuală sunt utilizate în comanda SrBio.




Figura 3. Sistemul robotic bio-inspirat (SrBio) [5]




Fig. 4. Comportament de tip pradă-vânător ($a > 1$)

Rețeaua neuronală de tip MLP și algoritmul genetic au fost capabile să rezolve acest *task* în timp ce rețeaua neuronală de tip RBF a avut probleme reale în atingerea acestui obiectiv. Deosebirea fundamentală a fost dată de timpul necesar atingerii acestui obiectiv, timp net inferior în cazul rețelei de tip MLP. Acest prim comportament învățat de către SrBio (evitarea unei coliziuni cu un obstacol) a evoluat, însă, ulterior și într-un alt tip de comportament, respectiv, de tip pradă-prădător (vezi **Fig. 4**). Acest nou tip de comportament se poate traduce prin aceea că, atunci când presupusul obstacol a dobândit o comportare de tip prădător, urmărind sistemul SrBio, acesta din urmă nu numai că s-a oprit din mersul său și și-a schimbat direcția, mergând în sens opus atunci când sistemul prădător s-a aflat în raza unuia dintre senzorii săi ci, în plus, el și-a crescut progresiv viteza ($a > 1$, vezi Fig. 3a) în încercarea continuă de a crește distanța dintre el și sistemul care-l urmărea (a se vedea **Fig. 4**).

IV. Concluzii

Cercetarea de față a proiectat, dezvoltat, implementat, îmbunătățit și testat o nouă clasă de sisteme de tipul BCI – parte componentă importantă a sistemului iBiAoRS (*intelligent, bio-inspired and with auto-organization robotic system*). Astfel, s-a re-proiectat și implementat structura cadru a sistemului BCI, oferindu-i acestuia capacități de operare paralelă (de tip pipeline) multiprocesor. Abordarea componentei BCI (reprezentând echivalentul nivelului ierarhic superior al sistemului biologic de control al dinamicii mișcării) a vizat găsirea unor modalități de implementare practică a sistemului care să asigure, în același timp, atât caracterul de lucru în timp real al acestuia cât și o performanță de clasificare cât mai ridicată. În acest sens, câteva soluții au fost propuse și analizate, acestea fiind după

cum urmează: (1) găsirea, într-o primă etapă preliminară, pentru fiecare subiect în parte, a task-urilor cele mai discriminative dintr-un set mai mare de task-uri mentale propuse (această soluție poate conduce la obținerea unor performanțe de clasificare superioare, în condițiile utilizării unor tehnici de procesare standard, nu foarte costisitoare din punct de vedere computațional; în exemplul nostru prin această abordare s-a obținut o creștere medie a ratei de clasificare corectă cu 14.24% până la 38.43% funcție de subiect în condițiile menținerii aceleiași metodologii de procesare – vezi Tabelul 2), (2) propunerea folosirii parametrilor de fază ai modelului ANAPP al semnalului EEG în construirea vectorilor de trăsături – fie independent, fie în combinație cu parametrii de amplitudine ai aceluiași model (rezultatele obținute în ambele cazuri au fost sub așteptări, fapt ce a impus necesitatea optimizării setului de trăsături), (3) optimizarea GA a setului de trăsături (care a dus la o mică îmbunătățire a performanțelor de clasificare dar a generat o reducere de aproximativ 50% a complexității structurii neuronale). Folosind un controler adaptiv, implementat pe o platformă robotică, cu o structură de tip auto-organizare continuă bazată pe o reprezentare locală a lumii înconjurătoare, complexul SrBio, a fost capabil să evite obstacolele fără vreun control suplimentar venit din partea componentei de tip BCI a sistemului global. În acest mod, utilizatorul sistemului s-a regăsit în situația de a iniția doar și, respectiv, de a termina o acțiune globală (de exemplu, comenzi cum ar fi: “ia-o la stânga” etc.) fără să mai dea, suplimentar, atenție și obstacolelor locale. Astfel, intervalul de timp dintre două comenzi succesive a crescut, oferind utilizatorului, precum și componentei BCI a sistemului, o fereastră mai mare de timp pentru a putea, pe de o parte, în cazul utilizatorului – iniția și susține corect un anumit task mental – și, pe de altă parte, în cazul componentei BCI – pentru a procesa corect semnalele electroencefalografice aferente task-ului.

În concluzie putem afirma că, prin activitățile de cercetare întreprinse și rezultatele obținute, acest contract de cercetare multidisciplinară și-a atins în totalitate obiectivele și activitățile științifice propuse, oferind rezultate științifice de calitate susținute și prin următoarea listă de lucrări publicate.

Lucrări publicate în cadrul grantului

- [1] **D.M. Dobrea, M.C. Dobrea**, *EEG Classification System – From an Universal System Implementation to a Particular Signal Modeling*, Proceedings of the Romanian Academy - Series A: Mathematics, Physics, Technical Sciences, Information Science, Vol. 10, Nr. 2, May–August 2009, pp. 197-204, ISSN 1454-8267
- [2] **D.M. Dobrea, M.C. Dobrea**, *A study on mental tasks discriminative power*, International Symposium on Signal Processing, Image Processing and Pattern Recognition (Eds. Y.-h. Lee et al., book title „Future Generation Information Technology”, Series „Lecture Notes in Computer Science”, vol. 5899, 2009, ISBN 978-3-642-10508-1, ISSN 0302-9743 (Print) 1611-3349 (Online), editura: Springer-Verlag Berlin Heidelberg), December 10-12, 2009, Jeju Island, Korea, pp. 61-68, lucrare indexată în baza de date Springer – DOI: 10.1007/978-3-642-10509-8
- [3] **M.C. Dobrea, D.M. Dobrea**, *The selection of proper discriminative cognitive tasks – a necessary prerequisite in high-quality BCI applications*, 2nd International Symposium on Applied Sciences in Biomedical and Communication Technologies, Nov. 24-27, 2009, Bratislava, Slovacia¹
- [4] **D.M. Dobrea, M.C. Dobrea**, *Optimisation of a BCI system using the GA technique*, 2nd International Symposium on Applied Sciences in Biomedical and Communication Technologies, November 24-27, 2009, Bratislava, Slovak Republic¹
- [5] **D.M. Dobrea, M.C. Dobrea**, *The concept of an intelligent, bio-inspired and brain controlled robotic system*, 9th International Conference on Information Technology and Applications in Biomedicine, November 5-7, 2009, Larnaca, Cyprus¹
- [6] **D.M. Dobrea**, *Senzor laser pentru determinarea non-contact a distanțelor, poziției și a mișcării diferitelor obiecte*, cerere brevet, 2009

Data: 09.12.09

Director de proiect:

Conf. Dr. Ing. Dan Marius Dobrea

Bibliografie

- [7] C. Guger, et. al., *Rapid prototyping of an EEG-based BCI*, IEEE Trans. on Neural Syst. and Rehab. Eng., vol. 9, no. 1, pp. 49-58, March 2001
- [8] J. Lehtonen, P. Jylanki, L. Kauhanen, M. Sams, *Online Classification of Single EEG Trials During Finger Movements*, IEEE Trans. on Biomed. Eng., vol. 55, no 2 pp. 713 – 720, Feb. 2008
- [9] S. J. Roberts, W. D. Penny, *Real-time BCI: a preliminary study using Bayesian learning*, Med. & Biol. Eng. & Comp., vol. 38, 2000, pp. 56-61
- [10] W. Penny, and S. Roberts, *Imagined hand movements identified from the EEG Mu-Rhythm*, 1998 Technical report, Imperial College, University of London, Available via <http://www.ee.ic.ac.uk>.
- [11] C. Vidaurre, A. Schlogl, R. Cabeza, R. Scherer, and G. Pfurtscheller, *Study of On-Line Adaptive Discriminant Analysis for EEG-Based Brain Computer Interfaces*, IEEE Trans. on Biomed. Eng., vol. 54, no. 3, pp. 550 – 556, March 2007
- [12] G. Schalk, D. J. McFarland, T. Hinterberger, N. Birbaumer, and J. R. Wolpaw, *BCI2000: a general-purpose brain-computer interface (BCI) system*, IEEE Trans. on Biomed. Eng., vol. 51, no. 6, pp. 1034 – 1043, June 2004
- [13] S. T. Grafton, et. al., *Evidence for a distributed hierarchy of action representation in the brain*, Hum. Mov. Sci., vol. 26, no. 4, pp. 590-616, 2007
- [14] B. Schepens, T. Drew, *Strategies for the Integration of Posture and Movement During Reaching*, J Neurophysiology, 90, pp. 3066-3086, 2003
- [15] C. Ghez, *The control of movement*, în E.R. Kandel, J.H. Schwartz, T.M. Jessell, Principles of neural science, Elsevier, pp. 533-547, 1991
- [16] M. R. Dimitrijevic, et. al., *Evidence for a Spinal Central Pattern Generator in Humans*, A. of the New York Acad. of Sci. 860, pp. 360-376, 1998
- [17] D.M. Dobrea, *Cercetari Fundamentale Pentru Modelarea si Explicarea Reflexului Vizual si Construirea Unui Sistem (Bio)Tehnologic de Asistare a Persoanelor Dezavantajate*, Contract nr.: GR 80/23.05.2007, tema 58, cod CNCISIS 17, 2007

¹ lucrare ce va fi indexată în IEEE Xplore în conformitate cu afirmația organizatorilor