

Obiectivul 1 (2015) - Studiul aspectelor referitoare la procesarea semnalelor folosind conceptul de compressed sensing

A1.1. - Studiul avantajelor si limitărilor conceptului de CS

A1.2. - Studiul teoremelor legate de CS si n-widths și a consecințelor acestora

În ultimii 8 ani, în teoria procesării semnalelor unidimensionale sau bidimensionale s-a introdus un nou concept în modalitatea de achiziție, analiză, sinteză și reconstrucție a datelor. Acest concept este cunoscut sub mai multe denumiri echivalente: *compressive sampling* sau *compressive sensing* (*achiziție/detectie prin compresie*).

Fie un vector $x \in \mathbb{R}^n$ cu reprezentare rară în baza definită de matricea $B \in \mathbb{R}^{n \times n}$ (coloanele matricii reprezintă elementele bazei). Vectorul x poate fi scris ca $x = B\gamma$, unde γ reprezintă descompunerea rară a lui x în B . Să presupunem că putem face un set de m măsurători asupra lui x prin proiecția sa pe un număr de m vectori oarecare (numiți *vectori de măsurare* sau *de proiecție*), unde $m < n$. Dacă se consideră acești vectori de măsurare ca reprezentând liniile unei *matrice de achiziție* $P \in \mathbb{R}^{m \times n}$, procesul de achiziție al semnalului x este descris de multiplicarea cu matricea P : $y = Px = PB\gamma = A\gamma$. Produsul dintre P și B poartă numele de *dicționar efectiv*. Făcând notația $A = PB$, se ajunge la forma uzuală a achiziției comprimate: $y = A\gamma$. Această ecuație exprimă faptul că vectorul rar γ este *achiziționat* cu ajutorul matricii A . Întrucât în general numărul de vectori de măsurare m este mult mai mic decât dimensiunea semnalului n , procesul poartă numele de *achiziție comprimată*.

Au fost studiate teoremele pe baza cărora este posibilă compresia cu pierderi minime și achiziția comprimată precum și implicațiile practice ale acestora. În esență problemele analizate se referă la precizarea proprietăților clasei de semnale adoptate din punctul de vedere al reprezentării într-o baza adecvată din care decurge stabilirea modul de achiziție a semnalelor din clasa respectivă. Astfel, principalele direcții de studiu au fost:

- semnale și reprezentări rare;
- achiziția comprimată a semnalelor;
- soluții și regularizare;
- condiții pentru recuperarea semnalelor rare, cu studiul Spark-ului unei matrici, proprietății de izometrie restrânsă (Restricted Isometry Property, RIP), proprietății spațiului nul (Null Space Property, NSP), coerența mutuală, relațiilor între spark, RIP, NSP și coerența mutuală, precum și utilizarea matricelor aleatoare în achiziția comprimată.

Au fost analizate o serie de rezultate teoretice care stau la baza utilizării dicționarelor supra-complete inerente algoritmilor de achiziție comprimată. De asemenea au fost studiate metodele existente de aplicare a conceptelor matematice în implementarea CS pe semnale medicale.

Scopul acestor analize este acela de a identifica modalitățile de construcție și caracterizare a dicționarelor supra-complete în vederea utilizării acestora în achiziția/compresia semnalelor electrocardiografice (ECG) și electroencefalografice (EEG).

Rezultatele obținute au fost raportate în:

[Fira IJARAI 2015] Adrian Brezilianu, Monica Fira, Marius Daniel Pestina, Compressed Sensing Based Encryption Approach for Tax Forms Data, International Journal of Advanced Research in Artificial Intelligence (IJARAI), Volume 4 Issue 11, 2015

[Fira EHB 2015] Fira Monica, Applications of Compressed Sensing: Compression and Encryption, International Conference on e-Health and Bioengineering, EHB 2015, 19-21 Noiembrie, Iasi, Romania

[Eva EHB 2015] Oana-Diana Eva și Anca Mihaela Lazăr, Channel Selection for Motor Imagery Paradigm - an Itakura Distance based Method, International Conference on e-Health and Bioengineering, EHB 2015, 19-21 Noiembrie, Iasi, Romania

Obiectivul 1 - Studiul aspectelor referitoare la procesarea semnalelor folosind conceptul de compressed sensing – CONTINUARE în ANUL 2016

În [CLEJU 2016] se propune reformularea modelului de analiză și a problemei aferente de reconstrucție a semnalului ca un caz particular al modelului de sinteză, ceea ce permite tratarea unitară a celor două teorii și, din punct de vedere practic, utilizarea algoritmilor existenți pentru modelul de sinteză (mult mai numeroși și mai bine dezvoltati) și pentru cazul modelului de analiză.

Factorul cheie care face posibilă achiziția comprimată a semnalelor îl reprezintă existența descompunerilor rare. În termeni de teoria semnalelor, acest lucru înseamnă că semnalele respective aparțin unei uniuni de subspații de dimensiuni reduse, comparativ cu dimensiunea semnalului însuși. Această "localizare" a semnalelor într-o zonă foarte restrictivă din spațiul vectorial permite identificarea acestora dintr-un număr redus de eșantioane/măsurători, ceea ce permite în principiu posibilitatea reconstrucției.

Generalizând această interpretare, există în literatura de specialitate direcții care explorează noi *modele de raritate*, adică noi tipuri de a defini subspații sau uniuni de subspații de semnale, pentru care se poate adapta teoria achiziției comprimate. Unul dintre aceste modele inovative este reprezentat de *modelul de raritate de analiză*,

numit și *co-raritate* ("cosparsity" în limba engleză). Spre deosebire de modelul clasic de raritate, denumit *raritate de sinteză*, care prevede că un semnal x este construit dintr-un număr limitat de atomi dintr-un dicționar:

$$x = D\gamma_S, \text{ cu } \|\gamma_S\|_0 = k,$$

modelul rarității de analiză specifică faptul că semnalul x produce un vector rar atunci când este analizat cu un operator liniar Ω :

$$\gamma_A = \Omega x, \text{ with } \|\gamma_A\|_0 = N - l.$$

În acest model semnalul x este ortogonal pe l linii ale matricii Ω , așadar aparține complementului ortogonal al subspațiului generat de aceste linii. Cele două modele sunt echivalente pentru cazul în care dicționarul D este o bază, dar sunt diferite atunci când acesta este supracomplet.

Principalele rezultate sunt sumarizate mai jos.

ECHIVALENȚA CELOR DOUĂ PROBLEME DE RECONSTRUCȚIE

[Teorema 1] Problema de reconstrucție a semnalului în modelul de analiză: $x = \underset{x}{\operatorname{argmin}} \|\Omega x\|_p$ cu $\|y - Mx\|_2^2 \leq \epsilon$, pentru $\epsilon \geq 0$, este echivalentă cu reconstrucția conform modelului de sinteză cu o constrângere suplimentară:

$$x = D \underset{\gamma}{\operatorname{argmin}} \|\gamma\|_p \text{ cu } \begin{cases} \|y - MD\gamma\|_2^2 \leq \epsilon \text{ și} \\ 0 = P\gamma \end{cases} \text{ unde } D = \Omega^\dagger \text{ și liniile matricii } P \text{ formează o bază pentru spațiul nul al dicționarului } D.$$

Garanții teoretice pentru reconstrucție

Se demonstrează că două garanții teoretice din literatură pentru reconstrucția cu succes a semnalelor conform modelelor de sinteză și de analiză, prin metoda minimizării normei ℓ_1 , sunt echivalente.

[Teorema 2] Condiția reconstrucției cu succes pentru modelul de analiză: $\sup_{x:0=\Omega_A x} |\langle \Omega_A c z, \operatorname{sign}(\Omega_A c x) \rangle| < \|\Omega_A z\|_1$, $\forall z \in \operatorname{Null}(M), z \neq 0$

este echivalentă cu condiția NSP ("Null SPace Property"): $\|\eta_T\|_1 < \|\eta_{T^c}\|_1, \forall \eta \in \operatorname{Null}(D)$, pentru sistemul rezultat în urma echivalenței de mai sus.

Pentru reconstrucția semnalelor de analiză cu algoritmul Orthogonal Matching Pursuit aplicat sistemului echivalent de mai sus, se găsește o condiție suficientă pentru succes.

[Teorema 3] O condiție suficientă pentru reconstrucția cu succes folosind algoritmul Orthogonal Matching Pursuit aplicat asupra sistemului rezultat în urma echivalenței de mai sus este: $\|D_{T^c}^* r\|_\infty < \|D_T^* r\|_\infty, \forall r \in \operatorname{Span}(D_T)$.

REZULTATE PRACTICE

În urma reformulării modelului de analiză ca un caz particular al celui de sinteză, pot fi utilizați la reconstrucție algoritmi uzuali din modelul de sinteză. Acest lucru este verificat practic prin simulări, care arată faptul că rata de succes în acest fel este comparabilă cu cea a unui algoritm nativ pentru modelul de analiza, Greedy Analysis Pursuit (GAP). Rezultate sunt prezentate grafic sub forma unor grafice de fază de tranziție ("phase transition plots")



Fig. 1 Analysis-based sparse recovery from noiseless measurements: fraction of cosparsely signals reconstructed with Greedy Analysis Pursuit (a) and with synthesis-based algorithms on the synthesis equivalent system with explicit constraint ((b), (c), (d), (e), (f), (g)). White indicates 100% recovered signals, black 0%. All synthesis-based algorithms are capable of analysis recovery, many of them with performance similar to GAP.

Fig. 2 Analysis-based sparse recovery from noisy measurements: fraction of cosparsely signals reconstructed with Greedy Analysis Pursuit (a) and with synthesis-based algorithms on the synthesis equivalent system with explicit constraint ((b), (c), (d), (e), (f), (g)). White indicates 100% recovered signals, black 0%. Note SL0 slightly outperforming GAP.

Pentru achiziția fără zgomot:

Pentru achiziția cu zgomot:

CONCLUZII

Modelul de raritate de analiză poate fi considerat ca un caz particular al modelului de sinteză, cu o constrângere liniară suplimentară. Acest lucru permite tratarea unitară a celor două teorii, echivalența multor rezultate teoretice, precum și utilizarea algoritmilor uzuali de reconstrucție de sinteză și pentru cazul modelului de analiză, cu rezultate similare.

Rezultatele obținute au fost raportate în:

[Cleju 2016] N. Cleju, *Analysis Sparsity With Explicit Orthogonality Constraint*, Acta Applicandae Mathematicae, Ed. Springer, în evaluare, trimis în 28.07.2016 (revista cu factor de impact 0.853).

Obiectivul 2 (2016) - Proiectarea unor metode noi de generare a matricei de măsurători utilizata

A2.1. - Metode de optimizare a matricei de măsurători

A2.2.- Influenta matricei de măsurători în achiziția comprimata

În urma studierii literaturii din domeniul CS se constată că matricea de achiziție trebuie să îndeplinească o serie de criterii pentru a putea permite recuperarea cu succes a semnalelor achiziționate. Principiul de bază este cel al incoerenței cu baza sau dicționarul supracomplet utilizat D : o matrice de achiziție "bună" trebuie să aibă liniile (vectorii de proiecție) incoerenți cu coloanele (atomii) dicționarului D . În acest fel, un semnal cu reprezentare rară, care este compus dintr-un număr limitat de atomi, va avea o corelație nenulă cu toți vectorii de proiecție.

Acest rezultat fundamental în ceea ce privește incoerența matricei de achiziție cu dicționarul utilizat D conduce la două direcții generale în ceea ce privește construcția matricei de achiziție, îndeosebi în cazul cel mai studiat în care D este o bază ortogonală. *Prima abordare* este aceea de a utiliza matrice aleatoare, ale căror elemente sunt variabile aleatoare independente și identic distribuite (i.i.d) cu anumite distribuții, cum ar fi distribuția normală sau cea Bernoulli. Se poate demonstra că o astfel de matrice aleatoare este, cu mare probabilitate, incoerentă cu orice bază sau dicționar fixat în prealabil. *O a doua abordare* întâlnită în cercetare este de a utiliza vectori de proiecție extrași dintr-o bază ortogonală despre care se știe că este incoerentă cu cea utilizată în descompunerile rare ale semnalelor de interes. Acest lucru necesită ca baza sau dicționarul D utilizat în reprezentările rare să fie cunoscute în avans, dar poate conduce la algoritmi de reconstrucție mai rapizi, dacă vectorii de proiecție sunt selectați dintr-o bază pentru care există algoritmi rapizi de transformare.

În cazul dicționarelor supracomplete, se poate întâmpla ca atomii să prezinte corelații semnificative între ei. Acest lucru este valabil în special pentru dicționarele obținute în urma unui proces de învățare, adică optimizate pentru anumite clase de semnale. În acest caz, proprietatea de incoerență nu mai este atât de ușor de satisfăcut, și matricea de achiziție trebuie sau poate fi adaptată pentru dicționarul folosit. Pentru acest scop, au fost propuși în literatura de specialitate o serie de algoritmi propuși de cercetători precum Elad, Xu sau Duarte.

O abordare des utilizată pentru a asigura unicitatea reconstrucției rare a unui semnal se bazează pe coerența mutuală a dicționarului efectiv $D_e = PD$. Coerența mutuală a unui dicționar se definește ca fiind corelația maximă între oricare doi atomi ai dicționarului, în valoare absolută. Rezultate teoretice din literatura de specialitate arată că este de dorit a avea un dicționar cu o valoare cât mai mică a coerenței mutuale, întrucât acest lucru crește mulțimea semnalelor ce pot fi reconstruite cu succes. Ca atare, majoritatea algoritmilor de optimizare urmăresc minimizarea acestui parametru.

S-au studiat algoritmi de optimizare cei mai cunoscuți existenți în literatură, și anume: **Algoritmul Elad** (urmărește reducerea unei valori derivate din coerența mutuală, respectiv coerența mutuală mediată t , μ_t , a dicționarului efectiv D_e), **Algoritmul Xu** (urmărește să aducă dicționarul efectiv D_e cât mai aproape de un *dicționar compact echiangular* (*equiangular tight frame, ETF*), întrucât un ETF are coerența minimă dintre toate matricele cu aceleași dimensiuni), **Algoritmul Duarte-Carvajalino-Sapiro** (un algoritm diferit pentru găsirea unei matrice de achiziție optimizate pentru un dicționar fixat, precum și o metodă de a optimiza simultan matricea de achiziție și dicționarul).

În [Fira IJACSA 2016] este prezentată o analiză comparativă a rezultatelor obținute folosind mai multe tipuri de matrice de proiecție (dintre care o matrice optimizată funcție de dicționar, propusa de membrii proiectului într-un articol anterior) și un mega-dicționar pentru semnale EEG detectare comprimat. Pentru evaluarea metodei propuse am folosit setul de date de la Competition BCI III 2005 - P300 Spelling.

Ca și matrice de proiecție am testat trei tipuri de matrice, și anume: a) Matrice Bernoulli cu elemente de -1 , 0 și 1 ; b) Matrice Random; c) Matrice optimizată funcție de dicționar – produsul dintre o matrice random și transpusa dicționarului folosit la reconstructive.

Rezultatele obținute cu matrice de tip Bernoulli sunt comparabile cu cele obținute cu matrice random. Dar când se utilizează matrice optimizată funcție de dicționar, rezultatele sunt mult îmbunătățite, fiind comparabile cu rezultatele obținute cu semnale originale. Dacă se face referire strict la rata de clasificare în paradigma de spelling, atunci ratele de clasificare obținute cu matrice optimizată sunt chiar îmbunătățite pentru $CR = 10:1$ și $5:1$.

Pentru a evalua rezultatele obținute din punct de vedere cantitativ al erorilor, am folosit și PRDN. Astfel ca tot utilizarea matricei de achiziție optimizată funcție de dicționar a avut cele mai mici erori.

Astfel, cele mai bune rezultate din punct de vedere al erorilor de clasificare în cadrul paradigmei de spelling s-au înregistrat pentru compresii $CR = 5:1$ și respective $CR = 10:1$, când ratele de clasificare obținute au fost 90% respective 92% (fata de semnalul original când s-a obținut 89%). În termeni de eroare s-a obținut PRDN = 29.77 pentru o compresie de $CR = 5:1$ și PRDN = 42.32 pentru $CR = 10:1$

Concluziile sunt ca matricea de achiziție optimizată funcție de dicționarul folosit la reconstrucție conduce la rezultate îmbunătățite fata de matricele standard de tip random sau Bernoulli.

Rezultatele obținute au fost raportate în:

[Fira IJACSA 2016] Monica Fira, "Compressed Sensing of Multi-Channel EEG Signals: quantitative and qualitative evaluation with Speller Paradigm", International Journal of Advanced Computer Science and Applications (IJACSA), Vol. 7, No. 6, 2016 (revista indexata ISI - Thomson Reuters)

Obiectivul 3 (2016) - Proiectarea unor dicționare specific semnalelor medicale de tip ECG și EEG

A3.1- Dicționare particulare specific semnalelor biomedicale de tip ECG și EEG

A3.2- Particularități privind achiziția de tip CS a semnalelor biomedicale ECG cu patologii

A3.3- Particularități privind achiziția de tip CS a semnalelor de tip EEG; Dicționare specific

În general, semnalele biomedicale nu prezintă o bună sparsitate în dicționare standard de tip wavelet, DCT, DST, etc. De aceea, de cele mai multe ori în cazul semnalelor de tip EEG sau ECG se preferă construirea unui dicționare specific semnalului, care să țină cont de statistica semnalului sau de elementele repetitive din semnal.

O analiză a posibilității utilizării dicționarelor standard de tip wavelet, pentru semnale de tip ECG, este prezentată în lucrarea [FIRA EHB 2015] și se constată că pentru rate de compresie de peste 5:1 calitatea semnalului reconstruit nu mai este mulțumitoare.

Tabel 1: Rezultate de compresie și reconstrucție pentru CR = 4:1 cu dicționare wavelet [FIRA EHB 2015]

Dictionary	CR	PRD	PRDN	RMS
Beylkin	4:1	1.80	10.31	15.51
Coiflet3	4:1	1.45	8.32	12.52
Coiflet4	4:1	2.23	12.76	19.20
Coiflet5	4:1	1.89	10.83	16.30
Daubechies8	4:1	1.71	9.79	14.73
Daubechies10	4:1	2.18	12.47	18.76
Daubechies12	4:1	2.30	13.16	19.80
Haar	4:1	4.05	23.11	34.77
Vaidyanathan	4:1	1.94	11.12	16.73

A3.1- Dicționare particulare specific semnalelor biomedicale de tip ECG și EEG

Semnalul ECG este un semnal care prezintă o pseudo-ciclicitate a complexului QRS și a undelor P și T. Astfel, în cazul semnalului ECG de obicei se speculează această repetabilitate a undelor. Semnalul EEG este un semnal puțin mai complicat, deoarece nu prezintă elemente de repetabilitate clară, cel puțin aceste elemente nu se vad la o inspecție a semnalului în domeniul timp. Semnalul EEG este alcătuit în principal din undele alpha, beta, theta, și delta care au o însemnătate în interpretarea clinică a semnalului EEG, însă aceste unde sunt în domeniul frecvență. CS în varianta clasică este o tehnică de procesare de semnal care în cazul semnalelor biomedicale se aplică la achiziția semnalului, adică în domeniul timp. Acest fapt face dificilă aplicarea tehnicii de CS pe semnale de tip EEG, care se pretează bine la lucrul în domeniul frecvență.

A3.2- Particularități privind achiziția de tip CS a semnalelor biomedicale ECG cu patologii

Plecând de la semnalul ECG segmentat în cicluri cardiace, în [Fira ICT4AWE 2016] am dezvoltat două metode de construire a dicționarelor specific pacientului și anume:

- dicționar format din bătăi cardiace cu unda R centrată;
- dicționar cu unda R necentrată.

Dicționar specific semnalului ECG format din bătăi cardiace cu unda R centrată - Fiecare segment ECG care conține unda P, complexul QRS și unda T, altfel spus, fiecare ciclu cardiac a fost reeșantionat pe 301 eșantioane, astfel încât, toate patternurile cardiace să aibă aceeași dimensiune, fiind astfel posibil să se creeze un dicționar specific pentru semnale ECG. Obținerea patternurilor cardiace cu reeșantionarea și centrarea undei R folosește metoda de segmentare, urmată de poziționarea amplitudinii undei R pe proba 151 și reeșantionare din partea stângă a undei R, respectiv din dreapta, pe 150 probe. Astfel, se va avea ca rezultat patternuri cardiace de dimensiune 301 care vor avea întotdeauna unda R poziționată în mijloc.

Dicționar specific semnalului ECG format din bătăi cardiace cu unda R centrată – Ciclurile cardiace extrase din semnalul ECG (care conțin unda P, complexul QRS și unda T) sunt reeșantionate la 301 eșantioane.




Fig. 3 – Patternuri cardiac cu unda R centrată




Fig. 4 – Patternuri cardiac fără unda R centrată

A3.3 Particularități privind achiziția de tip CS a semnalelor de tip EEG; Dicționare specific

În lucrarea [Fira ACHI 2016] sunt propuse două tipuri noi de dicționare specific semnalului EEG și sunt prezentate rezultatele utilizării acestor dicționare.

Dicționare temporal specific semnalului EEG - Plecând de la rezultatele din [Fira AECE 2012] am construit dicționare din segmente EEG de pe anumite canale predefinite, de la același moment de timp cu înregistrarea EEG comprimată. Astfel, pentru fiecare moment de timp vom avea câte un dicționar. Aceste dicționare sunt construite din semnalul EEG de la canalele care se achiziționează în mod clasic, iar acest dicționar este același pentru toate canalele achiziționate comprimat.

Dicționare specific canalului - Pentru fiecare canal EEG este construit câte un dicționar, atomii dicționarului fiind de fapt segmente EEG din setul de antrenare. Pentru datele folosite în lucrarea [Fira ACHI 2016] pentru datele culese pe 64 de canale vom avea 64 de dicționare. Astfel, fiecare dicționar a fost alcătuit din câte 2*85 atomi, adică pentru fiecare epocă din setul de antrenare am ales aleator 2 segmente de semnal EEG și le-am declarat atomi ai dicționarului.

Plecând de la ideea de aliniere a atomilor, s-a urmărit realizarea unei alinieri pentru semnalul EEG culese în timpul paradigmei de spelling. Astfel alinierea posibilă pentru EEG este bazată pe momentul de apariție al stimulului. Astfel, în [Fira COMM 2016] sunt testate două metode diferite de aliniere și construire a dicționarului necesar decompresiei, și anume:

- dicționar cu atomi de dimensiune 1 sec cu unda P300 și atomi fără P300 (notați NonP300);
- dicționar cu atomi formați din segmente EEG aliniate funcție de stimulul din paradigma de spelling.

Dicționar cu segmente EEG aliniate funcție de stimulul din paradigma de spelling [Fira COMM 2016]

– Acesta este un tip de dicționar particularizat paradigmei de spelling pe baza potențialului P300.

În acest caz dicționarul folosit la reconstrucție este alcătuit din segmente EEG care durează cât este iluminată o linie sau o coloană (adică cât durează un stimul) și perioada dintre aprinderi. Semnalele astfel segmentate sunt aliniate, începând toate cu perioada cât durează stimulul și au durată de 42 de eșantioane, adică 175 msec. În felul acesta unda P 300 nu apare tot timpul în aceeași regiune. Achiziția comprimată se realizează pe segmente EEG de dimensiune de 42 de eșantioane.

Această metodă are avantajul că poate fi făcută în timp real, necesitând doar adnotarea legată de momentul de start al stimulului. Un alt avantaj al acestei metode este faptul că prin concatenarea semnalelor reconstruite se obține semnalul EEG, adică nu este necesară o altă etapă suplimentară de reconstruire.

Dicționar specific paradigmei de spelling conținând atomi de dimensiune 1 sec, cu unda P300 și atomi NonP300 [Fira COMM 2016] - În acest caz dicționarul folosit la reconstrucție este alcătuit din atomi cu unda P300 aliniată și atomi fără unda P300. La alinierea undei P300 am folosit modalitatea de segmentare a semnalului EEG bazată pe stimul, sugerată în [Blankertz].

Etapa Construirea dicționarului: pentru toate cele 64 de canale, am extras și normalizat toate eșantioanele dintre 0 și 1 sec posterior față de începutul unei intensificări. Am obținut astfel, dintr-un set de antrenare de 85 de caractere constituite într-o bază de date de $12 * 15 * 85 = 15300$ semnale de 240 de eșantioane pentru fiecare canal. Aceste 15 300 semnale (pentru fiecare canal) sunt apoi împărțite în semnale cu unda P300 și fără această undă, adică NonP300, rezultând două subseturi, subsetul de 2550 semnale cu P300 și subsetul de 12750 semnale NonP300. Din acestea două subseturi am selectat aleator un număr stabilit de semnale care reprezintă atomii dicționarului.

Mega-dicționar EEG specific pacientului – în [Fira SOMET 2016 și Fira IJACSA 2016] am testat posibilitatea de a construi un mega-dicționar universal construit din segmente EEG de la toate cele 64 de canale EEG achiziționate în mod clasic. Astfel, au fost selectate pentru fiecare canal trei atomi, care constă în segmente EEG de pe canalul corespunzător, astfel încât am obținut un dicționar format din $3 \times 64 = 192$ atomi. Dimensiunea dicționarului este 192×240 , pentru că fiecare atom are dimensiunea 240. Pentru construcția dicționarului, am folosit semnale de antrenare din paradigma de Spelling. Testarea metodei a fost făcută folosind semnale de testare EEG care constau în semnale EEG achiziționate comprimat.

Mega-dicționar EEG universal – în [Fira SOMET 2016, Fira IJACSA 2016 și Fira Suceava 2016] am testat și posibilitatea construirii unui mega-dicționar specific semnalului EEG care să fie universal valabil, adică să nu depindă de pacient. Pentru aceasta, dicționarul a fost construit din bucăți din semnalele de antrenare din cadrul paradigmei de spelling, iar semnalele de test au fost comprimate utilizând achiziția comprimată și apoi reconstruite pe baza acestui dicționar. Testarea nedependentei de pacient s-a făcut având grijă ca dicționarul să fie construit de la semnalele provenind de la pacientul notat cu A și testarea metodei de achiziție comprimată să se facă pe semnalele de test de la pacientul B.

Rezultatele obținute au fost raportate în:

[Fira EHB 2015] Fira Monica, Applications of Compressed Sensing: Compression and Encryption, International Conference on e-Health and Bioengineering, EHB 2015, 19-21 Noiembrie, Iasi, Romania (indexata *IEEE Xplore*)

[Fira ICT4AWE 2016] Monica Fira, Liviu Goras, Victor-Andrei Maiorescu and Mihaela Catalina Luca, „Compressed Sensing and Clasification of Cardiac Beats Using Patient Specific Dictionaries”, International Conference of Information and Communication Technologies for Ageing Well and e-Health - ICT4AWE2016, Roma, Italia, 21-22 aprilie 2016

[Fira ACHI 2016] Monica Fira, Liviu Goras, Victor-Andrei Maiorescu, „The Analysis of the Specific Dictionaries for Compressive Sensing of EEG Signals”, International Conference on Advances in Computer-Human Interactions - ACHI 2016, Veneția, Italia, 24-28 aprilie 2016

[Fira COMM 2016] Monica Fira, Liviu Goras, „On Compressed Sensing for EEG Signals - Validation with P300 Speller Paradigm”, International Conference on Communications – COMMS 2016, Bucharest, Romania, 9-11 iunie 2016, DOI: 10.1109/ICComm.2016.7528296 (indexata *IEEE Xplore*)

[Fira IJACSA 2016] Monica Fira, “Compressed Sensing of Multi-Channel EEG Signals: quantitative and qualitative evaluation with Speller Paradigm”, International Journal of Advanced Computer Science and Applications (IJACSA), Vol. 7, No. 6, 2016 (revista indexata ISI - Thomson Reuters)

[Fira SOMET 2016] Monica Fira, Andrei Maiorescu, "P300 spelling and EEG compressed sensed based on a universal megadictionary", International Conference on Intelligent Software Methodologies, Tools and Techniques - SOMET 2016, Larnaca, Cipru, 12-14 septembrie 2016 (Volume 286: New Trends in Software Methodologies, Tools and Techniques, Series Frontiers in Artificial Intelligence and Applications, IOS press, DOI 10.3233/978-1-61499-674-3-203, pp: 203 - 212)

Obiectivul 4 (2016) - Metode de optimizare a matricei de măsurători și a dicționarelor utilizate la reconstrucție

A4.1.- Metode de optimizare a matricei de măsurători

A4.2.- Metode de optimizare a dicționarelor specifice de tip ECG și EEG

A4.1.- Metode de optimizare a matricei de măsurători

Algoritm îmbunătățit pentru optimizarea matricei de achiziție

În cadrul acestei activități am prezentat o posibilitate de îmbunătățire a algoritmilor prezentați în cadrul **Obiectivului 2 Activitatea A.2.1.** constă în rezolvarea următoarei clase probleme de optimizare:

$$\begin{aligned} \min \quad & \|G_e - G\|_p \\ \text{s. t.} \quad & G_e \geq 0 \\ & \text{rank}(G_e) = m \\ & \text{diag}(G_e) = 1 \end{aligned}$$

Această formulare reprezintă o generalizare și o îmbunătățire a primilor trei algoritmi prezentați mai sus, din următoarele considerente:

- la fel ca și algoritmul Duarte, și spre deosebire de algoritmi Elad și Xu, algoritmul propus urmărește minimizarea diferenței $\|G_e - G\|_p$, și nu a diferenței $\|G_e - I_N\|_p$. Motivul îl reprezintă faptul că atomii dicționarului original D pot prezenta corelații semnificative, reflectate prin valori mari în matricea G . În urma achiziționării cu matricea de achiziție, dicționarul efectiv D_e va avea corelații și mai mari, care trebuie micșorate. Procesul de micșorare a corelațiilor lui G_e nu trebuie însă să țină dincolo de corelațiile prezente inițial în matricea G , întrucât acestea erau prezente încă în dicționarul inițial și nu au survenit în urma procesului de achiziție;
- la fel ca în cazul algoritmilor Elad și Xu, și spre deosebire de algoritmul Duarte, se menține condiția ca diagonala principală a matricei G_e să fie egală cu unitatea, ceea ce înseamnă că atomii dicționarului efectiv D_e trebuie să fie normați. Acest lucru este esențial în toți algoritmi care urmăresc sub o formă sau alta minimizarea coerenței mutuale; altfel, produsul scalar a doi atomi cu norma mai mică decât 1 va fi mai mic decât valoarea reală a corelației dintre ei. Adăugarea acestei constrângeri schimbă fundamental natura algoritmului Duarte, nemaifiind posibilă o soluție simplă în formă explicită. Soluția se va obține printr-un algoritm numeric iterativ;
- formularea algoritmului propus reprezintă o generalizare a algoritmilor precedenți. Pentru $p = 2$, problema se reduce la algoritmul Duarte cu condiția suplimentară de normare a atomilor, iar pentru $p = \infty$, ea devine similară cu algoritmi Elad și Xu, dar cu minimizarea diferenței $\|G_e - G\|_p$ în loc de $\|G_e - I_N\|_p$, din motivele expuse mai sus.

Din aceste considerente, optimizarea matricei de achiziție prin rezolvarea acestei probleme de optimizare reprezintă o soluție mai robustă decât algoritmi din literatură prezentați anterior, combinând avantajele acestora.

Această tip de problemă de optimizare poartă numele de *cea mai apropiată matrice de corelație de rang redus (Rank Constrained Nearest Correlation Matrix, RCNCM)* [Cleju 2014], și reprezintă o problemă studiată îndeaproape în literatura de specialitate [@PieterszRankRedCorr; @GaoMajPen], cu aplicații în multiple domenii științifice. Pentru $p = 2$, se poate utiliza algoritmul din [@GaoMajPen], bazat pe penalizarea valorilor proprii și majorizare. Această variantă este denumită în continuare RCNCM. Pentru $p = \infty$, se pot folosi algoritmi similari cu algoritmul Elad și Xu, dar în care se minimizează iterativ diferența $G_e - G$. Aceștia vor fi numiți Elad-G și Xu-G. Diferența între RCNCM și Elad-G / Xu-G o reprezintă norma care este folosită pentru calcularea distanței dintre matrice, ℓ_2 , respectiv ℓ_∞ .

Au fost teste performanțele celor patru algoritmi prezentați mai sus în patru condiții diferite:

1. dicționar generat aleator, semnale sintetice perfect rare;
2. dicționarul este o matrice ortogonală aleatoare cu ușoare diferențe în ceea ce privește norma atomilor, semnalele sunt perfect rare;
3. dicționar real obținut prin învățare cu algoritmul K-SVD din date ce reprezintă porțiuni de imagini, semnalele sunt perfect rare;
4. dicționar real obținut prin învățare cu algoritmul K-SVD din date ce reprezintă porțiuni de imagini, semnalele sunt porțiuni reale de imagini.

Algoritmi testați sunt următorii: matrice de achiziție aleatoare cu elemente independente și identic distribuite din distribuția normală; algoritmul Elad; algoritmul Xu; algoritmul Duarte; algoritmul Elad-G; algoritmul Xu-G; algoritmul RCNCM.

Pentru reconstrucție se utilizează doi algoritmi frecvent utilizați în literatură:

- *Orthogonal Matching Pursuit* [@OMPPati1993], criteriul de terminare fiind eroarea reziduală mai mică decât un prag ϵ , numit în continuare $OMP-\epsilon$. Pragul este ales la 10^{-9} pentru semnalele sintetice perfect rare, și 10^{-3} pentru semnalele provenind din date reale.
- minimizarea normei ℓ_1 a soluției, printr-o problemă de programare liniară, notat în continuare BP (de la termenul englezesc *Basis Pursuit*).

Dimensiunea semnalelor este $n = 64$ și dicționarul cuprinde $N = 256$ atomi. Rezultatele prezentate sunt media a 10 rulări diferite cu inițializări aleatoare diferite.

În urma simulărilor (prezentate mai detaliat în raportul extins) concluzia este ca optimizarea matricei de achiziție este o soluție viabilă atunci când dicționarul utilizat prezintă corelații semnificative între atomi, cum este cazul dicționarelor supracomplete învățate sau construite din semnale reale. Dintre cei patru algoritmi de optimizare utilizați, performanțele cele mai bune au fost oferite de algoritmul RCNCM, urmat îndeaproape de algoritmul Duarte.

A4.2.- Metode de optimizare a dicționarelor specifice de tip ECG și EEG

În multe cazuri, semnalele de interes nu au reprezentări suficient de rare în baze sau dicționare uzuale (cum ar fi Fourier, wavelet etc.). Există algoritmi de optimizare a dicționarelor supracomplete în raport cu un anumit set de date de antrenare, cu scopul de a crește raritatea descompunerilor.

Notând cu X matricea care cuprinde semnalele de test x_i (pe coloane), cu D dicționarul și cu Γ matricea descompunerilor rare γ_i ale semnalelor, problema optimizării dicționarului poate fi formulată ca $\arg \min_{D, \Gamma} \sum_i \|x_i - D\gamma_i\|_2^2 + \lambda \|\gamma_i\|_0$. Cu alte cuvinte, se caută dicționarul D care permite ca semnalele să aibă descompuneri rare (norma ℓ_0 cât mai mică) de acuratețe ridicată (eroarea de reprezentare cât mai mică). Întrucât prezența normei ℓ_0 face ca problema să fie NP-hard, aceasta nu poate fi rezolvată în mod direct, în literatura de specialitate fiind propuși un număr de algoritmi alternativi.

În general, acești algoritmi pornesc de la un dicționar inițial, care este apoi actualizat în mod iterativ, în două etape:

1. având dicționarul la momentul k , D_k , se obțin descompunerile rare γ_i ale unui semnal sau ale mai multor semnalelor;
2. pe baza descompunerilor rare ale semnalelor, se actualizează atomii dicționarului cu scopul de a reduce eroarea de aproximare sau de a crește raritatea descompunerii.

În cele ce urmează sunt prezentați o serie de algoritmi uzuali întâlniți în literatură.

Au fost studiați mai mulți algoritmi de optimizare, și anume: **Metoda direcțiilor (Method Of Directions, MOD)**, **Algoritmul K-SVD**, **Algoritmul de învățare SPAMS**

Baze și dicționare pentru semnale ECG

Condiția esențială pentru reconstrucția semnalelor ECG dintr-un număr redus de proiecții aleatoare este, fără îndoială, ca semnalele respective să aibă descompunere rară în dicționarul folosit la reconstrucție. De aceea, este important a se investiga care tip de dicționar este mai potrivit pentru semnale ECG, în sensul că acestea au descompuneri mai rare, permițând așadar o reconstrucție mai bună.

Trebuie menționat că semnalele reale nu au o descompunere rară în mod exact. În realitate, descompunerea unor semnale reale poate fi considerată mai bine ca fiind „compresibilă”, în sensul ca este compusă din puțini atomi cu coeficienți semnificativi, restul atomilor având coeficienți de obicei nenuli dar de valoare mică. Acuratețea reconstrucției depinde atât de numărul atomilor semnificativi, cât și de energia conținută de atomii nesemnificativi. Din acest punct de vedere, o descompunere „mai bună” într-un dicționar poate însemna fie o descompunere cu un număr mai redus de coeficienți semnificativi, fie o descompunere cu valori mai mici ale coeficienților nesemnificativi. Este dificil a trasa o linie de demarcație între aceste două fenomene, importanța lor în succesul reconstrucției fiind greu de cuantificat separat. De aceea, le vom trata în mod unitar, considerând că un dicționar este mai bun cu cât aproximarea semnalului cu un număr redus de atomi se îmbunătățește, formulare care acoperă ambele fenomene.

În continuare, s-a investigat calitatea unui număr mare de dicționare, cuprinzând majoritatea bazelor *wavelet* ortogonale disponibile în pachetul software *WaveLab* versiunea 8.50: Haar, Beylkin, Coiflet 3, Coiflet 4, Coiflet 5, Daubechies 6, Daubechies 8, Daubechies 10, Daubechies 12, Daubechies 14, Symmlet 5, Symmlet 6, Symmlet 7, Symmlet 8, Symmlet 9, Vaidyanathan, Battle 1, Battle 3, Battle 5.

În afară de aceste baze *wavelet* standard, s-au considerat și trei metode de a genera baze particularizate pe baza semnalelor ECG:

1. dicționar alcătuit prin selecția aleatoare a unor segmente de semnal ECG din setul de test;
2. dicționar obținut cu algoritmul de învățare SPAMS (ODT) [Mairal2009DL];
3. dicționar obținut cu algoritmul de învățare K-SVD [Aharon2006KSVD].

Calitatea descompunerilor în aceste dicționare se evaluează prin calcularea erorii medii de aproximare a semnalelor atunci când se păstrează doar primii k atomi semnificativi, unde valoarea lui k variază de la 1 (descompunere extrem de rară) la 25 (nu foarte rară). Pentru bazele ortogonale, aproximările cu k atomi se obțin simplu prin aplicarea transformatei *wavelet* respective asupra semnalelor, păstrând apoi doar cei mai mari k coeficienți. Pentru cele trei baze suplimentare care nu sunt ortogonale această abordare nu este posibilă, aproximările cu k atomi fiind găsite prin algoritmul Orthogonal Matching Pursuit [OMPpati1993, OMPMallat1997].

Eroarea medie a aproximărilor cu k atomi pentru cele mai relevante baze ortogonale și pentru bazele particularizate este prezentată în Fig.5.

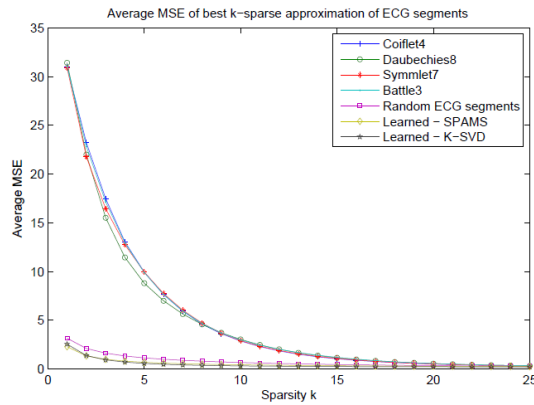


Fig.5: Eroarea medie de aproximare cu k atomi a semnalelor ECG

Rezultatele indică în mod clar că bazele particularizate pentru semnale ECG oferă performanțe mai bune decât cele *wavelet* standard în ceea ce privește aproximarea semnalelor ECG.

Achiziția comprimată a semnalelor ECG utilizând un dicționar particularizat

Achiziția comprimată a semnalelor este o soluție propusă în literatura de specialitate pentru a reduce efortul de calcul la achiziția semnalelor ECG cu dispozitive mobile, [EpflECG], dar de obicei sunt utilizate dicționare *wavelet* standard. Întrucât comparația de mai sus indică faptul că dicționarele particularizate permit reprezentări mai rare ale semnalelor, este de așteptat ca un astfel de dicționar să conducă la performanțe mai bune în reconstrucția semnalelor ECG achiziționate comprimat.

În cazul unui dicționar supracomplet, este dificil de estimat numărul optim de atomi: un număr mai mare de atomi înseamnă posibilitatea de a avea reprezentări mai rare ale semnalelor, dar cu prețul unui vector de descompunere de dimensiune mai mari (deci mai mulți coeficienți trebuie reconstituiți). Se cunoaște din literatură faptul că numărul de măsurători necesar pentru reconstrucția cu succes a unui vector rar N -dimensional este de ordinul $\mathcal{O}(k \log(N/k))$, așadar crește logaritmically odată cu dimensiunea vectorului, N . Prin urmare, valoarea optimă a lui N rezultă dintr-un compromis între puterea de reprezentare rară a dicționarului (necesită N mare) și posibilitatea reconstrucției semnalului (necesită N mic).

Pentru a estima acest lucru, în cele ce urmează este estimată acuratețea reconstrucției semnalelor ECG achiziționate comprimat cu m măsurători aleatoare, folosind dicționare particularizate de dimensiuni $256 \times N$ unde N este, pe rând, 256, 320, 384, 448, 512, 640 sau 768. Dicționarele sunt obținute prin trei metode diferite:

- selectarea aleatoare a N segmente ECG din setul de antrenare;
- algoritmul SPAMS de învățare a dicționarului;
- algoritmul K-SVD de învățare a dicționarului.

Acuratețea reconstrucției este măsurată prin valoarea PRDN, des întâlnită în literatură, definită ca:

$$PRDN(x, \hat{x}) = \frac{\|x - \hat{x}\|_2^2}{\|x - \mu_x\|_2^2} \times 100, \text{ unde } \mu_x \text{ reprezintă componenta continuă a lui } x.$$

Pentru reconstrucția semnalelor se utilizează metoda minimizării ℓ_1 , prin pachetul software ℓ_1 -magic pentru Matlab.

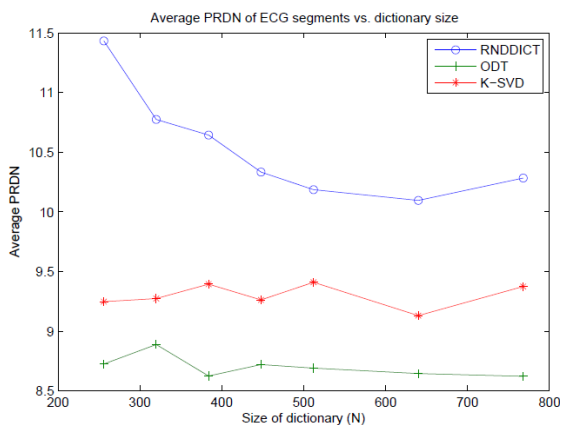


Fig. 6: Influența dimensiunii dicționarului asupra erorii PRDN

În ceea ce privește algoritmii de învățare a dicționarului și dimensiunea optimă a acestuia, Fig. 6 prezintă valorile PRDN medii obținute cu dicționare de dimensiuni diferite, obținute cu toate cele trei metode de învățare. Se observă că algoritmul SPAMS (marcat în legendă ca ODT – *Online Dictionary Training*) oferă cele mai bune rezultate, și pentru acesta dimensiunea dicționarului nu este foarte importantă (pentru plaja de valori testată). Pentru ceilalți algoritmi, o dimensiune mai mare a dicționarului este ușor benefică.

Bibliografie

[Cleju 2014] N. Cleju, Optimized projections for compressed sensing via rank-constrained nearest correlation matrix, Applied and Computational Harmonic Analysis, Volume 36, Issue 3, May 2014, Pages 495–507.

Obiectivul 5 (2016) - Proiectarea de aplicații ce vor utiliza dicționarelor particulare în prelucrarea semnalelor ECG

A5.1.- Clasificarea semnalelor ECG în spațiu comprimat

A5.2.- Analiza posibilităților de recunoaștere și clasificare a semnalelor ECG cu patologii folosind CS

Am investigat avantajele oferite de achiziția comprimată în aplicații de monitorizare a pacienților cu diferite afecțiuni cardiace, utilizând conceptul de “compressed sensed” pe semnalul ECG. Utilizând dicționare specific pacientului am analizat posibilitatea achiziției comprimate a băților cardiace, urmata de clasificarea acestor băți comprimate în una din două clase, și anume, băți normale sau băți modificate (adică patologice). De asemenea, câteva tipuri de matrice de proiecție, și anume, matrice aleatoare cu distribuție Gaussiană, matrice de tip Bernoulli cu elemente de -1, 0, 1 și matrice optimizată funcție de dicționarul folosit la reconstructive. S-au analizat și două tipuri de dicționare specific semnalului ECG (prezentate și la Obiectivul 3, Activitatea 3.2.), și anume, dicționar cu unda R centrată și dicționar fără unda R centrată.

Plecând de la rezultatele în legătura cu clasificarea băților cardiace achiziționate comprimat, prezentate în lucrarea [FIRA ISSCS 2011] și rezultatele privind dicționare specific pacientului prezentate în [Fira 2011 b, Fira 2013], în [FIRA ROMA 2016] s-a propus o nouă metodă de utilizare a conceptului de “compressed sensed” care să îmbine aceste rezultate anterioare. Scopul urmărit a fost de a dezvolta și implementa metoda de achiziție comprimată a semnalului ECG, completat de detecția băților cardiace anormale pentru a transmite aceste băți la un centru de supraveghere și monitorizare a persoanelor cu afecțiuni cardiace.

Împărțirea problemei propuse a se rezolva în subprobleme este următoarea:

- construirea de dicționare specific pacientului;
- clasificarea băților cardiace;
- achiziția comprimată a băților cardiace anormale;
- transmiterea băților anormale la un centru de supraveghere / înregistrarea acestor băți pentru o analiza ulterioară de către personal calificat;
- reconstruirea băților achiziționate comprimat.

Plecând de la semnalul ECG segmentat în cicluri cardiace, am dezvoltat două metode de construire a dicționarelor specific pacientului și anume:

- dicționar format din băți cardiace cu unda R centrată;
- dicționar cu unda R necentrată.

Se știe ca rezultatele achiziției comprimate sunt influențate într-o oarecare măsură și de tipul de matrice folosit la achiziție. De aceea, am analizat influența matricei de compresie asupra achiziției comprimate cât și asupra clasificării băților cardiace comprimate. Astfel, am testat trei tipuri de matrice, și anume:

- matrice random;
- matrice Bernoulli;
- matrice optimizată funcție de dicționar [Cleju] - (produsul dintre o matrice random și transpusa dicționarului folosit la reconstrucție).

Tipul de clasificator utilizat pentru a clasifica bățile cardiace este KNN (*the k-Nearest Neighbors – cel mai apropiat K vecin*). Am optat pentru acest tip de clasificator deoarece este un clasificator simplu de implementat chiar și în aplicații practice hardware. Pentru rezultate îmbunătățite se pot alege clasificatori mai performanți, însă rezultatele oferite de acest clasificator ne-a mulțumit pe deplin astfel încât sa-l alegem chiar și în viitor în implementări hardware.

Clasificatorul KNN a fost antrenat cu băți cardiace normale și anormale, uniform repartizate ca număr pe ambele clase. Aceste băți folosite la antrenarea clasificatorului au fost extrase din dicționarul construit pentru achiziția comprimată.

Pentru reconstrucție am utilizat algoritmul BP (Basis Pursuit) pentru a determina coeficienții necesari reconstrucției semnalului ECG inițial. Dicționarele testate, adică dicționarul cu unda R centrată și dicționarul fără unda R centrată au fost alcătuite din 700 de patternuri cardiac.

Majoritatea metodelor propuse de diferiți autori nu fructifica natura cvasi-periodica a semnalului ECG și particularitățile specific pacientului. De aceea, am dezvoltat, implementat și testat o metoda noua care tine cont de ambele avantaje, și anume, se lucrează cu băți cardiace (NU cu semnal ECG așa cum este el cules) și în al doilea rând, dicționarele cu care se lucrează sunt alcătuite din cicluri cardiace provenind de la subiectul pe care se face achiziția.

Astfel, primele 6 minute din înregistrare sau înregistrări anterioare de la același subiect (dacă există) se folosesc pentru a construi dicționarul necesar la reconstrucție. După ce s-a construit dicționarul, abia apoi începe monitorizarea băților cardiace, clasificarea acestora în normale sau patologice și achiziția comprimată a băților cardiace acolo unde este cazul (adică acolo unse se detectează o anormalitate cardiacă).

Pentru implementarea metodei propuse este nevoie de un o zona de memorie tampon.

Din eşantioanele ECG înregistrate și care sunt stocate în zona tampon pentru procesare, un ciclu cardiac complet este extras prin detectarea undei R, urmată apoi de segmentarea semnalului ECG între mijlocul a două

interval RR consecutive. Pentru cazul când se folosesc cicluri cardiac fără unda R centrata, segmentele extrase sunt reeșantionate pe 301 eșantioane. Pentru cazul cu unda R centrată, fiecare segment ECG este împărțit în două de unda R, și anume partea din fără unei R și partea de după unda R, fiecare din aceste părți fiind reeșantionate la 150 de eșantioane.

Un ciclu cardiac este reeșantionat la o dimensiune fixă de 301 eșantioane, opțional cu unda R aliniată la mijlocul segmentului.

O schemă bloc a metodei propuse este prezentată în Fig 7.




Fig. 7 – Principiul metodei de achiziție comprimată, specific metodei ECG

Pentru a evalua distorsiunile dintre semnalul original și semnalul reconstruit am folosit PRD și varianta acestuia normalizată (PRDN)

$$PRD\% = 100 \sqrt{\frac{\sum_{n=1}^N (x(n) - \tilde{x}(n))^2}{\sum_{n=1}^N x^2(n)}} \quad PRDN\% = 100 \sqrt{\frac{\sum_{n=1}^N (x(n) - \tilde{x}(n))^2}{\sum_{n=1}^N (x(n) - \bar{x})^2}}$$

unde $x(n)$ și $\tilde{x}(n)$ sunt eșantioanele originale și respectiv ale semnalului reconstruit, iar \bar{x} este media valorilor semnalului original iar N este lungimea ferestrei pe care se calculează PRD.

Pentru evaluarea compresiei am folosit rata de compresie (CR) definit ca raportul dintre numărul de biți necesari semnalului original și semnalului comprimat,

$$CR = \frac{b_{orig}}{b_{comp}}$$

unde b_{orig} și b_{comp} reprezintă numărul de biți necesari reprezentării semnalului original și respective semnalului comprimat.

Pentru a testa metoda propusa s-au folosit 14 înregistrări ECG publice din baza de date MIT-BIH Arrhythmia.

Tabelul 2 prezintă rezultatele medii obținute pe 14 înregistrări pentru o compresie de CR = 15:1 și pentru trei tipuri de matrice de achiziție folosite.

Tabel 2: Rezultate medii obținute pe 14 înregistrări

Projection matrix	CR	Avg. PRD	Avg. PRDN	Classification rate
Patient specific dictionary with un-centered R-wave				
Gaussian distribution Random*Dict†(20*301)	15:1	0.78	11.98	92.24%
0 and 1 (with controlled arrangement)(20*301)	15:1	0.94	16.06	84.71%
Gaussian distribution Random (20*301)	15:1	0.82	13.82	91.14%
Patient specific dictionary with centered R-wave				
Gaussian distribution Random*Dict†(20*301)	15:1	0.51	9	93.41%
0 and 1 (with controlled arrangement)(20*301)	15:1	0.71	12.4	88.06%
Gaussian distribution Random (20*301)	15:1	0.72	12.51	89.70%

În Tabelul 3 sunt prezentate rezultatele pentru reconstrucția patternurilor cardiac cu și fără unda R centrată, pentru compresii de CR = 4:1, 10:1 și 15:1 pentru matrice de achiziție optimizată funcție de dicționar.

Tabel 3: Rezultate medii obținute pe înregistrarea 117 pentru CR = 4:1, 10:1 și 15:1 pentru matrice optimizată funcție de dicționar

Projection matrix	CR	Avg. PRD	Avg. PRDN
Patient specific dictionary with un-centered R-wave			
Gaussian distribution Random*Dict†(20*301)	4:1	0.19	4.36
	10:1	0.29	6.77
	15:1	0.38	8.82
Patient specific dictionary with centered R-wave			
Gaussian distribution Random*Dict†(20*301)	14:1	0.19	4.54
	10:1	0.29	6.80
	15:1	0.36	8.43

În Tabelul 4 sunt prezentate rezultatele clasificării ciclurilor cardiac obținute pe semnalele reconstruite.

Tabel 4: Rezultatele pentru CR = 15:1

PPV_class1%	PPV_class2%	k-Nearest Neighbors	ID_ECG	Total Classification rate %	PPV_class1%	PPV_class2%	k-Nearest Neighbors	ID_ECG	Total Classification rate %
PPV = positive predictive value				PPV = positive predictive value					
99.9	96.4	1	100	99.8	51.4	83.5	1	201	59.0
99.9	85.7	2		99.6	65.7	77.1	2		68.4
99.6	92.9	3		99.4	61.3	79.9	3		65.7
88.8	100.0	1	101	88.8	49.3	80.0	1	202	50.3
99.4	100.0	2		99.4	66.2	75.0	2		66.5
96.4	100.0	3		96.4	57.5	80.0	3		58.2
100.0	99.5	1	102	99.5	97.3	94.8	1	203	50.3
100.0	97.6	2		97.6	98.6	90.5	2		66.5
100.0	97.7	3		97.7	97.7	94.4	3		58.2
68.8	99.1	1	104	98.0	98.7	93.3	1	210	98.2
75.0	96.9	2		96.2	99.6	87.7	2		98.5
56.3	99.8	3		98.2	99.2	89.0	3		98.3
95.4	87.5	1	105	95.3	97.2	100.0	1	212	99.0
98.2	87.5	2		98.1	98.4	99.7	2		99.2
97.5	87.5	3		97.4	96.9	100.0	3		98.9
99.6	97.7	1	106	98.9	0.0	100.0	1	217	82.9
99.9	95.7	2		98.4	0.0	100.0	2		82.9
99.9	95.7	3		98.4	0.0	100.0	3		82.9
100.0	100.0	1	119	100.0	90.0	62.9	1	219	89.3
100.0	100.0	2		100.0	99.3	54.3	2		98.1
100.0	100.0	3		100.0	93.8	60.0	3		92.8

Tabelul 5 conține rezultatele medii pe toate cele 14 înregistrări, precum și rezultate pentru înregistrarea 117, rezultate obținute atât de noi cât și cele raportate în [Polania 2011 a, b] și [Mamaghanian 2011].

Tabel 5: Rezultate medii obținute pe 24 de înregistrări, respective pe înregistrarea 117

	Record / Ave.	CR	Avg. PRD	Avg. PRDN
Other Compression Algorithms				
POLANIA [Polania 2011a,b]	117	8:1	2.18	Notspec.
POLANIA [Polania 2011a,b]	117	10:1	2.5	Notspec.
MAMAGHANIAN [Mamaghanian et al. 2011] for before and after inter-packet redundancy removal and Huffman coding	Ave. for 14 recs	4:1 (75)	Before Huffman 1.5:1 (35)	
		10:1 (90)	After Huffman 1.2:1 (15)	
			Before Huffman > 1.8:1 (45)	
		15:1 (93)	After Huffman > 1.8:1 (45)	
			Before Huffman > 1.8:1 (45)	
			After Huffman > 1.8:1 (45)	

Astfel, am proiectat, dezvoltat și testat posibilitatea de a construi dicționare specifice pacienților pentru a achiziționa comprimat bătăi cardiace care sunt clasificate de un clasificator de tipul KNN ca fiind anormale. Trebuie remarcate câteva aspecte foarte importante, și anume:

- rezultatele foarte bune de clasificare în două clase (normal și anormal), altfel spus, de detectie a batailor cardiace anormale achiziționate comprimat;
- posibilitatea reconstruirii bătăilor cardiace achiziționate comprimat;
- complexitate mica a calculelor în etapa de achiziție comprimate;
- un clasificator de tip KNN pentru partea de clasificare, ceea ce înseamnă de asemenea o complexitate mica de calcule.

Ținând cont de toate aceste aspect se poate considera că lucrarea de față este un prim pas important în implementarea software a unui algoritm de monitorizare și management a situațiilor de criză cardiacă.

Bibliografie

[Mamaghanian 2011] Mamaghanian H., Khaled N., Atienza D., Vanderghyest P., "Compressed Sensing for Real-Time Energy-Efficient ECG Compression on Wireless Body Sensor Nodes", IEEE Trans Biomed Eng. 2011 Sep;58(9):2456-66;

[Polania 2011a] Polania L. F., Carrillo R. E., Blanco-Velasco M., E. Barner K., "ECG compression via matrix completion", EUSIPCO 2011;

[Polania 2011b] Polania L. F., Carrillo R. E., Blanco-Velasco M., E. Barner K., "Compressed sensing based method for ECG compression", 2011 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), 2011.

Rezultatele obținute au fost raportate în:

[Fira ICT4AWE 2016] Monica Fira, Liviu Goras, Victor-Andrei Maioreescu and Mihaela Catalina Luca, „Compressed Sensing and Clasification of Cardiac Beats Using Patient Specific Dictionaries”, International Conference of Information and Communication Technologies for Ageing Well and e-Health - ICT4AWE2016, Roma, Italia, 21-22 aprilie 2016.

Obiectivul 6 (2016) - Proiectarea de aplicații ce vor utiliza dicționarelor particulare în prelucrarea semnale EEG

A6.1.- Posibilitatea integrării achiziției comprimate în sisteme de tip BCI

În [Fira ACHI 2016] este analizată posibilitatea utilizării a trei tipuri de dicționare specific semnalului EEG în aplicații de Brain Computer Interface (BCI). Rezultatele experimentale sunt analizate atât din punct de vedere cantitativ al erorilor de reconstructive, cât și din punct de vedere calitativ al semnalului (și anume, pe baza ratei de clasificare din cadrul paradigmei de spelling). Pentru evaluare am folosit semnalele EEG din cadrul competiției BCI Competition III 2005 -P300 Spelling – baza de date II.

Dicționarele testate sunt cele prezentate la **OBIECTIVUL 3 – ACTIVITATEA 3.3.** și anume:

- **Dicționare temporal specific semnalului EEG;**
- **Dicționare specific canalului;**
- **Dicționar standard wavelet Daubechies 10.**

Se observă că din punct de vedere al erorilor de reconstrucție exprimate prin PRDN, cele mai mici erori s-au obținut în cazul dicționarelor temporale specific semnalului EEG, adică alcătuite din atomi de la același moment de timp de pe canalele achiziționate normal. Dacă ținem cont de rata de clasificare pe paradigma de spelling, atunci cele mai bune rezultate se obțin în cazul dicționarelor specifice canalului.

Pe baza rezultatelor obținute se constată că cele mai proaste rezultate se obțin în cazul folosirii dicționarelor standard wavelet. Celelalte două dicționare, specific semnalului EEG, conduc la rezultate mult mai bune.

Astfel, în cazul dicționarului specific canalului se obțin cele mai bune rezultate din punct de vedere al clasificării în paradigma de spelling, și anume, pentru CR = 5:1 rata de clasificare este de 90%, iar pentru 10:1 se obține o rata de clasificare de 89% (pentru semnalele originale s-a obținut o rată de clasificare de 95%).

În cazul dicționarelor temporale specific semnalului EEG se obțin cele mai bune rezultate din punct de vedere al erorii exprimate ca și PRDN, adică pentru o compresie de 5:1 se obține un PRDN = 35.38, iar pentru 10:1 se obține PRDN = 31.42.

Rezultatele demonstrează ca dicționarele specific canalului sau dicționarele temporale specific semnalului EEG oferă rezultate mult îmbunătățite față de dicționarele standard wavelet.

În [Fira COMM 2016] sunt propuse două metode noi și diferite de achiziție comprimată a semnalului EEG. Metodele propuse sunt specific paradigmei de spelling - P300 Evoked Potentials. Rezultatele obținute sunt comparate atât ca erori de decompresie cât și prin măsuri ale acurateții semnalelor, și anume, clasificarea semnalelor EEG din punct de vedere al paradigmei de spelling.

În cazul semnalului ECG o aliniere atât a atomilor din dicționar cât și a segmentelor ECG achiziționate comprimat îmbunătățesc foarte mult rezultatele. Pentru semnalele ECG această aliniere se poate realiza ținând cont de unda R sau complexul QRS. În cazul semnalului EEG alinierea este mai dificilă deoarece nu există elemente evidente, repetitive și distincte în domeniul timp. Semnalul EEG este un semnal biologic care trebuie interpretat cu precădere în domeniul frecvență. Cu toate acestea în cazul experimentului BCI de spelling s-a observat că este specifică o modificare temporală care apare după aproximativ 300ms de la stimul, modificare numită P300. Această modificare temporară este evidențiată prin medierea mai multor semnale EEG. Dacă se analizează un singur segment EEG, fără medierea mai multor stimuli repetitivi atunci nu se observă această modificare temporală P300.

Plecând de la ideea de aliniere a atomilor, s-a urmărit realizarea unei alinieri pentru semnalul EEG culesse în timpul paradigmei de spelling. Astfel alinierea posibilă pentru EEG este bazată pe momentul de apariție al stimulului.

Plecând de la observațiile anterioare noi am testat două metode diferite de aliniere și construire a dicționarului necesar decompresiei (descrie la **OBIECTIVUL 3 – ACTIVITATEA 3.3.**), și anume:

- **Dicționar cu atomi de dimensiune 1 sec cu unda P300 și atomi fără P300 (notați NonP300);**
- **Dicționar cu atomi formați din segmente EEG alinate funcție de stimulul din paradigma de spelling.**

Partea comună a celor două metode este că din setul de semnale de antrenare, pentru fiecare canal EEG este construit un astfel de dicționar. Apoi, achiziția comprimată se realizează pe setul de semnale de test.

Astfel s-a constatat că pentru compresii mici, de exemplu de 5:1, este mai bună metoda de CS clasică (bazată pe dicționar cu segmente EEG alinate funcție de stimulul din paradigma de spelling). Pentru compresii însă de 10:1 este mai bună metoda "Compressed sensed for the procesed EEG signal"(bazată pe Dicționar cu atomi de dimensiune 1 sec cu unda P300 și atomi NonP300). Dezavantajul metodei Compressed sensed for the procesed EEG signal este însă faptul ca metoda necesită și o etapa de realiniere a semnalelor reconstruite. Adică, odată decomprimate, semnalele trebuie re-poziționate, deoarece în etapa de segmentare are loc de fapt o

suprapunere a semnalelor (se segmentează bucăți de 1 sec după fiecare stimul, iar stimulul durează 100 milisecunde iar perioada dintre stimuli durează 75 de milisecunde).

În [Fira IJACSA 2016] este prezentată posibilitatea achiziției comprimate (CS) a semnalului EEG pe baza a doua dicționare. Au fost analizate și comparate mai multe tipuri de matrice de achiziție, rezultatele fiind raportate atât din punct de vedere al erorilor de reconstrucție cât și din punct de vedere calitativ al semnalului reconstruit (prin clasificarea caracterelor în cadrul paradigmei de spelling, clasificare realizată pe baza analizei semnalului EEG). Cele mai bune rezultate au fost obținute cu matrice optimizate funcție de dicționarul particular utilizat în reconstrucție. Astfel, pentru mega-dicționar cele mai bune rezultate în ceea ce privește clasificarea se obțin pentru CR = 5: 1 și 10: 1 atingând rate de clasificare de 90%, respectiv, 92% (pentru semnalele originale de clasificare rata a fost de 89,37%). Din punct de vedere al erorilor, PRDN = 29.77 pentru CR = 5:1 și PRDN = 42,32 pentru CR = 10:1. Rezultatele demonstrează că metoda propusă cu mega-dicționar și matrice optimizat în funcție de dicționarul oferă rezultate îmbunătățit foarte mult în comparație cu matricele standard. [a se vedea **OBIECTIVUL 2** pentru detalii legate de rezultatele simulărilor]

În [Fira SOMET 2016] se propune o metoda de achiziție comprimată dedicată semnalului EEG care se bazează pe construirea unui megadicționar universal. Sunt analizate atât dependențele intra-pacient cât și inter-pacienți, observându-se ca rezultatele nu sunt dependente de pacient.

Plecând de la cele menționate anterior, s-a testat posibilitatea construirii unui mega-dicționar universal (**OBIECTIVUL 3 – ACTIVITATEA 3.3.**), alcătuit din segmente EEG de pe toate cele 64 de canale. Astfel s-au format câte trei atomi pentru fiecare canal, atomii fiind construiți din segmente EEG de pe fiecare canal, deci în total avem un dicționar alcătuit din $3 \times 64 = 192$ de atomi. Dimensiunea dicționarului este 192×240 , deoarece fiecare atom este de dimensiune 240. Menționăm că pentru construirea dicționarului s-a folosit semnalul de antrenare din paradigma de spelling, urmând că testarea metodei să se facă pe semnalul EEG de test. Adică, compressed sensed for EEG signal se va face pe semnalul de test. Ca și matrice de achiziție s-a folosit o matrice Bernoulli cu elemente de -1, 0 și 1.

Metoda propusă a fost testată atât pentru subiectul de la care s-au folosit semnalele EEG de antrenare pentru a construi dicționarul cât și pentru un alt subiect. În felul acesta s-a analizat posibilitatea de a folosi același dicționar pentru mai mulți subiecți, adică de a analiza variabilitatea inter-subiect.

Pentru construirea dicționarului s-au folosit semnalele EEG de antrenare de la subiectul A și respective B, iar pentru testarea metodei propuse s-a folosit semnalul EEG de la subiectul B.

Astfel, cele mai bune rezultate s-au obținut când dicționarul și datele de testare provin de la același pacient, însă pentru construirea dicționarului s-a folosit setul de antrenare iar testarea s-a realizat pe setul de date de test achiziționat comprimat și apoi reconstruit.

Pentru mega-dicționar, cele mai bune rezultate raportate ca rată de clasificare în paradigma de spelling s-au obținut pentru rate de compresie de CR = 5:1 și 10:1 când ratele de clasificare au fost de 88.17% și respective 81.75% (pe semnalul original, nesupus nici unei achiziții comprimate se obține o rata de clasificare de 89.37%). În termeni de eroare raportată ca PRDN se obțin PRDN = 40.93 pentru CR = 5:1 și PRDN = 54.54 pentru CR = 10:1. Aceste rezultate demonstrează ca mega-dicționarul propus oferă rezultate îmbunătățite comparativ cu dicționarele wavelet standard.

În [Fira IJACSA 2016 b] am propus o metoda de achiziție comprimată specifică semnalelor EEG bazată pe un mega-dicționar universal valabil mai multor pacienți. De asemenea este prezentată o analiză comparativă a rezultatelor obținute folosind mai multe tipuri de matrice de proiectie și un mega-dicționar pentru semnale EEG detectare comprimat.

Pentru a se testa metoda s-au folosit înregistrările din paradigma de spelling din cadrul competiției BCI Competition III Challenge 2005 - Dataset II.

Metoda propusă este testată și la variabilitatea inter-pacient a dicționarului, adică dicționar construit din setul de antrenare al unui subiect și testat pe setul de test al altui pacient. Baza de date de spelling pe care am testat având doar doi pacienți vom avea următoarele variante posibile de testare a metodei propuse:

- dictionary construit din setul de antrenare al subiectului A și testat pe datele de test ale subiectului A (TrainA - TestA);
- dictionary construit din setul de antrenare al subiectului B și testat pe datele de test ale subiectului B (notat cu TrainB - TestB);
- dictionary construit din setul de antrenare al subiectului A și testat pe datele de test ale subiectului B (notat cu TrainA - TestB);
- dictionary construit din setul de antrenare al subiectului B și testat pe datele de test ale subiectului A (notat cu TrainB - TestA).

Se observă că în urma reconstrucției cu dicționar construit din semnalul de antrenare al subiectului B se obțin rate de clasificare în paradigma de spelling superioare față de semnalul original. Acest lucru este valabil atât pentru subiectul B (92.4% comparativ cu 89.37%) cât și pentru subiectul A (89.15 % fata de 87.10%). În cazul folosirii unui dicționar alcătuit din semnale de antrenare ale subiectului A se obțin rezultate apropiate de semnalul original, însă un pic sub rata de clasificare originală.

Tabelul 6: Performantele de clasificare % și eroarea PRDN în paradigma de spelling pentru semnalul EEG reconstruit pentru o compresie CR = 10:1 (clasificarea obținută cu software din [4])

	CR Compression	Max Classification	Average Classification	PRDN
ORIGINAL A	10:1	94 %	87.10 %	-
AA	10:1	90 %	84.29 %	50.17
BA	10:1	95 %	89.15 %	45.09
ORIGINAL B	10:1	93 %	89.37 %	-
BB	10:1	97 %	92.40 %	43.07
AB	10:1	92 %	86.59 %	48.80

Este testată ipoteza confirm căreia acest mega-dicționar nu este specific pacientului. Testarea acestei ipoteze presupune construirea dicționarului din setul de învățare al unui subiect și folosirea lui pentru reconstrucția semnalelor de test a altor subiecți. Baza de date folosită are doar doi subiecți, însă semnalele EEG înregistrate sunt lungi. Astfel, s-a testat atât folosirea dicționarului în cadrul aceluiași subiect cât și la celalalt subiect. Chiar dacă pentru semnalele EEG reconstruite eroarea exprimată la măsurarea cantitativă prin PRDN este în jurul valorii 45, se constată că rata de clasificare în paradigma de spelling este foarte apropiată de valoarea obținută pe semnalul original sau chiar peste aceasta. Aceste rezultate pot fi interpretate astfel: în cazul ratei de clasificare din cadrul paradigmei de spelling este foarte importantă păstrarea formei semnalului EEG și nu contează foarte mult micile erori de reconstrucție.

Avantajul metodei compressed sensed este faptul că etapa de achiziție este foarte rapidă, de complexitate foarte mică, se face în timp real iar în urma acestei etape rezultă un semnal EEG comprimat. Partea dificilă apare la reconstrucția semnalului EEG și se datorează următoarelor două aspecte:

- complexitatea de calcul, însă la ora actuală există algoritmi matematici și în funcție de precizia dorită, de timpul alocat și de resursele disponibile se poate opta pentru un algoritm favorabil;
- cunoașterea unui dicționar în care semnalul EEG inițial are o sparsitate multumitoare.

Astfel, s-a analizat posibilitatea construirii unui dicționar specific semnalului EEG și dedicate în special paradigmei de spelling. Rezultatele obținute, în special rata de clasificare în spelling demonstrează că dicționarul construit asigură reconstrucția semnalului EEG cu rezultate bune, indiferent de semnalul EEG de învățare care a stat la baza construirii dicționarului.

Rezultatele obținute au fost raportate în:

[Fira ACHI 2016] Monica Fira, Liviu Goras, Victor-Andrei Maiorescu, „The Analysis of the Specific Dictionaries for Compressive Sensing of EEG Signals”, International Conference on Advances in Computer-Human Interactions - ACHI 2016, Veneția, Italia, 24-28 aprilie 2016;

[Fira COMM 2016] Monica Fira, Liviu Goras, „On Compressed Sensing for EEG Signals - Validation with P300 Speller Paradigm”, International Conference on Communications – COMMS 2016, Bucharest, Romania, 9-11 iunie 2016, DOI: 10.1109/ICComm.2016.7528296 (indexată *IEEE Xplore*);

[Fira IJACSA 2016] Monica Fira, “Compressed Sensing of Multi-Channel EEG Signals: quantitative and qualitative evaluation with Speller Paradigm”, International Journal of Advanced Computer Science and Applications (IJACSA), Vol. 7, No. 6, 2016 (revista indexată ISI - Thomson Reuters);

[Fira SOMET 2016] Monica Fira, Andrei Maiorescu, "P300 spelling and EEG compressed sensed based on a universal megadictionary", International Conference on Intelligent Software Methodologies, Tools and Techniques - SOMET 2016, Larnaca, Cipru, 12-14 septembrie 2016 (Volume 286: New Trends in Software Methodologies, Tools and Techniques, Series Frontiers in Artificial Intelligence and Applications, IOS press, DOI 10.3233/978-1-61499-674-3-203, pp: 203 - 212);

[Fira IJACSA 2016 b] Monica Fira, Goras Liviu, “Comparison of inter-and intra-subject variability of P300 spelling dictionary in EEG compressed sensing”, International Journal of Advanced Computer Science and Applications (IJACSA), Vol. 7, No. 10, 2016, 10.14569/IJACSA.2016.071049 (revista indexată ISI - Thomson Reuters).

Obiectivul 7 (2017) - Implementarea aplicatiilor dedicate semnalelor ECG si a celor dedicate semnalelor EEG

- Implementarea componentelor software dedicate procesarii semnalelor ECG si EEG
- Integrarea componentelor hardware si software

Obiectivul 8 (2017) – Testarea si validarea aplicatiilor pe date reale si pe date din baze de date internationale.

- Elaborare scenarii de test
- Executia scenariilor de test si interpretarea rezultatelor

In [Fira ICBBT 2017] s-au continuat cercetările privind achiziția comprimată a semnalelor medicale, în special cele de tip EEG, și analiza parametrilor implicați în scopul îmbunătățirii rezultatelor. S-a analizat posibilitatea construirii unui mega-dictionar general valabil pentru semnale EEG culese în cadrul paradigmelor de ortografie (spelling), dictionar care sa nu fie specific pacientului. S-a analizat impactul mărimii dictionarului folosit la reconstrucție asupra rezultatelor achiziției comprimate. S-au stabilit dimensiunile optime ale dictionarului folosit în cazul semnalelor EEG culese în cadrul paradigmei de Spelling – competiția BCI III – 2005. Pentru validarea rezultatelor s-au folosit măsurile cantitative de eroare exprimate ca PRD și PRDN precum și măsuri calitative de analiză a semnalului, exprimate ca rată de clasificare în paradigma de ortografie obținute utilizând programul de clasificare dezvoltat de câștigătorii competiției BCI III – 2005 – dataset 2 - Spelling, program prezentat în [1].

In [Fira ICBBT 2017] s-a testat posibilitatea de a construi un mega-dictionar universal format din segmente EEG din toate cele 64 de canale de culegere a semnalului EEG. Astfel, au fost selectate pentru fiecare canal un număr prestabilit de atomi (cuprins între 3 și 10), constând în segmente EEG aleator alese din canalul corespunzător. De exemplu, pentru dimensiunea presetată de 3 atomi de pe fiecare canal, rezultă un dictionar de dimensiune 192*240, deoarece dacă luăm câte 3 atomi de pe fiecare din cele 64 de canale rezultă un număr total de 192 de atomi, fiecare atom având dimensiunea de 240 de eşantioane. Pentru construirea dictionarului, s-a folosit semnalul de antrenament din paradigma de ortografie. Testarea metodei a fost efectuată utilizând semnale EEG de test care constau în semnale EEG comprimate. Ca matrice de achiziție, am folosit o matrice Bernoulli cu elemente -1, 0 și 1.

Pentru testare, s-au folosit atât semnalele EEG ale subiectului din care au fost folosite semnalele EEG pentru a construi dictionarul, cât și pentru un alt subiect. Astfel, a fost analizată posibilitatea utilizării aceluiași dictionar la mai mulți subiecți, examinând în acest fel variabilitatea inter-subiect a dictionarului construit.

În Tabel 1 sunt prezentate erorile de reconstrucție exprimate ca PRDN și PRD în funcție de mărimea dictionarului folosit la reconstrucție. De asemenea este prezentat și timpul necesar reconstrucției. Dictionarul este alcătuit din segmente EEG de la semnalele EEG de antrenament ale subiectului A și testarea este făcută pe semnalele de test ale subiectului B. Se testează astfel posibilitatea construirii unui dictionar care nu depinde de pacient.

Tabel 1. – Rezultate medii pentru compresie de CR = 5:1 pentru dictionar construit din semnalele de antrenare ale subiectului A și testare pe semnalele de test ale subiectului B, folosind matrice de tip Bernoulli

Nr. de atomi în dictionar	PRD	PRDN	Timp (sec)
3 * 64	42.3066	43.0167	74565
4 * 64	41.7742	42.4708	175732
5 * 64	40.9932	41.6808	279287
6 * 64	40.6198	41.3083	641622
7 * 64	40.8419	41.5395	1013457
8 * 64	40.8631	41.5624	1489640
9 * 64	40.7561	41.4568	2034170
10 * 64	40.7891	41.4889	2423660

Se observa în Tabelul 1 că din punct de vedere al erorilor, cele mai bune performanțe au fost obținute cu un dictionar construit din 6 atomi de pe fiecare din cele 64 de canale, adică un dictionar de 6*64 de atomi, fiecare atom având dimensiunea de 240 de eşantioane. Însă dacă analizăm compromisul optim între erorile de reconstrucție și timpul necesar reconstrucției observăm că un optim ar fi la 3 atomi de pe fiecare canal (adică 3*64 atoms). De aceea, în cele ce urmează vom analiza calitatea semnalului reconstruit exprimată ca și rată de clasificare în paradigma de ortografie cu ajutorul soft-ului prezentat în lucrarea [1] pentru dictionar de dimensiune 3*64 atomi respectiv 6*64 atomi.

Tabel 2. – Rezultate medii pentru compresie de CR = 5:1 pentru dicționar construit din semnalele de antrenare ale subiectului B și testare pe semnalele de test ale subiectului B, folosind matrice de tip Bernoulli

Nr. de atomi în dicționar	PRD	PRDN	Timp (sec)
3*64	39.8950	40.5642	72942
4*64	38.6311	39.2855	177745
5*64	37.9489	38.5892	268289
6*64	37.2178	37.8482	1012468
7*64	37.3893	38.0217	661724
8*64	39.0327	39.7128	1588880
9*64	39.0093	39.6939	2133060
10*64	38.9841	39.6676	2523760

Tabelul 2 prezintă rezultatele de reconstrucție pentru cazul când dicționarul și reconstrucția sunt făcute pe semnale EEG provenind de la subiectul B (pentru construirea dicționarului sunt folosite semnalele de antrenament ale subiectului B iar pentru testare sunt folosite semnalele de test ale subiectului B).

Tabelul 3 prezintă rezultatele de clasificare în paradigma de ortografie pentru semnalele EEG originale folosind programul câștigătorului competiției descris în lucrarea [1]. Se observă o rată maximă de clasificare de 93% pentru utilizarea tuturor celor 15 repetiții (epoci) ale fiecărui caracter. Pentru o singură repetiție se obține o rată de clasificare de doar 36%, iar pentru 5 repetiții ale fiecărui caracter se obține o rată de 73%.

Tabel 3. – Performanțele de clasificare % în paradigma de ortografie pentru semnalele EEG originale ale subiectului B obținute cu programul prezentat de câștigătorul competiției în [1] pentru diferite repetiții ale fiecărui caracter.

P300 Ortografie – performanțe de clasificare % - Subject B															
Semnale EEG originale – necomprimate și clasificate de programul dezvoltat de A. Rakotomamonjy și V. Guigue în [1] repetiții															
1repetiție				5 repetiții				10 repetiții				15 repetiții			
36	53	61	68	73	78	83	82	84	88	91	93	90	90	93	

În Tabelul 4 și Tabelul 5 sunt prezentate rezultatele de clasificare în paradigma de ortografie obținute cu programul prezentat în [1] pentru un semnal reconstruit cu un dicționar cu 3 respectiv 6 atomi de pe fiecare din cele 64 de canale EEG. Rezultatele de clasificare sunt exprimate în funcție de numărul de repetiții ale fiecărui caracter în cadrul paradigmei de ortografie (de la 1 repetiție pentru fiecare caracter până la toate cele 15 repetiții ale fiecărui caracter).

Tabel 4 – Performanțe de clasificare % în paradigma P300 de ortografie pentru semnal EEG reconstruit vs. număr de repetiții ale fiecărui caracter pentru o rată de compresie CR =5:1 și dicționar construit din 3*64 atomi (dicționar construit din semnalele de antrenament ale subiectului A și testat pe semnale de test ale subiectului B)

P300 Ortografie – performanțe de clasificare % pentru subiectul B și dicționar construit din 3* 64 atomi															
1repetiție				5 repetiții				10 repetiții				15 repetiții			
27	39	51	63	71	73	76	81	81	86	89	88	90	88	90	

În Tabel 5 se observă rezultate puțin îmbunătățite pentru rata de clasificare în cazul tuturor celor 15 repetiții, și anume de la 90% pentru dicționar de 3*64 atomi (prezentate în Tabel 3) la 93% pentru dicționar de 6*64 atomi.

Tabel 5 – Performanțe de clasificare % în paradigma P300 ortografie pentru semnal EEG reconstruit vs. număr de repetiții ale fiecărui caracter pentru o rată de compresie de CR =5:1 și dicționar construit din 6*64 atomi (dicționar construit din semnalele de antrenament ale subiectului A și testat pe semnale subiectului B)

P300 Ortografie – performanțe de clasificare % pentru subiectul B și dicționar construit din 6* 64 atomi															
1repetiție				5 repetiții				10 repetiții				15 repetiții			
24	48	55	62	70	74	76	81	85	89	90	95	92	91	93	

Figura 3 prezintă topografia erorilor PRDN pentru subiectul B pentru dicționar cu 3 * 64 atomi, respectiv 6 * 64 de atomi (dicționarul construit din semnal EEG de antrenament subiect A și testat cu EEG de test subiect B). Se observă că semnalele EEG culese comprimat cu electrozii din zona frontală și centrală prezintă erori de reconstrucție PRDN mai mici decât ceilalți electrozi, aceste două zone fiind specifice undelor P3a. Următoarea zonă, din punct de vedere al erorilor PRDN este zona parietală, zonă specifică undei P3b, iar cele mai mari erori sunt în zona temporală. Zona temporală nu are o semnificație prea mare pentru generația P300. În plus, se observă că se păstrează topologia erorilor pentru cele două dicționare, cu 3 și respectiv 6 atomi de pe fiecare din cele 64 de canale.

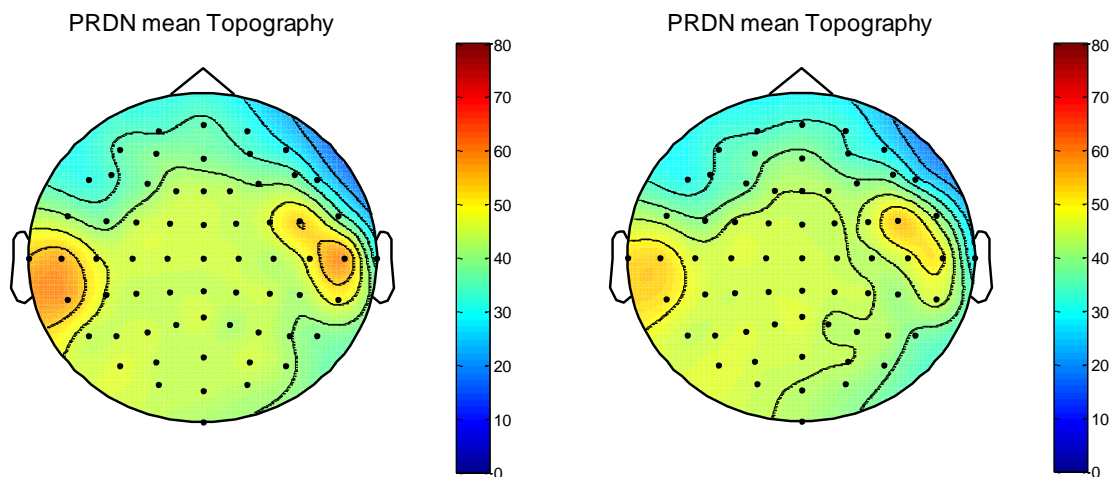


Figura 3. Topografia erorilor PRDN pentru achiziție EEG comprimată pentru subiectul B (dictionar subiect A – testare subiect B) și o rată de compresie de CR = 5:1 pentru dictionar cu 3*63 de atomi (stânga) și 6*64 de atomi (dreapta)

Pentru a face o comparație cu dicționarele standard, au fost analizate rezultatele obținute cu dicționar wavelet Daubechies10 pentru semnalele EEG ale subiectului B. Ambele tipuri de măsurători, erori de clasificare în paradigma de ortografie (vezi tabelul 6) (o clasificare maximă de 60% pentru 15 epoci pentru fiecare caractere), precum și erorile exprimate în PRDN (PRDN_mean = 98.25), sunt foarte slabe, cu mult sub cele înregistrate anterior folosind dicționarul mega-universal cu 3 * 64 atomi sau 6 * 64 atomi.

Tabel 6. – Performanțe de clasificare% în paradigma P300 ortografie pentru semnale EEG reconstruite cu programul prezentat în [1] vs. număr de repetiții pentru fiecare caracter pentru o rată de compresie de CR = 10:1 cu dictionar standard de tip wavelet Daubechies10, pentru subiectul B

P300 Ortografie – performanțe de clasificare % pentru dictionar wavelet Daubechies10														
1repetitie			5 repetiții			10 repetiții			15 repetiții					
10	14	20	26	30	40	44	48	48	50	55	50	54	60	60

Scopul principal al analizei a fost de a găsi numărul optim de atomi necesari pentru constituirea unui mega-dictionar universal semnalelor EEG achiziționate comprimat în timpul paradigmei de ortografie. Alt aspect important urmărit a fost acela de a demonstra că dicționarul propus oferă rezultate bune și pentru situația în care este utilizat pentru reconstrucția semnalelor EEG provenind de la alt pacient decât a fost construit. Pentru aceasta, dictionarul a fost construit din semnalele de antrenament de la un subiect (Subiect A) și a fost folosit pentru reconstrucția semnalelor de test ale altui subiect (Subiect B).

Astfel, în cazul construirii unui dicționar din semnalele de antrenament ale subiectului A cu câte 6 atomi pe de fiecare din cele 64 de canale EEG, se obține pentru semnalele EEG reconstruite ale subiectului B o rată de clasificare în paradigma de ortografie de 93% (rată de clasificare similară cu cea obținută cu semnalele originale). Micșorând dicționarul de la 6 atomi de pe fiecare canal EEG la 3 atomi pentru fiecare canal, se obține o rată de clasificare de 90%, timpul de calcul necesar reconstrucției semnalelor EEG fiind redus considerabil.

In [Fira ICCGI 2017] este analizată posibilitatea clasificării semnalelor EEG achiziționate comprimat (compressed sensed). Clasificarea semnalelor se face direct în spațial comprimat, adică nu este necesară reconstrucția semnalelor EEG. Pentru testare s-au folosit semnalele EEG dintr-un sistem BCI (interfața creier calculator), provenind din cadrul unei paradigme de spelling. Pentru clasificare s-au folosit două metode de clasificare, ambele bazate pe machine learning, și anume, a machine learning de tip Deep learning și a machine learning bazat pe Gradient boosting.

In [Fira ICCGI 2017] este testată ipoteza conform căreia dacă niste date se pot clasifica în spațial original, atunci ele pot fi achiziționate folosind principiul CS și se pot clasifica cu rezultate aproximativ similare și în spațiul comprimat. Cu alte cuvinte, vecini apropiați rămân apropiați și vecini îndepărtați rămân îndepărtați în compressed sensed space. Altfel spus, proporția distanțelor dintre vecini se păstrează.

Pentru testarea metodelor de clasificare s-au folosit semnale EEG culese de Ulrich Hoffmann și colaboratorii în cadrul laboratorului lor și folosite de acești în lucrările lui Hoffmann ^{1, 2}. Datele EEG sunt disponibile pe internet, free, la adresa (http://mmspg.epfl.ch/BCI_datasets).

¹ U. Hoffmann, G. Garcia, J.-M. Vesin, K. Diserens, T. Ebrahimi, "A Boosting Approach to P300 Detection with Application to Brain-Computer Interfaces", Proceedings of IEEE EMBS Conference on Neural Engineering, 2005

² U. Hoffmann, J. M. Vesin, T. Ebrahimi and K. Diserens, "An efficient P300-based brain-computer interface for disabled subjects", J Neurosci Methods. 2008 Jan 15;167(1):115-25. Epub 2007 Mar 13.

S-a folosit clasificatorul de tip Gradient boosting prezentat in [1]. Trebuie notat ca a fost folosit soft-ul dezvoltat de autorii acelei lucrari pentru a putea face o comparatie a rezultatelor de clasificare pe datele EEG originale comparativ cu aceleasi date EEG dar care presupunem ca ar fi fost achizitionate folosit principiul compressed sensed.

Am folosit învățarea profundă (deep learning) pentru a învăța o reprezentare utilă a caracteristicilor direct din date. Rețelele neuronale de tip "Autoencoder" sunt capabile să extragă caracteristicile din datele neetichetate. Autoencoderele sunt folosite ca instrumente pentru instruirea rețelelor neuronale profunde. Mecanismul de antrenament pentru autocodare este considerat nesupravegheat, deoarece nu sunt necesare date etichetate. Autoencoderele sunt instruite să reproducă intrările lor la ieșirile lor prin găsirea unui set de poandri care să minimizeze funcția de cost corespunzătoare: eroarea dintre intrări și reconstrucția lor la ieșiri. Un autoencoder are două părți: un encoder și un decodor. Atât encoderul, cât și decodorul ar putea avea mai multe straturi, dar, de obicei, ele sunt proiectate cu un singur strat pentru fiecare dintre ele [3]. Algoritmul de instruire pentru autocodare este bazat pe propagarea înapoi (back-propagation). Prin cascadarea a doi sau mai mulți autocoduri, se poate obține o rețea de tip deepnetwork.

Pentru testare s-au folosit semnalele EEG culese de Hoffmann, si anume, daza de date restransa disponibila la adresa [3]. Aceasta contine semnale EEG culese pe 32 de canale si este formata din 942 vectori EEG de clasificat, cu durata de 1 sec.

Pentru testarea clasificarii in spatial comprimat am optat pentru doua rapoarte de compresie, si anume, o compresie de 5:1 si respectiv de 10:1. Astfel, utilizand notiunile de compressed sensed si o matrice random am simulate ca achizitionam semnalele EEG direct comprimat.

Pentru testare folosind metoda gradient boosting au fost pastrati aceasi parametric ca si in lucrarea [1], si anume, numărul maxim de iterații ale algoritmului de amplificare (Mmax) a fost setat la 200, valoarea optimă M a fost determinată într-o buclă de validare încrucișată de 30×10 și a fost setată la 0,05.

Table 7 – Ratele maxime de clasificare penstru semnale EEG originale si EEG achizitionat comprimat folosinbd penstru clasificare Gradient Boosting

Metoda Gradient boosting – 23 canale (Fp1, AF3, F3, Fc1, Fc5, C3, CP1, CP5, P3, Pz, PO3, PO4, P4, CP6, CP2, C4, FC6, FC2, F4, AF4, Fp2, Fz, Cz)	
Spatiul de clasificare	Rata maxima de clasificare
EEG original	86%
EEG achizitionat comprimat cu CS 10:1	80%
EEG achizitionat comprimat cu CS 5:1	79%
Metoda Gradient boosting– 8 canale (Fz, Cz, Pz, Oz, P7, P3, P4, P8)	
EEG original	86%
EEG achizitionat comprimat cu CS 10:1	80%
EEG achizitionat comprimat cu CS 5:1	79%
Metoda Gradient boosting– 4 canale (Fz, Cz, Pz, Oz)	
EEG original	81%
EEG achizitionat comprimat cu CS 10:1	75%
EEG achizitionat comprimat cu CS 5:1	73%

Figura 4 prezintă precizia obținută în timpul buclei de validare încrucișată pentru configurare cu 23 de canale. După cum se poate observa, algoritmul de amplificare a gradientului converge la o soluție optimă. Diferența dintre rata de clasificare în spațiul original și spațiul simțit comprimat este relativ mică, de doar 6 procente.

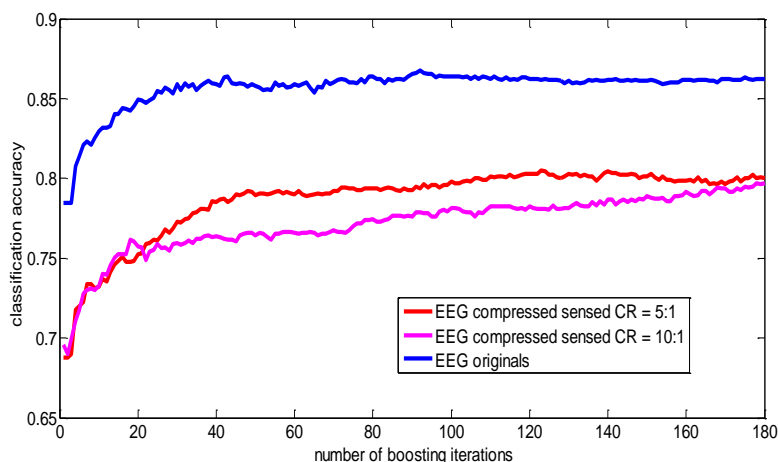


Figura 4 - Procentajul performanței de clasificare pentru diferite valori ale lui M.

Caracteristicile relevante pentru undele P300 nu pot fi identificate direct pe fiecare segment de semnal pe care îl avem la dispoziție. Din acest motiv, am selectat ca instrument de clasificare rețelele profunde cu autocodificatoare care pot extrage caracteristici relevante din datele neetichetate.

Table 8. Rata maximă de clasificare pentru semnalele EEG originale și semnalele EEG comprimate utilizând clasificator de tip Deep Learning

Rețea de tip Deep learning			
Spatiu de clasificare	Rata max de clasificare %	Dimensiunea semnalelor de clasificat	Config. Optima a rețelei
Metoda Deep Learning – 23 canale (Fp1, AF3, F3, Fc1, Fc5, C3, CP1, CP5, P3, Pz, PO3, PO4, P4, CP6, CP2, C4, FC6, FC2, F4, AF4, Fp2, Fz, Cz)			
EEG original	95%	2944	200-50
EEG achiziționat comprimat cu CS 10:1	81%	294	50-10
EEG achiziționat comprimat cu CS 5:1	78%	588	65-10
Metoda Deep Learning – 4 canale (Fz, Cz, Pz, Oz)			
EEG original	80%	512	50-5
EEG achiziționat comprimat cu CS 10:1	74%	52	20-5
EEG achiziționat comprimat cu CS 5:1	72%	104	50-5

Am folosit rețea de tip deep networks construită din doi autocodificatori, urmată de un strat soft-max pentru clasificarea semnalelor originale și, de asemenea, pentru semnalele comprimate. În cazul semnalelor comprimate, primul auto-codec are 200 de neuroni ascunși, iar cel de-al doilea are 40. Pentru semnalele comprimate am folosit un prim auto-encoder cu 40 de neuroni ascunși și al doilea cu doar 10.

S-a analizat posibilitatea clasificării semnalelor EEG (provenite din cadrul paradigmei de spelling) în semnale EEG care contin forma de unda P300 și semnale EEG fara unda P300. Aceasta clasificare este elemental essential în cadrul unui sistem BCI de spelling. Astfel, plecând de la o metoda propusa de Hoffmann, bazata pe gradient boosting s-a testat posibilitatea clasificării semnalelor EEG culesse comprimat cu ajutorul compressed sensed. Cu alte cuvinte s-a analizat posibilitatea de a clasifica semnalele EEG comprimate, adica in spatial comprimat, numit si compressed sensed space. Utilitatea acestei clasificari deriva din faptul ca utilizand fundamentele matematice ace CS se pot achizitiona semnale EEG direct comprimat (adica numarul esantionarelor semnalului EEG este sun teorema esantionarii – Nyquist frequency).

Se constata la utilizand algoritmul bazat pe gradient boosting se optin rate de clasificare apropiate pentru spatial normal si spatial comprimat (compressed sensed space). Astfel, daca pentru semnalele EEG originale rata de clasificare este de 86%, pentru spatial CS rata este cu doar 6% mai mica.

S-a studiat si posibilitatea clasificarii utilizand rețele neuronale de tip deep learning, rezultatele obtinute din punct de vedere al clasificarii fiind f apropiate de cele cu gradient boosting.

Rezultatele obtinute cu albele metode etstate confirma ipoteza prezentata in introducere, conform careia vecinatati apropiate in spatial initial raman apropiate si in spatial comprimat (compressed sensed space). Aceasta permite clasificarea semnalelor achizitionate direct comprimat si este utila in aplicatii unde este importanta doar clasa de apartenenta a unui semnal si nu forma acestuia.

In [Cleju ISSCS 2017] se prezintă un algoritm nou pentru recuperarea semnalului sparse, numit Least Squares Pursuit, bazat pe minimizarea celor mai mici patrate, urmată de alegerea atomului cu cel mai mare coeficient rezultat, într-o manieră lacomă una câte una. Rezultă o abordare similară cu cea a Ortogonale Matching Pursuit, dar cu prioritate diferită a constrângerilor. Noi propunem o implementare eficientă a algoritmului Least Squares Pursuit, să obținem garanții teoretice pentru recuperarea semnalelor și, în final, să prezentăm rezultate promițătoare de simulare.

Reconstrucția semnalelor rare și aplicațiile acestora sunt un subiect activ de cercetare în domeniul procesării semnalelor, de mai mult de o decadă. Se cunoaște faptul că un semnal x ce are o reprezentare rară γ^* în raport cu o bază sau dicționar supracomplet de semnale,

$$x = D\gamma^*, \text{ cu } \|\gamma^*\|_0 = k,$$

poate fi reconstruit dintr-un număr redus de măsurători liniare asupra semnalului, aranjate ca linii ale unei matrici de achiziție M , posibil contaminate cu un zgomot z de energie $\epsilon = \|z\|_2^2$:

$$y = Mx + z.$$

Refacerea semnalului constă în rezolvarea problemei de optimizare NP-completă:

$$x = D \cdot \underset{\gamma}{\operatorname{argmin}} \|\gamma\|_0 \text{ a.î. } \|y - MD\gamma\|_2^2 < \epsilon.$$

În literatura de specialitate, această problemă poartă numele de *achiziție comprimată* ("compressed sensing"), fiind studiată pe larg în ultimii 10 - 15 ani.

Pentru început, studiem cazul fără zgomot, $\epsilon = 0$, în care problema se reduce la găsirea soluției celei mai rare (în sensul normei ℓ_0) pentru un sistem de ecuații nedeterminat. Așadar, considerăm problema canonică care necesită rezolvare ca fiind următoarea:

$$\underset{\gamma}{\operatorname{argmin}} \|\gamma\|_0 \text{ a.î. } y = D\gamma.$$

În ecuația de mai sus am redenumit produsul MD din ecuația precedentă doar ca D , pentru simplitate. În cele ce urmează, propunem un algoritm *greedy* inovativ pentru rezolvarea acestei probleme de optimizare.

Întrucât problema de optimizare canonică este NP-**hard**, căutarea soluției optimă global este intractabilă, în locul acesteia fiind necesar să acceptăm o soluție suboptimală, care rezultă dintr-o aproximare a problemei originale. Unul dintre cei mai cunoscuți algoritmi pentru rezolvarea (aproximativă) a problemei canonice este Orthogonal Matching Pursuit (OMP). Algoritmul OMP estimează iterativ soluția γ prin adăugarea progresivă, la fiecare iterație, a celui mai promițător atom dintre cei neutilizați încă în reprezentare, adică a celui mai similar cu reziduuul aproximării la pasul curent. Algoritmul propus se bazează pe o abordare similară, de asemenea de tip *greedy*, dar cu o prioritarizare diferită a constrângerilor interne față de OMP.

În cele ce urmează, se vor prezenta algoritmul propus, intitulat Least Squares Pursuit, precum și relația sa cu algoritmul Orthogonal Matching Pursuit. De asemenea, se vor prezenta o metodă de implementare eficientă, condiții teoretice care garantează exactitatea soluției, precum și rezultate ale simulărilor practice de reconstrucție.

A. Algoritmul Least Squares Pursuit - Considerații generale

Rezolvarea directă a ecuației canonice nu este posibilă în general, deoarece norma ℓ_0 face ca problema să fie în categoria NP-*hard*. Algoritmii de tip *greedy pursuit*, dintre care cei mai cunoscuți sunt algoritmi Matching Pursuit și Orthogonal Matching Pursuit, estimează suportul semnalului într-o manieră treptată, selectând atomii unul câte unul. Mai precis, Orthogonal Matching Pursuit (OMP) selectează la pasul k pe acel atom cu numărul i care este cel mai corelat cu reziduuul de la pasul curent:

$$i = \mathbf{argmax} \| D^T r^{(k)} \| = \mathbf{argmax} \| D^T (y - D\gamma^{(k-1)}) \|.$$

În continuare, soluția curentă la pasul k , $\gamma^{(k)}$, este actualizată prin proiectarea vectorului y pe setul tuturor atomilor selectați până în acest moment, $T^{(k)}$, care include și cel mai recent selectat atom. Cu alte cuvinte, y se aproximează cât mai bine utilizând doar atomii din setul $T^{(k)}$, restul atomilor nefiind folosiți. Acest lucru poate fi exprimat după cum urmează:

$$\gamma^{(k)} = \mathbf{argmin}_{\gamma} \| y - D\gamma \|_2^2 \quad \text{a.î.} \quad \gamma_{T_c^{(k)}} = 0,$$

unde $\gamma_{T_c^{(k)}}$ reprezintă γ restricționat doar la indicii din $T_c^{(k)}$, care corespund atomilor care nu sunt folosiți în reprezentare.

Ideea algoritmului propus este de a înlocui în ecuația de mai sus termenul care asigură reprezentarea fidelă, $\| y - D\gamma \|_2^2$, cu termenul care asigură raritatea reprezentării, $\gamma_{T_c^{(k)}} = 0$. Această abordare are la bază observația că nici unul din cei doi termeni nu este a priori mai important decât celălalt, din moment ce soluția adevărată γ^* (presupunând că există și are suportul T) satisface ambii termeni în mod exact: permite reconstrucția fără erori a semnalului, și nu folosește decât atomi din T . Prin urmare, prioritatea unei termen față de celălalt reprezintă doar o alegere impusă de proiectarea algoritmului. OMP impune la fiecare pas condiția de raritate $\gamma_{T_c^{(k)}} = 0$, tolerând în schimb o reprezentare imperfectă a datelor, pe care urmărește să o minimizeze cu fiecare nou atom. Soluția propusă de noi reprezintă varianta complementară: se impune la fiecare pas condiția de reprezentare fidelă a datelor, $\| y - D\gamma \|_2^2 = 0$, tolerând în schimb inexactitatea rarității $\gamma_{T_c^{(k)}}$, și urmărind îmbunătățirea acesteia cu fiecare nou atom selectat. Așadar pasul de actualizarea soluției, dat fiind suportul estimat la pasul k , $T^{(k)}$, este dat de:

$$\gamma^{(k)} = \mathbf{argmin}_{\gamma} \| \gamma_{T_c^{(k)}} \|_2^2 \quad \text{a.î.} \quad y = D\gamma.$$

Această abordare este inspirată de un alt algoritm existent, Greedy Analysis Pursuit, proiectat pentru o formă alternativă de modele rare cunoscută sub numele de *co-raritate* (sau *raritate de analiză*), algoritm care utilizează aceleași priorități între termenului de reprezentare și cel de raritate ca și în cazul de față.

B. Descrierea algoritmului

Algoritmul propus constă în iterarea celor două etape obișnuite pentru algoritmii din categoria *greedy pursuit*, respectiv: (i) actualizarea soluției estimate pe baza suportului curent, și (ii) actualizarea suportului prin alegerea unui nou atom, pe baza soluției actualizate.

Fie notația $T^{(k)}$ pentru suportul estimat la pasul k și $T_c^{(k)}$ desemnând restul atomilor neutilizați. La pasul k , algoritmul calculează o nouă soluție prin rezolvarea unei probleme de tip cele mai mici pătrate cu ponderi (*weighted least-squares decomposition*):

$$\gamma^{(k)} = \mathbf{argmin}_{\gamma} \| I_{T_c^{(k)}} \gamma \|_2^2 \quad \text{a.î.} \quad y = D\gamma.$$

Notația $I_{T_c^{(k)}}$ desemnează o matrice unitate cu valori de 1 doar pe diagonala principală, și numai în locațiile corespunzătoare indicilor din setul $T_c^{(k)}$. Utilizarea matricii $I_{T_c^{(k)}}$ este doar pentru ușurarea notației, echivalentă cu restrângerea $\gamma_{T_c^{(k)}}$ din expresia precedentă, întrucât efectul său este de a păstra doar coeficienții $\gamma_{T_c^{(k)}}$ (cu alte cuvinte, coeficienții corespunzători suportului curent $\gamma_{T^{(k)}}$ nu au constrângeri de normă).

Așadar, la fiecare iterație se obține ca soluție o descompunere a vectorului y în care coeficienții atomilor neselectați au energie minimă, fără a exista însă nici o restricție asupra coeficienților atomilor selectați. Ca atare, descompunerea va utiliza cât mai mult posibil atomii selectați, atomii neselectați fiind utilizați doar pentru componentele care nu pot fi în nici un fel reprezentate altfel.

După ce are loc actualizarea soluției, urmează actualizarea suportului prin includerea în $\gamma_{T_c^{(k)}}$ a atomului i cu cel mai mare coeficient (în valori absolute):

$$i = \mathbf{argmax} \|\gamma_{T_c^{(k)}}\|.$$

Motivul este acela că, datorită coeficientului său de valoare mare, acesta este atomul cel mai probabil să facă parte din suport.

Algoritmul este descris în mod sintetic în secvența de mai jos. Criteriile de oprire a iterațiilor și de terminare a algoritmului pot fi, ca și la algoritmul OMP, fie un număr finit de iterații (dacă gradul de raritate a soluției căutate se cunoaște în avans), fie atingerea unui valori suficient de mici a obiectivului $\|I_{T_c^{(k)}}\gamma\|_2^2$.

Algoritmul Least Squares Pursuit

1. Inițializare: $T^{(0)} \leftarrow \emptyset$, $T_c^{(0)} \leftarrow \emptyset$

2. Repetă

1. Actualizare soluție curentă:

$$\gamma^{(k)} = \mathbf{argmin}_{\gamma} \|I_{T_c^{(k)}}\gamma\|_2^2 \quad \text{a.î. } y = D\gamma$$

2. Actualizare suport:

$$i = \mathbf{argmax} \|\gamma_{T_c^{(k)}}\|$$

$$T^{(0k+1)} \leftarrow T^{(k)} \cup \{i\}, \quad T_c^{(k+1)} \leftarrow T_c^{(k)} \setminus \{i\}$$

3. Până la: criteriu de oprire

Numele de **Least Squares Pursuit (LSP)** se justifică prin aceea că algoritmul urmează aceeași strategie de selecție a atomilor unul câte unul ca și OMP (de aici termenul de *Pursuit*), dar proiecția ortogonală realizată în OMP este înlocuită cu rezolvarea unei probleme de tipul celor mai mici pătrate (*Least Squares*).

C. Implementarea eficientă a algoritmului

O implementare naivă a algoritmului ar obține de fiecare dată soluția $\gamma^{(k)}$ prin rezolvarea ecuației de la pasul (2.1,) la fiecare iterație. Acest lucru poate fi evitat prin reutilizarea soluției precedente la fiecare nouă iterație, întrucât este mai ușor de calculat noua soluție pe baza celei precedente decât de rezolvat ecuația încă o dată. În cele ce urmează prezentăm o implementare mai eficientă pe baza acestei idei. Această optimizare este similară cu cea utilizată în mod curent în algoritmul OMP.

Fie soluția inițială de tip cele mai mici pătrate:

$$\gamma^{(0)} = \mathbf{argmin} \|\gamma\|_2^2 \quad \text{a.î. } y = D\gamma.$$

Deoarece $T^{(0)}$ este vid, $\gamma^{(0)}$ reprezintă chiar soluția de energie minimă a sistemului, și prin urmare poate fi reprezentată compact utilizând pseudo-inversa Moore-Penrose a matricii D , notată cu D^\dagger :

$$\gamma^{(0)} = D^\dagger y.$$

Să presupunem că la pasul k suportul estimat al soluției este $T^{(k)}$. Noua soluție $\gamma^{(k)}$ calculată diferă de soluția inițială $\gamma^{(0)}$ prin faptul că coeficienții atomilor din suportul $T^{(k)}$ nu mai au constrângeri de normă, cum aveau în cazul inițial.

Soluția estimată $\gamma^{(k)}$ poate fi împărțită în două, corespunzător suportului $T^{(k)}$ și co-suportului $T_c^{(k)}$ (co-suportul conține atomii care nu fac parte din suport). Aceasta conduce la:

$$y = D_{T^{(k)}}\gamma_{T^{(k)}}^{(k)} + D_{T_c^{(k)}}\gamma_{T_c^{(k)}}^{(k)}.$$

În continuare, să considerăm operatorul de proiecție ortogonală $P^{(k)}$ pe spațiul generat de matricea $D_T^{(k)}$:

$$P^{(k)} = D_T^{(k)}(D_T^{(k)})^\dagger.$$

De asemenea, fie și operatorul complementar de proiecție pe subspațiul complementar:

$$P_c^{(k)} = I - P^{(k)} = I - D_T^{(k)}(D_T^{(k)})^\dagger.$$

Cu fiecare nou atom inclus în suportul T , rangul operatorului $P^{(k)}$ crește cu o unitate, în timp ce subspațiul complementar generat de $P_c^{(k)}$ se micșorează cu o dimensiune. Ca atare, subspațiile generate de $P_c^{(k)}$ sunt incluse unul în altul pe măsură ce k crește, după cum urmează:

$$P_c^{(0)} \supset P_c^{(1)} \supset \dots \supset P_c^{(k)} \supset \dots$$

Aplicând operatorul $P_c^{(k)}$ asupra ecuației cu cele două părți, corespunzătoare suportului și co-suportului, se obține

$$P_c^{(k)}y = P_c^{(k)}D_{T_c^{(k)}}\gamma_{T_c^{(k)}}^{(k)} = P_c^{(k)}D\gamma^{(k)},$$

deoarece $P_c^{(k)}$ este ortogonal pe $D_T^{(k)}$.

Deoarece dorim să obținem $\gamma_{T_c^{(k)}}^{(k)}$ de normă ℓ_2 minimă, aceasta va fi soluția de energie minimă a ecuației de mai sus, adică ortogonală pe spațiul nul al acesteia. Spațiul nul al ecuației constă din spațiul nul al sistemului original D plus subspațiul generat de $D^\dagger D_T^{(k)}$, după cum rezultă din următoarele două observații:

1. Acest subspațiu este ortogonal pe matricea sistemului $P_c^{(k)}D$:

$$P_c^{(k)}DD^\dagger D_T^{(k)} = P_c^{(k)}D_T^{(k)} = 0.$$

2. Subspațiul generat de $D^\dagger D_T^{(k)}$ are dimensiunea $|T| = k$, așadar aceeași dimensiune cu cea a spațiului nul al ecuației în cauză. Mai mult, este inclus în spațiul generat de liniile dicționarului inițial D , deoarece coloanele matricii D^\dagger și liniile matricii D generează întotdeauna același subspațiu.

Aceste considerente arată că subspațiul generat de $D^\dagger D_T^{(k)}$ este chiar spațiul nul adițional, adăugat de descreșterea rangului operatorului $P_c^{(k)}$ la spațiul nul original al D .

Prin ce diferă soluția la pasul k , $\gamma^{(k)}$, de soluția precedentă $\gamma^{(k-1)}$? Amândouă sunt soluții de tip cele mai mici pătrate pentru ecuația de mai sus, fiind așadar ortogonale pe spațiile nule $D^\dagger D_T^{(k-1)}$ și $D^\dagger D_T^{(k)}$. Dar $D_T^{(k)}$ îl conține pe $D_T^{(k-1)}$ și în plus mai conține ultimul atom selectat (fie acesta notat d_k). Prin urmare, putem obține simplu $\gamma^{(k)}$ prin proiectare și extragere din $\gamma^{(k-1)}$ a componentei sale care face parte din acest subspațiu suplimentar generat de $D^\dagger d_k$:

$$\gamma^{(k)} = (I - D^\dagger d_k \{D^\dagger d_k\}^\dagger) \gamma^{(k-1)}.$$

Întrucât d_k este un vector, $D^\dagger d_k$ este de asemenea un vector, și în acest caz pseudo-inversa sa $\{D^\dagger d_k\}^\dagger$ se reduce la vectorul transpus și divizat cu norma sa ridicată la pătrat. Rezultă așadar:

$$\gamma^{(k)} = \gamma^{(k-1)} - \frac{1}{d_k^T D^\dagger D^\dagger d_k} D^\dagger d_k d_k^T D^\dagger \gamma^{(k-1)}.$$

Ecuația de mai sus se poate utiliza pentru actualizarea soluției estimate la fiecare pas, după selectarea fiecărui nou atom.

D. Garanții teoretice pentru reconstrucție

În continuare, se prezintă rezultate teoretice care indică o condiție suficientă pentru reconstrucția cu succes a semnalelor cu algoritmul Least Squares Pursuit. Această condiție este analoagă condițiilor similare prezentate în literatura de specialitate pentru algoritmi Greedy Analysis Pursuit și Orthogonal Matching Pursuit.

Trebuie menționat că o astfel de condiție teoretică ce garantează succesul algoritmului nu este neapărat utilă în sine, întrucât aceste condiții sunt în general greu de verificat și prea restrictive în practică. Totuși, faptul că un algoritm este *demonstrabil* optim măcar pe o subclasă restrânsă a problemei este un argument important în favoarea aceluiași algoritm, și justifică utilizarea mai largă a algoritmului. Din acest motiv, în literatura de specialitate există astfel de condiții publicate pentru aproape toți algoritmi importanți din familia *greedy pursuit*.

Se pornește de la versiunea neconstrânsă a ecuației care furnizează γ^k , care este:

$$\gamma^k = \underset{\gamma}{\text{argmin}} \|y - D\gamma\|_2^2 + \lambda \|I_{T^c} \gamma\|_2,$$

unde $\lambda \rightarrow 0$. Condiția $\lambda \rightarrow 0$ asigură faptul că termenul de raritate $\|I_{T^c} \gamma\|_2$ este infinit mai puțin important decât termenul de reprezentare fidelă $\|y - D\gamma\|_2^2$, ceea ce înseamnă că acesta din urmă devine practic o constrângere exactă, conducând la ecuația algoritmului LSP. Totuși, această formă neconstrânsă are avantajul că permite o analiză mai facilă. Menționăm aici că în cazul contrar, când $\lambda \rightarrow \infty$, se ajunge la cazul algoritmului OMP, ceea ce subliniază similitudinea celor doi algoritmi.

Din Lagrangeanul formulării neconstrânse a problemei se obține:

$$\lambda I_{T_c^{(k)}} \gamma^{(k)} = D^T \cdot u,$$

pentru un u oarecare, ceea ce înseamnă că $I_{T_c^{(k)}} \gamma^{(k)}$ se găsește complet în spațiul generat de D . Fie N o bază pentru spațiul nul al matricii D (N fiind considerată o matrice pe linii). Atunci, multiplicând la stânga cu N se obține 0:

$$N_{T_c^{(k)}} \gamma_{T_c^{(k)}}^{(k)} = 0.$$

Presupunând că nu au existat alegeri greșite ale atomilor până la iterația curentă k , co-suportul original T_c se regăsește complet în interiorul co-suportului de la pasul k , $T_c^{(k)}$. Ca atare, putem împărți mulțimea $T_c^{(k)}$ în două: suportul rămas de găsit, $T_\star^{(k)}$, și co-suportul original T_c . Împărțind ecuația precedentă pe baza aceleiași diviziuni conduce la:

$$N_{T_c} \gamma_{T_c}^{(k)} = -N_{T_\star^{(k)}} \gamma_{T_\star^{(k)}}^{(k)}.$$

Diferența dintre soluția rară adevărată γ^\star și soluția de la pasul k , $\gamma^{(k)}$ se regăsește complet în spațiul nul, întrucât ambele soluții conduc la același vector y . Prin urmare, avem:

$$\gamma^{(k)} - \gamma^\star = N^T \times v,$$

pentru un vector oarecare v . Păstrând din ecuația de mai sus doar liniile corespunzătoare adevăratului co-suport T_c și ținând cont că γ^\star este zero pentru acești atomi, rezultă faptul că:

$$\gamma_{T_c}^{(k)} = N_{T_c}^T \cdot v.$$

Așadar $\gamma_{T_c}^{(k)}$ aparține spațiului generat de $N_{T_c}^T$, ceea ce conduce la:

$$\gamma_{T_c}^{(k)} = N_{T_c}^\dagger N_{T_c} \gamma_{T_c}^{(k)}.$$

Înlocuind prima ecuație în expresia de mai sus conduce la:

$$\gamma_{T_c}^{(k)} = -N_{T_c}^\dagger N_{T_\star^{(k)}} \gamma_{T_\star^{(k)}}^{(k)}.$$

Așadar, condiția

$$\|N_{T_c}^\dagger N_{T_\star^{(k)}}\|_{\infty, \infty} < 1$$

este o condiție suficientă pentru ca

$$\| \gamma_{T_c}^{(k)} \|_{\infty} < \| \gamma_{T_*}^{(k)} \|_{\infty},$$

ceea ce garantează faptul că selecția următorului atom pe baza celui mai mare coeficient din $\gamma^{(k)}$ nu va da greș, atomul selectat fiind întotdeauna parte din adevăratul suport care mai rămâne de selectat, $T_*^{(k)}$. Unul câte unul, vor fi selectați în acest fel toți atomii din suportul real T , moment în care reprezentarea datelor este completă și algoritmul se oprește întrucât reziduul de reprezentare devine nul.

Deoarece suportul $T_*^{(k)}$ la pasul k ar putea fi, în general, la fel de mare ca suportul real T (de exemplu înaintea selecției primului atom), condiția globală care garantează alegerea corectă a atomilor la fiecare iterație, și deci succesul algoritmului, este:

$$\| N_{T_c}^{\dagger} N_T \|_{\infty, \infty} < 1.$$

E. Rezultate de simulare

Pentru a investiga performanța algoritmului Least Squares Pursuit în reconstrucția semnalelor cu reprezentare rară, s-au implementat o serie de teste de reconstrucție pe semnale generate aleator, reprezentându-se în final diagrama de tranziție de fază (*phase transition*) care sintetizează rezultatele.

Mai exact, s-a generat un dicționar aleator de dimensiuni $n \times N = 200 \times 240$, cu ajutorul căruia s-au generat semnale cu reprezentare rară prin combinarea aleatoare a atomilor din dicționar, cu coeficienți aleatori. Semnalele astfel obținute sunt înmulțite cu o matricea de achiziție de asemenea aleatoare, cu un număr variabil de linii m , fără a se adăuga zgomot. Din vectorii de măsurători obținuți în acest fel se încearcă refacerea semnalelor originale cu algoritmul Least Squares Pursuit. Considerăm că un semnal este reconstruit cu succes dacă eroarea de reconstrucție, relativă la norma semnalului, este mai scăzută decât 10^{-6} .

Succesul reconstrucției depinde de rata de compresie a achiziției, $\delta = \frac{m}{n}$, și de raritatea relativă a reprezentării, $\rho = \frac{k}{m}$. S-au testat toate perechile de valori pentru δ și ρ luând valori între 0.1 și 0.95, cu pasul de 0.05. Pentru fiecare astfel de pereche (δ, ρ) s-a testat reconstrucția a 100 de semnale generate aleator după procesul descris mai sus, reținându-se apoi procentul semnalelor reconstruite cu succes.

Reprezentarea grafică din figura de mai jos, cunoscută sub numele de *diagrama de tranziție de fază*, sintetizează într-o singură imagine rezultatele testului. Pentru fiecare pereche (δ, ρ) luminozitatea indică procentul de semnale reconstruite cu succes, unde alb înseamnă 100% semnale reconstruite, negru 0%, iar nivelele de gri performanțe intermediare. Zona albă reprezintă așadar domeniul în care algoritmul funcționează cu succes, „cantitatea” de alb din figură fiind o estimare calitativă a performanței sale în general.




Figura 5 - Refacerea semnalelor cu reprezentare rară cu LSP: procentul de semnale reconstruite cu succes. Albul indică 100% semnale reconstruite, negrul 0%.

Rezultatele arată faptul că algoritmul Least Squares Pursuit este o soluție viabilă pentru reconstrucția semnalelor cu reprezentare rară, în condiții fără zgomot, într-o plajă largă de condiții. Domeniul în care reconstrucția se face cu succes (zona albă) este comparabil cu cel obținut cu algoritmi similari existenți în literatură, cum ar fi Orthogonal Matching Pursuit sau Greedy Analysis Pursuit (cel din urmă pentru un model ușor diferit, raritatea de analiză).

F. Concluzii și perspective de dezvoltare

În cele de mai sus am prezentat un nou algoritm pentru refacerea semnalelor cu reprezentare rară, intitulat Least Squares Pursuit, bazat pe selecția repetată a celui mai semnificativ atom rezultat dintr-o serie de probleme succesive de tip cele mai mici pătrate. Această abordare este similară cu cea algoritmului Orthogonal Matching Pursuit, dar cu priorități diferite acordate constrângerilor de reprezentare fidelă și de raritate, dar și cu cea a algoritmului Greedy Analysis Pursuit, utilizat pentru modelul alternativ de raritate de analiză. Deși s-a analizat aici

doar cazul achiziției fără zgomot, rezultatele obținute sunt promițătoare și similare cu ale algoritmului Orthogonal Matching Pursuit, extrem de des întâlnit în literatura de specialitate.

Dezvoltările viitoare ale cercetărilor se pot concretiza pe mai multe direcții. În primul rând, atât Orthogonal Matching Pursuit cât și Least Squares Pursuit pot fi considerate cazuri limită ale unei formulări neconstrânse a problemei de optimizare, care le înglobează. Analiza teoretică și practică a acestui algoritm neconstrâns poate conduce la rezultate superioare în practică, și la o tratare unitară a ambilor algoritmi, dezirabilă din punct de vedere teoretic. În al doilea rând, rămâne de studiat cazul algoritmului Least Squares Pursuit în condiții de măsurători cu zgomot aditiv. În final, o ultimă direcție identificată este studiul legăturii dintre Least Squares Pursuit și metodele de reconstrucție de tip Basis Pursuit, bazate pe minimizarea normei ℓ_1 . Pentru algoritmul OMP, condiția teoretică ce garantează succesul algoritmului garantează de asemenea și succesul minimizării ℓ_1 , ceea ce reprezintă o relație surprinzătoare între doi algoritmi complet diferiți. Este posibil ca același lucru să se întâmple și cu algoritmul LSP, în virtutea similitudinii acestuia cu OMP.

In [Eva IJACSA 2017] este efectuată o evaluare comparativă pe două baze de date folosind trei metode de extragere a caracteristicilor și cinci metode de clasificare pentru o paradigmă de mișcare imaginara pe baza ritmului Mu. Pentru a extrage caracteristicile semnalelor electroencefalografice sunt propuse trei metode: ICA (analiza pe component independente), distanța Itakura și măsurători ale sincronizarilor de fază: valoarea blocării fazelor, indicele lagului de fază și indicele de întârziere a fazei ponderate. Clasificarea caracteristicilor extrase se face folosind LDA (analiza liniară discriminantă), analiza discriminatorie patrică, clasificatorul bazat pe distanța Mahalanobis, cel mai apropiat vecin k și SVM (mașina cu vector de suport). Scopul acestei comparații este de a evalua care metodă de extragere a trasaturi și care clasificator este mai potrivit pentru BCI (brain computer interface). Rezultatele sugerează că eficacitatea metodei de extragere a trasaturilor depinde de metoda de clasificare utilizată.

Bazele de date utilizate provin din surse diferite: baza de date BCI Competition 2002 – OSMAN a fost descărcată de pe internet, iar baza de date proprie a fost formată din înregistrările electroencefalografice ale voluntarilor în cadrul laboratorului de procesare a semnalelor din cadrul Facultății de Bioinginerie Medicală. Baza de date BCI Competition 2002 – OSMAN conține 9 subiecți foarte bine antrenați, acest lucru reliefându-se în rezultatele obținute. Baza de date proprie conține 40 de înregistrări de semnale EEG, toate viabile, înregistrate în timpul imaginării mișcării mâinii. Cercetarea pe datele achiziționate personal a fost mai eficientă deoarece toate detaliile și condițiile în care au fost realizate înregistrările sunt cunoscute. Opiniile voluntarilor, precum și informațiile privind experimentele sunt cunoscute. Voluntarii au efectuat mai întâi experimente ce au implicat mișcarea mâinii stângi/drepte și mai apoi imaginarea mișcării mâinii drepte/stângi. Pentru celalalt set de date utilizat nu sunt disponibile informații despre sistemul de achiziție (nu este descris sau menționat), nu este specificat dacă înregistrările au avut loc în aceeași zi sau în zile diferite, iar vârsta voluntarilor nu este specificată.

Tabelul 8. Ratele de clasificare medii și maxime obținute pentru metodele aplicate, clasificatori LDA, QDA și MD – baza de date proprie

Metodă		Rată de clasificare					
		LDA		QDA		MD	
		Medie ± deviație standard [%]	Maximă [%]	Medie ± deviație standard [%]	Maximă [%]	Medie ± deviație standard [%]	Maximă [%]
ICA	INFOMAX	81,3 ±12,74	97,73	83,6 ±15,9	100	82,28±15,82	100
	SOBI	78,8 ±15,63	97,78	79,3 ± 17,66	100	79,64 ± 17,52	100
	JADE	83,90 ±12,39	100	82,61±19,52	100	83,62 ± 15,59	100
Distanța Itakura	Model de ordin 6	82,40 ±12,60	100	88,19 ± 9,74	100	86,62 ± 11,28	100
	Model de ordin 10	83,35%±11,94	100	88,33±10,22	100	86,62 ± 9,78	98,33
Distanța Itakura simetrică	Model de ordin 6	81,35%±15,25	100	87,85±12,48	100	86,75 ±12,35	98,33
	Model de ordin 10	84,04 ± 12,54	100	89,43±10,03	100	87,15 ± 10,23	100
Sincronizare de fază	PLI	64,78 ± 7,09	82,12	73,98 ± 6,64	85,28	73,08 ± 6,35	84,67
	PLV	64,62 ±7,18	82,48	73,99 ± 6,67	85,64	73,03 ± 6,51	84,31
	WPLI	59,06 ± 3,62	66,67	64,08 ± 4,67	72,51	63,06 ±4,44	71,78

În Tabelul 8 sunt prezentate ratele de clasificare medii și maxime obținute pentru fiecare metodă aplicată. Pentru metodele ICA, calculul distanței Itakura și calculul distanței Itakura simetrice s-au obținut rate de clasificare maxime pentru clasificatorii LDA, QDA și MD. Cele mai mici rate de clasificare s-au obținut pentru indicii PLI, PLV și wPLI. Ratele medii de clasificare se află în intervalul 59.06% (wLI) - 89.43% (distanța Itakura simetrică). Ratele de clasificare cele mai mari atât medii, cât și maxime s-au obținut cu ajutorul clasificatorului pătratic.

Constatările din analiza Tabelul 8 sunt:

- metoda ICA, algoritmul JADE oferă cele mai bune rate de clasificare pentru clasificatorii LDA, QDA și MD;
- distanța Itakura și distanța Itakura simetrică, modelul de ordin 10 oferă rezultate optime pentru clasificatorul pătratic;
- Indicii PLI, PLV și wPLI, clasificatorul QDA prezintă cele mai mari rate de clasificare.

Tabelul 9. Ratele de clasificare medii și maxime obținute pentru metodele aplicate, clasificator KNN (k=1:5)

Metodă		KNN	Rată de clasificare	
		Număr de vecini	Medie \pm deviație standard [%]	Maximă [%]
ICA	INFOMAX	1	81,76 \pm 13,77	100
		2	81,76 \pm 13,76	100
		3	81,79 \pm 13,75	100
		4	81,80 \pm 13,74	100
		5	81,83 \pm 13,74	100
	SOBI	1	82,25 \pm 13,78	100
		2	82,21 \pm 13,79	100
		3	82,17 \pm 13,82	100
		4	82,14 \pm 13,84	100
		5	82,11 \pm 13,87	100
	JADE	1	84,61 \pm 13,81	99,80
		2	84,61 \pm 13,81	99,80
		3	84,62 \pm 13,80	99,80
		4	84,62 \pm 13,79	99,80
		5	84,63 \pm 13,78	99,81
Distanța Itakura	Model de ordin 6	1	84,69 \pm 9,92	97,50
		2	84,04 \pm 9,90	97,78
		3	83,56 \pm 9,49	97,08
		4	83,34 \pm 9,50	97,00
		5	82,58 \pm 9,62	96,94
	Model de ordin 10	1	85,00 \pm 9,91	97,50
		2	84,46 \pm 10,18	97,22
		3	84,12 \pm 10,33	97,08
		4	83,93 \pm 10,56	97,00
		5	83,40 \pm 10,68	96,94
Distanța Itakura simetrică	Model de ordin 6	1	84,55 \pm 11,54	99,17
		2	83,81 \pm 11,61	99,44
		3	83,50 \pm 11,52	99,17
		4	83,43 \pm 11,56	99,33
		5	82,93 \pm 11,50	98,61
	Model de ordin 10	1	86,10 \pm 16,96	99,17
		2	85,71 \pm 17,06	99,44
		3	85,00 \pm 16,89	98,75
		4	84,80 \pm 16,91	98,67
		5	84,22 \pm 16,85	97,78
Sincronizarea de fază	PLI	1	92,74 \pm 3,42	96,66
		2	92,83 \pm 3,40	96,71
		3	92,89 \pm 3,39	96,75
		4	92,97 \pm 3,38	96,80
		5	92,98 \pm 3,38	96,82
	PLV	1	92,73 \pm 3,41	96,57
		2	92,83 \pm 3,38	96,63
		3	92,89 \pm 3,38	96,67
		4	92,97 \pm 3,36	96,70
		5	92,99 \pm 3,37	96,72
	WPLI	1	83,15 \pm 6,83	92,94
		2	83,27 \pm 6,87	93,06
		3	83,33 \pm 6,87	93,16
		4	83,41 \pm 6,91	93,28
		5	83,42 \pm 6,90	93,33

Tabelul 9 prezintă ratele de clasificare medii și maxime obținute pentru metodele aplicate, clasificator kNN (k=1:5). Din analiza tabelului se pot desprinde următoarele:

- Metoda ICA, algoritmul JADE oferă cele mai bune rate de clasificare atât medii cât și maxime;
- Distanța Itakura și distanța Itakura simetrică, modelul de ordin 10 prezintă cele mai mari rate de discriminare;
- Pentru indicii PLI și PLV nu se disting diferențe semnificative între ratele de clasificare.

Tabelul 10. Ratele de clasificare medii și maxime obținute pentru metodele aplicate, clasificator SVM

Metodă		SVM	
		Rată de clasificare	
		Medie \pm deviație standard [%]	Maximă [%]
ICA	INFOMAX	82,29 \pm 17,28	100
	SOBI	81,10 \pm 18,07	100
	JADE	86,25 \pm 14,56	100
Distanța Itakura	Model de ordin 6	82,39 \pm 12,61	98,33
	Model de ordin 10	83,10 \pm 16,51	95,37

Distanța Itakura simetrică	Model de ordin 6	80,88 ± 16,90	98,33
	Model de ordin 10	83,24 ± 17,23	96,67
Sincronizarea de fază	PLI	92,69 ± 5,48	99,27
	PLV	92,88 ± 5,24	99,64
	WPLI	82,00 ± 7,06	92,70

Ratele de clasificare medii și maxime obținute pentru metodele aplicate, clasificator SVM sunt prezentate în Tabelul 10. Constatările care se pot desprinde din analiza sunt:

- Algoritmul JADE, metoda ICA oferă rată de clasificare maximă și rata de clasificare medie de 86.25%;
- Modelul de ordin 10 pentru distanța Itakura și distanța Itakura simetrică prezintă cele mai mari rate de clasificare;
- Indicele PLV oferă ratele de clasificare cele mai bune.

Pentru Baza de date BCI Competition 2002 – OSMAN concluziile sunt:

- Pentru algoritmul INFOMAX, cele mai bune rate de clasificare se obțin cu clasificatorul QDA;
- Pentru algoritmul SOBI, cele mai mari rate de clasificare se obțin cu clasificatorul LDA;
- Pentru algoritmul SOBI, cele mai mari rate de clasificare se obțin cu clasificatorul MD;
- Distanța Itakura normalizată, modelul de ordin 10 este cel mai adecvat pentru clasificatorii LDA, QDA și MD;
- Indicii PLI, PLV și wPLI, clasificatorul MD dispune cele mai mari rate de clasificare.

Cele mai bune rate de clasificare pentru clasificatorul kNN sunt oferite de:

- Algoritmul SOBI al metodei ICA;
- Distanța Itakura normalizată cu modelul de ordin 10;
- Indicii PLV și PLI.

Pentru clasificatorul SVM, se disting următoarele metode cu cele mai mari rate de clasificare:

- Algoritmul SOBI;
- Distanța Itakura normalizată cu modelul de ordin 10;
- Indicele PLV.

În general, cele mai ridicate rate de clasificare sunt obținute cu clasificatorul quadratic și cu clasificatorul kNN. Cele mai bune metode de extragere a caracteristicilor prin performanță sunt: sincronizarea fazelor, distanța Itakura și analiza componentei independente. Algoritmii sunt eficienți din punct de vedere al calculului, pur și simplu aplicați și pot fi exploatați de paradigmele imaginilor motorii.

In [Păsărică ISSCS 2017] analiza semnalelor electroencefalografice (EEG) pentru aplicații cu mișcare imaginara utilizând metoda coerenței direcționate parțial (PDC) evidențiază diferențe semnificative între perechile de canale care corespund mișcărilor și mișcărilor imaginare ale creierului. Se îmbunătățește analiza bazată pe PDC prin descompunerea semnalului EEG în componente de frecvență, pentru a identifica benzile de frecvență care sunt în mare parte influențate de activitatea imaginilor motorii. Ne concentrăm asupra perechilor de canale Cz-FP1 și FP1-FP2 datorită faptului că aceste canale prezintă cea mai mare diferență atunci când considerăm că indicatorul PDC reprezintă valorile obținute pentru înregistrările din setul de date. Se calculează diferența statistică dintre mișcare și mișcare imaginară prin dispersia datelor și testul Student "t". Aceste rezultate sunt utilizate pentru identificarea canalelor care sunt potrivite pentru aplicații cu mișcare imaginară, pentru a reduce complexitatea computațională a sistemului interfeței calculatorului creierului (BCI) și a algoritmului corespunzător.

Activitatea cerebrală este dependentă de funcții integrative de nivel înalt atât senzoriale cât și cognitive care se regăsesc în diferite arii ale creierului. Analiza semnalelor electroencefalografice (EEG) se folosește pentru a identifica aceste conexiuni cu scopul de a dezvolta aplicații care permit înțelegerea mai bună a creierului uman³. O aplicație dezvoltată în ultimii ani este reprezentată de implementarea unei modalități de interacționare între om și calculator, denumită interfață creier calculator (brain computer interface - BCI). Aceste dispozitive sunt dezvoltate pentru a permite comunicare fără a folosi sistemul nervos periferic care este implicat în conducerea impulsurilor nervoase de la creier la mușchi și asigurarea unui răspuns de tip feed-back de la receptorii senzoriali din organele de simț sau senzorii mecanici⁴. Complexitatea acestor dispozitive determină un timp de procesare mare al înregistrărilor achiziționate, fiind necesar să se determine condițiile optime de utilizare în ceea ce privește numărul de electrozi EEG folosiți și poziționarea acestora pe scalpul subiectului. Pentru aplicații de interfațare creier-calculator (BCI) numărul de canale EEG analizate este de obicei între 8 și 16⁵.

³ G. Pfurtscheller, C. Neuper, C. Guger, W. Harkman, H. Ramoser, A. Schlogl, B. Obermaier, M. Pregenzer, "Current trends in brain-computer interface (BCI) research", IEEE Transactions on Rehabilitation Engineering, vol. 8, no. 2, 2000

⁴ M. Petti, J. Toppi, F. Babiloni, F. Cincotti, D. Mattia, L. Astolfi, "EEG resting-state brain topological reorganization as function of age", Journal of Computational Intelligence and Neuroscience, vol. 2016, Art. ID 6243694, 1-11, 2016

⁵ F. Pichiorri, G. Morone, M. Petti, J. Toppi, I. Pisotta, M. Molinari, D. Mattia, "Brain-computer interface boosts motor imagery practice during stroke recovery", Annals of Neurology, vol. 77, no. 5, 851-865, 2015

Raportul prezintă analiza cuplării perechilor de canale EEG pentru înregistrări achiziționate în timpul activităților motor-imaginare, activităților motorii sau în timpul repausului. Nivelul de cuplare este determinat folosind metoda de coerență parțial direcționată (partial directed coherence - PDC) bazată pe causalitatea Granger pentru domeniul frecvență⁶. Pentru o analiză mai în profunzime, domeniul de frecvență EEG dintre 0-30 Hz este divizat în patru benzi de frecvență bazate pe ritmurile EEG: Delta, Theta, Alpha și Beta. Această metodă permite determinarea diferitelor caracteristici pentru activități motor imaginare și perioade de repaus. Literatura de specialitate prezintă utilizarea metodei PDC pentru analiza semnalelor EEG luând în considerare domeniul de frecvență 0-30 Hz în întregime. Lucrări de referință care prezintă utilizarea metodei PDC pentru analiza EEG sunt Lee et al. 2016⁷, Omidvarnia et al. 2013⁸ și Liang et al. 2016⁹.

Prima bază de date analizată este EEG Motor Movement/Imagery Dataset disponibilă public de la portalul Physionet.org, denumită pe parcursul raportului ca DB1¹⁰. Această bază de date conține peste 1500 de înregistrări EEG achiziționate de la 108 subiecți diferiți. Aceste înregistrări prezintă 64 de canale EEG și au o lungime de 1-2 minute, cu o frecvență de eșantionare de 160 Hz. Sistemul utilizat pentru achiziționarea acestor înregistrări este BCI 2000^{11 12}.

A doua bază de date analizată, denumită DB2, este reprezentată de BCI Competition IV database dezvoltată de Universitatea Tehnică din Berlin^{13, 14}. Această bază de date conține 10 înregistrări EEG cu 59 de canale achiziționate la o frecvență de eșantionare de 1000 Hz și o rezoluție de 16 biți. Dispozitivul EEG utilizat pentru achiziția acestor înregistrări este asemănător primei baze de date, BCI2000. Semnalele au fost filtrate folosind un filtru trece bandă între 0,05 și 200 Hz. Fiecare înregistrare prezintă secvențe care corespund imaginării mișcării și perioadelor de repaus. Aceste evenimente sunt adnotate pentru fiecare înregistrare, iar pentru a realiza analiza propusă am divizat înregistrările pe baza acestor adnotări. Secvențele de semnal sunt reprezentate de perioade de 4 secunde corespunzătoare activităților motor imaginare și 4 secunde corespunzătoare perioadelor de repaus. În total s-au obținut 994 de subînregistrări de durată scurtă pentru mâna stângă (497 subînregistrări motor imaginare ale mâinii stângi și 497 subînregistrări corespunzătoare perioadelor de repaus) și 998 de înregistrări de durată scurtă pentru mâna dreaptă (499 subînregistrări motor imaginare ale mâinii drepte și 499 subînregistrări corespunzătoare perioadelor de repaus). Baza de date conține de asemenea și înregistrări motor imaginare ale piciorului, dar acestea nu au fost selecționate pentru analiza prezentată în acest raport deoarece se urmărește studiul înregistrărilor similar din baze de date diferite. (Înregistrări motor imaginare ale mâinilor).

Metoda coerenței parțial direcționate (partial directed coherence - PDC)

Metoda implementată pentru această analiză este coerența parțial direcționată (PDC) [14], care a fost adaptată pentru această aplicație prin divizarea intervalului de frecvență EEG cuprins între 0-30 Hz în benzi de frecvență care corespund diferitelor ritmuri EEG. Prima bandă de frecvență este cuprinsă între 0-8 Hz și este specifică ritmurilor Delta, Theta și Alpha1. A doua bandă de frecvență este cuprinsă între 8-12 Hz și corespunde ritmului Alpha2. A treia bandă de frecvență este cuprinsă între 12-18 Hz și corespunde ritmurilor Beta1 și Beta2. Ultima bandă de frecvență este 18-30 Hz corespunzătoare ritmului Beta2 [15]. Acest raport prezintă comparația dintre canalele EEG pentru înregistrări motor imaginare și înregistrări ale activității cerebrale în timpul mișcării. Aceasta are rolul de a determina perechile de canale EEG ce pot fi utilizate pentru aplicații de interfațare om-calculator.

Metoda PDC este implementată prin definirea unui model autoregresiv multivariat (MVAR) al canalelor EEG analizate; pentru această analiză au fost selectate din literatura de specialitate și studiul experimental 11 canale EEG. Modelul MVAR de ordin $p=2$ este definit de formula:

⁶ K. Friston, R. Moran, A.K. Seth, "Analysing connectivity with Granger causality and dynamic causal modelling", *Current opinion in Neurobiology*, vol. 23, no. 2, 172-178, 2013

⁷ K. Lee, K. Kim, J. Song, J. Ryu, Y. Kim, C. Park, "Estimation of brain connectivity during motor imagery tasks using noise-assisted multivariate empirical mode decomposition", *Journal of Electrical Engineering & Technology*, vol. 11, Issue 6, pp. 1812-1824, 2016

⁸ A. Omidvarnia, G. Azemi, B. Boashash, J.M. O'Toole, P.B. Colditz, S. Vanhatalo, "Measuring time-varying information flow in scalp EEG signals: orthogonalized partial directed coherence", *IEEE Transactions on Biomedical Engineering*, vol. 61, Issue 3, pp. 680-693, 2014

⁹ S. Liang, K. Choi, J. Qin, Q. Wang, W. Pang, P. Heng, "Discrimination of motor imagery tasks via information flow pattern of brain connectivity", *Technology and Health Care*, vol. 24, pp. 795-801, 2016

¹⁰ A.L. Goldberger, L.A.N. Amaral, L. Glass, J.M. Hausdorff, P.C.H. Ivanov, R.G. Mark, J.E. Mietus, G.B. Moody, C.K. Peng, H.E. Stanley, "Physiobank, PhysioToolkit and PhysioNet: components of a new research resource for complex physiological signals", *Circulation*, vol. 101, issue 23, pp. e215-e220, 2000

¹¹ <http://www.schalklab.org/research/bci2000>

¹² G. Shalk, D.J. McFarland, T. Hinterberger, J.R. Wolpaw, "BCI2000: a general purpose brain-computer interface (BCI)

¹³ <http://www.bbci.de/competition/iv/#dataset1>

¹⁴ B. Blankertz, G. Dornhege, M. Krauledat, K.R. Muller, G. Curio, "The non-invasive Berlin brain-computer interface: fast acquisition of effective performance in untrained subjects", *Journal of Neuroimage*, vol. 37, no. 2, 539-550, 2007

$$\begin{bmatrix} x_I(n) \\ \vdots \\ x_N(n) \end{bmatrix} = \sum_{r=1}^p A_r \begin{bmatrix} x_I(n-r) \\ \vdots \\ x_N(n-r) \end{bmatrix} + \begin{bmatrix} w_I(n) \\ \vdots \\ w_N(n) \end{bmatrix} \quad (1)$$

unde $w(n)$ este matricea de covarianță, A_r (ecuația 2) reprezintă matricea care conține elementele $a_{ij}(r)$ care reprezintă interacțiunea liniară dintre două secvențe consecutive $x_j(n-r)$ și $x_i(n)$.

$$A_r = \begin{bmatrix} a_{11}(r) & a_{12}(r) & \dots & \dots & a_{1N}(r) \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ \vdots & \vdots & \vdots & a_{ij}(r) & \vdots \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ a_{N1}(r) & \dots & \dots & \dots & a_{NN}(r) \end{bmatrix} \quad (2)$$

Influența dintre canalele EEG este determinată pe baza indicatorului de corelație determinat folosind:

$$\pi_{ij}(n) = \frac{A_{ij}(n, f)}{\sqrt{a_j^H(n, f) a_j(n, f)}} \quad (3)$$

unde $\pi_{ij}(n)$ este parametrul de corelație, H este transpusa Hermetiană, $A_{ij}(n, f)$ este transformata Fourier a matricii $A_r(n)$ cu elementele $a_{ij}(n, f)$, n numărul de ferestre analizate și f variabila corespunzătoare benzilor de frecvență prezentate anterior. Valoarea indicatorului de corelație este cuprinsă în intervalul (0, 1), cu semnificația valorilor apropiate de 0 reprezentând un nivel scăzut de cuplare și valorile apropiate de 1 reprezentând un nivel crescut de cuplare.

Pentru analiza prezentată am folosit o fereastră glisantă de tip Hanning cu lungimea $N=500$ eşantioane și o suprapunere de 125 de eşantioane. Fereastra Hanning este definită astfel:

$$w(n) = \frac{1}{2} \times \left(1 - \cos\left(\frac{2\pi x(n)}{N}\right) \right); 0 \leq n \leq N \quad (4)$$

unde $w(n)$ reprezintă valoarea pentru eşantionul n , $x(n)$ este valoarea seriei de timp pentru eşantionul n , pentru acesată aplicație semnalul EEG, iar N reprezintă lungimea ferestrei glisante.




Figura 6 - Reprezentarea ferestrei Hanning în domeniul timp și frecvență

Suprapunerea ferestrelor este necesară pentru a preveni pierderile de informații la începutul și sfârșitul ferestrei analizate deoarece aceste valori sunt situate în apropierea valorii 0, așa cum este prezentat în figura de mai sus. Această metodă reduce generarea de lobi secundari, ceea ce reprezintă un avantaj pentru aplicații cu frecvențe selective.

Rezultatele analizei folosind metoda PDC au fost procesate pentru a determina perechile de canale care oferă cele mai multe informații pentru a înțelege cuplările în activități motor imaginare și legăturile dintre diferitele arii ale creierului. Rezultatele prezentate în tabelele de mai jos reprezintă valoarea medie a indicatorului PDC și deviația standard obținute pentru perechile de canale C3-Pz, C4-Pz, F1-F2, FC3-Fz, FC4-Fz și Fz-Pz.

Pentru perechile de canale C3-Pz/C4-Pz și FC3-Fz/FC4-Fz care au electrozii poziționați bilateral pe cele două emisfere ale creierului (emisfera stângă și emisfera dreaptă) se pot observa valori ridicate ale nivelului de corelație. Electrozii C3 și FC3 sunt localizați pe emisfera stângă în aria centrală, iar electrozii C4 și FC4 sunt localizați complementar, dar pe emisfera dreaptă. Acest aspect indică faptul că ambele emisfere sunt implicate în procesul cognitiv al activității motor imaginare.

motor imaginare au un nivel de corelație mai ridicat, comparativ cu înregistrări care conțin atât perioade motor imaginare cât și perioade de repaus. Prin divizarea domeniului de frecvență EEG în benzi de frecvență pe baza ritmurilor EEG se poate observa un nivel mai ridicat al indicatorului PDC pentru componentele de frecvență ridicată 18-30 Hz din cauza faptului că această bandă de frecvență corespunde ritmului Beta 2 specific activităților cerebrale motor imaginare sau mișcării propriu-zise.

Paramtrul de corelație obținut prin metoda PDC indică un nivel ridicat de cuplare între anumite perechi de canale EEG. Analiza prezentată ca o comparație între două baze de date arată că în timpul activităților motor imaginare sunt active multiple arii ale creierului: aria frontală responsabilă cu mișcarea, aria central-parietal-occipitală responsabilă cu integrarea informațiilor senzoriale provenite de la organele de simț și de la receptorii de feedback de la nivelul mușchilor. Atât influența directă cât și cea indirectă și implicit valoarea ridicată a indicatorului PDC sunt dovada unei bucle constante între ariile creierului și componentele senzoriale ale corpului uman. Trebuie avut în vedere și faptul că valori ridicate ale parametrului PDC s-au obținut pentru perechi de canale situate în emisfere diferite ale creierului, de exemplu, perechile FC3-Pz/FC4-Pz sau C3-Pz/C4-Pz. Acest aspect indică implicarea ambelor emisfere în activități motor imaginare. Ca referință se folosește semnalul achiziționat în perioadele de repaus din DB2 care indică un nivel scăzut de corelare între perechile de canale din cauza unui nivel scăzut de activitate cerebrală.

Implementarea unui sistem de interfațare om-calculator (BCI) care utilizează multiple canale EEG necesită identificarea și analiza unei configurații optime în ceea ce privește numărul de electrozi și poziționarea acestora. Analiza PDC este utilizată pentru a identifica acele canale potrivite pentru o astfel de aplicație, cu scopul de a reduce timpul computațional al unui sistem BCI și al algoritmul utilizat.

LUCRARI ALE MEMBRILOR ECHIPEI PE DOMENIUL PROIECTULUI IN PERIOADA OCTOMBRIE 2015 – SEPTEMBRIE 2017

[Fira IJARAI 2015] Adrian Brezilianu, Monica Fira, Marius Daniel Pestina, *Compressed Sensing Based Encryption Approach for Tax Forms Data*, International Journal of Advanced Research in Artificial Intelligence (IJARAI), Volume 4 Issue 11, 2015 (Revista BDI)

[Fira EHB 2015] Fira Monica, *Applications of Compressed Sensing: Compression and Encryption*, International Conference on e-Health and Bioengineering, EHB 2015, 19-21 Noiembrie, Iasi, Romania (conferinta indexata IEEE Xplore si ISI proceedings)

[Feraru EHB 2015] Silvia Monica Feraru, Marius Dan Zbancioc, Roxana Mihaela Barbu, Cristina Maria, *Using the Decision Tree for Emphasizing the Benefits of Associating Antioxidants in the Therapy of the Metabolic Syndrome*, International Conference on e-Health and Bioengineering, EHB 2015, 19-21 Noiembrie, Iasi, Romania (conferinta indexata IEEE Xplore si ISI proceedings)

[Eva EHB 2015] Oana-Diana Eva și Anca Mihaela Lazăr, *Channel Selection for Motor Imagery Paradigm - an Itakura Distance based Method*, International Conference on e-Health and Bioengineering, EHB 2015, 19-21 Noiembrie, Iasi, Romania (conferinta indexata IEEE Xplore si ISI proceedings)

[Eva Buletin 2015] Oana-Diana Eva, Anca Mihaela Lazăr, Monica Fira, *Normalized Itakura Distance for MU Rhythm*, Buletinul Institutului Politehnic din Iași, Tomul LIX (LXIII), Fasc. 4, 2015, Secția, Electrotehnică, Energetică, Electronică, pp. 91- 101 (Revista BDI)

[Fira ICT4AWE2016] Monica Fira, Liviu Goras, Victor-Andrei Maiorescu and Mihaela Catalina Luca, *Compressed Sensing and Clasification of Cardiac Beats Using Patient Specific Dictionaries*, International Conference of Information and Communication Technologies for Ageing Well and e-Health - ICT4AWE2016, Roma, Italia, 21-22 aprilie 2016

[Fira ACHI 2016] Monica Fira, Liviu Goras, Victor-Andrei Maiorescu, *The Analysis of the Specific Dictionaries for Compressive Sensing of EEG Signals*, International Conference on Advances in Computer-Human Interactions - ACHI 2016, Veneția, Italia, 24-28 aprilie 2016

[FiraCOMMS 2016] Monica Fira, Liviu Goras, *On Compressed Sensing for EEG Signals - Validation with P300 Speller Paradigm*, International Conference on Communications, COMMS 2016, Bucharest, Romania, 9-11 iunie 2016, DOI: 10.1109/ICComm.2016.7528296 (conferinta indexata IEEE Xplore si ISI proceedings)

[Fira IJACSA 2016 A] Monica Fira, *Compressed Sensing of Multi-Channel EEG Signals: quantitative and qualitative evaluation with Speller Paradigm*, International Journal of Advanced Computer Science and Applications (IJACSA), Vol. 7, No. 6, 2016 (revista indexata ISI - Thomson Reuters)

[Feraru DAS 2016] Monica Feraru, Monica Fira și Marius Zbancioc, *A new emotional corpus for the Romanian Language*, International Conference on Development and Application Systems DAS 2016, 19-21 mai 2016, Suceava, Romania (conferinta indexata IEEE Xplore si ISI proceedings)

[Fira SOMET 2016] Monica Fira, Andrei Maiorescu, *P300 spelling and EEG compressed sensed based on a universal megadictionary*, International Conference on Intelligent Software Methodologies, Tools and Techniques - SOMET 2016, Larnaca, Cipru, 12-14 septembrie 2016 (Volume 286: New Trends in Software Methodologies, Tools and Techniques, Series Frontiers in Artificial Intelligence and Applications, IOS press, DOI 10.3233/978-1-61499-674-3-203, pp: 203 - 212) (Revista BDI)

[Fira IJACSA 2016] Monica Fira, Liviu Goras, *Comparison of inter-and intra-subject variability of P300 spelling dictionary in EEG compressed sensing*, International Journal of Advanced Computer Science and Applications (IJACSA), Vol. 7, No. 10, 2016 (revista indexata ISI - Thomson Reuters)

[Fira ICBBT 2017] Monica Fira, Liviu Goras, *"On the size of the universal dictionaries used in EEG P300 spelling paradigm based on compressed sensing"*, 9Th International Conference on Bioinformatics and Biomedical Technology (ICBBT 2017), Lisabona, Portugalia, 14-16 mai 2017

[Fira ICCGI 2017] Monica Fira, *"The EEG Signal Classification In Compressed Sensing Space"*, The Twelfth International Multi-Conference on Computing in the Global Information Technology – ICCGI 2017, Nice, Franta, 23 -27 iulie 2017

[Eva IJACSA 2017] Oana Doana Eva, Anca Lazar, *"Feature Extraction and Classification Methods for a Motor Task Brain Computer Interface: A Comparative Evaluation for Two Databases"*, International Journal of Advanced Computer Science and Applications (IJACSA), septembrie, 2017

[Păsărică ISSCS 2017] Păsărică A., Eva O.D., Tărniceriu D., *"Analysis of EEG Channel Coupling for Motor Imagery Applications"*, International Symposium on Signals Circuits and Systems – ISSCS 2017, 13-14 Iulie 2017, Iasi, Romania

[Cleju ISSCS 2017] Nicolae Cleju, *Least Squares Pursuit for Sparse Signal Recovery*, International Symposium on Signals Circuits and Systems – ISSCS 2017, 13-14 Iulie 2017, Iasi, Romania

[Păsărică Buletin 2017] Păsărică A., Eva O.D., Tărniceriu D., *Study of electroencephalographic channels coupling in multiple database analysis*, Lucrare acceptata la Buletinul Institutului Politehnic din Iași, Secția Electrotehnică, Energetică, Electronică

[Eva Buletin 2017] Eva O.D., Păsărică A., Tărniceriu D., *Phase synchronization based channel selection for a motor imagery paradigm*, Lucrare acceptata la Buletinul Institutului Politehnic din Iași, Secția Electrotehnică, Energetică, Electronică

[Feraru ISSCS 2017] Feraru Silvia Monica, Zbancioc Marius Dan, *Emotion recognition for disgust and boredom states*, International Symposium on Signals Circuits and Systems – ISSCS 2017, 13-14 Iulie 2017, Iasi, Romania

LUCRARI IN EVALUARE

[Cleju 2016] N. Cleju, *Analysis Sparsity With Explicit Orthogonality Constraint*, Acta Applicandae Mathematicae, Ed. Springer, în evaluare, trimis în 28.07.2016 (revista cu factor de impact 0.853).