

## **Raport stiintific**

*privind implementarea proiectului in perioada ianuarie – decembrie 2012*

*Proiect PN-II-ID-PCE-2011-3-0400, "Reprezentari rare in prelucrarea semnalelor"*

### **Rezultate obtinute si publicatii**

Pentru lectura rapida a acestui raport, voi descrie la inceput pe scurt rezultatele obtinute si apoi le voi prezenta cu unele detalii tehnice.

Pana in acest moment, din activitatea de cercetare desfasurata in cadrul proiectului au rezultat publicatiile [1-6]. Dintre acestea patru articole sunt publicate [1,2] sau acceptate [3,4] in reviste ISI cu foarte buna reputatie, anume Signal Processing, IEEE Signal Processing Letters, Linear Algebra and Its Applications si Optimization and Engineering. Celelalte doua articole au fost prezentate la conferinta europeana cea mai importanta in prelucrarea semnalelor, EUSIPCO.

Cercetarea pentru publicatiile [2], [5] si [6] a fost efectuata aproape integral in 2012, iar pentru [3] doar partial. Publicatiile [1] si [4] au fost finalizate in 2011, [4] fiind in fapt inceputa si realizata in buna masura intr-un proiect IDEI anterior.

De asemenea, in ultima parte a anului 2012, au fost trimise spre publicare inca un articol de revista si doua la conferinte, dar nu am primit inca nici o decizie in privinta lor, asa ca nu voi da titlurile si destinatia articolelor. Continutul lor va fi mentionat in partea rezervata descrierii tehnice.

In noiembrie 2012, unul din membrii echipei, Cristian Rusu, a sustinut teza de doctorat, obtinand calificativul excelent.

### **Directii de cercetare**

In propunerea de proiect au fost specificate patru directii de cercetare:

- O1.** Proiectarea filtrelor rare
- O2.** Problema celor mai mici patrate totala rara (sparse total least squares)
- O3.** Filtrare rara distribuita
- O4.** Clasificare cu predictorii rari

Pe parcursul acestui an, tema O4 a fost extinsa la proiectarea dictionarelor pentru reprezentari rare, care acopera problema de clasificare (in modul in care era ea vazuta in propunerea de proiect) si, in plus, contine probleme de reprezentare foarte actuale. La tema O3 inca nu am inceput lucrul, unul dintre motive fiind lipsa unui mediu paralel de calcul.

## Descriere tehnica a rezultatelor

Voi detalia in continuare avansurile si rezultatele efective obtinute. Membrii echipei (Bogdan Dumitrescu, Bogdan Sicleru, Cristian Rusu) vor fi numiti prin initialele lor.

**O1.** Filtrele FIR care au  $s$  coeficienti diferiti de zero pot avea caracteristici de frecventa mai bune decat filtrele cu lungime  $s$ , deci cu ordin minim, iar complexitatea implementarii lor este similara. Succesul obtinut cu [1] in 2011 ne-a facut (BD si BS) sa extindem cercetarea la alte probleme.

O prima directie de atac, concretizata in [5], a fost proiectarea bancurilor de filtre rare 2-D prin metoda transformarii de variabile [TK93], care permite un compromis intre complexitatea implementarii si calitatea raspunsului in frecventa al filtrului obtinut. Fiecare filtru al bancului este implementat ca o combinatie intre un filtru simplu 1D si un filtru 2D, numit de transformare, cu o anume structura. Noi am urmarit obtinerea unui filtru rar de transformare. Metoda cea mai eficienta a fost cea lacoma (greedy), prin care cel mai mic coeficient al filtrului de transformare este fixat la zero, apoi optimizarea continua pentru ceilalti coeficienti. Datorita neconvexitatii problemei generale de optimizare, am impartit procesul de optimizare in mai multe etape, in fiecare minimizandu-se un criteriu de tip CMMP prin rezolvarea unei probleme convexe. Sunt optimizate pe rand transformarea in sine, filtrul 2D rezultat avand ca variabile coeficientii transformarii si filtrul 2D rezultat avand ca variabile coeficientii filtrului 1D. Se pot astfel obtine filtre rare care au energia in banda de oprire mai mica decat a filtrelor pline.

O a doua directie, finalizata de curand cu o lucrare trimisa la o conferinta (n-am primit inca acceptarea), se refera la factorizarea spectrala rara. Problema este urmatoarea: dandu-se o secventa de autocorelatie  $R(z)$ , sa se gaseasca secventa cauzala rara  $H(z)$  astfel incat  $R(z)=H(z)H(1/z)$ . Problema este foarte recenta [LV11,JOH12] si, ca mai toate problemele cu reprezentari rare, este NP-hard, deci rezolvabila in timp rezonabil doar cu metode euristice. Lucrarile citate folosesc relaxari convexe. Dificultatea problemei provine din faptul ca, de obicei, dintre factorii spectrali ai secventei de autocorelatie, doar unul (si eventual transformari simple ale lui) este rar (daca exista), ceilalti fiind plini. Am utilizat un rezultat anterior privind factorizarea spectrala cu baza rara cunoscuta [Du07] utilizand o problema de programare semidefinita (SDP); desi nu garanteaza rezultatul, problema SDP are de obicei ca solutie o matrice de rang 1 care da imediat factorul spectral. Am integrat acest test de existenta a factorizarii spectrale intr-un algoritm lacom in care se porneste de la suportul secventei de autocorelatie si se elimina pe rand cate un coeficient. Daca exista factorul spectral cu acel suport, procesul de eliminare continua; daca nu, se incearca eliminarea altuia. In prima faza, o parte din suportul secventei de autocorelatie este eliminata, folosind reguli simple privind structura pe care trebuie s-o aiba. Algoritmul propus da rezultate doar putin mai bune decat algoritmi anteriori, dar este mult mai rapid decat acestia si poate fi folosit chiar daca ordinul secventei de autocorelatie este mare.

**O2.** Problema celor mai mici patrute totale (CMMPT) rara este un subiect foarte actual, mai multe lucrari recente tratand diverse forme ale ei [HS10,ZLG11], fara a mentiona neaparat explicit apartenenta la acest tip de problema. BD a obtinut o conditie teoretica ce caracterizeaza situatia in care solutiile problemelor CMMP si CMMPT rare au acelasi suport de dimensiune  $s$ . Conditia este exprimata in functie de constantele de izometrie restransa ale matricei sistemului si de unghiul minim intre subspatii de dimensiune  $s$  formate de coloanele matricei. Nu exista un rezultat similar in literatura de specialitate. De asemenea, au fost propusi cativa algoritmi lacomi, care in multe cazuri gasesc o solutie mai apropiata de cea reala decat algoritmul din [ZLG11].

Lucrarea a fost trimisa spre publicare in decembrie 2011, dar a necesitat o revizie semnificativa in iunie 2012, incluzand refacerea unor teste numerice care sa arate cat de stranse sunt conditiile impuse. Noi

simulari ale algoritmilor au permis o descriere mai completa a rezultatelor acestora. Concluziile initiale au ramas insa practic neschimbate, iar articolul a fost finalmente acceptat.

**O4.** De aceasta tema se ocupa CR (supervizat de BD), a carui teza de doctorat a fost dedicata proiectarii dictionarelor pentru reprezentari rare. Principalele rezultatele obtinute sunt urmatoarele:

1. Simplificarea setului de antrenare pentru optimizarea dictionarelor pentru reprezentari rare cu ajutorul algoritmului K-SVD [AEB06]. Motivarea este data de durata mare de antrenare necesitata de algoritmul K-SVD (care da rezultate de calitate mai buna decat alti algoritmi) atunci cand numarul vectorilor de antrenare depaseste cateva zeci de mii. Algoritmul propus in [6] se bazeaza pe gruparea vectorilor de antrenare in clustere si utilizarea algoritmului K-SVD folosind un singur reprezentant al fiecarui cluster. Algoritmul K-SVD este usor modificat pentru a tine seama de numarul de vectori din fiecare cluster. Gruparea in clustere se face utilizand doar produse scalare si un proces iterativ de grupare. Algoritmul rezultat este mult mai rapid decat K-SVD iar eroarea de reprezentare cu dictionarul astfel obtinut este comparabila cu cea a dictionarului dat de K-SVD. Rezultatele sunt descrise pe larg in [6].
2. Un algoritm pentru antrenarea de dictionare cu dimensiune mica, descris in [2], care este probabil cea mai semnificativ rezultat obtinut pana acum in acest proiect. Algoritmul construiește dictionarul prin adaugarea de atomi alesi dintre cei mai prost reprezentati vectori de antrenare, urmata de cativa pasi in stil K-SVD de antrenare a dictionarului. Adaugarea si reantrenarea se repeta pana cand dictionarul satisface o eroare de reprezentare impusa. Deoarece se lucreaza cu dictionare mici, cel putin in fazele de inceput, algoritmul este relativ rapid, cu timp total comparabil cu cel al K-SVD. Mai important, dimensiunea dictionarului este cu 30-50% mai mica decat cea a dictionarului antrenat direct cu K-SVD. In acest fel, viteza aplicatiilor care folosesc dictionarele creste semnificativ, deoarece timpul de calcul al unei reprezentari este (cel putin) proportional cu dimensiunea dictionarului.
3. Un algoritm pentru optimizarea de dictionare cu incoerenta mare (coerenta este produsul scalar maxim intre doi atomi ai dictionarului, deci cu cat dictionarul este mai incoerent, cu atat atomii sunt mai aproape de ortogonalitate). Astfel de dictionare au in general proprietati mai bune in privinta certificarii raritatii reprezentarilor obtinute; gasirea celei mai bune reprezentari, cu algoritmi simpli obisnuiti gen OMP (Orthogonal Matching Pursuit), este mai frecventa decat in cazul dictionarelor coerente. In schimb, acestea din urma pot da eroare de reprezentare mai buna pentru anumite seturi de date. Algoritmul are doua faze. In prima se obtine un dictionar incoerent fara a se utiliza datele de antrenare; folosind o procedura iterativa in care se rezolva la fiecare pas probleme de programare liniara, se obtin rezultate mai bune decat cele din lucrarile anterioare cele mai recente. In faza a doua, pe baza datelor de antrenare, se proiecteaza doar o matrice ortogonala care inmulteste primul dictionar, pastrand astfel incoerenta. Ideea si procedura sunt originale. Pe baza rezultatelor descrise mai sus, un articol a fost trimis la o revista de top.
4. Un algoritm pentru proiectarea de dictionare formate din matrice ortogonale, in care reprezentarea unui vector de antrenare se face intr-o singura astfel de matrice. Chiar daca dictionarele obtinute au dimensiune mare, reprezentarea este extrem de rapida, batand chiar algoritmi rapizi ca OMP, in conditiile unor erori de reprezentare egale. Superioritatea fata de algoritmi care folosesc blocuri ortogonale, dar in care reprezentarea poate utiliza atomi oarecare, este evidenta. Un articol continand intreaga procedura si rezultate numerice a fost trimis la o conferinta.

## **Greutati intampinate si alte informatii**

In general, activitatea de cercetare a decurs normal, ceea ce era de asteptat, echipa fiind mica si formata inaintea inceperii proiectului. Singura problema notabila, cauzata de lentoarea procedurilor de achizitie din UPB (similara probabil cu cea din alte institutii de stat), a fost intarzierea achizitiei unei statii grafice performante, pe care sa o utilizam pentru implementarea unor algoritmi paraleli pe GPU. Desi procedurile au fost demarate in martie, sosirea efectiva a statiei este asteptata in cursul lunii decembrie.

O alta problema a fost accesul intermitent si partial la bazele de date cu articole stiintifice. Pentru noi dificultatea e totusi minora, intrucat am acces la aceste informatii prin intermediul Universitatii Tehnice din Tampere, unde sunt FiDiPro Fellow. Acest mod de lucru nu este totusi nici normal, nici natural.

Pagina web dedicata proiectului este <http://www.schur.pub.ro/Idci2011.htm>.

## **Articole publicate sau acceptate in reviste ISI**

[1] C.Rusu, B.Dumitrescu – Iterative Reweighted  $l_1$  Design of Sparse FIR Filters, Signal Processing, vol.92, no.4, pp.905-911, Apr. 2012.

[2] C.Rusu, B.Dumitrescu – Stagewise K-SVD to Design Efficient Dictionaries for Sparse Representations, IEEE Signal Processing Letters, vol.19, no.10, pp.631-634, Oct. 2012.

[3] B.Dumitrescu – Sparse Total Least Squares: Analysis and Greedy Algorithms, Linear Algebra and its Applications, accepted, 2012.

[4] B.C.Sicleru, B.Dumitrescu - POS3POLY - a MATLAB Preprocessor for Optimization with Positive Polynomials, Optimization and Engineering, accepted, 2012.

## **Articole publicate la conferinte**

[5] B.C.Sicleru, B.Dumitrescu – Least-Squares Design of 2-D Sparse Nonseparable Filter Banks Using Transformation of Variables: a Greedy Approach, EUSIPCO, Bucharest, Romania, pp. 76-80, Aug. 2012.

[6] C.Rusu – Clustering Before Training Large Datasets - Case Study: K-SVD, EUSIPCO, Bucharest, Romania, pp. 2188-2192, Aug. 2012.

## **Bibliografie**

[AEB06] M. Aharon, M. Elad, A. Bruckstein, „K-SVD: An Algorithm for Designing Overcomplete Dictionaries for Sparse Representation,” IEEE Trans. Signal Proc., vol.54, no.11, pp. 4311-4322, Nov. 2006.

[Du07] B. Dumitrescu, “Positive Trigonometric Polynomials and Signal Processing Applications,” Springer, 2007.

[HS10] M. Herman, T. Strohmer, “General Deviants: An Analysis of Perturbations in Compressed Sensing”, IEEE J. Sel. Topics Signal Proc., vol.4, no.2, pp.342–349, 2010.

[JOH12] K. Jaganathan, S. Oymak, and B. Hassibi, "Phase retrieval for sparse signals using rank minimization," in Proc. Int. Conf. Acc. Speech and Sign. Proc. (ICASSP), Kyoto, Japan, March 2012, pp. 3449–3452.

[LV11] Y.M. Lu and M. Vetterli, "Sparse spectral factorization: unicity and reconstruction algorithms," in Proc. Int. Conf. Acc. Speech and Sign. Proc. (ICASSP), Prague, Czech Republic, May 2011, pp. 5976–5979.

[TK93] D.B.H. Tay and N.G. Kingsbury, "Flexible design of multidimensional perfect reconstruction FIR 2-band filters using transformations of variables," IEEE Trans. Image Proc., vol. 2, no. 4, pp. 466–480, Oct. 1993.

[ZLG11] H. Zhu, G. Leus, G. Giannakis, "Sparsity-Cognizant Total Least-Squares for Perturbed Compressive Sampling", IEEE Trans. Signal Proc., vol.59, no.5, pp. 2002–2016, May 2011.

Director proiect,

Prof. Bogdan Dumitrescu

A handwritten signature in black ink, appearing to read 'B. Dumitrescu', is positioned below the typed name.