

**COMPETIȚIA DE PROIECTE DE CERCETARE A ACADEMIEI OAMENILOR
DE ȘTIINȚĂ DIN ROMÂNIA “AOȘR-TEAMS-III”
EDIȚIA 2024-2025**

**Dezvoltarea de soluții iterative îmbunătățite bazate pe descompuneri tensoriale
pentru aplicații în domeniul acustic**

ETAPA 3 – RAPORT DE CERCETARE ȘTIINȚIFICĂ

Rezumatul etapei

Obiectivul specific corespunzător celei de a treia etape a proiectului (desfășurată în perioada decembrie 2024 – iunie 2025) este:

O3. Îmbunătățirea performanțelor și studiul de convergență al algoritmilor adaptivi bazați pe descompuneri tensoriale de ordin superior.

În cadrul acestei etape de cercetare au fost îndeplinite toate activitățile asociate acestui obiectiv specific, prevăzute în planul de realizare a proiectului, după cum urmează:

1. Dezvoltarea unor variante cu performanță îmbunătățită ale algoritmului RLS bazat pe descompunerea tensorială.
2. Analiza de convergență a algoritmului RLS bazat pe descompunerea tensorială.
3. Dezvoltarea unor metode de estimare a parametrilor de incertitudine ai filtrului Kalman bazat pe descompunerea tensorială.
4. Publicarea unui articol de cercetare pe baza rezultatelor obținute.
5. Realizarea celui de-al treilea raport privind rezultatele intermediare ale proiectului.

Rezultatele din cadrul acestei etape de cercetare au fost publicate în lucrările [1, 2] din lista de referințe.

1 Introducere

În contextul identificării de sistem [3], dificultatea generală crește atunci când se avem de-a face cu identificarea răspunsurilor la impuls de lungă durată, care ridică provocări semnificative în ceea ce privește complexitatea computațională și acuratețea soluției. Un exemplu binecunoscut este legat de scenariile de compensare a ecoului acustic [4], unde traseele ecoului acustic sunt modelate ca filtre cu răspuns finit la impuls care pot atinge mii de coeficienți. În acest context, criteriile de performanță dorite sunt greu de atins atunci când avem de-a face cu un spațiu de parametri atât de mare. Pentru a îmbunătăți performanța metodelor de identificare atunci când se confruntă cu răspunsuri impuls de lungă durată, este firesc să se exploateze proprietățile intrinseci ale sistemelor de identificat. Acestea se pot referi, printre altele, la caracteristicile de raritate [5], caracteristicile de simetrie [6], proprietăți de rang scăzut [7], printre altele.

Mai multe abordări recente s-au concentrat pe tehnici bazate pe descompunere care implică cel mai apropiat produs Kronecker *nearest Kronecker product* - NKP) și aproximări de rang scăzut, e.g., [8] și [9] (cu referințele din acestea). Aceste metode exploatează descompunerea în valori singulare (*singular value decomposition* - SVD) a matricei corespunzătoare a răspunsului la impuls remodelat (obținut prin vectorizare inversă) și caracteristica sa de rang scăzut. Cu alte cuvinte, dacă un răspuns la impuls \mathbf{h} de lungime $L = L_1' L_2'$ (cu $L_2' \leq L_1'$) este remodelat ca o matrice \mathbf{H} de dimensiune $L_1' \times L_2'$ și rangul acestei matrice corespondente este $P' < L_2'$, atunci sistemul care trebuie identificat are proprietatea de rang scăzut. Prin urmare, folosind NKP, răspunsul la impuls poate fi descompus ca $\mathbf{h} = \sum_{p'=1}^{P'} \mathbf{h}_{2,p'} \otimes \mathbf{h}_{1,p'}$, unde $\mathbf{h}_{1,p'}$ și $\mathbf{h}_{2,p'}$ ($p' = 1, 2, \dots, P'$) sunt răspunsuri la impulsuri de lungimi L_1' și respectiv L_2' , iar \otimes este produsul Kronecker [10]. Ca rezultat, această abordare reformulează problema inițială de identificare a sistemului (care se bazează pe un singur filtru de lungime mare) pe baza unei combinații de două filtre (mult) mai scurte, de lungimi $P' L_1'$ și $P' L_2'$, care grupează seturile de coeficienți $\mathbf{h}_{1,p'}$ și $\mathbf{h}_{2,p'}$, cu $p' = 1, 2, \dots, P'$. În consecință, duce la câștiguri importante în ceea ce privește complexitatea și acuratețea soluției. Deoarece o gamă largă de sisteme din lumea reală dețin caracteristici de rang scăzut, această tehnică bazată pe descompunere a fost

aplicată cu succes în cadrul multor aplicații importante. Cu toate acestea, tehnica bazată pe NKP utilizată în aceste lucrări se bazează pe descompunerea de ordinul al doilea, exploatând SVD-ul matricei corespunzătoare (de rang scăzut) asociată răspunsului la impuls. Extinderea acestei tehnici la o descompunere de ordin superior se confruntă cu dificultatea de a lucra cu un tensor de rang superior, unde rangul său rezultă dintr-o sumă de tensori de rang 1. În contextul descompunerii de ordinul al doilea, ne bazăm pe faptul că rangul unei matrice este limitat de numărul coloanelor sale. Pe de altă parte, pentru descompunerea de ordin superior, rangul unui tensor de ordin superior ar putea depăși dimensiunea sa cea mai mare; prin urmare, aproximarea rangului său ar fi o problemă sensibilă [11, 12].

Recent, o metodă alternativă de extindere a abordării bazate pe NKP la un nivel de descompunere de ordinul al treilea a fost prezentată în [13], vizând o reducere mai mare a dimensionalității (adică o combinație de trei filtre mai scurte). În această lucrare anterioară, rangul unui tensor de ordinul al treilea este controlat în termeni de rang de matrice, care este limitat la valori mici. Cu toate acestea, extinderea abordării de descompunere de ordinul al treilea la un nivel de ordin superior nu poate fi realizată într-o manieră simplă.

În cadrul acestei etape a proiectului, a fost urmarită metoda de descompunere a tensorilor de ordinul al patrulea și au fost proiectați algoritmi adaptivi care exploatează această tehnică eficientă. Algoritmii rezultați actualizează în paralel și combină coeficienții a patru filtre adaptive de lungimi mult mai scurte (în comparație cu lungimea răspunsului la impuls original), obținând astfel un câștig important atât în ceea ce privește reducerea complexității, cât și creșterea performanței. Caracteristica principală a acestei abordări este că rangul tensorului este controlat și limitat la o valoare cunoscută, fără a necesita tehnici de aproximare. Această metodă de descompunere este potrivită pentru identificarea răspunsurilor la impuls de lungime mare, deoarece operează cu structuri de date mai mici.

2 Algoritmi de filtrare adaptivă bazați pe descompuneri tensoriale de ordin superior

Să considerăm cadrul unei probleme de identificare a unui sistem liniar, care funcționează într-un scenariu cu o singură intrare și o singură ieșire (*single input - single output - SISO*). Scopul de bază este de a obține o estimare bună a răspunsului la impuls necunoscut, având la dispoziție secvența de intrare și un semnal de referință, care reprezintă ieșirea sistemului necunoscut [6]. În acest context,

$$\mathbf{h} = [h_0 \quad h_1 \quad \cdots \quad h_{L-1}]^\top \quad (1)$$

este un răspuns impuls cu L coeficienți cu valori reale; aici, $^\top$ reprezintă operatorul de transpunere. Se presupune că $L = L_1 L_2$, cu $L_1 \geq L_2$ și L_1 și L_2 au același ordin. Așadar, după cum a fost arătat în [7], [8], acest răspuns la impuls al sistemului poate fi reprezentat în următoarea formă:

$$\mathbf{h} = \sum_{i=1}^{L_2} \mathbf{h}_2^i \otimes \mathbf{h}_1^i, \quad (2)$$

unde \mathbf{h}_1^i și \mathbf{h}_2^i sunt două răspunsuri de impuls de lungimi mai mici (în comparație cu \mathbf{h}), având L_1 și respectiv, L_2 coeficienți; aici, \otimes reprezintă produsul Kronecker [10].

În continuare, să considerăm că $L_1 = L_{11} L_{12}$, unde $L_{11} \geq L_{12}$; de asemenea, fie $L_2 = L_{21} L_{22}$, cu $L_{21} \geq L_{22}$. Putem aplica aceeași descompunere din (2) la \mathbf{h}_1^i și \mathbf{h}_2^i , adică

$$\mathbf{h}_1^i = \sum_{j=1}^{L_{12}} \mathbf{h}_{12}^{ij} \otimes \mathbf{h}_{11}^{ij}, \quad (3)$$

unde \mathbf{h}_{11}^{ij} și \mathbf{h}_{12}^{ij} sunt două răspunsuri la impuls de lungimi mai mici (comparativ cu \mathbf{h}_1^i), cu L_{11} și respectiv L_{12} coeficienți, în timp ce

$$\mathbf{h}_2^i = \sum_{k=1}^{L_{22}} \mathbf{h}_{22}^{ik} \otimes \mathbf{h}_{21}^{ik}, \quad (4)$$

unde \mathbf{h}_{21}^{ik} și \mathbf{h}_{22}^{ik} sunt două răspunsuri la impuls de lungimi mai scurte (în comparație cu \mathbf{h}_2^i), cu L_{21} și respectiv L_{22} coeficienți. În mod clar, trebuie să avem $L = L_1 L_2 = L_{11} L_{12} L_{21} L_{22}$, cu $L_1 \geq L_2$, $L_{11} \geq L_{12}$ și $L_{21} \geq L_{22}$.

Înlocuind (3) și (4) în (2), obținem

$$\begin{aligned} \mathbf{h} &= \sum_{i=1}^{L_2} \left(\sum_{k=1}^{L_{22}} \mathbf{h}_{22}^{ik} \otimes \mathbf{h}_{21}^{ik} \right) \otimes \left(\sum_{j=1}^{L_{12}} \mathbf{h}_{12}^{ij} \otimes \mathbf{h}_{11}^{ij} \right) \\ &= \sum_{i=1}^{L_2} \sum_{j=1}^{L_{12}} \sum_{k=1}^{L_{22}} \mathbf{h}_{22}^{ik} \otimes \mathbf{h}_{21}^{ik} \otimes \mathbf{h}_{12}^{ij} \otimes \mathbf{h}_{11}^{ij}. \end{aligned} \quad (5)$$

În continuare, să presupunem că \mathbf{h}_1^i și \mathbf{h}_2^i sunt de rang scăzut [7], adică $\mathbf{h}_1^i = \sum_{p=1}^P \mathbf{h}_{12}^{ip} \otimes \mathbf{h}_{11}^{ip}$ și $\mathbf{h}_2^i = \sum_{q=1}^Q \mathbf{h}_{22}^{iq} \otimes \mathbf{h}_{21}^{iq}$, unde $P \leq L_{12}$ și $Q \leq L_{22}$. Prin urmare, (5) poate fi scris ca

$$\mathbf{h} = \sum_{l=1}^{L_2} \sum_{p=1}^P \sum_{q=1}^Q \mathbf{h}_{22}^{lq} \otimes \mathbf{h}_{21}^{lq} \otimes \mathbf{h}_{12}^{lp} \otimes \mathbf{h}_{11}^{lp}. \quad (6)$$

Din (2) și (6) rezultă că reprezentările echivalente în forme matriciale și respectiv tensoriale de ordinul al patrulea vor fi

$$\mathbf{H} = \sum_{l=1}^{L_2} \mathbf{h}_1^l (\mathbf{h}_2^l)^\top = \sum_{l=1}^{L_2} \mathbf{h}_1^l \circ \mathbf{h}_2^l \quad (7)$$

și

$$\begin{aligned} \mathcal{H} &= \sum_{l=1}^{L_2} \sum_{p=1}^P \sum_{q=1}^Q \mathbf{h}_{11}^{lp} \circ \mathbf{h}_{12}^{lp} \circ \mathbf{h}_{21}^{lq} \circ \mathbf{h}_{22}^{lq} \\ &= \sum_{p=1}^P \sum_{q=1}^Q \left(\sum_{l=1}^{L_2} \mathbf{h}_{11}^{lp} \circ \mathbf{h}_{12}^{lp} \circ \mathbf{h}_{21}^{lq} \circ \mathbf{h}_{22}^{lq} \right) \\ &= \sum_{p=1}^P \sum_{q=1}^Q \mathcal{H}^{:pq}, \end{aligned} \quad (8)$$

unde \circ este produsul extern și $\mathcal{H}^{:pq} = \sum_{l=1}^{L_2} \mathbf{h}_{11}^{lp} \circ \mathbf{h}_{12}^{lp} \circ \mathbf{h}_{21}^{lq} \circ \mathbf{h}_{22}^{lq} \in \mathbb{R}^{L_{11} \times L_{12} \times L_{21} \times L_{22}}$. Se poate observa că $\mathcal{H}^{:pq}$ corespunde descompunerii poliadice canonicale (*canonical polyadic* - CP), adică factorizarea unui tensor de ordinul al patrulea într-o sumă de tensori de ordinul al patrulea de rang 1 [14]. În consecință, L_2 este numărul minim care generează $\mathcal{H}^{:pq}$. Drept urmare, rangul lui $\mathcal{H}^{:pq}$ este de asemenea L_2 , în timp ce \mathcal{H} rezultă ca o sumă dublă a PQ tensori de ordinul al patrulea (fiecare de rang L_2).

Pentru a exploata (6) în probleme practice de identificare de sistem, următoarea sarcină este să scriem această expresie în patru moduri alternative, în scopul extragerii fiecărui bloc (de răspunsuri la impuls scurte), conducând astfel la o identificare mai eficientă. În primul rând, ne concentrăm pe \mathbf{h}_{22}^{lq} , $l = 1, 2, \dots, L_2$, $q = 1, 2, \dots, Q$. Avem

$$\begin{aligned} \mathbf{h} &= \sum_{l=1}^{L_2} \sum_{p=1}^P \sum_{q=1}^Q \left(\mathbf{I}_{L_{22}} \otimes \mathbf{h}_{21}^{lq} \otimes \mathbf{h}_{12}^{lp} \otimes \mathbf{h}_{11}^{lp} \right) \mathbf{h}_{22}^{lq} \\ &= \sum_{l=1}^{L_2} \sum_{p=1}^P \sum_{q=1}^Q \mathbf{H}_{-22}^{lpq} \mathbf{h}_{22}^{lq} \\ &= \sum_{q=1}^Q \sum_{p=1}^P \mathbf{H}_{-22}^{:pq} \mathbf{h}_{22}^{:q} \\ &= \sum_{q=1}^Q \mathbf{H}_{-22}^{:+q} \mathbf{h}_{22}^{:q} = \underline{\mathbf{H}}_{-22} \mathbf{h}_{22}, \end{aligned} \quad (9)$$

unde $\mathbf{I}_{L_{22}}$ este matricea identitate de dimensiune $L_{22} \times L_{22}$, $\mathbf{H}_{-22}^{lpq} = \mathbf{I}_{L_{22}} \otimes \mathbf{h}_{21}^{lq} \otimes \mathbf{h}_{12}^{lp} \otimes \mathbf{h}_{11}^{lp}$ este o matrice de dimensiune $L \times L_{22}$,

$$\mathbf{H}_{-22}^{:pq} = [\mathbf{H}_{-22}^{1pq} \quad \mathbf{H}_{-22}^{2pq} \quad \cdots \quad \mathbf{H}_{-22}^{L_2pq}] \quad (10)$$

este o matrice de dimensiune $L \times L_2 L_{22}$,

$$\mathbf{h}_{22}^{:q} = \left[\left(\mathbf{h}_{22}^{1q} \right)^\top \quad \left(\mathbf{h}_{22}^{2q} \right)^\top \quad \cdots \quad \left(\mathbf{h}_{22}^{L_2q} \right)^\top \right]^\top \quad (11)$$

este un vector de lungime $L_2 L_{22}$, $\mathbf{H}_{-22}^{+:q} = \sum_{p=1}^P \mathbf{H}_{-22}^{:pq}$ este o matrice de dimensiune $L \times L_2 L_{22}$,

$$\underline{\mathbf{H}}_{-22} = [\mathbf{H}_{-22}^{+:1} \quad \mathbf{H}_{-22}^{+:2} \quad \cdots \quad \mathbf{H}_{-22}^{+:Q}] \quad (12)$$

este o matrice de dimensiune $L \times Q L_2 L_{22}$ și

$$\underline{\mathbf{h}}_{22} = \left[\left(\mathbf{h}_{22}^{:1} \right)^\top \quad \left(\mathbf{h}_{22}^{:2} \right)^\top \quad \cdots \quad \left(\mathbf{h}_{22}^{:Q} \right)^\top \right]^\top \quad (13)$$

este un vector coloană cu $Q L_2 L_{22}$ coeficienți.

În al doilea rând dezvoltăm (6) luând în considerare \mathbf{h}_{21}^{lq} , $l = 1, 2, \dots, L_2$, $q = 1, 2, \dots, Q$. Avem

$$\begin{aligned} \mathbf{h} &= \sum_{l=1}^{L_2} \sum_{p=1}^P \sum_{q=1}^Q \left(\mathbf{h}_{22}^{lq} \otimes \mathbf{I}_{L_{21}} \otimes \mathbf{h}_{12}^{lp} \otimes \mathbf{h}_{11}^{lp} \right) \mathbf{h}_{21}^{lq} \\ &= \sum_{l=1}^{L_2} \sum_{p=1}^P \sum_{q=1}^Q \mathbf{H}_{-21}^{lpq} \mathbf{h}_{21}^{lq} \\ &= \sum_{q=1}^Q \sum_{p=1}^P \mathbf{H}_{-21}^{:pq} \mathbf{h}_{21}^{:q} \\ &= \sum_{q=1}^Q \mathbf{H}_{-21}^{+:q} \mathbf{h}_{21}^{:q} = \underline{\mathbf{H}}_{-21} \underline{\mathbf{h}}_{21}, \end{aligned} \quad (14)$$

unde $\mathbf{I}_{L_{21}}$ este matricea identitate de dimensiune $L_{21} \times L_{21}$, $\mathbf{H}_{-21}^{lpq} = \mathbf{h}_{22}^{lq} \otimes \mathbf{I}_{L_{21}} \otimes \mathbf{h}_{12}^{lp} \otimes \mathbf{h}_{11}^{lp}$ este o matrice de dimensiune $L \times L_{21}$,

$$\mathbf{H}_{-21}^{:pq} = [\mathbf{H}_{-21}^{1pq} \quad \mathbf{H}_{-21}^{2pq} \quad \cdots \quad \mathbf{H}_{-21}^{L_2pq}] \quad (15)$$

este o matrice de dimensiune $L \times L_2 L_{21}$,

$$\mathbf{h}_{21}^{:q} = \left[\left(\mathbf{h}_{21}^{1q} \right)^\top \quad \left(\mathbf{h}_{21}^{2q} \right)^\top \quad \cdots \quad \left(\mathbf{h}_{21}^{L_2q} \right)^\top \right]^\top \quad (16)$$

este un vector coloană cu $L_2 L_{21}$ coeficienți, $\mathbf{H}_{-21}^{+:q} = \sum_{p=1}^P \mathbf{H}_{-21}^{:pq}$ este o matrice de dimensiune $L \times L_2 L_{21}$,

$$\underline{\mathbf{H}}_{-21} = [\mathbf{H}_{-21}^{+:1} \quad \mathbf{H}_{-21}^{+:2} \quad \cdots \quad \mathbf{H}_{-21}^{+:Q}] \quad (17)$$

este o matrice de dimensiune $L \times Q L_2 L_{21}$ și

$$\underline{\mathbf{h}}_{21} = \left[\left(\mathbf{h}_{21}^{:1} \right)^\top \quad \left(\mathbf{h}_{21}^{:2} \right)^\top \quad \cdots \quad \left(\mathbf{h}_{21}^{:Q} \right)^\top \right]^\top \quad (18)$$

este un vector de lungime $Q L_2 L_{21}$.

În al treilea rând, (6) poate fi dezvoltat extrăgând \mathbf{h}_{12}^{lp} , $l = 1, 2, \dots, L_2$, $p = 1, 2, \dots, P$. Avem

$$\begin{aligned}
\mathbf{h} &= \sum_{l=1}^{L_2} \sum_{p=1}^P \sum_{q=1}^Q \left(\mathbf{h}_{22}^{lq} \otimes \mathbf{h}_{21}^{lq} \otimes \mathbf{I}_{L_{12}} \otimes \mathbf{h}_{11}^{lp} \right) \mathbf{h}_{12}^{lp} \\
&= \sum_{l=1}^{L_2} \sum_{p=1}^P \sum_{q=1}^Q \mathbf{H}_{-12}^{lpq} \mathbf{h}_{12}^{lp} \\
&= \sum_{p=1}^P \sum_{q=1}^Q \mathbf{H}_{-12}^{:pq} \mathbf{h}_{12}^{:p} \\
&= \sum_{p=1}^P \mathbf{H}_{-12}^{:p:+} \mathbf{h}_{12}^{:p} = \underline{\mathbf{H}}_{-12} \mathbf{h}_{12},
\end{aligned} \tag{19}$$

unde $\mathbf{I}_{L_{12}}$ este matricea identitate de dimensiune $L_{12} \times L_{12}$, $\mathbf{H}_{-12}^{lpq} = \mathbf{h}_{22}^{lq} \otimes \mathbf{h}_{21}^{lq} \otimes \mathbf{I}_{L_{12}} \otimes \mathbf{h}_{11}^{lp}$ este o matrice de dimensiune $L \times L_{12}$,

$$\mathbf{H}_{-12}^{:pq} = \left[\begin{array}{ccc} \mathbf{H}_{-12}^{1pq} & \mathbf{H}_{-12}^{2pq} & \dots & \mathbf{H}_{-12}^{L_2pq} \end{array} \right] \tag{20}$$

este o matrice de dimensiune $L \times L_2 L_{12}$,

$$\mathbf{h}_{12}^{:p} = \left[\begin{array}{ccc} \left(\mathbf{h}_{12}^{1p} \right)^\top & \left(\mathbf{h}_{12}^{2p} \right)^\top & \dots & \left(\mathbf{h}_{12}^{L_2p} \right)^\top \end{array} \right]^\top \tag{21}$$

este un vector coloană cu $L_2 L_{12}$ coeficienți, $\mathbf{H}_{-12}^{:p:+} = \sum_{q=1}^Q \mathbf{H}_{-12}^{:pq}$ este o matrice de dimensiune $L \times L_2 L_{12}$,

$$\underline{\mathbf{H}}_{-12} = \left[\begin{array}{ccc} \mathbf{H}_{-12}^{:1:+} & \mathbf{H}_{-12}^{:2:+} & \dots & \mathbf{H}_{-12}^{:P:+} \end{array} \right] \tag{22}$$

este o matrice de dimensiune $L \times PL_2 L_{12}$ și

$$\underline{\mathbf{h}}_{12} = \left[\begin{array}{ccc} \left(\mathbf{h}_{12}^{:1} \right)^\top & \left(\mathbf{h}_{12}^{:2} \right)^\top & \dots & \left(\mathbf{h}_{12}^{:P} \right)^\top \end{array} \right]^\top \tag{23}$$

este un vector de lungime $PL_2 L_{12}$.

În final, putem exprima (6) luând în considerare \mathbf{h}_{11}^{lp} , $l = 1, 2, \dots, L_2$, $p = 1, 2, \dots, P$. Avem

$$\begin{aligned}
\mathbf{h} &= \sum_{l=1}^{L_2} \sum_{p=1}^P \sum_{q=1}^Q \left(\mathbf{h}_{22}^{lq} \otimes \mathbf{h}_{21}^{lq} \otimes \mathbf{h}_{12}^{lp} \otimes \mathbf{I}_{L_{11}} \right) \mathbf{h}_{11}^{lp} \\
&= \sum_{l=1}^{L_2} \sum_{p=1}^P \sum_{q=1}^Q \mathbf{H}_{-11}^{lpq} \mathbf{h}_{11}^{lp} \\
&= \sum_{p=1}^P \sum_{q=1}^Q \mathbf{H}_{-11}^{:pq} \mathbf{h}_{11}^{:p} \\
&= \sum_{p=1}^P \mathbf{H}_{-11}^{:p:+} \mathbf{h}_{11}^{:p} = \underline{\mathbf{H}}_{-11} \mathbf{h}_{11},
\end{aligned} \tag{24}$$

unde $\mathbf{I}_{L_{11}}$ este matricea identitate de dimensiune $L_{11} \times L_{11}$, $\mathbf{H}_{-11}^{lpq} = \mathbf{h}_{22}^{lq} \otimes \mathbf{h}_{21}^{lq} \otimes \mathbf{h}_{12}^{lp} \otimes \mathbf{I}_{L_{11}}$ este o matrice de dimensiune $L \times L_{11}$,

$$\mathbf{H}_{-11}^{:pq} = \left[\begin{array}{ccc} \mathbf{H}_{-11}^{1pq} & \mathbf{H}_{-11}^{2pq} & \dots & \mathbf{H}_{-11}^{L_2pq} \end{array} \right] \tag{25}$$

este o matrice de dimensiune $L \times L_2 L_{11}$,

$$\mathbf{h}_{11}^{:p} = \left[\begin{array}{ccc} \left(\mathbf{h}_{11}^{1p} \right)^\top & \left(\mathbf{h}_{11}^{2p} \right)^\top & \dots & \left(\mathbf{h}_{11}^{L_2p} \right)^\top \end{array} \right]^\top \tag{26}$$

este un vector coloană cu L_2L_{11} coeficienți, $\mathbf{H}_{-11}^{:p:+} = \sum_{q=1}^Q \mathbf{H}_{-11}^{:pq}$ este o matrice de dimensiune $L \times L_2L_{11}$,

$$\mathbf{H}_{-11} = [\mathbf{H}_{-11}^{:1:+} \quad \mathbf{H}_{-11}^{:2:+} \quad \cdots \quad \mathbf{H}_{-11}^{:P:+}] \quad (27)$$

este o matrice de dimensiune $L \times PL_2L_{11}$ și

$$\mathbf{h}_{11} = [(\mathbf{h}_{11}^{:1:})^\top \quad (\mathbf{h}_{11}^{:2:})^\top \quad \cdots \quad (\mathbf{h}_{11}^{:P:})^\top]^\top \quad (28)$$

este un vector de lungime PL_2L_{11} .

Pentru a exploata abordarea anterioară în cadrul problemelor de identificare a sistemului, să considerăm un sistem SISO liniar cu răspuns la impuls \mathbf{h} de lungime L . La indicele în timp discret t , rezultatul acestui sistem, notat cu $d(t)$, este dat de convoluția dintre eșantioanele semnalului de intrare, $x(t)$, și coeficienții răspunsului la impuls al sistemului din (1), de obicei corupt de un zgomot aditiv, adică

$$d(t) = \mathbf{h}^\top \mathbf{x}(t) + w(t), \quad (29)$$

unde

$$\mathbf{x}(t) = [x(t) \quad x(t-1) \quad \cdots \quad x(t-L+1)]^\top \quad (30)$$

este un vector care grupează cele mai recente L eșantioane de timp ale semnalului de intrare cu medie zero și $w(t)$ este zgomotul aditiv cu medie zero. În acest context, $x(t)$ și $w(t)$ sunt semnale cu valori reale, care sunt necorelate.

Pe baza descompunerilor prezentate mai sus, semnalul de referință din (29) poate fi rescris ca

$$d(t) = \mathbf{h}_{22}^\top \mathbf{H}_{-22}^\top \mathbf{x}(t) + w(t) \quad (31)$$

$$= \mathbf{h}_{21}^\top \mathbf{H}_{-21}^\top \mathbf{x}(t) + w(t) \quad (32)$$

$$= \mathbf{h}_{12}^\top \mathbf{H}_{-12}^\top \mathbf{x}(t) + w(t) \quad (33)$$

$$= \mathbf{h}_{11}^\top \mathbf{H}_{-11}^\top \mathbf{x}(t) + w(t). \quad (34)$$

În cele ce urmează, arătăm cum se pot folosi expresiile anterioare pentru a deriva un algoritm RLS, care duce la o performanță mai bună decât filtrul RLS convențional.

Fie $\hat{\mathbf{h}}(t)$ o estimare a \mathbf{h} la indicele de timp t , adică un filtru adaptiv de lungime L , cu coeficienți reali. În plus, putem construi $\hat{\mathbf{h}}_{22}(t)$, $\hat{\mathbf{h}}_{21}(t)$, $\hat{\mathbf{h}}_{12}(t)$, $\hat{\mathbf{h}}_{11}(t)$ și $\hat{\mathbf{H}}_{-22}(t)$, $\hat{\mathbf{H}}_{-21}(t)$, $\hat{\mathbf{H}}_{-12}(t)$, $\hat{\mathbf{H}}_{-11}(t)$ în același mod în care am construit \mathbf{h}_{22} , \mathbf{h}_{21} , \mathbf{h}_{12} , \mathbf{h}_{11} și \mathbf{H}_{-22} , \mathbf{H}_{-21} , \mathbf{H}_{-12} , \mathbf{H}_{-11} . În acest context, semnalul de eroare a priori rezultă ca diferența dintre semnalul dorit $d(t)$ și $y_E(t) = \hat{\mathbf{h}}^\top(t-1)\mathbf{x}(t)$, care este semnalul estimat. În consecință, $e(t) = d(t) - y_E(t)$, care poate fi rescris în continuare în patru moduri alternative:

$$e(t) = d(t) - \hat{\mathbf{h}}_{22}^\top(t-1)\mathbf{x}_{22}(t) \quad (35)$$

$$= d(t) - \hat{\mathbf{h}}_{21}^\top(t-1)\mathbf{x}_{21}(t) \quad (36)$$

$$= d(t) - \hat{\mathbf{h}}_{12}^\top(t-1)\mathbf{x}_{12}(t) \quad (37)$$

$$= d(t) - \hat{\mathbf{h}}_{11}^\top(t-1)\mathbf{x}_{11}(t), \quad (38)$$

unde $\mathbf{x}_{22}(t) = \mathbf{H}_{-22}^\top(t-1)\mathbf{x}(t)$, $\mathbf{x}_{21}(t) = \mathbf{H}_{-21}^\top(t-1)\mathbf{x}(t)$, $\mathbf{x}_{12}(t) = \mathbf{H}_{-12}^\top(t-1)\mathbf{x}(t)$ și $\mathbf{x}_{11}(t) = \mathbf{H}_{-11}^\top(t-1)\mathbf{x}(t)$.

Din (35) și ținând cont că $\hat{\mathbf{h}}_{21}$, $\hat{\mathbf{h}}_{12}$ și $\hat{\mathbf{h}}_{11}$ sunt fixate, urmând criteriul de optimizare al celor mai mici pătrate (*least-squares* - LS), funcția cost pentru primul filtru component poate fi exprimată ca

$$\begin{aligned} \mathcal{J} [\hat{\mathbf{h}}_{22}(t) | \hat{\mathbf{h}}_{21}, \hat{\mathbf{h}}_{12}, \hat{\mathbf{h}}_{11}] &= \sum_{n=1}^t \lambda_{22}^{t-n} [d(n) - \hat{\mathbf{h}}_{22}^\top(n)\mathbf{x}_{22}(n)]^2 \\ &= \sigma_d^2(t) - 2\hat{\mathbf{h}}_{22}^\top(t)\mathbf{r}_{22}(t) + \hat{\mathbf{h}}_{22}^\top(t)\mathbf{R}_{22}(t)\hat{\mathbf{h}}_{22}(t), \end{aligned} \quad (39)$$

unde $0 < \lambda_{22} \leq 1$ este un factor de uitare, $\sigma_d^2(t) = \sum_{n=1}^t \lambda_{22}^{t-n} d^2(n)$ și

$$\mathbf{r}_{22}(t) = \sum_{n=1}^t \lambda_{22}^{t-n} \mathbf{x}_{22}(n) d(n) = \lambda_{22} \mathbf{r}_{22}(t-1) + \mathbf{x}_{22}(t) d(t), \quad (40)$$

$$\mathbf{R}_{22}(t) = \sum_{n=1}^t \lambda_{22}^{t-n} \mathbf{x}_{22}(n) \mathbf{x}_{22}^\top(n) = \lambda_{22} \mathbf{R}_{22}(t-1) + \mathbf{x}_{22}(t) \mathbf{x}_{22}^\top(t). \quad (41)$$

În mod similar, urmând (36) și ținând cont că $\hat{\mathbf{h}}_{22}$, $\hat{\mathbf{h}}_{12}$, and $\hat{\mathbf{h}}_{11}$ sunt fixate, a doua funcție cost LS poate fi scrisă ca

$$\begin{aligned} \mathcal{J} \left[\hat{\mathbf{h}}_{21}(t) | \hat{\mathbf{h}}_{22}, \hat{\mathbf{h}}_{12}, \hat{\mathbf{h}}_{11} \right] &= \sum_{n=1}^t \lambda_{21}^{t-n} \left[d(n) - \hat{\mathbf{h}}_{21}^\top(t) \mathbf{x}_{21}(n) \right]^2 \\ &= \sigma_d^2(t) - 2 \hat{\mathbf{h}}_{21}^\top(t) \mathbf{r}_{21}(t) + \hat{\mathbf{h}}_{21}^\top(t) \mathbf{R}_{21}(t) \hat{\mathbf{h}}_{21}(t), \end{aligned} \quad (42)$$

cu $0 < \lambda_{21} \leq 1$ și

$$\mathbf{r}_{21}(t) = \sum_{n=1}^t \lambda_{21}^{t-n} \mathbf{x}_{21}(n) d(n) = \lambda_{21} \mathbf{r}_{21}(t-1) + \mathbf{x}_{21}(t) d(t), \quad (43)$$

$$\mathbf{R}_{21}(t) = \sum_{n=1}^t \lambda_{21}^{t-n} \mathbf{x}_{21}(n) \mathbf{x}_{21}^\top(n) = \lambda_{21} \mathbf{R}_{21}(t-1) + \mathbf{x}_{21}(t) \mathbf{x}_{21}^\top(t). \quad (44)$$

În continuare, pe baza (37) și ținând cont că $\hat{\mathbf{h}}_{22}$, $\hat{\mathbf{h}}_{21}$ și $\hat{\mathbf{h}}$ sunt fixate, a treia funcție cost LS devine

$$\begin{aligned} \mathcal{J} \left[\hat{\mathbf{h}}_{12}(t) | \hat{\mathbf{h}}_{22}, \hat{\mathbf{h}}_{21}, \hat{\mathbf{h}}_{11} \right] &= \sum_{n=1}^t \lambda_{12}^{t-n} \left[d(n) - \hat{\mathbf{h}}_{12}^\top(t) \mathbf{x}_{12}(n) \right]^2 \\ &= \sigma_d^2(t) - 2 \hat{\mathbf{h}}_{12}^\top(t) \mathbf{r}_{12}(t) + \hat{\mathbf{h}}_{12}^\top(t) \mathbf{R}_{12}(t) \hat{\mathbf{h}}_{12}(t), \end{aligned} \quad (45)$$

unde $0 < \lambda_{12} \leq 1$ și

$$\mathbf{r}_{12}(t) = \sum_{n=1}^t \lambda_{12}^{t-n} \mathbf{x}_{12}(n) d(n) = \lambda_{12} \mathbf{r}_{12}(t-1) + \mathbf{x}_{12}(t) d(t), \quad (46)$$

$$\begin{aligned} \mathbf{R}_{12}(t) &= \sum_{n=1}^t \lambda_{12}^{t-n} \mathbf{x}_{12}(n) \mathbf{x}_{12}^\top(n) \\ &= \lambda_{12} \mathbf{R}_{12}(t-1) + \mathbf{x}_{12}(t) \mathbf{x}_{12}^\top(t). \end{aligned} \quad (47)$$

În final, din (38) și ținând cont că $\hat{\mathbf{h}}_{22}$, $\hat{\mathbf{h}}_{21}$ și $\hat{\mathbf{h}}$ sunt fixate, a patra funcție cost LS este

$$\begin{aligned} \mathcal{J} \left[\hat{\mathbf{h}}_{11}(t) | \hat{\mathbf{h}}_{22}, \hat{\mathbf{h}}_{21}, \hat{\mathbf{h}}_{12} \right] &= \sum_{n=1}^t \lambda_{11}^{t-n} \left[d(n) - \hat{\mathbf{h}}_{11}^\top(t) \mathbf{x}_{11}(n) \right]^2 \\ &= \sigma_d^2(t) - 2 \hat{\mathbf{h}}_{11}^\top(t) \mathbf{r}_{11}(t) + \hat{\mathbf{h}}_{11}^\top(t) \mathbf{R}_{11}(t) \hat{\mathbf{h}}_{11}(t), \end{aligned} \quad (48)$$

cu $0 < \lambda_{11} \leq 1$ și

$$\mathbf{r}_{11}(t) = \sum_{n=1}^t \lambda_{11}^{t-n} \mathbf{x}_{11}(n) d(n) = \lambda_{11} \mathbf{r}_{11}(t-1) + \mathbf{x}_{11}(t) d(t), \quad (49)$$

$$\mathbf{R}_{11}(t) = \sum_{n=1}^t \lambda_{11}^{t-n} \mathbf{x}_{11}(n) \mathbf{x}_{11}^\top(n) = \lambda_{11} \mathbf{R}_{11}(t-1) + \mathbf{x}_{11}(t) \mathbf{x}_{11}^\top(t). \quad (50)$$




Figure 1: Dezalinierea normalizată a algoritmilor RLS convențional și RLS-FOT (cu $P = Q = 1$ și $P = Q = 2$), folosind diferite valori ale factorilor de uitare. Semnalul de intrare este un proces AR(1), SNR = 20 dB, iar calea ecoului se modifică după 10 secunde.

Minimizarea (39), (42), (45) și (48) în raport cu $\hat{\mathbf{h}}_{22}(t)$, $\hat{\mathbf{h}}_{21}(t)$, $\hat{\mathbf{h}}_{12}(t)$ și respectiv $\hat{\mathbf{h}}_{11}(t)$ conduce la ecuațiile normale asociate:

$$\mathbf{R}_{22}(t)\hat{\mathbf{h}}_{22}(t) = \mathbf{r}_{22}(t), \quad (51)$$

$$\mathbf{R}_{21}(t)\hat{\mathbf{h}}_{21}(t) = \mathbf{r}_{21}(t), \quad (52)$$

$$\mathbf{R}_{12}(t)\hat{\mathbf{h}}_{12}(t) = \mathbf{r}_{12}(t), \quad (53)$$

$$\mathbf{R}_{11}(t)\hat{\mathbf{h}}_{11}(t) = \mathbf{r}_{11}(t). \quad (54)$$

Acestea pot fi rezolvate pe baza algoritmului RLS, folosind lema de inversare a matricei [6] pentru a actualiza recursiv inversele matricelor din partea stângă a (51)–(54). Notând cu $\star \in \{22, 21, 12, 11\}$, ciclul bazat pe RLS pentru fiecare filtru component este sumarizat prin următoarele relații:

$$\mathbf{k}_\star(t) = \frac{\mathbf{P}_\star(t)\mathbf{x}_\star(t)}{\lambda_\star + \mathbf{x}_\star^\top(t)\mathbf{P}_\star(t)\mathbf{x}_\star(t)}, \quad (55)$$

$$\mathbf{P}_\star(t) = \frac{1}{\lambda_\star} [\mathbf{I}_\star - \mathbf{k}_\star(t)\mathbf{x}_\star^\top(t)] \mathbf{P}_\star(t), \quad (56)$$

$$\hat{\mathbf{h}}_\star(t) = \hat{\mathbf{h}}_\star(t-1) + \mathbf{k}_\star(t)e(t), \quad (57)$$

unde $\mathbf{k}_\star(t)$ este vectorul de câștig Kalman, $\mathbf{P}_\star(t)$ reprezintă inversa matricei $\mathbf{R}_\star(t)$ și \mathbf{I}_\star este matricea identitate de dimensiune corespunzătoare.

Soluțiile $\hat{\mathbf{h}}_{22}(t)$, $\hat{\mathbf{h}}_{21}(t)$, $\hat{\mathbf{h}}_{12}(t)$ și $\hat{\mathbf{h}}_{11}(t)$ pot fi descompuse ca în (13), (18), (23) și respectiv (28). Așadar, estimatul filtrului global optim rezultă ca

$$\hat{\mathbf{h}}(t) = \sum_{l=1}^{L_2} \sum_{p=1}^P \sum_{q=1}^Q \hat{\mathbf{h}}_{22}^{lq}(t) \otimes \hat{\mathbf{h}}_{21}^{lq}(t) \otimes \hat{\mathbf{h}}_{12}^{lp}(t) \otimes \hat{\mathbf{h}}_{11}^{lp}(t), \quad (58)$$

unde răspunsurile la impuls scurte $\hat{\mathbf{h}}_{22}^{lq}(t)$, $\hat{\mathbf{h}}_{21}^{lq}(t)$, $\hat{\mathbf{h}}_{12}^{lp}(t)$ și $\hat{\mathbf{h}}_{11}^{lp}(t)$ sunt extrase din (11), (16), (21) și respectiv (26).

3 Rezultate experimentale

În experimente folosim un răspuns la impuls de rețea \mathbf{h} cu $L = 256$ coeficienți [15]. Descompunerea tensorială de ordinul al patrulea a acestui răspuns la impuls este efectuată folosind $L_1 = L_2 = 16$ și $L_{11} = L_{12} = L_{21} = L_{22} = 4$.

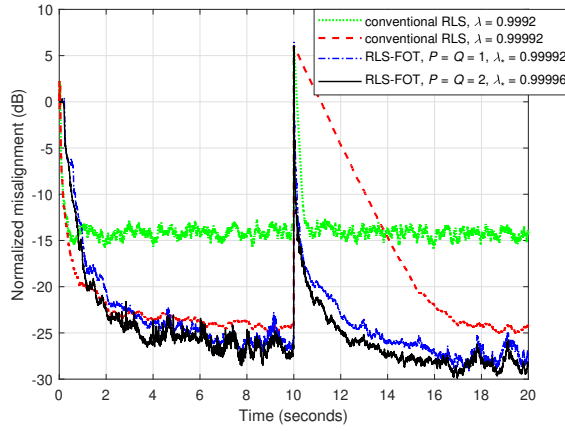


Figure 2: Dezalinierea normalizată a algoritmilor RLS convențional și RLS-FOT (cu $P = Q = 1$ și $P = Q = 2$), folosind diferite valori ale factorilor de uitare. Semnalul de intrare este un proces AR(1), SNR = 10 dB, iar calea ecoului se modifică după 10 secunde.

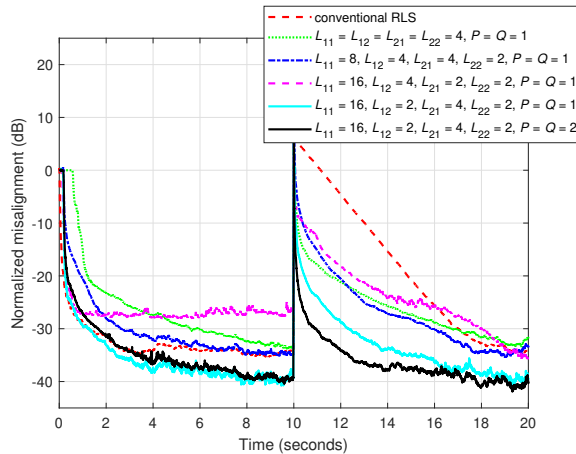


Figure 3: Dezalinierea normalizată a algoritmilor RLS convențional și RLS-FOT, folosind diferite setări pentru parametrii de descompunere. Semnalul de intrare este un proces AR(1), SNR = 20 dB, iar calea ecoului se modifică după 10 secunde.

Semnalul de intrare este un proces AR(1) cu polul la 0,8. Rezultatele sunt prezentate în Fig. 1 și 2, pentru un raport semnal zgomot (*signal to noise ratio* - SNR) = 20 dB și respectiv SNR = 10 dB. Se poate observa performanța superioară de urmărire a RLS-FOT în comparație cu algoritmul RLS convențional. Câștigul general este mai evident pentru un SNR mai mic, ca în Fig. 2.

Există multe probleme interesante care merită investigate. De exemplu, un aspect important este legat de modul în care efectuăm descompunerea, deoarece factorizarea lui L influențează atât spațiul parametrilor (adică numărul de coeficienți), cât și complexitatea de calcul. Un astfel de experiment este ilustrat în Fig. 3.

De exemplu, când $L = 256$, folosirea $L_{11} = L_{12} = L_{21} = L_{22} = 4$ și $P = Q = 1$ duce la o combinație paralelă de patru filtre, fiecare cu lungimea 64. Cu alte cuvinte, spațiul parametrilor rămâne același, dar ordinea complexității este redusă de la $\mathcal{O}_{\text{RLS}} = 256^2 = 65536$ la $\mathcal{O}_{\text{RLS-FOT}} = 4 \times 64^2 = 16384$ operații. Cu toate acestea, deoarece L_2 este termenul care influențează complexitatea de calcul a tuturor filtrelor, putem viza o valoare mai mică pentru acest factor, de exemplu, folosind descompunerea $L_{11} = 8$, $L_{12} = 4$, $L_{21} = 4$ și $L_{22} = 2$. În acest caz, pentru $P = Q = 1$, spațiul parametrilor se reduce la $16 + 32 + 32 + 64 = 144$ coeficienți. În plus, când $L_{11} = 16$, $L_{12} = 4$, $L_{21} = 2$ și $L_{22} = 2$, cu $P = Q = 1$, numărul total de coeficienți este și mai mic, adică $8 + 8 + 16 + 64 = 96$. Pe de altă parte, parametrii de “rang” P și Q sunt legați de L_{12} și respectiv de L_{22} . În scopul reducerii acestor

valori, putem folosi $L_{11} = 16$, $L_{12} = 2$, $L_{21} = 4$ și $L_{22} = 2$. Pentru $P = Q = 1$, numărul total de coeficienți este $16 + 16 + 32 + 64 = 128$, care reprezintă jumătate față de abordarea convențională (de lungime completă), cu $L = 256$. Pe de altă parte, folosind $P = Q = 2$, obținem reprezentarea “de rang complet” a răspunsului la impuls, cu același spațiu de parametri ($32 + 32 + 64 + 128 = 256$), dar cu un ordin de complexitate mai mic, adică $\mathcal{O}_{\text{RLS-FOT}} = 32^2 + 32^2 + 64^2 + 128^2 = 22528 < \mathcal{O}_{\text{RLS}} = 256^2 = 65536$ operații. Deoarece încă sunt combinate filtre adaptive mai scurte, comportamentul de convergență/urmărire ar trebui să fie mai bun în comparație cu algoritmul RLS convențional (de exemplu, a se vedea curba neagră față de curba roșie punctată din Fig. 3). Desigur, toate aceste descompuneri ar trebui analizate în contextul unui rang scăzut, care reprezintă cadrul principal. Utilizarea valorilor mici pentru $L_2 = L_{21}L_{22}$ ar putea influența caracteristicile de rang scăzut ale răspunsurilor la impuls corespunzătoare (de exemplu, a se vedea curba magenta corespunzătoare $L_2 = L_{21}L_{22} = 2 \times 2 = 4$ din Fig. 3).

Toate aceste aspecte ar trebui analizate cu atenție, pentru a viza cea mai bună combinație și compromisul între criteriile principale, adică spațiul parametrilor, complexitatea și performanța. Câștigurile ar trebui să fie și mai evidente pentru valori mai mari ale lui L , ca în cazul răspunsurilor la impuls acustice de cameră. În plus, deoarece pentru diferite configurații de descompunere avem de-a face cu diferite lungimi ale filtrelor componente (unele dintre ele destul de scurte), pot fi luate în considerare diferite strategii de proiectare a factorilor de uitare.

References

- [1] L.-M. Dogariu, R.-L. Costea, C. Paleologu, and J. Benesty, “A fourth-order tensorial Wiener filter using the conjugate gradient method,” *Symmetry*, vol. 16, no. 11 (18 pages), Dec. 2024.
- [2] R. A. Otopoleanu, J. Benesty, C. Paleologu, C. L. Stanciu, L. M. Dogariu, and S. Ciochină, “A practical regularized recursive least-squares algorithm for robust system identification,” in *Proc. European Signal Processing Conference (EUSIPCO)*, 2025.
- [3] L. Ljung, *System Identification: Theory for the User*. Second Edition, Upper Saddle River, NJ: Prentice-Hall, 1999.
- [4] E. Hänsler and G. Schmidt, *Acoustic Echo and Noise Control—A Practical Approach*. Hoboken, NJ: Wiley, 2004.
- [5] S. Radhika, F. Albu, and A. Chandrasekar, “Proportionate maximum Versoria criterion-based adaptive algorithm for sparse system identification,” *IEEE Trans. Circuits Systems II: Express Briefs*, vol. 69, pp. 1902–1906, Mar. 2022.
- [6] S. Haykin, *Adaptive Filter Theory*. Fifth Edition, Upper Saddle River, NJ, USA: Pearson, 2014.
- [7] J. Benesty, C. Paleologu, L.-M. Dogariu, and S. Ciochină, “Identification of linear and bilinear systems: a unified study,” *Electronics*, vol. 10, no. 15 (33 pages), Jul. 2021.
- [8] C. Paleologu, J. Benesty, and S. Ciochină, “Linear system identification based on a Kronecker product decomposition,” *IEEE/ACM Trans. Audio, Speech, Language Processing*, vol. 26, pp. 1793–1808, Oct. 2018.
- [9] L.-M. Dogariu, J. Benesty, C. Paleologu, and S. Ciochină, “Identification of room acoustic impulse responses via Kronecker product decompositions,” *IEEE/ACM Trans. Audio, Speech, Language Processing*, vol. 30, pp. 2828–2841, Sept. 2022.
- [10] C. F. Van Loan, “The ubiquitous Kronecker product,” *J. Computational Applied Mathematics*, vol. 123, pp. 85–100, 2000.
- [11] A. Cichocki, D. P. Mandic, A. Phan, C. F. Caiafa, G. Zhou, Q. Zhao, and L. De Lathauwer, “Tensor decompositions for signal processing applications: From two-way to multiway component analysis,” *IEEE Signal Processing Mag.*, pp. 145–163, Mar. 2015.
- [12] N. Sidiropoulos, L. De Lathauwer, X. Fu, K. Huang, E. Papalexakis, and C. Faloutsos, “Tensor decomposition for signal processing and machine learning,” *IEEE Trans. Signal Processing*, vol. 65, pp. 3551–3582, July 2017.
- [13] J. Benesty, C. Paleologu, and S. Ciochină, “Linear system identification based on a third-order tensor decomposition,” *IEEE Signal Processing Lett.*, vol. 30, pp. 503–507, May 2023.
- [14] T. G. Kolda and B. W. Bader, “Tensor decompositions and applications,” *SIAM Review*, vol. 51, no. 3, pp. 455–500, 2009.
- [15] *Digital Network Echo Cancellers*, ITU-T Recommendation G.168, 2015.

Membrii echipei proiectului,

Laura-Maria Dogariu

Ionuț-Dorinel Fîciu