

UNIVERSITATEA "POLITEHNICA" TIMIȘOARA  
Facultatea de Electronică și Telecomunicații

*Handwritten signature*

*GHEORGHE MARCEL GABREA*

ÎMBUNĂTĂȚIREA RAPORTULUI  
SEMNAL PE ZGOMOT AL UNUI SEMNAL VOCAL  
CAPTAT ÎNTR-UN MEDIU ZGOMOTOS.  
METODE MONOCAPTOR ȘI BICAPTOR.

Teză de doctorat

**Conducători științifici :**

*Prof. dr. ing. IOAN NAFORNIȚĂ*

*Prof. dr. ing. MOHAMED NAJIM*

Timișoara - 1998

# CUPRINS

<b>INTRODUCERE.....</b>	<b>1</b>
<b>CAPITOLUL I STADIUL ACTUAL ÎN ÎMBUNĂTĂȚIREA CALITĂȚII SEMNALULUI VOCAL UTILIZÂND UN SINGUR CAPTOR.....</b>	<b>5</b>
I.1. INTRODUCERE.....	5
I.2. METODE BAZATE PE ANALIZA FOURIER DE SCURTĂ DURATĂ.....	5
I.3. METODE BAZATE PE FILTRAREA OPTIMALĂ .....	8
<i>I.3.1. Metode bazate pe filtrarea de tip Wiener .....</i>	<i>8</i>
<i>I.3.2. Metode bazate pe modelarea AR și filtrarea Wiener necauzală.....</i>	<i>9</i>
<i>I.3.3. Metode bazate pe un model numai poli și filtrarea Kalman.....</i>	<i>13</i>
I.4 METODE BAZATE PE REPREZENTAREA SEMNALULUI VOCAL PRINTR-O SUMĂ DE SINUSOIDE.....	20
<i>I.4.1. Metode bazate pe reprezentarea semnalului vocal printr-o sumă de sinusoides și pe     descompunerile trunchiate SVD și QSVD.....</i>	<i>20</i>
<i>I.4.2. Metode bazate pe estimarea optimală .....</i>	<i>22</i>
<b>CAPITOLUL II RESTAURAREA UNUI SEMNAL VOCAL ÎNECAT ÎNTR-UN ZGOMOT ALB SAU COLORAT UTILIZÂND FILTRUL KALMAN .....</b>	<b>25</b>
II.1. INTRODUCERE.....	25
II.2. ELIMINAREA ZGOMOTULUI ÎN CAZUL UNUI SEMNAL VOCAL CONTAMINAT DE UN ZGOMOT ALB UTILIZÂND FILTRAREA KALMAN .....	26
<i>II.2.1. Metoda I.....</i>	<i>27</i>
II.2.1.1. Estimarea matricei de tranziție.....	27
II.2.1.2. Estimarea câștigului optimal Kalman .....	30
II.2.1.2.1. Calculul funcției de autocorelație a secvenței de inovație.....	30
II.2.1.2.2. Obținerea iterativă a câștigului Kalman .....	32
II.2.1.2.3. Testul de optimalitate .....	33
II.2.1.3. Etapele de calcul și algoritmul corespunzător metodei Ia.....	33
II.2.1.4. Alternativă de estimare a câștigului optimal.....	35

BIBLIOTECA CENTRALĂ  
UNIVERSITATEA "POLITEHNICA"  
TIMIȘOARA

II.2.1.4.1	Calculul funcției de autocorelație a lui $e^*(n)$ .....	36
II.2.1.4.2.	Procedura iterativă de estimare a câștigului optimal Kalman.....	37
II.2.1.5.	Etapele de calcul și algoritmul corespunzator metodei Ib .....	38
<i>II.2.2. Metoda II</i>	.....	40
II.2.2.1	Estimarea varianței zgomotului pe canal .....	40
II.2.2.2	Estimarea varianței zgomotului de excitație al modelului AR.....	41
II.2.2.3	Etapele de calcul și algoritmul metodei II .....	43
<i>II.2.4. Metoda III</i>	.....	45
II.2.4.1.	Estimarea parametrilor utilizând algoritmul EM .....	46
II.2.4.2.	Etapele de calcul și algoritmul metodei III .....	48
II.3.	ELIMINAREA ZGOMOTULUI ÎN CAZUL UNUI SEMNAL VOCAL CONTAMINAT DE UN ZGOMOT COLORAT UTILIZÂND FILTRAREA KALMAN.....	50
<i>II.3.1. Metoda IV</i>	.....	50
II.3.1.1	Estimarea matricei de tranziție.....	50
II.3.1.2	Estimarea câștigului optimal Kalman .....	53
II.3.1.3.	Etapele de calcul și algoritmul metodei IV .....	54
<i>II.3.2. Metoda V</i>	.....	56
II.4.	CONCLUZII.....	60

## **CAPITOLUL III ÎMBUNĂȚIREA CALITĂȚII SEMNALULUI VOCAL**

### **UTILIZÂND DOUĂ SEMNALE CAPTATE ÎN ACELASI MEDIU ZGOMOTOS. 61**

III.1.	INTRODUCERE .....	61
III.2.	ÎMBUNĂȚIREA RAPORTULUI SEMNAL/ZGOMOT UTILIZÂND UN SINGUR FILTRU .....	64
III.3.	ÎMBUNĂȚIREA RAPORTULUI SEMNAL PE ZGOMOT UTILIZÂND DOUĂ FILTRE .....	65
<i>III.3.1. Îmbunătățirea raportului semnal pe zgomot utilizând schema FFIS</i>	.....	69
III.3.1.1.	Metode bazate pe decorelarea semnalelor intermediare .....	70
III.3.1.1.1.	Metoda propusă de Compennolle și Gerven .....	73
III.3.1.1.2.	Separarea surselor prin metoda propusă de Weinstein și al. ....	75
III.3.1.1.3.	Metoda propusă de Lindgren și al. ....	79
III.3.1.2.	Separarea surselor utilizând statisticile de ordin superior .....	85
<i>III.3.2. Separarea surselor utilizând schema FBIS</i>	.....	91
III.3.2.1.	Metode bazate pe decorelarea semnalelor de ieșire.....	91

III.3.2.1.1. Metoda propusă de Gerven et Compernelle.....	91
III.3.2.1.2. Separarea surselor utilizând două funcții nelineare.....	93
III.3.2.2. Separarea surselor utilizând un filtru adaptiv dublu .....	95
III.3.2.2.1. Analiza soluțiilor posibile .....	95
III.3.2.2.2. Filtrul adaptiv dublu de tip LMS.....	99
III.3.2.2.3. Filtrul adaptiv dublu de tip DRLS (Double Recursive Least Squares) sau DFTF (Double Fast Transversal Filter) .....	100
III.4. CONCLUZII .....	105
<b>CAPITOLUL IV REZULTATE EXPERIMENTALE.....</b>	<b>106</b>
IV.1. INTRODUCERE.....	106
IV.2. METODE DE EVALUARE.....	107
IV.2.1. <i>Teste subiective</i> .....	107
IV.2.2. <i>Metode obiective</i> .....	108
IV.2.2.1. Raportul semnal/zgomot.....	108
IV.2.2.2. Distanța Itakura .....	109
IV.3. REZULTATELE EVALUĂRII : COMPARAREA METODELOR MONOCAPTOR.....	109
IV.3.1. <i>Cazul unui zgomot alb</i> .....	110
IV.3.1.1. Cazul unui semnal AR contaminat cu un zgomot alb gaussian .....	111
IV.3.1.2. Cazul unui semnal real contaminat cu un zgomot alb gaussian.....	112
IV.3.1.3. Comentarii asupra studiului comparativ.....	112
IV.3.2. <i>Cazul unui zgomot colorat</i> .....	114
IV.3.2.1. Cazul unui semnal AR contaminat cu un zgomot colorat sintetizat printr-un proces AR .....	115
IV.3.2.2. Cazul unui semnal real contaminat cu un zgomot sintetic .....	116
IV.3.2.3. Cazul unui semnal real contaminat cu un zgomot real.....	117
IV.3.2.4. Comentarii asupra studiului comparativ.....	119
IV.4. REZULTATELE EVALUĂRII : COMPARAREA METODELOR BICAPTOR .....	120
IV.4.1. <i>Criterii de evaluare suplimentare</i> .....	120
IV.4.2. <i>Algoritmi utilizați</i> .....	121
IV.4.3. <i>Cazul captării a două zgomote colorate printr-un sistem având două filtre de     interferență de tip FIR</i> .....	122

<i>IV.4.4. Cazul captării a două semnale PAM printr-un sistem având două filtre de interferență de tip FIR.....</i>	<i>127</i>
<i>IV.4.5. Cazul captării a două semnale AR printr-un sistem având două filtre de interferență de tip FIR.....</i>	<i>131</i>
<i>IV.4.6. Cazul captării unui semnal și unui zgomot real printr-un sistem având două filtre de interferență de tip FIR.....</i>	<i>135</i>
<b>CONCLUZII.....</b>	<b>139</b>
<b>BIBLIOGRAFIE .....</b>	<b>143</b>

# INTRODUCERE

Vorbirea este facultatea de a comunica gândul printr-un sistem de sunete articulate, este modalitatea de comunicare specifică oamenilor. Informația unui mesaj vorbit se găsește în fluctuațiile presiunii aerului, generat și apoi emis de aparatul respirator. Aceste fluctuații constituie semnalul vocal, sunt detectate de ureche, care apoi le preanalizează. Rezultatele sunt transmise creierului, care le interpretează. Semnalul vocal este “fragil” și trebuie să fie “manipulat” cu multă precauție.

Îmbunătățirea calității semnalului vocal se face ameliorând una sau mai multe aspecte perceptibile ale acestuia. Obiectivul nostru este ameliorarea performanțelor sistemelor de comunicații în cazul în care semnalul de intrare este contaminat cu zgomot. Reducerea nivelului acestui zgomot este o operație necesară în multe aplicații dintre care am putea aminti:

- radiotelefonul utilizat în habitaclul unei mașini, unde semnalul vocal este contaminat cu zgomotul motorului, zgomote aerodinamice, zgomotul de mers al mașinii, etc.;
- comunicațiile la mare distanță;

- postul telefonic instalat într-un mediu zgomotos, de exemplu într-un birou de schimb valutar unde zgomotele conversațiilor și ale echipamentelor perturbă semnalul vocal;
- videotelefoanele și sistemele de teleconferințe;
- restaurarea înregistrărilor vechi;
- sistemele de recunoaștere și codare utilizate în medii zgomotoase.

Noi ne vom preocupa de îmbunătățirea calității semnalului vocal în cazul transmiterii acestuia în special pentru telefonul utilizat în autoturisme. Obiectivul acestui studiu este înlăturarea zgomotului în vederea îmbunătățirii calității sunetului în cazul utilizării unui post telefonic “mâini-libere” în habitacul autoturismelor. Presupunem că sunetul se captează cu unul sau două microfoane și căutăm să reducem nivelul zgomotului fără a distorsiona puternic semnalul util. Tehnicile pe care le vom studia nu trebuie să fie aplicabile doar în cazul unui tip de zgomot (zgomot de motor, ...) sau pentru o aplicație particulară, riscând astfel de a dezvolta metode puțin robuste. Dar tehnicile pe care le vom propune pot varia de la o aplicație la alta.

Vom prezenta, în *capitolul I*, stadiul actual al metodelor de îmbunătățire a raportului semnal/zgomot în cazul în care se dispune doar de un singur semnal captat într-un mediu zgomotos. Această problemă a făcut obiectul mai multor studii. Nu este de mirare că întâlnim metode diferite, pe care le-am regrupat în trei mari familii. Vom prezenta doar principiile generale ale acestor metode fără a face o evaluare și o comparație sistematică.

În *capitolul II* vom propune noi metode, pe care le vom grupa în două clase.

În prima clasă vom propune trei noi metode considerând semnalul vocal modelat printr-un proces AR de ordin  $p$  contaminat cu un zgomot alb, aditiv și de medie nulă. Prima metodă estimează coeficienții AR ai semnalului utilizând funcția de autocorelație a semnalului captat și câștigul optimal Kalman calculat iterativ în două moduri diferite, metoda a doua propune estimarea varianțelor zgomotului de excitație și a zgomotului de măsură după ce în prealabil s-a filtrat semnalul captat și metoda a treia estimează parametrii utilizând algoritmul EM (Expectation-Maximisation).

În cea de-a doua clasă vom considera semnalul vocal și respectiv zgomotul modelate printr-un proces AR de ordin  $p$  și respectiv  $q$ . Vom propune două noi metode în acest context. În cadrul

primei metode parametrii zgomotului se estimează în perioadele de “liniște”. Parametrii semnalului vocal se estimează în timpul perioadelor de “activitate vocală”. În cadrul celei de-a doua metode parametrii semnalului vocal și ai zgomotului se estimează utilizând algoritmul EM. În acest caz nu se impune existența unui detector de activitate vocală.

*Capitolul III* tratează îmbunătățirea raportului semnal/zgomot al semnalului vocal în cazul în care se dispune de două semnale captate separat în același mediu zgomotos. Considerăm două surse acustice: prima sursă generează semnalul vocal, iar cea de-a doua generează zgomotul. Presupunem sursele punctiforme și că semnalul vocal și zgomotul sunt necorelate.

Utilizăm semnalele captate de două microfoane plasate în același mediu zgomotos. Primul semnal, numit semnal de prelucrat, este captat de microfonul plasat aproape de vorbitor, cel de-al doilea semnal, numit semnal de referință, este captat de microfonul plasat în vecinătatea sursei de zgomot. Ambele semnale conțin atât componente ale semnalului vocal cât și ale zgomotului.

Mai multe metode au fost propuse în acest context. Prima metodă propusă de Widrow utilizează un singur filtru adaptiv și este utilizabilă doar în cazul în care componenta semnalului vocal captată de cel de-al doilea microfon este neglijabilă. În alte cazuri, mai realiste, trebuie utilizate scheme mai complexe ca de exemplu schema FFIS (FeedForward Implementation Scheme) și schema FBIS (FeedBack Implementation Scheme).

Noi am regrupat metodele bazate pe schema FFIS în două clase.

În prima clasă am regrupat metodele bazate pe decorelarea semnalelor intermediare din sistemul de prelucrare, iar în cea de-a doua clasă metodele bazate pe momentele de ordin superior. Am propus un nou algoritm care poate opera atât secvențial cât și pe blocuri utilizând momentele de ordinul trei.

Utilizând schema FBIS se pot separa componentele corespunzătoare celor două surse din semnalele captate de cele două microfoane fără a fi nevoie de filtre auxiliare de egalizare. Am regrupat aceste metode în două clase.

În prima clasă am regrupat metodele bazate pe decorelarea semnalelor de ieșire și în cea de-a doua clasă metodele bazate pe utilizarea unui filtru dublu.

Ne-am focalizat atenția asupra metodelor care utilizează o structură de filtru dublu. Dacă Vallauri a propus utilizarea unei structuri cu două filtre LMS noi, pentru a ameliora performanțele acestora, am propus utilizarea a două filtre RLS sau SFTF. De asemenea am



justificat convergența unei astfel de structuri către o soluție care realizează separarea semnalelor.

În final, *capitolul IV* se face o evaluare a principalelor metode prezentate în capitolele anterioare. Evaluarea poate fi făcută de manieră obiectivă sau subiectivă. Noi vom utiliza teste obiective suficient de pertinente.

# CAPITOLUL I

## Stadiul actual în îmbunătățirea calității semnalului vocal utilizând un singur captor

### I.1. Introducere

În acest capitol vom prezenta principalele metode utilizate în îmbunătățirea raportului semnal/zgomot în cazul în care se dispune doar de un semnal captat într-un mediu zgomotos. Mai multe studii au făcut obiectul acestei probleme. Metodele pe care le vom prezenta le vom clasifica în :

- 1 - metode bazate pe analiza spectrală de scurtă durată,
- 2 - metode bazate pe filtrarea optimală de tip Wiener sau de tip Kalman,
- 4 - metode bazate pe reprezentarea semnalului vocal printr-o sumă de sinusoid.

### I.2. Metode bazate pe analiza Fourier de scurtă durată

Vom considera semnalul captat  $y(n)$  drept rezultatul sumei dintre semnalul vocal  $s(n)$  și zgomotul  $b(n)$  :

$$y(n) = s(n) + b(n) \quad (I.1)$$

Dacă semnalul și zgomotul nu sunt corelate densitatea interspectrală de putere semnal/zgomot este nulă și atunci densitatea spectrală de putere a semnalului captat este suma densităților spectrale de putere ale semnalului vocal și zgomotului :

$$S_{yy}(\omega) = S_{ss}(\omega) + S_{bb}(\omega) \quad (I.2)$$

Deoarece semnalul vocal  $s(n)$  este un semnal nestaționar ecuația (I.2) este neutilizabilă. Putem însă considera semnalul de vorbire staționar pe intervale scurte de timp, de ordinul a 10-30 ms. Vom nota prin  $y_w(n)$  și respectiv prin  $b_w(n)$  ultimele  $N$  eșantioane ale semnalului  $y(n)$  și respectiv  $b(n)$  ponderate cu fereastra  $w(n)$ . În acest caz putem scrie [BOL78] :

$$|\hat{S}_w(\omega)|^2 = |Y_w(\omega)|^2 - E\{|B_w(\omega)|^2\} \quad (I.3)$$

relație, unde prin  $\hat{S}_w(\omega)$ ,  $B_w(\omega)$  și  $Y_w(\omega)$  am notat transformatele Fourier ale semnalului  $\hat{s}_w(n)$  (estimatul semnalului  $s_w(n)$ ),  $b_w(n)$  și  $y_w(n)$  iar prin  $E\{\cdot\}$  medierea statistică.

Pentru a estima semnalul  $s_w(n)$  avem nevoie, în domeniul spectral, de amplitudinea și faza transformatei Fourier a acestuia la diferite frecvențe. Deoarece estimarea fazei lui  $\hat{S}_w(\omega)$  este dificilă o vom aproxima prin [WAN82] :

$$\varphi_s(\omega) \cong \varphi_y(\omega) \quad (I.4)$$

În acest caz estimata transformatei Fourier a semnalului de vorbire  $\hat{s}_w(n)$  va fi :

$$\hat{S}_w(\omega) = \left[ |Y_w(\omega)|^2 - E\{|B_w(\omega)|^2\} \right]^{1/2} e^{j\varphi_y(\omega)} \quad (I.5)$$

În figura I.1 este prezentată schema tipică a acestei metode numită subtracție spectrală.

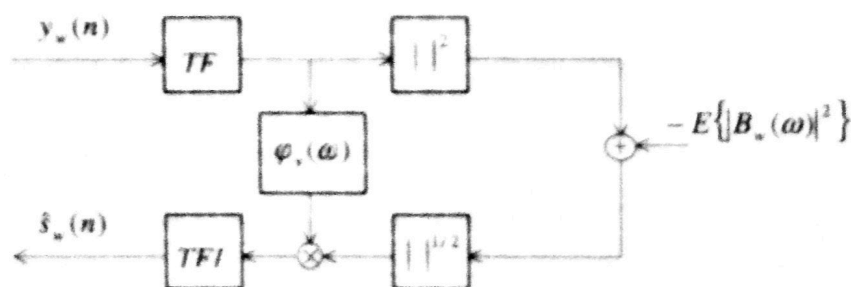


fig. I.1 Subtracția spectrală ([BOL78],[BOL79])

Se poate remarca faptul că, la diferite frecvențe, valoarea amplitudinii estimatei transformatei Fourier a semnalului de vorbire, calculate conform relației (I.3), poate fi negativă. Pentru aceste frecvențe vom considera semnalul vocal de amplitudine nulă [BOL79]. Efectul acestei considerații este cunoscutul fenomen de introducere de “tonuri muzicale”.

Substracția spectrală se poate generaliza utilizând următoarea relație [WEI74][WEI83] :

$$\hat{S}_w(\omega) = [|Y_w(\omega)|^a - E\{|B_w(\omega)|^a\}]^{1/a} e^{j\varphi_y(\omega)} \quad (I.6)$$

relație în care  $a$  este un parametru.

Cazul  $a = 1$  corespunde substracției spectrale de amplitudine,  $a = 2$  substracției spectrale de putere iar în celelalte cazuri substracției spectrale generalizate [DEL93].

S-au propus mai multe metode pentru diminuarea zgomotului muzical rezidual :

1. O metodă utilizată pentru diminuarea acestor “tonuri muzicale” constă în ponderarea spectrului zgomotului mediu  $E\{|B_w(\omega)|^a\}$  în relația (I.6) [BER79] :

$$\hat{S}_w(\omega) = [|Y_w(\omega)|^a - \alpha E\{|B_w(\omega)|^a\}]^{1/a} e^{j\varphi_y(\omega)} \quad (I.7)$$

Alegând valori mai mari decât 1 pentru factorul de ponderare  $\alpha$  se vor anula inclusiv componentele semnalului vocal de amplitudine mică. Deci, eliminarea parțială a “tonurilor muzicale” este însoțită de distorsionarea semnalului vocal [AKB95].

2. O altă metodă utilizată constă în supraestimarea numai acelor componente ale zgomotului care depășesc un anumit prag spectral [BER79] :

$$\hat{S}_w(\omega) = \begin{cases} [|Y_w(\omega)|^a - \alpha [E\{|B_w(\omega)|^2\}]^{a/2}]^{1/a} e^{j\varphi_y(\omega)} & \text{dacă } |Y_w(\omega)|^2 - \alpha E\{|B_w(\omega)|^2\} \geq \beta E\{|B_w(\omega)|^2\} \\ [\beta E\{|B_w(\omega)|^2\}]^{1/2} e^{j\varphi_y(\omega)} & \text{în rest} \end{cases} \quad (I.8)$$

$\alpha \geq 1$  și  $0 < \beta < 1$

Supraestimarea zgomotului se poate face diferit pentru fiecare componentă spectrală [LEB91] :

$$\hat{S}_w(\omega) = [|Y_w(\omega)|^2 - \alpha(\omega) E\{|B_w(\omega)|^2\}]^{1/2} e^{j\varphi_y(\omega)} \quad (I.9)$$

$$\alpha(\omega) = \begin{cases} \alpha_{\max} & \text{dacă } |Y_w(\omega)|^2 - \alpha_{\max} E\{|B_w(\omega)|^2\} \geq \beta E\{|B_w(\omega)|^2\} \\ \max(\alpha_{\max} - i^* \Delta, 1) & \text{în rest} \end{cases}$$

cu  $i^* = \underset{i}{\operatorname{argmin}} \{i \in N \mid |Y_w(\omega)|^2 - (\alpha_{\max}(\omega) - i\Delta) E\{|B_w(\omega)|^2\} \geq \beta E\{|B_w(\omega)|^2\}\}$  (I.10)

$$\alpha_{\max} \geq 1, \quad 0 < \beta \ll 1, \quad 0 < \Delta < 1$$

3. O altă metodă propune netezirea amplitudinii transformatei Fourier a estimatului semnalului de vorbire  $|\hat{S}_w(\omega)|$  făcând o mediere pe mai multe blocuri. Notăm prin  $|\hat{S}_w(\omega, k)|$  amplitudinea transformatei Fourier pe termen scurt, corespunzătoare blocului  $k$ , a estimatului semnalului de vorbire. Vom nota prin  $|\bar{S}_w(\omega, i)|$  amplitudinea spectrului mediu pentru  $2I+1$  blocuri [BER79] :

$$|\bar{S}_w(\omega, i)| = \frac{1}{2I+1} \sum_{k=i-I}^{i+I} |\hat{S}_w(\omega, k)| \quad (I.11)$$

### I.3. Metode bazate pe filtrarea optimală

#### I.3.1. Metode bazate pe filtrarea de tip Wiener

În domeniul spectral expresia filtrului Wiener necauzal este :

$$H(\omega) = \frac{S_{ss}(\omega)}{S_{ss}(\omega) + S_{bb}(\omega)} \quad (I.12)$$

relație în care prin  $S_{ss}(\omega)$  și  $S_{bb}(\omega)$  am notat densitățile spectrale de putere ale semnalului și respectiv zgomotului.

Deoarece semnalul de vorbire și/sau zgomotul sunt nestaționare pe durată lungă relația de calcul a filtrului Wiener necauzal se poate aproxima prin :

$$H(\omega) = \frac{E\{|S_w(\omega)|^2\}}{E\{|S_w(\omega)|^2\} + E\{|B_w(\omega)|^2\}} \quad (I.13)$$

Deoarece semnalul de vorbire și zgomotul sunt presupuse necorelate se poate scrie :

$$E\{|S_w(\omega)|^2\} = E\{|Y_w(\omega)|^2\} - E\{|B_w(\omega)|^2\} \quad (I.14)$$

Transformata Fourier de scurtă durată a estimatului semnalului de vorbire este dată de :

$$\hat{S}_w(\omega) = H(\omega)Y_w(\omega) \quad (I.15)$$

Se poate remarca faptul că faza spectrului semnalului estimat coincide cu faza spectrului semnalului captat, filtrul Wiener fiind de fază nulă. Combinând relațiile (I.13) și (I.15), înlocuind densitatea spectrală a semnalului prin estimata sa, se obține următoarea relație :

$$|\hat{S}_w(\omega)| = \frac{|\hat{S}_w(\omega)|^2}{|\hat{S}_w(\omega)|^2 + E\{|B_w(\omega)|^2\}} |Y_w(\omega)| \quad (I.16)$$

Se poate defini filtrarea Wiener generalizată [LIM79] prin :

$$|\hat{S}_w(\omega)| = \left[ \frac{|\hat{S}_w(\omega)|^2}{E\{|\hat{S}_w(\omega)|^2\} + E\{|B_w(\omega)|^2\}} \right]^{1/a} |Y_w(\omega)| \quad (I.17)$$

Pentru  $a = 2$  ecuația (I.17) este o ecuație de gradul doi în  $|\hat{S}_w(\omega)|$ . Prima soluție este soluția nulă. Cea de-a doua este :

$$|\hat{S}_w(\omega)| = \left[ |Y_w(\omega)|^2 - E\{|B_w(\omega)|^2\} \right]^{1/2} \quad (I.18)$$

Putem remarca faptul că această din urmă relație este similară substrației spectrale de putere ( $a = 2$ ).

În general rezolvarea ecuației (I.18) se face iterativ. La iterația  $i$  estimarea filtrului optimal se face, utilizând  $|\hat{S}_w(\omega, i-1)|^2$ , conform ecuației:

$$H(\omega, i) = \left[ \frac{|\hat{S}_w(\omega, i-1)|^2}{|\hat{S}_w(\omega, i-1)|^2 + E\{|B_w(\omega)|^2\}} \right]^{1/a} \quad (I.19)$$

iar apoi se calculează  $\hat{S}_w(\omega, i)$  :

$$\hat{S}_w(\omega, i) = H(\omega, i)Y_w(\omega) \quad (I.20)$$

### I.3.2. Metode bazate pe modelarea AR și filtrarea Wiener necauzală

Această metodă se bazează pe modalarea semnalului vocal printr-un proces AR de ordinul  $p$  :

$$s(n) = \sum_{i=1}^p a_i s(n-i) + u(n) \quad (I.21)$$

relație în care prin  $s(n)$  am notat semnalul de vorbire,  $a_i$  ( $i = 1, p$ ) sunt coeficienții modelului și  $u(n)$  semnalul de excitație.

Semnalul  $u(n)$  este un zgomot alb de medie nulă și dispersie  $\sigma_u^2$  pentru semnale nesonore și un tren de impulsuri pentru semnalele sonore. Cum zgomotul  $b(n)$  este presupus aditiv, de medie nulă și dispersie  $\sigma_b^2$  semnalul captat  $y(n)$  este :

$$y(n) = s(n) + b(n) \quad (I.22)$$

Fie vectorii :

$$\mathbf{s} = [s(N-1) \quad \dots \quad s(0)]^T \quad (I.23)$$

$$\mathbf{y} = [y(N-1) \quad \dots \quad y(0)]^T \quad (I.24)$$

$$\mathbf{a} = [a(1) \quad \dots \quad a(p)]^T \quad (I.25)$$

Metoda propune estimarea coeficienților modelului utilizând criteriul probabilității maxim a posteriori. Pentru simplificare vom presupune  $u(n)$  și  $b(n)$  două procese cu distribuție gaussiană. Se caută acei coeficienți  $\mathbf{a}$  care maximizează probabilitatea a posteriori :

$$\hat{\mathbf{a}} = \arg \max_{\mathbf{a}} p(\mathbf{s}|\mathbf{y}) \quad (I.26)$$

Printre ecuațiile obținute din (I.29) unele sunt nelineare și dificil de rezolvat. Lim [LIM79] a propus o metodă iterativă de rezolvare a acestui sistem, metodă care conduce la o soluție suboptimală. Fiecare iterație conține două etape. În prima etapă, a iterației  $k$ , se estimează coeficienții modelului AR utilizând criteriul probabilității maxim a posteriori :

$$\hat{\mathbf{a}}_k = \arg \max_{\mathbf{a}} p(\mathbf{s}|\hat{\mathbf{s}}_{k-1}, \mathbf{y}, \hat{\sigma}_{u,k-1}^2) \quad (I.27)$$

relație în care prin  $\hat{\mathbf{s}}_{k-1}$  am notat estimatul vectorului  $\mathbf{s}$  la iterația  $k-1$  :

$$\hat{\mathbf{s}}_{k-1} = [\hat{s}_{k-1}(N-1) \quad \dots \quad \hat{s}_{k-1}(0)]^T \quad (I.28)$$

iar prin  $\hat{\sigma}_{u,k-1}^2$  estimata varianței lui  $u(n)$  la iterația  $k-1$ .

În practică estimarea coeficienților AR se face utilizând metoda corelației.

Reactualizarea varianței semnalului  $u(n)$  se face utilizând teorema lui Parseval:

$$\frac{N}{2\pi} \int_{-\pi}^{\pi} \frac{\hat{\sigma}_{u,k}^2}{\left|1 - \sum_{i=1}^p \hat{a}_{i,k} e^{-ji\omega}\right|^2} d\omega = \sum_{n=0}^{N-1} y^2(n) - N\hat{\sigma}_b^2 \quad (\text{I.29})$$

unde prin  $\hat{\sigma}_b^2$  am notat estimata varianței zgomotului  $b(n)$  (estimată pe durata perioadelor de liniste).

În cea de-a doua etapa se estimează semnalul de vorbire:

$$\hat{s}_k = \arg \max_s p(s | a_k, y, \hat{\sigma}_{u,k}^2) \quad (\text{I.30})$$

Aceasta se face utilizând filtrul Wiener necauzal :

$$H(\omega, k) = \frac{\hat{S}_{ss}(\omega, k)}{\hat{S}_{ss}(\omega, k) + \hat{\sigma}_b^2} \quad (\text{I.31})$$

relație în care estimata densității spectrale de putere a semnalului vocal la iterația  $k$  este:

$$\hat{S}_{ss}(\omega, k) = \frac{\hat{\sigma}_{u,k}^2}{\left|1 - \sum_{i=1}^p \hat{a}_{i,k} e^{-ji\omega}\right|^2} \quad (\text{I.32})$$

Schema corespunzatoare este prezentată în fig. I.5 [AKB95].

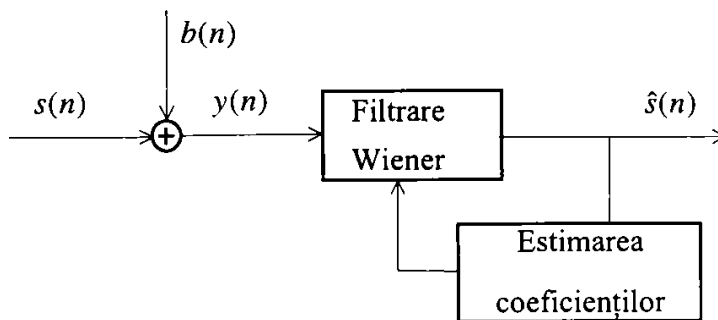


fig. I.2 Filtrare Wiener necauzală utilizând un model AR

Convergența acestei metode este condiționată de forma funcției densității de probabilitate a semnalului vocal. Dacă această densitate prezintă un maxim global și inițializarea este făcută în apropierea acestuia, atunci se poate realiza atât estimarea coeficienților AR cât și estimarea semnalului vocal. Comparativ cu substrația spectrală metoda prezintă avantajul neintroducerii de “tonuri muzicale”. Dar, această metodă prezintă două inconveniente:



- numărul diferit de iterații în funcție de natura semnalului de vorbire (sonor, nesonor, liniste etc.),
- prin creșterea numărului de iterații se elimină progresiv componentele zgomotului, eliminare însoțită și de o ușoară și progresivă distorsionare a semnalului vocal datorată diminuării benzilor formanzilor.

Pentru a înlătura aceste inconveniente se impune utilizarea unor constrângeri în estimarea coeficienților AR astfel încât să se mențină stabilitatea sistemului :

- polii trebuie să rămână în interiorul cercului unitar poziționați în vecinătatea acestuia, poziție specifică semnalelor vocale,
- polii nu trebuie să se modifice substanțial de la un bloc la altul sau de la o iterație la alta.

Calculul poziției acestor poli este destul de laborios având în vedere ordinul ridicat al polinomului  $A(z)$ .

Pentru a simplifica calculele, Hansen și Clements [HAN87] au propus utilizarea perechilor de raze spectrale. Aceste raze spectrale se obțin utilizând polinoamele de predicție directă  $A(z)$  și retrogradă  $B(z)$  asociate semnalului de vorbire. Polinomul  $B(z)$  se obține din  $A(z)$  prin relația :

$$B(z) = z^{-p-1}A(z^{-1}) \quad (I.33)$$

Se definesc polinoamele :

$$P(z) = A(z) + B(z) \quad (I.34)$$

$$Q(z) = A(z) - B(z) \quad (I.35)$$

Pentru valori pare ale lui  $p$  avem [BOI87] :

$$P(z) = (z+1) \prod_{i=1}^{p/2} (1 + \alpha_i z^{-1} + z^{-2}) \quad (I.36)$$

$$Q(z) = (z-1) \prod_{i=1}^{p/2} (1 + \beta_i z^{-1} + z^{-2}) \quad (I.37)$$

unde :

$$\alpha_i = -2 \cos \varphi_i \quad i = 1, 2, \dots, p/2 \quad (I.38)$$

$$\beta_i = -2 \cos \psi_i \quad i = 1, 2, \dots, p/2 \quad (\text{I.39})$$

unde  $\varphi_i$  și  $\psi_i$  reprezintă perechea  $i$  de raze spectrale.

Polinoamele  $P(z)$  și  $Q(z)$  au rădăcinile situate alternant pe cercul unitar, proprietate rezultată din descompunerea lui  $A(z)$  în parte reciprocă și parte antireciprocă. Alternarea lui  $\varphi_i$  și  $\psi_i$  pe cercul unitar constituie un criteriu de stabilitate a lui  $1/A(z)$  [BOI87].

Se definesc coeficienții de poziție  $p_i = \varphi_i$  și coeficienții diferență :

$$d_i = \min_{j=0,1} (|\varphi_{i+j} - \psi_i|) \quad i = 1, 2, \dots, p/2 \quad (\text{I.40})$$

Hansen et Clements [HAN87] au propus două clase de constrângeri : constrângeri inter și intra-bloc.

În ceea ce privesc constrângerile inter-bloc s-a propus o netezire pe mai multe blocuri a coeficienților de poziție  $p_i$  utilizând o fereastră triunghiulară. Lărgimea ferestrei este aleasă în funcție de natura semnalului vocal din blocurile implicate (sonor, nesonor, liniște, etc.).

Se cunoaște că acești coeficienți de poziție sunt strâns legați de poziția formanzilor. Pentru a nu distorsiona semnalul vocal, prezervând caracteristicile sale perceptuale, lărgimea ferestrei asociată primului coeficient este mai mică.

În ceea ce privesc constrângerile intra-bloc se pot impune constrângeri asupra coeficienților de poziție sau asupra funcției de autocorelație.

### I.3.3. Metode bazate pe un model numai poli și filtrarea Kalman

Vom considera semnalul de vorbire  $s(n)$  modelat printr-un proces autoregresiv AR de ordinul  $p$  (I.21). Pentru început vom considera zgomotul ambiant  $b(n)$  un zgomot alb de medie nulă și dispersie  $\sigma_b^2$ . Vom rescrie ecuațiile (I.21) și (I.22) care descriu modelarea semnalului de vorbire și semnalului captat utilizând reprezentarea în spațiul stărilor [PAL87] [GIB91] :

$$\mathbf{x}(n+1) = \Phi \mathbf{x}(n) + \Gamma u(n+1) \quad (\text{I.41})$$

$$y(n) = \mathbf{H} \mathbf{x}(n) + b(n) \quad (\text{I.42})$$

relații în care prin  $\mathbf{x}(n)$  am notat vectorul de stare construit din ultimele  $p$  eșantioane ale semnalului vocal  $s(n)$  :

$$\mathbf{x}(n) = [s(n-p+1), \dots, s(n)]^T \quad (\text{I.43})$$

prin  $\Phi$  matricea de tranziție :

$$\Phi = \begin{bmatrix} 0 & 1 & 0 \\ \vdots & \vdots & \vdots \\ 0 & 0 & 1 \\ a_p & a_{p-1} & \dots & a_1 \end{bmatrix} \quad (\text{I.44})$$

iar prin  $\Gamma$  și  $H$  am notat matricele de intrare și ieșire:

$$\Gamma = H^T = [0, 0, \dots, 0, 1]^T \quad (\text{I.45})$$

Paliwal și Basu [PAL87] au propus o metodă de estimare a semnalului de vorbire  $s(n)$  utilizând filtrarea Kalman, filtrare care permite estimarea vectorului de stare  $\hat{\mathbf{x}}(n/n)$ , la momentul  $n$  dispunând de eșantioanele semnalului captat  $\{y(1), y(2), \dots, y(n)\}$ , în sensul minimizării erorii medii pătratice.

Vom nota prin :

- $P(n/n)$  matricea de autocorelație a erorii de predicție a posteriori,
- $\hat{\mathbf{x}}(n/n-1)$  estimatul apriori al vectorului de stare  $\mathbf{x}(n)$ , estimat calculat dispunând de eșantioanele semnalului captat  $\{y(1), y(2), \dots, y(n-1)\}$ ,
- $P(n/n-1)$  matricea de autocorelație a erorii de predicție apriori.

Ecuțiile care descriu algoritmul filtrării Kalman sunt [NAJ88]:

$$\hat{\mathbf{x}}(n/n) = \hat{\mathbf{x}}(n/n-1) + \mathbf{K}(n)(y(n) - \mathbf{H}\hat{\mathbf{x}}(n/n-1)) \quad (\text{I.46})$$

$$\hat{\mathbf{x}}(n+1/n) = \Phi \hat{\mathbf{x}}(n/n) \quad (\text{I.47})$$

$$\mathbf{P}(n/n) = [\mathbf{I} - \mathbf{K}(n)]\mathbf{P}(n/n-1) \quad (\text{I.48})$$

$$\mathbf{K}(n) = \mathbf{P}(n/n-1)\mathbf{H}^T [\mathbf{H}\mathbf{P}(n/n-1)\mathbf{H}^T + \sigma_b^2]^{-1} \quad (\text{I.49})$$

$$\mathbf{P}(n+1/n) = \Phi \mathbf{P}(n/n) \Phi^T + \sigma_u^2 \Gamma \Gamma^T \quad (\text{I.50})$$

În relațiile de mai sus am notat prin  $\mathbf{K}(n)$  câștigul Kalman.

Estimarea semnalului de vorbire se face în două etape :

- 1) estimarea parametrilor necesari filtrului Kalman, respectiv coeficienții AR, dispersia zgomotului ambient  $b(n)$  și dispersia semnalului de excitație  $u(n)$ .
- 2) se filtrează semnalul captat cu filtrul Kalman utilizând parametrii estimați în prima etapă. Estimatul semnalului de vorbire  $\hat{s}(n)$  se obține extrăgând ultima componentă a vectorului  $\hat{\mathbf{x}}(n/n)$ .

Pentru validarea experimentală Paliwal a utilizat parametrii așa zisi “ideali”, adică parametrii corespunzători semnalului vocal calculați direct din acesta în absența zgomotului și varianța zgomotului estimată direct din zgomot.

Schema bloc este prezentată în figura I.3.

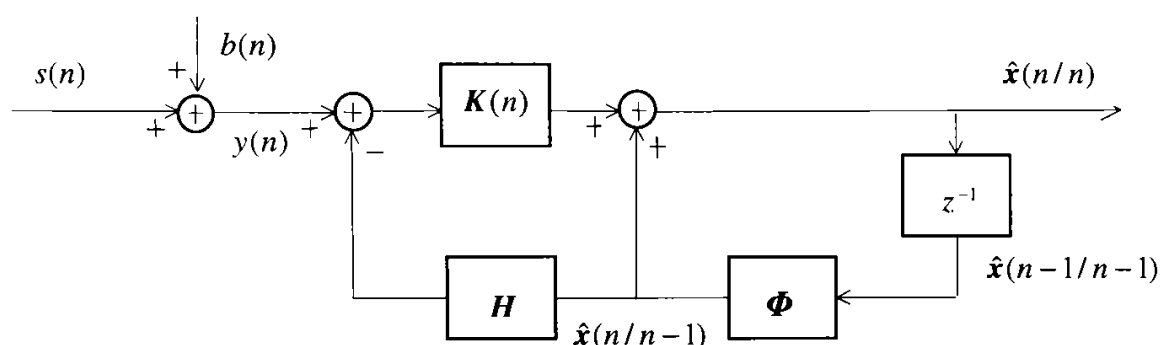


fig I.3 Filtrare Kalman bazată pe modelarea AR [PAL87]

Pentru de estimarea parametrilor necesari filtrului Kalman, Gibson și alții [GIB88][GIB91] au propus o metodă iterativă care conduce la o soluție suboptimală.

Metoda alternează două etape.

- 1) se estimează parametrii semnalului vocal din estimatul semnalului vocal obținut în iterația precedentă,
- 2) se filtrează semnalul captat cu un filtru Kalman utilizând parametrii estimați în prima etapă. Dispersia zgomotului se estimează pe durata perioadelor lipsite de activitate vocală.

Schema bloc care sintetizează această metodă este prezentată în figura I.4.

În această schemă notațiile sunt clasice cu excepția faptului că s-a introdus un indice suplimentar  $i$ , indice care reprezintă numărul iterației. Valorile estimatelor câștigului Kalman și matricei de tranziție au fost și ele înlocuite prin estimatele obținute după iterația  $i$ . Prin  $i_{MAX}$  am notat numărul maxim de iterații.

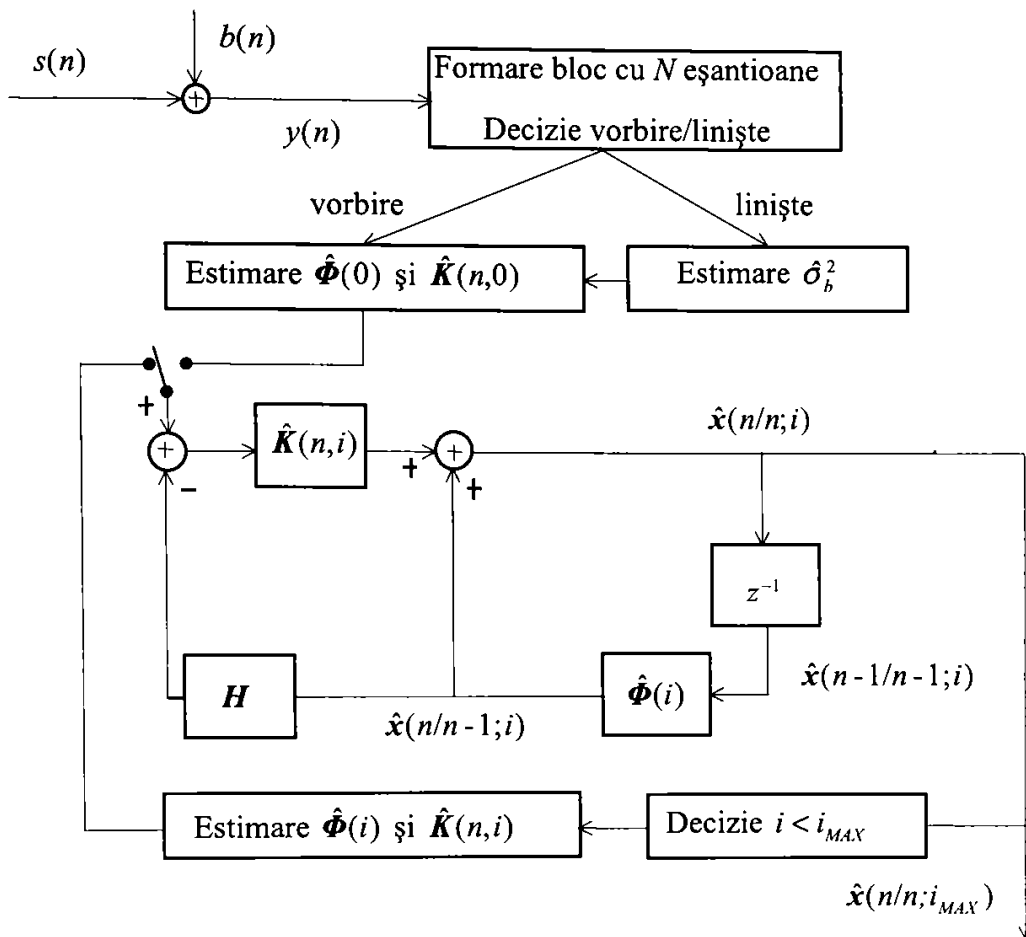


fig I.4 Filtrare Kalman bazată pe modelarea AR [GIB88]

Oppenheim și al. [OPP94] au propus o metodă adaptivă de estimare a parametrilor necesari filtrului Kalman. Ei utilizează o scriere a sistemului în spațiul stărilor puțin diferită față de cea propusă de Paliwal, vectorul de stare conține  $p+1$  componente și este definit prin :

$$\mathbf{x}(n) = [s(n-p), \dots, s(n)]^T \quad (I.51)$$

Matrice de tranziție  $\Phi$  de dimensiune  $(p+1) \times (p+1)$  este definită prin :

$$\Phi = \begin{bmatrix} 0 & 1 & 0 & \dots & 0 \\ 0 & 0 & 1 & \dots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & \dots & 1 \\ 0 & a_p & a_{p-1} & \dots & a_1 \end{bmatrix} \quad (I.52)$$

Estimatul vectorului de stare  $\hat{\mathbf{x}}(n/n)$  este definit prin :

$$\hat{\mathbf{x}}(n/n) = [\hat{s}(n-p/n), \dots, \hat{s}(n/n)]^T \quad (I.53)$$

Estimatul matricei rezultate în urma produsului vectorului de stare cu transpusul său este [OPP94]:

$$\mathbf{x}(n)\hat{\mathbf{x}}^T(n) = \hat{\mathbf{x}}(n/n)\hat{\mathbf{x}}^T(n/n) + \mathbf{P}(n/n) \quad (\text{I.54})$$

Fie  $\mathbf{R}(n)$  matricea de autocorelație :

$$\mathbf{R}(n) = E\left\{\mathbf{x}(n)\mathbf{x}^T(n)\right\} \quad (\text{I.55})$$

Estimata acestei matrice poate fi aproximată, presupunând semnalul ergodic, prin medierea temporală [OPP94]:

$$\hat{\mathbf{R}}(n) = \frac{\sum_{i=1}^n \lambda^{n-i} \mathbf{x}(i)\hat{\mathbf{x}}^T(i)}{\sum_{i=1}^n \lambda^{n-i}} \quad (\text{I.56})$$

relație în care prin  $\lambda < 1$  am notat un factor de uitare care ne permite să urmărim caracterul nestaționar al semnalului de vorbire.

Vom impune estimatelor mărimilor corespunzătoare semnalului vocal, modelizat printr-un proces autoregresiv AR, să verifice ecuațiile Youle-Walker :

$$\hat{\mathbf{R}}(n) \begin{bmatrix} -\hat{a}_p(n) \\ \vdots \\ -\hat{a}_1(n) \\ 1 \end{bmatrix} = \begin{bmatrix} 0 \\ \vdots \\ 0 \\ \hat{\sigma}_u^2(n) \end{bmatrix} \quad (\text{I.57})$$

Estimarea dispersiei zgomotului aditiv  $b(n)$ , zgomot presupus necorelat cu semnalul vocal  $s(n)$ , se face conform ecuației (I.58) unde prin  $\eta < 1$  am notat un alt factor de uitare :

$$\hat{\sigma}_b^2(n) = \frac{\sum_{i=1}^n \eta^{n-i} (y^2(i) - 2y(i)\hat{s}(i/n) + \hat{s}^2(i/n))}{\sum_{i=1}^n \eta^{n-i}} \quad (\text{I.58})$$

Această metodă poate fi utilizată atât pentru îmbunătățirea calității semnalului captat într-un mediu zgomotos cât și pentru anularea activă a zgomotului [ZAN94].

Schema bloc a acestei metode este prezentată în figura I.5.

*Handwritten notes:* c. just

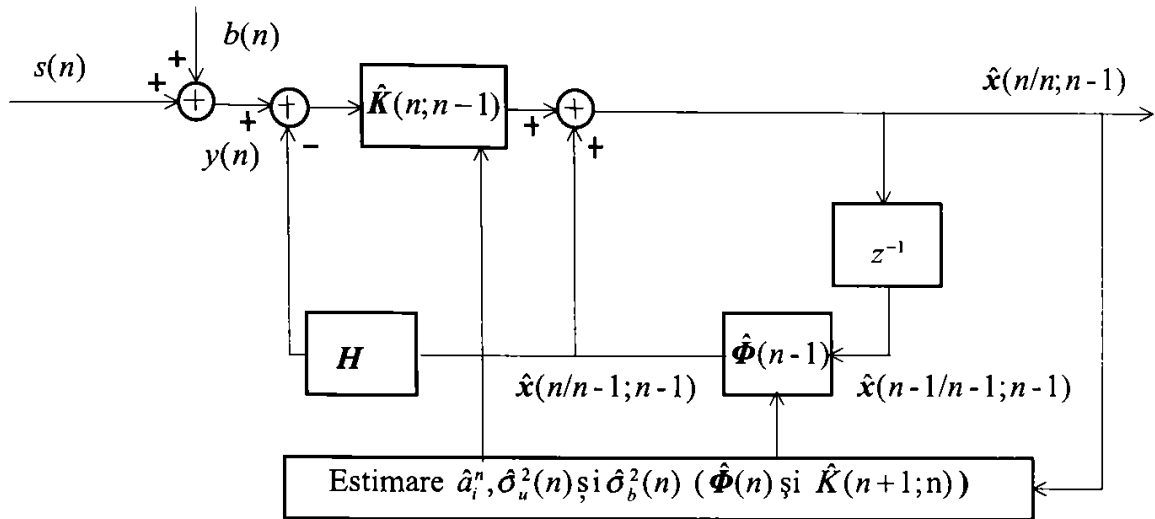


fig I.5 Filtrare Kalman bazată pe un model AR [OPP94]

Zgomotul real nu este un zgomot alb, el este un zgomot colorat. Pentru simplificare îl vom considera modelabil printr-un proces autoregresiv de ordinul  $q$  :

$$b(n) = \sum_{j=1}^q c_j b(n-j) + v(n) \quad (I.59)$$

Cele două semnale de excitație  $u(n)$  și  $v(n)$  se presupun independente, de tip zgomot alb distribuite gaussian, de medii nule și dispersii  $\sigma_u^2$  și  $\sigma_v^2$ .

Sistemul se poate reprezenta în spațiul stărilor prin următoarele ecuații [GIB91] :

$$\mathbf{x}(n+1) = \Phi \mathbf{x}(n) + \Gamma \mathbf{n}(n+1) \quad (I.60)$$

unde prin  $\mathbf{x}(n)$  am notat vectorul de stare.

Semnalul captat de singurul captor disponibil este :

$$y(n) = s(n) + b(n) = \mathbf{H} \mathbf{x}(n) \quad (I.61)$$

În acest caz vectorul de stare este format din ultimele  $p$  valori ale semnalului de vorbire concatenate cu ultimele  $q$  valori ale zgomotului [GIB91] :

$$\mathbf{x}(n) = [s^T(n), \mathbf{b}^T(n)]^T \quad (I.62)$$

$$\mathbf{s}(n) = [s(n-p+1), \dots, s(n)]^T \quad (I.63)$$

$$\mathbf{b}(n) = [b(n-q+1), \dots, b(n)]^T \quad (I.64)$$

Matricea de tranziție  $\Phi$  are în componență două matrice notate  $\Phi_s$  și  $\Phi_b$ , conținând respectiv parametrii AR ai semnalului vocal și parametrii AR ai zgomotului :

$$\Phi = \begin{bmatrix} \Phi_s & 0 \\ 0 & \Phi_b \end{bmatrix} \quad (I.65)$$

$$\Phi_s = \begin{bmatrix} 0 & 1 & 0 \\ \vdots & \vdots & \vdots \\ 0 & 0 & 1 \\ a_p & a_{p-1} & a_1 \end{bmatrix} \quad (I.66)$$

$$\Phi_b = \begin{bmatrix} 0 & 1 & 0 \\ \vdots & \vdots & \vdots \\ 0 & 0 & 1 \\ c_q & c_{q-1} & \dots & c_1 \end{bmatrix} \quad (I.67)$$

Matricele  $\Gamma$  și  $H$  sunt definite prin :

$$\Gamma = \begin{bmatrix} 0 & 1 & 0 & \dots & 0 \\ 0 & \dots & 0 & 0 & \dots & 1 \end{bmatrix}^T \quad (I.68)$$

$$H = [0, 0, \dots, 0, 1, 0, 0, \dots, 0, 1] \quad (I.69)$$

iar vectorul  $n(n)$  prin :

$$n(n) = [u(n) \quad v(n)]^T \quad (I.70)$$

Pentru estimarea parametrilor necesari aplicării filtului Kalman, în cazul unui zgomot colorat, Gibson și al. [GIB91] au propus ca metodă de estimare o extensie a metodei propuse în cazul unui zgomot ambient de tip zgomot alb [GIB87]. Parametrii zgomotului sunt estimați în perioadele de liniște sau utilizând un captor suplimentar dispus în vecinătatea sursei de zgomot. Schema bloc este similară schemei I.4 cu singura diferență, că aici, în timpul perioadelor de liniște, se estimează parametrii zgomotului, zgomot modelat printr-un proces autoregresev de ordin  $p$ .

Metoda propusă de Oppenheim și al. [OPP94] pentru un zgomot alb a fost generalizată de Verbout [VEB94] pentru un zgomot colorat. Alegerea vectorului de stare este diferită de cea prezentată anterior. Vectorul de stare este compus din ultimele  $p+1$  eșantioane ale semnalului



vocal și ultimele  $q$  eşantioane ale zgomotului. Schema bloc este asemănătoare schemei bloc prezentate în figura I.5.

## I.4 Metode bazate pe reprezentarea semnalului vocal printr-o sumă de sinusoid

### I.4.1. Metode bazate pe reprezentarea semnalului vocal printr-o sumă de sinusoid și pe descompunerile trunchiate SVD și QSVD

Aceste metode [JEN94][JEN95] se bazează pe descompunerea spațiului generat de semnalul captat în două subspații și anume, subspațiul semnal și subspațiul zgomot. Vom aranja eşantioanele semnalului captat într-o matrice a observațiilor de tip Hankel, de dimensiune  $L \times M$ , cu  $L \geq M$ ,  $L+M+1=N$ , notată  $\mathbf{Y}$ :

$$\mathbf{Y} = \begin{bmatrix} y(0) & y(1) & \dots & y(M-1) \\ y(1) & y(2) & \dots & y(M) \\ \vdots & \vdots & \dots & \vdots \\ y(L-1) & y(L) & \dots & y(N-1) \end{bmatrix} \quad (1.71)$$

unde  $y(0), \dots, y(N-1)$  sunt cele  $N$  eşantioane disponibile ale semnalului captat.

Descompunerea SVD (Singular Value Decomposition) a matricei  $\mathbf{Y}$  se poate scrie :

$$\mathbf{Y} = [\mathbf{U}_1 \quad \mathbf{U}_2] \begin{bmatrix} \Sigma_1 & 0 \\ 0 & \Sigma_2 \end{bmatrix} \begin{bmatrix} \mathbf{V}_1 \\ \mathbf{V}_2 \end{bmatrix} \quad (1.72)$$

relație în care  $\mathbf{U}_1 \in R^{L \times K}$ ,  $\mathbf{V}_1 \in R^{M \times K}$ ,  $\Sigma_1 = \text{diag}(\sigma_y^1, \sigma_y^2, \dots, \sigma_y^K)$  și  $\Sigma_2 = \text{diag}(\sigma_y^{K+1}, \sigma_y^{K+2}, \dots, \sigma_y^M)$ .

Matricea Hankel obținută se poate scrie ca sumă a două matrice Hankel, una corespunzătoare semnalului  $\mathbf{S}$  și alta corespunzătoare zgomotului  $\mathbf{B}$ . Semnalul vocal poate fi modelat printr-o sumă de  $K$  sinusoid. Alegând o valoare pentru  $M$  astfel încât  $K < M$  matricea  $\mathbf{S}$  va fi o matrice de rang  $K$ , deci nu va fi o matrice de rang plin. Dacă zgomotul ambiant este alb matricea  $\mathbf{B}$  este de rang plin.

Estimarea matricei  $\mathbf{S}$  se va face pornind de la matricea  $\mathbf{Y}$  utilizând două metode și anume metoda celor mai mici pătrate și metoda varianței minime. Metoda celor mai mici pătrate

conduce la cea mai apropiată matrice, notată  $\hat{S}_{LS}$  de dimensiune  $K \times M$  și rang  $K$ , în normă Frobenius de matricea Hankel a semnalului captat  $Y$  [JEN95] :

$$\hat{S}_{LS} = U_1(F_{LS}\Sigma_1)V_1^T \text{ cu } F_{LS} = I_K \quad (I.73)$$

Metoda varianței minime caută matricea  $\hat{S}_{MV}$  obținută prin multiplicare la dreapta a matricei  $Y$  cu o matrice de  $T$  dimensiune  $M \times M$  astfel încât să se minimizeze norma Frobenius a matricei diferență  $Y - \hat{S}_{MV}$  [JEN95] :

$$\hat{S}_{MV} = U_1(F_{MV}\Sigma_1)V_1 \text{ cu } F_{MV} = \text{diag} \left( \left(1 - \frac{\sigma_b^2}{\sigma_y^2}\right), \dots, \left(1 - \frac{\sigma_b^2}{\sigma_y^{K^2}}\right) \right) \quad (I.74)$$

Estimarea celor  $N$  eșantioane ale semnalului de vorbire se face prin mediere anti-diagonală efectuată asupra matricelor  $\hat{S}_{LS}$  sau  $\hat{S}_{MV}$  [JEN94].

În cazul în care zgomotul nu mai este un zgomot alb, este necesară o albire prealabilă a acestuia. Vom utiliza ultimele  $N$  eșantioanele zgomotului  $b(i), \dots, b(i+N-1)$  unde  $i$  este primul eșantion din ultima perioadă de liniște. Cu aceste eșantioane se construiește matricea  $B$  de tip Hankel și de dimensiune  $L \times M$ . Se descompune această matrice, utilizând descompunerea QR, în  $B = QR$ . Se construiește matricea  $Z = YR^{-1}$  și ținând seama de caracterul aditiv al zgomotului aceasta se exprimă prin suma dintre matricea corespunzătoare semnalului de vorbire  $SR^{-1}$  și matricea corespunzătoare zgomotului  $Q$ . Matricea  $Q$  are coloanele ortogonale și fiecare coloană este de normă  $\sigma_q^2$ . Se utilizează algoritmul descris pentru un zgomot alb pentru a estima matricea  $SR^{-1}$  și se obțin matricele  $\hat{Z}_{LS}$  utilizând metoda celor mai mici pătrate matricele sau  $\hat{Z}_{MV}$  utilizând metoda varianței minime.. Estimata matricei Hankel corespunzătoare semnalului vocal se obține prin multiplicarea la dreapta a matricei  $\hat{Z}_{LS}$  sau  $\hat{Z}_{MV}$  cu matricea  $R$ .

Calculul necesitat de această metodă este destul de laborios. Pentru reducerea acestuia Jensen și al. [JEN95] au propus utilizarea descompunerii QSVD (Quotient Singular Value Decomposition) [LOA85] a matricelor  $Y$  și  $B$ , lucru echivalent descompunerii SVD a matricei  $Z = YR^{-1}$  :

$$\mathbf{Z} = \mathbf{U}\Delta\Theta^{-1}, \mathbf{B} = \mathbf{V}\Omega\Theta^{-1}, \quad \text{cu} \quad \mathbf{U}, \mathbf{V} \in R^{L \times M}, \mathbf{U}^T \mathbf{U} = \mathbf{I}, \mathbf{V}^T \mathbf{V} = \mathbf{I},$$

$$\Delta = \text{diag}(\delta_1, \dots, \delta_M), \Omega = \text{diag}(\mu_1, \dots, \mu_M) \quad (\text{I.75})$$

$$\delta_1 \geq \delta_2 \geq \dots \geq \delta_M, \mu_1 \leq \mu_2 \leq \dots \leq \mu_M$$

Estimata matricei  $\mathbf{SR}^{-1}$  se poate calcula prin :

$$\hat{\mathbf{Z}}_{LS} = \mathbf{U} \begin{bmatrix} \mathbf{F}_{LS} \mathbf{A}_1 & 0 \\ 0 & 0 \end{bmatrix} \Theta^{-1} \text{ sau } \hat{\mathbf{Z}}_{MV} = \mathbf{U} \begin{bmatrix} \mathbf{F}_{MV} \mathbf{A}_1 & 0 \\ 0 & 0 \end{bmatrix} \Theta^{-1}$$

$$\mathbf{A}_1 = \text{diag}(\delta_1, \dots, \delta_K), \mathbf{F}_{LS} = \mathbf{I}, \mathbf{F}_{MV} = \text{diag} \left( \left(1 - \frac{\sigma_q^2}{\delta_1^2}\right), \dots, \left(1 - \frac{\sigma_q^2}{\delta_K^2}\right) \right) \quad (\text{I.76})$$

În urma prelucrării semnalului captat, prin aceste metode, se constata o îmbunătățire a raportului semnal/zgomot dar și prezența unor “tonuri muzicale”. Metoda varianței minime este mai puțin sensibilă la alegerea numărului de sinusoides comparativ cu metoda celor mai mici pătrate.

#### I.4.2. Metode bazate pe estimarea optimală

McAulay și Malpass [MAC80] au propus o metodă bazată pe estimarea optimală în sensul EMMP (Erorea Minimă Medie Patratică). Această metodă este bazată pe:

- modelarea semnalului vocal printr-o sumă de sinusoides de amplitudini  $A(\omega)$  și faze  $\theta(\omega)$
- zgomotul este modelat printr-o variabilă aleatoare distribuită gaussian  $B_w(\omega)$  :

$$Y_w(\omega) = A(\omega)e^{j\theta(\omega)} + B_w(\omega) \quad (\text{I.77})$$

Amplitudinea  $A(\omega)$  se estimează prin căutarea valorii amplitudinii corespunzătoare maximului probabilității a posteriori considerând faza sinusoides o variabilă aleatoare distribuită uniform :

$$\hat{A}(\omega) = |\hat{S}_w(\omega)| = \frac{1}{2} \left[ |Y_w(\omega)| + \sqrt{|Y_w(\omega)|^2 - E\{B_w(\omega)^2\}} \right] \quad (\text{I.78})$$

McAulay și Malpass au considerat și cazul în care prezența semnalului vocal este incertă. Se fac două ipoteze: ipoteza  $H_1$  când semnalul vocal este prezent și ipoteza  $H_0$  când acesta este absent.

Estimata amplitudinii semnalului vocal este :

$$\hat{A}(\omega) = |\hat{S}_w(\omega)| = \frac{1}{2} \left[ |Y_w(\omega)| + \sqrt{|Y_w(\omega)|^2 - E\{B_w(\omega)^2\}} \right] p(H_1 | |Y_w(\omega)|) \quad (I.79)$$

Prin  $p(H_1 | |Y_w(\omega)|)$  s-a notat [MCA80] :

$$p(H_1 | |Y_w(\omega)|) = \frac{\exp(-RSB_{pr}(\omega)) I_0(2\sqrt{RSB_{pr}(\omega)(1+RSB_{po}(\omega))})}{1 + \exp(-RSB_{pr}(\omega)) I_0(2\sqrt{RSB_{pr}(\omega)(1+RSB_{po}(\omega))})} \quad (I.80)$$

iar prin  $RSB_{pr}(\omega)$  raportul semnal/zgomot apriori și prin  $RSB_{po}(\omega)$  raprtul semnal/zgomot aposteriori, rapoarte definite definite [AKB95] :

$$RSB_{pr} = \frac{E\{S_w(\omega)^2\}}{E\{B_w(\omega)^2\}}, \quad RSB_{po} = \frac{|Y_w(\omega)|^2}{E\{B_w(\omega)^2\}} - 1 \quad (I.81)$$

Idea de a ține cont incertitudinea prezenței semnalului vocal în semnalul captat a fost utilizată de Ephraim și Malah, care modelează componenta spectrală a semnalului vocal la frecvența  $\omega$  printr-o variabilă aleatoare distribuită gaussian și zgomotul printr-o variabilă aleatoare distribuită gaussian  $B_w(\omega)$ . Atunci transformata Fourier pe termen scurt a semnalului captat  $y(n)$  la frecvența  $\omega$  este:

$$Y_w(\omega) = S_w(\omega) + B_w(\omega) \quad (I.82)$$

Metoda caută valoarea amplitudinii corespunzătoare maximului probabilității aposteriori.

Modulul transformatei Fourier pe termen scurt a estimatului semnalului vocal este [EPH84] :

$$|\hat{S}_w(\omega)| = \frac{\sqrt{\pi}}{2} \frac{\sqrt{V_w(\omega)}}{1 + RSB_{po}(\omega)} \exp\left(-\frac{V_w(\omega)}{2}\right) \left[ (1 + V_w(\omega)) I_0\left(\frac{V_w(\omega)}{2}\right) + V_w(\omega) I_1\left(\frac{V_w(\omega)}{2}\right) \right] |X_w(\omega)| \quad (I.83)$$

unde prin  $V_w(\omega)$  am notat :

$$V_w(\omega) = \frac{RSB_{pr}(\omega)}{1 + RSB_{pr}(\omega)} (1 + RSB_{po}(\omega)) \quad (I.84)$$

Utilizând cele două ipoteze :  $H_1$  când semnalul vocal este prezent și  $H_0$  când acesta este absent relația (I.83) devine [EPH84] :

$$|\hat{S}_w(\omega)| = \frac{\sqrt{\pi}}{2} \frac{\sqrt{V_w(\omega)}}{1 + RSB_{po}(\omega)} \exp\left(-\frac{V_w(\omega)}{2}\right) \left[ (1 + V_w(\omega)) I_0\left(\frac{V_w(\omega)}{2}\right) + V_w(\omega) I_1\left(\frac{V_w(\omega)}{2}\right) \right] \frac{\Lambda_w(\omega)}{1 + \Lambda_w(\omega)} |X_w(\omega)| \quad (I.85)$$

unde prin  $\Lambda_w(\omega)$  am notat :

$$\Lambda_w(\omega) = \frac{1 - q(\omega) \exp(V_w(\omega))}{q(\omega) 1 + RSB_{pr}(\omega)} \quad (I.86)$$

iar prin  $q(\omega)$  probabilitatea absenței semnalului vocal la  $\omega$ .

## CAPITOLUL II

### **Restaurarea unui semnal vocal înecat într-un zgomot alb sau colorat utilizând filtrul Kalman**

#### **II.1. Introducere**

Scopul urmărit în acest capitol este îmbunătățirea raportului semnal pe zgomot în cazul în care se dispune doar de un singur semnal captat într-un mediu zgomotos. Zgomotul ambiant este presupus aditiv și poate fi alb sau colorat. Modelând semnalul vocal printr-un proces AR și zgomotul printr-un zgomot alb sau colorat (modelat tot printr-un proces AR) și filtrând semnalul captat cu un filtru Kalman se poate estima semnalul vocal.

În literatura de specialitate au fost propuse mai multe metode pentru îmbunătățirea raportului semnal pe zgomot utilizând filtrul Kalman [PAL87][GIB88][GIB91] și [OPP94] (I.3.3). Noi, vom propune câteva metode noi pe care le vom grupa în două clase :

În prima clasă vom considera cazul unui semnal vocal  $s(n)$ , modelabil printr-un proces AR de ordinul  $p$ , contaminat cu un zgomot alb aditiv  $b(n)$ , de medie nulă și varianță  $\sigma_b^2$ , (I.41 – I.45) și vom propune trei metode.

În cea de-a doua clasă vom considera semnal vocal  $s(n)$  contaminat cu un zgomot aditiv  $b(n)$ . Semnalul vocal și respectiv zgomotul sunt modelate prin procese AR de ordin  $p$  și respectiv  $q$ . Vom propune două metode de îmbunătățire a raportului semnal pe zgomot.

## **II.2. Eliminarea zgomotului în cazul unui semnal vocal contaminat de un zgomot alb utilizând filtrarea Kalman**

Aplicarea filtrelor Kalman necesită cunoașterea apriori a matricei de tranziție și a varianțelor zgomotului de excitație și respectiv zgomotului pe canal. Vom propune trei metode bazate pe filtrarea Kalman pentru îmbunătățirea raportului semnal/zgomot în cazul unui semnal vocal înecat într-un zgomot alb.

Primele două metode pe care le vom propune au fost dezvoltate utilizând două articole a lui R.K. Mehra [MEH70] și [MEH71]. Mehra a propus o metodă pentru estimarea matricelor de covarianță a zgomotului de excitație și a zgomotului pe canal în cazul unui sistem dinamic multidimensional. Această metodă se bazează pe proprietatea filtrului optimal Kalman de a produce o secvență de inovație de tip zgomot alb.

Metoda alternează două etape și anume în prima etapă se face estimarea matricelor, de tranziție și de covarianță, pe când în cea de-a doua etapă se filtrează cu filtrul Kalman obținut utilizând matricele estimate în etapa anterioară. Procesul iterativ se oprește în momentul obținerii unei secvențe de inovație de tip zgomot alb.

Principala dificultate întâlnită este rezolvarea sistemului liniar de ecuații scris cu scopul de a identifica matricea de covarianță a zgomotului de excitație. Este posibil ca numărul ecuațiilor liniar independente să fie inferior numărului de necunoscute din aceasta matrice. În acest caz este posibilă doar estimarea iterativă a câștigului optimal Kalman.

Față de metoda propusă de Mehra cele două metode sunt mai simple deoarece în nici o metodă propusă nu alternăm calculul câștigului cu calculul varianțelor zgomotelor cum face Mehra și deoarece ne referim la cazul particular al unui semnal autoregresiv.

Prima metodă propusă de noi [GAB96b] și [GAB97c] estimează iterativ câștigul optimal Kalman. Se propun două variante de estimare a câștigului.

Cea de-a doua metodă [GAB97b] își propune estimarea varianțelor zgomotelor de excitație și a zgomotului pe canal utilizând informațiile obținute în urma filtării, cu un câștig Kalman

inițial cunoscut, a semnalului captat. După ce au fost estimate aceste variante se estimează semnalul vocal cu filtrul Kalman obținut utilizând aceste variante.

A treia metodă propusă [GAB96d] estimează parametrii semnalului și ai zgomotului utilizând algoritmul EM (Expectation-Maximisation) după care se filtrează cu filtrul Kalman obținut prin utilizarea acestor parametrii.

## II.2.1. Metoda I

Mai întâi se estimează coeficienții AR ai semnalului vocal pornind de la estimata funcției de autocorelație a semnalului captat. Estimarea acestor coeficienți ne permite estimarea matricei de tranziție  $\Phi$ . Reprezentarea în spațiul stărilor este completă dacă se pot estima variantele zgomotului de excitație și zgomotului pe canal.

Această metodă estimează iterativ câștigul optimal Kalman. Câștigul optimal Kalman conține informații “mascate” legate de varianța zgomotului de excitație și cea a zgomotului pe canal. Se propun două variante de estimare a acestuia, una utilizând articolele lui Mehra și alta un articol al lui Carew și Bélanger [CAR73].

### II.2.1.1. Estimarea matricei de tranziție

Notăm prin  $\mathbf{H}(n)$  matricea de autocorelație a lui  $\mathbf{x}(n)$  definită prin:

$$\mathbf{H}(n) = E\{\mathbf{x}(n)\mathbf{x}^T(n)\} \quad (\text{II.1})$$

și prin  $\gamma_{yy}(k)$  funcția de autocorelație a semnalului observabil  $y(n)$  :

$$\gamma_{yy}(k) = E\{y(n)y(n-k)\} \quad (\text{II.2})$$

Deoarece zgomotul de excitație și zgomotul de canal,  $u(n)$  și  $b(m)$ , sunt necorelate putem afirma că  $\mathbf{x}(n)$  și  $v(m)$  sunt la rândul lor necorelate (pentru orice valori ale lui  $m$  și  $n$ ). Atunci putem scrie :

$$\gamma_{yy}(k) = \mathbf{H}E\{\mathbf{x}(n)\mathbf{x}^T(n-k)\}\mathbf{H}^T + E\{b(n)b(n-k)\} \quad (\text{II.3})$$

Utilizând ecuația (I.43) putem scrie vectorul de stare la momentul  $n$  în funcție de valoarea sa din urma cu  $k$  eșantioane și de cele  $k$  valori anterioare ale zgomotului de excitație :



$$\mathbf{x}(n) = \Phi^k \mathbf{x}(n-k) + \sum_{i=1}^k \Phi^{i-1} \Gamma u(n-i+1) \quad (\text{II.4})$$

Cum  $\mathbf{x}(n-k)$  și  $u(n-i+1)$  (cu  $1 \leq i \leq k$ ) sunt necorelate putem rescrie ecuația (II.3) :

$$\gamma_{yy}(k) = \mathbf{H} \mathbf{E} \{ \Phi^k \mathbf{x}(n-k) \mathbf{x}^T(n-k) \} \mathbf{H}^T + \mathbf{E} \{ b(n)b(n-k) \} \quad (\text{II.5})$$

sau :

$$\gamma_{yy}(k) = \mathbf{H} \Phi^k \mathbf{\Pi}(n-k) \mathbf{H}^T + \sigma_b^2 \delta(n-k) \quad (\text{II.6})$$

Dacă presupunem că  $\mathbf{x}(n)$  este staționar, pentru  $k > 0$  ecuația (II.6) se poate rescrie :

$$\gamma_{yy}(k) = \mathbf{H} \Phi^k \mathbf{\Pi}(n-k) \mathbf{H}^T \quad (\text{II.7})$$

Dacă rescriem ecuația (II.7) pentru  $1 \leq k \leq p$  și concatenăm într-un vector obținem :

$$\begin{bmatrix} \gamma_{yy}(1) \\ \gamma_{yy}(2) \\ \vdots \\ \gamma_{yy}(p) \end{bmatrix} = \begin{bmatrix} \mathbf{H} \Phi \\ \mathbf{H} \Phi^2 \\ \vdots \\ \mathbf{H} \Phi^p \end{bmatrix} \mathbf{\Pi} \mathbf{H}^T \quad (\text{II.8})$$

relație care poate fi rescrisă :

$$\mathbf{\Pi} \mathbf{H}^T = \begin{bmatrix} \mathbf{H} \Phi \\ \mathbf{H} \Phi^2 \\ \vdots \\ \mathbf{H} \Phi^p \end{bmatrix}^{-1} \begin{bmatrix} \gamma_{yy}(1) \\ \gamma_{yy}(2) \\ \vdots \\ \gamma_{yy}(p) \end{bmatrix} \quad (\text{II.9})$$

Conform teoremei lui Caley-Hamilton matricea de tranziție  $\Phi$  verifică ecuația caracteristică :

$$\det[\Phi - \lambda \mathbf{I}]_p = 0 \quad (\text{II.10})$$

Dezvoltând această ecuație ținând seama de (I.44) obținem:

$$\det \begin{bmatrix} -\lambda & 1 & 0 & 0 & 0 \\ 0 & -\lambda & 1 & 0 & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ 0 & 0 & 0 & \dots & -\lambda & 1 \\ a_p & a_{p-1} & a_{p-2} & & a_p & a_p - \lambda \end{bmatrix} = 0 \quad (\text{II.11})$$

Pentru a găsi o formă de calcul recursiv dezvoltăm determinantul din (II.11) după prima coloană și obținem :

$$\det[\Phi - \lambda I]_p = -\lambda \det[\Phi - \lambda I]_{p-1} + (-1)^p a_p \quad (\text{II.12})$$

relție care ne permite să scriem :

$$\lambda^p = \sum_{i=1}^p a_i \lambda^{p-i} \quad (\text{II.13})$$

Conform teoremei lui Caley-Hamilton putem înlocui pe  $\lambda$  prin  $\Phi$  și obținem :

$$\Phi^p = \sum_{i=1}^p a_i \Phi^{p-i} \quad (\text{II.14})$$

Dacă înmulțim relația (II.14) la stânga cu  $H\Phi^k$ , la dreapta cu  $\Pi H^T$  și ținem cont de relația (II.6) obținem :

$$\gamma_{yy}(p+k) = \begin{bmatrix} \gamma_{yy}(k) & \gamma_{yy}(k+1) & \cdots & \gamma_{yy}(p+k-1) \end{bmatrix} \begin{bmatrix} a_p \\ a_{p-1} \\ \vdots \\ a_1 \end{bmatrix} \quad (\text{II.15})$$

Remarcăm faptul că ecuația (II.15) poate fi obținută și prin utilizarea ecuațiilor Yule-Walker modificate [KAY88].

Scriind (II.15) pentru  $1 \leq k \leq p$  se obține :

$$\begin{bmatrix} a_p \\ \vdots \\ a_1 \end{bmatrix} = \begin{bmatrix} \gamma_{yy}(1) & \cdots & \gamma_{yy}(p) \\ \vdots & \ddots & \vdots \\ \gamma_{yy}(p) & \cdots & \gamma_{yy}(2p-1) \end{bmatrix}^{-1} \begin{bmatrix} \gamma_{yy}(p+1) \\ \vdots \\ \gamma_{yy}(2p) \end{bmatrix} \quad (\text{II.16})$$

Estimarea funcției de autocorelație  $\gamma_{yy}(k)$  (cu  $1 \leq k \leq 2p$ ) se face utilizând  $N$  valori ale semnalului observabil  $y(n)$  ( $0 \leq n \leq N-1$ ) :

$$\hat{\gamma}_{yy}(k) = \frac{1}{N} \sum_{i=k}^{N-1} y(i)y(i-k) \quad (\text{II.17})$$

și atunci (II.16) se mai poate scrie :

$$\begin{bmatrix} \hat{a}_p \\ \vdots \\ \hat{a}_1 \end{bmatrix} = \begin{bmatrix} \hat{\gamma}_{yy}(1) & \cdots & \hat{\gamma}_{yy}(p) \\ \vdots & \ddots & \vdots \\ \hat{\gamma}_{yy}(p) & \cdots & \hat{\gamma}_{yy}(2p-1) \end{bmatrix}^{-1} \begin{bmatrix} \hat{\gamma}_{yy}(p+1) \\ \vdots \\ \hat{\gamma}_{yy}(2p) \end{bmatrix} \quad (\text{II.18})$$

Utilizând coeficienții AR obținuți din (II.18) estimata matricei de  $\Phi$  se poate scrie:

$$\hat{\Phi} = \begin{bmatrix} 0 & 1 & 0 \\ \vdots & \vdots & \vdots \\ 0 & 0 & 1 \\ \hat{a}_p & \hat{a}_{p-1} & \cdots & \hat{a}_1 \end{bmatrix} \quad (\text{II.19})$$

### II.2.1.2. Estimarea câștigului optimal Kalman

Principalele etape în calculul acestui câștig optimal sunt :

- calculul funcției de autocorelație a secvenței de inovație,
- dezvoltarea unui procedeu iterativ de calcul al estimatului câștigului optimal
- testul de optimabilitate care testează dacă secvența de inovație este sau nu albă.

#### II.2.1.2.1. Calculul funcției de autocorelație a secvenței de inovație

Vom nota prin  $\tilde{\mathbf{x}}(n/n-1)$  eroarea de predicție a priori :

$$\tilde{\mathbf{x}}(n/n-1) = \mathbf{x}(n) - \hat{\mathbf{x}}(n/n-1) \quad (\text{II.20})$$

iar prin  $\mathbf{P}(n/n-1)$  matricea autocorelație asociată :

$$\mathbf{P}(n/n-1) = E\{\tilde{\mathbf{x}}(n/n-1)\tilde{\mathbf{x}}^T(n/n-1)\} \quad (\text{II.21})$$

Câștigul Kalman la momentul  $n$  se poate calcula utilizând [NAJ88] :

$$\mathbf{K}(n) = \mathbf{P}(n/n-1)\mathbf{H}^T (\mathbf{H}\mathbf{P}(n/n-1)\mathbf{H}^T + \sigma_b^2)^{-1} \quad (\text{II.22})$$

Dacă înlocuim, în formula de calcul a inovației, observația prin suma dintre semnal și zgomotul pe canal și punem în evidență eroarea de predicție obținem :

$$e(n) = \mathbf{H}\tilde{\mathbf{x}}(n/n-1) + b(n) \quad (\text{II.23})$$

Vom nota prin  $\gamma_{ee}(k)$  funcția de autocorelație a secvenței de inovație  $e(n)$  :

$$\gamma_{ee}(k) = E\{e(n)e(n-k)\} \quad (\text{II.24})$$

relație care, ținând seama de (II.23), devine :

$$\begin{aligned} \gamma_{ee}(k) = & \mathbf{H}E\{\tilde{\mathbf{x}}(n/n-1)\tilde{\mathbf{x}}^T(n-k/n-k-1)\}\mathbf{H}^T + E\{b(n)b(n-k)\} + \\ & \mathbf{H}E\{\tilde{\mathbf{x}}(n/n-1)b(n-k)\} + \mathbf{H}E\{\tilde{\mathbf{x}}(n-k/n-k-1)b(n)\} \end{aligned} \quad (\text{II.25})$$

Vom scrie recursiv relația de calcul a lui  $\tilde{\mathbf{x}}(n/n-1)$  :

$$\begin{aligned} \tilde{\mathbf{x}}(n/n-1) = & \left\{ \prod_{i=1}^k \Phi(\mathbf{I} - \mathbf{K}(n-i)\mathbf{H}) \right\} \tilde{\mathbf{x}}(n-k/n-k-1) + \sum_{i=1}^k \left\{ \prod_{j=1}^{i-1} \Phi(\mathbf{I} - \mathbf{K}(n-j)\mathbf{H}) \right\} \Gamma u(n-i+1) \\ & - \sum_{i=1}^k \left\{ \prod_{j=1}^{i-1} \Phi(\mathbf{I} - \mathbf{K}(n-j)\mathbf{H}) \right\} \Phi \mathbf{K}(n-i) b(n-i) \end{aligned} \quad (\text{II.26})$$

Pentru  $1 \leq i \leq k$ :

$$E\{u(n-i+1)\tilde{\mathbf{x}}^T(n-k/n-k-1)\} = 0 \quad (\text{II.27})$$

$$E\{b(n-i)\tilde{\mathbf{x}}^T(n-k/n-k-1)\} = 0 \quad (\text{II.28})$$

Primul termen din (II.25) se poate scrie:

$$\mathbf{H}E\{\tilde{\mathbf{x}}(n/n-1)\tilde{\mathbf{x}}^T(n-k/n-k-1)\}\mathbf{H}^T = \mathbf{H} \left\{ \prod_{i=1}^k \Phi(\mathbf{I} - \mathbf{K}(n-i)\mathbf{H}) \right\} \mathbf{P}(n-k/n-k-1)\mathbf{H}^T \quad (\text{II.29})$$

Cel de-al treilea termen din (II.25) se poate scrie:

$$\mathbf{H}E\{\tilde{\mathbf{x}}(n/n-1)b(n-k)\} = \mathbf{H} \left\{ \prod_{i=1}^{k-1} \Phi(\mathbf{I} - \mathbf{K}(n-i)\mathbf{H}) \right\} \Phi \mathbf{K}(n-k)\sigma_b^2 \quad (\text{II.30})$$

Ultimul termen din (II.25) este nul.

Cel de-al doilea termen din (II.25) este:

$$E\{b(n)b(n-k)\} = \sigma_b^2 \delta(n-k) \quad (\text{II.31})$$

Deci pentru  $k > 0$  relația (II.25) se mai poate scrie:

$$\begin{aligned} \gamma_{ee}(k) = & \mathbf{H} \left\{ \prod_{i=1}^{k-1} \Phi(\mathbf{I} - \mathbf{K}(n-i)\mathbf{H}) \right\} \Phi \\ & [\mathbf{P}(n-k/n-k-1)\mathbf{H}^T - \mathbf{K}(n-k)(\mathbf{H}\mathbf{P}(n-k/n-k-1)\mathbf{H}^T + \sigma_b^2)] \end{aligned} \quad (\text{II.32})$$

Se poate observa că în cazul în care câștigul este optimal, adică acesta se poate calcula cu relația (II.22), acest termen este nul.

Pentru  $k = 0$ :

$$\gamma_{ee}(0) = \mathbf{H}\mathbf{P}(n/n-1)\mathbf{H}^T + \sigma_b^2 \quad (\text{II.33})$$

### II.2.1.2.2 Obținerea iterativă a câștigului Kalman

Pentru  $n$  tinzând la infinit filtrul ajunge în regim permanent deci câștigul și matricea de autocorelație a erorii de predicție rămân constante :

$$\lim_{n \rightarrow \infty} \mathbf{K}(n) = \mathbf{K} \text{ și } \lim_{n \rightarrow \infty} \mathbf{P}(n/n-1) = \mathbf{P} \quad (\text{II.34})$$

atunci relația (II.32) de calcul a funcției de autocorelație a secvenței de inovație se poate rescrie :

$$\gamma_{ee}(k) = \mathbf{H}(\Phi(\mathbf{I} - \mathbf{KH}))^{k-1} \Phi [\mathbf{PH}^T - \mathbf{K}\gamma_{ee}(0)] \quad (\text{II.35})$$

Dacă scriem această relație pentru valori ale lui  $k$  cuprinse între  $1 \leq k \leq p$  și le dispunem sub forma unui vector obținem :

$$\begin{bmatrix} \gamma_{ee}(1) \\ \gamma_{ee}(2) \\ \vdots \\ \gamma_{ee}(p) \end{bmatrix} = \begin{bmatrix} \mathbf{H}\Phi \\ \mathbf{H}(\Phi(\mathbf{I} - \mathbf{KH}))^1 \Phi \\ \vdots \\ \mathbf{H}(\Phi(\mathbf{I} - \mathbf{KH}))^{p-1} \Phi \end{bmatrix} [\mathbf{PH}^T - \mathbf{K}\gamma_{ee}(0)] \quad (\text{II.36})$$

relație care se mai poate scrie :

$$\mathbf{K} = \mathbf{PH}^T / \gamma_{ee}(0) - \begin{bmatrix} \mathbf{H}\Phi \\ \mathbf{H}(\Phi(\mathbf{I} - \mathbf{KH}))^1 \Phi \\ \vdots \\ \mathbf{H}(\Phi(\mathbf{I} - \mathbf{KH}))^{p-1} \Phi \end{bmatrix}^{-1} \begin{bmatrix} \gamma_{ee}(1) \\ \gamma_{ee}(2) \\ \vdots \\ \gamma_{ee}(p) \end{bmatrix} / \gamma_{ee}(0) \quad (\text{II.37})$$

În cazul optimal al doilea termen din (II.37) este nul. În cazul suboptimal el este nenul și vom utiliza o procedură iterativă de calcul a lui  $\mathbf{K}$  utilizând relațiile (II.22), (II.33), (II.34) și (II.37) [MEH70] :

$$\mathbf{K}(i) = \mathbf{K}(i-1) + \begin{bmatrix} \mathbf{H}\Phi \\ \mathbf{H}(\Phi(\mathbf{I} - \mathbf{KH}))^1 \Phi \\ \vdots \\ \mathbf{H}(\Phi(\mathbf{I} - \mathbf{KH}))^{p-1} \Phi \end{bmatrix}^{-1} \begin{bmatrix} \gamma_{ee}(1) \\ \gamma_{ee}(2) \\ \vdots \\ \gamma_{ee}(p) \end{bmatrix} / \gamma_{ee}(0) \quad (\text{II.38})$$

Estimarea funcției de autocorelație a secvenței de inovație se face utilizând valorile secvenței de inovație  $e(n)$  (cu  $0 \leq n \leq N-1$ ):

$$\hat{\gamma}_{ee}(k) = \frac{1}{N} \sum_{i=k}^{N-1} e(i)e(i-k) \quad (\text{II.39})$$

iar relația de calcul a estimatului câștigului optimal se rescrie prin:

$$\hat{K}(i) = \hat{K}(i-1) + \begin{bmatrix} H\hat{\Phi} \\ H\hat{\Phi}[I - \hat{K}(i-1)H]\hat{\Phi} \\ \vdots \\ H[\hat{\Phi}[I - \hat{K}(i-1)H]]^{p-1}\hat{\Phi} \end{bmatrix}^{-1} \begin{bmatrix} \hat{\gamma}_{ee}(1) \\ \hat{\gamma}_{ee}(2) \\ \vdots \\ \hat{\gamma}_{ee}(p) \end{bmatrix} / \hat{\gamma}_{ee}(0) \quad (\text{II.40})$$

### II.2.1.2.3 Testul de optimalitate

Pentru a testa dacă câștigul Kalman este optimal, Mehra a sugerat utilizarea unui test statistic. Se va testa dacă secvența de inovație este albă sau nu. Procedura de calcul iterativ a câștigului se repetă până când secvența de inovație obținută devine albă și gaussiană. Atunci trebuie ca :

$$|\hat{\gamma}_{ee}(k)| \leq 1.95 \hat{\gamma}_{ee}(0) / \sqrt{N} \quad \text{pentru } k > 0 \quad (\text{II.41})$$

În cazul în care se va utiliza estimata matricei de tranziție condiția de albire a secvenței de inovație este necesară dar nu suficientă [BOO72]. Martin propune o condiție suplimentară și anume de a obține o secvență de inovație de medie nulă [MAR74] :

$$E\{\hat{\gamma}_{ee}(k)\} = 0 \quad (\text{II.42})$$

În locul testului (II.41) vom utiliza testul următor, propus de către P. Stoica [STO77] și având un grad de încredere superior :

$$\sum_{i=1}^k \hat{\gamma}_{ee}^2(i) \leq (k+1.65\sqrt{2k}) \hat{\gamma}_{ee}^2(0)/N \quad (\text{II.43})$$

### II.2.1.3 Etapele de calcul și algoritmul corespunzător metodei Ia

Estimarea matricei de tranziție și a câștigului optimal se face conform celor discutate în paragrafele II.2.1.1 și II.2.1.2. Semnalul de vorbire se va estima prin :

$$\hat{s}(n) = H\hat{x}(n/n) = H\hat{\Phi}\hat{x}(n/n-1) \quad (\text{II.44})$$

Lista etapelor de calcul este prezentată în figura II.1.

## ALGORITMUL METODEI Ia

### DISPONIBIL LA MOMENTUL INIȚIAL

- eșantioanele  $y(n)$  cu  $0 \leq n \leq N-1$
- ordinul  $p$
- valoarea inițială a câștigului  $\hat{K}(0)$

### I. ESTIMAREA MATRICEI DE TRANZIȚIE

$$\hat{\gamma}_{yy}(k) = \frac{1}{N} \sum_{i=k}^{N-1} y(i)y(i-k) \quad \text{pentru } 1 \leq k \leq 2p$$

$$\begin{bmatrix} \hat{a}_p \\ \vdots \\ \hat{a}_1 \end{bmatrix} = \begin{bmatrix} \hat{\gamma}_{yy}(1) & & \hat{\gamma}_{yy}(p) \\ & \ddots & \vdots \\ \hat{\gamma}_{yy}(p) & \cdots & \hat{\gamma}_{yy}(2p-1) \end{bmatrix}^{-1} \begin{bmatrix} \hat{\gamma}_{yy}(p+1) \\ \vdots \\ \hat{\gamma}_{yy}(2p) \end{bmatrix}$$

$$\hat{\Phi} = \begin{bmatrix} 0 & 1 & & 0 \\ \vdots & \vdots & & \vdots \\ 0 & 0 & & 1 \\ \hat{a}_p & \hat{a}_{p-1} & \cdots & \hat{a}_1 \end{bmatrix}$$

### II. FILTRARE KALMAN

Inițializare :

$$\hat{x}(0/-1) = 0$$

filtrare (pentru  $0 \leq n \leq N-1$ )

$$e(n) = y(n) - H\hat{x}(n/n-1)$$

$$\hat{x}(n+1/n) = \hat{\Phi}\hat{x}(n/n-1) + \hat{\Phi}\hat{K}(i)e(n)$$

### III. ESTIMAREA CÂȘTIGULUI OPTIMAL

$$\hat{\gamma}_{ee}(k) = \frac{1}{N} \sum_{i=k}^{N-1} e(i)e(i-k) \quad \text{pentru } 0 \leq k \leq p$$

$$\text{Dacă } \sum_{i=1}^p \hat{\gamma}_{ee}^2(i) \geq (p+1.65\sqrt{2p})\hat{\gamma}_{ee}^2(0)/N$$

$$\hat{K}(i) = \hat{K}(i-1) + \begin{bmatrix} H\hat{\Phi} \\ H\hat{\Phi}[I - \hat{K}(i-1)H]\hat{\Phi} \\ \vdots \\ H[\hat{\Phi}[I - \hat{K}(i-1)H]]^{p-1}\hat{\Phi} \end{bmatrix}^{-1} \begin{bmatrix} \hat{y}_{ee}(1) \\ \hat{y}_{ee}(2) \\ \vdots \\ \hat{y}_{ee}(p) \end{bmatrix} / \hat{y}_{ee}(0)$$

Întoarcere la II.

#### IV. ESTIMAREA SEMNALULUI VOCAL

$$\hat{s}(n) = H\hat{x}(n/n) = H\hat{\Phi}\hat{x}(n/n-1) \text{ pentru } 0 \leq n \leq N-1$$

Fig. II.1 : Algoritmul metodei Ia

#### II.2.1.4. Alternativă de estimare a câștigului optimal

O alternativă la metoda lui Mehra [MEH70][MEH71] pentru estimarea câștigului optimal Kalman a fost propusă de Carew et Bellanger [CAR73]. Aceasta este bazată pe scrierea relației de calcul a matricei de autocorrelație, a diferenței erorilor de predicție a vectorului de stare obținute cu un câștig suboptimal și respectiv optimal, în funcție de câștigul suboptimal utilizat și de câștigul optimal. Câștigul optimal se estimează rezolvând iterativ această relație. Vom nota cu \* mărimile corespunzătoare acestui câștig suboptimal. Notăm prin  $\mathbf{x}^*(n/n-1)$  estimatul lui  $\mathbf{x}(n)$  obținut cu câștigul suboptimal  $\mathbf{K}^*$  și prin  $\hat{\mathbf{x}}(n/n-1)$  estimatul optimal al lui  $\mathbf{x}(n)$  obținut cu câștigul optimal  $\mathbf{K}$ .

Definim matricea de autocorelație a diferenței estimațiilor vectorului de stare obținuți cu câștig optimal și respectiv suboptimal  $\mathbf{P}^*(n/n-1)$  :

$$\mathbf{P}^*(n/n-1) = E\{(\hat{\mathbf{x}}(n/n-1) - \mathbf{x}^*(n/n-1))(\hat{\mathbf{x}}(n/n-1) - \mathbf{x}^*(n/n-1))^T\} \quad (\text{II.45})$$

Dacă filtrarea Kalman s-a efectuat cu câștigul suboptimal  $\mathbf{K}^*$  și cu matricea de tranziție  $\Phi$  atunci ecuația de filtrare este :

$$\mathbf{x}^*(n+1/n) = \Phi\mathbf{x}^*(n/n-1) + \Phi\mathbf{K}^*(y(n) - H\mathbf{x}^*(n/n-1)) \quad (\text{II.46})$$

Relația de calcul recursiv, a diferenței dintre estimații vectorului de stare  $\mathbf{x}(n)$  obținuți în cazul optimal și suboptimal, este :



$$\begin{aligned}\hat{x}(n/n-1) - x^*(n/n-1) &= \Phi(I - K^*H)(\hat{x}(n-1/n-2) - x^*(n-1/n-2)) \\ &+ \Phi(K - K^*)e(n-1)\end{aligned}\quad (\text{II.47})$$

iar (II.45) devine :

$$P^*(n/n-1) = \Phi(I - K^*H)P^*(n-1/n-2)(I - K^*H)^T \Phi^T + \gamma_{ee}(0)(K - K^*)(K - K^*)^T \quad (\text{II.48})$$

relație în care prin  $\gamma_{ee}(0)$  am notat funcția de autocorelație a secvenței de inovație, obținută cu câștigul optimal  $K$ , în zero.

#### II.2.1.4.1 Calculul funcției de autocorelație a lui $e^*(n)$

Fie  $e^*(n)$  secvența de inovație obținută cu  $K^*$  :

$$e^*(n) = y(n) - Hx^*(n/n-1) \quad (\text{II.49})$$

și  $\gamma_{ee}^*(k)$  funcția de autocorelație a lui  $e^*(n)$  :

$$\gamma_{ee}^*(k) = E\{e^*(n)e^*(n-k)\} \quad (\text{II.50})$$

Vom rescrie inovația obținută cu un câștig suboptimal  $e^*(n)$  în funcție de cea obținută cu câștigul optimal  $e(n)$  :

$$e^*(n) = e(n) + H(\hat{x}(n/n-1) - x^*(n/n-1)) \quad (\text{II.51})$$

Ținând seama de relația (II.47) vom scrie relația de recurență a acestei secvențe :

$$e^*(n) = H\Phi(I - K^*H)(\hat{x}(n-1/n-2) - x^*(n-1/n-2)) + e(n) + H\Phi(K - K^*)e(n-1) \quad (\text{II.52})$$

relație care o vom generaliza :

$$\begin{aligned}e^*(n) &= H(\Phi(I - K^*H))^k(\hat{x}(n-k/n-k-1) - x^*(n-k/n-k-1)) + e(n) + \\ &\sum_{i=1}^k H(\Phi(I - K^*H))^{i-1} \Phi(K - K^*)e(n-i)\end{aligned}\quad (\text{II.53})$$

Pentru  $e^*(n-k)$  (II.51) se poate scrie :

$$e^*(n-k) = e(n-k) + H(\hat{x}(n-k/n-k-1) - x^*(n-k/n-k-1)) \quad (\text{II.54})$$

Secvența  $e(n)$  este o secvență albă și ortogonală atât pe  $\hat{x}(n-k/n-k-1)$  cât și pe  $x^*(n-k/n-k-1)$  [KAI68]. Utilizând (II.50)(II.53) și (II.54)  $\gamma_{ee}^*(k)$  se poate exprima prin :

$$\gamma_{ee}^*(k) = H[\Phi(I - K^*H)]^{k-1}[\Phi(I - K^*H)P^*(n-k/n-k-1)H^T + \Phi(K - K^*)\gamma_{ee}(0)] \quad (II.55)$$

Pentru  $k = 0$   $\gamma_{ee}^*(0)$  este :

$$\gamma_{ee}^*(0) = HP^*(n/n-1)H^T + \gamma_{ee}(0) \quad (II.56)$$

#### II.2.1.4.2. Procedura iterativă de estimare a câștigului optimal Kalman

Utilizând un câștig suboptimal, când  $n$  tîde către infinit, se ajunge în regim permanent :

$$\lim_{n \rightarrow \infty} P^*(n/n-1) = P^* \quad (II.57)$$

În acest caz relațiile (II.48)(II.55) și (II.56) se pot rescrie :

$$P^* = \Phi(I - K^*H)P^*(I - K^*H)^T \Phi^T + \gamma_{ee}(0)(K - K^*)(K - K^*)^T \quad (II.58)$$

$$\gamma_{ee}(0) = \gamma_{ee}^*(0) - HP^*H^T \quad (II.59)$$

$$\gamma_{ee}^*(k) = H[\Phi(I - K^*H)]^{k-1} \Phi[(I - K^*H)P^*H^T + (K - K^*)\gamma_{ee}(0)] \quad (II.60)$$

Scriind secvența de inovație obținută cu un câștig suboptimal pentru  $k$  luând valorile  $1 \leq k \leq p$  și ordonând aceste valori într-un vector obținem :

$$\begin{bmatrix} \gamma_{ee}^*(1) \\ \gamma_{ee}^*(2) \\ \vdots \\ \gamma_{ee}^*(p) \end{bmatrix} = \begin{bmatrix} H\Phi \\ H(\Phi(I - K^*H))^1\Phi \\ \vdots \\ H(\Phi(I - K^*H))^{p-1}\Phi \end{bmatrix} [(I - K^*H)P^*H^T + (K - K^*)\gamma_{ee}(0)] \quad (II.61)$$

relație care se mai poate rescrie :

$$K = K^* - (I - K^*H)P^*H^T / \gamma_{ee}(0) + \begin{bmatrix} H\Phi \\ H(\Phi(I - K^*H))^1\Phi \\ \vdots \\ H(\Phi(I - K^*H))^{p-1}\Phi \end{bmatrix}^{-1} \begin{bmatrix} \gamma_{ee}^*(1) \\ \gamma_{ee}^*(2) \\ \vdots \\ \gamma_{ee}^*(p) \end{bmatrix} / \gamma_{ee}(0) \quad (II.62)$$

Metoda propusă de Carew și Bélanger [CAR73] propune rezolvarea iterativă a ecuațiilor (II.58)(II.59) și (II.62) în raport cu  $K, P^*$  și  $\gamma_{ee}(0)$ . Pentru aceasta vom proceda în felul următor :

- fie  $P^*(0)$  valoarea inițială a lui  $P^*$

- calculăm varianța secvenței de inovație și câștigul optimal cu relațiile (II.59) și (II.62)
- cu noile valori obținute facem reactualizarea lui  $P^*$

Matematic pentru iterația  $i$  se poate scrie:

$$\gamma_{eei}(0) = \gamma_{ee}^*(0) - HP_i^*H^T \quad (II.63)$$

$$K_i = K^* - (I - K^*H)P_i^*H^T / \gamma_{eei}(0) + \begin{bmatrix} H\Phi \\ H(\Phi(I - K^*H))^1\Phi \\ \vdots \\ H(\Phi(I - K^*H))^{p-1}\Phi \end{bmatrix}^{-1} \begin{bmatrix} \gamma_{ee}^*(1) \\ \gamma_{ee}^*(2) \\ \vdots \\ \gamma_{ee}^*(p) \end{bmatrix} / \gamma_{eei}(0) \quad (II.64)$$

$$P_{i+1}^* = \Phi(I - K^*H)P_i^*(I - K^*H)^T\Phi^T + \gamma_{eei}(0)(K_i - K^*)(K_i - K^*)^T \quad (II.65)$$

Estimarea secvenței  $\gamma_{ee}^*(k)$  se face utilizând valorile lui  $e^*(n)$  (cu  $0 \leq n \leq N-1$ ):

$$\hat{\gamma}_{ee}^*(k) = \frac{1}{N} \sum_{i=k}^{N-1} e^*(i)e^*(i-k) \quad (II.66)$$

Atunci la iterația  $i$  avem :

$$\gamma_{eei}(0) = \hat{\gamma}_{ee}^*(0) - HP_i^*H^T \quad (II.67)$$

$$K_i = K^* - (I - K^*H)P_i^*H^T / \gamma_i(0) + \begin{bmatrix} H\Phi \\ H(\Phi(I - K^*H))^1\Phi \\ \vdots \\ H(\Phi(I - K^*H))^{p-1}\Phi \end{bmatrix}^{-1} \begin{bmatrix} \hat{\gamma}^*(1) \\ \hat{\gamma}^*(2) \\ \vdots \\ \hat{\gamma}^*(p) \end{bmatrix} / \gamma_i(0) \quad (II.68)$$

$$P_{i+1}^* = \Phi(I - K^*H)P_i^*(I - K^*H)^T\Phi^T + \gamma_i(0)(K_i - K^*)(K_i - K^*)^T \quad (II.69)$$

### II.2.1.5. Etapele de calcul și algoritmul corespunzator metodei Ib

Estimarea matricei de tranziție și a câștigului optimal se face conform celor discutate în paragrafele II.2.1.1 și II.2.1.4.

## ALGORITMUL METODEI IB

### DISPONIBIL LA MOMENTUL INIȚIAL

- eșantioanele  $y(n)$  cu  $0 \leq n \leq N-1$
- ordinul  $p$
- valoarea inițială a câștigului  $K^*$

### I. ESTIMAREA MATRICEI DE TRANZIȚIE

$$\hat{\gamma}_{yy}(k) = \frac{1}{N} \sum_{i=k}^{N-1} y(i)y(i-k) \quad \text{pentru } 1 \leq k \leq 2p$$

$$\begin{bmatrix} \hat{a}_p \\ \vdots \\ \hat{a}_1 \end{bmatrix} = \begin{bmatrix} \hat{\gamma}_{yy}(1) & & \hat{\gamma}_{yy}(p) \\ \vdots & \ddots & \vdots \\ \hat{\gamma}_{yy}(p) & \cdots & \hat{\gamma}_{yy}(2p-1) \end{bmatrix}^{-1} \begin{bmatrix} \hat{\gamma}_{yy}(p+1) \\ \vdots \\ \hat{\gamma}_{yy}(2p) \end{bmatrix} \quad \hat{\Phi} = \begin{bmatrix} 0 & 1 & 0 \\ \vdots & \vdots & \vdots \\ 0 & 0 & 1 \\ \hat{a}_p & \hat{a}_{p-1} & \hat{a}_1 \end{bmatrix}$$

### II. FILTRARE KALMAN UTILIZÂND CÂȘTIGUL $K^*$

inițializare :

$$\mathbf{x}^*(0/-1) = 0$$

filtrare (pentru  $0 \leq n \leq N-1$ )

$$\mathbf{e}^*(n) = y(n) - \mathbf{H}\mathbf{x}^*(n/n-1)$$

$$\mathbf{x}^*(n+1/n) = \hat{\Phi}\mathbf{x}^*(n/n-1) + \hat{\Phi}K^*(y(n) - \mathbf{H}\mathbf{x}^*(n/n-1))$$

### III. ESTIMAREA CÂȘTIGULUI OPTIMAL

$$\hat{\gamma}_{ee}^*(k) = \frac{1}{N} \sum_{i=k}^{N-1} e^*(i)e^*(i-k) \quad \text{pentru } 0 \leq k \leq p$$

$$\text{Dacă } \sum_{i=1}^p \hat{\gamma}_{ee}^{*2}(i) \geq (p+1.65\sqrt{2p})\hat{\gamma}_{ee}^{*2}(0)/N$$

$$\gamma_{eei}(0) = \hat{\gamma}_{ee}^*(0) - \mathbf{H}\mathbf{P}_i^*\mathbf{H}^T$$

$$K_i = K^* - (I - K^* H) P_i^* H^T / \gamma_{ee_i}(0) + \begin{bmatrix} H \hat{\Phi} \\ H(\hat{\Phi}(I - K^* H))^1 \hat{\Phi} \\ \vdots \\ H(\hat{\Phi}(I - K^* H))^{p-1} \hat{\Phi} \end{bmatrix}^{-1} \begin{bmatrix} \hat{\gamma}_{ee}^*(1) \\ \hat{\gamma}_{ee}^*(2) \\ \vdots \\ \hat{\gamma}_{ee}^*(p) \end{bmatrix} / \gamma_{ee_i}(0)$$

$$P_{i+1}^* = \hat{\Phi}(I - K^* H) P_i^* (I - K^* H)^T \hat{\Phi}^T + \gamma_{ee_i}(0) (K_i - K^*) (K_i - K^*)^T$$

$$\hat{K}_{opt} = K_i$$

Întoarcere la II.

#### IV. FILTRARE KALMAN

inițializare :

$$\hat{x}(0/-1) = 0$$

filtrare (pentru  $0 \leq n \leq N-1$ )

$$e(n) = y(n) - H\hat{x}(n/n-1)$$

$$\hat{x}(n+1/n) = \hat{\Phi}\hat{x}(n/n-1) + \hat{\Phi}\hat{K}_{opt}e(n)$$

#### V. ESTIMAREA SEMNALULUI VOCAL

$$\hat{s}(n) = H\hat{x}(n/n) = H\hat{\Phi}\hat{x}(n/n-1) \text{ pentru } 0 \leq n \leq N-1$$

Fig. II.2 : Algoritmul metodei Ib

### II.2.2. Metoda II

Această metodă își propune estimarea varianței zgomotului de excitație și a varianței zgomotului pe canal pentru ca apoi să putem utiliza filtrarea Kalman standard. Estimarea acestor varianțe se face utilizând proprietățile secvenței de inovație obținute în urma filtrării cu un câștig suboptimal.

#### II.2.2.1 Estimarea varianței zgomotului pe canal

Se filtrează semnalul  $y(n)$  utilizând câștigul suboptimal  $K$  folosind relațiile corespunzătoare etapei II din algoritmul metodei Ia. Vom utiliza relația (II.36) :

$$PH^T = K\gamma_{ee}(0) + \begin{bmatrix} H\Phi \\ H(\Phi(I - KH))^1\Phi \\ \vdots \\ H(\Phi(I - KH))^{p-1}\Phi \end{bmatrix}^{-1} \begin{bmatrix} \gamma_{ee}(1) \\ \gamma_{ee}(2) \\ \vdots \\ \gamma_{ee}(p) \end{bmatrix} \quad (II.70)$$

Utilizând relația (II.33) calculul varianței zgomotului pe canal se face conform ecuației :

$$\sigma_b^2 = \gamma_{ee}(0) - HPH^T \quad (II.71)$$

Relațiile (II.70) și (II.71) se vor rescrie înlocuind valorile matricei de tranziție și a funcției de autocorelație a secvenței de inovație prin estimatele lor :

$$\hat{PH}^T = K\hat{\gamma}_{ee}(0) + \begin{bmatrix} H\hat{\Phi} \\ H(\hat{\Phi}(I - KH))^1\hat{\Phi} \\ \vdots \\ H(\hat{\Phi}(I - KH))^{p-1}\hat{\Phi} \end{bmatrix}^{-1} \begin{bmatrix} \hat{\gamma}_{ee}(1) \\ \hat{\gamma}_{ee}(2) \\ \vdots \\ \hat{\gamma}_{ee}(p) \end{bmatrix} \quad (II.72)$$

și

$$\hat{\sigma}_b^2 = \hat{\gamma}(0) - H\hat{P}\hat{H}^T \quad (II.73)$$

### II.2.2.2 Estimarea varianței zgomotului de excitație al modelului AR

Vom calcula recursiv matricea de autocorelație a erorii de predicție apriori :

$$P(n/n-1) = \Phi(I - K(n-1)H)P(n-1/n-2)(I - K(n-1)H)^T\Phi^T + \Phi K(n-1)K^T(n-1)\Phi^T\sigma_b^2 + \Gamma\Gamma^T\sigma_u^2 \quad (II.74)$$

În regim staționar  $\lim_{n \rightarrow \infty} P(n/n-1) = P$  și  $\lim_{n \rightarrow \infty} K(n-1) = K$  și atunci (II.74) se rescrie [MEH70] :

$$P = \Phi(I - KH)P(I - KH)^T\Phi^T + \Phi KK^T\Phi^T\sigma_b^2 + \Gamma\Gamma^T\sigma_u^2 \quad (II.75)$$

sau :

$$P = \Phi P \Phi^T + \Gamma\Gamma^T\sigma_u^2 + \Omega \quad (II.76)$$

relație în care prin  $\Omega$  am notat :

$$\Omega = \Phi[KK^T\gamma_{ee}(0) - KHP - PH^TK] \quad (II.77)$$

Dacă se scriu  $k$  recurențe folosind (II.76) înlocuind în membrul drept valoarea matricei  $P$  prin întreg membrul drept se obține [MEH70] :

$$P = \Phi^k P (\Phi^k)^T + \sum_{i=0}^{k-1} \Phi^i \Gamma \Gamma^T (\Phi^i)^T \sigma_u^2 + \sum_{i=0}^{k-1} \Phi^i \Omega (\Phi^i)^T \quad (\text{II.78})$$

Vom înmulți relația (II.78) la stânga cu  $H$  și la dreapta cu  $(\Phi^k)^T H^T$  cu scop de a pune în evidență termeni de tipul  $PH^T$  sau transpusul acestuia  $HP^T$  :

$$HP(\Phi^k)^T H^T = H\Phi^k PH^T + \sum_{i=0}^{k-1} H\Phi^i \Gamma \Gamma^T (\Phi^{i-k})^T H^T \sigma_u^2 + \sum_{i=0}^{k-1} H\Phi^i \Omega (\Phi^{i-k})^T H^T \quad (\text{II.79})$$

Ținând cont că matricea  $P$  este simetrică varianța zgomotului de excitație  $u(n)$  se poate calcula prin :

$$\sigma_u^2 = \frac{(\Phi^k)^T H^T H \Phi^k - H\Phi^k PH^T - \sum_{i=0}^{k-1} H\Phi^i \Omega (\Phi^{i-k})^T H^T}{\sum_{i=0}^{k-1} H\Phi^i H^T H (\Phi^{i-k})^T H^T} \quad (\text{II.80})$$

Observând forma particulară a relației (II.80) putem remarca faptul că numitorul acesteia este nul pentru valori ale lui  $k$  cuprinse în intervalul  $0 < k < p$  deoarece  $H(\Phi^k)^T H^T$  este nulă pentru aceste valori ale lui  $k$ . Ținând seama de forma particulară a lui  $H$  se remarcă faptul că valoarea lui  $H(\Phi^k)^T H^T$  este chiar elementul  $(p,p)$  al matricei  $(\Phi^k)^{-1}$ .

Tinând seama de forma particulară a lui  $\Phi$  putem remarca faptul că prin înmulțirea unei matrice oarecare  $A$  la stânga cu matricea  $\Phi$  se obține o matrice  $B = \Phi A$  care are primele  $p-1$  linii egale cu ultimele  $p-1$  linii ale matricei  $A$ . Deci primele  $p-1$  linii ale lui  $B$  se obțin prin decalarea cu o linie în sus a ultimelor  $p-1$  linii ale lui  $A$ .

Dacă în locul matricei oarecare  $A$  considerăm matricea  $\Phi$  atunci linia  $p-1$  a matricei  $\Phi$ , linie formata din  $p-1$  zerouri și un ultim element egal cu 1, se va găsi în toate matricele  $\Phi^k$  (cu  $0 < k < p$ ) în poziția  $p-k$ . Calculul elementului  $(p,p)$  al matricei  $(\Phi^k)^{-1}$  necesită calculul minorului  $(p,p)$  al matricei  $\Phi^k$  (cu  $0 < k < p$ ). Cum în matricea  $\Phi^k$  linia  $p-k$  are primele  $p-1$  elemente nule minorul va fi nul. Deoarece acest minor este nul atunci și elementul  $(p,p)$  al matricei  $(\Phi^k)^{-1}$  va fi nul pentru  $0 < k < p$ . Deci ecuația de mai sus este inutilizabilă pentru valori ale lui  $k$  inferioare lui  $p$ . Trebuie ca valoarea aleasă pentru  $k$  să fie cel puțin  $p$ . Dacă în (II.80)

înlocuim valoarea lui  $\Phi$  prin estimata acesteia, vectorul  $\mathbf{PH}^T$  prin estimatul său și alegem o valoare corespunzătoare pentru  $k$  relația devine :

$$\hat{\sigma}_u^2 = \frac{(\hat{\mathbf{P}}\mathbf{H}^T)^T (\hat{\Phi}^{-k})^T \mathbf{H}^T - \mathbf{H}\hat{\Phi}^k \hat{\mathbf{P}}\mathbf{H}^T - \sum_{i=0}^{k-1} \mathbf{H}\hat{\Phi}^i \hat{\Omega} (\hat{\Phi}^{i-k})^T \mathbf{H}^T}{\sum_{i=0}^{k-1} \mathbf{H}\hat{\Phi}^i \mathbf{H}^T \mathbf{H} (\hat{\Phi}^{i-k})^T \mathbf{H}^T} \quad (\text{II.81})$$

cu :

$$\hat{\Omega} = \hat{\Phi} [\mathbf{K}\mathbf{K}^T \hat{\gamma}_{ee}(0) - \mathbf{K}(\hat{\mathbf{P}}\mathbf{H}^T)^T - \hat{\mathbf{P}}\mathbf{H}^T \mathbf{K}] \quad (\text{II.82})$$

### II.2.2.3 Etapele de calcul și algoritmul metodei II

Estimarea matricei de tranziție se face ca în paragraful II.2.1.1. Estimarea varianței zgomotului pe canal se face ca în paragraful II.2.2.1. Varianța zgomotului de excitație se estimează conform ecuațiilor descrise în paragraful II.2.2.2. Algoritmul acestei metode este prezentat în figura II.3.

#### ALGORITMUL METODEI II

##### DISPONIBIL LA MOMENTUL INIȚIAL

- eșantioanele  $y(n)$  cu  $0 \leq n \leq N-1$
- ordinul  $p$
- valoarea inițială  $\hat{\mathbf{K}}(0)$

##### I. ESTIMAREA MATRICEI DE TRANZIȚIE

$$\hat{\gamma}_{yy}(k) = \frac{1}{N} \sum_{i=k}^{N-1} y(i)y(i-k) \quad \text{pentru } 1 \leq k \leq 2p$$

$$\begin{bmatrix} \hat{a}_p \\ \vdots \\ \hat{a}_1 \end{bmatrix} = \begin{bmatrix} \hat{\gamma}_{yy}(1) & \cdots & \hat{\gamma}_{yy}(p) \\ \vdots & \ddots & \vdots \\ \hat{\gamma}_{yy}(p) & \cdots & \hat{\gamma}_{yy}(2p-1) \end{bmatrix}^{-1} \begin{bmatrix} \hat{\gamma}_{yy}(p+1) \\ \vdots \\ \hat{\gamma}_{yy}(2p) \end{bmatrix}$$



$$\hat{\Phi} = \begin{bmatrix} 0 & 1 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & & 1 \\ \hat{a}_p & \hat{a}_{p-1} & \dots & \hat{a}_1 \end{bmatrix}$$

## II. FILTRARE KALMAN

inițializare :

$$\hat{x}(0/-1) = 0$$

filtrare (pentru  $0 \leq n \leq N-1$ ) :

$$e(n) = y(n) - H\hat{x}(n/n-1)$$

$$\hat{x}(n+1/n) = \hat{\Phi}\hat{x}(n/n-1) + \hat{\Phi}K(0)e(n)$$

## III. ESTIMAREA AUTOCORELAȚIEI INOVAȚIEI

$$\hat{\gamma}_{ee}(k) = \frac{1}{N} \sum_{i=k}^{N-1} e(i)e(i-k) \text{ pentru } 0 \leq k \leq p$$

## IV. ESTIMAREA MATRICEI $PH^T$

$$\hat{PH}^T = K\hat{\gamma}_{ee}(0) + \begin{bmatrix} H\hat{\Phi} \\ H(\hat{\Phi}(I-KH))^1\hat{\Phi} \\ \vdots \\ H(\hat{\Phi}(I-KH))^{p-1}\hat{\Phi} \end{bmatrix}^{-1} \begin{bmatrix} \hat{\gamma}_{ee}(1) \\ \hat{\gamma}_{ee}(2) \\ \vdots \\ \hat{\gamma}_{ee}(p) \end{bmatrix}$$

## V. ESTIMAREA VARIANȚEI ZGOMOTULUI PE CANAL

$$\hat{\sigma}_b^2 = \hat{\gamma}_{ee}(0) - H\hat{PH}^T$$

## VI. ESTIMAREA VARIANȚEI ZGOMOTULUI DE EXCITAȚIE

$$\hat{\Omega} = \hat{\Phi} [KK^T\hat{\gamma}_{ee}(0) - K(\hat{PH}^T)^T - \hat{PH}^T K]$$

$$\hat{\sigma}_u^2 = \frac{(\hat{PH}^T)^T(\hat{\Phi}^{-k})^T H^T - H\hat{\Phi}^k \hat{PH}^T - \sum_{i=0}^{k-1} H\hat{\Phi}^i \hat{\Omega}(\hat{\Phi}^{i-k})^T H^T}{\sum_{i=0}^{k-1} H\hat{\Phi}^i H^T H(\hat{\Phi}^{i-k})^T H^T}$$

## VII. FILTRARE KALMAN STANDARD

inițializare :

$$\hat{\mathbf{x}}(0/-1) = 0$$

$$\mathbf{P}(0/-1) = \delta \mathbf{I}$$

filtrare (pentru  $0 \leq n \leq N-1$ ):

$$\mathbf{e}(n) = y(n) - \mathbf{H}\hat{\mathbf{x}}(n/n-1)$$

$$\mathbf{K}(n) = \mathbf{P}(n/n-1)\mathbf{H}^T (\mathbf{H}\mathbf{P}(n/n-1)\mathbf{H}^T + \sigma_b^2)^{-1}$$

$$\hat{\mathbf{x}}(n/n) = \hat{\mathbf{x}}(n/n-1) + \mathbf{K}(n)\mathbf{e}(n)$$

$$\hat{\mathbf{s}}(n) = \mathbf{H}\hat{\mathbf{x}}(n/n) = \mathbf{H}\hat{\Phi}\hat{\mathbf{x}}(n/n-1)$$

$$\mathbf{P}(n/n) = (\mathbf{I} - \mathbf{K}(n)\mathbf{H})\mathbf{P}(n/n-1)$$

$$\hat{\mathbf{x}}(n+1/n) = \hat{\Phi}\hat{\mathbf{x}}(n/n)$$

$$\mathbf{P}(n+1/n) = \hat{\Phi}\mathbf{P}(n/n)\hat{\Phi}^T + \sigma_u^2$$

Fig. II.3 : Algoritmul metodei II

### II.2.4. Metoda III

Această metodă constă din două etape :

- în prima etapă se face estimarea parametrilor semnalului și zgomotului utilizând un algoritm EM (Expectation-Maximisation)
- în etapa a doua se filtrează semnalul observabil  $y(n)$  cu un filtru Kalman utilizând parametrii estimați în prima etapă.

În partea de estimare vom folosi algoritmul propus de Deriche pentru estimarea parametrilor unui semnal AR gaussian contaminat cu un zgomot alb gaussian [DER94]. Pentru aceasta vom presupune semnalul de vorbire modelat printr-un proces AR și în plus vom presupune zgomotul de excitație ca fiind un zgomot alb cu distribuție gaussiană. Această ipoteză este destul de nerealistă dar experimental se poate constata că algoritmul propus utilizând această ipoteză este aplicabil. De asemenea vom presupune că zgomotul pe canal este alb și gaussian.

### II.2.4.1. Estimarea parametrilor utilizând algoritmul EM

Vom considera  $N$  eșantioane ale semnalului observabil  $y(n)$  cu ajutorul cărora vom construi vectorul  $N$  dimensional  $\mathbf{y}_N(n)$  :

$$\mathbf{y}_N(n) = [y(n), \dots, y(n - N + 1)]^T = \mathbf{s}_N(n) + \mathbf{b}_N(n) \quad (\text{II.83})$$

Densitățile de probabilitate ale proceselor  $N$  dimensionale  $\mathbf{s}_N(n)$  și  $\mathbf{b}_N(n)$  se pot reprezenta în funcție de parametrii semnalului respectiv zgomotului pe canal [THE92] :

$$p(\mathbf{s}_N(n); a_i, \sigma_u^2) = (2\pi)^{-N/2} |\mathbf{R}_s(a_i, \sigma_u^2)|^{-1/2} \exp\{-\frac{1}{2} \mathbf{s}_N^T(n) \mathbf{R}_s^{-1}(a_i, \sigma_u^2) \mathbf{s}_N(n)\} \quad (\text{II.84})$$

$$p(\mathbf{b}_N^T(n); \sigma_b^2) = (2\pi)^{-N/2} |\sigma_b^2 \mathbf{I}|^{-1/2} \exp\{-\frac{1}{2} \mathbf{b}_N^T(n) \mathbf{b}_N(n) \sigma_b^{-2}\} \quad (\text{II.85})$$

Utilizând formula de calcul a mediei statistice condiționate,  $\mathbf{y}$  în raport cu  $\mathbf{x}$ , a două variabile aleatoare gaussiene de medii nule [THE92] :

$$\boldsymbol{\mu}_{y/x} = \mathbf{R}_{xy}^T \mathbf{R}_x^{-1} \mathbf{x} \quad (\text{II.86})$$

în calculul mediilor statistice ale vectorilor  $\mathbf{s}_N(n)$  și  $\mathbf{b}_N(n)$  condiționate de  $\mathbf{y}_N(n)$ , notate prin  $\boldsymbol{\mu}_{s/y}(a_i, \sigma_u^2, \sigma_b^2)$  și  $\boldsymbol{\mu}_{b/y}(a_i, \sigma_u^2, \sigma_b^2)$ , se obține :

$$\boldsymbol{\mu}_{s/y}(a_i, \sigma_u^2, \sigma_b^2) = \mathbf{R}_s(a_i, \sigma_u^2) \{ \mathbf{R}_s(a_i, \sigma_u^2) + \sigma_b^2 \mathbf{I} \}^{-1} \mathbf{y}_N(n) \quad (\text{II.87})$$

$$\boldsymbol{\mu}_{b/y}(a_i, \sigma_u^2, \sigma_b^2) = \sigma_b^2 \{ \mathbf{R}_s(a_i, \sigma_u^2) + \sigma_b^2 \mathbf{I} \}^{-1} \mathbf{y}_N(n) \quad (\text{II.88})$$

Utilizând formula de calcul a matricei de autocorelație condiționate,  $\mathbf{y}$  în raport cu  $\mathbf{x}$ , a două variabile aleatoare gaussiene de medii nule [THE92] :

$$\mathbf{R}_{y/x} = \mathbf{R}_y - \mathbf{R}_{xy}^T \mathbf{R}_x^{-1} \mathbf{R}_{xy} \quad (\text{II.89})$$

putem calcula matricele de autocorelație  $\mathbf{R}_{s/y}(a_i, \sigma_u^2, \sigma_b^2)$  și  $\mathbf{R}_{b/y}(a_i, \sigma_u^2, \sigma_b^2)$  ale vectorilor  $\mathbf{s}_N(n)$  și  $\mathbf{b}_N(n)$  condiționate de  $\mathbf{y}_N(n)$  în felul următor :

$$\mathbf{R}_{s/y}(a_i, \sigma_u^2, \sigma_b^2) = \mathbf{R}_s(a_i, \sigma_u^2) - \mathbf{R}_s(a_i, \sigma_u^2) \{ \mathbf{R}_s(a_i, \sigma_u^2) + \sigma_b^2 \mathbf{I} \}^{-1} \mathbf{R}_s(a_i, \sigma_u^2) \quad (\text{II.90})$$

$$\mathbf{R}_{b/y}(a_i, \sigma_u^2, \sigma_b^2) = \sigma_b^2 \mathbf{I} - \sigma_b^4 \{ \mathbf{R}_s(a_i, \sigma_u^2) + \sigma_b^2 \mathbf{I} \}^{-1} \quad (\text{II.91})$$

La iterația  $m$ , în etapa numită "Expectation" a algoritmului EM se calculează funcțiile  $Q_s(a_i, \sigma_u^2)$  și  $Q_b(\sigma_b^2)$  [DER94] :

$$Q_s(a_i, \sigma_u^2) = E\{\ln[p(s_N(n); a_i, \sigma_u^2)/y_N(n), a_i^{(m)}, \sigma_u^{2(m)}, \sigma_b^{2(m)}]\} \quad (\text{II.92})$$

$$Q_b(\sigma_b^2) = E\{\ln[p(\mathbf{b}_N(n); \sigma_b^2)/y_N(n), a_i^{(m)}, \sigma_u^{2(m)}, \sigma_b^{2(m)}]\} \quad (\text{II.93})$$

Relația (II.92) se poate scrie ținând seama de (II.84) și reținând doar termenii care conțin parametrii semnalului și zgomotului :

$$Q_s(a_i, \sigma_u^2) = -\frac{1}{2} \ln |\mathbf{R}_s(a_i, \sigma_u^2)| - \frac{1}{2} \text{Trace}\{\mathbf{R}_s^{-1}(a_i, \sigma_u^2) E[\mathbf{s}_N(n) \mathbf{s}_N^T(n) / y_N(n), a_i^{(m)}, \sigma_u^{2(m)}, \sigma_b^{2(m)}]\} \quad (\text{II.94})$$

Vom nota prin  $\mathbf{G}_s(a_i^{(m)}, \sigma_u^{2(m)}, \sigma_b^{2(m)})$  :

$$\mathbf{G}_s(a_i^{(m)}, \sigma_u^{2(m)}, \sigma_b^{2(m)}) = E[\mathbf{s}_N(n) \mathbf{s}_N^T(n) / y_N(n), a_i^{(m)}, \sigma_u^{2(m)}, \sigma_b^{2(m)}] \quad (\text{II.95})$$

Relația (II.95) se mai poate scrie [DER94] :

$$\mathbf{G}_s(a_i^{(m)}, \sigma_u^{2(m)}, \sigma_b^{2(m)}) = \mathbf{R}_{s/y}(a_i^{(m)}, \sigma_u^{2(m)}, \sigma_b^{2(m)}) + \boldsymbol{\mu}_{s/y}(a_i^{(m)}, \sigma_u^{2(m)}, \sigma_b^{2(m)}) \boldsymbol{\mu}_{s/y}^T(a_i^{(m)}, \sigma_u^{2(m)}, \sigma_b^{2(m)}) \quad (\text{II.96})$$

sau ținând seama de (II.87) și (II.90) :

$$\mathbf{G}_s(a_i^{(m)}, \sigma_u^{2(m)}, \sigma_b^{2(m)}) = \mathbf{R}_s(a_i^{(m)}, \sigma_u^{2(m)}) + \mathbf{R}_s(a_i^{(m)}, \sigma_u^{2(m)}) [\mathbf{R}_s(a_i^{(m)}, \sigma_u^{2(m)}) + \sigma_b^{2(m)} \mathbf{I}]^{-1} \{y_N(n) \mathbf{y}_N^T(n) [\mathbf{R}_s(a_i^{(m)}, \sigma_u^{2(m)}) + \sigma_b^{2(m)} \mathbf{I}]^{-1} - \mathbf{I}\} \mathbf{R}_s(a_i^{(m)}, \sigma_u^{2(m)}) \quad (\text{II.97})$$

Deci (II.94) se rescrie :

$$Q_s(a_i, \sigma_u^2) = -\frac{1}{2} \ln |\mathbf{R}_s(a_i, \sigma_u^2)| - \frac{1}{2} \text{Trace}[\mathbf{R}_s^{-1}(a_i, \sigma_u^2) \mathbf{G}_s(a_i^{(m)}, \sigma_u^{2(m)}, \sigma_b^{2(m)})] \quad (\text{II.98})$$

Relația (II.93) se poate scrie ținând seama de (II.85) și reținând doar termenii care conțin parametri :

$$Q_b(\sigma_b^2) = -\frac{N}{2} \ln \sigma_b^2 - \frac{1}{2} \text{Trace}\{\sigma_b^{-2} E[\mathbf{b}_N(n) \mathbf{b}_N^T(n) / y_N(n), a_i^{(m)}, \sigma_u^{2(m)}, \sigma_b^{2(m)}]\} \quad (\text{II.99})$$

Vom nota cu :

$$\mathbf{G}_b(a_i^{(m)}, \sigma_u^{2(m)}, \sigma_b^{2(m)}) = E[\mathbf{b}_N(n) \mathbf{b}_N^T(n) / y_N(n), a_i^{(m)}, \sigma_u^{2(m)}, \sigma_b^{2(m)}] \quad (\text{II.100})$$

care se poate rescrie [DER94] :

$$\begin{aligned} \mathbf{G}_b(a_i^{(m)}, \sigma_u^{2(m)}, \sigma_b^{2(m)}) &= \mathbf{R}_{b/y}(a_i^{(m)}, \sigma_u^{2(m)}, \sigma_b^{2(m)}) \\ &+ \boldsymbol{\mu}_{b/y}(a_i^{(m)}, \sigma_u^{2(m)}, \sigma_b^{2(m)}) \boldsymbol{\mu}_{b/y}^T(a_i^{(m)}, \sigma_u^{2(m)}, \sigma_b^{2(m)}) \end{aligned} \quad (\text{II.101})$$

sau ținând seama de (II.88) et (II.91) :

$$\begin{aligned} \mathbf{G}_b(a_i^{(m)}, \sigma_u^{2(m)}, \sigma_b^{2(m)}) &= \sigma_b^{2(m)} \mathbf{I} + \sigma_b^{4(m)} [\mathbf{R}_s(a_i^{(m)}, \sigma_u^{2(m)}) + \sigma_b^{2(m)} \mathbf{I}]^{-1} \\ &\{ \mathbf{y}_N(n) \mathbf{y}_N^T(n) [\mathbf{R}_s(a_i^{(m)}, \sigma_u^{2(m)}) + \sigma_b^{2(m)} \mathbf{I}]^{-1} - \mathbf{I} \} \end{aligned} \quad (\text{II.102})$$

Atunci (II.101) se va rescrie :

$$Q_b(\sigma_b^2) = -\frac{N}{2} \ln(\sigma_b^2) - \frac{1}{2} \text{Trace}[\sigma_b^{-2} \mathbf{G}_b(a_i^{(m)}, \sigma_u^{2(m)}, \sigma_b^{2(m)})] \quad (\text{II.103})$$

În etapa "Maximization" se calculează  $a_i^{(m+1)}, \sigma_u^{2(m+1)}, \sigma_b^{2(m+1)}$  prin căutarea maximului, în raport cu acești parametri, în relațiile (II.98) și (II.103). Căutând maximul în raport cu varianța zgomotului pe canal în relația (II.103) se obține [DER94] :

$$\sigma_b^{2(m+1)} = \frac{1}{N} \text{Trace}[\mathbf{G}_b(a_i^{(m)}, \sigma_u^{2(m)}, \sigma_b^{2(m)})] \quad (\text{II.104})$$

Procedeeul se repetă până când se consideră că s-a ajuns la parametrii optimali. Cunoșcând acești parametri se poate filtra cu un filtru Kalman secvența  $y(n)$ . Estimatul semnalului de vorbire  $\hat{s}(n)$  va fi componenta  $p$  a lui  $\hat{\mathbf{x}}(n/n)$ .

### II.2.4.2. Etapele de calcul și algoritmul metodei III

Estimarea parametrilor semnalului și zgomotului se face utilizând un algoritm de tip EM prezentat în paragraful II.2.4.1. Utilizând acești parametri se filtrează, cu un filtru Kalman, secvența  $y(n)$ . Principalele etape ale algoritmului acestei metode sunt prezentate în figura II.4.

#### ALGORITMUL METODEI III

##### DISPONIBIL LA MOMENTUL ÎNIIȚIAL

- eșantioanele  $y(n)$  pentru  $0 \leq n \leq N-1$
- ordinul  $p$
- valorile inițiale  $a_i^{(0)}, \sigma_u^{2(0)}, \sigma_b^{2(0)}$  (pentru  $1 \leq i \leq p$ )

## I. ESTIMAREA PARAMETRILOR

Estimarea (E-Step) :

$$\mathbf{G}_s(a_i^{(m)}, \sigma_u^{2(m)}, \sigma_b^{2(m)}) = \mathbf{R}_s(a_i^{(m)}, \sigma_u^{2(m)}) + \mathbf{R}_s(a_i^{(m)}, \sigma_u^{2(m)}) [\mathbf{R}_s(a_i^{(m)}, \sigma_u^{2(m)}) + \sigma_b^{2(m)} \mathbf{I}]^{-1} \{ \mathbf{y}_N(n) \mathbf{y}_N^T(n) [\mathbf{R}_s(a_i^{(m)}, \sigma_u^{2(m)}) + \sigma_b^{2(m)} \mathbf{I}]^{-1} - \mathbf{I} \} \mathbf{R}_s(a_i^{(m)}, \sigma_u^{2(m)})$$

$$\mathbf{G}_b(a_i^{(m)}, \sigma_u^{2(m)}, \sigma_b^{2(m)}) = \sigma_b^{2(m)} \mathbf{I} + \sigma_b^{4(m)} [\mathbf{R}_s(a_i^{(m)}, \sigma_u^{2(m)}) + \sigma_b^{2(m)} \mathbf{I}]^{-1} \{ \mathbf{y}_N(n) \mathbf{y}_N^T(n) [\mathbf{R}_s(a_i^{(m)}, \sigma_u^{2(m)}) + \sigma_b^{2(m)} \mathbf{I}]^{-1} - \mathbf{I} \}$$

$$Q_s(a_i, \sigma_u^2) = -\frac{1}{2} \ln |\mathbf{R}_s(a_i, \sigma_u^2)| - \frac{1}{2} \text{Trace}[\mathbf{R}_s^{-1}(a_i, \sigma_u^2) \mathbf{G}_s(a_i^{(m)}, \sigma_u^{2(m)}, \sigma_b^{2(m)})]$$

Maximizarea (M-Step) :

$$\sigma_b^{2(m+1)} = \frac{1}{N} \text{Trace}[\mathbf{G}_b(a_i^{(m)}, \sigma_u^{2(m)}, \sigma_b^{2(m)})]$$

$$(a_i^{(m+1)}, \sigma_u^{2(m+1)}) = \underset{(a_i, \sigma_u^2)}{\text{argmax}} Q_s(a_i, \sigma_u^2)$$

Presupunem că algoritmul EM a ajuns la convergență după  $L$  iterații. Fie notația :

$$(\hat{a}_i, \hat{\sigma}_u^2, \hat{\sigma}_b^2) = (a_i^{(L)}, \sigma_u^{2(L)}, \sigma_b^{2(L)}) \text{ pentru } 1 \leq i \leq p$$

## III. FILTRARE KALMAN STANDARD

inițializare :

$$\hat{\mathbf{x}}(0/-1) = \mathbf{0}$$

$$\hat{\Phi} = \begin{bmatrix} 0 & 1 & & 0 \\ \vdots & \vdots & & \vdots \\ 0 & 0 & & 1 \\ \hat{a}_p & \hat{a}_{p-1} & \cdots & \hat{a}_1 \end{bmatrix}$$

filtrare (pentru  $0 \leq n \leq N-1$ )

$$e(n) = y(n) - \mathbf{H} \hat{\mathbf{x}}(n/n-1)$$

$$\hat{\mathbf{x}}(n+1/n) = \hat{\Phi} \hat{\mathbf{x}}(n/n-1) + \hat{\Phi} \mathbf{K}(n) e(n)$$

#### IV. ESTIMAREA SEMNALULUI DE VORBIRE

$$\hat{s}(n) = H\hat{x}(n/n) = H\hat{\Phi}\hat{x}(n/n-1) \text{ pentru } 0 \leq n \leq N-1$$

Fig. II.4: Algoritmul metodei III

### II.3. Eliminarea zgomotului în cazul unui semnal vocal contaminat de un zgomot colorat utilizând filtrarea Kalman

În acest paragraf vom propune două metode de îmbunătățire a raportului semnal/zgomot în cazul în care semnalul vocal este contaminat de un zgomot colorat.

Prima metodă este o extensie a metodei Ia propusă în paragraful II.2.

Cea de-a doua metodă estimează parametrii AR ai semnalului și ai zgomotului precum și varianțele zgomotelor de excitație corespunzătoare celor două modele. Estimarea acestor parametrii se face cu ajutorul unui algoritm EM.

#### II.3.1. Metoda IV

În cadrul acestei metode vom considera semnalul vocal  $s(n)$  și zgomotul canalului  $b(n)$  modelate prin procese autoregresive de ordin  $p$  respectiv  $q$ .

Se estimează parametrii AR ai zgomotului pe canal în perioadele de liniște în timp ce parametrii AR ai semnalului vocal și câștigul optimal Kalman se estimează în perioadele de activitate vocală.

Estimarea matricei de tranziție va fi prezentată în paragraful II.3.1.1, estimarea câștigului optimal Kalman în paragraful II.3.1.2, iar etapele de calcul și algoritmul acestei metode în II.3.1.3.

##### II.3.1.1 Estimarea matricei de tranziție

Estimarea matricei de tranziție se va face în două etape. În prima etapă se va estima partea matricei corespunzătoare zgomotului  $\Phi_b$ , iar în cea de a doua etapă se va estima partea matricei corespunzătoare semnalului  $\Phi_s$ . Estimarea matricei  $\Phi_b$  se face utilizând ecuațiile

Yule-Walker scrise pentru un proces AR de ordin  $q$ . Dacă dispunem de un bloc cu  $N$  eşantioane ale lui  $y(n)$  corespunzătoare unei perioade de linişte putem scrie :

$$y(n) = b(n) = \sum_{j=1}^q c_j b(n-j) + v(n) \text{ pentru } m \leq n \leq N+m-1 \quad (\text{II.105})$$

unde prin  $m$  am notat numărul primului eşantion din bloc. Ținând cont de (II.105) se poate scrie funcția de autocorelație a observației  $y(n)$  :

$$\gamma_{yy}(k) = \sum_{j=1}^q c_j \gamma_{yy}(k-j) + \sigma_v^2 \delta(k) \quad (\text{II.106})$$

În (II.106) am notat prin  $\delta(k)$  impulsul Dirac. Se pot scrie ecuațiile Yule-Walker ținând seama de faptul că funcția de autocorelație este o funcție pară :

$$\begin{bmatrix} \gamma_{yy}(0) & \gamma_{yy}(1) & \dots & \gamma_{yy}(q) \\ \gamma_{yy}(1) & \gamma_{yy}(0) & \dots & \gamma_{yy}(q-1) \\ \vdots & \vdots & \ddots & \vdots \\ \gamma_{yy}(q) & \gamma_{yy}(q-1) & \dots & \gamma_{yy}(0) \end{bmatrix} \begin{bmatrix} 1 \\ c_1 \\ \vdots \\ c_q \end{bmatrix} = \begin{bmatrix} \sigma_v^2 \\ 0 \\ \vdots \\ 0 \end{bmatrix} \quad (\text{II.107})$$

Estimarea funcției de autocorelație  $\gamma_{yy}(k)$  (pentru  $0 \leq k \leq q$ ) se va face utilizând valorile secvenței observabile  $y(n)$  (cu  $m \leq n \leq N+m-1$ ), presupunând  $b(n)$  ergodig, prin:

$$\hat{\gamma}_{yy}(k) = \frac{1}{N} \sum_{i=m+k}^{N+m-1} y(i)y(i-k) \quad (\text{II.108})$$

Utilizând estimata funcției de autocorelație (II.107) se poate rescrie :

$$\begin{bmatrix} \hat{\gamma}_{yy}(0) & \hat{\gamma}_{yy}(1) & \dots & \hat{\gamma}_{yy}(q) \\ \hat{\gamma}_{yy}(1) & \hat{\gamma}_{yy}(0) & \dots & \hat{\gamma}_{yy}(q-1) \\ \vdots & \vdots & \ddots & \vdots \\ \hat{\gamma}_{yy}(q) & \hat{\gamma}_{yy}(q-1) & \dots & \hat{\gamma}_{yy}(0) \end{bmatrix} \begin{bmatrix} 1 \\ \hat{c}_1 \\ \vdots \\ \hat{c} \end{bmatrix} = \begin{bmatrix} \hat{\sigma}^2 \\ 0 \\ \vdots \\ 0 \end{bmatrix} \quad (\text{II.109})$$

Rezolvarea sistemului de ecuații (II.109) se face utilizând algoritmul Levinson. Având estimați parametrii AR ai zgomotului  $b(n)$ , obținuți prin rezolvarea sistemului (II.109), putem scrie matricea de tranziție  $\Phi_b$  :



$$\hat{\Phi}_b = \begin{bmatrix} 0 & 1 & 0 \\ \vdots & \vdots & \vdots \\ 0 & 0 & 1 \\ \hat{c}_q & \hat{c}_{q-1} & \cdots & \hat{c}_1 \end{bmatrix} \quad (\text{II.110})$$

În etapa a doua vom estima partea matricei de tranziție corespunzătoare semnalului  $\Phi_s$ . Estimarea acestei matrice se bazează pe faptul că semnalul  $s(n)$  și zgomotul pe canal  $b(n)$  sunt necorelate. Funcția de autocorelație a semnalului vocal se determină prin substituția funcțiilor de autocorelație a secvenței observabile și funcția de autocorelație a zgomotului pe canal [KAY88]. După ce se estimează funcția de autocorelație a semnalului vocal, rezolvând ecuațiile Youle-Walker scrise pentru un model AR de ordin  $p$ , se pot estima coeficienții AR corespunzători semnalului vocal  $s(n)$ . Fie un bloc cu  $N$  eșantioane ale secvenței de observație  $y(n)$ , în care este prezent semnalul vocal :

$$y(n) = s(n) + b(n) \text{ pentru } m \leq n \leq N+m-1 \quad (\text{II.111})$$

unde prin  $m$  am notat numărul primului eșantion din bloc. Funcția de autocorelație a secvenței observabile  $y(n)$  este :

$$\gamma_{yy}(k) = E\{y(n)y(n-k)\} = E\{s(n)s(n-k)\} + E\{b(n)b(n-k)\} = \gamma_{ss}(k) + \gamma_{bb}(k) \quad (\text{II.112})$$

Estimarea funcției de autocorelație a zgomotului se face utilizând valorile lui  $y(n)$  ( $m \leq n \leq N+m-1$ ) înregistrate în perioada de liniște cea mai recentă. Funcția de autocorelație a zgomotului  $\gamma_{bb}(k)$  se estimează prin :

$$\hat{\gamma}_{bb}(k) = \frac{1}{N} \sum_{i=m+k}^{N+m-1} y(i)y(i-k) \quad (\text{II.113})$$

Vom presupune că după cele  $N$  eșantioane folosite pentru estimarea funcției de autocorelație a zgomotului sunt urmate de o perioadă în care semnalul de vorbire este prezent. Fie  $M$  eșantioane  $y(n)$  (cu  $N+m \leq n \leq N+m+M-1$ ) înregistrate în această perioadă. Ținând cont de (II.112) se poate scrie :

$$\hat{\gamma}_{ss}(k) = \frac{1}{M} \sum_{i=N+m+k}^{N+m+M-1} y(i)y(i-k) - \alpha \hat{\gamma}_{bb}(k) \quad (\text{II.114})$$

Factorul  $\alpha$  este astfel ales încât estimata matricei de autocorelație a semnalului să rămână pozitiv definită. Cum  $s(n)$  este modelat printr-un proces AR de ordin  $p$  putem scrie :

$$\gamma_{ss}(k) = \sum_{i=1}^p a_i \gamma_{ss}(k-i) + \sigma_u^2 \delta(k) \quad (\text{II.115})$$

Funcția de autocorelație fiind pară ecuațiile Yule-Walker scrise pentru  $s(n)$  sunt :

$$\begin{bmatrix} \gamma_{ss}(0) & \gamma_{ss}(1) & \dots & \gamma_{ss}(p) \\ \gamma_{ss}(1) & \gamma_{ss}(0) & \dots & \gamma_{ss}(p-1) \\ \vdots & \vdots & \ddots & \vdots \\ \gamma_{ss}(p) & \gamma_{ss}(p-1) & \dots & \gamma_{ss}(0) \end{bmatrix} \begin{bmatrix} 1 \\ a_1 \\ \vdots \\ a_p \end{bmatrix} = \begin{bmatrix} \sigma_u^2 \\ 0 \\ \vdots \\ 0 \end{bmatrix} \quad (\text{II.116})$$

Relația (II.116) se poate scrie înlocuind  $\gamma_{ss}(k)$  prin estimata sa  $\hat{\gamma}_{ss}(k)$  :

$$\begin{bmatrix} \hat{\gamma}_{ss}(0) & \hat{\gamma}_{ss}(1) & \dots & \hat{\gamma}_{ss}(p) \\ \hat{\gamma}_{ss}(1) & \gamma_{ss}(0) & \dots & \hat{\gamma}_{ss}(p-1) \\ \vdots & \vdots & \ddots & \vdots \\ \hat{\gamma}_{ss}(p) & \hat{\gamma}_{ss}(p-1) & \dots & \hat{\gamma}_{ss}(0) \end{bmatrix} \begin{bmatrix} 1 \\ \hat{a}_1 \\ \vdots \\ \hat{a}_p \end{bmatrix} = \begin{bmatrix} \sigma_u^2 \\ 0 \\ \vdots \\ 0 \end{bmatrix} \quad (\text{II.117})$$

Rezolvarea ecuației (II.117) se va face cu ajutorul algoritmului Levinson. Utilizând estimări parametrilor AR ai semnalului  $s(n)$  se poate scrie matricea  $\Phi_s$  :

$$\Phi_s = \begin{bmatrix} 0 & 1 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & 1 \\ \hat{a}_p & \hat{a}_{p-1} & \dots & \hat{a}_1 \end{bmatrix} \quad (\text{II.118})$$

### II.3.1.2 Estimarea câștigului optimal Kalman

Estimarea câștigului optimal se bazează pe proprietatea secvenței de inovație de a deveni albă când filtrul Kalman operează cu parametrii cunoscuți și câștig optimal [KAI68]. Procedura iterativă de determinare a câștigului optimal este cea propusă de Mehra ca și alternativă în calculul matricei de covarianța a zgomotului de excitație [MEH70]. Etapele de calcul a câștigului optimal au fost prezentate în paragraful II.2.1.2. Relația de calcul iterativ al câștigului Kalman este :

$$K(i) = K(i-1) + \begin{bmatrix} H\Phi \\ H(\Phi(I - KH))'\Phi \\ \vdots \\ H(\Phi(I - KH))^{p-1}\Phi \end{bmatrix}^{-1} \begin{bmatrix} \gamma_{ee}(1) \\ \gamma_{ee}(2) \\ \vdots \\ \gamma_{ee}(p) \end{bmatrix} / \gamma_{ee}(0) \quad (\text{II.119})$$

În relația (II.119) am notat prin  $i$  numărul iterației și prin  $\gamma_{ee}(k)$  funcția de autocorelație a secvenței de inovație. Estimarea funcției de autocorelație a secvenței de inovație se face utilizând eșantioanele secvenței de inovație  $e(n)$  (cu  $m+N \leq n \leq m+N+M-1$ ) cu formula :

$$\hat{\gamma}_{ee}(k) = \frac{1}{M} \sum_{i=N+m+k}^{N+M+m-1} e(i)e(i-k) \quad (\text{II.120})$$

În acest caz relația (II.119) se rescrie :

$$\hat{K}(i) = \hat{K}(i-1) + \begin{bmatrix} H\hat{\Phi} \\ H\hat{\Phi}[I - \hat{K}(i-1)H]\hat{\Phi} \\ \vdots \\ H\hat{\Phi}[I - \hat{K}(i-1)H]^{p-1}\hat{\Phi} \end{bmatrix}^{-1} \begin{bmatrix} \hat{\gamma}_{ee}(1) \\ \hat{\gamma}_{ee}(2) \\ \vdots \\ \hat{\gamma}_{ee}(p) \end{bmatrix} / \hat{\gamma}_{ee}(0) \quad (\text{II.121})$$

Procedeeul iterativ (II.121) se repetă până când secvența de inovație devine albă și de medie nulă [BOO72]. Se testează dacă [STO77] :

$$\sum_{i=1}^k \gamma_{ee}^2(i) \leq (k+1.65\sqrt{2k})\gamma_{ee}^2(0)/N \quad (\text{II.122})$$

### II.3.1.3. Etapele de calcul și algoritmul metodei IV

Estimarea parametrilor AR a fost prezentată în paragraful II.3.1.1. Estimarea câștigului optimal Kalman se face conform paragrafului II.3.1.2. Algoritmul metodei IV este prezentat în figura II.5.

<b>ALGORITMUL METODEI IV</b>
<u>DISPONIBIL LA MOMENTUL INIȚIAL</u>
- eșantioanele $y(n)$ cu $m \leq n \leq m+N+M-1$
- valorile $p$ și $q$
- valoarea inițială $\hat{K}(0)$

## I. ESTIMAREA MATRICEI DE TRANZIȚIE

$$\hat{\gamma}_{yy}(k) = \frac{1}{N} \sum_{i=m+k}^{N+m-1} y(i)y(i-k) \text{ pentru } 0 \leq k \leq \max(p,q)$$

$$\begin{bmatrix} \hat{\gamma}_{yy}(0) & \hat{\gamma}_{yy}(1) & \cdots & \hat{\gamma}_{yy}(q) \\ \hat{\gamma}_{yy}(1) & \hat{\gamma}_{yy}(0) & \cdots & \hat{\gamma}_{yy}(q-1) \\ \vdots & \vdots & \ddots & \vdots \\ \hat{\gamma}_{yy}(q) & \hat{\gamma}_{yy}(q-1) & \cdots & \hat{\gamma}_{yy}(0) \end{bmatrix} \begin{bmatrix} 1 \\ \hat{c}_1 \\ \vdots \\ \hat{c}_q \end{bmatrix} = \begin{bmatrix} \hat{\sigma}_v^2 \\ 0 \\ \vdots \\ 0 \end{bmatrix}$$

$$\hat{\Phi}_b = \begin{bmatrix} 0 & 1 & 0 \\ \vdots & \vdots & \vdots \\ 0 & 0 & 1 \\ \hat{c}_q & \hat{c}_{q-1} & \hat{c}_1 \end{bmatrix}$$

$$\hat{\gamma}_{ss}(k) = \frac{1}{M} \sum_{i=N+m+k}^{N+m+M-1} y(i)y(i-k) - \alpha \hat{\gamma}_{bb}(k)$$

$$\begin{bmatrix} \hat{\gamma}_{ss}(0) & \hat{\gamma}_{ss}(1) & \cdots & \hat{\gamma}_{ss}(p) \\ \hat{\gamma}_{ss}(1) & \hat{\gamma}_{ss}(0) & \cdots & \hat{\gamma}_{ss}(p-1) \\ \vdots & \vdots & \ddots & \vdots \\ \hat{\gamma}_{ss}(p) & \hat{\gamma}_{ss}(p-1) & \cdots & \hat{\gamma}_{ss}(0) \end{bmatrix} \begin{bmatrix} 1 \\ \hat{a}_1 \\ \vdots \\ \hat{a}_p \end{bmatrix} = \begin{bmatrix} \sigma_u^2 \\ 0 \\ \vdots \\ 0 \end{bmatrix}$$

$$\hat{\Phi}_s = \begin{bmatrix} 0 & 1 & 0 \\ \vdots & \vdots & \vdots \\ 0 & 0 & 1 \\ \hat{a}_p & \hat{a}_{p-1} & \hat{a}_1 \end{bmatrix}$$

$$\hat{\Phi} = \begin{bmatrix} \hat{\Phi}_s & 0 \\ 0 & \hat{\Phi}_b \end{bmatrix}$$

## II. FILTRARE KALMAN

inițializare :

$$\hat{x}(0/-1) = 0$$

filtrare (pentru  $m+N \leq n \leq m+N+M-1$ )

$$e(n) = y(n) - H\hat{x}(n/n-1)$$

$$\hat{\mathbf{x}}(n+1/n) = \hat{\Phi} \hat{\mathbf{x}}(n/n-1) + \hat{\Phi} \hat{\mathbf{K}}(i) e(n)$$

### III. ESTIMAREA CÂȘTIGULUI OPTIMAL

$$\hat{\gamma}_{ee}(k) = \frac{1}{M} \sum_{i=N+m+k}^{N+M+m-1} e(i)e(i-k) \text{ pentru } 0 \leq k \leq p$$

$$\text{Dacă } \sum_{i=1}^p \gamma_{ee}^2(i) \geq (p+1.65\sqrt{2p}) \gamma_{ee}^2(0)/N$$

$$\mathbf{K}(i) = \mathbf{K}(i-1) + \begin{bmatrix} \mathbf{H} \hat{\Phi} \\ \mathbf{H}(\hat{\Phi}(\mathbf{I} - \mathbf{K}\mathbf{H})) \hat{\Phi} \\ \vdots \\ \mathbf{H}(\hat{\Phi}(\mathbf{I} - \mathbf{K}\mathbf{H}))^{p-1} \hat{\Phi} \end{bmatrix}^{-1} \begin{bmatrix} \gamma_{ee}(1) \\ \gamma_{ee}(2) \\ \vdots \\ \gamma_{ee}(p) \end{bmatrix} / \gamma_{ee}(0)$$

Întoarcere la II.

### IV. ESTIMAREA SEMNALULUI VOCAL

$\hat{s}(n)$  este componenta  $p$  a vectorului  $\hat{\mathbf{x}}(n/n)$

Fig. II.5 : Algoritmul metodei IV

### II.3.2. Metoda V

Această metodă [GAB96a] estimează toți parametri necesri filtrării Kalman utilizând un algoritmul EM. Estimarea acestor parametri se face extinzând metoda propusă de Deriche pentru calculul parametrilor unui semnal modelat printr-un proces AR contaminat de un zgomot colorat.

Estimarea parametrilor se face utilizând un bloc cu  $N$  eşantioane ale semnalului observabil  $y(n)$  aranjate în vectorul :

$$\mathbf{y}_N(n) = [y(n), \dots, y(n-N+1)]^T = \mathbf{s}_N(n) + \mathbf{b}_N(n) \quad (\text{II.123})$$

Presupunând că semnalul de vorbire și zgomotul pot fi modelate prin procese AR gaussiene putem scrie densitățile de probabilitate ale vectorilor aleatori  $\mathbf{s}_N(n)$  și  $\mathbf{b}_N(n)$  [THE92] :

$$p(\mathbf{s}_N(n)/a_i, \sigma_u^2) = (2\pi)^{-N/2} |\mathbf{R}_s(a_i, \sigma_u^2)|^{-1/2} \exp\{-\frac{1}{2} \mathbf{s}_N^T(n) \mathbf{R}_s^{-1}(a_i, \sigma_u^2) \mathbf{s}_N(n)\} \quad (\text{II.124})$$

$$p(\mathbf{b}_N(n)/c_j, \sigma_v^2) = (2\pi)^{-N/2} |\mathbf{R}_b(c_j, \sigma_v^2)|^{-1/2} \exp\{-\frac{1}{2} \mathbf{b}_N^T(n) \mathbf{R}_b^{-1}(c_j, \sigma_v^2) \mathbf{b}_N(n)\} \quad (\text{II.125})$$

relații în care prin  $\mathbf{R}_s(a_i, \sigma_u^2)$  și  $\mathbf{R}_b(c_j, \sigma_v^2)$  (cu  $1 \leq i \leq p$  și  $1 \leq j \leq q$ ) am notat matricele de autocorelație ale semnalului respectiv zgomotului definite prin :

$$\mathbf{R}_s(a_i, \sigma_u^2) = E\{ \mathbf{s}_N(n) \mathbf{s}_N^T(n) \} \quad (\text{II.126})$$

$$\mathbf{R}_b(c_j, \sigma_v^2) = E\{ \mathbf{b}_N(n) \mathbf{b}_N^T(n) \} \quad (\text{II.127})$$

Mediile condiționate  $\boldsymbol{\mu}_{s/y}(a_i, \sigma_u^2, c_j, \sigma_v^2/y_N(n))$  și  $\boldsymbol{\mu}_{b/y}(a_i, \sigma_u^2, c_j, \sigma_v^2/y_N(n))$ , ale vectorilor aleatori  $\mathbf{s}_N(n)$  și  $\mathbf{b}_N(n)$  condiționate de realizarea vectorului aleator  $\mathbf{y}_N(n)$ , sunt [THE92] :

$$\boldsymbol{\mu}_{s/y}(a_i, \sigma_u^2, c_j, \sigma_v^2/y_N(n)) = \mathbf{R}_s(a_i, \sigma_u^2) [\mathbf{R}_s(a_i, \sigma_u^2) + \mathbf{R}_b(c_j, \sigma_v^2)]^{-1} \mathbf{y}_N(n) \quad (\text{II.128})$$

$$\boldsymbol{\mu}_{b/y}(a_i, \sigma_u^2, c_j, \sigma_v^2/y_N(n)) = \mathbf{R}_b(c_j, \sigma_v^2) [\mathbf{R}_s(a_i, \sigma_u^2) + \mathbf{R}_b(c_j, \sigma_v^2)]^{-1} \mathbf{y}_N(n) \quad (\text{II.129})$$

iar matricele de autocorelație condiționate de realizarea vectorului aleator  $\mathbf{y}_N(n)$   $\mathbf{R}_{s/y}(a_i, \sigma_u^2, c_j, \sigma_v^2/y_N(n))$  și  $\mathbf{R}_{b/y}(a_i, \sigma_u^2, c_j, \sigma_v^2/y_N(n))$  :

$$\mathbf{R}_{s/y}(a_i, \sigma_u^2, c_j, \sigma_v^2/y_N(n)) = \mathbf{R}_s(a_i, \sigma_u^2) + [\mathbf{R}_s(a_i, \sigma_u^2) + \mathbf{R}_b(c_j, \sigma_v^2)]^{-1} \mathbf{R}_s(a_i, \sigma_u^2) \quad (\text{II.130})$$

$$\mathbf{R}_{b/y}(a_i, \sigma_u^2, c_j, \sigma_v^2/y_N(n)) = \mathbf{R}_b(c_j, \sigma_v^2) + [\mathbf{R}_s(a_i, \sigma_u^2) + \mathbf{R}_b(c_j, \sigma_v^2)]^{-1} \mathbf{R}_b(c_j, \sigma_v^2) \quad (\text{II.131})$$

La iterația  $m$ , în etapa "Estimare" a algoritmului EM se calculează [DER94] :

$$Q_s = E\{\ln[p(\mathbf{s}_N(n); a_i, \sigma_u^2)]/y_N(n), a_i^{(m)}, \sigma_u^{2(m)}, c_j^{(m)}, \sigma_v^{2(m)}\} \quad (\text{II.132})$$

$$Q_b = E\{\ln[p(\mathbf{b}_N(n); c_j, \sigma_v^2)]/y_N(n), a_i^{(m)}, \sigma_u^{2(m)}, c_j^{(m)}, \sigma_v^{2(m)}\} \quad (\text{II.133})$$

Etapa "Maximizare" constă în determinarea valorilor  $a_i^{(m+1)}, \sigma_u^{2(m+1)}, c_j^{(m+1)}, \sigma_v^{2(m+1)}$  care maximizează pe  $Q_s$  și  $Q_b$ .

Relațiile (II.132) și (II.133) se pot rescrie [GAB96a] :

$$Q_s = -\frac{1}{2} \ln |\mathbf{R}_s(a_i, \sigma_u^2)| - \frac{1}{2} \text{Trace}\{\mathbf{R}_s^{-1}(a_i, \sigma_u^2) \mathbf{G}_s^{(m)}\} \quad (\text{II.134})$$

$$Q_b = -\frac{1}{2} \ln |\mathbf{R}_b(c_j, \sigma_v^2)| - \frac{1}{2} \text{Trace}\{\mathbf{R}_b^{-1}(c_j, \sigma_v^2) \mathbf{G}_b^{(m)}\} \quad (\text{II.135})$$

unde am notat prin :

$$\begin{aligned} \mathbf{G}_s^{(m)} &= \mathbf{R}_{s/y}(a_i^{(m)}, \sigma_u^{2(m)}, \mathbf{c}_j^{(m)}, \sigma_v^{2(m)}/\mathbf{y}_N(n)) \\ &+ \boldsymbol{\mu}_{s/y}^T(a_i^{(m)}, \sigma_u^{2(m)}, \mathbf{c}_j^{(m)}, \sigma_v^{2(m)}/\mathbf{y}_N(n)) \boldsymbol{\mu}_{s/y}(a_i^{(m)}, \sigma_u^{2(m)}, \mathbf{c}_j^{(m)}, \sigma_v^{2(m)}/\mathbf{y}_N(n)) \end{aligned} \quad (\text{II.136})$$

$$\begin{aligned} \mathbf{G}_b^{(m)} &= \mathbf{R}_{b/y}(a_i^{(m)}, \sigma_u^{2(m)}, \mathbf{c}_j^{(m)}, \sigma_v^{2(m)}/\mathbf{y}_N(n)) \\ &+ \boldsymbol{\mu}_{b/y}^T(a_i^{(m)}, \sigma_u^{2(m)}, \mathbf{c}_j^{(m)}, \sigma_v^{2(m)}/\mathbf{y}_N(n)) \boldsymbol{\mu}_{b/y}(a_i^{(m)}, \sigma_u^{2(m)}, \mathbf{c}_j^{(m)}, \sigma_v^{2(m)}/\mathbf{y}_N(n)) \end{aligned} \quad (\text{II.137})$$

Algoritmul de calcul al acestei metode este prezentat în figura II.6.

### ALGORITMUL METODEI V

#### DISPONIBIL LA MOMENTUL INIȚIAL

- eșantioanele  $y(n)$  cu  $0 \leq n \leq N-1$
- valorile  $p$  și  $q$
- valorile inițiale  $a_i^{(0)}, \sigma_u^{2(0)}, \mathbf{c}_j^{(0)}, \sigma_v^{2(0)}$  (pentru  $1 \leq i \leq p$  și  $1 \leq j \leq q$ )

#### I. ESTIMAREA PARAMETRILOR

Estimarea (E-Step) :

$$\boldsymbol{\mu}_{s/y}(a_i, \sigma_u^2, \mathbf{c}_j, \sigma_v^2/\mathbf{y}_N(n)) = \mathbf{R}_s(a_i, \sigma_u^2) [\mathbf{R}_s(a_i, \sigma_u^2) + \mathbf{R}_b(\mathbf{c}_j, \sigma_v^2)]^{-1} \mathbf{y}_N(n)$$

$$\boldsymbol{\mu}_{b/y}(a_i, \sigma_u^2, \mathbf{c}_j, \sigma_v^2/\mathbf{y}_N(n)) = \mathbf{R}_b(\mathbf{c}_j, \sigma_v^2) [\mathbf{R}_s(a_i, \sigma_u^2) + \mathbf{R}_b(\mathbf{c}_j, \sigma_v^2)]^{-1} \mathbf{y}_N(n)$$

$$\mathbf{R}_{s/y}(a_i, \sigma_u^2, \mathbf{c}_j, \sigma_v^2/\mathbf{y}_N(n)) = \mathbf{R}_s(a_i, \sigma_u^2) + [\mathbf{R}_s(a_i, \sigma_u^2) + \mathbf{R}_b(\mathbf{c}_j, \sigma_v^2)]^{-1} \mathbf{R}_s(a_i, \sigma_u^2)$$

$$\mathbf{R}_{b/y}(a_i, \sigma_u^2, \mathbf{c}_j, \sigma_v^2/\mathbf{y}_N(n)) = \mathbf{R}_b(\mathbf{c}_j, \sigma_v^2) + [\mathbf{R}_s(a_i, \sigma_u^2) + \mathbf{R}_b(\mathbf{c}_j, \sigma_v^2)]^{-1} \mathbf{R}_b(\mathbf{c}_j, \sigma_v^2)$$

$$\begin{aligned} \mathbf{G}_s^{(m)} &= \mathbf{R}_{s/y}(a_i^{(m)}, \sigma_u^{2(m)}, \mathbf{c}_j^{(m)}, \sigma_v^{2(m)}/\mathbf{y}_N(n)) \\ &+ \boldsymbol{\mu}_{s/y}^T(a_i^{(m)}, \sigma_u^{2(m)}, \mathbf{c}_j^{(m)}, \sigma_v^{2(m)}/\mathbf{y}_N(n)) \boldsymbol{\mu}_{s/y}(a_i^{(m)}, \sigma_u^{2(m)}, \mathbf{c}_j^{(m)}, \sigma_v^{2(m)}/\mathbf{y}_N(n)) \end{aligned}$$

$$\begin{aligned} \mathbf{G}_b^{(m)} &= \mathbf{R}_{b/y}(a_i^{(m)}, \sigma_u^{2(m)}, \mathbf{c}_j^{(m)}, \sigma_v^{2(m)}/\mathbf{y}_N(n)) \\ &+ \boldsymbol{\mu}_{b/y}^T(a_i^{(m)}, \sigma_u^{2(m)}, \mathbf{c}_j^{(m)}, \sigma_v^{2(m)}/\mathbf{y}_N(n)) \boldsymbol{\mu}_{b/y}(a_i^{(m)}, \sigma_u^{2(m)}, \mathbf{c}_j^{(m)}, \sigma_v^{2(m)}/\mathbf{y}_N(n)) \end{aligned}$$

$$Q_s = -\frac{1}{2} \ln |\mathbf{R}_s(a_i, \sigma_u^2)| - \frac{1}{2} \text{Trace} \{ \mathbf{R}_s^{-1}(a_i, \sigma_u^2) \mathbf{G}_s^{(m)} \}$$

$$Q_b = -\frac{1}{2} \ln |\mathbf{R}_b(\mathbf{c}_j, \sigma_v^2)| - \frac{1}{2} \text{Trace} \{ \mathbf{R}_b^{-1}(\mathbf{c}_j, \sigma_v^2) \mathbf{G}_b^{(m)} \}$$

Maximizare (M-Spep) :

$$(a_i^{(m+1)}, \sigma_u^{2(m+1)}) = \underset{(a_i, \sigma_u^2)}{\operatorname{argmax}} Q_s(a_i, \sigma_u^2)$$

$$(c_j^{(m+1)}, \sigma_v^{2(m+1)}) = \underset{(c_j, \sigma_v^2)}{\operatorname{argmax}} Q_b(c_j, \sigma_v^2)$$

Presupunem că algoritmul EM a atins convergența după  $L$  iterații. Notăm prin :

$$(\hat{a}_i, \hat{c}_j, \hat{\sigma}_u^2, \hat{\sigma}_v^2) = (a_i^{(L)}, c_j^{(L)}, \sigma_u^{2(L)}, \sigma_v^{2(L)}) \text{ pentru } 1 \leq i \leq p \text{ și } 1 \leq j \leq q$$

### III. FILTRAJ KALMAN STANDARD

inițializare :

$$\hat{\mathbf{x}}(0/-1) = \mathbf{0}$$

$$\hat{\Phi}_s = \begin{bmatrix} 0 & 1 & 0 \\ \vdots & \vdots & \vdots \\ 0 & 0 & 1 \\ \hat{a}_p & \hat{a}_{p-1} & \hat{a}_1 \end{bmatrix}; \hat{\Phi}_b = \begin{bmatrix} 0 & 1 & 0 \\ \vdots & \vdots & \vdots \\ 0 & 0 & 1 \\ \hat{c}_q & \hat{c}_{q-1} & \hat{c}_1 \end{bmatrix}$$

filtrare (pentru  $0 \leq n \leq N-1$ )

$$e(n) = y(n) - \mathbf{H}\hat{\mathbf{x}}(n/n-1)$$

$$\hat{\mathbf{x}}(n+1/n) = \hat{\Phi}\hat{\mathbf{x}}(n/n-1) + \hat{\Phi}\mathbf{K}(n)e(n)$$

### IV. ESTIMAREA SEMNALULUI VOCAL

$\hat{s}(n)$  este componenta  $p$  din  $\hat{\mathbf{x}}(n/n)$

Fig. II.6: Algoritmul metodei V



## II.4. Concluzii

În acest capitol am descris câteva metode propuse de noi pentru îmbunătățirea calității unui semnal vocal contaminat cu un zgomot alb sau colorat utilizând un singur captor. Aceste metode au fost grupate în două clase.

În prima clasă am grupat metodele utilizate în cazul unui semnal de vorbire contaminat de un zgomot alb. Primele două metode propuse au fost dezvoltate pornind de la articolele lui R.K. Mehra [MEH70][MEH71]. Prima metodă (Metoda Ia și Ib [GAB96b][GAB97c]) estimează iterativ câștigul optimal Kalman, câștig care conține contribuția “mascată” a varianțelor zgomotului de excitație și a zgomotului pe canal. Cea de-a doua metodă (Metoda II [GAB97b]) estimează varianțele zgomotului de excitație și a zgomotului pe canal utilizând secvența de inovație obținută printr-o filtrare cu un câștig Kalman inițial. Cea de-a treia metodă (Metoda III [GAB96c]) estimează parametrii utilizând algoritmul EM.

În cea de-a doua clasă am grupat două metode de îmbunătățire a calității unui semnal vocal contaminat cu un zgomot colorat. Ambele metode sunt extensii ale unor metode propuse în prima clasă. Metoda IV [GAB97a] este o extensie a metodei I și metoda V [GAB96c] este o extensie a metodei III.

## **CAPITOLUL III**

### **Îmbunătățirea calității semnalului vocal utilizând două semnale captate în același mediu zgomotos**

#### **III.1. Introducere**

Scopul acestui capitol este de a construi sisteme capabile să îmbunătățească raportul semnal/zgomot în cazul unui semnal vocal când se dispune de două semnale captate în același mediu zgomotos. Vom considera în mediul zgomotos două surse acustice presupse punctiforme și anume o sursă care generează semnalul vocal și alta care generează zgomotul. Ipoteza care permite îmbunătățirea raportului semnal/zgomot este de a avea un zgomot necorelat cu semnalul de vorbire [WID75].

Pentru a realiza acest lucru vom utiliza două semnale captate cu ajutorul a două microfoane dispuse în același mediu zgomotos. Se va plasa primul microfon în apropierea sursei care generează semnalul vocal iar cel de-al doilea microfon în apropierea sursei care generează zgomotul. Semnalele captate de cele două microfoane conțin informații atât despre semnalul

de vorbire cât și despre zgomot. Semnalul captat de primul microfon îl vom numi semnal de prelucrat iar cel captat de-al doilea microfon semnal de referință.

Spre exemplu se poate considera cazul în care semnalele au fost captate în habitacul unui autoturism cu scopul de îmbunătățire a raportului semnal/zgomot pentru a facilita sarcinile unui sistem de recunoaștere a vorbirii în realizarea telefonului “mână liberă” [VAL92].




Fig. III.1 Schema de simulare a celor două microfoane

În cazul nostru am simulat sistemul de înregistrare a celor două semnale prin cel ilustrat în figura III.1. Microfonul  $M_1$  a fost plasat în apropierea sursei de semnal iar microfonul  $M_2$  în apropierea sursei de zgomot. Semnalul de prelucrat  $p_1(n)$ , captat de microfonul  $M_1$ , este suma dintre semnalul vocal  $s(n)$  și  $b'(n)$ , ultimul fiind componenta zgomotului captată de primul microfon. Deci :

$$p_1(n) = s(n) + b'(n) \quad (\text{III.1})$$

Semnalul de referință  $p_2(n)$ , captat de cel de-al doilea microfon  $M_2$ , este suma dintre zgomotul  $b(n)$  și  $s'(n)$ . Semnalul  $s'(n)$  este componenta semnalului vocal captată de cel de-al doilea microfon. Deci :

$$p_2(n) = b(n) + s'(n) \quad (\text{III.2})$$

Deoarece microfonul  $M_1$  este plasat foarte aproape de sursa care generează semnalul vocal, iar microfonul  $M_2$  este plasat foarte aproape de sursa de zgomot putem considera că semnalul vocal intră nemodificat în microfonul  $M_1$  și că zgomotul intră nemodificat în microfonul  $M_2$ . Cazul în care această condiție nu este îndeplinită rămâne un subiect deschis.

Semnalul  $s'(n)$  poate fi considerat semnalul de ieșire al sistemului  $H_1(z)$  având ca semnal de intrare pe  $s(n)$ , iar  $b'(n)$  poate fi considerat semnalul de ieșire al sistemului  $H_2(z)$  având ca semnal de intrare pe  $b(n)$ . Scopul nostru este de a găsi funcțiile de transfer  $H_1(z)$  și  $H_2(z)$  (sau răspunsurile la impuls al acestor două sisteme), găsirea acestor funcții permițându-ne reconstruirea lui  $s(n)$  și a lui  $b(n)$  din  $p_1(n)$  și  $p_2(n)$ .

Primele rezultate în acest sens au fost obținute de Widrow [WID75]. Acesta a utilizat un singur filtru adaptiv (Fig. III.2).




Fig. III.2 Schema de principiu a îmbunătățirii raportului semnal/zgomot utilizând un filtru adaptiv

Intrarea filtrului adaptiv  $W(z)$  este semnalul de referință  $p_2(n)$  iar ieșirea este semnalul  $b''(n)$ , dorit cât mai apropiat de  $b'(n)$ . Expresia lui  $b''(n)$  este :

$$b''(n) = \mathbf{w}_N^T(n-1) \mathbf{p}_{2N}(n) \quad (\text{III.3})$$

relație în care prin  $w_i(n-1)$  am notat coeficienții filtrului de ordin  $N$  calculați la momentul  $n-1$  iar prin  $\mathbf{w}_N(n-1)$  vectorul acestor coeficienți :

$$\mathbf{w}_N(n-1) = [w_1(n-1), \dots, w_N(n-1)]^T \quad (\text{III.4})$$

iar prin  $\mathbf{p}_{2N}(n)$  vectorul ultimelor  $N$  eșantioane ale semnalului  $p_2(n)$  :

$$\mathbf{p}_{2N}(n) = [p_2(n), \dots, p_2(n-N+1)]^T \quad (\text{III.5})$$

În paragrafele următoare vom prezenta mai multe metode utilizând unul sau două filtre în diferite variante de scheme pe care le vom utiliza.

## III.2. Îmbunătățirea raportului semnal/zgomot utilizând un singur filtru

Schema de principiu pentru îmbunătățirea raportului semnal/zgomot cu un singur filtru este cea din figura III.2. Trebuie, mai întâi, să alegem un criteriu iar apoi să găsim un algoritm care să minimizeze sau să maximizeze o funcție matematică scrisă în conformitate cu acest criteriu. Drept criteriu am putea alege :

- criteriul erorii medii pătratice minime
- criteriul recursiv al celor mai mici pătrate

Vom calcula filtrul optimal, în sens Wiener, iar apoi vom pune în evidență erorile care apar în momentul ajungerii la această soluție optimală. În cazul nostru, în domeniul timp, ecuația Wiener-Hopf se poate scrie [WID75] :

$$\sum_{k=-\infty}^{\infty} w^*(k) \gamma_{p_2 p_2}(n-k) = \gamma_{p_2 p_1}(k) \quad (\text{III.6})$$

sau în domeniul frecvență :

$$W^*(\omega) = \frac{S_{p_2 p_1}(\omega)}{S_{p_2 p_2}(\omega)} \quad (\text{III.7})$$

Dacă ne referim acum la schema prin care am simulat obținerea celor două semnale  $p_1(n)$  și  $p_2(n)$  și le înlocuim în relația (III.7) se obține [WID75] :

$$W^*(\omega) = \frac{H_2(\omega)S_{bb}(\omega) + H_1^*(\omega)S_{ss}(\omega)}{S_{bb}(\omega) + |H_1(\omega)|^2 S_{ss}(\omega)} \quad (\text{III.8})$$

Utilizând această formulă putem să calculăm diferite rapoarte semnal/zgomot în diferite puncte ale schemei, prezentate în figura III.2, în cazul în care filtrul adaptiv se va înlocui cu filtrul optimal Wiener [WID75].

Valoarea raportului semnal/zgomot pentru semnalul captat de primul microfon este :

$$SNR_{p_1}(\omega) = \frac{S_{ss p_1}(\omega)}{S_{bb p_1}(\omega)} = \frac{S_{ss}(\omega)}{|H_2(\omega)|^2 S_{bb}(\omega)} \quad (\text{III.9})$$

În ceea ce privește raportul semnal/zgomot pentru semnalul captat de-al doilea microfon se poate scrie :

$$SNR_{p_2}(\omega) = \frac{S_{ss_{p_2}}(\omega)}{S_{bb_{p_2}}(\omega)} = \frac{S_{ss}(\omega)|H_1(\omega)|^2}{S_{bb}(\omega)} \quad (\text{III.10})$$

Pentru semnalul de ieșire  $s_1(n)$ , putem scrie :

$$SNR_{s_1}(\omega) = \frac{S_{ss_{s_1}}(\omega)}{S_{bb_{s_1}}(\omega)} = \frac{S_{bb}(\omega)}{S_{ss}(\omega)|H_1(\omega)|^2} \quad (\text{III.11})$$

Se poate observa că relația de calcul a raportului semnal/zgomot a semnalului de ieșire este exact inversul raportului zgomot/semnal din intrarea de referință. Vom obține un raport semnal/zgomot mai bun în cazul în care în componența semnalului captat de cel de-al doilea microfon componenta semnalului vocal este foarte mică, ideal este de a avea în semnalul de referință numai zgomot.

Nici cu filtrul optimal Wiener nu se obține întotdeauna o îmbunătățire a raportului semnal pe zgomot. Față de algoritmul LMS utilizând algoritmul RLS, clasic sau rapid, se obține o viteză de convergență mai mare spre soluția optimală Wiener. În cazul în care componenta semnalului vocal în cel de-al doilea microfon nu mai este de neglijat comportarea acestui algoritm este mult înrăutățită. În acest caz utilizarea unor scheme având în componență două filtre adaptive poate aduce o ameliorare sensibilă a calității semnalului vocal estimat.

### III.3. Îmbunătățirea raportului semnal pe zgomot utilizând două filtre

În cazul în care în semnalul captat de cel de-al doilea microfon există și o componentă a semnalului vocal vom utiliza structuri cu două filtre, fiecare structură având două intrări și două ieșiri. Metodele propuse vor fi bazate pe două scheme distincte [COM92], [YEL94], [GER95] :

- FFIS (FeedForward Implementation Scheme) (Fig. III.3)
- FBIS (FeedBack Implementation Scheme) (Fig. III.4)

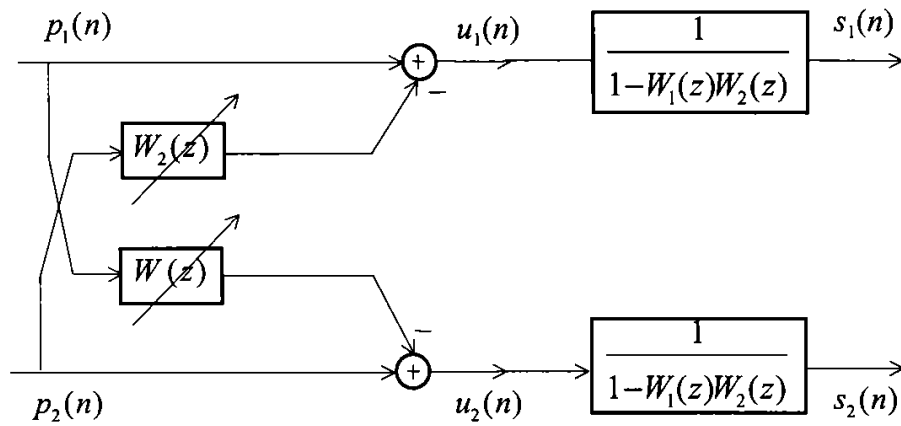


Fig. III.3 Schema FFIS (FeedForward Implementation Scheme)

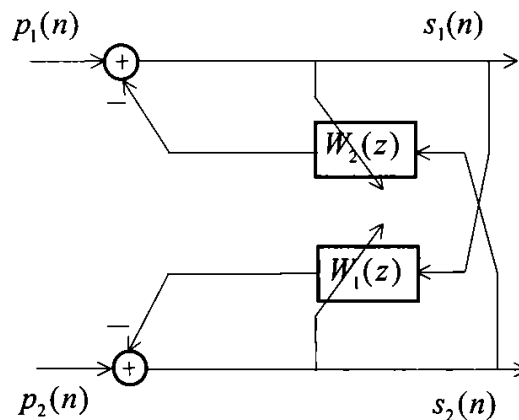


Fig. III.4 Schema FBIS (FeedBack Implementation Scheme)

În schema FFIS cele două semnale de intrare utilizate sunt semnalele captate de cele două microfoane,  $p_1(n)$  și  $p_2(n)$ , obținute cu sistemul din Fig. III.1. Semnalele intermediare  $u_1(n)$  și  $u_2(n)$  sunt :

$$u_1(n) = p_1(n) - w_2(n) * p_2(n) \quad (\text{III.12})$$

$$u_2(n) = p_2(n) - w_1(n) * p_1(n) \quad (\text{III.13})$$

Vom înlocui valorile  $p_1(n)$  și  $p_2(n)$  în ecuațiile (III.12) și (III.13) în funcție de  $s(n)$  și  $b(n)$  :

$$u_1(n) = s(n) - w_2(n) * h_1(n) * s(n) + b(n) * (h_2(n) - w_2(n)) \quad (\text{III.14})$$

$$u_2(n) = b(n) - w_1(n) * h_2(n) * b(n) + s(n) * (h_1(n) - w_1(n)) \quad (\text{III.15})$$

Obținerea a două semnale de ieșire, unul purtător de informație despre semnalul vocal și cel de-al doilea despre zgomot, conduce la două soluții posibile. Prima soluție constă în a găsi informație despre semnalul de vorbire în primul semnal de ieșire iar cea de-a doua constă în a găsi informație despre semnalul de vorbire în cel de-al doilea semnal de ieșire. Filtrele care verifică aceste soluții sunt :

$$w_1(n) = h_1(n) \quad (\text{III.16})$$

$$w_2(n) = h_2(n) \quad (\text{III.17})$$

și :

$$w_1(n) * h_2(n) = \delta(n) \quad (\text{III.18})$$

$$w_2(n) * h_1(n) = \delta(n) \quad (\text{III.19})$$

Prima soluție conduce la următoarele semnale intermediare  $u_1(n)$  și  $u_2(n)$  :

$$u_1(n) = s(n) - h_1(n) * h_2(n) * s(n) \quad (\text{III.20})$$

$$u_2(n) = b(n) - h_1(n) * h_2(n) * b(n) \quad (\text{III.21})$$

Se poate remarca că semnalele  $u_1(n)$  și  $u_2(n)$  pot fi considerate drept semnalele de ieșire ale filtrului cu răspunsul la impuls  $\delta(n) - h_1(n) * h_2(n)$  având la intrare semnalul vocal și respectiv zgomotul.

În etapa a doua pentru a estima semnalul vocal este nevoie să adăugăm încă un filtru de egalizare. Stabilitatea acestui filtru este legată de structura filtrului cu răspuns la impuls  $\delta(n) - h_1(n) * h_2(n)$ . Este necesar ca acesta să fie de fază minimă pentru a admite un filtru invers.

Relația de calcul a lui  $s_1(n)$ , care estimează semnalul de vorbire, este :

$$s_1(n) = u_1(n) + s_1(n) * w_1(n) * w_2(n) \quad (\text{III.22})$$

Putem remarca faptul că cazul în care filtrele de amestec,  $h_1(n)$  și  $h_2(n)$ , sunt filtre FIR prima soluție conduce la două filtre,  $w_1(n)$  și  $w_2(n)$ , de asemenea FIR.



Soluția a doua, prezentată prin ecuațiile (III.18) și (III.19), conduce la semnalele,  $u_1(n)$  și  $u_2(n)$ , date de relațiile (III.23) și (III.24) :

$$u_1(n) * h_1(n) = b(n) * (h_1(n) * h_2(n) - \delta(n)) \quad (\text{III.23})$$

$$u_2(n) * h_2(n) = s(n) * (h_1(n) * h_2(n) - \delta(n)) \quad (\text{III.24})$$

Putem remarca faptul căci chiar dacă cele două filtre de amestec,  $h_1(n)$  și  $h_2(n)$ , sunt filtre de tip FIR filtrele  $w_1(n)$  și  $w_2(n)$  nu sunt filtre FIR. După egalizarea cu inversul filtrului  $h_1(n) * h_2(n) - \delta(n)$  se obțin semnalele :

$$s_1(n) = b(n) * h_2(n) \quad (\text{III.25})$$

$$s_2(n) = s(n) * h_1(n) \quad (\text{III.26})$$

Pentru noi este de interes prima soluție deoarece toate filtrele sunt de tip FIR deci stabile și mai ușor de implementat adaptiv decât filtrele IIR.

Pentru schema FBIS semnalele de ieșire  $s_1(n)$  și  $s_2(n)$  sunt :

$$s_1(n) = p_1(n) - w_2(n) * s_2(n) \quad (\text{III.27})$$

$$s_2(n) = p_2(n) - w_1(n) * s_1(n) \quad (\text{III.28})$$

Dacă în (III.27) și (III.28) vom înlocui semnalele  $p_1(n)$  și  $p_2(n)$  în funcție de  $s(n)$  și  $b(n)$  obținem relațiile :

$$s_1(n) * (\delta(n) - w_1(n) * w_2(n)) = s(n) * (\delta(n) - h_1(n) * w_2(n)) - b(n) * (h_2(n) - w_2(n)) \quad (\text{III.29})$$

$$s_2(n) * (\delta(n) - w_1(n) * w_2(n)) = b(n) * (\delta(n) - w_1(n) * h_2(n)) - s(n) * (h_1(n) - w_1(n)) \quad (\text{III.30})$$

Putem vedea că putem obține două soluții care realizează separarea în (III.29) și (III.30) și anume :

$$w_1(n) = h_1(n) \quad (\text{III.31})$$

$$w_2(n) = h_2(n) \quad (\text{III.32})$$

și :

$$w_1(n) * h_2(n) = \delta(n) \quad (\text{III.33})$$

$$w_2(n) * h_1(n) = \delta(n) \quad (\text{III.34})$$

În cazul în care filtrele verifică prima soluție dată prin ecuațiile (III.31) și (III.32) semnalele  $s_1(n)$  și  $s_2(n)$  sunt :

$$s_1(n) = s(n) \quad (\text{III.35})$$

$$s_2(n) = b(n) \quad (\text{III.36})$$

Dacă se analizează stabilitatea acestei structuri se poate vedea că este legată de stabilitatea inversului filtrului cu răspunsul la impuls  $\delta(n) - h_1(n) * h_2(n)$ . Deci se ajunge la o condiție de stabilitate similară primei soluții din cazul schemei FFIS. Dacă filtrele de amestec  $h_1(n)$  și  $h_2(n)$  sunt filtre FIR atunci se ajunge la două filtre  $w_1(n)$  și  $w_2(n)$  tot FIR.

Cea de-a doua soluție prezentată prin ecuațiile (III.33) și (III.34) conduce la semnalele  $s_1(n)$  și  $s_2(n)$  :

$$s_1(n) = b(n) * h_2(n) \quad (\text{III.37})$$

$$s_2(n) = s(n) * h_1(n) \quad (\text{III.38})$$

Soluția a doua nu conduce la două filtre FIR în cazul în care filtrele de amestec sunt FIR.

Dacă examinăm cele două soluții pentru cele două scheme putem observa că se ajunge la semnale de ieșire egale obținute cu filtre egale. În cele ce urmează vom discuta câteva metode care ne permit să ajungem la aceste soluții. Evident vom căuta mai ales prima soluție care implică numai filtre FIR.

### III.3.1. Îmbunătățirea raportului semnal pe zgomot utilizând schema FFIS

După cum am văzut mai sus prin utilizarea schemei FFIS se pot separa cele două semnale. În acest paragraf vom expune câteva metode propuse în literatură pentru a realiza acest lucru. Pentru aceasta vom grupa aceste metode în două clase.

În prima clasă vom grupa acele metode care fac reactualizarea coeficienților filtrelor prin decorelarea celor două semnale intermediare. Îpoteza care permite realizarea acestei decorelări este chiar faptul că cele două semnale, semnalul vocal și zgomotul, sunt necorelate. În cea de-a doua clasă vom descrie o metodă bazată pe statisticile de ordin superior ale semnalelor intermediare. Pentru aceasta se presupune că cele două semnale nu sunt gaussiene.

### III.3.1.1. Metode bazate pe decorelarea semnalelor intermediare

În cele ce urmează vom vedea că prin căutarea unor filtre care decorelează cele două semnale intermediare se poate ajunge la prima soluție de separare, soluție dorită a fi obținută. Cele două filtre  $w_1$  și  $w_2$  se reactualizează a.î.  $u_1(n)$  și  $u_2(n)$  sa fie decorelate :

$$E\{u_1(n)u_2^*(n-k)\}=0 \quad \forall n,k \quad (\text{III.39})$$

Densitățile spectrale de putere asociate semnalelor  $u_1(n)$  și  $u_2(n)$  sunt :

$$S_{u_1u_1}(\omega) = S_{p_1p_1}(\omega) - W_2(\omega)S_{p_2p_1}(\omega) - W_2^*(\omega)S_{p_1p_2}(\omega) + |W_2(\omega)|^2 S_{p_2p_2}(\omega) \quad (\text{III.40})$$

$$S_{u_1u_2}(\omega) = S_{p_1p_2}(\omega) - W_2(\omega)S_{p_2p_2}(\omega) + W_2(\omega)W_1^*(\omega)S_{p_2p_1}(\omega) - W_1^*(\omega)S_{p_1p_1}(\omega) \quad (\text{III.41})$$

$$S_{u_2u_1}(\omega) = S_{p_2p_1}(\omega) - W_1(\omega)S_{p_1p_1}(\omega) + W_1(\omega)W_2^*(\omega)S_{p_1p_2}(\omega) - W_2^*(\omega)S_{p_2p_2}(\omega) \quad (\text{III.42})$$

$$S_{u_2u_2}(\omega) = S_{p_2p_2}(\omega) - W_1(\omega)S_{p_1p_2}(\omega) - W_1^*(\omega)S_{p_2p_1}(\omega) + |W_1(\omega)|^2 S_{p_1p_1}(\omega) \quad (\text{III.43})$$

Rezolvarea în domeniul frecvenței a ecuației (III.39) conduce la relațiile [WEI93] :

$$S_{p_2p_1}(\omega) - W_1(\omega)S_{p_1p_1}(\omega) - W_2^*(\omega)S_{p_2p_2}(\omega) + W_2^*(\omega)W_1(\omega)S_{p_1p_2}(\omega) = 0 \quad (\text{III.44})$$

$$S_{p_1p_2}(\omega) - W_2(\omega)S_{p_2p_2}(\omega) - W_1^*(\omega)S_{p_1p_1}(\omega) + W_1^*(\omega)W_2(\omega)S_{p_2p_1}(\omega) = 0 \quad (\text{III.45})$$

Soluțiile sistemului de ecuații (III.44)(III.45) sunt :

$$W_1(\omega) = \frac{S_{p_2p_1}(\omega) - W_2^*(\omega)S_{p_2p_2}(\omega)}{S_{p_1p_1}(\omega) - W_2^*(\omega)S_{p_1p_2}(\omega)} \quad (\text{III.46})$$

$$W_2(\omega) = \frac{S_{p_1p_2}(\omega) - W_1^*(\omega)S_{p_1p_1}(\omega)}{S_{p_2p_2}(\omega) - W_1^*(\omega)S_{p_2p_1}(\omega)} \quad (\text{III.47})$$

După cum se poate observa relațiile (III.46) și (III.47) nu conduc la o soluție unică. Pentru a găsi soluțiile posibile în funcție de filtrele de amestec vom înlocui în aceste relații valorile densităților spectrale de putere  $S_{p_i p_j}(\omega)$ ,  $i, j \in \{1, 2\}$  ținând seama de modelarea generării semnalelor captate și de faptul că semnalul vocal și zgomotul sunt necorelate. Se pot scrie densitățile spectrale de putere asociate semnalelor captate de cele două microfoane :

$$\begin{bmatrix} S_{p_1 p_1}(\omega) & S_{p_1 p_2}(\omega) \\ S_{p_2 p_1}(\omega) & S_{p_2 p_2}(\omega) \end{bmatrix} = \begin{bmatrix} S_{ss}(\omega) + H_2(\omega)H_2^*(\omega)S_{bb}(\omega) & H_1^*(\omega)S_{ss}(\omega) + H_2(\omega)S_{bb}(\omega) \\ H_1(\omega)S_{ss}(\omega) + H_2^*(\omega)S_{bb}(\omega) & H_1(\omega)H_1^*(\omega)S_{ss}(\omega) + S_{bb}(\omega) \end{bmatrix} \quad (\text{III.48})$$

Utilizând această ecuație matriceală se pot scrie densitățile spectrale de putere, asociate semnalelor intermediare, în funcție de densitățile spectrale, asociate semnalului vocal și zgomotului și de cele două filtre de amestec :

$$S_{u_1 u_1}(\omega) = S_{ss}(\omega)(1 - H_1(\omega)W_2(\omega))(1 - H_1^*(\omega)W_2^*(\omega)) + S_{bb}(\omega)(H_2(\omega) - W_2(\omega))(H_2^*(\omega) - W_2^*(\omega)) \quad (\text{III.49})$$

$$S_{u_1 u_2}(\omega) = S_{ss}(\omega)(1 - H_1(\omega)W_2(\omega))(H_1^*(\omega) - W_1^*(\omega)) + S_{bb}(\omega)(H_2(\omega) - W_2(\omega))(1 - H_2^*(\omega)W_1^*(\omega)) \quad (\text{III.50})$$

$$S_{u_2 u_1}(\omega) = S_{ss}(\omega)(H_1(\omega) - W_1(\omega))(1 - H_1^*(\omega)W_2^*(\omega)) + S_{bb}(\omega)(1 - H_2(\omega)W_2(\omega))(H_2^*(\omega) - W_2^*(\omega)) \quad (\text{III.51})$$

$$S_{u_2 u_2}(\omega) = S_{ss}(\omega)(H_1(\omega) - W_1(\omega))(H_1^*(\omega) - W_1^*(\omega)) + S_{bb}(\omega)(1 - H_2(\omega)W_1(\omega))(1 - H_2^*(\omega)W_1^*(\omega)) \quad (\text{III.52})$$

Se poate observa că relațiile (III.50) și (III.51) verifică :

$$S_{u_2 u_1}(\omega) = S_{u_1 u_2}^*(\omega) \quad (\text{III.53})$$

Soluția va fi multiplă deoarece avem o singură relație și avem de căutat două filtre. Ecuația (III.48) se mai poate scrie :

$$\begin{aligned} & S_{ss}(\omega)(1 - H_1(\omega)W_2(\omega))(H_1^*(\omega) - W_1^*(\omega)) - \\ & S_{bb}(\omega)(H_2(\omega) - W_2(\omega))(1 - H_2^*(\omega)W_1^*(\omega)) = 0 \end{aligned} \quad (\text{III.54})$$

Printre soluțiile acceptabile se găsește

- soluția « dorită » :

$$W_i(\omega) = H_i(\omega) \quad i \in \{1,2\} \quad (\text{III.55})$$

soluție care prezintă avantajul de a conduce la filtre FIR când filtrele de amestec sunt FIR.

- ce de-a « doua » soluție :

$$W_i(\omega) = \frac{1}{H_j(\omega)} \quad i, j \in \{1,2\}, i \neq j \quad (\text{III.56})$$

care nu conduce la filtre FIR când filtrele de amestec sunt FIR.

- soluția « degenerată » :

$$W_i(\omega) = H_i(\omega) \text{ și } W_j(\omega) = \frac{1}{H_i(\omega)} \quad i, j \in \{1,2\}, i \neq j \quad (\text{III.57})$$

soluție care conduce la o ieșire nulă și care nu conduce la filtre FIR în cazul unor filtre de amestec FIR.

- soluții care nu anulează nici un termen din (III.54) dar care anulează pe ansamblu această relație.

În acest ultim caz se poate demonstra [LIN96a][LIN97] că dacă :

1. filtrele de amestec și cele de separare sunt FIR cauzale sau anticauzale
2. filtrele de amestec verifică :

$$\begin{aligned} 1 - H_1(\omega)H_2(\omega) \text{ este de faza minimă} \\ 1 - h_1(0)h_2(0) \neq 0 \end{aligned} \quad (\text{III.58})$$

3. densitatea spectrală de putere a semnalului vocal nu este proporțională cu densitatea spectrală de putere a zgomotului :

$$\nexists k \in \mathbf{R} \text{ a.î. } \forall \omega S_{ss}(\omega) = kS_{bb}(\omega) \quad (\text{III.59})$$

atunci există soluții care să realizeze separarea surselor utilizând doar decorelația semnalelor intermediare.

În cele ce urmează vom prezenta mai mulți algoritmi care au fost propuși să separe cele două semnale.

### III.3.1.1.1. Metoda propusă de Compernelle și Gerven

Realizarea decorelării semnalelor  $u_1(n)$  și  $u_2(n)$  se face căutând iterativ soluția ecuației  $S_{u_1 u_2}(z) = 0$  [COM92][GER95]. Pentru a deduce algoritmul acestei metode vom face ipoteza simplificatoare de modelare a semnalului vocal  $s(n)$  și a zgomotului  $b(n)$  prin două zgomote albe de medii nule și varianțe  $\sigma_s^2$  și respectiv  $\sigma_b^2$ . Filtrele de amestec  $h_1$  și  $h_2$  sunt presupuse a fi filtre FIR cu  $N_1 + 1$  și respectiv  $N_2 + 1$  coeficienți. Vom căuta filtrele  $w_1$  și  $w_2$  având respectiv  $N_1 + 1$  și  $N_2 + 1$  coeficienți a.î.  $w_1 \equiv h_1$  și  $w_2 \equiv h_2$ .

În domeniul temporal decorelarea celor două semnale intermediare,  $u_1(n)$  și  $u_2(n)$ , se realizează prin anularea funcției lor de intercorelație :

$$\forall i \in \mathbf{Z} \quad \gamma_{u_1 u_2}(i) = E\{u_1(n)u_2(n-i)\} = 0 \quad (\text{III.60})$$

Presupunem că primul filtru a ajuns la prima soluție de separație  $w_1 \equiv h_1$ . Pentru a face reactualizarea lui  $w_2$  vom utiliza relația (III.60) scrisă pentru  $N_2 + 1$  valori ale lui  $i$  :

$$\gamma_{u_2 u_1}(i) = E\{u_2(n)u_1(n-i)\} = 0 \text{ pentru } 0 \leq i \leq N_2 \quad (\text{III.61})$$

Reactualizarea coeficientului  $i$  al filtrului  $w_2$  se face prin :

$$w_{2i}(n) = w_{2i}(n-1) + \mu_2 u_1(n)u_2(n-i) \quad (\text{III.62})$$

relație în care prin  $\mu_2$  am notat pasul :

$$\mu_2 = \frac{\alpha_2}{\sigma_s^2} \quad (\text{III.63})$$

În mod asemănător presupunem că cel de-al doilea filtru a ajuns la prima soluție de separație  $w_2 \equiv h_2$ . Pentru a face reactualizarea lui  $w_1$  vom utiliza relația (III.60) scrisă pentru  $N_1 + 1$  valori ale lui  $i$  :

$$\gamma_{u_2 u_1}(i) = E\{u_2(n)u_1(n-i)\} = 0 \text{ pentru } 1 \leq i \leq N_1 \quad (\text{III.64})$$

În această ultimă relație vom presupune  $i$  strict pozitiv deoarece presupunem că  $w_{10}(0) = h_1(0) = 0$  [COM92][GER95]. În acest caz reactualizarea coeficientului  $i$  al filtrului  $w_1$  se face prin :

$$w_i(n) = w_i(n-1) + \mu_1 u_2(n) u_1(n-i) \quad (\text{III.65})$$

relație în care prin  $\mu_1$  am notat pasul :

$$\mu_1 = \frac{\alpha_1}{\sigma_b^2} \quad (\text{III.66})$$

Pentru a realiza un algoritm convergent trebuie însă ca cele două filtre să convergă în același timp. Divergența unui filtru atrage divergența și a celui de-al doilea. De asemenea algoritmul poate converge și către o altă soluție decât cea « dorită ». Compemolle și Gerven au arătat existența unei posibile soluții numită « fantomă » [COMP 92] :

$$W_1(z)H_1^*(z) \cong \frac{1}{W_2^*(z)H_2(z)} \cong \frac{\sigma_b^2 + |H_1(z)|^2 \sigma_s^2}{\sigma_s^2 + |H_2(z)|^2 \sigma_b^2} \quad (\text{III.67})$$

Teoretic nu s-a găsit condițiile în care acest algoritm converge la soluția « dorită ». Experimental s-a observat că dacă filtrele de amestec  $h_1(n)$  și  $h_2(n)$  verifică relațiile [COM92]:

$$\sum_{i=1}^{N_1} h_1^2(i) < 1 \quad (\text{III.68})$$

și

$$\sum_{i=0}^{N_2} h_2^2(i) < 1 \quad (\text{III.69})$$

atunci  $W_1(z) \cong H_1(z)$  și  $W_2(z) \cong H_2(z)$ . În acest caz  $u_1(n)$  și  $u_2(n)$  sunt :

$$u_1(n) \cong s(n) - h_1(n) * h_2(n) * s(n) \quad (\text{III.70})$$

$$u_2(n) \cong b(n) - h_1(n) * h_2(n) * b(n) \quad (\text{III.71})$$

Estimarea semnalului vocal  $s(n)$  se face prin  $s_1(n)$  :

$$s_1(n) = u_1(n) + s_1(n) * w_1(n) * w_2(n) \quad (\text{III.72})$$

Pașii algoritmului sunt prezentați în tabelul III.5 :

## ALGORITM SAD

### I. INITIALIZARE

$$\mathbf{w}_1(0) = \mathbf{0}_{N_1+1}$$

$$\mathbf{w}_2(0) = \mathbf{0}_{N_2+1}$$

### II. ESTIMARE

$$u_1(n) = p_1(n) - \mathbf{w}_{2N_2+1}^T(n-1) \mathbf{p}_{2N_2+1}(n)$$

$$u_2(n) = p_2(n) - \mathbf{w}_{1N_1+1}^T(n-1) \mathbf{p}_{1N_1+1}(n)$$

### III. ADAPTARE

$$w_{1i}(n) = w_{1i}(n-1) + \mu_1 u_2(n) u_1(n-i) \text{ pentru } 1 \leq i \leq N_1$$

$$w_{2i}(n) = w_{2i}(n-1) + \mu_2 u_1(n) u_2(n-i) \text{ pentru } 0 \leq i \leq N_2$$

### IV. EGALIZARE

$$s_1(n) = u_1(n) + \sum_{i=0}^{N_2} \sum_{j=1}^{N_1} w_{2i}(n) w_{1j}(n-i+1) s_1(n-i-j+2)$$

Fig. III.5 Algoritmul SAD

#### III.3.1.1.2. Separarea surselor prin metoda propusă de Weinstein și al.

Se presupune că semnalele  $s(n)$  și  $b(n)$  sunt necorelate :

$$\forall n, i \quad E\{s(n)b(n-i)\} = 0 \quad (\text{III.73})$$

și se vor căuta acele filtre  $w_1$  și  $w_2$  pentru care semnalele intermediare  $u_1(n)$  și  $u_2(n)$  sunt la rândul lor necorelate :

$$\forall n, i \quad E\{u_1(n)u_2(n-i)\} = 0 \quad (\text{III.74})$$

În domeniul frecvențial relația (III.74) conduce la ecuațiile [WEI93] :



$$S_{p_2 p_1}(\omega) - W_1(\omega)S_{p_1 p_1}(\omega) - W_2^*(\omega)S_{p_2 p_2}(\omega) + W_2^*(\omega)W_1(\omega)S_{p_1 p_2}(\omega) = 0 \quad (\text{III.75})$$

$$S_{p_1 p_2}(\omega) - W_2(\omega)S_{p_2 p_2}(\omega) - W_1^*(\omega)S_{p_1 p_1}(\omega) + W_1^*(\omega)W_2(\omega)S_{p_2 p_1}(\omega) = 0 \quad (\text{III.76})$$

Ecuatiile (III.75) și (III.76) conduc la soluții multiple. Printre aceste soluții se găsește și soluția lui Widrow în cazul în care  $w_1(n) = 0 \forall n$  și soluția « dorită »  $w_1(n) = h_1(n)$  și  $w_2(n) = h_2(n)$  [WEI93].

Pentru a rezolva aceste ecuații se vor rescrie (III.75) și (III.76) ținând cont de :

$$\begin{bmatrix} S_{p_1 u_1} & S_{p_1 u_2} \\ S_{p_2 u_1} & S_{p_2 u_2} \end{bmatrix} = \begin{bmatrix} S_{p_1 p_1} & S_{p_1 p_2} \\ S_{p_2 p_1} & S_{p_2 p_2} \end{bmatrix} \begin{bmatrix} 1 & -W_1^*(\omega) \\ -W_2^*(\omega) & 1 \end{bmatrix} \quad (\text{III.77})$$

și se obțin relațiile [WEI93] :

$$S_{p_2 u_1}(\omega) - W_1(\omega)S_{p_1 u_1}(\omega) = 0 \quad (\text{III.78})$$

$$S_{p_1 u_2}(\omega) - W_2(\omega)S_{p_2 u_2}(\omega) = 0 \quad (\text{III.79})$$

Se vor considera filtrele de amestec  $h_1$  și  $h_2$  filtre FIR având respectiv  $N_1 + 1$  și  $N_2 + 1$  coeficienți și se vor căuta filtrele  $w_1$  și  $w_2$  având și ele respectiv  $N_1 + 1$  și  $N_2 + 1$  coeficienți. Rezolvarea ecuațiilor (III.78) și (III.79) se va face în domeniul temporal aplicând transformata Fourier inversă :

$$\gamma_{p_2 u_1}(k) - \sum_{i=0}^{N_1} w_1(i)\gamma_{p_1 u_1}(k-i) = 0 \quad k = 0, 1, \dots, N_1 \quad (\text{III.80})$$

$$\gamma_{p_1 u_2}(k) - \sum_{i=0}^{N_2} w_2(i)\gamma_{p_2 u_2}(k-i) = 0 \quad k = 0, 1, \dots, N_2 \quad (\text{III.81})$$

în care am notat prin :

$$\gamma_{u_1 u_2}(k) = E\{u_1(i)u_2^*(i-k)\} = 0 \quad k = 0, 1, \dots, N_1 \quad (\text{III.82})$$

$$\gamma_{u_2 u_1}(k) = E\{u_2(i)u_1^*(i-k)\} = 0 \quad k = 0, 1, \dots, N_2 \quad (\text{III.83})$$

Rezolvarea ecuațiilor (III.82) și (III.83), utilizând o scriere matriceală, conduce la doi algoritmi de reactualizare a coeficienților, algoritmi care în cazul în care cel de-al doilea filtru

este nă să se reducă la algoritmul LMS sau RLS. Pașii acestor algoritmi ELMS (Extension of LMS) și ERLS (Extension of RLS) sunt [WEI93]:

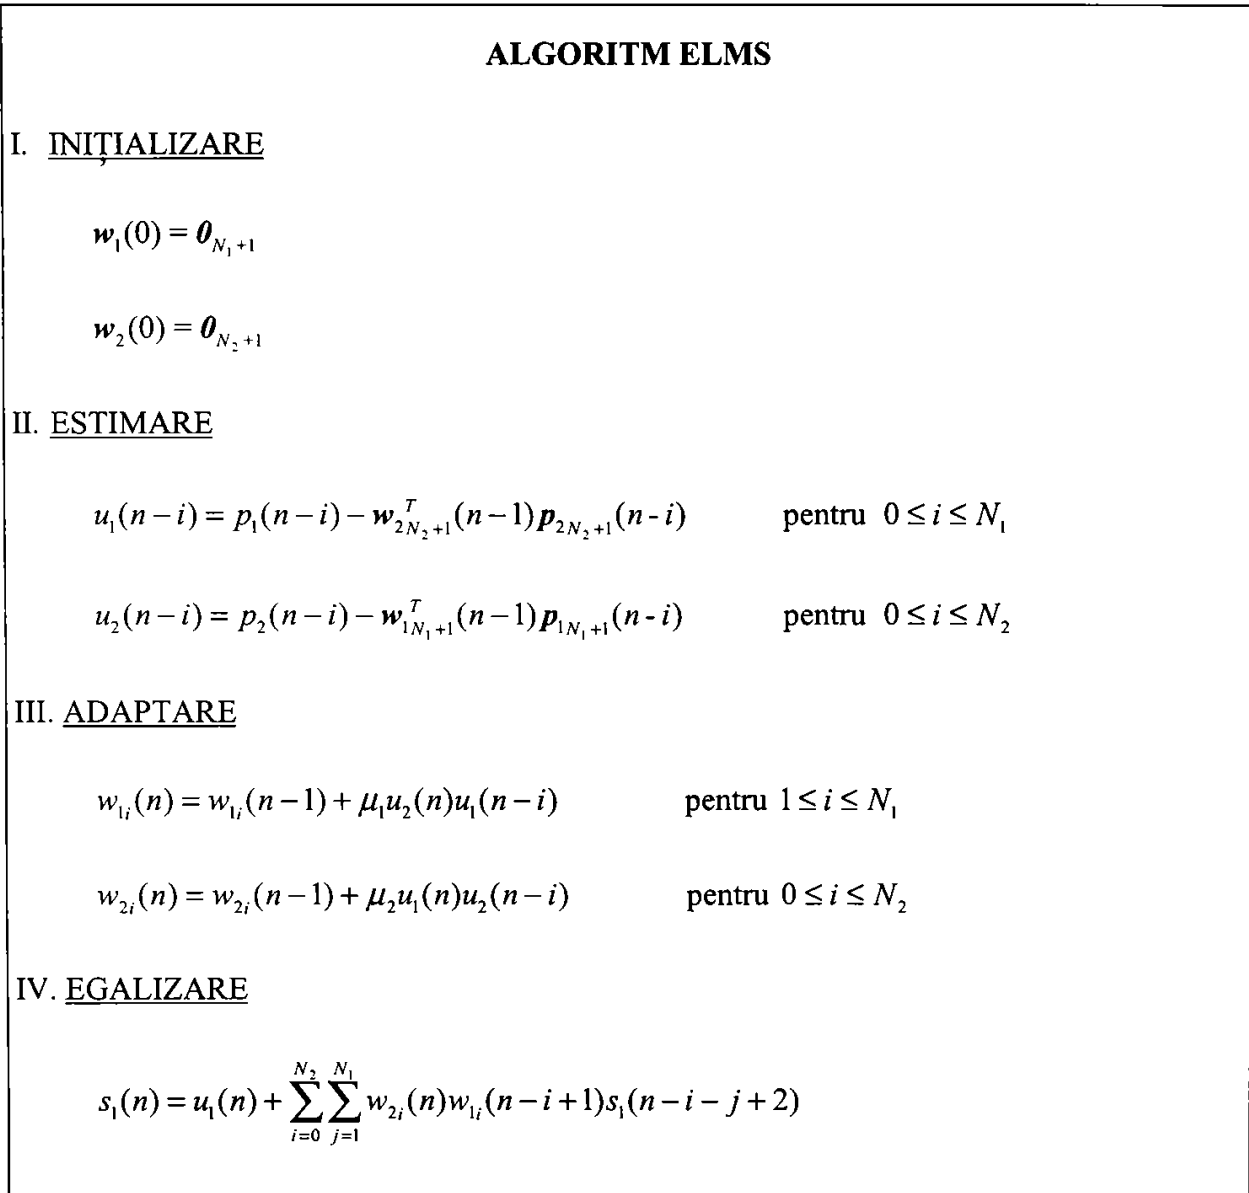


Fig. III.6 Algoritmul ELMS

Observație : Algoritmul ELMS este foarte apropiat de algoritmul SAD. Singura diferență este faptul că în acest algoritm se estimează la fiecare nou eșantion vectorii  $\mathbf{u}_{1N_1+1}(n)$  și  $\mathbf{u}_{2N_2+1}(n)$  în timp ce în SAD se estimează doar valorile curente  $u_1(n)$  și  $u_2(n)$ .

## ALGORITM ERLS

### I. INITIALIZARE

$$\mathbf{w}_1(0) = \boldsymbol{\theta}_{N_1+1}$$

$$\mathbf{w}_2(0) = \boldsymbol{\theta}_{N_2+1}$$

$$\mathbf{Q}_1(0) = \delta_1 \mathbf{I}_{N_1+1}$$

$$\mathbf{Q}_2(0) = \delta_2 \mathbf{I}_{N_2+1}$$

### II. ESTIMARE

$$u_1(n-i) = p_1(n-i) - \mathbf{w}_{2N_2+1}^T(n-1) \mathbf{p}_{2N_2+1}(n-i) \quad \text{pentru } 0 \leq i \leq N_1$$

$$u_2(n-i) = p_2(n-i) - \mathbf{w}_{1N_1+1}^T(n-1) \mathbf{p}_{1N_1+1}(n-i) \quad \text{pentru } 0 \leq i \leq N_2$$

$$\mathbf{Q}_1(n) = \frac{1}{\beta_1} \left[ \mathbf{Q}_1(n-1) - \frac{\mathbf{Q}_1(n-1) \mathbf{u}_{1N_1+1}^*(n) \mathbf{p}_{1N_1+1}^T(n) \mathbf{Q}_1(n-1)}{\beta_1 + \mathbf{p}_{1N_1+1}^T(n) \mathbf{Q}_1(n-1) \mathbf{u}_{1N_1+1}^*(n)} \right]$$

$$\mathbf{Q}_2(n) = \frac{1}{\beta_2} \left[ \mathbf{Q}_2(n-1) - \frac{\mathbf{Q}_2(n-1) \mathbf{u}_{2N_2+1}^*(n) \mathbf{p}_{2N_2+1}^T(n) \mathbf{Q}_2(n-1)}{\beta_2 + \mathbf{p}_{2N_2+1}^T(n) \mathbf{Q}_2(n-1) \mathbf{u}_{2N_2+1}^*(n)} \right]$$

### III. ADAPTARE

$$\mathbf{w}_1(n) = \mathbf{w}_1(n-1) + \mathbf{Q}_1(n) \mathbf{u}_{1N_1+1}(n) u_2(n)$$

$$\mathbf{w}_2(n) = \mathbf{w}_2(n-1) + \mathbf{Q}_2(n) \mathbf{u}_{2N_2+1}(n) u_1(n)$$

### IV. EGALIZARE

$$s_1(n) = u_1(n) + \sum_{i=0}^{N_2} \sum_{j=1}^{N_1} w_{2i}(n) w_{1j}(n-i+1) s_1(n-i-j+2)$$

Fig. III.7 Algoritmul ERLS

### III.3.1.1.3. Metoda propusă de Lindgren și al.

În această metodă se presupune că funcțiile de autocorelație, a semnalului vocal și respectiv a zgomotului, au un suport finit :

$$\forall |k| > L_1 \quad \gamma_{ss}(k) = E\{s(n)s(n-k)\} = 0 \quad (\text{III.84})$$

$$\forall |k| > L_2 \quad \gamma_{bb}(k) = E\{b(n)b(n-k)\} = 0 \quad (\text{III.85})$$

Această constrângere este destul de puternică și nerealistă. Un semnal care ar verifica această condiție ar fi un semnal obținut prin trecerea unui zgomot alb printr-un filtru FIR, deci un semnal MA (Moving Average). Semnalul de vorbire se modelează de obicei printr-un proces AR care are suportul funcției de autocorelație infinit.

Dacă semnalele  $s(n)$  și  $b(n)$  respectă condițiile (III.84) și (III.85) atunci se poate determina suportul funcției de intercorelație a semnalelor intermediare  $u_1(n)$  și  $u_2(n)$ . Pentru simplificare se consideră cele două filtre de separare fiind cauzale, FIR și având același număr de coeficienți cu filtrele de amestec. Transformata Z a funcției de intercorelație a semnalelor  $u_1(n)$  și  $u_2(n)$  are suport intervalul [LIN97] :

$$I = [\min(-L_1 - N_2, -L_2 - N_1 - N_2), \max(L_1 + N_1 + N_2, L_2 + N_2)] \quad (\text{III.86})$$

Fie  $U$  valoarea absolută maximă a marginilor acestui interval :

$$U = \max(\text{abs}(\min(-L_1 - N_2, -L_2 - N_1 - N_2), \max(L_1 + N_1 + N_2, L_2 + N_2))) \quad (\text{III.87})$$

Atunci funcția de intercorelație este :

$$\forall |k| > U \quad \gamma_{u_1 u_2}(k) = E\{u_1(n)u_2(n-k)\} = 0 \quad (\text{III.88})$$

Se poate observa că se dispune de un număr de  $2U+1$  ecuații și se caută  $N_1 + N_2$  necunoscute.

Lindgren și alții [LIN96b][LIN97] au propus minimizarea funcției  $V(\boldsymbol{\theta}(n))$  :

$$V(\boldsymbol{\theta}(n)) = \sum_{k=-U}^U (\gamma_{u_1 u_2}(k, \boldsymbol{\theta}(n)))^2 \quad (\text{III.89})$$

relație în care prin  $\boldsymbol{\theta}(n)$  am notat vectorul care conține concatenate valorile coeficienților celor două filtre de separare :

$$\theta(n) = [w_{10}(n), w_{11}(n), \dots, w_{1N_1}(n), w_{20}(n), w_{21}(n), \dots, w_{2N_2}(n)]^T \quad (\text{III.90})$$

Se poate remarca faptul că în cazul în care filtrele de separație sunt egale cu filtrele deduse pentru a obține soluția « dorită » funcția propusă a fi minimizată se anulează și se obține un minim global [LIN97].

Fie vectorii  $w_1(n)$  și  $w_2(n)$  :

$$w_1(n) = [w_{10}(n), w_{11}(n), \dots, w_{1N_1}(n)]^T \quad (\text{III.91})$$

$$w_2(n) = [w_{20}(n), w_{21}(n), \dots, w_{2N_2}(n)]^T \quad (\text{III.92})$$

Calculul funcției de intercorelație  $\gamma_{u_1 u_2}(k)$  se face cu relația [LIN97] :

$$\gamma_{u_1 u_2}(k) = \gamma_{p_1 p_2}(k) - w_2^T(n) r_{p_2 p_2}(k) - w_1^T(n) r_{p_1 p_1}(k) + w_2^T(n) R_{p_2 p_1}(k) w_1^T(n) \quad (\text{III.93})$$

relație în care am notat prin :

$$r_{p_2 p_2}(k) = [\gamma_{p_2 p_2}(k), \gamma_{p_2 p_2}(k+1), \dots, \gamma_{p_2 p_2}(k+N_2)]^T \quad (\text{III.94})$$

$$r_{p_1 p_1}(k) = [\gamma_{p_1 p_1}(k), \gamma_{p_1 p_1}(k+1), \dots, \gamma_{p_1 p_1}(k+N_1)]^T \quad (\text{III.95})$$

$$R_{p_2 p_1}(k) = \begin{bmatrix} \gamma_{p_2 p_1}(k) & \gamma_{p_2 p_1}(k+1) & \gamma_{p_2 p_1}(k+N_1) \\ \gamma_{p_2 p_1}(k+1) & \gamma_{p_2 p_1}(k+2) & \gamma_{p_2 p_1}(k+N_1+1) \\ \vdots & \vdots & \vdots \\ \gamma_{p_2 p_1}(k+N_2) & \gamma_{p_2 p_1}(k+N_2+1) & \dots & \gamma_{p_2 p_1}(k+N_1+N_2) \end{bmatrix} \quad (\text{III.96})$$

Gradientul funcției  $V(\theta(n))$  în raport cu vectorul parametrilor este [LIN97] :

$$\nabla V(\theta(n)) = 2 \sum_{k=-U}^U \frac{\gamma_{u_1 u_2}(k, \theta(n))}{\theta(n)} \gamma_{u_1 u_2}(k, \theta(n)) = 2 \sum_{k=-U}^U g(k, \theta(n)) \gamma_{u_1 u_2}(k, \theta(n)) \quad (\text{III.97})$$

relație în care  $g(k, \theta(n))$  este:

$$g(k, \theta(n)) = [g_{w_{10}}(k, \theta(n)) \quad g_{w_{1N_1}}(k, \theta(n)) \quad g_{w_{20}}(k, \theta(n)) \quad g_{w_{2N_2}}(k, \theta(n))]^T \quad (\text{III.98})$$

și :

$$g_{w_{1i}}(k, \theta(n)) = -\gamma_{p_1 p_1}(k+i) + [\gamma_{p_2 p_1}(k+i) \quad \dots \quad \gamma_{p_2 p_1}(k+i+N_2)] w_2(n) \quad (\text{III.99})$$

$$g_{w_{2i}}(k, \theta(n)) = -\gamma_{p_2 p_2}(k+i) + [\gamma_{p_2 p_1}(k+i) \quad \dots \quad \gamma_{p_2 p_1}(k+i+N_1)] w_1(n) \quad (\text{III.100})$$

Procedura de reactualizare a vectorului parametrilor este :

$$\boldsymbol{\theta}(n) = \boldsymbol{\theta}(n-1) - \mu(n)\nabla V(\boldsymbol{\theta}(n-1)) \quad (\text{III.101})$$

Pașii acestui algoritm, numit SSG (Source Separation using Gradient), sunt prezentați în tabelul de mai jos:

**ALGORITM SSG**

**I. INITIALIZARE**

$$\mathbf{w}_1(0) = \mathbf{0}_{N_1+1}$$

$$\mathbf{w}_2(0) = \mathbf{0}_{N_2+1}$$

$$\boldsymbol{\theta}(0) = [w_{10}(0), w_{12}(0), \dots, w_{1N_1}(0), w_{20}(0), w_{21}(0), \dots, w_{2N_2}(0)]^T$$

**II. ESTIMARE**

$$u_1(n) = p_1(n) - \mathbf{w}_{2N_2+1}^T(n-1)\mathbf{p}_{2N_2+1}(n)$$

$$u_2(n) = p_2(n) - \mathbf{w}_{1N_1+1}^T(n-1)\mathbf{p}_{1N_1+1}(n)$$

$$\gamma_{p_i p_j}^{(n)}(k) = \frac{n-1}{n} \gamma_{p_i p_j}^{(n-1)}(k) + \frac{1}{n} p_i(n)p_j(n-k) \quad i, j \in \{1, 2\}$$

$$\mathbf{r}_{p_2 p_2}^{(n)}(k) = [\gamma_{p_2 p_2}^{(n)}(k), \gamma_{p_2 p_2}^{(n)}(k+1), \dots, \gamma_{p_2 p_2}^{(n)}(k+N_2)]^T$$

$$\mathbf{r}_{p_1 p_1}^{(n)}(k) = [\gamma_{p_1 p_1}^{(n)}(k), \gamma_{p_1 p_1}^{(n)}(k+1), \dots, \gamma_{p_1 p_1}^{(n)}(k+N_1)]^T$$

$$\mathbf{R}_{p_2 p_1}(k) = \begin{bmatrix} \gamma_{p_2 p_1}(k) & \gamma_{p_2 p_1}(k+1) & \gamma_{p_2 p_1}(k+N_1) \\ \gamma_{p_2 p_1}(k+1) & \gamma_{p_2 p_1}(k+2) & \gamma_{p_2 p_1}(k+N_1+1) \\ \vdots & \vdots & \vdots \\ \gamma_{p_2 p_1}(k+N_2) & \gamma_{p_2 p_1}(k+N_2+1) & \dots & \gamma_{p_2 p_1}(k+N_1+N_2) \end{bmatrix}$$

$$\gamma_{u_1 u_2}^{(n)}(k) = \gamma_{p_1 p_2}^{(n)}(k) - \mathbf{w}_2^T(n-1)\mathbf{r}_{p_2 p_2}^{(n)}(k) - \mathbf{w}_1^T(n-1)\mathbf{r}_{p_1 p_1}^{(n)}(k) + \mathbf{w}_2^T(n-1)\mathbf{R}_{p_2 p_1}^{(n)}(k)\mathbf{w}_1^T(n-1)$$

$$\gamma_{w_{1i}}(k, \boldsymbol{\theta}(n-1)) = -\gamma_{p_1 p_1}^{(n)}(k+i) + [\gamma_{p_2 p_1}^{(n)}(k+i) \quad \dots \quad \gamma_{p_2 p_1}^{(n)}(k+i+N_2)]\mathbf{w}_2(n-1)$$

$$\gamma_{w_{2i}}(k, \boldsymbol{\theta}(n-1)) = -\gamma_{p_2 p_2}^{(n)}(k+i) + [\gamma_{p_2 p_1}^{(n)}(k+i) \cdots \gamma_{p_2 p_1}^{(n)}(k+i+N_1)] \mathbf{w}_1(n-1)$$

$$\mathbf{g}(k, \boldsymbol{\theta}(n-1)) =$$

$$[\mathbf{g}_{w_{10}}(k, \boldsymbol{\theta}(n-1)) \cdots \mathbf{g}_{w_{1N_1}}(k, \boldsymbol{\theta}(n-1)) \quad \mathbf{g}_{w_{20}}(k, \boldsymbol{\theta}(n-1)) \quad \mathbf{g}_{w_{2N_2}}(k, \boldsymbol{\theta}(n-1))]^T$$

$$\nabla V(\boldsymbol{\theta}(n-1)) = 2 \sum_{k=-U}^U \mathbf{g}(k, \boldsymbol{\theta}(n-1)) \gamma_{u_1 u_2}^{(n)}(k)$$

### III. ADAPTARE

$$\boldsymbol{\theta}(n) = \boldsymbol{\theta}(n-1) - \mu(n) \nabla V(\boldsymbol{\theta}(n-1))$$

$$\boldsymbol{\theta}(n) = [w_{10}(n), w_{12}(n), \dots, w_{1N_1}(n), w_{20}(n), w_{21}(n), \dots, w_{2N_2}(n)]^T$$

### IV. EGALIZARE

$$s_1(n) = u_1(n) + \sum_{i=0}^{N_2} \sum_{j=1}^{N_1} w_{2i}(n) w_{1i}(n-i+1) s_1(n-i-j+2)$$

Fig. III.8 Algoritmul SSG

Se poate arăta că în cazul în care semnalele  $s(n)$  și  $b(n)$  au aceeași culoare algoritmul SSG converge destul de lent. Pentru a mări viteza de convergență, nu numai în cazul unor semnale colorate identic, se poate utiliza algoritmul Newton pentru minimizarea funcției cost (III.89) [LIN96b][LIN97]. Matricea hessiană a lui  $V(\boldsymbol{\theta})$  necesară algoritmului Newton este :

$$\mathbf{H} = \begin{bmatrix} \frac{\partial^2 V(\boldsymbol{\theta})}{\partial \mathbf{w}_1^2} & \frac{\partial^2 V(\boldsymbol{\theta})}{\partial \mathbf{w}_1 \partial \mathbf{w}_2} \\ \frac{\partial^2 V(\boldsymbol{\theta})}{\partial \mathbf{w}_2 \partial \mathbf{w}_1} & \frac{\partial^2 V(\boldsymbol{\theta})}{\partial \mathbf{w}_2^2} \end{bmatrix} \quad (\text{III.102})$$

În cazul în care matricea hessiană necesară algoritmului Newton este negativ definită algoritmul poate să devieze de la direcția optimă de căutare a minimumului. Cum matricea (III.102) nu este întotdeauna pozitiv definită, pentru eliminarea acestui inconvenient, se poate alege următoarea matrice hessiană modificată :

$$\tilde{\mathbf{H}} = \begin{bmatrix} \frac{\partial \gamma_{u_1 u_2}(k)}{\partial \mathbf{w}_1} \left( \frac{\partial \gamma_{u_1 u_2}(k)}{\partial \mathbf{w}_1} \right)^T & \frac{\partial \gamma_{u_1 u_2}(k)}{\partial \mathbf{w}_1} \left( \frac{\partial \gamma_{u_1 u_2}(k)}{\partial \mathbf{w}_2} \right)^T \\ \frac{\partial \gamma_{u_1 u_2}(k)}{\partial \mathbf{w}_2} \left( \frac{\partial \gamma_{u_1 u_2}(k)}{\partial \mathbf{w}_1} \right)^T & \frac{\partial \gamma_{u_1 u_2}(k)}{\partial \mathbf{w}_2} \left( \frac{\partial \gamma_{u_1 u_2}(k)}{\partial \mathbf{w}_2} \right)^T \end{bmatrix}^T \quad (\text{III.103})$$

În acest caz reactualizarea vectorului parametrilor se face prin :

$$\boldsymbol{\theta}(n) = \boldsymbol{\theta}(n-1) - \mu(n) \tilde{\mathbf{H}}^{-1} \nabla V(\boldsymbol{\theta}(n-1)) \quad (\text{III.104})$$

Pașii algoritmului SSDN (Source Separation using Damped Newton Algorithm) sunt prezentați în tabelul următor :

<b>ALGORITM SSDN</b>	
<b>I. <u>INITIALIZARE</u></b>	
$\mathbf{w}_1(0) = \boldsymbol{\theta}_{N_1+1}$	
$\mathbf{w}_2(0) = \boldsymbol{\theta}_{N_2+1}$	
$\boldsymbol{\theta}(0) = [w_{10}(0), w_{12}(0), \dots, w_{1N_1}(0), w_{20}(0), w_{21}(0), \dots, w_{2N_2}(0)]^T$	
$\epsilon$	
<b>II. <u>ESTIMARE LA MOMENTUL <math>n</math></u></b>	
$u_1(n) = p_1(n) - \mathbf{w}_{2N_2+1}^T(n-1) \mathbf{p}_{2N_2+1}(n)$	
$u_2(n) = p_2(n) - \mathbf{w}_{1N_1+1}^T(n-1) \mathbf{p}_{1N_1+1}(n)$	
$\gamma_{p_i p_j}^{(n)}(k) = \frac{n-1}{n} \gamma_{p_i p_j}^{(n-1)}(k) + \frac{1}{n} p_i(n) p_j(n-k) \quad i, j \in \{1, 2\}$	
<b>III. <u>CALCUL LA MOMENTUL <math>n</math></u></b>	
$\mathbf{r}_{p_2 p_2}^{(n)}(k) = [\gamma_{p_2 p_2}^{(n)}(k), \gamma_{p_2 p_2}^{(n)}(k+1), \dots, \gamma_{p_2 p_2}^{(n)}(k+N_2)]^T$	
$\mathbf{r}_{p_1 p_1}^{(n)}(k) = [\gamma_{p_1 p_1}^{(n)}(k), \gamma_{p_1 p_1}^{(n)}(k+1), \dots, \gamma_{p_1 p_1}^{(n)}(k+N_1)]^T$	



$$\mathbf{R}_{p_2 p_1}(k) = \begin{bmatrix} \gamma_{p_2 p_1}(k) & \gamma_{p_2 p_1}(k+1) & \gamma_{p_2 p_1}(k+N_1) \\ \gamma_{p_2 p_1}(k+1) & \gamma_{p_2 p_1}(k+2) & \gamma_{p_2 p_1}(k+N_1+1) \\ \vdots & \vdots & \vdots \\ \gamma_{p_2 p_1}(k+N_2) & \gamma_{p_2 p_1}(k+N_2+1) & \cdots \gamma_{p_2 p_1}(k+N_1+N_2) \end{bmatrix}$$

$$\gamma_{u_1 u_2}^{(n)}(k) = \gamma_{p_1 p_2}^{(n)}(k) - \mathbf{w}_2^T(n-1) \mathbf{r}_{p_2 p_2}^{(n)}(k) - \mathbf{w}_1^T(n-1) \mathbf{r}_{p_1 p_1}^{(n)}(k) + \mathbf{w}_2^T(n-1) \mathbf{R}_{p_2 p_1}^{(n)}(k) \mathbf{w}_1^T(n-1)$$

$$V(\boldsymbol{\theta}(n-1)) = \sum_{k=-U}^U (\gamma_{u_1 u_2}^{(n)}(k, \boldsymbol{\theta}(n-1)))^2$$

$$\mathbf{g}_{w_{1i}}(k, \boldsymbol{\theta}(n-1)) = -\gamma_{p_1 p_1}^{(n)}(k+i) + [\gamma_{p_2 p_1}^{(n)}(k+i) \quad \gamma_{p_2 p_1}^{(n)}(k+i+N_2)] \mathbf{w}_2(n-1)^T$$

$$\mathbf{g}_{w_{2i}}(k, \boldsymbol{\theta}(n-1)) = -\gamma_{p_2 p_2}^{(n)}(k+i) + [\gamma_{p_2 p_1}^{(n)}(k+i) \quad \cdots \quad \gamma_{p_2 p_1}^{(n)}(k+i+N_1)] \mathbf{w}_1(n-1)^T$$

$$\mathbf{g}(k, \boldsymbol{\theta}(n-1)) =$$

$$[\mathbf{g}_{w_{10}}(k, \boldsymbol{\theta}(n-1)) \quad \mathbf{g}_{w_{1N_1}}(k, \boldsymbol{\theta}(n-1)) \quad \mathbf{g}_{w_{20}}(k, \boldsymbol{\theta}(n-1)) \quad \cdots \quad \mathbf{g}_{w_{2N_2}}(k, \boldsymbol{\theta}(n-1))]^T$$

$$\tilde{\mathbf{g}} = \nabla V(\boldsymbol{\theta}(n-1)) = 2 \sum_{k=-U}^U \mathbf{g}(k, \boldsymbol{\theta}(n-1)) \gamma_{u_1 u_2}^{(n)}(k)$$

$$\tilde{\mathbf{H}} = \begin{bmatrix} \frac{\partial \Phi_{u_1 u_2}^{(n)}(k)}{\partial \mathbf{w}_1} \left( \frac{\partial \Phi_{u_1 u_2}^{(n)}(k)}{\partial \mathbf{w}_1} \right)^T & \frac{\partial \Phi_{u_1 u_2}^{(n)}(k)}{\partial \mathbf{w}_1} \left( \frac{\partial \Phi_{u_1 u_2}^{(n)}(k)}{\partial \mathbf{w}_2} \right)^T \\ \frac{\partial \Phi_{u_1 u_2}^{(n)}(k)}{\partial \mathbf{w}_2} \left( \frac{\partial \Phi_{u_1 u_2}^{(n)}(k)}{\partial \mathbf{w}_1} \right)^T & \frac{\partial \Phi_{u_1 u_2}^{(n)}(k)}{\partial \mathbf{w}_2} \left( \frac{\partial \Phi_{u_1 u_2}^{(n)}(k)}{\partial \mathbf{w}_2} \right)^T \end{bmatrix}$$

$$\tilde{\boldsymbol{\theta}} = \tilde{\mathbf{H}}^{-1} \tilde{\mathbf{g}}$$

$$\mu = 1$$

Până când ( $V < V(\boldsymbol{\theta}(n-1))$ ) și ( $\mu > \varepsilon$ )

$$\tilde{\boldsymbol{\theta}} = \boldsymbol{\theta}(n-1) - \mu \tilde{\mathbf{g}}$$

$$\mu = \mu / 2$$

$$[\tilde{w}_{10}, \tilde{w}_{12}, \dots, \tilde{w}_{1N_1}, \tilde{w}_{20}, \tilde{w}_{21}, \dots, \tilde{w}_{2N_2}]^T = \tilde{\boldsymbol{\theta}}(n)$$

$$\gamma_{u_1 u_2}^{(n)}(k, \tilde{\boldsymbol{\theta}}) = \gamma_{p_1 p_2}^{(n)}(k) - \tilde{w}_2^T \mathbf{r}_{p_2 p_2}^{(n)}(k) - \tilde{w}_1^T \mathbf{r}_{p_1 p_1}^{(n)}(k) + \tilde{w}_2^T \mathbf{R}_{p_2 p_1}^{(n)}(k) \tilde{w}_1^T$$

$$V = \sum_{k=-U}^U (y_{u_1 u_2}^{(n)}(k, \tilde{\theta}))^2$$

Sfârșit

Dacă ( $V < V(\theta(n-1))$ ) atunci :

$$\theta(n) = \tilde{\theta}$$

$$[w_{10}(n), w_{12}(n), \dots, w_{1N_1}(n), w_{20}(n), w_{21}(n), \dots, w_{2N_2}(n)]^T = \theta(n)$$

Dacă nu

$$\theta(n-1) = [w_{10}(n), w_{12}(n), \dots, w_{1N_1}(n), w_{20}(n), w_{21}(n), \dots, w_{2N_2}(n)]^T$$

Sfârșit

#### IV. EGALIZARE

$$s_1(n) = u_1(n) + \sum_{i=0}^{N_2} \sum_{j=1}^{N_1} w_{2i}(n) w_{1j}(n-i+1) s_1(n-i-j+2)$$

Fig. III.9 Algoritmul SSDN

### III.3.1.2. Separarea surselor utilizând statisticile de ordin superior

După cum am văzut prin utilizarea statisticilor de ordinul doi, deci prin decorelarea celor două semnale intermediare, se ajunge la soluții multiple pentru filtrele  $w_1$  și  $w_2$ . Dacă se utilizează momentele de ordin trei sau superior lui trei se poate demonstra că se ajunge la o soluție unică. Pentru aceasta se vor presupune semnalele  $s(n)$  și  $b(n)$  necorelate până la ordinul trei inclusiv. De asemenea vom presupune semnalul vocal și zgomotul negausiene. În continuare vom reda o metodă propusă de Weinstein și Yellin [YEL94]. Această metodă arată posibilitatea separării utilizând statisticile de ordin superior însă nu precizează algoritmul de calcul. Noi am propus un algoritm, [GAB96f], de calcul care să permită identificarea filtrelor de amestec și implicit separarea semnalelor captate.

Vom scrie în domeniul frecvență sub formă matriceală semnalele captate de cele două

microfoane :

$$\begin{bmatrix} P_1(\omega) \\ P_2(\omega) \end{bmatrix} = \begin{bmatrix} 1 & H_2(\omega) \\ H_1(\omega) & 1 \end{bmatrix} \begin{bmatrix} S(\omega) \\ B(\omega) \end{bmatrix} \quad (\text{III.105})$$

Apoi vom scrie semnalele intermediare  $U_1(\omega)$  și  $U_2(\omega)$  :

$$\begin{bmatrix} U_1(\omega) \\ U_2(\omega) \end{bmatrix} = \begin{bmatrix} 1 & -W_2(\omega) \\ -W_1(\omega) & 1 \end{bmatrix} \begin{bmatrix} P_1(\omega) \\ P_2(\omega) \end{bmatrix} \quad (\text{III.106})$$

Grupând (III.105) și (III.106) obținem :

$$\begin{bmatrix} U_1(\omega) \\ U_2(\omega) \end{bmatrix} = \begin{bmatrix} T_{11}(\omega) & T_{12}(\omega) \\ T_{21}(\omega) & T_{22}(\omega) \end{bmatrix} \begin{bmatrix} S(\omega) \\ B(\omega) \end{bmatrix} \quad (\text{III.107})$$

relație în care prin  $T_{ij}(\omega)$  am notat elementele matricei de transfer a sistemului cu două intrări (semnalul vocal și zgomotul) și două iesiri (cele două semnale intermediare). Ne interesează găsirea acelor filtre  $w_1$  și  $w_2$  care să realizeze separarea semnalelor. Două soluții sunt acceptabile în acest sens. Prima soluție ar impune ca  $T_{12}(\omega) = 0$  și  $T_{21}(\omega) = 0$ , iar a doua  $T_{11}(\omega) = 0$  și  $T_{22}(\omega) = 0$ . Cum semnalul vocal și zgomotul au fost presupuse necorelate până la ordinul trei inclusiv vom căuta filtrele  $w_1$  și  $w_2$  a.î. semnalele  $u_1$  și  $u_2$  să fie necorelate până la ordinul trei inclusiv. Pentru aceasta se vor căuta filtrele pentru care cumulanții de ordin trei se anulează. Cumulantul de ordin trei a trei semnale aleatoare, de medii nule,  $x_i(n)$ ,  $x_j(n)$  și  $x_k(n)$  se definește prin :

$$\text{cum}(x_i(n), x_j(n + \tau_j), x_k(n + \tau_k)) = E\{x_i(n)x_j(n + \tau_j)x_k(n + \tau_k)\} \quad (\text{III.108})$$

Se definește bispectrul drept transformata Fourier bidimensională a cumulantului respectiv :

$$S_{x_i x_j x_k}(\omega_1, \omega_2) = \sum_{\tau_1} \sum_{\tau_2} \text{cum}(x_i(n), x_j(n + \tau_1), x_k(n + \tau_2)) e^{-j(\omega_1 \tau_1 + \omega_2 \tau_2)} \quad (\text{III.109})$$

În continuare vom considera semnalul vocal  $s(n)$  și zgomotul  $b(n)$  de medii nule, filtrele  $h_i$  și  $w_i$  ( $i \in \{1,2\}$ ) filtre FIR și atunci semnalele intermediare  $u_i$  ( $i \in \{1,2\}$ ) vor fi și ele de medie nulă. Fie următoarea teoremă [YEL94] :

Dacă  $s(n)$  și  $b(n)$  sunt două procese aleatoare pentru care putem scrie :

$$S_{s^* s s}(\omega_1, \omega_2) \neq 0 \text{ și } S_{b^* b b}(\omega_1, \omega_2) \neq 0 \quad \forall \omega_1, \omega_2 \quad (\text{III.110})$$

$$S_{s^*sb}(\omega_1, \omega_2) = 0 \text{ și } S_{b^*bs}(\omega_1, \omega_2) = 0 \quad \forall \omega_1, \omega_2 \quad (\text{III.111})$$

și dacă în plus :

$$T_{11}(0)T_{22}(0) - T_{12}(0)T_{21}(0) \neq 0 \quad (\text{III.112})$$

atunci dacă filtrele de separare  $W_i(\omega)$  ( $i \in \{1,2\}$ ) sunt alese a.î. :

$$\forall \omega_1, \omega_2 \in R \quad S_{u_i u_j}(\omega_1, \omega_2) = 0 \quad i, j \in \{1,2\}, i \neq j \quad (\text{III.113})$$

se obține fie  $T_{11}(\omega) = T_{22}(\omega) = 0$  fie  $T_{12}(\omega) = T_{21}(\omega) = 0$ .

Deci vom obține una din cele două soluții care realizează separarea spre deosebire de cazul în care se utilizau doar statisticile de ordinul doi, unde soluțiile erau multiple [WEI93].

Relația (III.113) se poate scrie în domeniul timp aplicând transformata Fourier inversă :

$$\text{cum}(u_i^*(n), u_i(n + \tau_1), u_j(n + \tau_2)) = 0 \quad \forall \tau_1, \tau_2, i \neq j, i, j \in \{1,2\} \quad (\text{III.114})$$

Vom considera filtrele  $h_i$  și  $w_i$  ( $i \in \{1,2\}$ ) cu răspuns finit la impuls fără a impune de a fi cauzale sau de fază minimă. În acest caz semnalele rezultate în urma amestecului sunt :

$$p_1(n) = s(n) - \sum_{k=h_{21}}^{h_{22}} h_2(k)b(n-k) \quad (\text{III.115})$$

$$p_2(n) = b(n) - \sum_{k=h_{11}}^{h_{12}} h_1(k)s(n-k) \quad (\text{III.116})$$

Semnalele intermediare  $u_i$  ( $i \in \{1,2\}$ ), la rândul lor, se pot scrie:

$$u_1(n) = p_1(n) - \sum_{k=w_{21}}^{w_{22}} w_2(k)p_2(n-k) \quad (\text{III.117})$$

$$u_2(n) = p_2(n) - \sum_{k=w_{11}}^{w_{12}} w_1(k)p_1(n-k) \quad (\text{III.118})$$

Vom presupune că suporturile filtrelor de amestec sunt incluse în suporturile filtrelor de separație în conformitate cu combinația corespunzătoare primei soluții :

$$[h_{11}, h_{12}] \subset [w_{11}, w_{12}] \text{ și } [h_{21}, h_{22}] \subset [w_{21}, w_{22}] \quad (\text{III.119})$$

Relațiile (III.114) se rescriu [YEL94] :

$$\text{cum}(u_2^*(n), u_2(n + \tau_1), p_1(n + \tau_2)) = \sum_{k=w_{21}}^{w_{22}} w_2(k) \text{cum}(u_2^*(n), u_2(n + \tau_1), p_2(n + \tau_2)) \quad (\text{III.120})$$

$$\text{cum}(u_1^*(n), u_1(n + \tau_1), p_2(n + \tau_2)) = \sum_{k=w_{21}}^{w_{22}} w_1(k) \text{cum}(u_1^*(n), u_1(n + \tau_1), p_1(n + \tau_2)) \quad (\text{III.121})$$

pentru  $\forall \tau_1, \tau_2$ .

Rezolvarea acestor ecuații lineare în  $w_i$  ( $i \in \{1, 2\}$ ) se va face iterativ [GAB96f]. Vom lucra cu blocuri de date de lungime  $l_b$  aleasă arbitrar. Estimarea cumulanților corespunzători noului bloc de date  $i$  se va face odată cu achiziția acestuia în funcție de cumulanții estimați pentru blocul de date anterior  $i-1$  și de datele din noul bloc. Pentru aceasta vom utiliza relațiile :

$$\begin{aligned} \text{cum}^{(i)}(u_1^*(n), u_1(n + \tau_1), p_1(n + \tau_2)) &= (1 - \lambda) \text{cum}^{(i-1)}(u_1^*(n), u_1(n + \tau_1), p_1(n + \tau_2)) + \\ &\quad \lambda \frac{1}{l_b} \sum_{k=0}^{l_b-1} u_1^*(n-k) u_1(n + \tau_1 - k) p_1(n + \tau_2 - k) \end{aligned} \quad (\text{III.122})$$

$$\begin{aligned} \text{cum}^{(i)}(u_1^*(n), u_1(n + \tau_1), p_2(n + \tau_2)) &= (1 - \lambda) \text{cum}^{(i-1)}(u_1^*(n), u_1(n + \tau_1), p_2(n + \tau_2)) + \\ &\quad \lambda \frac{1}{l_b} \sum_{k=0}^{l_b-1} u_1^*(n-k) u_1(n + \tau_1 - k) p_2(n + \tau_2 - k) \end{aligned} \quad (\text{III.123})$$

$$\begin{aligned} \text{cum}^{(i)}(u_2^*(n), u_2(n + \tau_1), p_2(n + \tau_2)) &= (1 - \lambda) \text{cum}^{(i-1)}(u_2^*(n), u_2(n + \tau_1), p_2(n + \tau_2)) + \\ &\quad \lambda \frac{1}{l_b} \sum_{k=0}^{l_b-1} u_2^*(n-k) u_2(n + \tau_1 - k) p_2(n + \tau_2 - k) \end{aligned} \quad (\text{III.124})$$

$$\begin{aligned} \text{cum}^{(i)}(u_2^*(n), u_2(n + \tau_1), p_1(n + \tau_2)) &= (1 - \lambda) \text{cum}^{(i-1)}(u_2^*(n), u_2(n + \tau_1), p_1(n + \tau_2)) + \\ &\quad \lambda \frac{1}{l_b} \sum_{k=0}^{l_b-1} u_2^*(n-k) u_2(n + \tau_1 - k) p_1(n + \tau_2 - k) \end{aligned} \quad (\text{III.125})$$

în care prin  $\lambda$  am notat factorul de uitare.

Se poate remarca faptul că utilizând (III.120) și (III.121) se pot identifica filtrele de amestec dacă avem un număr de ecuații suficient de mare, număr dependent de alegerea lui  $\tau_1$  și  $\tau_2$ . Ne vom limita doar la cazul unor filtre de amestec FIR cauzale, filtre care în acest caz verifică :

$$0 = w_{11} \leq w_{12} = N_1 \quad \text{și} \quad 0 = w_{21} \leq w_{22} = N_2 \quad (\text{III.126})$$

Valorile  $\tau_1$  și  $\tau_2$  se aleg a.î. :

$$\tau_{1\max} < \tau_1 \leq 0 \text{ și } \tau_{2\max} < \tau_2 \leq 0 \quad \tau_{1\max}, \tau_{2\max} \in \mathbf{Z} \quad (\text{III.127})$$

Astfel am obținut două sisteme liniare de ecuații în care necunoscutele sunt coeficienții filtrelor de separare. Fiecare sistem, generat de ecuațiile (III.120) sau (III.121), are  $\tau_{1\max} \tau_{2\max}$  ecuații. Sistemul generat cu (III.120) are  $N_2$  necunoscute iar cel generat cu (III.121) are  $N_1$  necunoscute. Valorile  $\tau_{1\max}, \tau_{2\max}$  sunt astfel alese pentru a obține sisteme supradeterminate. În acest caz se pot rezolva utilizând algoritmul Robbins-Monro [ROB51] presupunând că pe timpul celor  $l_b$  eșantioane coeficienții filtrelor de amestec rămân constanți. Vom nota prin :

$$\mathbf{R}_1^{(i)}(-\tau_2 - \tau_{2\max} \tau_1 + 1, k + 1) = \text{cum}^{(i)}(u_1^*(n), u_1(n + \tau_1), p_1(n + \tau_2)) \quad (\text{III.128})$$

$$\mathbf{q}_1^{(i)}(-\tau_2 - \tau_{2\max} \tau_1 + 1) = \text{cum}^{(i)}(u_1^*(n), u_1(n + \tau_1), p_2(n + \tau_2)) \quad (\text{III.129})$$

$$\mathbf{R}_2^{(i)}(-\tau_2 - \tau_{2\max} \tau_1 + 1, k + 1) = \text{cum}^{(i)}(u_2^*(n), u_2(n + \tau_1), p_2(n + \tau_2)) \quad (\text{III.130})$$

$$\mathbf{q}_2^{(i)}(-\tau_2 - \tau_{2\max} \tau_1 + 1) = \text{cum}^{(i)}(u_2^*(n), u_2(n + \tau_1), p_1(n + \tau_2)) \quad (\text{III.131})$$

Pașii algoritmului SSB (Sources Seapartion using Bispectra) [GAB96f] sunt prezenți în tabelul următor :

### ALGORITM SSB

#### I. INIȚIALIZARE

$$\mathbf{w}_1(0) = \mathbf{0}_{N_1+1}$$

$$\mathbf{w}_2(0) = \mathbf{0}_{N_2+1}$$

$$\tau_{1\max}, \tau_{2\max} \in \mathbf{Z}$$

$$\mathbf{R}_1^{(0)} = \mathbf{0}_{(\tau_{1\max} \tau_{2\max}) \times (N_1+1)}$$

$$\mathbf{q}_1^{(0)} = \mathbf{0}_{(\tau_{1\max} \tau_{2\max}) \times 1}$$

$$\mathbf{R}_2^{(0)} = \mathbf{0}_{(\tau_{1\max} \tau_{2\max}) \times (N_2+1)}$$

$$\mathbf{q}_2^{(0)} = \mathbf{0}_{(\tau_{1\max} \tau_{2\max}) \times 1}$$

## II. ESTIMARE PENTRU BLOCUL $i$

$$u_1(n) = p_1(n) - \mathbf{w}_{2N_2+1}^T(i-1) \mathbf{p}_{2N_2+1}(n)$$

$$u_2(n) = p_2(n) - \mathbf{w}_{1N_1+1}^T(i-1) \mathbf{p}_{1N_1+1}(n)$$

Pentru  $\tau_{1\max} < \tau_1 \leq 0$  și  $\tau_{2\max} < \tau_2 \leq 0$

$$\begin{aligned} \mathbf{R}_1^{(i)}(-\tau_2 - \tau_{2\max} \tau_1 + 1, k + 1) &= (1 - \lambda) \mathbf{R}_1^{(i-1)}(-\tau_2 - \tau_{2\max} \tau_1 + 1, k + 1) + \\ &\lambda \sum_{j=0}^{l_b-1} u_1^*(n-j) u_1(n + \tau_1 - j) p_1(n + \tau_2 - j) \quad N_1 \leq k \leq 0 \end{aligned}$$

$$\begin{aligned} \mathbf{q}_1^{(i)}(-\tau_2 - \tau_{2\max} \tau_1 + 1) &= (1 - \lambda) \mathbf{q}_1^{(i-1)}(-\tau_2 - \tau_{2\max} \tau_1 + 1) + \\ &\lambda \sum_{j=0}^{l_b-1} u_1^*(n-j) u_1(n + \tau_1 - j) p_2(n + \tau_2 - j) \end{aligned}$$

$$\begin{aligned} \mathbf{R}_2^{(i)}(-\tau_2 - \tau_{2\max} \tau_1 + 1, k + 1) &= (1 - \lambda) \mathbf{R}_2^{(i-1)}(-\tau_2 - \tau_{2\max} \tau_1 + 1, k + 1) + \\ &\lambda \sum_{j=0}^{l_b-1} (u_2^*(n-j) u_2(n + \tau_1 - j) p_2(n + \tau_2 - j) \quad N_2 \leq k \leq 0 \end{aligned}$$

$$\begin{aligned} \mathbf{q}_2^{(i)}(-\tau_2 - \tau_{2\max} \tau_1 + 1) &= (1 - \lambda) \mathbf{q}_2^{(i-1)}(-\tau_2 - \tau_{2\max} \tau_1 + 1) + \\ &\lambda \sum_{j=0}^{l_b-1} u_2^*(n-j) u_2(n + \tau_1 - j) p_1(n + \tau_2 - j) \end{aligned}$$

Sfârșit

## III. ADAPTARE

$$\mathbf{w}_1(i) = \mathbf{w}_1(i-1) - \mu_1 \mathbf{R}_1^H (\mathbf{R}_1^{(i)} \mathbf{w}_1(i-1) - \mathbf{q}_1^{(i)})$$

$$\mathbf{w}_2(i) = \mathbf{w}_2(i-1) - \mu_2 \mathbf{R}_2^H (\mathbf{R}_2^{(i)} \mathbf{w}_2(i-1) - \mathbf{q}_2^{(i)})$$

## IV. EGALIZARE

$$s_1(n) = u_1(n) + \sum_{i=0}^{N_2} \sum_{j=1}^{N_1} w_{2i}(n) w_{1j}(n-i+1) s_1(n-i-j+2)$$

Fig. III.10 Algoritmul SSB

### III.3.2. Separarea surselor utilizând schema FBIS

În acest paragraf vom expune câteva metode propuse în literatură sau propuse de noi pentru a realiza acest lucru. Pentru aceasta vom grupa aceste metode în două clase.

În prima clasă vom grupa acele metode care fac reactualizarea coeficienților filtrelor prin decorelarea celor două semnale de ieșire. În cea de-a doua clasă vom grupa metodele care au în componența lor două filtre adaptive clasice.

#### III.3.2.1. Metode bazate pe decorelarea semnalelor de ieșire

În cele ce urmează vom vedea că prin căutarea unor filtre care decorelează cele două semnale de ieșire se poate ajunge la prima soluție de separare, soluție dorită a fi obținută. Vom prezenta în acest sens două metode. Prima metodă propune reactualizarea coeficienților celor două filtre de separare a.î. semnalele de ieșire să fie decorelate. Cea de a doua metodă propune anularea unei funcții rezultate ca o combinație de două funcții neliniare aplicate semnalelor de ieșire.

##### III.3.2.1.1. Metoda propusă de Gerven et Compernelle

Se consideră semnalele  $s(n)$  și  $b(n)$  nestaționare și de medii nenule. Semnalele de ieșire vor fi de asemenea nestaționare și de medii nenule cu mediile :

$$M_1(s_1(n)) = E\{s_1(n)\} \quad (\text{III.132})$$

$$M_1(s_2(n)) = E\{s_2(n)\} \quad (\text{III.133})$$

Momentele de ordinul doi al semnalelor captate de cele două microfoane sunt :

$$M_2(p_1(n)) = E\{p_1^2(n)\} \quad (\text{III.134})$$

$$M_2(p_2(n)) = E\{p_2^2(n)\} \quad (\text{III.135})$$

Criteriul utilizat va fi decorelarea celor două ieșiri [GER94] :

$$\forall i \in \mathbf{Z} \quad M_{11}(s_1(n), s_2(n-i)) = E\{[s_1(n) - E\{s_1(n)\}][s_2(n-i) - E\{s_2(n-i)\}]\} = 0 \quad (\text{III.136})$$

Estimarea momentelor se face reactualizând odată cu achiziția unui nou eșantion valoarea momentului estimată la momentul anterior. Pentru estimarea mediilor de utilizează relațiile :



$$M_1(s_1(n)) = \alpha_m M_1(s_1(n-1)) + (1 - \alpha_m) s_1(n) \quad (\text{III.137})$$

$$M_1(s_2(n)) = \alpha_m M_1(s_2(n-1)) + (1 - \alpha_m) s_2(n) \quad (\text{III.138})$$

unde prin  $\alpha_m$  am notat coeficientul care ține seama de ponderea estimatului la momentul anterior. Estimarea momentelor de ordinul doi se face cu :

$$M_2(p_1(n)) = \alpha_e M_2(p_1(n-1)) + (1 - \alpha_e) p_1^2(n) \quad (\text{III.139})$$

$$M_2(p_2(n)) = \alpha_e M_2(p_2(n-1)) + (1 - \alpha_e) p_2^2(n) \quad (\text{III.140})$$

$$M_{11}(s_1(n), s_2(n-i)) = \alpha_x M_{11}(s_1(n-1), s_2(n-i-1)) + (1 - \alpha_x)(s_1(n) - M_1(s_1(n)))(s_2(n-i) - M_1(s_2(n-i))) \quad (\text{III.141})$$

$$M_{11}(b_2(n), s_1(n-i)) = \alpha_x M_{11}(b_2(n-1), s_1(n-i-1)) + (1 - \alpha_x)(b_2(n) - M_1(b_2(n)))(s_1(n-i) - M_1(s_1(n-i))) \quad (\text{III.142})$$

În relațiile de mai sus diferitele valori ale factorilor de ponderare  $\alpha_e, \alpha_m$  și  $\alpha_x$  se aleg experimental în funcție de dinamica semnalelor utilizate.

Pașii algoritmului SADFB (Symmetric Adaptive Decorrelator using Feedback Implementation Scheme) [GER94][GER95] sunt prezentați în tabelul următor :

<b>ALGORITM SADFB</b>	
<b>I. <u>INIȚIALIZARE</u></b>	
$w_1(0) = \theta_{N_1+1}$	
$w_2(0) = \theta_{N_2+1}$	
<b>II. <u>ESTIMARE</u></b>	
$tp_1(n) = p_1(n) - \sum_{k=1}^{N_2} w_{2k}(n-1) s_2(n-k)$	
$tp_2(n) = p_2(n) - \sum_{k=1}^{N_2} w_{1k}(n-1) s_1(n-k)$	

$$s_1(n) = (tp_1(n) - w_{20}(n-1)tp_1(n)) / (1 - w_{10}(n-1)w_{20}(n-1))$$

$$s_2(n) = (tp_2(n) - w_{10}(n-1)tp_2(n)) / (1 - w_{10}(n-1)w_{20}(n-1))$$

$$M_1(s_1(n)) = \alpha_m M_1(s_1(n-1)) + (1 - \alpha_m) s_1(n)$$

$$M_1(s_2(n)) = \alpha_m M_1(s_2(n-1)) + (1 - \alpha_m) s_2(n)$$

$$M_2(p_1(n)) = \alpha_e M_2(p_1(n-1)) + (1 - \alpha_e) p_1^2(n)$$

$$M_2(p_2(n)) = \alpha_e M_2(p_2(n-1)) + (1 - \alpha_e) p_2^2(n)$$

$$M_{11}(s_1(n), s_2(n-i)) = \alpha_x M_{11}(s_1(n-1), s_2(n-i-1)) + \\ (1 - \alpha_x)(s_1(n) - M_1(s_1(n)))(s_2(n-i) - M_1(s_2(n-i)))$$

$$M_{11}(s_2(n), s_1(n-i)) = \alpha_x M_{11}(s_2(n-1), s_1(n-i-1)) + \\ (1 - \alpha_x)(s_2(n) - M_1(s_2(n)))(s_1(n-i) - M_1(s_1(n-i)))$$

### III. ADAPTARE

$$w_{1i}(n) = w_{1i}(n-1) + \mu_1 M_{11}(s_2(n) s_1(n-i)) / M_2(s_1(n)) \text{ pentru } 0 \leq i \leq N_1$$

$$w_{2i}(n) = w_{2i}(n-1) + \mu_2 M_{11}(s_1(n) s_2(n-i)) / M_2(s_2(n)) \text{ pentru } 0 \leq i \leq N_2$$

Fig. III.11 Algoritmul SADFB

#### III.3.2.1.2. Separarea surselor utilizând două funcții neliniare

În această metodă [NGU91][NGU92][NGU93][GER94] și [NGU95] semnalul vocal  $s(n)$  și zgomotul  $b(n)$  se consideră necorelate și de medii nenule, se consideră două funcții neliniare impare  $f$  și  $g$  iar filtrele  $w_1$  și  $w_2$  se aleg a.î. semnalele  $s_1(n)$  și  $s_2(n)$  să verifice relația :

$$\forall n, i \ E\{f(s_1(n))g(s_2(n-i))\} = 0 \quad (\text{III.143})$$

Alegând funcțiile  $f(.) = (.)^3$  și  $g(.) = (.)$  ecuația (III.143) revine la anularea momentelor încrucișate de ordinul patru [NGY93][GER94]. Momentele centrate de ordinul patru pentru semnalele de ieșire sunt :

$$\forall i \in \mathbf{Z} \quad M_{31}(s_1(n), s_2(n-i)) = E\{[s_1(n) - E\{s_1(n)\}]^3 [s_2(n-i) - E\{s_2(n-i)\}]\} = 0 \quad (\text{III.144})$$

$$\forall i \in \mathbf{Z} \quad M_{31}(s_2(n), s_1(n-i)) = E\{[s_2(n) - E\{s_2(n)\}]^3 [s_1(n-i) - E\{s_1(n-i)\}]\} = 0 \quad (\text{III.145})$$

iar momentele de ordin patru ale semnalelor de ieşire sunt :

$$M_4(s_1(n)) = E\{s_1^4(n)\} \quad (\text{III.146})$$

$$M_4(s_2(n)) = E\{s_2^4(n)\} \quad (\text{III.147})$$

Estimarea acestor momente se face asemănător ca și în metoda precedentă. Pașii algoritmului SSFG (Signal separation using *f* ang *g* functions) [GER94][GER95] sunt :

### ALGORITM SSFG

#### I. INITIALISARE

$$w_1(0) = \theta_{N_1+1}$$

$$w_2(0) = \theta_{N_2+1}$$

#### II. ESTIMARE

$$tp_1(n) = p_1(n) - \sum_{k=1}^{N_2} w_{2k}(n-1)s_2(n-k)$$

$$tp_2(n) = p_2(n) - \sum_{k=1}^{N_1} w_{1k}(n-1)s_1(n-k)$$

$$s_1(n) = (tp_1(n) - w_{20}(n-1)tp_1(n)) / (1 - w_{10}(n-1)w_{20}(n-1))$$

$$s_2(n) = (tp_2(n) - w_{10}(n-1)tp_2(n)) / (1 - w_{10}(n-1)w_{20}(n-1))$$

$$M_1(s_1(n)) = \alpha_m M_1(s_1(n-1)) + (1 - \alpha_m)s_1(n)$$

$$M_1(s_2(n)) = \alpha_m M_1(s_2(n-1)) + (1 - \alpha_m)s_2(n)$$

$$M_4(s_1(n)) = \alpha_e M_4(s_1(n-1)) + (1 - \alpha_e)s_1^4(n)$$

$$M_4(s_2(n)) = \alpha_e M_4(s_2(n-1)) + (1 - \alpha_e)s_2^4(n)$$

$$M_{31}(s_1(n), s_2(n-i)) = \alpha_x M_{31}(s_1(n-1), s_2(n-i-1)) + \\ (1 - \alpha_x)(s_1(n) - M_1(s_1(n)))^3 (s_2(n-i) - M_1(s_2(n-i)))$$

$$M_{31}(s_2(n), s_1(n-i)) = \alpha_x M_{11}(s_2(n-1), s_1(n-i-1)) + \\ (1 - \alpha_x)(s_2(n) - M_1(s_2(n)))^3 (s_1(n-i) - M_1(s_1(n-i)))$$

### III. ADAPTARE

$$w_{1i}(n) = w_{1i}(n-1) + \mu_1 M_{31}(s_2(n) s_1(n-i)) / M_4(s_1(n)) \text{ pentru } 0 \leq i \leq N_1$$

$$w_{2i}(n) = w_{2i}(n-1) + \mu_2 M_{31}(s_1(n) s_2(n-i)) / M_4(s_2(n)) \text{ pentru } 0 \leq i \leq N_2$$

Fig. III.12 Algoritmul SSFG

#### III.3.2.2. Separarea surselor utilizând un filtru adaptiv dublu

Vom numi filtru adaptiv dublu acel sistem cu două intrări și două ieșiri realizat după schema FBIS și în care filtrele sunt filtre adaptive clasice, fiecare filtru are semnal de intrare un semnal de ieșire al sistemului, semnal de referință unul din semnalele captate de cele două microfoane și semnal de eroare celălalt semnal de ieșire al sistemului.

În literatură a fost propusă utilizarea unui filtru adaptiv dublu de tip LMS [VAL92]. Dar nu s-a justificat cum se realizează separarea celor două semnale decât experimental.

Noi am propus utilizarea unui filtru adaptiv dublu de tip RLS sau SFTF și am găsit o explicație a convergenței acestor filtre către prima soluție de separare.

##### III.3.2.2.1. Analiza soluțiilor posibile

Deoarece cele două filtre sunt filtre adaptive putem afirma că în anumite condiții acestea vor converge către soluția optimală Wiener-Hopf. Convergența și viteza de convergență sunt legate de caracteristicile semnalelor de intrare ale acestor filtre și de parametrii fiecărui tip filtru în parte. Dacă cele două filtre converg către soluția optimală Wiener-Hopf este posibil ca în anumite condiții aceste soluții optimale să coincidă cu prima soluție de separare numită soluția « dorită » [GAB96d][GAB96e]. Semnalele  $s_1(n)$  și  $s_2(n)$  sunt :

$$s_1(n) = p_1(n) - w_2(n-1) * s_2(n) \quad (\text{III.148})$$

$$s_2(n) = p_2(n) - w_1(n-1) * s_1(n) \quad (\text{III.149})$$

Filtrul  $w_1$  este un filtru adaptiv care are la intrare semnalul  $s_1(n)$  și semnal dorit  $s_2(n)$ . Filtrul  $w_2$  este un filtru adaptiv care are la intrare semnalul  $s_2(n)$  și semnal dorit  $s_1(n)$ . Ecuațiile Wiener-Hopf scrise pentru  $w_1$  și  $w_2$  [HAY91][WID75] sunt :

$$\sum_{k=-\infty}^{\infty} w_1(k) \gamma_{s_1 s_1}(n-k) = \gamma_{p_2 s_1}(n) \text{ sau } W_1(\omega) = \frac{S_{p_2 s_1}(\omega)}{S_{s_1 s_1}(\omega)} \quad (\text{III.150})$$

$$\sum_{k=-\infty}^{\infty} w_2(k) \gamma_{s_2 s_2}(n-k) = \gamma_{p_1 s_2}(n) \text{ sau } W_2(\omega) = \frac{S_{p_1 s_2}(\omega)}{S_{s_2 s_2}(\omega)} \quad (\text{III.151})$$

Pentru a calcula filtrele  $w_1$  și  $w_2$  în sens Wiener trebuie mai întâi să estimăm densitățile spectrale de putere necesare în (III.150) și (III.151). Vom exprima cele două semnale de ieșire în funcție de semnalul vocal și de zgomot :

$$s_1(n) * (\delta(n) - w_1(n) * w_2(n)) = s(n) * (\delta(n) - h_1(n) * w_2(n)) + b(n) * (h_2(n) - w_2(n)) \quad (\text{III.152})$$

$$s_2(n) * (\delta(n) - w_1(n) * w_2(n)) = b(n) * (\delta(n) - w_1(n) * h_2(n)) + p(n) * (h_1(n) - w_1(n)) \quad (\text{III.153})$$

Vom lua în calcul cazul unor filtre cu coeficienți reali. În acest caz densitățile spectrale de putere [THE92] sunt :

$$S_{s_1 s_1}(\omega) |1 - W_1(\omega) W_2(\omega)|^2 = S_{ss}(\omega) |1 - W_2(\omega) H_1(\omega)|^2 + S_{bb}(\omega) |W_2(\omega) - H_2(\omega)|^2 \quad (\text{III.154})$$

$$S_{s_2 s_2}(\omega) |1 - W_1(\omega) W_2(\omega)|^2 = S_{bb}(\omega) |1 - W_1(\omega) H_2(\omega)|^2 + S_{ss}(\omega) |W_1(\omega) - H_1(\omega)|^2 \quad (\text{III.155})$$

Vom utiliza următoarea teoremă [THE92] :

Fie trei semnale reale  $x(n)$ ,  $y(n)$ ,  $h(n)$  și  $v(n)$  a.î. :

$$v(n) = x(n) * h(n) \quad (\text{III.156})$$

atunci se poate scrie :

$$S_{vy}(\omega) = H(\omega) S_{xy}(\omega) \quad (\text{III.157})$$

Vom nota :

$$a_1(n) = s(n) * (\delta(n) - h_1(n) * w_2(n)) + b(n) * (h_2(n) - w_2(n)) \quad (\text{III.158})$$

$$a_2(n) = b(n) * (\delta(n) - w_1(n) * h_2(n)) + s(n) * (h_1(n) - w_1(n)) \quad (\text{III.159})$$

Dacă considerăm  $[x(n), v(n), y(n), h(n)]$  corespunzător ecuațiilor (III.156)(III.157) înlocuit prin  $[s_1(n), a_1(n), p_2(n), \delta(n) - w_1(n) * w_2(n)]$  se poate scrie :

$$S_{a_1 p_2}(\omega) = (1 - W_1(\omega)W_2(\omega))S_{s_1 p_2}(\omega) \quad (\text{III.160})$$

și dacă considerăm  $[x(n), v(n), y(n), h(n)]$  corespunzător ecuațiilor (III.156)(III.157) înlocuit prin  $[b_2(n), a_2(n), p_1(n), \delta(n) - w_1(n) * w_2(n)]$  se poate scrie :

$$S_{a_2 p_1}(\omega) = (1 - W_1(\omega)W_2(\omega))S_{s_2 p_1}(\omega) \quad (\text{III.161})$$

Rescriem ecuațiile (III.160)(III.161) :

$$S_{p_2 a_1}(\omega) = (1 - W_1^*(\omega)W_2^*(\omega))S_{p_2 s_1}(\omega) \quad (\text{III.162})$$

$$S_{p_1 a_2}(\omega) = (1 - W_1^*(\omega)W_2^*(\omega))S_{p_1 b_2}(\omega) \quad (\text{III.163})$$

Vom utiliza următoarea teorema [THE92] :

Fie  $x(n), y(n)$  și  $z(n)$  trei semnale reale și  $h(n)$  și  $g(n)$  doua filtre cu coeficienți reali a.î. :

$$y(n) = h(n) * x(n) \quad (\text{III.164})$$

$$z(n) = g(n) * x(n) \quad (\text{III.165})$$

atunci :

$$S_{yz}(\omega) = H(\omega)G^*(\omega)S_{xx}(\omega) \quad (\text{III.166})$$

Ținând seama că semnalul vocal și zgomotul sunt necorelate și de propoziția enunțată mai sus pentru :

$$a_1(n) = s(n) * (\delta(n) - h_1(n) * w_2(n)) + b(n) * (h_2(n) - w_2(n)) \quad (\text{III.167})$$

$$p_2(n) = s(n) * h_1(n) + b(n) \quad (\text{III.168})$$

se scrie :

$$S_{p_2 a_1}(\omega) = S_{ss}(\omega)H_1(\omega)(1 - H_1^*(\omega)W_2^*(\omega)) + S_{bb}(\omega)(H_2^*(\omega) - W_2^*(\omega)) \quad (\text{III.169})$$

și pentru :

$$a_2(n) = s(n) * (h_1(n) - w_1(n)) + b(n) * (\delta(n) - w_1(n) * h_2(n)) \quad (\text{III.170})$$

$$p_1(n) = s(n) + b(n) * h_2(n) \quad (\text{III.171})$$

se scrie:

$$S_{p_1 a_2}(\omega) = S_{ss}(\omega)(H_1^*(\omega) - W_1^*(\omega)) + S_{bb}(\omega)H_2(\omega)(1 - H_2^*(\omega)W_1^*(\omega)) \quad (\text{III.172})$$

Vom rescrie (III.162) și (III.163) utilizând (III.171) și (III.172) :

$$S_{p_2 s_1}(\omega) = \frac{S_{ss}(\omega)H_1(\omega)(1 - H_1^*(\omega)W_2^*(\omega)) + S_{bb}(\omega)(H_2^*(\omega) - W_2^*(\omega))}{1 - W_1^*(\omega)W_2^*(\omega)} \quad (\text{III.173})$$

$$S_{p_1 s_2}(\omega) = \frac{S_{ss}(\omega)(H_1^*(\omega) - W_1^*(\omega)) + S_{bb}(\omega)H_2(\omega)(1 - H_2^*(\omega)W_1^*(\omega))}{1 - W_1^*(\omega)W_2^*(\omega)} \quad (\text{III.174})$$

Tinând seama de (150)(154) și (173) soluția Wiener-Hopf pentru  $W_1(\omega)$  devine :

$$W_1(\omega) = \frac{S_{ss}(\omega)H_1(\omega)(1 - H_1^*(\omega)W_2^*(\omega)) + S_{bb}(\omega)(H_2^*(\omega) - W_2^*(\omega))}{S_{ss}(\omega)|1 - H_1(\omega)W_2(\omega)|^2 + S_{bb}(\omega)|H_2(\omega) - W_2(\omega)|^2} (1 - W_1(\omega)W_2(\omega)) \quad (\text{III.175})$$

iar pentru  $W_2(\omega)$  , ținând seama de (III.151)(III.155) și (III.174) :

$$W_2(\omega) = \frac{S_{ss}(\omega)(H_1^*(\omega) - W_1^*(\omega)) + S_{bb}(\omega)H_2(\omega)(1 - H_2^*(\omega)W_1^*(\omega))}{S_{ss}(\omega)|H_1(\omega) - W_1(\omega)|^2 + S_{bb}(\omega)|1 - H_2(\omega)W_1(\omega)|^2} (1 - W_1(\omega)W_2(\omega)) \quad (\text{III.176})$$

Vom rescrie (III.175) și (III.176) :

$$\frac{S_{ss}(\omega)(H_1(\omega) - W_1(\omega))(1 - H_1^*(\omega)W_2^*(\omega)) + S_{bb}(\omega)(H_2^*(\omega) - W_2^*(\omega))(1 - W_1(\omega)H_2(\omega))}{S_{ss}(\omega)|1 - H_1(\omega)W_2(\omega)|^2 + S_{bb}(\omega)|H_2(\omega) - W_2(\omega)|^2} = 0 \quad (\text{III.177})$$

$$\frac{S_{ss}(\omega)(H_1^*(\omega) - W_1^*(\omega))(1 - H_1(\omega)W_2(\omega)) + S_{bb}(\omega)(H_2(\omega) - W_2(\omega))(1 - H_2^*(\omega)W_1^*(\omega))}{S_{ss}(\omega)|H_1(\omega) - W_1(\omega)|^2 + S_{bb}(\omega)|1 - H_2(\omega)W_1(\omega)|^2} = 0 \quad (\text{III.178})$$

Se poate vedea că ecuațiile (III.177) și (III.178) au numărătorii unul complexul conjugat al celuilalt. Deci, cu alte cuvinte, dispunem de o singură ecuație și avem nevoie să identificăm

două filtre. Deci mai multe seturi de soluții sunt acceptabile pentru această ecuație, dintre care amintim :

- soluția « dorită » :

$$W_i(\omega) = H_i(\omega) \quad i \in \{1,2\} \quad (\text{III.179})$$

- a « doua » soluție:

$$W_i(\omega) = \frac{1}{H_j(\omega)} \quad i, j \in \{1,2\}, i \neq j \quad (\text{III.180})$$

- soluția « degenerată » :

$$W_i(\omega) = H_i(\omega) \text{ si } W_j(\omega) = \frac{1}{H_i(\omega)} \quad i, j \in \{1,2\}, i \neq j \quad (\text{III.181})$$

Pentru noi este de dorit să obținem soluția « dorită » care este de tip FIR când filtrele de amestec sunt tot FIR.

### III.3.2.2.2. Filtrul adaptiv dublu de tip LMS

Criteriul ales este minimizarea erorilor medii pătratice  $E\{s_1^2(n)\}$  și  $E\{s_2^2(n)\}$ . Pentru aceasta se pot utiliza două filtre adaptive de tip LMS sau NLMS [WID76][WID85]. Pașii algoritmului DLMS (Double Least Mean Squares) sau DNLMS (Double Normalized Least Mean Squares) [VAL92][GER95] sunt:

#### ALGORITM DLMS și DNLMS

##### I. INIȚIALIZARE

$$w_1(0) = \mathbf{0}_{N_1+1}$$

$$w_2(0) = \mathbf{0}_{N_2+1}$$

##### II. ESTIMARE

$$tp_1(n) = p_1(n) - \sum_{k=1}^{N_2} w_{2k}(n-1)s_2(n-k)$$



$$tp_2(n) = p_2(n) - \sum_{k=1}^{N_2} w_{1k}(n-1)s_1(n-k)$$

$$s_1(n) = (tp_1(n) - w_{20}(n-1)tp_1(n)) / (1 - w_{10}(n-1)w_{20}(n-1))$$

$$s_2(n) = (tp_2(n) - w_{10}(n-1)tp_2(n)) / (1 - w_{10}(n-1)w_{20}(n-1))$$

### III. ADAPTARE

$$w_{1N_1+1}(n) = w_{1N_1+1}(n-1) + \mu_1 s_{1N_1+1}(n) s_2(n)$$

$$w_{2N_2+1}(n) = w_{2N_2+1}(n-1) + \mu_2 s_{2N_2+1}(n) s_1(n)$$

Pentru DLMS :  $\mu_1 = ct$  și  $\mu_2 = ct$

$$\text{Pentru DNLMS : } \mu_1 = \frac{\alpha_1}{\beta_1 + s_{1N_1+1}^T(n)s_{1N_1+1}(n)} \text{ și } \mu_2 = \frac{\alpha_2}{\beta_2 + s_{2N_2+1}^T(n)s_{2N_2+1}(n)}$$

Fig. III.13 Algoritmii DLMS et DNLMS

#### III.3.2.2.3. Filtrul adaptiv dublu de tip DRLS (Double Recursive Least Squares) sau DFTF (Double Fast Transversal Filter)

Criteriul ales este minimizarea sumei ponderate a pătatelor. Pentru aceasta se pot utiliza două filtre adaptive de tip RLS [ALE86]. Pașii algoritmului obținut numit DRLS (Double Recursive Least Squares) [GAB96e] sunt :

#### ALGORITM DRLS

##### I. INIȚIALIZARE

$$w_1(0) = \theta_{N_1+1}$$

$$w_2(0) = \theta_{N_2+1}$$

$$C_1(0) = \delta_1 I_{N_1+1}$$

$$\mathbf{C}_2(0) = \delta_2 \mathbf{I}_{N_2+1}$$

## II. ESTIMARE

$$tp_1(n) = p_1(n) - \sum_{k=1}^{N_2} w_{2k}(n-1)s_2(n-k)$$

$$tp_2(n) = p_2(n) - \sum_{k=1}^{N_2} w_{1k}(n-1)s_1(n-k)$$

$$s_1(n) = (tp_1(n) - w_{20}(n-1)tp_1(n)) / (1 - w_{10}(n-1)w_{20}(n-1))$$

$$s_2(n) = (tp_2(n) - w_{10}(n-1)tp_2(n)) / (1 - w_{10}(n-1)w_{20}(n-1))$$

$$\mu_1(n) = \mathbf{s}_{1N_1+1}^T(n) \mathbf{C}_1(n-1) \mathbf{s}_{1N_1+1}(n)$$

$$\mathbf{g}_{1N_1+1}(n) = \frac{\mathbf{C}_1(n-1) \mathbf{s}_{1N_1+1}(n)}{\lambda_1 + \mu_1(n)}$$

$$\mu_2(n) = \mathbf{s}_{2N_2+1}^T(n) \mathbf{C}_2(n-1) \mathbf{s}_{2N_2+1}(n)$$

$$\mathbf{g}_{2N_2+1}(n) = \frac{\mathbf{C}_2(n-1) \mathbf{s}_{2N_2+1}(n)}{\lambda_2 + \mu_2(n)}$$

## III. ADAPTARE

$$\mathbf{w}_{2N_2+1}(n) = \mathbf{w}_{2N_2+1}(n-1) + s_1(n) \mathbf{g}_{2N_2+1}(n)$$

$$\mathbf{w}_{1N_1+1}(n) = \mathbf{w}_{1N_1+1}(n-1) + s_2(n) \mathbf{g}_{1N_1+1}(n)$$

$$\mathbf{C}_2(n) = \frac{1}{\lambda_2} [\mathbf{C}_2(n-1) - \mathbf{g}_{2N_2+1}(n) \mathbf{s}_{2N_2+1}^T(n) \mathbf{C}_2(n-1)]$$

$$\mathbf{C}_1(n) = \frac{1}{\lambda_1} [\mathbf{C}_1(n-1) - \mathbf{g}_{1N_1+1}(n) \mathbf{s}_{1N_1+1}^T(n) \mathbf{C}_1(n-1)]$$

Fig. III.14 Algoritmul DRLS

Cum complexitatea de calcul, în cazul unui filtru RLS, este mare [ALE86], am înlocuit acest algoritm printr-un algoritm cu o complexitate mai mică de calcul, SFTF (Stabilised Fast Transversal Filter) propus de Benallal și Gilloire [BEN89] și rezultat prin stabilizarea pentru semnalul vocal a algoritmului FTF (Fast Transversal Filter) propus de Cioffi și Kailath [CIO84]. Pașii algoritmului DFTF (Double Fast Transversal Filter) [GAB96c] sunt :

## ALGORITM DFTF

### I. INITIALIZARE

$$\mathbf{a}_{11N_1+1}(0) = \mathbf{0}_{N_1+1}$$

$$\mathbf{b}_{11N_1+1}(0) = \mathbf{0}_{N_1+1}$$

$$\mathbf{g}_{1N_1+1}(0) = \mathbf{0}_{N_1+1}$$

$$\mathbf{w}_{1N_1+1}(0) = \mathbf{0}_{N_1+1}$$

$$\gamma_{1N_1+1}(-1) = 1$$

$$\alpha_{1N_1+1}(-1) = E_{01} \lambda_1^{N_1+1} (N_1 + 1) / 100$$

$$\mathbf{a}_{22N_2+1}(0) = \mathbf{0}_{N_2+1}$$

$$\mathbf{b}_{22N_2+1}(0) = \mathbf{0}_{N_2+1}$$

$$\mathbf{g}_{2N_2+1}(0) = \mathbf{0}_{N_2+1}$$

$$\mathbf{w}_{2N_2+1}(0) = \mathbf{0}_{N_2+1}$$

$$\gamma_{2N_2+1}(-1) = 1$$

$$\alpha_{2N_2+1}(-1) = E_{02} \lambda_2^{N_2+1} (N_2 + 1) / 100$$

## II. ESTIMARE

$$tp_1(n) = p_1(n) - \sum_{k=1}^{N_2} w_{2k}(n-1)s_2(n-k)$$

$$tp_2(n) = p_2(n) - \sum_{k=1}^{N_2} w_{1k}(n-1)s_1(n-k)$$

$$s_1(n) = (tp_1(n) - w_{20}(n-1)tp_1(n))/(1 - w_{10}(n-1)w_{20}(n-1))$$

$$s_2(n) = (tp_2(n) - w_{10}(n-1)tp_2(n))/(1 - w_{10}(n-1)w_{20}(n-1))$$

$$e_{1N_1+1}(n) = s_1(n) - \mathbf{a}_{11N_1+1}^T(n-1)s_{1N_1+1}(n-1)$$

$$\alpha_{1N_1+1}(n) = \lambda_1 \alpha_{1N_1+1}(n-1) + \gamma_{1N_1+1}(n-1)e_{1N_1+1}^2(n) + C_1$$

$$\gamma_{1N_1+2}(n) = \lambda_1 \gamma_{1N_1+1}(n-1) \frac{\alpha_{1N_1+1}(n-1)}{\alpha_{1N_1+1}(n)}$$

$$\mathbf{c}_{11N_1+2}(n) = \begin{bmatrix} 0 \\ \mathbf{c}_{1N_1+1}(n-1) \end{bmatrix} + \frac{e_{1N_1+1}(n)}{\lambda_1 \alpha_{1N_1+1}(n)} \begin{bmatrix} 1 \\ -\mathbf{a}_{11N_1+1}(n-1) \end{bmatrix}$$

$$\mathbf{a}_{11N_1+1}(n) = (1 - g_1) \{ \mathbf{a}_{1N_1+1}(n-1) - \mathbf{c}_{1N_1+1}(n-1) \gamma_{1N_1+1}(n-1) e_{1N_1+1}(n) \}$$

$$r_{1N_1+1}^c(n) = s_1(n - N_1 - 1) - \mathbf{b}_{11N_1+1}(n-1) \mathbf{s}_{1N_1+1}^T(n)$$

$$\xi_{1N_1+1}(n) = r_{1N_1+1}^c(n) + \lambda_1^{-N_1} \alpha_{1N_1+1}(n-1) \gamma_{1N_1+1}(n-1) \mathbf{c}_{11N_1+2}^{N_1+2}(n)$$

$$r_{1N_1+1}(n) = r_{1N_1+1}^c(n) + \xi_{1N_1+1}(n)$$

$$\gamma_{1N_1+1}(n) = \gamma_{1N_1+2}(n) [1 + \gamma_{1N_1+2}(n) r_{1N_1+1}(n) \mathbf{c}_{11N_1+2}^{N_1+2}(n)]^{-1}$$

$$\begin{bmatrix} \mathbf{c}_{1N_1+1}(n) \\ 0 \end{bmatrix} = \mathbf{c}_{11N_1+2}(n) - \mathbf{c}_{11N_1+2}^{N_1+2}(n) \begin{bmatrix} \mathbf{b}_{11N_1+1}(n-1) \\ 1 \end{bmatrix}$$

$$\mathbf{b}_{11N_1+1}(n) = (1 - g_1) \{ \mathbf{b}_{1N_1+1}(n-1) - \mathbf{c}_{1N_1+1}(n-1) \gamma_{1N_1+1}(n) r_{1N_1+1}(n) \}$$

$$e_{2N_2+1}(n) = s_2(n) - \mathbf{a}_{22N_2+1}^T(n-1)s_{2N_2+1}(n-1)$$

$$\alpha_{2N_2+1}(n) = \lambda_2 \alpha_{2N_2+1}(n-1) + \gamma_{2N_2+1}(n-1)e_{2N_2+1}^2(n) + C_2$$

$$\gamma_{2N_2+2}(n) = \lambda_2 \gamma_{2N_2+1}(n-1) \frac{\alpha_{2N_2+1}(n-1)}{\alpha_{2N_2+1}(n)}$$

$$\mathbf{c}_{21N_2+2}(n) = \begin{bmatrix} 0 \\ \mathbf{c}_{2N_2+1}(n-1) \end{bmatrix} + \frac{e_{2N_2+1}(n)}{\lambda_2 \alpha_{2N_2+1}(n)} \begin{bmatrix} 1 \\ -\mathbf{a}_{22N_2+1}(n-1) \end{bmatrix}$$

$$\mathbf{a}_{22N_2+1}(n) = (1 - g_2) \{ \mathbf{a}_{22N_2+1}(n-1) - \mathbf{c}_{2N_2+1}(n-1) \gamma_{2N_2+1}(n-1) e_{2N_2+1}(n) \}$$

$$r_{2N_2+1}^c(n) = s_2(n - N_2 - 1) - \mathbf{b}_{22N_2+1}(n-1) \mathbf{s}_{2N_2+1}^T(n)$$

$$\xi_{2N_2+1}(n) = r_{2N_2+1}^c(n) + \lambda_2^{-N_2} \alpha_{2N_2+1}(n-1) \gamma_{2N_2+1}(n-1) \mathbf{c}_{21N_2+2}^{N_2+2}(n)$$

$$r_{2N_2+1}(n) = r_{2N_2+1}^c(n) + \xi_{2N_2+1}(n)$$

$$\gamma_{2N_2+1}(n) = \gamma_{2N_2+2}(n) [1 + \gamma_{2N_2+2}(n) r_{2N_2+1}(n) \mathbf{c}_{21N_2+2}^{N_2+2}(n)]^{-1}$$

$$\begin{bmatrix} \mathbf{c}_{2N_2+1}(n) \\ 0 \end{bmatrix} = \mathbf{c}_{21N_2+2}(n) - \mathbf{c}_{21N_2+2}^{N_2+2}(n) \begin{bmatrix} \mathbf{b}_{22N_2+1}(n-1) \\ 1 \end{bmatrix}$$

$$\mathbf{b}_{22N_2+1}(n) = (1 - g_2) \{ \mathbf{s}_{2N_2+1}(n-1) - \mathbf{c}_{2N_2+1}(n-1) \gamma_{2N_2+1}(n) r_{2N_2+1}(n) \}$$

### III. ADAPTARE

$$\mathbf{w}_{1N_1+1}(n) = \mathbf{w}_{1N_1+1}(n-1) - \mathbf{c}_{1N_1+1}(n) s_2(n) \gamma_{1N_1+1}(n)$$

$$\mathbf{w}_{2N_2+1}(n) = \mathbf{w}_{2N_2+1}(n-1) - \mathbf{c}_{2N_2+1}(n) s_1(n) \gamma_{2N_2+1}(n)$$

Fig. III.15 Algoritm DFTF

Comparativ cu algoritmi DLMS sau DNLMS se obține o viteză de convergență mai mare, deci convergența către soluția optimală Wiener se face mai repede. În schimb crește numărul necesar de calcule la fiecare iterație.

### III.4. Concluzii

În cazul în care în semnalul captat de cel de-al doilea microfon există și o componentă a semnalului vocal  $p(n)$ , prin utilizarea unui singur filtru adaptiv pentru anularea zgomotului se obține un raport semnal pe zgomot al semnalului de ieșire egal cu inversul raportului zgomot pe semnal corespunzător semnalului captat de cel de-al doilea microfon. Astfel se poate obține un raport semnal pe zgomot al semnalului de ieșire mai mic decât raportul semnal pe zgomot al semnalului captat de primul microfon. În acest caz s-a propus utilizarea unor structuri cu două filtre adaptive. Se pot utiliza algoritmi care fac apel la statisticile de ordinul doi sau la statisticile de ordin superior. Respectând anumite condiții specifice fiecărui algoritm se ajunge la convergența către soluția « dorită ». Un studiu comparativ va fi prezentat în capitolul următor.

# CAPITOLUL IV

## Rezultate experimentale

### IV.1. Introducere

Există două domenii în prelucrarea semnalului vocal unde este necesară evaluarea calității semnalului prelucrat și anume în compresie și în îmbunătățirea raportului semnal/zgomot. Istoric vorbind, cea mai mare parte a acestor metode au fost formulate în scopul evaluării algoritmilor de compresie. Recent, datorită progresului realizat în îmbunătățirea raportului semnal/zgomot, acești algoritmi au început să fie din ce în ce mai frecvent utilizați și în cuantizarea calității algoritmilor de îmbunătățire a raportului semnal/zgomot.

Scopul acestui capitol este de a face o evaluare a algoritmilor descriși în capitolele anterioare. Evaluarea poate fi făcută utilizând criterii obiective sau criterii subiective. Testele subiective se bazează pe compararea semnalului prelucrat cu semnalul original prin audiție de una sau mai multe persoane. Acestea sunt cele mai bune criterii de evaluare dar necesită mult timp și sunt costisitoare. Testele obiective se bazează pe o comparare matematică a semnalului original cu semnalul prelucrat. Cea mai mare parte a testelor obiective folosesc o distanță matematică.

Organizarea acestui capitol este următoarea: în paragraful IV.2 vom prezenta principalele metode de evaluare folosite în literatura de specialitate, în paragraful IV.3 se vor evalua metodele care utilizează un singur captor și în paragraful IV.3 cele care utilizează doi captori.

## **IV.2. Metode de evaluare**

### **IV.2.1. Teste subiective**

Testele subiective se bazează pe opinia uneia sau mai multor persoane în urma ascultării unei fraze. Cel mai răspândit test este testul MOS (Mean Opinion Score) [IEE69] care cuantizează opinia ascultătorului în cinci nivele :

- 5. Foarte bun
- 4. Bun
- 3. Mediu
- 4. Satisfăcător
- 5. Nesatisfăcător

Procedura de evaluare este :

1. La început ascultătorul este “antrenat” fie ascultând semnalul original apoi semnalul zgomotos pentru a cunoaște valorile maxime și respectiv minime MOS, fie ascultând fraze cu un MOS cunoscut.
2. Se ascultă apoi semnalele rezultate în urma prelucrării cu mai mulți algoritmi și se va atribui pentru fiecare semnal o notă. Semnalul prelucrat cu un anumit algoritm se va asculta de mai multe ori. Ordinea de ascultare a frazelor va fi aleatoare.

Pentru a putea compara rezultatul testului efectuat cu rezultatul altui test MOS se va utiliza același semnal zgomotos. Principalul avantaj al unui astfel de test este faptul că el oferă posibilitatea ascultătorului de a alege notarea funcție de diferite distorsiuni dar prezintă în același timp dezavantajul de a da un rezultat funcție de persoanele utilizate, de experiența lor, de starea lor de oboseală și nu în ultimul rând de limba lor maternă.

Noi am făcut numai teste pur informative și am utilizat un număr redus de persoane.



## IV.2.2. Metode obiective

Datorită creșterii complexității și performanțelor algoritmilor de îmbunătățire a raportului semnal/zgomot metodele obiective au devenit indispensabile în evaluarea acestor algoritmi mai ales în condițiile în care semnalele rezultate în urma prelucrării sunt foarte asemănătoare. De asemenea acestea se pot utiliza cu succes și în alegerea parametrilor algoritmilor. Ele sunt repetabile și ușor de realizat. Cea mai mare parte a acestora fac o comparație între semnalul original și semnalul prelucrat, deci presupun disponibil semnalul original. Datorită faptului că semnalul vocal este un semnal nestaționar aceste teste comparative se fac pe perioade scurte de timp, perioade în care se poate considera staționar. Rezultatul final este o combinație a acestor rezultate intermediare.

Dintre metodele obiective mai utilizate putem aminti :

- raportul semnal/zgomot,
- distanța Itakura,
- distanțele bazate pe reprezentarea LPC,
- distanța spectrală
- distanța obiectivă globală.

Noi vom utiliza raportul semnal/zgomot și distanța Itakura.

### IV.2.2.1. Raportul semnal/zgomot

Raportul semnal/zgomot este una din cele mai utilizate metode de evaluare. Există mai multe variante de calcul a acestuia. Fie semnalul original  $s(n)$ , zgomotul aditiv  $b(n)$ , semnalul zgomotos  $y(n)$  și semnalul prelucrat  $\hat{s}(n)$  definim semnalul eroare :

$$\varepsilon(n) = s(n) - \hat{s}(n) \quad (\text{IV.1})$$

și energia acestuia :

$$E_\varepsilon = \sum_{n=0}^{N-1} \varepsilon^2(n) = \sum_{n=0}^{N-1} (s(n) - \hat{s}(n))^2 \quad (\text{IV.2})$$

relație în care prin  $N$  am notat numărul eșantioanelor disponibile.

Energia semnalului original este :

$$E_s = \sum_{n=0}^{N-1} s^2(n) \quad (\text{IV.3})$$

Se definește raportul semnal/zgomot global :

$$RSB = 10 \log_{10} \frac{E_s}{E_\epsilon} = 10 \log_{10} \frac{\sum_{n=0}^{N-1} s^2(n)}{\sum_{n=0}^{N-1} (s(n) - \hat{s}(n))^2} \quad (\text{IV.4})$$

Raportul semnal/zgomot global este ușor de calculat dar se observă căci el nu ține cont de caracterul nestaționar al semnalului vocal. Pentru a ține cont caracterul nestaționar se împart cele  $N$  eșantioane în  $M$  blocuri, se calculează raporturile semnal/zgomot pentru fiecare bloc în parte și apoi se face media acestor rapoarte. Valoarea rezultată poartă numele de raport semnal/zgomot segmental.

#### IV.2.2.2. Distanța Itakura

Vom considera semnalul vocal modelabil printr-un proces AR de ordinul  $p$ . Se vor estima parametrii acestui model atât din semnalul original  $s(n)$  cât și din semnalul prelucrat  $\hat{s}(n)$ . Fie vectorii care conțin acești parametri  $\mathbf{a}$  și  $\hat{\mathbf{a}}$ . Fie  $\mathbf{R}$  matricea de autocorelație a semnalului  $s(n)$ . Se definește distanța Itakura [DEL93] :

$$d_I(\mathbf{a}, \hat{\mathbf{a}}) = \log_{10} \left( \frac{\mathbf{a}^T \mathbf{R} \mathbf{a}}{\hat{\mathbf{a}}^T \mathbf{R} \hat{\mathbf{a}}} \right) \quad (\text{IV.5})$$

Această distanță ține seama de distorsiunile de fază și este sensibilă la poziționarea și lărgimea formanzilor din spectrul LPC. Este de remarcat faptul că această distanță nu este o metrică deoarece nu posedă proprietatea de simetrie.

### IV.3. Rezultatele evaluării : compararea metodelor monocaptor

În acest paragraf vom prezenta comparativ rezultatele obținute utilizând diferite metode în diferite condiții. Pentru o mai bună evaluare vom regiza mai multe scenarii. Pentru început vom face o comparare a diferiților algoritmi pentru un semnal captat în prezența unui zgomot alb gaussian iar apoi pentru un semnal captat în prezența unui zgomot colorat.

### IV.3.1. Cazul unui zgomot alb

Vom considera două situații :

1. – în primul caz vom testa algoritmi pentru un semnal AR, semnal staționar având spectrul mediu asemănător unui semnal vocal, contaminat cu un zgomot alb gaussian într-un raport semnal/zgomot predefinit.
2. – în cel de-al doilea caz vom testa algoritmi pentru un semnal vocal real contaminat cu un zgomot alb gaussian într-un raport semnal/zgomot predefinit.

Vom testa următorii algoritmi :

1. – metoda, bazată pe modelul AR și filtrare necauzală Wiener, propusă de Oppenheim și Lim [LIM79], metodă pe care o vom numi (O&L79)
2. – metoda, bazată pe un model AR și filtrare Kalman, propusă de Paliwal și Basu [PAL87], metodă pe care o vom numi (P&B87B)
3. – metoda, bazată pe un model AR și filtrare Kalman, propusă de Gibson, Koo și Gray [GIB91], metodă pe care o vom numi (GB91B)
4. – metoda, bazată pe un model AR și filtrare Kalman, propusă de Oppenheim, Weinstein, Zangi, Feder, și Gauger, [OPP94], metodă pe care o vom numi (OPP94)
5. – metoda, bazată pe descompunerea SVD și reprezentarea semnalului vocal printr-o sumă de sinusoid, propusă de Jensen, Hansen și Sorensen [JEN95], metodă pe care o vom numi (SVD95)
6. – metoda, bazată pe modelul AR și filtrare Kalman estimând câștigul optimal, propusă de Gabrea, Mandridake și Najim [GAB96b], metodă pe care o vom numi (M1A)
7. – metoda, bazată pe modelul AR și filtrare Kalman estimând câștigul optimal, propusă de Gabrea, Mandridake și Najim [GAB97c], metodă pe care o vom numi (M1B)
8. - metoda, bazată pe modelul AR și filtrare Kalman estimând varianțele zgomotelor, metodă propusă de Gabrea și Mandridake [GAB97b], metodă pe care o vom numi (M2)
9. – metoda, bazată pe modelul AR și filtrare Kalman estimând parametrii cu algoritmul EM, propusă de Gabrea [GAB96d], metodă pe care o vom numi (M3).

### IV.3.1.1. Cazul unui semnal AR contaminat cu un zgomot alb gaussian

În acest caz vom lua în calcul  $N=256$  eşantioane ale unui semnal AR contaminat cu un zgomot alb gaussian. Zgomotul a fost adăugat astfel încât să se obțină un raport semnal/zgomot cuprins între  $-10$  dB și  $10$  dB. Rezultatele sunt mediate utilizând 250 realizări. În tabelul IV.1 se prezintă câștigul în raport semnal/zgomot în funcție de raportul semnal/zgomot al semnalului observabil.

TABELUL IV.1

CÂȘTIGUL ÎN RAPORT SEMNAL/ZGOMOT FUNCȚIE DE RAPORTUL SEMNAL/ZGOMOT AL SEMNALULUI OBSERVABIL PENTRU DIFERIȚI ALGORITMI. SEMNAL AR. ZGOMOT ALB GAUSIAN.  $N=256$ . REZULTATE MEDII UTILIZÂND 250 REALIZARI.

RSB (dB)	CÂȘTIG RSB PENTRU DIFERIȚI ALGORITMI (dB)								
	O&L79	P&B87	GB91B	OPP94	SVD95	M1A	M1B	M2	M3
-10	7.15	11.56	10.17	10.58	8.44	9.57	7.67	9.59	5.96
-5	5.45	8.67	7.17	7.40	8.57	7.26	5.92	6.64	4.10
0	4.13	6.30	5.97	5.34	7.84	5.46	4.43	4.39	3.46
5	3.13	4.32	4.15	3.55	6.15	3.43	3.35	2.95	2.84
10	2.21	2.64	2.48	2.09	3.84	2.03	2.14	1.60	2.06
15	1.42	1.38	1.29	0.58	1.97	1.04	1.04	0.81	1.31




Fig. IV.1 : Exemplu de prelucrare a unui semnal AR contaminat cu un zgomot alb gaussian având raportul semnal/zgomot  $RSB=0$  dB utilizând algoritmul M1A

În figura IV.1 se prezintă un exemplu de prelucrare a semnalului  $y(n)$ , având un raport semnal/zgomot  $RSB=0\text{ dB}$ , utilizând algoritmul M1A.

#### IV.3.1.2. Cazul unui semnal real contaminat cu un zgomot alb gaussian

Vom considera cazul în care semnalul  $s(n)$  este semnalul corespunzător unei fraze pronunțate în franceză. Semnalul  $y(n)$  este suma dintre  $s(n)$  și un zgomot alb gaussian de medie nulă  $b(n)$  a cărui varianță s-a ales astfel încât să se obțină un raport semnal/zgomot cuprins între  $-10\text{ dB}$  și  $10\text{ dB}$ .

În tabelul IV.2 se prezintă câștigul în raport semnal/zgomot obținut.

TABELUL IV.2

CÂȘTIGUL ÎN RAPORT SEMNAL/ZGOMOT FUNCȚIE DE RAPORTUL SEMNAL/ZGOMOT AL SEMNALULUI OBSERVABIL PENTRU DIFERIȚI ALGORITMI. SEMNAL REAL. ZGOMOT ALB GAUSIAN. REZULTATE MEDII UTILIZÂND 100 REALIZĂRI.

RSB (dB)	CÂȘTIG RSB PENTRU DIFERIȚI ALGORITMI (dB)								
	INTRARE	O&L79	P&B87	GB91B	OPP94	SVD95	M1A	M1B	M2
-10	-1.58	10.92	10.06	10.62	6.94	4.41	5.70	3.34	7.08
-5	-0.85	8.54	7.46	6.64	6.55	3.91	4.63	3.24	5.21
0	-0.46	5.78	4.57	3.01	5.49	2.64	2.91	2.54	3.54
5	1.03	3.87	2.96	0.38	3.90	1.87	1.87	0.91	3.01
10	2.02	2.48	1.92	-2.69	2.88	0.90	0.74	-2.66	2.14
15	2.34	1.38	1.00	-3.98	1.95	0.10	-0.51	0.75	1.02

În figura IV.2 se prezintă un exemplu de utilizare a metodei M1A pentru un semnal de intrare  $y(n)$  având un raport semnal/zgomot  $RSB=0\text{ dB}$ . După reprezentările temporale ale semnalului de intrare și respectiv semnalului prelucrat am trasat distanțele Itakura corespunzătoare. În figura IV.3 am reprezentat spectrogramele asociate semnalelor din figura IV.2.

#### IV.3.1.3. Comentarii asupra studiului comparativ

Rezultatele studiului comparativ sunt grupate în tabelele IV.1 și IV.2.

Cele mai bune rezultate, comparând câștigul în raport semnal/zgomot, s-au obținut cu un filtru Kalman, în cazul unui semnal AR sau a unui semnal real înecat într-un zgomot alb, pentru un raport semnal/zgomot al semnalului observabil mai mic de  $5\text{ dB}$ .




Fig. IV.2 : Exemplu de prelucrare al unui semnal real contaminat cu zgomot alb având raportul semnal/zgomot  $RSB=0\text{ dB}$  utilizând algoritmul M1A

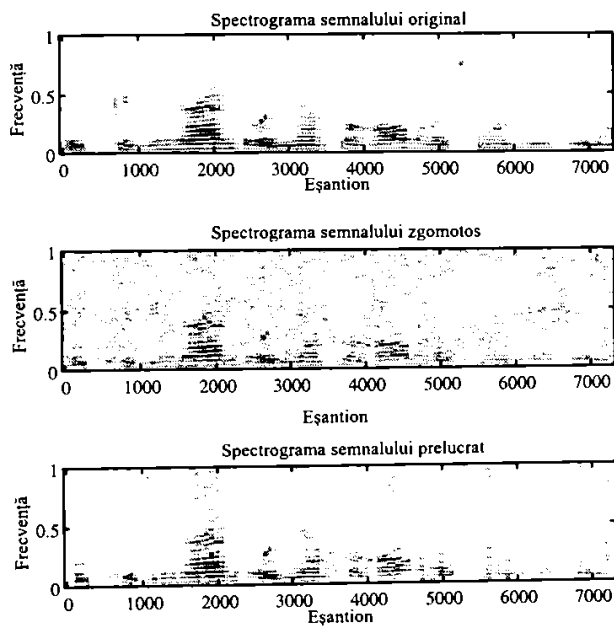


Fig. IV.3 : Spectroamele corespunzătoare semnalelor din figura IV.2

Trebuie subliniat faptul că metodele O&L79, P&B87 și GB91B au nevoie de cunoașterea varianței zgomotului aditiv. Algoritmul P&B87 oferă cele mai bune rezultate dar estimarea parametrilor semnalului vocal se face direct din semnalul vocal original, semnal indisponibil într-o situație reală. Printr-o estimare reală, pornind de la semnalul observabil, câștigul scade puțin.

Metodele propuse de noi, M1A, M1B, M2 și M3, nu mai necesită cunoașterea varianței zgomotului aditiv dar se va afecta puțin câștigul comparativ cu celelalte metode care utilizează filtrul Kalman. Se obțin rezultate superioare, comparând câștigul în raport semnal/zgomot, față de metodele O&L79 și SVD95, pentru un semnal observabil având un raport semnal/zgomot mai mic de 5 dB.

Dintre metodele propuse cel mai bine s-a comportat metoda M3, metodă care necesită mai multe calcule comparativ cu M1 și M2. Principalul avantaj al metodelor propuse de noi este eliminarea detectorului de activitate vocală necesitat de celelalte metode care utilizează un filtru Kalman pentru a putea estima pe durata pauzelor varianța zgomotului aditiv.

### IV.3.2. Cazul unui zgomot colorat

Vom considera trei situații pentru a compara diferiți algoritmi :

- 1.- în prima situație în cazul unui semnal AR, semnal staționar având spectrul asemănător unui semnal vocal, contaminat cu un zgomot colorat, staționar, modelat și el tot printr-un proces AR.
- 2.- în cea de-a doua situație în cazul unui semnal real contaminat cu un zgomot colorat, staționar, modelat printr-un proces AR.
- 3.- în cea de-a treia situație în cazul unui semnal real contaminat aditiv cu un zgomot real a cărui amplitudine se modifică pentru a avea un raport semnal/zgomot predefinit.

Algoritmi utilizați :

1. - substrația spectrală :[LEB91], metodă pe care o vom numi (SS)
2. - metoda bazată pe filtrul Wiener neacauza, metodă pe care o vom numi (FW)
3. - metoda bazată pe modelul AR și filtrare Kalman, extensia metodei propusă de Paliwal și Basu [PAL87], metodă pe care o vom numi (P&B87C)

4. - metoda bazată pe modelul AR și filtrare Kalman, propusă de Gibson, Koo și Gray [GIB91], metodă pe care o vom numi (GB91C)
5. - metoda bazată pe modelul AR și filtrare Kalman, propusă de Verbout [VER94], metodă pe care o vom numi (VER94)
6. - metoda bazată pe descompunerea QSVD și reprezentarea semnalului vocal printr-o sumă de sinusoid, propusă de Jensen, Hansen și Sorensen [JEN95], metodă pe care o vom numi (QSVD95)
7. - metoda bazată pe estimarea optimală în sensul minimizării erorii medii pătratice EQMM și reprezentarea semnalului vocal printr-o sumă de sinusoid, propusă de Ephraim și Malah [EPH84], metodă pe care o vom numi (EPH84)
8. - metoda bazată pe modelul AR și filtrare Kalman estimând câștigul optimal, propusă de Gabrea, Mandridake și Najim [GAB97a], metodă pe care o vom numi (M4)
9. - metoda bazată pe modelul AR și filtrare Kalman estimând parametrii cu ajutorul algoritmului EM, propusă de Gabrea, Mandridake și Najim [GAB96d], metodă pe care o vom numi (M5)

#### IV.3.2.1. Cazul unui semnal AR contaminat cu un zgomot colorat sintetizat printr-un proces AR

Rezultatele sunt prezentate în tabelul IV.3.

TABELUL IV.3

CÂȘTIGUL ÎN RAPORT SEMNAL/ZGOMOT FUNCȚIE DE RAPORTUL SEMNAL/ZGOMOT AL SEMNALULUI CAPTAT PENTRU DIFERIȚI ALGORITMI. SEMNAL AR. ZGOMOT AR. N=256.

REZULTATE MEDII UTILIZÂND 100 REALIZARI.

RSB (dB) INTRARE	CÂȘTIG RSB PENTRU DIFERIȚI ALGORITMI (dB)								
	SS	FW	P&B 87C	GB 91C	VER 94	QSVD 95	EPH 84	M4	M5
-5	8.62	3.22	11.87	11.25	9.49	14.74	5.67	7.76	11.35
0	7.32	3.15	9.79	9.41	8.05	12.54	4.74	6.31	9.55
5	5.51	2.66	7.72	7.43	6.38	10.55	4.99	3.70	7.58
10	3.78	2.52	5.65	5.43	4.84	8.21	4.21	2.74	5.48
15	1.92	2.05	3.83	3.74	2.91	4.93	3.17	2.81	3.77



În figura IV.4 am prezentat un exemplu de prelucrare a unui semnal AR contaminat cu un zgomot colorat având un  $RSB=0$  dB utilizând metodele M4 și M5.

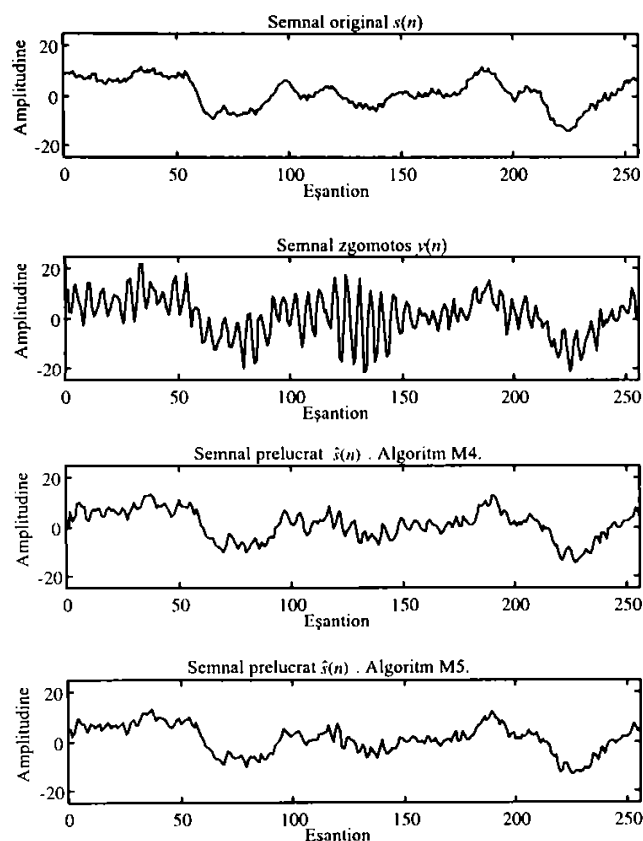


Fig. IV.4: Exemplu de prelucrare a unui semnal AR contaminat cu un zgomot colorat având un  $RSB=0$  dB utilizând metodele M4 și M5

#### IV.3.2.2. Cazul unui semnal real contaminat cu un zgomot sintetic

În acest caz se va considera un semnal real contaminat cu un zgomot modelat printr-un proces AR. În tabelul IV.4 se prezintă câștigul în raport semnal/zgomot obținut funcție de raportul semnal/zgomot al semnalului captat.

În figura IV.5 se prezintă un exemplu de prelucrare a unui semnal real contaminat cu un zgomot colorat sintetic având un  $RSB=0$  dB utilizând metoda M5.

TABELUL IV.4

CÂȘTIG ÎN RAPORT SEMNAL/ZGOMOT FUNCȚIE DE RAPORTUL SEMNAL/ZGOMOT AL SEMNALULUI CAPTAT PENTRU DIFERIȚI ALGORITMI. SEMNAL REAL. ZGOMOT AR. N=256.

REZULTATE MEDII PE UTILIZÂND 50 REALIZĂRI.

RSB (dB) INTRARE	CÂȘTIG RSB PENTRU DIFERIȚI ALGORITMI (dB)								
	SS	FW	P&B 87C	GB 91C	VER 94	QSVD 95	EPH 84	M4	M5
-5	4.84	2.88	9.83	9.54	7.89	9.88	5.49	6.90	9.63
0	4.21	2.74	7.19	6.87	5.99	7.95	4.38	6.08	7.03
5	3.41	2.12	4.82	4.39	4.23	5.27	3.24	3.57	4.44
10	2.39	1.81	2.81	2.24	2.06	1.01	2.16	2.58	2.68
15	1.78	1.29	1.33	1.07	-2.79	-3.78	1.38	-0.05	1.22




Fig. IV.5 : Exemplu de prelucrare a unui semnal real contaminat cu un zgomot sintetic având un  $RSB=0$  dB cu metoda M5

### IV.3.2.3. Cazul unui semnal real contaminat cu un zgomot real

În acest caz se consideră un semnal real contaminat cu un zgomot real, ambele făcând parte din baza de date oferită de societatea Matra. În tabelul IV.5 se prezintă câștigul în raport semnal/zgomot în funcție de raportul semnal/zgomot al semnalului zgomotos.

TABELUL IV.5

CĂȘTIG ÎN RAPORT SEMNAL/ZGOMOT FUNCȚIE DE RAPORTUL SEMNAL/ZGOMOT AL SEMNALULUI CAPTAT PENTRU DIFERIȚI ALGORITMI. SEMNAL REAL. ZGOMOT REAL.

RSB (dB)	CĂȘTIG RSB PENTRU DIFERIȚI ALGORITMI (dB)								
	SS	FW	P&B 87C	GIB 91C	VER 94	QSVD 95	EPH 84	M4	M5
-10	8.91	3.43	12.49	7.89	9.64	7.71	5.11	6.79	11.12
-5	6.42	3.14	8.84	6.24	7.03	5.84	4.33	6.09	8.17
0	3.77	2.76	5.77	4.16	3.98	3.54	3.64	3.67	4.78
5	2.98	2.14	3.46	2.35	1.34	1.76	2.81	1.12	2.89
10	1.78	1.31	1.94	1.21	-0.73	-0.37	1.63	-1.59	1.56
15	0.68	0.82	1.04	0.62	-2.70	-3.63	0.92	-4.21	0.93
20	0.29	0.46	0.54	0.31	-2.17	-2.88	0.51	-7.00	0.47




Fig. IV.6 : Exemplu de prelucrare a unui semnal real contaminat cu un zgomot real având un raport semnal/zgomot  $RSB=0$  dB utilizând metoda M5

În figura IV.6 se prezintă un exemplu de prelucrare a unui semnal real contaminat cu un zgomot real având un raport semnal/zgomot  $RSB=0 \text{ dB}$  utilizând metoda M5. După semnalul zgomotos și respectiv după semnalul rezultat în urma prelucrării am trasat distanțele Itakura corespunzătoare. În figura IV.7 am reprezentat spectrogramele asociate.

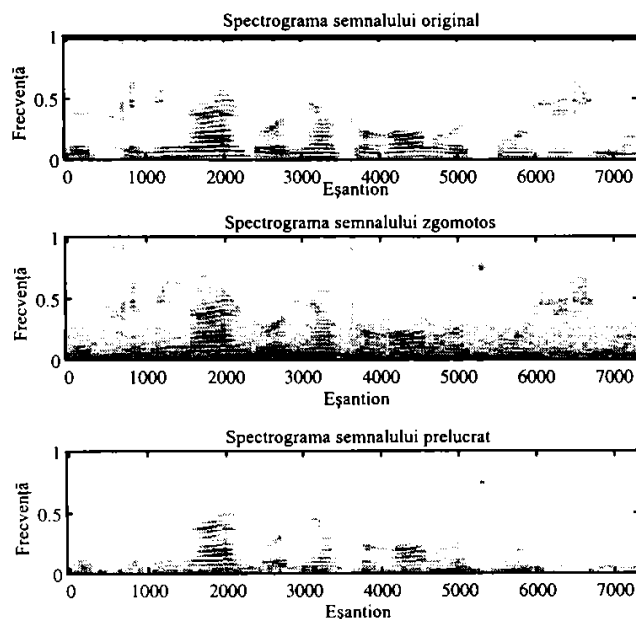


Fig. IV.7 : Spectrogramele asociate semnalelor din exemplul prezentat în figura IV.6.

#### IV.3.2.4. Comentarii asupra studiului comparativ

În studiul comparativ efectuat am utilizat 7 metode prezente în literatură, metode pe care le putem grupa în :

- metoda SS care utilizează subtracția spectrală,
- metoda WF care utilizează filtrul Wiener,
- metodele P&B87C, GIB91C și VER94 care utilizează filtrul Kalman,
- metoda QSVD95 care utilizează descompunerea în valori singulare,
- metoda EPH84 care utilizează esimarea optimală în sensul erorii medii pătratice.

Se remarcă faptul că metodele care utilizează filtrarea Kalman se află pe locul doi, comparând câștigul în raport semnal/zgomot, pentru primele două cazuri după metoda QSVD95. Dintre acestea se detașează metoda P&B87C care utilizează “parametrii ideali”, iar în cazul în care estimarea parametrilor se face direct din semnalul captat cele mai bune rezultate se obțin cu metoda GIB91C. Metoda M5 nu necesită cunoașterea prealabilă a parametrilor zgomotului dar o bună inițializare a algoritmului EM reduce numărul de iterații ale acestuia. Dacă acesta

este bine inițializat după puține iterații se obțin rezultate superioare algoritmului GIB91C. Metoda M4 are nevoie de estimări parametrilor AR atât corespunzători semnalului cât și zgomotului și nu necesită estimarea varianțelor zgomotelor generatoare corespunzătoare celor două procese AR. Estimarea acestor varianțe se face indirect prin estimarea câștigului optimal Kalman. Rezultatele acestei metode, pentru un raport semnal/zgomot mic la intrare, sunt superioare metodelor FW și EPH84.

Din tabelul IV.5 se observă că s-au obținut cele mai bune rezultate cu metoda P&B87C. Estimând parametrii semnalului direct din semnalul captat, cu metodele GIB91C și VER94, se diminuează câștigul. Metoda M5, propusă de noi, oferă un câștig superior metodei GIB91C dacă este bine inițializat algoritmul EM. Metoda M4 oferă rezultate destul de bune, puțin inferioare metodei GIB91C dar comparabile cu rezultatele altor metode care nu utilizează filtrul Kalman.

## **IV.4. Rezultatele evaluării : compararea metodelor bicaptor**

În acest paragraf vom prezenta rezultatele obținute testând metodele de prelucrare în diferite condiții experimentale. Vom introduce câteva noi mărimi care ne vor permite o mai bună evaluare a acestora.

### **IV.4.1. Criterii de evaluare suplimentare**

În cazul metodelor bicaptor vom adăuga următoarele criterii de evaluare :

- eroarea pătratică sau eroarea pătratică minimă EQM,
- interferența reziduală IR,
- eroarea parametrică pătratică EQP,
- evoluția mediei și varianței coeficienților în timp.

Se definește eroarea instantanee ca fiind diferența dintre semnalul original (semnalul sursă) și semnalul captat (semnalul prelucrat). Eroarea pătratică globală EQG este suma pătratelor erorilor instantanee pentru toate eșantioanele disponibile. Eroarea pătratică medie EQM este media erorilor instantanee medie efectuată pe mai multe realizări. Dacă nu se dispune decât de o singură realizare se aproximează media statistică cu media temporară utilizând o fereastră alunecătoare.

Interferența reziduală IR este inversa raportului semnal/zgomot, raport calculat pentru blocuri fără suprapunere de eșantioane și de lungime fixată. Se poate defini interferența reziduală medie ca fiind media pe mai multe realizări ale interferențelor reziduale.

Eroarea pătratică parametrică EQP se calculează pentru blocuri nesuprapuse și este media pătratelor diferențelor dintre coeficienții filtrelor adaptive din schemele de prelucrare și coeficienții filtrelor optimale. Media se face atât ținând seama de numărul coeficienților cât și de numărul eșantioanelor din bloc.

Evoluția mediei și varianței coeficienților în timp se face folosind mai multe realizări calculând media și dispersia coeficienților.

#### **IV.4.2. Algoritmi utilizați**

În compararea metodelor vom folosi următorii algoritmi :

1. - metoda bazată pe decorelarea semnalelor de ieșire utilizând criteriul propus de Lindgren și Broman [LIN97], metodă pe care o vom numi (SSG)
2. - metoda bazată pe decorelarea instantanee, propusă de Compernelle și Gerven [GER95], metodă pe care o vom numi (SAD)
3. - metoda bazată pe decorelarea instantanee a semnalelor de ieșire și algoritmul LMS, propusă de Weinstein, Feder și Oppenheim [WEI93], metodă pe care o vom numi (ELMS)
4. - metoda bazată pe decorelarea instantanee a semnalelor de ieșire și algoritmul RLS, propusă de Weinstein, Feder și Oppenheim [WEI93], metodă pe care o vom numi (ERLS)
5. - metoda bazată pe utilizarea a două filtre adaptive de tip LMS, propusă de Compernelle și Gerven [GER95], metodă pe care o vom numi (DLMS)
6. – metoda bazată pe utilizarea a două filtre adaptive de tip RLS, propusă de Gabrea, Mandridake și Najim [GAB96c], metodă pe care o vom numi (DFRLS)

### IV.4.3. Cazul captării a două zgomote colorate printr-un sistem având două filtre de interferență de tip FIR

Rezultatele pe care le vom prezenta în acest paragraf au fost obținute în următoarele condiții [LIN97] :

- semnalele  $p_1(n)$  și  $p_2(n)$  au fost obținute cu ajutorul filtrelor de amestec :
- $h_1=[0.7 \ 0.3]$  și  $h_2=[0 \ 0.5 \ -0.1]$ .
- semnalele  $s_1(n)$  și  $s_2(n)$  au fost obținute prin filtrarea a două zgomote albe cu ajutorul a două filtre de ordinul doi,
- zgomotele sunt de medie nulă, varianță unitară și s-au generat în 10000 puncte,
- filtrele de ordinul doi au polii situați în cercul unitar la distanțele  $r_1=r_2=0.8$  de centru cercului și unghiurile  $\varphi_1 = \pm\pi/4$  și  $\varphi_2 = \pm3\pi/4$ ,
- rezultatele sunt mediate pe 50 realizări,
- fiecare bloc are 200 de eșantioane,
- alegerea parametrilor s-a făcut comparând rezultate mediate pe 10 realizări.

Vom considera trei tipuri de distribuții ale zgomotelor albe :

1. - uniformă
2. - gaussiană
3. – exponențială

În tabelul IV.6 se prezintă câștigul în raport semnal/zgomot funcție de raportul semnal/zgomot al semnalului captat pentru cele trei tipuri de distribuție a zgomotului. De altfel am constatat că tipul distribuției influențează foarte puțin rezultatele obținute, lucru care ne-a determinat să reprezentăm doar cazul zgomotelor distribuite gaussian. Astfel în figurile IV.8 și IV.9 se reprezintă mediile coeficienților iar în figurile IV.10 și IV.11 varianțele acestora. În figura IV.12 se reprezintă interferența medie înainte și după prelucrare pentru fiecare algoritm utilizat, iar în figura IV.13 eroarea parametrică pătratică pentru fiecare algoritm.

TABELUL IV.6

CÂȘTIGUL ÎN RAPORT SEMNAL/ZGOMOT ÎN FUNCȚIE DE RAPOARTELE SEMNAL/ZGOMOT PENTRU DIFERIȚI ALGORITMI. CAZUL CAPȚĂRII A DOUĂ ZGOMOTE COLORATE PRINTR-UN SISTEM CU DOUĂ FILTRE DE INTERFERENȚĂ DE TIP FIR.

CAZ	CAPTOR	RSB (dB) INTRARE	CÂȘTIG RSB (dB) PENTRU ALGORITMI					
			SSG	SAD	ELMS	ERLS	DLMS	DRLS
1	1	4.81	20.46	19.12	19.45	19.25	19.31	22.79
	2	0.62	19.00	5.13	5.13	5.42	18.09	26.47
2	1	4.82	20.39	19.03	19.26	19.19	19.09	22.10
	2	0.61	18.74	5.14	5.13	5.39	18.07	26.20
3	1	4.82	19.92	19.09	19.28	19.13	19.11	22.76
	2	0.61	18.28	5.10	5.10	5.36	17.99	26.39




Fig. IV.8 Mediile coeficienților primului filtru






Fig. IV.9 Mediile coeficienților celui de-al doilea filtru




Fig. IV.10 Varianțele coeficienților primului filtru




Fig. IV.11 Varianțele coeficienților celui de-al doilea filtru




Fig. IV.12 Interferența reziduală




Fig. IV.13 Eroarea parametrică reziduală

Din tabelele IV.11 și IV.12 se poate remarca faptul că algoritmi SAD, ELMS și ERLS sunt mai puțin eficienți comparativ cu ceilalți algoritmi pentru îmbunătățirea raportului semnal/zgomot corespunzător semnalului celei de-a doua surse. Se constată de asemenea că rezultatele obținute cu algoritmi SAD și ELMS sunt practic aceleași. Algoritmul DRLS oferă cele mai bune rezultate referitor la câștigul în raport semnal/zgomot.

Dacă comparăm interferența reziduală constatăm superioritatea algoritmului DRLS precum și faptul că acesta nu a ajuns la convergență după 4000 de eșantioane.

Referitor la comportarea coeficienților filtrelor (fig. IV.8, IV.9, IV.12) remarcăm o mai bună convergență a algoritmului SSG față de algoritmul propus de noi DRLS. Convergența algoritmului SSG este mai lentă dar mai precisă.

#### IV.4.4. Cazul captării a două semnale PAM printr-un sistem având două filtre de interferență de tip FIR

Rezultatele pe care le vom prezenta în acest paragraf au fost obținute în următoarele condiții :

- semnalele  $p_1(n)$  și  $p_2(n)$  au fost obținute cu ajutorul filtrelor :

$$h_1 = [0.02 \ -0.025 \ 0.035 \ -0.105 \ -0.25 \ 0.36 \ 0.18 \ 0 \ 0.105 \ 0.015 \ 0.036]$$

$$h_2 = [0.2035 \ 0.4075 \ 0.2035].$$

- semnalele sursă,  $s_1(n)$  și  $s_2(n)$ , sunt două semnale 4-PAM generate în 4000 de puncte,
- fiecare sursă poate lua cu probabilitate egală unul din cele patru nivele -3, -1, 1 și 3,
- rezultatele sunt mediate pe 50 realizări,
- fiecare bloc are 100 de eșantioane,
- alegerea parametrilor s-a făcut comparând rezultatele mediate pe 10 realizări.

În tabelul IV.7 se prezintă câștigul în raport semnal/zgomot funcție de raportul semnal/zgomot al semnalului captat.

TABELUL IV.7

CÂȘTIGUL ÎN RAPORT SEMNAL/ZGOMOT ÎN FUNCȚIE DE RAPOARTELE SEMNAL/ZGOMOT PENTRU DIFERIȚI ALGORITMI. CAZUL CAPTĂRII A DOUĂ SEMNALE 4-PAM PRINTR-UN SISTEM CU DOUĂ FILTRE DE INTERFERENȚĂ DE TIP FIR.

CAPTOR	RSB (dB) INTRARE	CÂȘTIG RSB (dB) PENTRU ALGORITMI					
		SSG	SAD	ELMS	ERLS	DLMS	DRLS
1	5.99	8.51	8.45	8.74	8.54	9.00	9.36
2	6.05	9.74	3.09	3.19	3.84	10.43	10.55

În figurile IV.14 și IV.15 se reprezintă mediile, realizate utilizând 50 de realizări, a câte doi coeficienți pentru fiecare filtru. În figura IV.16 se reprezintă interferența medie înainte și după prelucrare pentru fiecare algoritm utilizat, iar în figura IV.13 eroarea parametrică pătratică pentru fiecare algoritm.




Fig. IV.14 Mediile a doi coeficienți ai primului filtru




Fig. IV.15 Mediile a doi coeficienți ai celui de-al doilea filtru




Fig. IV.16 Interferența reziduală




Fig. IV.17 Eroarea parametrică reziduală

Ca și în exemplul precedent constatăm o slabă eficacitate a algoritmilor SAD, ELMS și ERLS în îmbunătățirea raportului semnal/zgomot al semnalului captat de cel de-al doilea captor precum și comportamentul aproape identic al algoritmilor SAD și ELMS. Din punct de vedere al câștigului în raport semnal/zgomot algoritmul propus de noi, DRLS, se comportă cel mai bine dar raportat la algoritmi DLMS și SSG se câștigă mai puțin de un *dB*.

Dacă se compară interferența reziduală, se constată că algoritmul DRLS oferă cele mai bune rezultate dar algoritmul SSG deși converge mai lent după aproximativ 2000 de eșantioane devine cel mai bun. După cum am remarcat și în câștigul în raport semnal/zgomot algoritmi SAD, ELMS și ERLS oferă rezultate destul de nesatisfăcătoare chiar o tendință de divergență pentru semnalul celei de-a doua surse precum și rezultatele aproape identice ale algoritmilor SAD și ELMS.

Dacă comparăm comportarea coeficienților filtrelor (fig. IV.14, IV. 15, IV. 17) constatăm cea mai rapidă convergență a algoritmului DRLS și cea mai precisă a lui SSG.

În figura IV.18 se prezintă un exemplu de separare a două semnale 4-PAM utilizând algoritmul DRLS.

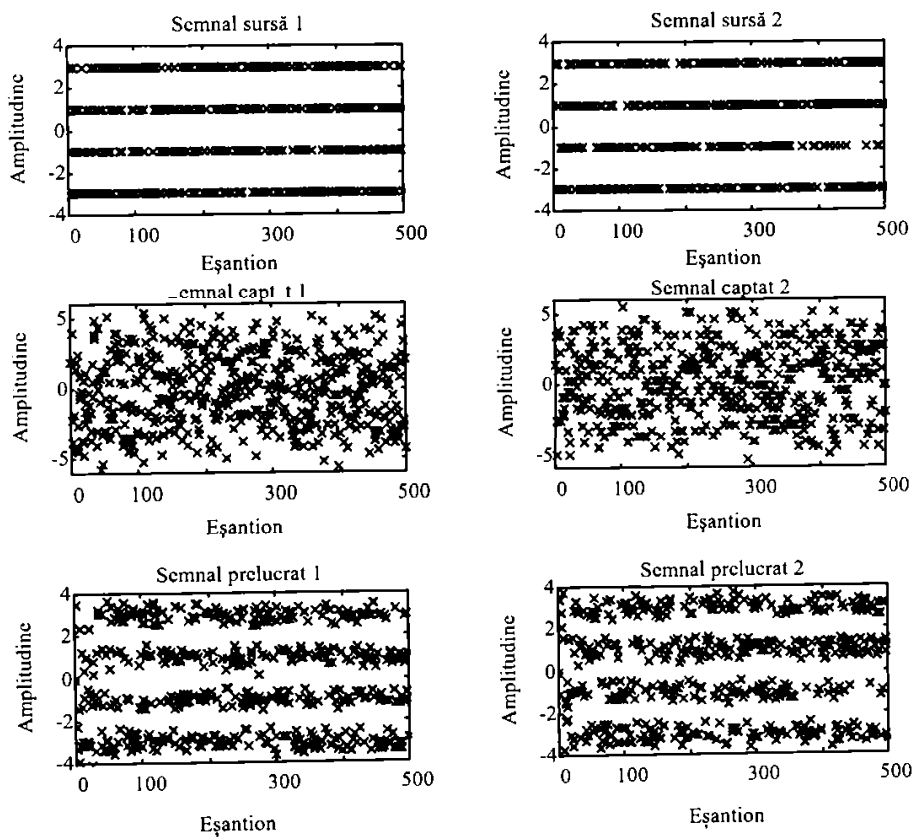


Fig. IV.18 Separarea cu ajutorul algoritmului DRLS a două semnale 4-PAM

#### IV.4.5. Cazul captării a două semnale AR printr-un sistem având două filtre de interferență de tip FIR

Rezultatele pe care le vom prezenta în acest paragraf au fost obținute în următoarele condiții :

- semnalele  $p_1(n)$  și  $p_2(n)$  au fost obținute conform relațiilor :

$$p_1(n) = s_1(n) + s_2(n)*h_2(n)$$

$$p_2(n) = s_2(n) + s_1(n)*h_1(n)$$

$$h_1 = [0.05903 \ -0.05268 \ -0.06256 \ 0.12734 \ 0.4901 \ 0.142796 \ -0.051458 \ -0.0159489 \\ 0.010203 \ 0.00012 \ 0]$$

$$h_2 = [0.046520 \ -0.018077 \ 0.03601 \ 0.180955 \ 0.36475 \ 0.220127 \ -0.077205 \ -0.024521 \\ 0.012375 \ -0.000011 \ 0].$$

Pentru primele 3000 puncte și conform relațiilor :

$$p_1(n) = s_1(n) + s_2(n)*h_4(n)$$

$$p_2(n) = s_2(n) + s_1(n)*h_3(n)$$

$$h_3 = [0.0105-1.0907862e-02 \ -9.5862249e-03 \ -5.4309726e-02 \ 1.4528681e-01 \\ 4.9461315e-01 \ 1.4528681e-01 \ -5.4309726e-02 \ -9.5862249e-03 \ -1.0907862e- \\ 02 \ 0.0105e+00]$$

$$h_4 = [0.035e+00 \ -1.1959607e-02 \ -1.7325158e-02 \ 2.4047196e-01 \ 4.0813720e-01 \\ 2.4047196e-01 \ -1.7325158e-02 \ -1.1959607e-02 \ -8.7180096e-03 \\ 0.0000000e+00 \ 0.0000000e+00].$$

Pentru ultimele 3000 puncte.

- filtrele  $h_i$  ( $i=1,2,3,4$ ) sunt filtre de tipul trece jos,
- semnalele,  $s_1(n)$  și  $s_2(n)$ , sunt două semnale AR de ordinul 10 fiecare având spectrul mediu asemănător unui semnal vocal și s-au generat în 6000 de puncte,
- coeficienții AR sunt :



$$g_1 = [1.1827 \ -0.7163 \ 0.6874 \ -0.0834 \ 0.0648 \ -0.2025 \ -0.1069 \ -0.0964 \ -0.0270 \ 0.2012]$$

$$g_2 = [1.7683 \ -1.1768 \ 1.1469 \ -1.4245 \ 0.5697 \ -0.1023 \ 0.0743 \ 0.4081 \ -0.4924 \ 0.0975]$$

- rezultatele s-au mediat pe 50 realizări,
- ficare bloc are 100 de eşantioane,
- alegerea parametrilor s-a făcut comparând rezultate mediate pe 10 realizări.

În tabelul IV.8 se prezintă, pentru algoritmi descriși mai sus, câștigul în raport semnal/zgomot în funcție de raportul semnal/zgomot al semnalului captat.

TABELUL IV.8

CÂȘTIGUL ÎN RAPORT SEMNAL/ZGOMOT ÎN FUNCȚIE DE RAPOARTELE SEMNAL/ZGOMOT PENTRU DIFERIȚI ALGORITMI. CAZUL CAPTĂRII A DOUĂ SEMNALE AR PRINTR-UN SISTEM CU DOUĂ FILTRE DE INTERFERENȚĂ DE TIP FIR.

CAPTOR	RSB (dB) INTRARE	CÂȘTIG RSB (dB) PENTRU ALGORITMI					
		SSG	SAD	ELMS	ERLS	DLMS	DRLS
1	3.70	7.58	5.71	5.71	5.68	7.66	8.73
2	2.36	7.64	2.24	2.28	1.82	8.11	9.87

În tabelul IV.8 se poate remarca că algoritmul DRLS oferă cel mai mare câștig în raport semnal/zgomot. Comparativ cu DLMS și SSG se câștigă aproximativ un dB pentru semnalul primei surse și doi dB pentru semnalul celei de-a doua.

Comparând interferența medie reziduală se constată că algoritmul DRLS este cel mai performant, algoritmi SAD și ELMS sunt aproape identici și că algoritmi SAD, ELMS și ERLS sunt practic ineficienți pentru semnalul celei de-a doua surse.

Pentru toți algoritmi coeficienții filtrelor converg destul de lent (fig. IV.19 și IV.20). Cea mai precisă convergență este a algoritmului SSG.


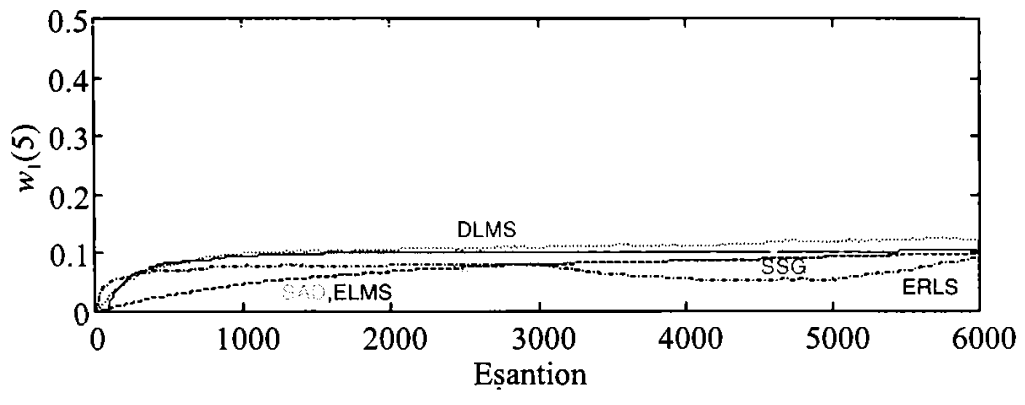


Fig. IV.19 Mediile a doi coeficienți ai primului filtru

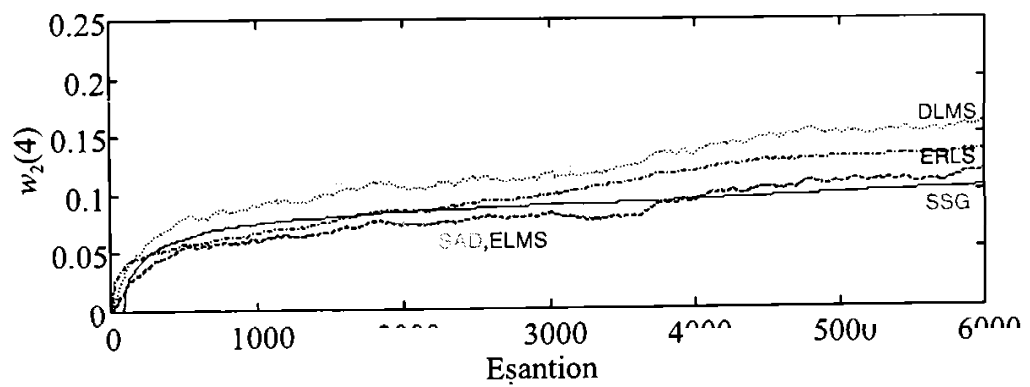
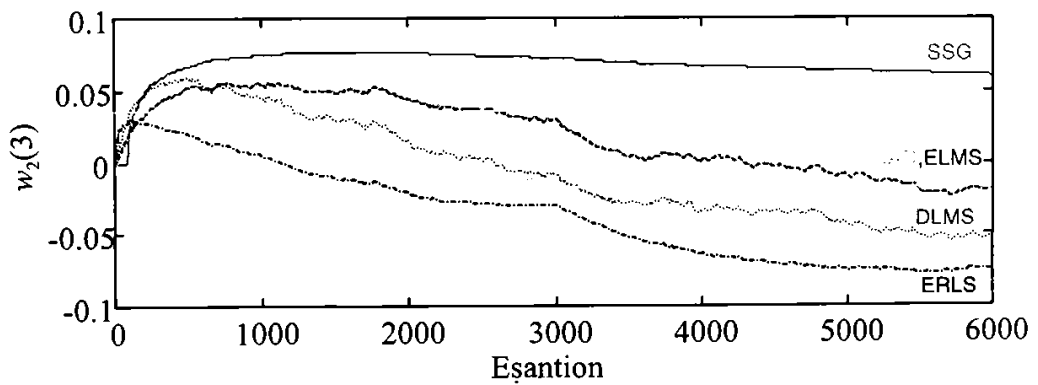


Fig. IV.20 Mediile a doi coeficienți ai celui de-al doilea filtru




Fig. IV.21 Interferența reziduală




Fig. IV.22 Eroare parametrică reziduală

#### IV.4.6. Cazul captării unui semnal și unui zgomot real printr-un sistem având două filtre de interferență de tip FIR

Rezultatele care sunt prezentate în acest paragraf au fost obținute în următoarele condiții :

- semnalele  $p_1(n)$  și  $p_2(n)$  s-au obținut printr-un sistem având următoarele filtre de interferență :

$$h_1 = [0.05903 \ -0.05268 \ -0.06256 \ 0.12734 \ 0.4901 \ 0.142796 \ -0.051458 \ -0.0159489 \\ 0.010203 \ 0.00012]$$

$$h_2 = [0.046520 \ -0.018077 \ 0.03601 \ 0.180955 \ 0.36475 \ 0.220127 \ -0.077205 \ -0.024521 \\ 0.012375 \ -0.000011],$$

- semnalele,  $s_1(n)$  et  $s_2(n)$ , sunt două semnale reale,  $s_1(n)$  este un semnal vocal și  $s_2(n)$  este un zgomot real,
- atât semnalul cât și zgomotul au fost înregistrate în habitaclul unui autoturism,
- semnalul vocal a fost înregistrat pe durata staționării având motorul oprit,
- zgomotul a fost înregistrat în mai multe cazuri,
- fiecare bloc are 100 de eșantioane,

Vom considera următoarele cinci tipuri de zgomot :

1. – autoturism Renault 25 rulând cu viteza de 40 km/h pe piatră cubică,
2. – autoturism Renault 25 rulând cu 130 km/h pe autostradă cu geamurile închise,
3. – autoturism Renault 25 parcat pe timp de ploaie,
4. – zgomot de circulație, Renault 25 oprit cu ferestrele deschise,
5. – autoturism Renault 25 rulând pe autostradă cu viteza de 130 km/h și geamurile deschise.

În tabelul IV.9 se prezintă câștigul în raport semnal/zgomot în funcție de raportul semnal/zgomot al semnalului captat pentru algoritmi descriși mai sus cu excepția algoritmului SSG care a fost omis datorită necesității unui timp mare de calcul.

TABELUL IV.9

CĂȘTIGUL ÎN RAPORT SEMNAL/ZGOMOT ÎN FUNCȚIE DE RAPOARTELE SEMNAL/ZGOMOT PENTRU DIFERIȚI ALGORITMI. CAZUL CAPTĂRII UNUI SEMNAL REAL SI A UNUI ZGOMOT REAL PRINTR-UN SISTEM CU DOUĂ FILTRE DE INTERFERENȚĂ DE TIP FIR.

CAS	CAPTOR	RSB (dB) INTRARE	CĂȘTIG RSB (dB) PENTRU ALGORITMI				
			SAD	ELMS	ERLS	DLMS	DRLS
1	1	10.48	7.65	9.10	3.72	9.77	11.36
	2	-3.20	3.53	3.62	6.00	17.71	20.97
2	1	2.45	13.44	13.48	11.38	13.22	21.60
	2	4.66	0.90	0.89	0.20	13.30	19.53
3	1	11.40	8.30	8.36	2.35	7.93	14.22
	2	-4.08	4.77	4.78	4.94	16.61	22.48
4	1	9.97	11.18	11.15	11.07	12.35	19.25
	2	-2.91	3.80	3.78	3.35	19.49	27.74
5	1	3.09	13.05	12.06	10.01	14.74	21.39
	2	3.79	0.48	2.25	2.91	15.09	22.64

Din tabelul IV.9 se constată o slabă eficiență a algoritmilor SAD, ELMS și ERLS pentru semnalul al doilea, comportament aproape identic al algoritmilor SAD și ELMS precum și superioritatea algoritmului DRLS.

În figura IV.23 se prezintă interferența reziduală înainte și după prelucrare pentru fiecare semnal, iar în figura IV.24 erorile parametrice reziduale pentru fiecare filtru, ambele pentru fiecare algoritm în parte.

Dacă comparăm interferența reziduală se constată că algoritmi DRLS, SAD și ELMS au un comportament aproape identic și că algoritmi SAD, ELMS și ERLS sunt aproape ineficienți vizavi de cea de-a doua sursă.

Referitor la comportamentul evoluției coeficienților filtrelor în timp se poate remarca (fig. IV.24) că cea mai bună convergență s-a obținut cu algoritmul DRLS.




Fig. IV.23 Interferența reziduală




Fig. IV.24 Eroarea parametrică reziduală

In figura IV.25 se prezintă un exemplu de prelucrare utilizând algoritmul DRLS.

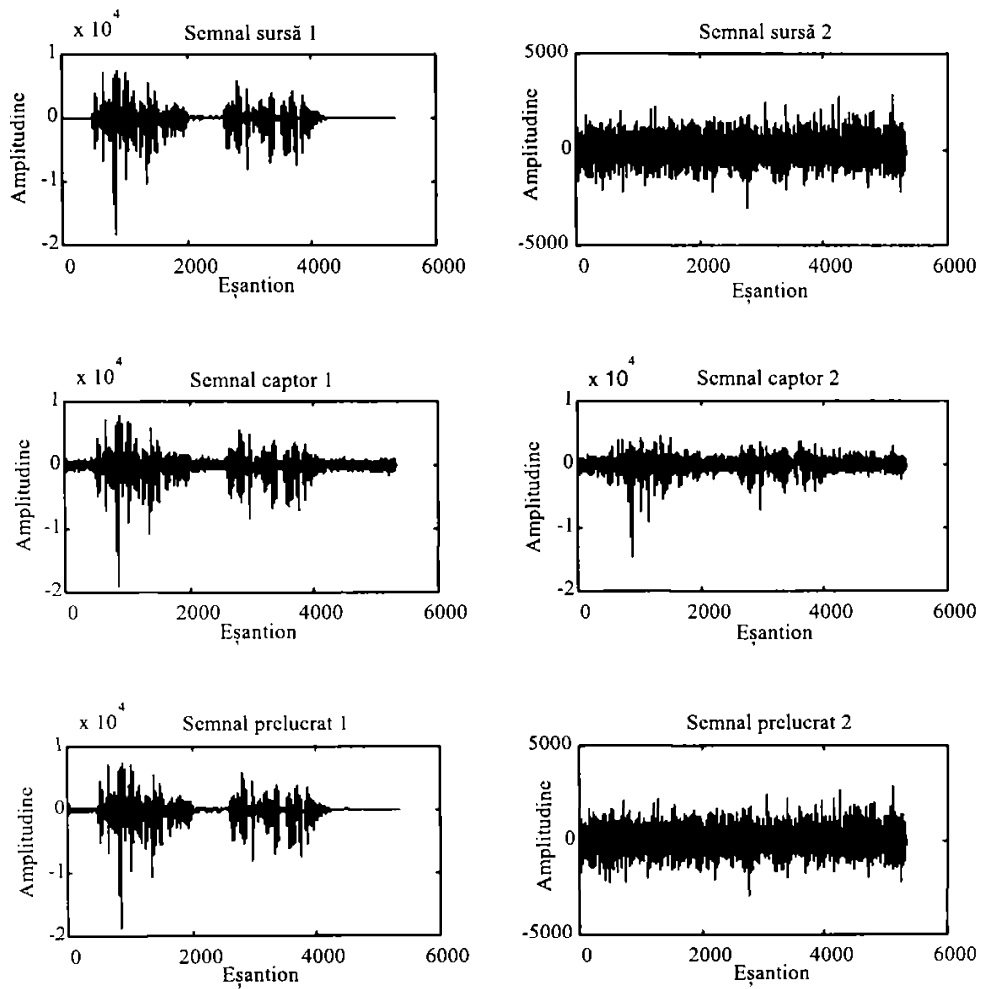


Fig. IV.25 Exemplu de prelucrare utilizând algoritmul DRLS

## CONCLUZII

Scopul acestei lucrări este îmbunătățirea raportului semnal/zgomot în cazul în care se dispune de unul sau două semnale captate într-un același mediu zgomotos. Zgomotul a fost presupus aditiv, alb sau colorat. Mai întâi am efectuat un studiu bibliografic al metodelor existente în literatura de specialitate, atât în cazul monocaptor cât și în cazul bicaptor după care acestea au fost clasificate. Lucrarea a fost concepută în felul următor :

Mai întâi am studiat metodele monocaptor.

Am propus trei noi metode de îmbunătățire a raportului semnal/zgomot pentru un semnal vocal, modelat printr-un proces AR, înecat în zgomot alb utilizând filtrarea Kalman :

1. prima metodă estimează coeficienții AR, utilizând funcția de autocorelație a semnalului observabil și câștigul optimal Kalman calculat iterativ, în două moduri diferite, exploatând proprietățile secvenței de inovație,
2. cea de-a doua metodă estimează varianțele zgomotului de excitație și respectiv zgomotului pe canal exploatând rezultatele obținute după un filtraj prealabil al semnalului observabil cu un filtru suboptimal,



3. cea de-a treia metodă estimează parametrii necesari filtrului Kalman utilizând algoritmul EM.

În cazul în care raportul semnal/zgomot corespunzător semnalului observabil este mai mic de  $5 \text{ dB}$ , cu un filtru Kalman se obțin rezultate superioare metodelor bazate pe filtrarea Wiener sau pe descompunerea în valori singulare. Raportate la metodele existente în literatură și care utilizează de asemenea un filtru Kalman, metodele propuse de noi au avantajul de a nu necesita cunoașterea varianței zgomotului pe canal. Câștigul în raport semnal/zgomot este puțin diminuat dar ele prezintă avantajul de a nu necesita existența unui detector de activitate vocală care să stabilească perioadele de liniște, perioade când se face estimarea varianței zgomotului pe canal. Raportat la câștigul în raport semnal/zgomot cea de-a treia este cea mai performantă. Performanțele acesteia sunt însă plătite printr-o complexitate mai mare a calculelor.

Am propus de asemenea două metode în cazul în care zgomotul ambiant este presupus colorat și modelat printr-un proces AR. Aceste metode sunt extensii ale primei și a celei de-a treia metode propuse în cazul unui zgomot ambiant alb :

1. prima metodă estimează parametrii zgomotului în perioadele de liniște. Parametrii semnalului vocal și câștigul optimal Kalman sunt estimați pe durata perioadelor de activitate vocală.
2. cea de-a doua metodă estimează atât parametrii semnalului cât și pe cei ai zgomotului cu ajutorul unui algoritm EM.

Metodele bazate pe filtrarea Kalman conduc și în acest caz la rezultate superioare, din punct de vedere al câștigului în raport semnal/zgomot, în comparație cu metodele bazate pe analiza spectrală de scurtă durată, cu cele bazate pe filtrarea Wiener și cu cele bazate pe estimarea optimală în sensul minimizării erorii medii pătratice. Dar conduc la rezultate inferioare metodelor bazate pe descompunerea în valori singulare pentru un raport semnal/zgomot mai mic de  $5 \text{ dB}$ .

Cea de-a doua metodă propusă de noi oferă, comparativ cu alte metode bazate pe filtrarea Kalman, avantajul de a nu necesita un detector de activitate vocală. O bună inițializare a algoritmului EM diminuează numărul de iterații necesare acestuia ca să ajungă la convergență și implicit a numărului de calcule necesare algoritmului.

Apoi am studiat metodele bicaptor.

Toate aceste metode pleacă de la următoarele ipoteze : semnalele sunt rezultate din două surse, sursa semnalului vocal și sursa zgomotului; semnalele captate de cei doi captori provenind de la aceeași sursă sunt puternic corelate pe când semnalele provenind de la surse diferite sunt necorelate. S-a considerat cazul în care semnalele de interferență s-au obținut prin intermediul unor filtre FIR. Pentru a îmbunătăți raportul semnal/zgomot este necesară determinarea funcțiilor de transfer a acestor două filtre. Cunoșcând aceste filtre de transfer se pot reconstrui semnalele sursă pornind de la semnalele captate.

Mai multe lucrări au făcut obiectul acestui subiect. Am putea aminti prima metodă propusă în literatură de B. Widrow. Această metodă utilizează un singur filtru adaptiv și din păcate nu este aplicabilă decât în cazul în care componenta semnalului vocal captată de cel de-al doilea microfon este neglijabilă. În celelalte cazuri trebuie să se utilizeze structuri mai complexe. Am studiat apoi metodele bazate pe schemele FFIS (FeedForward Implementation Scheme) și FBIS (FeedBack Implementation Scheme).

Am grupat metodele bazate pe utilizarea schemei FFIS în două clase :

1. în prima clasă cele bazate pe decorelarea semnalelor intermediare
2. în cea de-a doua clasă cele bazate pe utilizarea momentelor de ordin superior.

În cadrul metodelor din cea de-a doua clasă am propus un nou algoritm utilizând momentele de ordinul trei.

Utilizarea schemei FBIS nu necesită adăugarea unor filtre de egalizare, filtre necesare în schema FFIS. Metodele bazate pe schema FBIS au fost grupate în două clase :

1. în prima clasă cele bazate pe decorelarea semnalelor de ieșire
2. în cea de-a doua cele care utilizează o structură de filtru dublu.

Ne-am focalizat atenția asupra metodelor care utilizează un filtru dublu. Cele două filtre sunt două filtre adaptive clasice. Dacă Vallauri a propus utilizarea a două filtre de tip LMS noi am propus utilizarea a două filtre RLS sau SFTF pentru a ameliora performanțele. Algoritmul DRLS rezultat a condus la rezultate mai bune comparativ cu algoritmul DLMS, rezultate cuantizate prin raportul semnal/zgomot al semnalelor de ieșire, lucru care se explică prin superioritatea vitezei de convergență a algoritmului RLS comparativ cu cea a algoritmului LMS.

De asemenea am justificat convergența unei astfel de structuri către o soluție care să ne permită reconstrucția semnalelor sursă.

Am constatat lipsa de eficacitate a schemei FFIS precum și a metodelor bazate pe decorelarea semnalelor.

Dacă ne referim la interferența reziduală, care nu este altcineva decât inversul raportului semnal/zgomot calculat pentru blocuri de date adiacente, am observat superioritatea algoritmului DRLS precum și faptul că acesta nici după câteva mii de eșantioane nu a ajuns la convergență.

Referitor la evoluția în timp a coeficienților filtrelor de separare am constatat superioritatea algoritmului SSG secondat de algoritmul DRLS. Dacă convergența algoritmului SSG este mai precisă, în sensul că se ajunge în regim permanent la o eroare mai mică, această convergență se atinge mai lent comparativ cu algoritmul DRLS.

Algoritmul DRLS se detașează prin cel mai bun raport performanță/calculare necesare.

## BIBLIOGRAFIE

- [AKB95] Akbari Azirani, A., "Rehaussement de la parole en ambiance bruitée. Application aux télécommunications main-libres", Thèse de l'Université de Rennes I, Novembre 1995.
- [ALE86] Alexander, S.T., *Adaptive signal processing*, Springer-Verlag, 1986.
- [AND79] Anderson, B.D.O., and J.B. Moore, *Optimal Filtering*, Prentice-Hall, New Jersey 1979.
- [BEN88] Benallal, A., A. Gilloire, "A new method to stabilize Fast RLS algorithms based on first order model of propagation of numerical errors", Proc. of IEEE ICASSP 1988, New York, pp. 1373-1376.
- [BEN89]. Benallal, A , A. Gilloire, "Instabilité et stabilité des algorithmes des moindres carrés transversaux rapides exites par la parole", GRETSI 1989, Juan-les-Pins, pp. 509-512.
- [BER79] Beruti, M., R. Schwartz, and J. Makhoul, "Enhancement of speech corrupted by acoustic noise", ICASSP 79, pp. 208-211, April 1979.
- [BOI87] Boite, R. et M. Kunt, *Traitement de la parole*, Presses Polytechniques Romandes, Lausanne, 1987.
- [BOL78] Boll, S.F., "Suppression of noise in speech using the SABER method", ICASSP 78, Tulsa, Okla., pp. 606-609, 1978.
- [BOL79] Boll, S.F., "Suppression of acoustic noise in speech using spectral subtraction", IEEE Trans. on ASSP, vol. 27, pp. 113-120, Apr. 1979.
- [BOL80] Boll, S.F., "Adaptive noise canceling in speech using the short-time transform", ICASSP 80, Denver, Colo., pp. 692-695, 1980.

- [BOO72] Boozer, D.D., and W.L. McDaniel, Jr., "On Innovation Sequence Testing of the Kalman Filter", IEEE Trans. on Automatic Control. Vol. AC-17, pp. 158-160, February 1972.
- [CAL76] Callahan, M.W., "Acoustic signal processing based on the short-time spectrum", Ph.D dissertation, Dep. Comput. Sci., Univ. Utah, Salt Lake City, Mar. 1976.
- [CAR73] Carew, B., and P.R. Belanger, "Identification of Optimum Filter Steady-State Gain for Systems with Unknown Noise Covariances", IEEE Trans. on Automatic Control. Vol. AC-18, pp. 582-587, December 1973.
- [CIO84] Cioffi, J.M., T. Kailath, "Fast RLS transversal filters for adaptive filtering", IEEE Trans. on ASSP 32, no. 2, April 1984.
- [COM92] Compemolle, D.V., and S.V. Gerven, "Blind Separation of Sources : Signal Separation in a Symmetric Adaptive Noise Canceller by Output Decorrelation", Proc. of IEEE ICASSP 1992, pp. IV-221 - 224.
- [DEL93] Deller, J.R., Jr., J.G. Proakis, J.H.L. Hansen, *Discrete-Time Processing of Speech Signals*, Macmillan, Englewood Cliffs, 1993.
- [DEM77] Dempster, A.P., N.M. Laird and D.B. Rubin, "Maximum likelihood from incomplete data via EM algorithm", J. Royal Statistical Soc., Ser. B, vol. 39, no. 1, pp. 1-38, 1977.
- [DER94] Deriche, M., "AR Parameter Estimation from Noisy Data using the EM Algorithm", ICASSP 94, vol. IV, pp. 69-73.
- [EPH84] Ephraim, Y., and D. Malah, "Speech Enhancement Using a Minimum Mean-Square Error Short-Time Spectral Amplitude Estimator", IEEE Tran. On ASSP, vol. ASSP-32, no. 6, pp. 1109- 1121, December 1984.
- [FRA76] Frazier, R.H., S. Samson, L.D. Braida, and A.V. Oppenheim, "Enhancement of speech by adaptive filtering", ICASSP 76, pp. 251-253, Apr. 1976.

- [GAB96a] Gabrea, M., E. Mandridake et M. Najim, "Restauration par Filtrage de Kalman d'un Signal de Parole Noyé dans un Bruit Coloré", AGI'96 Forum des Doctorants « Automatique, Genie informatique, Image », Tours, Juin 1996, pp. 21-24.
- [GAB96b] Gabrea, M., E. Mandridake and M. Najim, "A Single Microphone Noise Canceller Based on Adaptive Kalman Filter", Proc. of EUSIPCO 1996, Trieste, Italy, September 1996, vol. 2, pp. 979-982.
- [GAB96c] Gabrea, M., E. Mandridake, M. Menez, M. Najim and A. Vallauri, "Two Microphones Speech Enhancement System Based on a Double Fast Recursive Least Squares (DFRLS) Algorithm", Proc. of EUSIPCO 1996, Trieste, Italy, September 1996, vol. 2, pp. 983-986.
- [GAB96d] Gabrea, M., "A Single Microphone Noise Canceller Based on Adaptive Kalman Filter", Proc. of ISET 1996, Timisoara, Romania, September 1996, vol. 2, pp. 91-94.
- [GAB96e] Gabrea, M., "A Noise Canceller Based on Higher Order Statistics", Proc. of ISET 1996, Timisoara, Romania, September 1996, vol. 2, pp. 95-98.
- [GAB96f] Gabrea, M., "A Double RLS Noise Canceller and Some Related Schemes", Proc. of ICECS 1996, Rodos, Greece, October 1996.
- [GAB97a] Gabrea, M., E. Mandridake, D. Bastard and M. Najim "Adaptiv Kalman Filter for Speech Enhancement from Colored Noise", Emerging Techniques for Communication Terminals, COST 254, Toulouse, France, 7-9 July 1997.
- [GAB97b] Gabrea, M., et E. Mandridake "Restauration d'un Signal de Parole Noyé dans un Bruit Blanc par Filtrage de Kalman avec les Variances Inconnues", soumis pour publication.
- [GAB97c] Gabrea, M., E. Mandridake, and M. Najim "A New Noise Canceller Based on Adaptive Kalman Filter", soumis pour publication 1997
- [GER94] Gerven, S.V., D.V. Compernelle, H.L. Nguyen-Thi and C. Jutten, "Blind Separation of Sources : A Comparative Study of 2-nd and 4-nd Order Solution", Proc. of EUSIPCO 1994, pp. 1153- 1156.

- [GER95] Gerven, S.V., and D.V. Compernelle, "Signal Separation by Symmetric Adaptive Decorrelation : Stability, Convergence, and Uniqueness", IEEE Trans. On Signal Processing, vol. 43, no. 7, July 1995, pp. 1602 - 1612.
- [GIB88] Gibson, J.D., T.R. Fischer, and B. Koo, "Estimation and vector quantization of noisy speech", ICASSP 88, pp. 541-544, 1988.
- [GIB91] Gibson, J.D., B. Koo and S.D. Gray, "Filtering of Colored Noise for Speech Enhancement and Coding", IEEE Trans. on Signal Processing, Vol. 39, No. 8, pp. 1732-1742, August 1991.
- [HAN87] Hansen, J.H.L., and M.A. Clements, "Iterative speech enhancement with spectral constraints", ICASSP 87, Dallas, Tex., vol. 1, pp. 189-192, Apr. 1987.
- [HAN88] Hansen, J.H.L., and M.A. Clements, "Constrained iterative speech enhancement with application to automatic speech recognition", ICASSP 88, New York, pp. 561-564, 1988.
- [HAN91] Hansen, J.H.L., and M.A. Clements, "Constrained iterative speech enhancement with application to automatic speech recognition", IEEE Tran. on ASSP, vol. 39, pp. 795-805, Apr. 1991.
- [HAY91] Haykin, S., *Adaptive filter theory*, Prentice-Hall 1991.
- [IEE69] "IEEE recommended practice for speech quality measurements", IEEE Tran. On Audio and Electroacoustics, pp. 227-246, Sept. 1969.
- [JEN94] Jensen, S.H., P.C. Hansen, S.D. Hansen, and J.A. Sorensen, "A Signal Subspace Approach for Noise Reduction of Speech Signals", EUSIPCO 94, pp. 1174-1177.
- [JEN95] Jensen, S.H., P.C. Hansen, S.D. Hansen, and J.A. Sorensen, "Reduction of Broad-Band Noise in Speech by Truncated QSVD", IEEE Tran. On SAP, vol. 3, no. 6, pp. 439- 448, Novembre 1995.

- [KAI68] Kailath, T., “An innovations approach to least-squares estimation, part I: linear filtering in additive white noise”, IEEE Trans. Automatic Control, Vol. AC-13, pp. 646-655, December 1968.
- [LEB91] Le Bouquin, R., and G. Faucon, “Maximum Likelihood Noise Cancellation with Spectral Constraints”, ICASSP 91, pp. 941-944, April 1991.
- [LIM78] Lim, J., “Evaluation of a correlation subtraction method for enhancing speech degraded by additive noise”, IEEE Tran. On ASSP, ASSP-26, pp. 471-472, Oct. 1978.
- [LIM79] Lim, J.S., and A.V. Oppenheim “Enhancement and Bandwidth Compression of Noisy Speech”, Proceedings of the IEEE, vol. 67, No. 12, pp. 1586-1604, Dec. 1979.
- [LIN95] Lindgren, U., T. Wigren and H. Broman, “On the convergence of a class of blind separation algorithms”, IEEE Trans. On Signal Processing, vol. 43, no. 12, Dec. 1997, pp. 3054-3058.
- [LIN96a] Lindgren, U., and H. Broman, “On the Identifiability of a Mixing Channel based on Second Order Statistics”, Proc. of Radio Vetenskap och Kommunikation, Lulea, Sweden, May 1996, pp. 420- 424.
- [LIN96b] Lindgren, U., H. Broman and H. Sahlin, “Source Separation Based on Second Order Statistics”, Proc. of EUSIPCO 1996, Trieste, September 1996, pp. 609- 702.
- [LIN97] Lindgren, U., and H. Broman, “Source Separation Using a Criterion based on Second Order Statistics”, Technical Raport CTH-TE-36, Chalmers Univ. Of Tech., Goteborg, Sweden, 1995, soumis for IEEE Trans. On Signal Processing January 1997.
- [LOA85] van Loan, C.F., “Computing the CS and Generalized Singular Value Decomposition”, Numer. Math., vol. 46, pp. 479-491, 1985.



- [MAR74] Martin, W.C., and A.R. Stubberud , “An Additional Requirement for Innovations Testing in System Identification”, IEEE Trans. on Automatic Control. Vol. AC-19, pp. 583-584, October 1974.
- [MAY79] Maybeck, P.S., *Stochastic Models, Estimation, and Control, Volume 1*, Academic Press, Orlando 1979.
- [MCA80] McAulay, R.J., and M.L. Malpass, “Speech Enhancement Using a Soft-Decision Noise Suppression Filter”, IEEE Tran. On ASSP, vol. ASSP-28, no. 2, pp. 137-145, April 1980.
- [MEH70] Mehra, R.K., “On the Identification of Variances and Adaptive Kalman Filtering”, IEEE Trans. on Automatic Control. Vol. AC-15, No. 2, pp. 175-184, April 1970.
- [MEH71] Mehra, R.K., “On-Line Identification of Linear Dynamic Systems with Applications to Kalman Filtering”, IEEE Trans. on Automatic Control. Vol. AC-16, No. 1, pp. 12-21, February 1971.
- [NAJ88] Najim, M., *Modélisation et identification en traitement du signal*, Masson, 1988.
- [NAJ98] Najim, M., *Filtrage optimal*, Techniques de l’Ingénieur , Paris 1998.
- [NGU91] Nguyen Thi, H.L., C. Jutten et J. Caelen, “Séparation aveugle de parole et de bruit dans un mélange convolutif”, GRETI 1991, Juan-les-Pins, pp. 737-740.
- [NGU92] Nguyen-Thi, H.L., C. Jutten and J. Caelen, “Speech Enhancement : Analysis and Comparison of Methods on Various Real Situations”, Proc. of EUSIPCO 1992, pp. 303- 306.
- [NGU93] Nguyen Thi, H.L., et C. Jutten, “Comparaison de quelques algorithmes adaptatifs de séparation aveugle de sources dans un mélange convolutif”, GRETI 1993, Juan-les-Pins, pp. 333-336.
- [NGU95] Nguyen Thi, H.L., and C. Jutten, “Blind source separation for convolutive mixtures”, Signal Processing, vol. 45, no. 2, August 1995, pp. 209-229.

- [OPP94] Oppenheim, A.V., E. Weinstein, K.C. Zangi, M. Feder, and D. Gauger, "Single-Sensor Active Noise Cancellation", IEEE Tran. On SAP, vol. 2, no. 2, April 1994.
- [PAL87] Paliwal, K.K., and A. Basu, "A Speech Enhancement Method Based on Kalman Filtering", ICASSP 87, pp. 177- 180, 1987.
- [PAR76] Parson, T.W., "Separation of speech from interfering speech by means of harmonic selection", J. Acoust. Soc. Amer., vol. 60, pp. 911-918, Oct. 1976.
- [PER77] Perlmutter, Y.M., L.D. Braida, R.H. Frazier et al. "Evaluation of a speech enhancement systems", ICASSP 77, Hartford, pp. 212-215, 1977.
- [ROB51] Robbins, H., and S. Monro, "A Stochastic Approximation Method", Annals of Mathematical Statistics, vol. 22, 1951, pp. 400-407.
- [SHI70] Shields, U.C., Jr., "Separation of added speech signals by digital comb filterig", S.M. thesis, Dept. Elect. Eng., Massachusetts Inst. Technol., Cambridge, 1970.
- [STO77] Stoica, P., "A Test for Whiteness", IEEE Trans. on Automatic Control. Vol. AC-22, pp. 992-993, December 1977.
- [THE92] Therrien, C.W., *Discrete Random Signals and Statistical Signal Processing*, Prentice Hall, New Jersey 1992.
- [VAL92] Vallauri, A., "Méthodes de reconnaissance de la parole et de réduction du bruit, et applications", Thèse de Docteur Ingénieur, Décembre 1992, Nice, France.
- [VEB94] Verbout, S.M., "Signal Enhancement for Automatic Recognition of Noisy Speech", RLE Technical Report No. 584, M.I.T., May 1994.
- [WAN82] Wang, D.L., J.S. Lim "The unimportance of phase in speech enhancement", IEEE Trans. on ASSP, vol. 30, pp. 679-681, Aug. 1982.
- [WEI74] Weiss, M.R., E. Aschkenasy and T.W. Parson "Study and development of the INTEL technique for improving speech intelligibility", Nicolet Scientific Corp., Final Report NSC-FR/4023, Dec. 1974.

- [WEI83] Weiss, M.R., and E. Aschkenasy “Computerized audio processor”, Rome Air Development Center, Final Report RADC-TR-83-109, May 1983.
- [WEI93] Weinstein, E., M. Feder and A.V. Oppenheim, “Multi-Channel Signal Separation by Decorrelation”, IEEE Trans. On Speech and Audio Processing, vol. 1, no. 4, October 1993, pp. 405 - 413.
- [WID75] Widrow, B., J.R. Glover, Jr., J.M. McCool, J. Kaunitz, C.S. Williams, R.H. Hearn, J.R. Zeidler, E. Dong, Jr. and R.C. Goodlin, “Adaptive Noise Cancelling: Principles and Applications”, Proc. IEEE, vol. 63, no. 12, pp. 1692 - 1716, Dec. 1975.
- [WID76] Widrow, B., J.M. McCool, M.G. Larimore and C.R. Johnson, Jr., “Stationary and Nonstationary Learning Characteristics of the LMS Adaptive Filter”, Proc. IEEE, vol. 64, no. 8, pp. 1151 - 1162, Aug. 1976.
- [WID85] Widrow, B., and S.D. Stearns, *Adaptive Signal processing*, Prentice-Hall 1985.
- [YEL94] Yellin, D., and E. Weinstein, “Criteria for Multichannel Signal Separation”, IEEE Trans. On Signal Processing, vol. 42, no. 8, August 1994, pp. 2158 – 2169, 1977.
- [ZAN94] Zangi, K.C., “Optimal Feedback Control Formulation of the Active Noise Cancellation Problem : Pointwise and Distributed”, RLE technical Report No. 583, M.I.T., May 1994.