## SISTEME DE ESTIMARE A STARII APARATELOR DE ZBOR

pentru

# SPECIALIZAREA: SISTEME COMPLEXE DE INGINERIE AEROSPAȚIALĂ

## TITULAR CURS: S.L. DR. ING. MIHAI LUNGU

**UNIVERSITATEA DIN CRAIOVA** 

### **CAPITOLUL 1**

# ESTIMAREA STĂRII APARATELOR DE ZBOR UTILIZÂND OBSERVERE DE STARE

### **1.1. INTRODUCERE**

Observerele sunt folosite pentru estimarea vectorului de stare al sistemului condus (aparatului de zbor) folosind semnalele de intrare și de ieșire ale acestuia. Prin măsurarea unor componente ale vectorului de stare (componentele vectorului de ieșire), se reduce numărul senzorilor din sistemul de conducere, mai ales al celor pentru măsurarea unor variabile de stare greu accesibile sau greu măsurabile, cum este, de exemplu, cazul deformărilor elastice [51], [213], [242].

Primele structuri de observere au fost descoperite de Luenbergher în anii 1966, 1971. Observerele sunt folosite atât pentru sisteme cu intrări cunoscute, cât și pentru sisteme cu intrări necunoscute, proiectarea lor aparținând mai multor cercetători (Bhatta-Charyya, 1978; Chen și Patton, 1999; Chorless și Tu, 1998; Darouach, 1994; Hostetter și Meditch, 1973; Hou și Müller, 1992; Hui și Zak, 1993 și 2005; Kudva, 1980; Kurek, 1983; Wang, 1975; Yang și Wilde, 1988; Krzminski și Kakzorek, 2005 ș.a.).

Observerele recente sunt dedicate sistemelor cu o parte din intrări necunoscute, respectiv sistemelor cu subsisteme a căror dinamică este necunoscută. Pentru astfel de sisteme se proiectează observere cu ordin redus; intrările necunoscute pot fi perturbații, erori etc.

Dintre observerele pentru estimarea stării sistemelor stochastice, cel mai

cunoscut este estimatorul (filtrul) Kalman-Bucy [80], [125], [142]. În cazul sistemelor neliniare cu intrări parțial necunoscute sau cu subsisteme necunoscute, se construiesc observere adaptive care utilizează rețele neuronale [86], [110], [123], [146], [159].

Cercetări mai recente se referă la proiectarea observerelor pentru sisteme cu întârziere internă [48], [61], [85], [236], bazate pe teoria lui Lyapunov; proiectarea observerelor presupune rezolvarea unor inegalități matriceale.

Observerele de stare liniare sunt folosite pentru estimarea stării x a sistemelor liniare pe baza vectorului y al variabilelor măsurate și al vectorului de intrare sau a unor componente ale acestuia.

### **1.2. PROIECTAREA OBSERVERELOR LINIARE**

### **1.2.1. OBSERVERE LUENBERGER**

Se dă sistemul

$$\begin{cases} \dot{x}(t) = Ax(t) + Bu(t), \\ y(t) = Cx(t) + Du(t) \end{cases}$$
(1.1)

și se dorește construirea unui nou sistem de forma

$$\begin{cases} \dot{w}(t) = Jw(t) + Hy(t) + Mu(t), \\ \hat{x}(t) = Lw(t) + Ny(t) + Pu(t), \end{cases}$$
(1.2)

sistem cu intrările u(t), y(t) și ieșirile: starea estimată  $\hat{x}(t)$  și mărimea de stare w(t) [184].

Sistemul rezultant trebuie să fie stabil (matricea *J* să aibă valorile proprii în semiplanul stâng complex  $\Leftrightarrow \Lambda(J) \subset C_{-}$  și  $\lim_{t \to \infty} (\hat{x}(t) - x(t)) = 0$  (vectorul de stare estimat  $\hat{x}(t)$  să aproximeze starea sistemului) [184].

Deoarece  $x(t) \neq \hat{x}(t)$ , se evaluează w-Vx, unde V - matrice de fidelizare. Această matrice evaluează modul în care starea estimatorului (w) urmărește starea sistemului

inițial (x).

Se calculează 
$$(w - Vx)' = (w - Vx)^T$$
 și se obține [184]

$$\dot{w} - V\dot{x} = Jw + Hy + Mu - VAx - VBu + JVx - JVx \Leftrightarrow (w - Vx)' = J(w - Vx) + JVx + H(Cx + Du) + (M - VB)u - VAx = = J(w - Vx) + JVx + HCx + HDu - VAx + (M - VB)u = = J(w - Vx) + (JV + HC - VA)x + (M - VB + HD)u.$$
(1.3)

Se calculează, de asemenea, și eroarea de estimare a observerului  $\hat{x} - x$ 

$$e = \hat{x} - x = Kw + Ny + Pu - x = L(w - Vx) + LVx + NCx + + NDu + Pu - x = L(w - Vx) + (LV + NC - I)x + (P + ND)u.$$
(1.4)

Alăturând ecuațiile (1.3) și (1.4) se obține

$$\begin{cases} (w - Vx)' = J(w - Vx) + (JV + HC - VA)x + (M - VB + HD)u, \\ \hat{x} - x = L(w - Vx) + (LV + NC - I)x + (P + ND)u. \end{cases}$$
(1.5)

Pentru ca  $\hat{x}(t) \rightarrow x(t)$  trebuie ca ieșirea sistemului de mai sus să tindă asimptotic la zero (ieșirea sistemului (1.5) este  $\hat{x} - x$ ). Acest lucru se realizează dacă sunt satisfăcute simultan condițiile [184]

$$\begin{cases} a) \Lambda(J) \subset C_{-}, \\ b) JV + HC - VA = 0, \\ c) M - VB + HD = 0, \\ d) LV + NC - I = 0, \\ e) P + ND = 0. \end{cases}$$
(1.6)

Dacă aceste condiții sunt simultan satisfăcute, sistemul de ecuații (1.5) devine

$$\begin{cases} (w - Vx)' = J(w - Vx), \\ \hat{x} - x = L(w - Vx). \end{cases}$$
(1.7)

Din prima ecuație rezultă  $w - Vx \rightarrow 0$  și, în aceste condiții,  $\Rightarrow \hat{x} - x \rightarrow 0$ , indiferent de inițializarea sistemului sau a observerului [184]. Așadar, proiectarea estimatorului de stare se reduce la rezolvarea sistemului de ecuații (1.6). Acesta este un sistem cu 4 ecuații și o condiție legată de localizarea valorilor proprii; sistemul are 7 necunoscute: *J*, *V*, *H*, *M*, *L*, *N*, *P*.

#### Caz particular

Presupunem că estimatorul nu are transfer direct I/O, adică N = 0 [184]. Sistemul (1.6) devine

$$\begin{cases} \Lambda(J) \subset C_{-}, \\ JV + HC - VA = 0, \\ M - VB + HD = 0, \\ LV - I = 0, \\ P = 0. \end{cases}$$
(1.8)

Alegând V=I, rezultă L=I, P=0, iar sistemul (1.8) devine

$$\begin{cases} \Lambda(J) \subset \mathcal{C}_{-}, \\ J = A - HC, \\ M = B - HD. \end{cases}$$
(1.9)

Impunând valori proprii dorite (în semiplanul stâng complex) pentru matricea J=A-HC se determină atât matricea H cât și matricea J. Pentru aceasta este nevoie ca perechea (C, A) să fie detectabilă. Dacă în plus (C, A) - observabilă, rezultă ca spectrul matricei de stare J poate fi alocat arbitrar [184]. În acest moment s-au determinat toate matricele din ecuația (1.6). Așadar, estimatorul de stare obținut este descris de următoarele ecuațiile [184]:

$$\begin{cases} \dot{w}(t) = (A - HC)w(t) + Bu(t) + Hy(t) - HDu(t), \\ \hat{x}(t) = w(t), \end{cases}$$
(1.10)

sistem echivalent cu [184]

$$\dot{\hat{x}}(t) = (A - HC)\hat{x}(t) + (B - HD)u(t) + Hy(t).$$
(1.11)

Deci, pentru determinarea vectorului de stare estimat sunt necesare semnalele u și y.

Observerul obținut se numește estimator Luenberger. Pentru ca estimatorul să aibă coeficienți reali, spectrul matricei J = A - HC se alege simetric [184]. Dacă însă perechea (C, A) este observabilă, spectrul matricei de stare a estimatorului (A - HC) poate fi ales arbitrar [184].

Condiția de observabilitate a perechii (C, A) este necesară și suficientă pentru a putea construi un observer Luenberger [184]. Estimatorul Luenberger are dimensiunea n (numărul de linii și de coloane ale matricei A). De aceea, el se mai numește estimator cu ordin întreg [184].

## 1.2.2. ESTIMAREA STĂRII SISTEMELOR LINIARE ȘI CONTINUE CU DINAMICĂ PARȚIAL CUNOSCUTĂ

Operațiunea de proiectare a observerelor este mai dificilă în cazul în care dinamica liniară asociată sistemului este parțial cunoscută. De altfel, în practică, cunoașterea exactă a dinamicii unui avion este importantă, fiind nevoie de luarea în calcul a necunoscutelor ce afectează dinamica sistemului [198]. Proiectarea unui observer se poate face doar dacă se cunosc complet matricele din ecuația de stare. Totuși, așa cum se va arăta în continuare, există posibilitatea construirii unui observer Luenberger și în cazul în care matricea sistemului are o parte cunoscută și alta necunoscută. În anumite condiții [198], elementele necunoscute se vor înlocui cu zerouri și se va lucra cu matricea rezultantă. Dinamica sistemului, caracterizată în principal de matricea din ecuația de stare, poate avea un element necunoscut sau mai multe elemente necunoscute așezate fie pe aceiași linie sau coloană, fie așezate aleator.

Se consideră un sistem continuu și liniar descris de ecuațiile de stare

$$\begin{cases} \dot{x}(t) = \mathcal{A}x(t), \\ y(t) = Cx(t), \end{cases}$$
(1.12)

unde  $x(t) \in \mathcal{M}^{n \times 1}$  este vectorul de stare,  $y(t) \in \mathcal{M}^{p \times 1}$  – vectorul măsurătorilor sistemului,  $\mathcal{A} \in \mathcal{M}^{n \times n}(R)$  și  $C \in \mathcal{M}^{p \times n}(R)$  sunt matricele sistemului. Obiectivul este acela de a vedea în ce condiții se poate construi un estimator Luenberger pentru estimarea stării Matricea A se poate scrie A = A + F, unde A este o matrice cunoscută, iar F – partea necunoscută a dinamicii sistemului.

**Cazul 1:** Dinamica sistemului are un singur element necunoscut Se presupune că [198]

$$\mathcal{A} = A + \alpha F, \tag{1.13}$$

unde  $|\alpha| < 1$  și

$$A = \begin{bmatrix} 0 & \mathbf{x} \cdots & \mathbf{x} \\ \mathbf{x} & \mathbf{x} \cdots & \mathbf{x} \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{x} & \mathbf{x} \cdots & \mathbf{x} \end{bmatrix}, F = \begin{bmatrix} 1 & 0 \cdots & 0 \\ 0 & 0 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & 0 \end{bmatrix}.$$
 (1.14)

Astfel, sistemul (1.12) se poate scrie

$$\begin{cases} \dot{x}(t) = Ax(t) + \alpha Fx(t), \\ y(t) = Cx(t). \end{cases}$$
(1.15)

Estimatorul Luenberger ce va fi proiectat este descris de ecuațiile

$$\begin{cases} \dot{\hat{x}}(t) = A\hat{x}(t) + L[y(t) - \hat{y}(t)], \\ \hat{y}(t) = C\hat{x}(t), \end{cases}$$
(1.16)

în care L (matricea de amplificare a observerului) se alege (determină) astfel încât matricea (A - LC) să fie stabilă [198]. Determinarea matricei L este o operațiune relativ simplă. Problema este determinarea unor condiții necesare și suficiente astfel încât proiectarea estimatorului să se facă utilizând din matricea sistemului  $\mathcal{A}$  doar partea cunoscută (matricea A). Pentru aceasta se alege eroarea

$$e(t) = \hat{x}(t) - Tx(t),$$
 (1.17)

în care matricea T se alege în majoritatea cazurilor ca fiind matricea unitate. Se calculează  $\dot{e}(t)$ , ținându-se seama de ecuațiile (1.12), (1.16) și (1.17) și se obține

$$\dot{e}(t) = \dot{\hat{x}}(t) - T\dot{x}(t) = A\hat{x}(t) + L[y(t) - \hat{y}(t)] - TAx(t) = = A\hat{x}(t) + L[Cx(t) - C\hat{x}(t)] - T(A + \alpha F)x(t) = = (A - LC)e(t) + [(A - LC)T + LC - TA - \alpha TF]x(t).$$
(1.18)

Se introduce vectorul

$$X(t) = [e(t) \ x(t)]^{T}$$
(1.19)

și ecuațiile (1.12) și (1.18) conduc la [198]

$$\dot{X}(t) = \begin{bmatrix} (A - LC) \left( (A - LC)T + LC - TA \right) \\ 0 \quad (A - LC) \end{bmatrix} X(t) + \begin{bmatrix} 0 & -\alpha TF \\ 0 & (LC + \alpha F) \end{bmatrix} X(t).$$
(1.20)

Se remarcă valabilitatea relației [198]

$$\begin{bmatrix} 0 & -\alpha TF \\ 0 & (LC + \alpha F) \end{bmatrix} = \begin{bmatrix} 0 & -T \\ LC & I \\ D_1 \end{bmatrix} \cdot \begin{bmatrix} I & 0 \\ 0 & \alpha F \\ D_2 \end{bmatrix} \cdot \begin{bmatrix} 0 & I \\ 0 & I \\ D_3 \end{bmatrix}$$
(1.21)

și, cu aceasta, ecuația (1.20) se scrie

$$\dot{X}(t) = \overline{A}X(t) + D_1 D_2 D_3 X(t), \qquad (1.22)$$

unde

$$\overline{A} = \begin{bmatrix} (A - LC) \left( (A - LC)T + LC - TA \right) \\ 0 \qquad (A - LC) \end{bmatrix}.$$
(1.23)

Deoarece s-a ales  $|\alpha| < 1$  se poate demonstra că  $D_2^T D_2 \le I$  și sistemul (1.22) este cuadratic stabil dacă și numai dacă inegalitatea liniar matriceală

$$\overline{A}^{T}P + P\overline{A} + PD_{1}D_{1}^{T}P + D_{3}^{T}D_{3} < 0$$
(1.24)

are ca soluție o matrice *P* simetrică și pozitiv definită [198].

### **Cazul 2:** Dinamica sistemului are o coloană cu termeni necunoscuți Și în acest caz $\mathcal{A} = A + F$ , unde

$$A = \begin{bmatrix} 0 & \mathbf{x} \cdots & \mathbf{x} \\ 0 & \mathbf{x} \cdots & \mathbf{x} \\ \vdots & \vdots & \ddots & \vdots \\ 0 & \mathbf{x} \cdots & \mathbf{x} \end{bmatrix}, F = \begin{bmatrix} a_1 & 0 \cdots & 0 \\ a_2 & 0 \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ a_n & 0 \cdots & 0 \end{bmatrix}.$$
 (1.25)

Raționamentul este analog celui de mai sus, ajungându-se tot la ecuația (1.22). Pentru a se putea însă proiecta estimatorul de stare este nevoie de satisfacerea simultană a două condiții [198]:

1) 
$$1 - \sum_{i=1}^{n} a_i^2 \ge 0;$$

2) inegalitatea matriceală (1.24) are ca soluție o matrice P simetrică și pozitiv definită.

**Cazul 3:** Dinamica sistemului are o diagonală cu termeni necunoscuți În acest caz A = A + F, unde

$$A = \begin{bmatrix} 0 & \mathbf{x} & \cdots & \mathbf{x} \\ \mathbf{x} & 0 & \cdots & \mathbf{x} \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{x} & \mathbf{x} & \cdots & 0 \end{bmatrix}, F = \begin{bmatrix} a_1 & 0 & \cdots & 0 \\ 0 & a_2 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & a_n \end{bmatrix}.$$
 (1.26)

Ecuația estimatorului este și în acest caz ecuația (1.16), echivalentă cu (1.20) sau (1.22). Proiectarea observerului Luenberger, utilizând din matricea cu o coloană necunoscută A doar partea cunoscută A, este posibilă doar dacă sunt îndeplinite simultan condițiile [198]:

1)  $1 - a_i^2 \ge 0, i = \overline{1, r};$ 

2) inegalitatea liniar matriceală (1.24) are ca soluție o matrice P simetrică și pozitiv definită.

Cazul 4: Dinamica sistemului are câteva elemente necunoscute dispuse aleator

$$\mathcal{A} = A + F, A = \begin{bmatrix} 0 & x \cdots & x \\ x & x \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ x & 0 & \cdots & x \end{bmatrix}, F = \begin{bmatrix} a_1 & 0 & \cdots & 0 \\ 0 & 0 & \cdots & a_2 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & a_r & \cdots & 0 \end{bmatrix}.$$
 (1.27)

Matricea F se scrie

$$F = \sum_{i=1}^{r} F_i , \qquad (1.28)$$

unde  $F_i$  – matrice formate doar din zerouri cu excepția unui singur element  $a_i$  (pe coloana *i*). Se ajunge tot la ecuația (1.22), în care, de această dată, [198]

$$D_{1} = \begin{bmatrix} D_{1,1} & D_{1,2} & \cdots & D_{1,r} \end{bmatrix}, D_{2} = \begin{bmatrix} D_{2,1} & & & \\ & D_{2,2} & & \\ & & \ddots & \\ & & & D_{2,r} \end{bmatrix}, D_{3} = \begin{bmatrix} D_{3,1} & D_{3,2} & \cdots & D_{3,r} \end{bmatrix}^{T}.$$
 (1.29)

Condițiile necesare și suficiente pentru proiectarea estimatorului de stare Luenberger sunt, în acest caz, aceleași cu cele de la cazul anterior [198].

# 1.2.3. PROIECTAREA OBSERVERELOR LINIARE UTILIZÂND FORMULA BASS-GURA

Se consideră sistemul descris de ecuațiile (1.1) cu D = 0. Notând cu  $\hat{x}$  vectorul de stare estimat, se construiește un observer descris de ecuația [60]

$$\dot{\hat{x}}(t) = \hat{A}\hat{x}(t) + Ly(t) + Hu(t).$$
 (1.30)

Matricele  $\hat{A}, L$  și H se calculează astfel încât, în regim staționar,  $\hat{x}(t) \rightarrow x(t)$ . Se consideră eroarea observerului  $e(t) = x(t) - \hat{x}(t)$ ; derivând în timp eroarea e(t) se obține

$$\dot{e}(t) = Ax(t) + Bu(t) - \hat{A}(x(t) - e(t)) - LCx(t) - Hu(t) = = \hat{A}e(t) + (-\hat{A} + A - LC)x(t) + (B - H)u(t).$$
(1.31)

Trebuie îndeplinite simultan condițiile

$$\begin{cases} B - H = 0 \Leftrightarrow B = H, \\ -\hat{A} + A - LC = 0 \Leftrightarrow \hat{A} = A - LC. \end{cases}$$
(1.32)

În aceste condiții, eroarea de estimare devine [60]

$$\dot{e}(t) = \hat{A}e(t); \tag{1.33}$$

în acest caz, eroarea converge la zero  $(e(t) \rightarrow 0)$  dacă  $\hat{A}$  este o matrice stabilă.

Având în vedere ecuația (1.32), ecuația (1.30) a estimatorului de stare se scrie

$$\hat{x}(t) = A\hat{x}(t) + Bu(t) + L(y(t) - C\hat{x}y(t)), \qquad (1.34)$$

adică forma generală Luenberger

Făcând notația [60]

$$r(t) = y(t) - \hat{y}(t) = y(t) - C\hat{x}(t), \qquad (1.35)$$

ecuația (1.34) devine

$$\hat{x}(t) = A\hat{x}(t) + Bu(t) + Lr(t),$$
 (1.36)

în care r(t) se numește reziduul estimatorului de stare.

Există o multitudine de metode pentru determinarea matricei de amplificare a observerului L. Cum estimatorul de stare are forma filtrului Kalman, matricea L poate fi determinată prin rezolvarea unei probleme optimale. O altă variantă ar fi determinarea matricei prin metoda poziționării polilor. Metoda Bass-Gura reprezintă o alternativă la metoda poziționării polilor. Pentru descrierea metodei se consideră a(s) şi  $\hat{a}(s)$  – polinoamele caracteristice ale matricelor A, respectiv  $\hat{A}$ 

$$a(\mathbf{s}) = \det(\mathbf{s}I \cdot A), \hat{a}(\mathbf{s}) = \det(\mathbf{s}I \cdot \hat{A}).$$
(1.37)

Cele două polinoame caracteristice se pot scrie

$$a(\mathbf{s}) = \mathbf{s}^{n} + \sum_{i=1}^{n} a_{i} \mathbf{s}^{n-i}, \, \hat{a}(\mathbf{s}) = \mathbf{s}^{n} + \sum_{i=1}^{n} \hat{a}_{i} \mathbf{s}^{n-i}, \quad (1.38)$$

unde n este numărul de linii și de coloane ale matricei A. Dependența între cele două polinoame caracteristice este [60]

$$\hat{a}(s) - a(s) = a(s)C(sI_n - A)^{-1}L$$
 (1.39)

și, utilizând formula Leverreim-Souriau,

$$\left(sI_n - A\right)^{-1} = \frac{s^{n-1}I_n + s^{n-2}(A + a_1I_n) + s^{n-3}(A^2 + a_1A + a_2I_n) + \dots + (A^{n-1} + a_1A^{n-2} + \dots + a_{n-1}I_n)}{a(s)}, (1.40)$$

ecuația (1.39) conduce la

$$\begin{cases} \hat{a}_{1} - a_{1} = CL, \\ \hat{a}_{2} - a_{2} = CAL + a_{1}CL, \\ \hat{a}_{3} - a_{3} = CA^{2}L + a_{1}CAL + a_{2}CL, \\ \vdots \\ \hat{a}_{n} - a_{n} = CA^{n-1}L + a_{1}CA^{n-2}L + \dots + a_{n-1}CL. \end{cases}$$
(1.41)

Sistemul de ecuații (1.41), considerându-se vectorii

$$a = [a_1 \ a_2 \ \cdots \ a_n]^T, \hat{a} = [\hat{a}_1 \ \hat{a}_2 \ \cdots \ \hat{a}_n]^T, \qquad (1.42)$$

se scrie

$$\hat{a} - a = T_a O_{A,C} L, \qquad (1.43)$$

în care  $O_{A,C}$  este matricea de observabilitate asociată sistemului (1.1), adică

$$O_{A,C} = \begin{bmatrix} C \ CA \ CA^2 \ \cdots \ CA^{n-1} \end{bmatrix}^T, \tag{1.44}$$

iar  $T_a$  este o matrice inferior triunghiulară având forma

$$T_{a} = \begin{bmatrix} 1 & 0 & 0 & \cdots & 0 \\ a_{1} & 1 & 0 & \cdots & 0 \\ a_{2} & a_{1} & 1 & \cdots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ a_{n-1} & a_{n-2} & a_{n-3} & \cdots & 1 \end{bmatrix}.$$
 (1.45)

Matricea de amplificare a observerului (L) se determină din ecuația (1.43) astfel [60]

$$L = (T_a O_{A, C})^{-1} (\hat{a} - a), \qquad (1.46)$$

după ce, în prealabil, s-au determinat matricele  $O_{A,C}$  și  $T_a$ . Deoarece  $T_a$  este o matrice

inferior triunghiulară  $\Rightarrow \det(T_a) = 1 \Rightarrow T_a$  – matrice nesingulară. Pentru ca formula Bass-Gura să poată fi aplicată, matricea  $O_{A,C}$  trebuie să fie inversabilă, deci  $rang(O_{A,C}) = n$  (sistemul descris de ecuațiile (1.1) trebuie să fie observabil).

#### <u>Observații</u>

1. În Matlab/Simulink polinomul caracteristic asociat unei matrice se determină cu ajutorul comenzii *poly* [67];

2. În (1.46), vectorul  $\hat{a}$  se determină impunând valori proprii dorite pentru observer;

3. Considerând A – matrice pătratică de ordinal  $n \Leftrightarrow A \in \mathcal{M}^{n \times n}$  și că sistemul (1.1) are s ieșiri  $\Leftrightarrow C \in \mathcal{M}_{s \times n}$ , dimensiunile matricelor  $T_a$  și  $O_{A,C}$  sunt, respectiv,  $T_a \in \mathcal{M}^{n \times n}, O_{A,C} \in \mathcal{M}^{(s \cdot n) \times n}$ . Pentru a putea efectua produsul matricelor  $T_a$  și  $O_{A,C}$  din ecuația (1.46) este nevoie ca  $s \cdot n = n \Leftrightarrow s = 1$  (sistemul trebuie să aibă o singură ieșire). Cu alte cuvinte, o condiție necesară a metodei Bass-Gura pentru proiectarea observerelor este ca sistemul descris de ecuațiile de stare (1.1) să aibă o singură ieșire.

Aşadar, algoritmul Bass-Gura pentru proiectarea observerului este [60]:

### **Algoritmul Bass-Gura**

**Pasul 1**: Cunoscându-se matricea A a sistemului, se determină polinomul caracteristic a (s) asociat acestei matrice.

**Pasul 2**: Se impun valori proprii dorite pentru observer și se determină polinomul caracteristic  $\hat{a}(s)$  asociat matricei  $\hat{A} = A - LC$ .

**Pasul 3**: Se calculează matricea  $T_a$  cu formula (1.45) și matricea de observabilitate a sistemului  $O_{A,C}$  utilizând ecuația (1.44).

**Pasul 4**: Se calculează matricea de amplificare a estimatorului de stare cu ecuația (1.46) și se proiectează observerul descris de ecuația (1.34).

În cele ce urmează se validează algoritmul Bass-Gura de proiectare a observerelor liniare pentru două cazuri concrete ale mișcărilor longitudinală, respectiv laterală ale aeronavelor. Pentru început, se consideră mișcarea longitudinală a unei aeronave descrisă de ecuația de stare

$$\begin{bmatrix} \Delta \dot{V}_{x} \\ \Delta \dot{\alpha} \\ \Delta \dot{\theta} \\ \Delta \dot{\Theta}_{y} \end{bmatrix} = \begin{bmatrix} -0.007 \ 0.012 \ -9.81 \ 0 \\ -0.128 \ -0.54 \ 0 \ 1 \\ 0 \ 0 \ 0 \ 1 \\ 0.065 \ 0.96 \ 0 \ -0.99 \end{bmatrix} \begin{bmatrix} \Delta V_{x} \\ \Delta \alpha \\ \Delta \theta \\ \Delta \omega_{y} \end{bmatrix} + \begin{bmatrix} 0 \\ -0.04 \\ 0 \\ -12.5 \end{bmatrix} \delta_{p}$$
(1.47)

și de ecuația de ieșire y = Cx cu  $C = \begin{bmatrix} 0 & 0 & 1 & 0 \end{bmatrix}$ . Pentru observer se impun valorile proprii dorite -1, -2, -3 și -4. Se obțin succesiv, conform algoritmului de mai sus,

$$a(\mathbf{s}) = \mathbf{s}^{4} + 1.537\mathbf{s}^{3} - 0.413\mathbf{s}^{2} + 0.635\mathbf{s} - 0.861, \hat{a}(\mathbf{s}) = \mathbf{s}^{4} + 10\mathbf{s}^{3} + 69\mathbf{s}^{2} + 50\mathbf{s} + 24,$$

$$T_{a} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 1.537 & 1 & 0 & 0 \\ -0.413 & 1.537 & 1 & 0 \\ 0.635 & -0.413 & 1.537 & 1 \end{bmatrix}, O_{A,C} = \begin{bmatrix} 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \\ 0.065 & 0.96 & 0 & -0.99 \\ -0.187 - 1.468 - 0.637 & 1.94 \end{bmatrix}, \quad (1.48)$$

$$L = \begin{bmatrix} -276.462 & 41.643 & 8.463 & 56.405 \end{bmatrix}^{T}.$$



Fig. 1.1. Modelul Matlab/Simulink al observerului Bass-Gura

Programul Matlab din anexa A1.1 reprezintă implementarea software a procedurii de construcție a estimatorului Bass-Gura. Modelul Matlab/Simulink din fig. 1.1 este utilizat în cadrul programului din anexă pentru obținerea caracteristicilor de timp din fig. 1.2 (erorile de estimare a variabilelor de stare cu estimatorul de stare Bass-Gura pentru u = 0) și caracteristicile de timp din fig. 1.3 pentru legea de comandă  $u = -K\hat{x}$ (*K* calculată cu algoritmul ALGLX [157]); caracteristicile exprimă variabilele de stare  $x_i(t) - cu linie continuă și <math>\hat{x}_i(t) - cu linie întreruptă.$ 



Fig. 1.2. Erorile de estimare a stării estimatorului Bass-Gura (K = 0)



Fig. 1.3. Variabilele de stare  $x_i(t)$  și  $\hat{x}_i(t)$  - mișcarea longitudinală  $(K \neq 0)$ 

Se implementează software observerul Bass-Gura și pentru cazul mișcării laterale a unei aeronave Boeing 747, care zboară cu M = 0.8 la H = 40000 ft; ecuația de stare a mișcării laterale este

$$\begin{bmatrix} \Delta \dot{\beta} \\ \Delta \dot{\omega}_z \\ \Delta \dot{\omega}_x \\ \Delta \dot{\phi} \end{bmatrix} = \begin{bmatrix} -0.0558 - 0.9968 & 0.0802 & 0.0415 \\ 0.598 & -0.115 & -0.0318 & 0 \\ 0.305 & 0.388 & -0.465 & 0 \\ 0 & 0.0805 & 1 & 0 \end{bmatrix} \begin{bmatrix} \Delta \beta \\ \Delta \omega_z \\ \Delta \omega_x \\ \Delta \phi \end{bmatrix} + \begin{bmatrix} 0.0073 & 0 \\ -0.475 & 0.123 \\ 0.153 & 1.063 \\ 0 & 0 \end{bmatrix} \begin{bmatrix} \delta_d \\ \delta_e \end{bmatrix}.$$
(1.49)



Fig. 1.4. Erorile de estimare a stării estimatorului Bass-Gura (K = 0)



Fig. 1.5. Variabilele de stare  $x_i(t)$  și  $\hat{x}_i(t)$  - mișcarea laterală  $(K \neq 0)$ 

S-au impus aceleași valori proprii dorite ca și în cazul mișcării longitudinale și se obțin

$$a(s) = s^{4} + 0.635s^{3} + 0.669s^{2} + 0.234s - 0.0127, \hat{a}(s) = s^{4} + 10s^{3} + 69s^{2} + 50s + 24,$$

$$T_{a} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0.635 & 1 & 0 & 0 \\ 0.669 & 0.635 & 1 & 0 \\ 0.234 & 0.669 & 0.635 & 1 \end{bmatrix}, O_{A,C} = \begin{bmatrix} 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \\ 0.065 & 0.96 & 0 & -0.99 \\ -0.187 - 1.468 - 0.637 & 1.94 \end{bmatrix},$$
(1.50)
$$L = \begin{bmatrix} 17.73 & 64.215 & 57.207 & 9.364 \end{bmatrix}^{T}.$$

Erorile de estimare a variabilelor de stare sunt prezentate în fig. 1.4 (pentru K = 0), iar variabilele de stare  $x_i(t)$  și  $\hat{x}_i(t)$  pentru K calculat cu algoritmul ALGLX [157] sunt prezentate în fig. 1.5. Programul Matlab utilizat este similar celui din anexa A1.1, iar modelul Matlab/Simulink este identic cu cel din fig. 1.1.

### **1.2.4. ESTIMATOARE DE STARE CU ORDIN REDUS**

Se consideră sistemul (1.1) cu m intrări, p ieșiri și ordinul n (numărul variabilelor de stare = n). Nu este neapărat nevoie să se construiască un observer care să estimeze direct toate cele n variabile de stare, întrucât o parte dintre ele (p dintre cele n) sunt direct măsurabile. Se presupune că matricea C este epică, adică

$$\operatorname{rang}\left(C\right) = p. \tag{1.51}$$

Se vor estima doar n - p variabile de stare; un estimator de acest tip se numește estimator cu ordin redus [34], [157]. Se face presupunerea că rang (C) = p (ipoteză fără de care nu se poate construi estimatorul cu ordin redus) și se presupune, prin alegerea directă a variabilelor de stare direct măsurabile, că

$$C = \begin{bmatrix} 0 & I_p \end{bmatrix}. \tag{1.52}$$

În aceste condiții, a doua ecuație de stare (1.1) devine

$$y = Cx + Du = \begin{bmatrix} 0 & I_p \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} + Du = x_2 + Du,$$
 (1.53)

unde  $x_2$  - vectorul format din cele p variabile de stare direct măsurabile, iar  $x_1$  - vectorul format din cele n-p variabile de stare ce urmează a fi estimate. Se partiționează matricele A, B, V, L, N astfel [34]

$$A = \begin{bmatrix} A_1 & A_3 \\ A_2 & A_4 \end{bmatrix}, B = \begin{bmatrix} B_1 \\ B_2 \end{bmatrix}, V = \begin{bmatrix} V_1 & V_2 \end{bmatrix}, L = \begin{bmatrix} L_1 \\ L_2 \end{bmatrix}, N = \begin{bmatrix} N_1 \\ N_2 \end{bmatrix}.$$
 (1.54)

Ecuațiile a doua și a patra din sistemul de ecuații (1.6) devin

$$\begin{cases} J[V_1 \ V_2] + H[0 \ I_p] - [V_1 \ V_2] \begin{bmatrix} A_1 \ A_3 \\ A_2 \ A_4 \end{bmatrix} = 0, \\ \begin{bmatrix} L_1 \\ L_2 \end{bmatrix} [V_1 \ V_2] + \begin{bmatrix} N_1 \\ N_2 \end{bmatrix} [0 \ I_p] = I, \end{cases}$$
(1.55)

sistem echivalent cu

$$\begin{cases} \begin{bmatrix} JV_1 & JV_2 \end{bmatrix} + \begin{bmatrix} 0 & H \end{bmatrix} - \begin{bmatrix} V_1A_1 + V_2A_2 & V_1A_3 + V_2A_4 \end{bmatrix} = 0, \\ \begin{bmatrix} L_1V_1 & L_1V_2 \\ L_2V_1 & L_2V_2 \end{bmatrix} + \begin{bmatrix} 0 & N_1 \\ 0 & N_2 \end{bmatrix} = I$$
(1.56)

sau

$$JV_1 - V_1A_1 - V_2A_2 = 0, JV_2 + H - V_1A_3 - V_2A_4 = 0,$$
  

$$L_1V_1 = I, L_1V_2 + N_1 = 0, L_2V_1 = 0, L_2V_2 + N_2 = I.$$
(1.57)

Se alege [34]

$$L_1 = I_{n-p}$$
(1.58)

și se obțin

$$V_1 = I_{n-p}, L_2 = 0, N_2 = I_p, N_1 = -V_2.$$
(1.59)

Sistemul de ecuații devine

$$\begin{cases} J - A_1 - V_2 A_2 = 0, \\ JV_2 + H - A_3 - V_2 A_4 = 0, \\ N_1 = -V_2. \end{cases}$$
(1.60)

Din prima ecuație (1.60) rezultă

$$J = A_1 + V_2 A_2 . (1.61)$$

Dacă perechea  $(A_1, A_2)$ -observabilă, având în vedere că  $\Lambda(J) \subset C_-$ , prin impunerea (alegerea) valorilor proprii ale matricei  $J = A_1 + V_2 A_2$  se determină  $V_2$  și, implicit,  $N_1$ [34]. Se determină, de asemenea, și J, din cea de-a doua ecuație (1.60) obținându-se apoi matricea H

$$H = A_3 + V_2 A_4 - (A_1 + V_2 A_2) V_2$$
(1.62)

În [34] se demonstrează că perechea  $(A_1, A_2)$  este observabilă dacă perechea (C, A) este observabilă. Așadar, algoritmul pentru proiectarea observerului este [34]:

### **Algoritmul 1**

**Pasul 1**: Se face transformarea sistemului (A, B, C, D) într-unul  $(\widetilde{A}, \widetilde{B}, \widetilde{C}, \widetilde{D})$ , unde

$$\widetilde{A} = \begin{bmatrix} A_1 & A_3 \\ A_2 & A_4 \end{bmatrix}, \widetilde{B} = TB = \begin{bmatrix} B_1 \\ B_2 \end{bmatrix}, \widetilde{C} = \begin{bmatrix} 0 & I_p \end{bmatrix} \widetilde{D} = D;$$
(1.63)

 $A_1 \in \mathcal{M}^{(n-p)\times(n-p)}$ ,  $A_2 \in \mathcal{M}^{p\times(n-p)}$ ,  $A_3 \in \mathcal{M}^{(n-p)\times p}$ ,  $A_4 \in \mathcal{M}^{p\times p}$ ,  $B_1 \in \mathcal{M}^{(n-p)\times m}$ ,  $B_2 \in \mathcal{M}^{p\times m}$ . Transformarea se face prin intermediul matricei de transformare *T*.

**Pasul 2**: Se verifică dacă perechea  $(A_1, A_2)$  – observabilă. În caz contrar, observerul nu poate fi construit.

**Pasul 3**: Se alege  $L_1 = I_{n-p}$  și rezultă  $V_1 = N_2 = I_{n-p}$ ,  $L_2 = 0$ .

**Pasul 4**: Se impun valori proprii pentru matricea  $J = A_1 + V_2 A_2$  și se determină  $V_2$ , rezultând apoi matricele J și  $N_1 = -V_2$ .

**Pasul 5**: Se calculează matricea H cu ecuația (1.62).

Pasul 6: Se calculează matricele M și P

$$M = VB - HD \Leftrightarrow M = \begin{bmatrix} V_1 & V_2 \end{bmatrix} \begin{bmatrix} B_1 \\ B_2 \end{bmatrix} - HD = B_1 + V_2B_2 - HD; \quad (1.64)$$

$$P = -ND \Leftrightarrow P = -\begin{bmatrix} N_1 \\ N_2 \end{bmatrix} D = \begin{bmatrix} V_2 D \\ -D \end{bmatrix}.$$
 (1.65)

Pasul 7: Ecuațiile (1.2), ce descriu estimatorul de stare, devin

$$\begin{cases} \dot{w} = (A_1 + V_2)A_2w + Hy + (B_1 + V_2B_2 - HD)u, \\ \hat{x} = \begin{bmatrix} \hat{x}_1 \\ \hat{x}_2 \end{bmatrix} = \begin{bmatrix} I_{n-p} \\ 0 \end{bmatrix} w + \begin{bmatrix} -V_2 \\ I_p \end{bmatrix} y + \begin{bmatrix} V_2D \\ -D \end{bmatrix} u.$$
(1.66)

#### **Observații**

1) estimatorul cu ordin redus are ordinul n - p (dimensiunea stării w(t));

2) a doua ecuație (1.66) est echivalentă cu

$$\hat{x}_1 = w - V_2 y + V_2 Du. \tag{1.67}$$

Această ecuație este asociată variabilelor de stare ce vor fi estimate (cele din vectorul  $\hat{x}_1$ ). De asemenea,  $\hat{x}_2$  (vectorul ce conține variabilele de stare direct măsurabile) se obține cu expresia [34]

$$\hat{x}_2 = x_2 = y - Du. \tag{1.68}$$

Aşadar,

$$\begin{cases} \hat{x}_1 = w - V_2 y + V_2 D u, \\ \hat{x}_2 = x_2 = y - D u. \end{cases}$$
(1.69)

În cele ce urmează este prezentat un alt algoritm de proiectare a observerelor cu ordin redus (observer cu ordin redus de tip Luenberger).

Se consideră sistemul descris de ecuațiile de stare (1.1), în care  $A \in \mathcal{M}^{p \times n}$ ,  $B \in \mathcal{M}^{n \times m}, C \in \mathcal{M}^{p \times n}, D = 0$  și rang(C) = p. În acest caz observerul cu ordin redus va avea ordinul (n - p). Primul pas este acela de partiționare a matricelor A, B, C și a vectorului de stare x(t) [231]

$$A = \begin{bmatrix} A_{11} & A_{12} \\ A_{21} & A_{22} \end{bmatrix}, B = \begin{bmatrix} B_1 \\ B_2 \end{bmatrix}, C = \begin{bmatrix} C_1 & C_2 \end{bmatrix}, x(t) = \begin{bmatrix} x_1(t) \\ x_2(t) \end{bmatrix},$$
(1.70)

unde  $A_{11} \in \mathcal{M}^{p \times p}, A_{12} \in \mathcal{M}^{p \times (n-p)}, A_{21} \in \mathcal{M}^{(n-p) \times p}, A_{22} \in \mathcal{M}^{(n-p) \times (n-p)}, B_1 \in \mathcal{M}^{p \times m}, B_2 \in \mathcal{M}^{(n-p) \times m}, C_1 \in \mathcal{M}^{p \times p}, C_2 \in \mathcal{M}^{p \times (n-p)}, x_1(t) \in \mathcal{M}^{p \times 1}, x_2(t) \in \mathcal{M}^{(n-p) \times 1}.$ 

Se face schimbarea de variabilă

$$\bar{x} = Tx, \qquad (1.71)$$

$$\hat{\mathbf{n}} \operatorname{care} T = \begin{bmatrix} C_1 & C_2 \\ 0 & I_{n-p} \end{bmatrix} \, \hat{\mathbf{s}} \, \hat{\mathbf$$

unde

$$\overline{x}(t) = \begin{bmatrix} \overline{x}_1(t) \\ \overline{x}_2(t) \end{bmatrix}, \ \overline{A} = \begin{bmatrix} \overline{A}_{11} & \overline{A}_{12} \\ \overline{A}_{21} & \overline{A}_{22} \end{bmatrix}, \ \overline{B} = \begin{bmatrix} \overline{B}_1 \\ \overline{B}_2 \end{bmatrix}, \ \overline{C} = \begin{bmatrix} I_p & 0 \end{bmatrix}$$
(1.73)

şi

$$\overline{A}_{11} = [C_1 A_{11} + C_2 A_{21}] C_1^{-1}, \overline{A}_{12} = -\overline{A}_{11} C_2 + C_1 A_{12} + C_2 A_{22},$$
  

$$\overline{A}_{21} = A_{21} C_1^{-1}, \overline{A}_{22} = A_{22} - A_{21} C_1^{-1} C_2, \overline{B}_1 = C_1 B_1 + C_2 B_2, \overline{B}_2 = B_2.$$
(1.74)

Primele p variabile de stare (cele cuprinse în vectorul  $\bar{x}_1(t)$ ) sunt măsurate prin intermediul senzorilor și nu mai este nevoie să fie estimate, iar următoarele (n - p)variabile de stare (cele cuprinse în vectorul  $\bar{x}_2(t)$ ) vor fi estimate.

Ecuația de stare (1.72) se scrie sub forma

$$\begin{cases} \bar{x}_{1}(t) = \overline{A}_{11}\bar{x}_{1}(t) + \overline{A}_{12}\bar{x}_{2}(t) + \overline{B}_{1}u(t), \\ \bar{x}_{2}(t) = \overline{A}_{21}\bar{x}_{1}(t) + \overline{A}_{22}\bar{x}_{2}(t) + \overline{B}_{2}u(t), \\ y(t) = \bar{x}_{1}(t). \end{cases}$$
(1.75)

Prima ecuație (1.75) exprimă faptul că  $\dot{\bar{x}}_1(t) = \dot{y}(t)$  conține informații despre  $\bar{x}_2(t)$ . De aceea, se introduce notația [231]

$$\xi(t) = \dot{\bar{x}}_{1}(t) - \overline{A}_{11}\bar{x}_{1}(t) \stackrel{(1.75)}{=} \overline{A}_{12}\bar{x}_{2}(t) + \overline{B}_{1}u(t).$$
(1.76)

Estimarea variabilei  $\xi(t)$  va depinde de estimarea vectorului  $\bar{x}_2(t)$ , adică  $\hat{x}_2(t)$ ; rezultă

$$\hat{\xi}(t) = \overline{A}_{12}\hat{\overline{x}}_2(t) + \overline{B}_1u(t).$$
(1.77)

Se construiește observerul cu ordin redus de tip Luenberger având forma [231]

$$\dot{\bar{x}}_{2}(t) = \bar{A}_{21}\bar{x}_{1}(t) + \bar{A}_{22}\hat{\bar{x}}_{2}(t) + \bar{B}_{2}u(t) + L[\xi(t) - \hat{\xi}(t)].$$
(1.78)

Dezavantajul metodei este că, pentru obținerea variabilei  $\xi(t)$ , este nevoie de derivarea lui  $\bar{x}_1(t)$ . Pentru eliminarea acestui dezavantaj se introduce variabila

$$\hat{z}(t) = \hat{\bar{x}}_2(t) - Ly(t)$$
 (1.79)

și rezultă

$$\dot{\hat{z}}(t) = \dot{\bar{x}}_{2}(t) - L\dot{y}(t) = \overline{A}_{21}\overline{x}_{1}(t) + \overline{A}_{22}\hat{\bar{x}}_{2}(t) + \overline{B}_{2}u(t) + L[\xi(t) - \hat{\xi}(t)] - \\
- L[\overline{A}_{11}\overline{x}_{1}(t) + \overline{A}_{12}\overline{x}_{2}(t) + \overline{B}_{1}u(t)] \Leftrightarrow \\
\dot{\hat{z}}(t) = \overline{A}_{21}\overline{x}_{1}(t) + \overline{A}_{22}\hat{z}(t) + \overline{A}_{22}L\overline{x}_{1}(t) + \overline{B}_{2}u(t) + L[\underline{\xi}(t) - \hat{\xi}(t)] - L\overline{A}_{11}\overline{x}_{1}(t) - \\
- L\overline{A}_{12}\hat{z}(t) - L\overline{A}_{12}L\overline{x}_{1}(t) - L\overline{B}_{1}u(t) \Leftrightarrow \\
\dot{\hat{z}}(t) = (\overline{A}_{22} - L\overline{A}_{12})\hat{z}(t) + (\overline{B}_{2} - L\overline{B}_{1})u(t) + (\overline{A}_{21} + \overline{A}_{22}L - L\overline{A}_{11} - L\overline{A}_{12}L)\overline{x}_{1}(t)$$
(1.80)

echivalentă cu

$$\dot{\hat{z}}(t) = \overline{M}\hat{z}(t) + \overline{N}u(t) + \overline{P}y(t), \qquad (1.81)$$

unde [231]

$$\overline{M} = \overline{A}_{22} - L\overline{A}_{12}, \overline{N} = \overline{B}_2 - L\overline{B}_1, \overline{P} = \overline{A}_{21} + \overline{A}_{22}L - L\overline{A}_{11} - L\overline{A}_{12}L.$$
(1.82)

Notând cu

$$e(t) = \bar{x}_2(t) - \hat{\bar{x}}_2(t)$$
(1.83)

și calculând derivata erorii  $(\dot{e}(t))$ , se obține [231]

$$\dot{e}(t) = \overline{M}e(t) = \left(\overline{A}_{22} - L\overline{A}_{12}\right)e(t).$$
(1.84)

Conform teoremei de observabilitate Popov-Bellevith [65], dacă sistemul

original descris de perechea (A, C) este observabil, atunci și sistemul descris de perechea  $(\overline{A}_{22}, \overline{A}_{12})$  este observabil. Pentru stabilitatea sistemului, matricea  $\overline{M}$  trebuie să fie stabilă. Matricea de amplificare L se calculează impunând valori proprii pentru matricea  $\overline{M} = \overline{A}_{22} - L\overline{A}_{12}$ ; în Matlab se utilizează instrucțiunea *place*.

Determinarea vectorului  $\hat{z}(t)$  se face rezolvând ecuația diferențială (1.81). Apoi, se determină estimarea vectorului  $\bar{x}_2$ , adică  $\hat{\bar{x}}_2$ , cu formula (1.79).

Algoritmul de proiectare a observerului cu ordin redus este cel de mai jos.

### Algoritmul 2

**Pasul 1**: Se calculează  $p = \operatorname{rang}(C)$  și se partiționează marticele A, B, C și vectorul de stare x(t) conform ecuației (1.70).

**Pasul 2**: Se calculează matricea T, ea trebuind să fie nesingulară. În cazul în care T este singulară, se alege o nouă matrice C și se reia algoritmul începând cu primul pas.

**Pasul 3**: Se calculează  $\overline{A}_{11}, \overline{A}_{12}, \overline{A}_{21}, \overline{A}_{22}, \overline{B}_1, \overline{B}_2$  cu ecuația (1.74) și apoi se formează matricele  $\overline{A}, \overline{B}$  și  $\overline{C}$  utilizând ecuația (1.73).

**Pasul 4**: Se verifică dacă perechea  $(\overline{A}_{22}, \overline{A}_{12})$  este observabilă. În caz contrar, estimatorul de stare cu ordin redus nu poate fi construit. Se calculează apoi matricea L impunând valori proprii dorite pentru matricea  $\overline{M} = \overline{A}_{22} - L\overline{A}_{12}$ .

**Pasul 5**: Se calculează matricele  $\overline{M}$ ,  $\overline{N}$  și  $\overline{P}$  cu formula (1.82).

**Pasul 6**: Se construiește observerul descris de ecuațiile (1.72), a treia ecuație (1.75), ecuația (1.81) și ecuația (1.79). Au rezultat vectorii  $\bar{x}_1(t)$ , vector obținut prin măsurători,  $\hat{x}_2(t)$  – estimarea vectorului  $\bar{x}_2(t)$  și, implicit,  $\hat{x} = [\bar{x}_1 \ \hat{x}_2]^T$ .

**Pasul 7**: Se obține vectorul de stare estimat  $\hat{x}$  astfel  $\hat{x} = T^{-1}\hat{\overline{x}}$ .

În fig. 1.6 este prezentată structura sistemului de comandă optimală a mișcării aparatelor de zbor, ce are în componență un observer cu ordin redus de tip Luenberger.

În cele ce urmează, se validează algoritmul 2 de proiectare a observerelor cu

ordin redus pentru două cazuri concrete ale mișcărilor longitudinală, respectiv laterală ale aeronavelor. Pentru început, se consideră mișcarea longitudinală a unei aeronave

descrisă de ecuația de stare (1.47) și de ecuația de ieșire y = Cx cu  $C = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 & 0 \end{bmatrix}$ .

Pentru determinarea matricei L s-au impus valorile proprii dorite  $s_1 = s_2 = -0.7$ . Se obțin succesiv, conform algoritmului de mai sus,



Fig. 1.6. Schema bloc de modelare a observerului cu ordin redus



Fig. 1.7. Modelul Matlab/Simulink al observerului cu ordin redus de tip Luenberger



Fig. 1.8. Variabilele de stare  $x_i(t)$  și  $\hat{x}_i(t)$  - mișcarea longitudinală (K = 0)



Fig. 1.9. Variabilele de stare  $x_i(t)$  și  $\hat{x}_i(t)$  - mișcarea longitudinală  $(K \neq 0)$ 

Programul Matlab din anexa A1.2 reprezintă implementarea software a procedurii de construcție a estimatorului cu ordin redus de tip Luenberger. Modelul Matlab/ Simulink din fig. 1.7 este utilizat în cadrul programului din anexă pentru obținerea caracteristicilor de timp din fig. 1.8 (u = 0) și din fig. 1.9 (pentru legea de comandă  $u = -K\hat{x}$ ; K este calculată cu algoritmul ALGLX [157]); aceste caracteristici exprimă variabilele de stare  $x_i(t)$  – cu linie continuă și  $\hat{x}_i(t)$  – cu linie întreruptă.

Se implementează software algoritmul 2 de proiectare a observerelor cu ordin redus și pentru cazul mișcării laterale a unei aeronave Boeing 747, care zboară cu M=0.8la H = 40000 ft; ecuația de stare a mișcării laterale este (1.49). Pentru determinarea matricei L s-au impus valorile proprii dorite  $s_1 = s_2 = -0.4$ . Se obțin succesiv, conform algoritmului de mai sus,

$$p = 2, T = I_4, \overline{M} = \begin{bmatrix} -0.4 & 0 \\ 0 & -0.4 \end{bmatrix}, \overline{N} = \begin{bmatrix} 1.124 & 0.811 \\ -4.15 & 1.057 \end{bmatrix},$$
  
$$\overline{P} = \begin{bmatrix} -0.917 & -0.194 \\ 2.022 & 11.561 \end{bmatrix}, L = \begin{bmatrix} 0 & 2.044 \\ 9.06 & -8.597 \end{bmatrix}.$$
 (1.86)

Este apelat același model Matlab/Simulink din fig. 1.7 și se obțin caracteristicile din fig. 1.10 și fig. 1.11. Acestea exprimă variabilele de stare  $x_i(t)$  – cu linie continuă și  $\hat{x}_i(t)$  – cu linie întreruptă pentru cazul K = 0 (fig. 1.10) și cazul  $K \neq 0$  (fig. 1.11). Matricea de amplificare K, și în acest caz, a fost calculată cu algoritmul ALGLX [157].



Fig. 1.10. Variabilele de stare  $x_i(t)$  și  $\hat{x}_i(t)$  - mișcarea laterală (K = 0)



Fig. 1.11. Variabilele de stare  $x_i(t)$  și  $\hat{x}_i(t)$  - mișcarea laterală  $(K \neq 0)$ 

În continuare, este prezentat un alt observer cu ordin redus pentru sistemele la care numărul de măsurători este mai mare decât numărul de mărimi controlate (observere LTR - loop transfer recovery) [177].

Se consideră sistemul descris de ecuațiile de stare (1.1) cu matricea  $D = 0, x \in \mathcal{M}^{n \times 1}, u \in \mathcal{M}^{p \times 1}, y \in \mathcal{M}^{m \times 1}; p < m < n$ . Se vor măsura n - m variabile de stare și, pentru că starea x nu este complet măsurabilă, vom avea nevoie de un estimator de stare. Ecuațiile estimatorului sunt [177]

$$\begin{cases} \dot{z} = Fz + (TB)u + K_f y, \\ \hat{x} = Nz + My. \end{cases}$$
(1.87)

Legea de comandă ce trebuie să asigure stabilizarea sistemului are forma clasică  $u = -K_c \hat{x}$ . Prima ecuație (1.87) reprezintă forma standard a unui observer de tip Luenberger ce consideră intrarea u și ieșirea y ca intrări ale sistemului și estimează  $K_c x$ . În cazul filtrului Kalman, matricele F, T, N și M sunt respectiv  $A - K_f C, I, K_c$ și matricea nulă (O). Este posibil ca  $M \neq O$ , dar, până în prezent, s-a demonstrat că obligatoriu T = I și  $N = K_c$  pentru filtrul Kalman. Din prima ecuație (1.1) rezultă  $y = C(sI - A)^{-1}Bu$ , iar din prima ecuație (1.87) rezultă  $z = (sI - F)^{-1}[(TB)u + K_f y]$ . Schema bloc de modelare a ecuațiilor generale (1.1) și ecuațiilor (1.87) este cea din fig. 1.12 [177].



Fig. 1.12 Schema bloc de modelare a ecuațiilor generale (1.1) și ecuațiilor (1.87)

Tsui a demonstrat că o condiție necesară și suficientă pentru convergența observerului este

$$N(sI - F)^{-1}TB = 0, (1.88)$$

 $(\forall)$ s  $\in C$ ; *N* satisface ecuația

$$K_c = NT + MC, \qquad (1.89)$$

iar T este soluția ecuației Sylvester

$$TA - FT = K_f C. \tag{1.90}$$

Condiția (1.88) este îndeplinită dacă se determină  $T \in \mathcal{M}^{(n-m)\times n}$  ce satisface ecuația [177]

$$TB = 0.$$
 (1.91)

Aşadar, condițiile (1.89)-(1.91) sunt suficiente pentru convergența observerului. Este evident că observerul nu poate fi, în acest caz, filtrul Kalman pentru că T = I și ar însemna TB = IB = B,  $(\forall)$  matricea B.

Observerul ce se constuiește în continuare este unul general cu  $T \neq I$ . Se cunosc matricele A, B, C și  $K_c$  și se determină matricele  $F, K_f, M$  și N. Matricea F a observerului se alege arbitrar. Algoritmul de proiectare a observerului este unul economic și necesită  $n^3$  operații. Pașii algoritmului Monahemi [177] sunt următorii:

#### Algoritmul 3 (Algoritmul Monahemi [177])

Pasul 1: Se realizează factorizarea QR a matricei B :

$$[W, S] = \operatorname{qr}(B); \tag{1.92}$$

matricele obținute W și S se partiționează astfel:

$$W = \begin{bmatrix} W_1 & W_2 \end{bmatrix}; S = \begin{bmatrix} S_1 \\ 0_{(n-p) \times p} \end{bmatrix},$$
(1.93)

unde  $W_1 \in \mathcal{M}^{n \times p}, W_2 \in \mathcal{M}^{n \times (n-p)}, S_1 \in \mathcal{M}^{p \times p}$ .

Pasul 2: Se calculează matricele [177]

$$C_1 = CW_1, A_1 = W_2^T A W_1, A_2 = W_2^T A W_2.$$
(1.94)

**Pasul 3**: Se realizează factorizarea matricei  $C_1$  și rezultă matricele Q și R

$$[Q, R] = \operatorname{qr}(C_1); \qquad (1.95)$$

se partiționează matricele Q și R astfel [177]

$$Q = \begin{bmatrix} Q_1 & Q_2 \end{bmatrix}, R = \begin{bmatrix} R_1 \\ 0_{(m-p) \times p} \end{bmatrix},$$
(1.96)

în care  $Q_1 \in \mathcal{M}^{m \times p}, Q_2 \in \mathcal{M}^{m \times (m-p)}$ .

Pasul 4: Se calculează matricea

$$E = Q^T C W_2 \tag{1.97}$$

și se partiționează această matrice după cum urmează [177]

$$E = \begin{bmatrix} E_1 & E_2 \end{bmatrix}^T; (1.98)$$

 $E_1 \in \mathcal{M}^{p \times (n-p)}, E_2 \in \mathcal{M}^{(m-p) \times (n-p)}.$ 

Pasul 5: Se rezolvă ecuația Sylvester

$$Z(A_2 - A_1 R_1^{-1} E_1) - FZ = L_2 E_2$$
(1.99)

cu necunoscuta Z;  $L_2$  se alege arbitrar [177].

Pasul 6: Se calculează matricea observerului

$$K_{f} = \left[ ZA_{1}R_{1}^{-1} \ L_{2} \right] Q^{T}$$
(1.100)

și matricea  $T = ZW_2^T$ .

**Pasul 7**: Cunoscând matricele T și  $K_c$ , se determină matricele M și N [177]

$$\begin{bmatrix} N & M \end{bmatrix} = K_c \begin{bmatrix} T \\ C \end{bmatrix}^{-1}.$$
 (1.101)

Proiectarea observerului este posibilă dacă sunt îndeplinite anumite condiții. Dacă matricea CB are rang maxim p, condițiile necesare și suficiente sunt [177]:

1) perechea  $(A_2 - A_1 R_1^{-1} E_1, E_2)$  este controlabilă;

2) valorile proprii ale matricei  $A_2 - A_1 R_1^{-1} E_1$  sunt diferite de cele ale lui F.

În continuare, este prezentat un alt algoritm de proiectare a unui observer liniar funcțional asociat unui sistem MIMO (observer Nakade&Galcade [180]). Se consideră din nou sistemul clasic, liniar și invariant în timp (1.1) cu  $D = 0, x \in \mathcal{M}^{n \times 1}, u \in \mathcal{M}^{p \times 1},$  $y \in \mathcal{M}^{m \times 1}, A \in \mathcal{M}^{n \times n}, B \in \mathcal{M}^{n \times p}, C \in \mathcal{M}^{m \times n}$ . Fără micșorarea generalității, matricea Cpoate fi considerată de forma canonică [180]

$$C = \begin{bmatrix} C_1 & 0 \end{bmatrix}, \tag{1.102}$$

unde  $C_1 \in \mathcal{M}^{m \times m}$ . Pentru proiectarea observerului,  $C_1$  trebuie să fie inversabilă.

Legea de control ce stabilizează sistemul este de forma

$$u(t) = -Kx(t), (1.103)$$

cu  $K \in \mathcal{M}^{p \times n}$ . Primul pas în proiectarea observerului este scrierea matricei de amplificare K sub forma [180]

$$K = FT + WC, \tag{1.104}$$

unde  $F \in \mathcal{M}^{p \times r}, T \in \mathcal{M}^{r \times n}, W \in \mathcal{M}^{p \times m}; p \leq r \leq n$ .

Ecuația (1.103) devine

$$u(t) = -Kx(t) = -(FTx(t) + WCx(t)) = -(KTx(t) + Wy(t)) = -(Kz(t) + Wy(t)), \quad (1.105)$$

în care s-a făcut notația

$$z(t) = Tx(t), \ z(t) \in \mathcal{M}^{r \times 1}.$$
(1.106)

z(t) verifică ecuația [180]

$$\dot{z}(t) = Ez(t) + TBu(t) + Gy(t), \qquad (1.107)$$

cu  $E \in \mathcal{M}^{r \times r}, G \in \mathcal{M}^{r \times m}$ . Alegerea matricei E se face astfel încât aceasta să fie stabilă. De exemplu, se alege  $E = \text{diag}(\lambda_i); i = \overline{1, p}$ , unde  $\lambda_i$  sunt valori proprii din semiplanul stâng complex.

Se consideră eroarea observerului

$$e(t) = z(t) - Tx(t).$$
(1.108)

Prin derivare, rezultă

$$\dot{e}(t) = \dot{z}(t) - T\dot{x}(t) = Ez(t) - ETx(t) + GCx(t) - TAx(t) + ETx(t).$$
(1.109)

Ecuația anterioară este echivalentă cu

$$\dot{e}(t) = E\underbrace{(z(t) - Tx(t))}_{e(t)} + (GC - TA + ET)x(t) \Leftrightarrow \dot{e}(t) = Ee(t) + (GC - TA + ET)x(t). \quad (1.110)$$

Pentru ca  $\dot{e}(t) = Ee(t)$  să fie ecuația ce corespunde unui observer convergent, trebuie ca [180]

$$GC - TA + ET = 0.$$
 (1.111)

La această ecuație se adaugă ecuația (1.104) și faptul că E – matrice stabilă. Aceste condiții stau la baza proiectării observerului cu ordin redus. Pentru determinarea matricelor F, T, W, G și E matricele  $F \in \mathcal{M}^{p \times n}, T \in \mathcal{M}^{r \times n}$  se scriu sub forma

$$K = [K_1 \ K_2], T = [T_1 \ T_2], \tag{1.112}$$

 $K_1 \in \mathcal{M}^{p \times m}, K_2 \in \mathcal{M}^{p \times (n-m)}, T_1 \in \mathcal{M}^{r \times m}, T_2 \in \mathcal{M}^{r \times (n-m)}$ . Cele două matrice de mai sus mai pot fi scrise și sub forma [180]

$$K = [k_1 \ k_2 \ \dots \ k_n], T = [t_1 \ t_2 \ \dots \ t_n],$$
(1.113)

unde

$$k_1^T = \begin{bmatrix} k_{11} & k_{21} & \dots & k_{p1} \end{bmatrix}, k_2^T = \begin{bmatrix} k_{12} & k_{22} & \dots & k_{p2} \end{bmatrix}, \dots, k_n^T = \begin{bmatrix} k_{1n} & k_{2n} & \dots & k_{pn} \end{bmatrix}$$
(1.114)

şi

$$t_1^T = \begin{bmatrix} t_{11} & t_{21} & \dots & t_{r1} \end{bmatrix}, t_2^T = \begin{bmatrix} t_{12} & t_{22} & \dots & t_{r2} \end{bmatrix}, \dots, t_n^T = \begin{bmatrix} t_{1n} & t_{2n} & \dots & t_{rn} \end{bmatrix}.$$
(1.115)

Înlocuind K și T de forma (1.113) în ecuația (1.104), se obține

$$\begin{bmatrix} k_1 & k_2 & \dots & k_n \end{bmatrix} - F \begin{bmatrix} t_1 & t_2 & \dots & t_n \end{bmatrix} - \begin{bmatrix} WC_1 & 0 \end{bmatrix} = 0.$$
(1.116)

Folosind ecuațiile (1.102), (1.104) și (1.111), rezultă

$$GC_1[I_m \ 0_{m \times (n-m)}] = TA - ET.$$
 (1.117)

Înmulțind ecuația (1.117) la dreapta cu  $\begin{bmatrix} I_m & 0_{m \times (n-m)} \end{bmatrix}^T$ , rezultă [180]

$$GC_1 = (TA - ET) \begin{bmatrix} I_m & 0_{m \times (n-m)} \end{bmatrix}^T \iff G = (TA - ET) \begin{bmatrix} I_m & 0_{m \times (n-m)} \end{bmatrix}^T \cdot C_1^{-1} . \quad (1.118)$$

De asemenea, înmulțind tot ecuația (1.117) la dreapta, dar de această dată cu  $[0_{m \times (n-m)} I_{n-m}]^T$ , se obține

$$(TA - ET) \begin{bmatrix} 0_{m \times (n-m)} & I_{n-m} \end{bmatrix}^T = 0.$$
 (1.119)

În continuare, se partiționează matricea A astfel

$$A = \begin{bmatrix} A_{11} & A_{12} \\ A_{21} & A_{22} \end{bmatrix},$$
 (1.120)

 $A_{11} \in \mathcal{M}^{m \times m}, A_{12} \in \mathcal{M}^{m \times (n-m)}, A_{21} \in \mathcal{M}^{(n-m) \times m}, A_{22} \in \mathcal{M}^{(n-m) \times (n-m)}$ . Cu acestea, și ținând cont de  $T = [T_1 \ T_2]$ , ecuația (1.119) se scrie

$$\begin{pmatrix} \begin{bmatrix} T_1 & T_2 \end{bmatrix} \begin{bmatrix} A_{11} & A_{12} \\ A_{21} & A_{22} \end{bmatrix} - E \begin{bmatrix} T_1 & T_2 \end{bmatrix} \end{pmatrix} \begin{bmatrix} 0_{m \times (n-m)} & I_{n-m} \end{bmatrix}^T = 0 \Leftrightarrow$$

$$\Leftrightarrow \begin{bmatrix} T_1 A_{11} + T_2 A_{21} - ET_1 & T_1 A_{12} + T_2 A_{22} - ET_2 \end{bmatrix} \begin{bmatrix} 0_{m \times (n-m)} & I_{n-m} \end{bmatrix}^T = 0,$$

$$(1.121)$$

echivalentă cu

$$T_1 A_{12} + T_2 A_{22} - ET_2 = 0. (1.122)$$

De asemenea, ținând cont de partiționarea matricei A (ecuația (1.120)) și a matricei T (ecuația (1.112)), ecuația (1.118) se scrie [180]

$$G = \left( \begin{bmatrix} T_1 & T_2 \end{bmatrix} \begin{bmatrix} A_{11} & A_{12} \\ A_{21} & A_{22} \end{bmatrix} - E \begin{bmatrix} T_1 & T_2 \end{bmatrix} \right) \begin{bmatrix} I_m & 0_{m \times (n-m)} \end{bmatrix}^T \begin{pmatrix} C_1^{-1} \end{pmatrix} \Leftrightarrow$$

$$\Leftrightarrow G = \begin{bmatrix} T_1 A_{11} + T_2 A_{21} - E T_1 & T_1 A_{12} + T_2 A_{22} - E T_2 \end{bmatrix} \begin{bmatrix} I_m & 0_{m \times (n-m)} \end{bmatrix}^T \begin{pmatrix} C_1^{-1} \end{pmatrix}$$
(1.123)

sau

$$G = (T_1 A_{12} + T_2 A_{22} - ET_2) (C_1^{-1}).$$
(1.124)

Ecuațiile (1.102) și (1.104) conduc la

$$K = FT + W \begin{bmatrix} C_1 & 0_{m \times (n-m)} \end{bmatrix} \Leftrightarrow W \begin{bmatrix} C_1 & 0_{m \times (n-m)} \end{bmatrix} = K - FT.$$
(1.125)

Înmulțind ecuația (1.125) la dreapta cu  $\begin{bmatrix} I_m & 0_{m \times (n-m)} \end{bmatrix}^T$ , se obține

$$WC_1 = (K - FT) [I_m \ 0_{(n-m) \times m}]^T,$$
 (1.126)

ecuație echivalentă cu

$$WC_{1} = \left( \begin{bmatrix} K_{1} & K_{2} \end{bmatrix} - F \begin{bmatrix} T_{1} & T_{2} \end{bmatrix} \right) \begin{bmatrix} I_{m} & 0_{(n-m) \times m} \end{bmatrix}^{T} \iff WC_{1} = \begin{bmatrix} K_{1} - FT_{1} & K_{2} - FT_{2} \end{bmatrix} \begin{bmatrix} I_{m} & 0_{(n-m) \times m} \end{bmatrix}^{T} (1.127)$$

sau

$$WC_1 = K_1 - FT_1. (1.128)$$

Înmulțind ecuația (1.125) la dreapta cu  $\begin{bmatrix} 0_{m \times (n-m)} & I_{n-m} \end{bmatrix}^T$ , se obține [180]

$$(K - FT) \begin{bmatrix} 0_{m \times (n-m)} & I_{n-m} \end{bmatrix}^T = 0 \Leftrightarrow (\begin{bmatrix} K_1 & K_2 \end{bmatrix} - F \begin{bmatrix} T_1 & T_2 \end{bmatrix}) \begin{bmatrix} 0_{m \times (n-m)} & I_{n-m} \end{bmatrix}^T = 0 \Leftrightarrow (1.129) \\ \Leftrightarrow \begin{bmatrix} K_1 - FT_1 & K_2 - FT_2 \end{bmatrix} \begin{bmatrix} 0_{m \times (n-m)} & I_{n-m} \end{bmatrix}^T = 0$$

sau

$$K_2 = FT_2$$
. (1.130)

S-au obținut 4 relații foarte importante (ecuațiile (1.122), (1.124), (1.128) și (1.130)), prin intermediul cărora se calculează matricele  $T_1, T_2, W$  și G. Matricea K, și implicit  $K_1$  și  $K_2$ , se calculează cu metoda LQR sau cu algoritmul ALGLX [157]; matricea E se obține alegând cele r valori proprii stabile ale acesteia, iar matricea F

se alege ca fiind o matrice  $(p \times r)$  cu elemente aparținând matricei K. Ordinul observerului se calculează ca fiind un număr natural cel puțin egal cu p(n - m)/m. Algoritmul Nakade&Galcade [180] poate fi sintetizat ca mai jos:

#### Algoritmul 4 (Algoritmul Nakade&Galcade [180])

**Pasul 1**: Se calculează ordinul observerului ca fiind numărul natural  $\geq p(n-m)/m$ .

**Pasul 2**: Se calculează matricea K cu metoda LQR, algoritmul ALGLX [157] sau alt algoritm din literatura de specialitate. Partiționarea matricei K se face conform ecuației (1.112);  $K_1 \in \mathcal{M}^{p \times m}, K_2 \in \mathcal{M}^{p \times (n-m)}$ .

**Pasul 3**: Se alege matricea F ca fiind o matrice  $(p \times r)$  cu elemente aparținând matricei K.

**Pasul 4**: Se alege aleator o matrice stabilă *E*.

**Pasul 5**: Folosind ecuația (1.130) și pseudo-inversarea matricelor, se determină  $T_2$ 

$$T_2 = F^+ K_2 \,. \tag{1.131}$$

**Pasul 6**: Se partiționează matricea A, conform ecuației (1.120), și se determină  $A_{11}, A_{12}, A_{21}$  și  $A_{22}$ .  $A_{12}, A_{22}, T_2$ , aflate la pasul anterior, și matricea E se introduc în ecuația (1.122) pentru determinarea matricei  $T_1$ . Se obține

$$T_1 = \left(EF^+K_2 - F^+K_2A_{22}\right) \cdot A_{12}^+ . \tag{1.132}$$

Cu  $T_1$  și  $T_2$  aflate la pașii 5 și 6 se construiește matricea

$$T = \begin{bmatrix} T_1 & T_2 \end{bmatrix} = \begin{bmatrix} (EF^+K_2 - F^+K_2A_{22})A_{12}^+ & F^+K_2 \end{bmatrix}.$$
 (1.133)

**Pasul** 7: Se calculează W cu ecuația (1.128) utilizând  $T_1$  cu forma (1.132); se obține

$$W = \left[K_1 - F\left(EF^+K_2 - F^+K_2A_{22}\right)A_{12}^+\right]C_1^{-1}.$$
 (1.134)

**Pasul 8**: Se calculează matricea G cu ecuația (1.124);  $T_1$  și  $T_2$  au formele (1.132), respectiv, (1.131).

Pasul 9: Se construiește observerul descris de ecuațiile (1.106) și (1.107) [180]

$$\dot{z}(t) = Ez(t) + TBu(t) + Gy(t),$$
  

$$z(t) - T\hat{x}(t) = 0.$$
(1.135)

## 1.3. PROIECTAREA OBSERVERELOR PENTRU DETECTAREA DEFECTELOR

Se pot construi observere pentru sisteme MIMO folosindu-se tehnica poziționării polilor; aceste observere pot fi implementate cu succes pe diverse UAV-uri. Recent există o preocupare majoră pentru proiectarea de observere care să fie folosite și în cazul defectelor (teoria FDI) [45], [63], [76], [99], [209], [249].

Se consideră sistemul descris de ecuațiile de stare (1.1), unde  $x \in \mathcal{M}^{n \times 1}$ ,  $u \in \mathcal{M}^{r \times 1}, y \in \mathcal{M}^{m \times 1}$ . Se proiectează un observer descris de ecuațiile

$$\begin{cases} \dot{\hat{x}}(t) = A\hat{x}(t) + Bu(t) + L(y(t) - \hat{y}(t)), \\ \hat{y}(t) = C\hat{x}(t); \end{cases}$$
(1.136)

 $\hat{x} \in \mathcal{M}^{n \times 1}, \hat{y} \in \mathcal{M}^{m \times 1}, L \in \mathcal{M}^{n \times m}.$ 

Se definesc, pentru sistemele (1.1) și (1.136) eroarea de estimare

$$e(t) = x(t) - \hat{x}(t)$$
(1.137)

și semnalul rezidual

$$r(t) = y(t) - \hat{y}(t). \tag{1.138}$$

Derivând semnalul eroare e, se obține [92]

$$\dot{e}(t) = \dot{x}(t) - \dot{\hat{x}}(t) = Ax(t) + Bu(t) - A\hat{x}(t) - Bu(t) - L(y(t) - \hat{y}(t)) = = (A - LC)x(t) - (A - LC)\hat{x}(t) = (A - LC)(x(t) - \hat{x}(t)) = (A - LC)e(t) = A_{obs}e(t).$$
(1.139)

De asemenea,

$$r(t) = y(t) - \hat{y}(t) = Cx(t) - C\hat{x}(t) = C(x(t) - \hat{x}(t)) = Ce(t).$$
(1.140)

Alăturând ecuațiile (1.139) și (1.140), se obține sistemul [92]

$$\begin{aligned}
\dot{e}(t) &= \dot{x}(t) - \dot{x}(t) = (A - LC)e(t) = A_{obs}e(t), \\
r(t) &= Ce(t).
\end{aligned}$$
(1.141)

Este de dorit ca eroarea  $e = x - \hat{x}$  a sistemului să tindă la zero. Pentru aceasta este suficient ca matricea  $A_{obs}$  să fie stabilă, adică  $\Lambda(A_{obs}) \subset C_{-}$ . Așadar, proiectarea sistemului este o chestiune relativ simplă dacă se impun valori proprii dorite pentru matricea  $A_{obs}$ . Alegerea lor este însă în strânsă legătură cu valorile proprii ale sistemului în circuit închis. Se consideră astfel că legea de conducere (reacția sistemului) este de forma

$$u = -Kx. \tag{1.142}$$

Prima ecuație (1.1) devine

$$\dot{x} = Ax - BKx = (A - BK)x = \widetilde{A}x, \qquad (1.143)$$

unde

$$\widetilde{A} = A - BK. \tag{1.144}$$

Atât matricea observerului  $A_{obs} = A - LC$  cât și matricea de stabilitate a sistemului  $\widetilde{A} = A - BK$  au *n* valori proprii. Fie  $s_i, i = \overline{1, n}$  cele *n* valori proprii ale matricei  $A_{obs}$  și  $\widetilde{s}_i, i = \overline{1, n}$  ele *n* valori proprii ale matricei  $\widetilde{A}$  [92]. Fie, de asemenea,  $v_i, i = \overline{1, n}$  – vectorii proprii asociați valorilor proprii  $s_i$  și  $\widetilde{v}_i, i = \overline{1, n}$  – vectorii proprii asociați valorilor proprii  $\widetilde{s}_i$ . În acest caz, sunt valabile ecuațiile

$$A\widetilde{v}_i = \widetilde{s}_i \widetilde{v}_i , A_{obs} v_i = s_i v_i .$$
(1.145)

Dacă se notează cu

$$\Omega = \operatorname{diag}\left(\widetilde{s}_{1}, \widetilde{s}_{2}, ..., \widetilde{s}_{n}\right)$$
(1.146)

matricea diagonală ce conține valorile proprii ale matricei  $\widetilde{A}$  (matrice ce descrie
sistemul în circuit închis) și cu

$$V = \begin{bmatrix} \widetilde{v}_1 & \widetilde{v}_2 & \cdots & \widetilde{v}_n \end{bmatrix}$$
(1.147)

matricea ce are ca și coloane vectorii proprii  $\tilde{v}_i$  asociați valorilor proprii  $\tilde{s}_i$ , prima ecuație (1.145) devine [92]

$$(A - BK)V = \Omega V \Leftrightarrow AV - BKV = \Omega V \tag{1.148}$$

sau

$$AV + BW = \Omega V, \tag{1.149}$$

în care s-a făcut notația

$$W = -KV. \tag{1.150}$$

Deoarece sistemul este controlabil [92],

$$\operatorname{rang}([A - sI_n \ B]) = n, (\forall) s \in C$$
(1.151)

și se pot alege două matrice inversabile  $P(s) \in \mathcal{M}^{n \times n}[s]$  și  $Q(s) \in \mathcal{M}^{(n+r) \times (n+r)}[s]$  care satisfac ecuația

$$P(s)[A - sI_n \ B] \cdot Q(s) = [0 \ I_n]$$
(1.152)

 $(\forall)_{s \in C}$ . În continuare, se partiționează matricea Q(s) astfel [92]

$$Q(s) = \begin{bmatrix} Q_{11}(s) & Q_{12}(s) \\ Q_{21}(s) & Q_{22}(s) \end{bmatrix},$$
(1.153)

în care  $Q_{11}(s) \in \mathcal{M}^{n \times r}[s], Q_{12}(s) \in \mathcal{M}^{n \times n}[s], Q_{21}(s) \in \mathcal{M}^{r \times r}[s]$  și  $Q_{22}(s) \in \mathcal{M}^{r \times n}[s]$  (*n* - numărul variabilelor de stare, *r* – numărul de intrări ale sistemului).

Dacă sistemul descris de ecuația (1.1) este controlabil,  $\operatorname{rang}(B) = r$  și matricea de stabilitate a sistemului  $(\widetilde{A})$  are valorile proprii  $\widetilde{s}_i$ , este posibilă obținerea matricei de amplificare K astfel [92]

$$K = -WV^{-1}, (1.154)$$

în care

$$V = \begin{bmatrix} \widetilde{v}_1 & \widetilde{v}_2 & \cdots & \widetilde{v}_n \end{bmatrix}, \widetilde{v}_i = Q_{11}(\mathbf{s}) \widetilde{f}_i, i = \overline{1, n}$$
(1.155)

şi

$$W = [w_1 \ w_2 \ \cdots \ w_n], w_i = Q_{21}(s) \widetilde{f}_i, i = \overline{1, n}, \qquad (1.156)$$

unde  $\widetilde{f}_i \in \mathbf{C}^r$  – vectori parametrici ce satisfac condițiile [92]

$$\widetilde{s}_i = \widetilde{s}_j \Leftrightarrow \widetilde{f}_i = \widetilde{f}_j, i, j = \overline{1, n}, \det(V) \neq 0.$$
 (1.157)

Pentru ca eroarea de estimare a observerului să tindă la zero  $(e \rightarrow 0)$  trebuie determinată matricea L astfel încât valorile proprii  $s_i$  ale matricei  $A_{obs}$  să fie situate în semiplanul stâng complex. Dacă sistemul descris de ecuația (1.1) este observabil  $\Leftrightarrow$  rang(C) = m și  $s_i$  sunt valorile proprii ale matricei  $A_{obs}$ , matricea de amplificare a observerului(L) se obține cu ecuația [92]

$$L = -(W_{obs} \ V_{obs}^{-1})^T, \tag{1.158}$$

în care

$$V_{obs} = [v_1 \ v_2 \ \cdots \ v_n], v_i = Q_{obs_{11}}(s_i) f_i, i = \overline{1, n}$$
(1.159)

şi

$$W_{obs} = [w_1 \ w_2 \ \cdots \ w_n], w_i = Q_{obs_{21}}(\mathbf{s}_i) f_i, i = \overline{1, n}$$
(1.160)

unde  $f_i \in \mathbf{C}^r$  – vectori parametrici ce satisfac condiția

$$s_i = \bar{s}_j \Leftrightarrow f_i = \bar{f}_j, i, j = 1, n.$$
(1.161)

Matricele  $Q_{obs_{11}}$  și  $Q_{obs_{21}}$  sunt submatrice ale matricei [92]

$$Q_{obs} = \begin{bmatrix} Q_{obs_{11}} & Q_{obs_{12}} \\ Q_{obs_{21}} & Q_{obs_{22}} \end{bmatrix},$$
(1.162)

$$\mathsf{cu} \ Q_{obs_{11}} \in \mathcal{M}^{n \times r}[\mathbf{s}], Q_{obs_{12}} \in \mathcal{M}^{n \times n}[\mathbf{s}], Q_{obs_{21}} \in \mathcal{M}^{n \times r}[\mathbf{s}] \ \text{si} \ Q_{obs_{22}} \in \mathcal{M}^{r \times n}[\mathbf{s}].$$

Observerul construit poate fi util în cazul în care se dorește detectarea defectelor. După ce a fost construit observerul, se calculează semnalul rezidual pentru a vedea dacă vreunul dintre senzorii din sistem s-a defectat. Astfel, dacă  $r(t) = y(t) - \hat{y}(t) = 0$ , înseamnă că senzorii funcționează bine. În cazul în care  $r(t) \neq 0$ , unul dintre senzori s-a defectat. Senzorul "k", care s-a defectat, este determinat calculând

$$r_k(t) = y_k(t) - \hat{y}_k(t), \qquad (1.163)$$

pentru toate cele "k" ieșiri ale sistemului  $(k = \overline{1, m})$ .

## **1.4. OBSERVERE OPTIMALE**

În cazul în care aparatul de zbor evoluează în condiții de perturbații aleatoare, se folosesc observerele optimale (filtrul Kalman-Bucy). Se consideră dinamica aeronavei descrisă de ecuația

$$\begin{cases} \dot{x}(t) = A(t)x(t) + B(t)u(t) + B^{*}(t)w(t), \\ y(t) = C(t)x(t) + v(t), \end{cases}$$
(1.164)

în care  $x \in \mathcal{M}^{n \times 1}$  este vectorul de stare,  $u \in \mathcal{M}^{m \times 1}$  – vectorul de comandă,  $A \in \mathcal{M}^{n \times n}$ ,  $B \in \mathcal{M}^{n \times m}, B^* \in \mathcal{M}^{n \times l}$  – matrice;  $w \in \mathcal{M}^{l \times 1}$  este un proces aleator de tip zgomot alb,  $y \in \mathcal{M}^{m \times 1}$  – vector măsurat,  $C \in \mathcal{M}^{m \times n}$  – matrice de selectare și  $v \in \mathcal{M}^{m \times 1}$  – zgomot asociat senzorilor (proces aleator de tip zgomot alb).

Procesele aleatoare  $w \neq v$  sunt descrise cu ajutorul matricelor de corelație

$$Q^{*}(t) = M[w(t)w^{T}(t')], R^{*}(t) = M[v(t)v^{T}(t')], \qquad (1.165)$$

unde M[·] reprezintă media,  $Q^*, R^*$  – matrice simetrice și pozitiv semidefinite care exprimă intensitățile zgomotelor w și v [92], [157]

$$Q^{*}(t) = \begin{bmatrix} q_{1}(t) & 0 & 0 & \cdots & 0 \\ 0 & q_{2}(t) & 0 & \cdots & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ 0 & 0 & 0 & \cdots & q_{l}(t) \end{bmatrix}, R^{*}(t) = \begin{bmatrix} r_{1}(t) & 0 & 0 & \cdots & 0 \\ 0 & r_{2}(t) & 0 & \cdots & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ 0 & 0 & 0 & \cdots & r_{m}(t) \end{bmatrix}.$$
 (1.166)

O covarianță mică implică intrări tip zgomot aproape de medie (zero în acest caz), iar o covarianță mare conduce la intrări zgomot departe de medie.

Procesele aleatoare w și v sunt necorelate între ele, adică

$$N(t) = \mathbf{M}[w(t)v^{T}(t')] = 0.$$
(1.167)

În aplicații practice, dacă  $B^*$  nu se cunoaște, se poate considera  $B^* = B$ .

Filtrul Kalman-Bucy are drept scop determinarea vectorului de stare estimat  $(\hat{x}(t))$ , funcție de măsurătorile  $y(\tau)(0 \le \tau < t)$ , care să minimezeze funcția [92]

$$J = \operatorname{trace}\left(L(t)\right),\tag{1.168}$$

în care L(t) este covarianța pentru eroarea de estimare

$$L(t) = M\left[ (x(t) - \hat{x}(t))(x(t) - \hat{x}(t))^T \right].$$
(1.169)

Estimatorul cuadratic liniar (LQE) se numește filtru Kalman-Bucy și este descris de ecuațiile (1.136) în care

$$L(t) = P^{*}(t)C^{T}(t)R^{*}(t); \qquad (1.170)$$

 $P^*(t)$  este o matrice pozitiv definită - soluție a ecuației Riccati [92]

$$\dot{P}^{*}(t) = A(t)P^{*}(t) + P^{*}(t)A^{T}(t) - P^{*}(t)C^{T}(t)R^{*-1}(t)C(t)P^{*}(t) + B^{*}(t)Q^{*}(t)B^{*T}(t)$$
(1.171)

sau

$$A(t)P^{*}(t) + P^{*}(t)A^{T}(t) - P^{*}(t)C^{T}(t)R^{*-1}(t)C(t)P^{*}(t) + B^{*}(t)Q^{*}(t)B^{*T}(t) = 0, \quad (1.172)$$

dacă sistemul este considerat invariant în timp. Considerând  $e(t) = x(t) - \hat{x}(t) -$  eroarea de estimare a filtrului, se poate determina ecuația asociată dinamicii erorii

$$\dot{e}(t) = A(t)x(t) + B(t)u(t) + B^{*}(t)w(t) - A(t)\hat{x}(t) - B(t)u(t) - L(t)[C(t)x(t) - C(t)\hat{x}(t)] - L(t)v(t) = [A(t) - L(t)C(t)]e(t) + B^{*}(t)w(t) - L(t)v(t).$$
(1.173)

Aşadar, viteza de convergență este dependentă de valorile proprii (părțile reale ale valorilor proprii) ale matricei (A(t) - L(t)C(t)) dar și de zgomotul senzorilor. Asupra estimatorului cuadratic linear (LQE) întotdeauna va exista o influență a zgomotului procesului (w) și o influență a zgomotului senzorilor (v). Alegerea matricei A(t) va accentua/diminua efectul lui v(t) asupra lui  $\hat{x}(t)$  [92].

Dacă  $Q^*(t)$  și  $R^*(t)$  sunt matrice simetrice și pozitiv semidefinite, dinamica sistemului este considerată constantă în timp,  $(A, B^*)$  – pereche controlabilă și (A, C) – pereche detectabilă, se poate determina  $P^*(t)$  ca soluție a ecuației (1.171) și apoi matricea de amplificare a observerului L(t). Pentru filtrul Kalman-Bucy se tip optimal, se obține funcția de transfer [92]

$$\frac{\hat{X}(s)}{Y(s)} = \frac{L}{sI - (A - LC)}.$$
 (1.174)

Funcția de transfer face legătura între "măsurători" și "starea estimată.

In fig. 1.13 este prezentată schema bloc de modelare a sistemului de comandă optimală a mișcării aparatului de zbor, constituită din următoarele subsisteme: modelul dinamic al aparatului de zbor, sistemul de măsurare, observerul optimal de tip filtru Kalman-Bucy și subsistemul de comandă optimală (matricea de amplificare K).



Fig. 1.13. Schema bloc de modelare a filtrului Kalman-Bucy

Se consideră mișcarea aeronavei descrisă de ecuația de stare (1.47) [157] și de ecuația de ieșire y = Cx + v cu  $C = \begin{bmatrix} 0 & 0 & 1 & 0 \\ 0 & -1 & 1 & 0 \end{bmatrix}$ , adică  $y^T = \begin{bmatrix} 0 & 9 \end{bmatrix}$ ,  $9 = \theta - \alpha$ . Alegând  $Q^* = \begin{bmatrix} 0.01 \end{bmatrix}$  și  $R^* = \begin{bmatrix} 0.01 & 0 \\ 0 & 0.01 \end{bmatrix}$ , se rezolvă ecuația Riccati (1.172) și rezultă  $P^* = \begin{bmatrix} 1.73 & -0.20 & -0.11 & -0.02 \\ -0.20 & 0.04 & 0.04 & 0.08 \\ -0.11 & 0.04 & 0.04 & 0.09 \\ -0.02 & 0.08 & 0.09 & 0.44 \end{bmatrix}$ ,  $L = \begin{bmatrix} -11.01 & 9.58 \\ 4.01 & -0.93 \\ 4.26 & 0.24 \\ 9.11 & 0.57 \end{bmatrix}$ . (1.175)

Programul Matlab din anexa A1.3 reprezintă implementarea software a procedurii de construcție a filtrului Kalman-Bucy; matricele  $P^*$  și L se calculează cu instrucțiunea LQE, cu sintaxa [L, P, E] = LQE(A, G, C, Q, R, N), în care:  $P = P^*, Q = Q^*, R = R^*, G = B^*,$ N este matricea din ecuația (1.167), iar E reprezintă vectorul ce conține valorile proprii ale matricei A-LC.

În fig. 1.14 este prezentat modelul Matlab/Simulink pentru structura din fig. 1.13. Cu acesta, rezultă caracteristicile de timp din fig. 1.15 (erorile de estimare a variabilelor de stare cu estimatorul de stare Kalman-Bucy pentru u = 0) și caracteristicile de timp din fig. 1.16 pentru legea de comandă  $u = -K\hat{x}$  (*K* calculată cu algoritmul ALGLX); aceste caracteristici exprimă variabilele de stare  $x_i(t)$  – cu linie continuă și  $\hat{x}_i(t)$  – cu linie întreruptă.



Fig. 1.14. Modelul Matlab/Simulink pentru structura din fig. 1.13



Fig. 1.15. Erorile de estimare a stării estimatorului Kalman-Bucy (K = 0)



Fig. 1.16. Variabilele de stare  $x_i(t)$  și  $\hat{x}_i(t)$  - mișcarea longitudinală  $(K \neq 0)$ 

Se implementează software filtrul Kalman-Bucy și pentru cazul mișcării laterale a unei aeronave Boeing 747; ecuația de stare a mișcării laterale este (1.49). Se obțin

$$P^* = \begin{bmatrix} 0.0087 & -0.0004 & 0.0016 & 0.0002 \\ -0.0004 & 0.0055 & 0.0027 & 0.0023 \\ 0.0016 & 0.0027 & 0.0104 & 0.0070 \\ 0.0002 & 0.0023 & 0.0070 & 0.0120 \end{bmatrix}, \ L = \begin{bmatrix} 0.0238 \\ 0.2340 \\ 0.6993 \\ 1.1985 \end{bmatrix};$$
(1.176)

erorile de estimare a variabilelor de stare sunt prezentate în fig. 1.17 (pentru K=0), iar variabilele de stare  $x_i(t)$  și  $\hat{x}_i(t)$  pentru K calculat cu algoritmul ALGLX sunt prezen-

tate în fig. 1.18. Programul Matlab utilizat este similar celui din anexa A1.3, iar modelul Matlab/Simulink este identic cu cel din fig. 1.14.



Fig. 1.17. Erorile de estimare a stării estimatorului Kalman-Bucy (K=0)



Fig. 1.18. Variabilele de stare  $x_i(t)$  și  $\hat{x}_i(t)$  - mișcarea laterală  $(K \neq 0)$ 

# 1.5. TEHNICI DE PROIECTARE A OBSERVERELOR LINIARE DISCRETE

## **1.5.1. CHESTIUNI GENERALE**

Se consideră sistemul discret descris de ecuațiile de stare în variantă discretă [231]

$$x_{k+1} = Ax_k + Bu_k, y_k = Cx_k, (1.177)$$

în care  $x_k \in R^n$  este vectorul de stare discret cu *n* componente,  $u_k \in R^l$  – vectorul de ieșire cu *l* componente, iar  $y_k \in R^m$  – vectorul celor *m* ieșiri ale sistemului discret.

Există două tipuri de estimatoare ca urmare a măsurătorii care trebuie să fie disponibilă la momentul k sau la momentul k + 1. În primul caz, estimatorul se numește *estimator-predictor* și oferă o estimare a stării  $\hat{x}_{k+1/k}$  la momentul k + 1, cunoscându-se estimarea de la momentul k; în al doilea caz, se construiește un *estimator-corector*, estimarea fiind notată cu  $\hat{x}_{k+1/k+1}$ .

#### Cazul 1: Estimatorul - predictor

În acest caz, se cunoaște  $y_k$  dar nu se cunoaște  $y_{k+1}$  [231]

$$\hat{x}_{k+1/k} = A\hat{x}_{k/k-1} + Bu_k + K_p (y_k - \hat{y}_{k/k-1}), \qquad (1.178)$$

unde  $\hat{y}_{k/k-1} = C\hat{x}_{k/k-1}$ . Introducând expresia lui  $\hat{y}_{k/k-1}$  în ecuația (1.178), se obține

$$\hat{x}_{k+1/k} = A\hat{x}_{k/k-1} + Bu_k + K_p(y_k - C\hat{x}_{k/k-1}) = (A - K_pC)\hat{x}_{k/k-1} + Bu_k + K_py_k .$$
(1.179)

Structura anterioară este identică cu cea din cazul sistemelor continue. Dacă se notează eroarea observerului discret cu [231]

$$\widetilde{x}_{k+1/k} = x_{k+1} - \hat{x}_{k+1/k} , \qquad (1.180)$$

ecuația estimatorului de stare se scrie

$$\widetilde{x}_{k+1/k} = (A - K_p C) \widetilde{x}_{k+1/k};$$
 (1.181)

estimatorul este asimptotic stabil dacă matricea  $(A - K_p C)$  este stabilă, adică dacă valorile proprii ale matricei sunt în modul subunitare (matricea  $(A - K_p C)$  este matrice Schur) [231].

#### Cazul 2: Estimatorul - corector

În acest caz,  $y_{k+1}$  este cunoscut, ecuația observerului fiind

$$\hat{x}_{k+1/k+1} = A\hat{x}_{k/k} + Bu_k + K_c(y_{k+1} - \hat{y}_{k+1}); \qquad (1.182)$$

 $\hat{y}_{k+1}$  reprezintă estimarea ieșirii la momentul k + 1. Ea se poate realiza în două moduri diferite: anticipare și predicție.

În primul caz

$$\hat{y}_{k+1} = C\hat{x}_{k+1/k+1}; \qquad (1.183)$$

eroarea estimatorului este [231]

$$\widetilde{x}_{k+1/k+1} = x_{k+1} - \hat{x}_{k+1/k+1}, \qquad (1.184)$$

iar eroarea estimatorului devine

$$\hat{x}_{k+1/k+1} = \left(I + K_c C\right)^{-1} A \widetilde{x}_{k/k} .$$
(1.185)

Estimatorul este stabil dacă matricea  $(I + K_c C)^{-1}$  este matrice Schur.

În cel de-al doilea caz [231]

$$\hat{y}_{k+1} = C(A\hat{x}_{k/k} + Bu_k); \tag{1.186}$$

ecuația estimatorului devine

$$\hat{x}_{k+1/k+1} = (I - K_c C) (A \hat{x}_{k/k} + B u_k) + K_c y_{k+1}.$$
(1.187)

Cu aceleași notații ca și în cazul precedent

$$\widetilde{x}_{k+1/k+1} = (I - K_c C) A \hat{x}_{k/k} .$$
(1.188)

Estimatorul este asimptotic stabil dacă  $(I - K_c C)$  este matrice Schur. Metodologia de calcul a amplificărilor  $K_p$  și  $K_c$  este prezentată mai jos [231].

Eroarea de estimare este dată de ecuația scrisă sub formă unificată

$$\widetilde{x}_{k+1} = \left(A - KC^*\right)\widetilde{x}_k. \tag{1.189}$$

Se notează cu  $z_k$  variabila a cărei evoluție este

$$z_{k+1} = A^T z_k + C^{*T} w_k . (1.190)$$

Căutarea legii de comandă  $w_k^*$  se face prin minimizarea criteriului de performanță

$$J = \frac{1}{2} \sum_{k=0}^{\infty} \left( z_k^T Q z_k + w_k^T R w_k \right),$$
(1.191)

unde Q și R sunt matrice simetrice și pozitiv definite. Se obține [231]

$$w_k^* = \left(R - C^* L C^{*T}\right)^{-1} C^* L A^T z_k , \qquad (1.192)$$

în care L este soluția ecuației Riccati

$$Q + L = ALA^{T} + ALC^{*T} \left( R - C^{*}LC^{*T} \right)^{-1} C^{*}LA^{T} .$$
 (1.193)

Se obține [231]

$$K_{p} = -AL_{p}C^{T} \left( R - CL_{p}C^{T} \right)^{-1}, \qquad (1.194)$$

cu  $L_p$  – soluția ecuației

$$Q + L_p = AL_p A^T + AL_p C^T (R - CL_p C^T)^{-1} CL_p A^T$$
(1.195)

sau

$$K_{c} = -AL_{c}C^{T} \left( R - CL_{c}C^{T} \right)^{-1} CAL_{c}A^{T}, \qquad (1.196)$$

cu  $L_c$  – soluția ecuației

$$Q + L_{c} = AL_{c}A^{T} + AL_{c}C^{T} (R - CAL_{c}A^{T}C^{T})^{-1}CAL_{c}A^{T}.$$
 (1.197)

Din cele două tipuri de estimatoare discrete, estimatorul predictor este cel mai utilizat datorită analogiilor care există între acesta și estimatoarele continue.

Ecuațiile estimatoarelor predictor pot fi puse și sub alte forme dacă se ia în considerație și matricea nenulă D din ecuația de stare [96]

$$x(k+1) = Ax(k) + Bu(k), y(k) = Cx(k) + Du(k).$$
(1.198)

Ecuațiile observerului discret sunt

$$\hat{x}(k+1) = A\hat{x}(k) + Bu(k) + K_p[y(k) - \hat{y}(k)], \ \hat{y}(k) = C\hat{x}(k) + Du(k).$$
(1.199)

Notând eroarea observerului cu  $e(k) = \hat{x}(k) - x(k)$ , pentru un observer Luenberger discret, se obține

$$e(k+1) = (A - K_{p}C)e(k).$$
(1.200)

În ecuațiile (1.198) și (1.199), intrarea observerului u(k) se calculează ca și în cazul sistemelor continue:  $u(k) = -K\hat{x}(k)$ ; ecuațiile observerului devin [96]

$$\hat{x}(k+1) = A\hat{x}(k) - BK\hat{x}(k) + K_p[y(k) - \hat{y}(k)], \ \hat{y}(k) = C\hat{x}(k) - DK\hat{x}(k)$$
(1.201)

sau, mai simplu,

$$\hat{x}(k+1) = (A - BK)\hat{x}(k) + K_p[y(k) - \hat{y}(k)], \ \hat{y}(k) = (C - DK)\hat{x}(k);$$
(1.202)

matricea K se poate determina impunând valori proprii dorite pentru matricea (A - BK).

## **1.5.2. FILTRUL DISCRET KALMAN-BUCY**

Se consideră sistemul discret descris de ecuațiile de stare [4], [59], [196]

$$x(k+1) = Ax(k) + Bu(k) + B^*w(k), y(k) = Cx(k) + v(k),$$
(1.203)

unde w și v sunt procese aleatoare de tip zgomote albe. Matricele de corelație ale celor două procese aleatoare sunt

$$R_{w} = \mathbf{M}[w(k)w^{T}(k)], R_{v} = \mathbf{M}[v(k)v^{T}(k)].$$
(1.204)

Se condideră că cele două procese sunt necorelate, adică, pentru orice  $i \neq j$ ,

$$M[w(i)w^{T}(j)] = 0, M[v(i)v^{T}(j)].$$
(1.205)

Proiectarea filtrului Kalman presupune determinarea unei matrice de amplificare L care să minimizeze

$$P(k) = M\left\{ [x(k) - \hat{x}(k)] [x(k) - \hat{x}(k)]^{T} \right\};$$
(1.206)

Structura observerului este [4], [59], [196]

$$\hat{x}(k) = A\bar{x}(k) + L_0(k)[y(k) - C\bar{x}(k)], \qquad (1.207)$$

unde matricea  $L_0(k)$  se calculează astfel:

$$L_0(k) = P(k)C^T R_v^{-1}, (1.208)$$

iar matricea P(k) se exprimă cu relația

$$P(k) = N(k) - N(k)C^{T} [CN(k)C^{T} + R_{v}]^{-1} CN(k).$$
(1.209)

Matricea N(k) este covarianța estimărilor  $\bar{x}(k)$ .  $\bar{x}(k)$  din ecuația (1.207) se calculează după cum urmează:

$$\bar{x}(k) = A\hat{x}(k-1) + Bu(k-1), \qquad (1.210)$$

iar actualizarea matricei de corelație N(k) se face cu formula [4], [59], [196]

$$N(k+1) = AP(k)A^{T} + B^{*}R_{w}B^{*T}.$$
(1.211)



Fig. 1.19. Schema bloc de modelare a filtrului discret Kalman-Bucy

Ecuațiile (1.209) și (1.211) conduc la ecuația

$$N(k+1) = A \left\{ N(k) - N(k) C^{T} [CN(k)C^{T} + R_{v}]^{-1} CN(k) \right\} A^{T} + B^{*} R_{w} B^{*T}. \quad (1.212)$$

Schema bloc de modelare a filtrului discret Kalman-Bucy este prezentată în fig. 1.19.

Considerând parcursă iterația k+1, deci considerând că se cunosc x(k-1),

 $\hat{x}(k-1), u(k-1), P(k-1)$  și w(k-1), cronologia pașilor la iterația k este următoarea:

**Pasul 1**: Se determină  $\bar{x}(k)$  cu ecuația (1.210).

**Pasul 2:** Se determină matricea *N*(*k*) astfel

$$N(k) = AP(k-1)A^{T} + B^{*}R_{w}B^{*T}.$$
(1.213)

**Pasul 3:** Se calculează matricea P(k) în funcție de N(k) utilizând ecuația (1.209). **Pasul 4:** Se calculează matricea  $L_0(k)$  cu ecuația (1.208). **Pasul 5:** Se calculează x(k) și y(k) astfel:

$$x(k) = Ax(k-1) + Bu(k-1) + B^*w(k-1), y(k) = Cx(k) + v(k).$$
(1.214)

**Pasul 6:** Se calculează  $\hat{x}(k)$  utilizând ecuația (1.207) și  $u(k) = -K\hat{x}(k)$ .

În cele ce urmează, se validează algoritmul de proiectare a filtrului Kalman-Bucy pentru două cazuri ale mișcărilor longitudinală, respectiv laterală ale aeronavelor.



Fig. 1.20. Variabilele de stare  $x_i(t)$  și  $\hat{x}_i(t)$  - mișcarea longitudinală

Pentru început, se consideră mișcarea longitudinală a unei aeronave descrisă de ecuația de stare (1.47) [157] și de ecuația de ieșire y=Cx+v cu  $C=I_4$ . Programul Matlab din anexa A1.4 reprezintă implementarea software a procedurii de construcție a filtrului discret Kalman-Bucy; matricele N, P și  $L_0$  se calculează la fiecare iterație k. Matricea de amplificare K se calculează în Matlab utilizând instrucțiunea **DLQR** cu sintaxa

 $[K, S, E] = DLQR(A_d, B_d, Q, R);$  matricele  $A_d$  și  $B_d$  sunt transpunerile discrete ale matricelor A și B. Utilizând programul Matlab din anexă, rezultă caracteristicile de timp din fig. 1.20 pentru legea de comandă  $u = -K\hat{x}$ ; aceste caracteristici exprimă variabilele de stare  $x_i(t)$  – cu linie continuă și  $\hat{x}_i(t)$  – cu linie întreruptă.

Se implementează software filtrul discret Kalman-Bucy și pentru cazul mișcării laterale a unei aeronave Boeing 747, care zboară cu M = 0.8 la H = 40000 ft; ecuația de stare a mișcării laterale este (1.49) [157]. Programul Matlab utilizat este similar celui din anexa A1.4. Variabilele de stare  $x_i(t)$  și  $\hat{x}_i(t)$ , pentru K calculat folosind instrucțiunea DLQR, sunt prezentate în fig. 1.21.



Fig. 1.21. Variabilele de stare  $x_i(t)$  și  $\hat{x}_i(t)$  - mișcarea laterală

# 1.6. ESTIMAREA INTRĂRILOR NECUNOSCUTE PENTRU SISTEMELE LINIARE

## 1.6.1. ALGORITMI PENTRU ESTIMAREA INTRĂRILOR NECUNOSCUTE ALE SISTEMELOR LINIARE

#### 1.6.1.1. Introducere

Estimarea intrărilor necunoscute poate avea o importanță deosebită în procesul de detecție a defectelor. Hou și Muller [84] sunt autorii unui algoritm de proiectare a

unui observer cu ordin redus pentru sisteme liniare cu intrări necunoscute. Ei au împărțit sistemul asociat ecuației de stare în două subsisteme: primul depinde de intrările necunoscute, iar în cel de-al doilea intrările necunoscute nu contează [84], [168]. Având în vedere că starea celui de-al doilea subsistem poate fi obținută prin măsurători, Hou și Muller au proiectat un observer cu ordin redus pentru intrări necunoscute.

#### 1.6.1.2. Algoritmul Hou & Muller

Se consideră sistemul invariant în timp [84], [168]

$$\begin{cases} x(k+1) = Ax(k) + Bu(k) + Dd(k) \\ y(k) = Cx(k), \end{cases}$$
(1.215)

unde  $x \in \mathcal{M}^{n \times 1}$  este vectorul de stare,  $u \in \mathcal{M}^{p \times 1}$  – vectorul intrărilor,  $y \in \mathcal{M}^{m \times 1}$  – vectorul de ieșire (vectorul măsurătorilor) și  $d \in \mathcal{M}^{s \times 1}$  – vectorul intrărilor necunoscute; matricele A, B, C, D au, respectiv, dimensiunile:  $A \in \mathcal{M}^{n \times n}, B \in \mathcal{M}^{n \times p}, C \in \mathcal{M}^{m \times n}, D \in \mathcal{M}^{n \times s}$ . Algoritmul propus de Hou și Muller presupune că matricea C are rang de linie maxim (toți vectorii linie ai matricei C sunt liniari independenți) și matricea D are rang de coloană maxim (toți vectorii coloană ai matricei D sunt liniari independenți). Ultima presupunere conduce la [84], [168]

$$D = H \begin{bmatrix} R \\ 0 \end{bmatrix} K^{T}, \qquad (1.216)$$

unde  $H \in \mathcal{M}^{n \times n}$ ,  $R \in \mathcal{M}^{s \times s}$ ,  $K \in \mathcal{M}^{s \times s}$ . În ecuația (1.216) matricea H trebuie să fie ortogonală ( $HH^T = I$ ). Introducând D de forma (1.216) în ecuațiile (1.215) se obține

$$x(k+1) = Ax(k) + Bu(k) + H\begin{bmatrix} R\\ 0 \end{bmatrix} K^{T} d(k), y(k) = Cx(k).$$
(1.217)

Se înmulțește la stânga cu  $H^T$  prima ecuație (1.217) și se obține [84], [168]

$$H^{T}x(k+1) = H^{T}AHH^{T}x(k) + H^{T}Bu(k) + H^{T}H\begin{bmatrix} R\\0 \end{bmatrix}K^{T}d(k), y(k) = CHH^{T}x(k) \quad (1.218)$$

sau

$$\overline{x}(k+1) = \overline{A}\overline{x}(k) + \overline{B}u(k) + \begin{bmatrix} R \\ 0 \end{bmatrix} \overline{d}(k), \ y(k) = \overline{C}\overline{x}(k),$$
(1.219)

în care

$$\overline{x}(k) = H^T x(k), \overline{d}(k) = K^T d(k), \overline{A} = H^T A H, \overline{B} = H^T B, \overline{C} = CH.$$
(1.220)

Noul vector de stare  $\overline{x}(k)$  se scrie astfel:

$$\overline{\mathbf{x}}(k) = \left[\overline{\mathbf{x}}_1(k) \ \overline{\mathbf{x}}_2(k)\right]^T, \tag{1.221}$$

unde  $\overline{x}_1(k) \in \mathcal{M}^{s \times 1}$  – vectorul de stare asociat intrărilor necunoscute,  $\overline{x}_2(k) \in \mathcal{M}^{(n-s) \times 1}$  – vectorul de stare asociat intrărilor cunoscute. Matricele  $\overline{A}, \overline{B}$  și  $\overline{C}$  se partiționează după cum urmează [84], [168]:

$$\overline{A} = \begin{bmatrix} \overline{A}_{11} & \overline{A}_{12} \\ \overline{A}_{21} & \overline{A}_{22} \end{bmatrix}, \overline{B} = \begin{bmatrix} \overline{B}_1 \\ \overline{B}_2 \end{bmatrix}, \overline{C} = \begin{bmatrix} \overline{C}_1 & \overline{C}_2 \end{bmatrix},$$
(1.222)

în care

$$\begin{split} \overline{A}_{11} &\in \mathcal{M}^{s \times s}, \overline{A}_{12} &\in \mathcal{M}^{s \times (n-s)}, \overline{A}_{21} &\in \mathcal{M}^{(n-s) \times s}, \overline{A}_{22} &\in \mathcal{M}^{(n-s) \times (n-s)}, \\ \overline{B}_{1} &\in \mathcal{M}^{s \times p}, \overline{B}_{2} &\in \mathcal{M}^{(n-s) \times p}, \overline{C}_{1} &\in \mathcal{M}^{m \times s}, \overline{C}_{2} &\in \mathcal{M}^{m \times (n-s)}. \end{split}$$

Cele două ecuații (1.219), utilizând (1.221) și (1.222), devin

$$\begin{cases} \overline{x}_{1}(k+1) = \overline{A}_{11}\overline{x}_{1}(k) + \overline{A}_{12}\overline{x}_{2}(k) + \overline{B}_{1}u(k) + R\overline{d}(k), \\ \overline{x}_{2}(k+1) = \overline{A}_{21}\overline{x}_{1}(k) + \overline{A}_{22}\overline{x}_{2}(k) + \overline{B}_{2}u(k), \\ y(k) = \overline{C}_{1}\overline{x}_{1}(k) + \overline{C}_{2}\overline{x}_{2}(k). \end{cases}$$
(1.223)

Algoritmul propus de Hou și Muller [84] funcționează în continuare doar dacă matricea  $\overline{C}_1$  are rang de coloană maxim. În acest caz  $\overline{C}_1$  se poate scrie printr-o ecuație similară ecuației (1.216):

$$\overline{C}_1 = H_1 \begin{bmatrix} R_1 \\ 0 \end{bmatrix} K_1^T, \qquad (1.224)$$

unde  $H_1 \in \mathcal{M}^{m \times m}, K_1 \in \mathcal{M}^{s \times s}, R_1 \in \mathcal{M}^{s \times s}$ . În continuare, se partiționează matricea  $H_1$  astfel [84], [168]

$$H_1 = [H_{11} \ H_{12}]; \tag{1.225}$$

 $H_{11} \in \mathcal{M}^{m \times s}, H_{12} \in \mathcal{M}^{m \times (m-s)}$ . Dacă se face notația [84]

$$\overline{y}(k) = H_1^T y(k) = \begin{bmatrix} H_{11}^T \\ H_{12}^T \end{bmatrix} y(k) = \begin{bmatrix} \overline{y}_1(k) \\ \overline{y}_2(k) \end{bmatrix}, \qquad (1.226)$$

a treia ecuație (1.223) devine

$$y(k) = H_1 \begin{bmatrix} R_1 \\ 0 \end{bmatrix} K_1^T \bar{x}_1(k) + \bar{C}_2 \bar{x}_2(k).$$
(1.227)

Se înmulțește această ultimă ecuație la stânga cu $H_1^{\rm T}$ și rezultă

$$H_{1}^{T} y(k) = \underbrace{H_{1}^{T} H_{1}}_{I} \begin{bmatrix} R_{1} \\ 0 \end{bmatrix} K_{1}^{T} \overline{x}_{1}(k) + H_{1}^{T} \overline{C}_{2} \overline{x}_{2}(k) \Leftrightarrow$$

$$\Leftrightarrow \begin{bmatrix} H_{11}^{T} \\ H_{12}^{T} \end{bmatrix} y(k) = \begin{bmatrix} R_{1} \\ 0 \end{bmatrix} K_{1}^{T} \overline{x}_{1}(k) + \begin{bmatrix} H_{11}^{T} \\ H_{12}^{T} \end{bmatrix} \overline{C}_{2} \overline{x}_{2}(k)$$
(1.228)

echivalentă cu

$$\overline{y}_{1}(k) = R_{1}K_{1}^{T}\overline{x}_{1}(k) + H_{11}^{T}\overline{C}_{2}\overline{x}_{2}(k), \ \overline{y}_{2}(k) = C_{2}\overline{x}_{2}(k),$$
(1.229)

unde

$$C_2 = H_{12}^T \overline{C}_2 \,. \tag{1.230}$$

Ținând cont de expresia

$$\overline{y}_1(k) = \begin{bmatrix} I_s & 0 \end{bmatrix} \begin{bmatrix} \overline{y}_1(k) \\ \overline{y}_2(k) \end{bmatrix} \Leftrightarrow \overline{y}_1(k) = G^T \overline{y}(k), \qquad (1.231)$$

din prima ecuație (1.229) se obține [84]

$$\bar{x}_{1}(k) = \left(R_{1}K_{1}^{T}\right)^{-1}\left[\bar{y}_{1}(k) - H_{11}^{T}\overline{C}_{2}\bar{x}_{2}(k)\right] = \left(R_{1}K_{1}^{T}\right)^{-1}\left[G^{T}\underbrace{H_{1}^{T}y(k)}_{\bar{y}(k)} - H_{11}^{T}\overline{C}_{2}\bar{x}_{2}(k)\right]$$
(1.232)

echivalentă cu

$$\bar{x}_{1}(k) = K_{1}R_{1}^{-1}G^{T}H_{1}^{T}[y(k) - \bar{C}_{2}\bar{x}_{2}(k)]; \qquad (1.233)$$

în ecuația de mai sus s-a ținut cont de

$$\left(R_{1}K_{1}^{T}\right)^{-1} = K_{1}R_{1}^{-1}, \qquad (1.234)$$

întrucât  $K_1$  este matrice ortogonală, dar și de relația

$$G^{T}H_{1}^{T} = \begin{bmatrix} I_{s} & 0 \end{bmatrix} \begin{bmatrix} H_{11}^{T} \\ H_{12}^{T} \end{bmatrix} = H_{11}^{T}.$$
 (1.235)

În continuare, se introduce  $\overline{x}_1(k)$  cu forma (1.233) în cea de-a doua ecuație (1.223) și se obține [84]

$$\overline{x}_{2}(k+1) = \overline{A}_{21}K_{1}R^{-1}G^{T}H_{1}^{T}y(k) - \overline{A}_{21}K_{1}R^{-1}G^{T}H_{1}^{T}\overline{C}_{2}\overline{x}_{2}(k) + \overline{A}_{22}\overline{x}_{2}(k) + \overline{B}_{2}u(k) \quad (1.236)$$

sau

$$\bar{x}_2(k+1) = A_2 \bar{x}_2(k) + B_2 u(k) + D_2 y(k), \qquad (1.237)$$

în care

$$A_{2} = \overline{A}_{22} - \overline{A}_{21}K_{1}R^{-1}G^{T}H_{1}^{T}, B_{2} = \overline{B}_{2}, D_{2} = \overline{A}_{21}K_{1}R^{-1}G^{T}H_{1}^{T}.$$
(1.238)

Pentru estimarea vectorului  $\bar{x}_2$ , se construiește un observer de tip Luenberger bazat pe ecuația (1.237) și pe a doua ecuație (1.229). Acest observer poate fi construit dacă și numai dacă perechea  $(A_2, C_2)$  este observabilă. Ecuația asociată observerului este [84], [168]

$$\hat{x}_{2}(k+1) = (A_{2} - LC_{2})\hat{x}_{2}(k) + B_{2}u(k) + (D_{2} + LH_{12}^{T})y(k).$$
(1.239)

În proiectarea observerului (ecuația (1.239)) s-a avut în vedere faptul că

 $L\underbrace{H_{12}^{T}y(k)}_{\overline{y_2}(k)} = LC_2\overline{x}_2(k). \ \overline{d}(k) \text{ si, implicit, } d(k) \text{ se obțin din prima ecuație (1.223) după}$ 

cum urmează:

$$\overline{x}_{1}(k+1) = \overline{A}_{11}\overline{x}_{1}(k) + \overline{A}_{12}\overline{x}_{2}(k) + \overline{B}_{1}u(k) + RK^{T}d(k) \Leftrightarrow$$
$$\Leftrightarrow d(k) = \underbrace{(RK^{T})^{-1}}_{KR^{-1}} [\overline{x}_{1}(k+1) - \overline{A}_{11}\overline{x}_{1}(k) - \overline{A}_{12}\overline{x}_{2}(k) - \overline{B}_{1}u(k)]$$
(1.240)

echivalentă cu

$$d(k) = KR^{-1} \{ \overline{x}_1(k+1) - \overline{A}_{11}K_1R_1^{-1}G^TH_1^T [y(k) - \overline{C}_2\overline{x}_2(k)] - \overline{A}_{12}\overline{x}_2(k) - \overline{B}_1u(k) \} = = KR^{-1}\overline{x}_1(k+1) - KR^{-1}\overline{A}_{11}R_1^{-1}G^TH_1^Ty(k) + + (KR^{-1}R_1^{-1}G^TH_1^T\overline{C}_2 - KR^{-1}\overline{A}_{12})\overline{x}_2(k) - KR^{-1}\overline{B}_1u(k).$$
(1.241)

 $\bar{x}_2$  se estimează cu observerul (1.239) și, deci, intrarea necunoscută estimată  $\hat{d}(k)$  se calculează cu formula

$$\hat{d}(k) = KR^{-1}\overline{x}_{1}(k+1) - KR^{-1}\overline{A}_{11}R_{1}^{-1}G^{T}H_{1}^{T}y(k) + + \left(KR^{-1}R_{1}^{-1}G^{T}H_{1}^{T}\overline{C}_{2} - KR^{-1}\overline{A}_{12}\right)\overline{x}_{2}(k) - KR^{-1}\overline{B}_{1}u(k).$$
(1.242)

Aşadar,  $\bar{x}_2(k)$  se estimează cu observerul descris de ecuația (1.239), iar  $\bar{x}_1(k)$  se determină apoi cu o ecuație de tipul (1.233) în care  $\bar{x}_2 \rightarrow \hat{x}_2$ 

$$\hat{\overline{x}}_{1}(k) = K_{1}R_{1}^{-1}G^{T}H_{1}^{T}\left[y(k) - \overline{C}_{2}\hat{\overline{x}}_{2}(k)\right].$$
(1.243)

#### Algoritmul Hou & Muller

**Pasul 1**: Se verifică dacă matricea *D* are rang de coloană maxim.

**Pasul 2**: Se determină matricele H, R și K utilizând ecuația (1.216).

**Pasul 3**: Se calculează matricele  $\overline{A}, \overline{B}, \overline{C}$  utilizând ecuația (1.220) și apoi se partiționează vectorul de stare  $\overline{x}(k) = H^T x(k) \rightarrow$  ecuația (1.221).

**Pasul 4**: Se partiționează matricele  $\overline{A}, \overline{B}, \overline{C} \rightarrow$  ecuația (1.222).

**Pasul 5**: Se verifică dacă  $\overline{C}_1$  are rang de coloană maxim. În caz contrar algoritmul nu

poate continua.

**Pasul 6**: Se determină matricele  $H_1, R_1$  și  $K_1$  utilizând ecuația (1.224) și apoi se partiționează  $H_1$  (ecuația (1.225)), rezultând  $H_{11}$  și  $H_{12}$ ; se calculează  $C_2$  cu ecuația (1.230).

**Pasul 7:** Se calculează matricele  $A_2, B_2, D_2$  cu ecuația (1.238) și se proiectează observerul de stare descris de ecuațiile (1.239). Matricea *L* se obține impunând valori proprii convenabile (în semiplanul stâng complex) pentru matricea  $(A_2 - LC_2)$ .

**Pasul 8:** Cu  $\hat{x}_2$  obținut la pasul 7, se calculează  $\hat{x}_1$  (ecuația (1.243)) și apoi se estimează vectorul intrărilor necunoscute  $\hat{d}(k)$  cu ecuația (1.242).

**Pasul 9:** Vectorul de stare  $\bar{x}(k)$  se estimează astfel:  $\hat{x}(k) = [\hat{x}_1(k) \ \hat{x}_2(k)]^T$ ; x(k) se obține ținând seama de prima ecuație (1.220) și de faptul că H – matrice ortogonală:

$$x(k) = H\hat{x}(k) = H\left[\hat{x}_{1}(k) \ \hat{x}_{2}(k)\right]^{T}.$$
(1.244)

## 1.6.2. PROIECTAREA OBSERVERELOR PENTRU SISTEMELE LINIARE CU INTRĂRI NECUNOSCUTE

#### 1.6.2.1. Proiectarea observerelor cu ordin întreg

Există numeroase metode pentru proiectarea observerelor și a observerelor cu ordin redus pentru sistemele liniare cu intrări necunoscute. Metodele pot fi împărțite în 3 categorii: metode geometrice, metode algebrice și cele care utilizează inversa generalizată [18]. Metodele geometrice au fost introduse de Bhattacharyya [12], iar cele algebrice au ca reprezentanți de frunte pe Kudva, Viswadam și Ramakrishna [141], Hautus [81], Hou & Muller [84], Darouach, Zasadzinski și S. J. Xu [49], Yang și Wild [239], O'Reilly [187] etc.

Se consideră sistemul invariant în timp

$$\dot{x} = Ax + Bu + Dd, y = Cx,$$
 (1.245)

unde  $x \in \mathcal{M}^{n \times 1}$  – vector de stare,  $u \in \mathcal{M}^{p \times 1}$  – vectorul intrărilor cunoscute,  $d \in \mathcal{M}^{s \times 1}$  – vectorul intrărilor necunoscute și  $y \in \mathcal{M}^{m \times 1}$  – vectorul ieșirilor. Matricele A, B, C, D au respectiv dimensiunile  $A \in \mathcal{M}^{n \times n}, B \in \mathcal{M}^{n \times p}, C \in \mathcal{M}^{m \times n}, D \in \mathcal{M}^{n \times s}$ .

Se presupune, fără micșorarea generalității, că  $m \ge s$ , rang(D) = s, rang(C) = m și perechea (C, A) – observabilă. Se construiește observerul descris de ecuațiile [18], [187]

$$\dot{z} = Nz + Ly + Gu, \, \hat{x} = z - Ey,$$
 (1.246)

în care  $z \in \mathcal{M}^{n \times 1}$  și  $\hat{x} \in \mathcal{M}^{n \times 1}$  – estimarea vectorului de stare x. Matricele N, L, G și E sunt matrice cunoscute și trebuie calculate astfel încât  $\hat{x} \to x$ . Se consideră eroarea de estimare  $e = \hat{x} - x$  și se calculează derivata acesteia; se obține

$$\dot{e} = \dot{x} - \dot{x} = Ne + (NP + LC - PA)x + (G - PB)u - PDd$$
, (1.247)

unde s-a făcut notația [18]

$$P = I_n + EC. \tag{1.248}$$

Dacă  $\hat{x} \rightarrow x \Rightarrow \dot{e} = Ne$ , deci, conform ecuației (1.247), rezultă

$$NP + LC - PA = 0, G - PB = 0, (I_n + EC)D = 0$$
(1.249)

și, în plus, matricea N trebuie să fie stabilă.

Din cea de-a treia ecuație (1.249) se determină matricea E astfel

$$(I_n + EC)D = 0 \Leftrightarrow D + ECD = 0 \Rightarrow E = -D(CD)^+,$$
 (1.250)

în care "+" este simbolul pseudo-inversei, adică

$$(CD)^{+} = [(CD)^{T} (CD)]^{-1} (CD)^{T}.$$
 (1.251)

Pentru a se putea calcula pseudo-inversa matricei (*CD*), aceasta trebuie să aibă rang de coloană maxim, adică rang(*CD*) = s; *CD*  $\in \mathcal{M}^{m \times s}$ .

După determinarea lui E (ecuația (1.250)) se calculează P cu ecuația (1.248) și

apoi, utilizând cea de-a doua ecuație (1.249), rezultă matricea G [18], [187]

$$G = PB = (I_n + EC)B = [I_n - D(CD)^+ C]B.$$
(1.252)

Determinarea matricelor N și L se face utilizând prima ecuație (1.249). Procedura este destul de dificilă întrucât ecuația

$$NP + LC - PA = 0$$
 (1.253)

este o ecuație matriceală cu 2 necunoscute.

În [18] se procedează după cum urmează: se alege N de forma

$$N = PA - KC, \qquad (1.254)$$

unde K se alege, la rândul ei, astfel încât matricea N să fie stabilă. Introducând N de forma (1.254) în ecuația (1.253) se obține [18], [187]

$$LC = PA - PAP + KCP \Leftrightarrow LC = (I_n + EC)A - (I_n + EC)A(I_n + EC) + KC(I_n + EC) \Leftrightarrow$$
  
$$\Leftrightarrow LC = -AEC - ECAEC + KC + KCEC \Leftrightarrow LC = -\underbrace{(I_n + EC)}_{P}AEC + K(I_m + CE)C \Leftrightarrow (1.255)$$
  
$$\Leftrightarrow LC = -PAEC + K(I_m + CE)C$$

sau

$$L = -PAE + K(I_m + CE).$$
(1.256)

Aşadar, dinamica observerului este

$$\dot{z} = (PA - KC)z + [K(I_m + CE) - PAE]y + PBu, \\ \dot{x} = z - Ey.$$
(1.257)

Rezolvarea ecuației (1.253) și, implicit, determinarea matricelor N și L, se poate face și prin partiționarea matricelor N, P, L, C și A (algoritmul O'Reilly îmbunătățit)

$$N = \begin{bmatrix} N_1 & N_2 \\ N_3 & N_4 \end{bmatrix}, P = \begin{bmatrix} P_1 & P_2 \\ P_3 & P_4 \end{bmatrix}, L = \begin{bmatrix} L_1 \\ L_2 \end{bmatrix}, C = \begin{bmatrix} C_1 & C_2 \end{bmatrix}, A = \begin{bmatrix} A_1 & A_2 \\ A_3 & A_4 \end{bmatrix}, \quad (1.258)$$

în care

$$\begin{split} N &\in \mathcal{M}^{n \times n}, N_{1} \in \mathcal{M}^{(n-m) \times (n-m)}, N_{2} \in \mathcal{M}^{(n-m) \times m}, N_{3} \in \mathcal{M}^{m \times (n-m)}, N_{4} \in \mathcal{M}^{m \times m}, \\ P &\in \mathcal{M}^{n \times n}, P_{1} \in \mathcal{M}^{(n-m) \times (n-m)}, P_{2} \in \mathcal{M}^{(n-m) \times m}, P_{3} \in \mathcal{M}^{m \times (n-m)}, P_{4} \in \mathcal{M}^{m \times m}, \\ L &\in \mathcal{M}^{n \times m}, L_{1} \in \mathcal{M}^{(n-m) \times m}, L_{2} \in \mathcal{M}^{m \times m}, \\ C &\in \mathcal{M}^{m \times n}, C_{1} \in \mathcal{M}^{m \times (n-m)}, C_{2} \in \mathcal{M}^{m \times m}, \\ A &\in \mathcal{M}^{n \times n}, A_{1} \in \mathcal{M}^{(n-m) \times (n-m)}, A_{2} \in \mathcal{M}^{(n-m) \times m}, A_{3} \in \mathcal{M}^{m \times (n-m)}, A_{4} \in \mathcal{M}^{m \times m}. \end{split}$$
(1.259)

Ecuația (1.253) este echivalentă cu sistemul de ecuații matriceale

$$\begin{cases} N_1 P_1 + N_2 P_3 + L_1 C_1 - P_1 A_1 - P_2 A_3 = 0_{(n-m)\times(n-m)}, \\ N_1 P_2 + N_2 P_4 + L_1 C_2 - P_1 A_2 - P_2 A_4 = 0_{(n-m)\times m}, \\ N_3 P_1 + N_4 P_3 + L_2 C_1 - P_3 A_1 - P_4 A_3 = 0_{m\times(n-m)}, \\ N_3 P_2 + N_4 P_4 + L_2 C_2 - P_3 A_2 - P_4 A_4 = 0_{m\times m}. \end{cases}$$
(1.260)

Sistemul anterior are 6 necunoscute  $(N_i, i = \overline{1, 4} \text{ şi } L_j, j = \overline{1, 2})$  şi doar 4 ecuații. Pentru a putea fi rezolvat considerăm  $N_1 \in \mathcal{M}^{(n-m)\times m}$  şi  $N_3 \in \mathcal{M}^{m\times(n-m)}$  două matrice alese aleator. Din cele 4 submatrice  $N_i, i = \overline{1, 4}$ , oricare două pot fi considerate cunoscute (alese aleator) urmând ca celelalte două, împreună cu  $L_1$  şi  $L_2$ , să fie necunoscutele sistemului (1.260). Făcând notațiile

$$\widetilde{A}_{1} = P_{1}A_{1} + P_{2}A_{3} - N_{1}P_{1}, \widetilde{A}_{2} = P_{1}A_{2} + P_{2}A_{4} - N_{1}P_{2}, 
\widetilde{A}_{3} = P_{3}A_{1} + P_{4}A_{3} - N_{3}P_{1}, \widetilde{A}_{4} = P_{3}A_{2} + P_{4}A_{4} - N_{3}P_{2},$$
(1.261)

sistemul de ecuații matriceale (1.260) se transformă în două sisteme de ecuații, fiecare cu câte 2 necunoscute

$$\begin{cases} N_2 P_3 + L_1 C_1 = \widetilde{A}_1, \\ N_2 P_4 + L_1 C_2 = \widetilde{A}_2, \end{cases}$$
(1.262)

$$\begin{cases} N_4 P_3 + L_2 C_1 = \widetilde{A}_3, \\ N_4 P_4 + L_2 C_2 = \widetilde{A}_4. \end{cases}$$
(1.263)

Pentru rezolvarea primului sistem, se scoate  $N_2$  din a doua ecuație (1.262)

$$N_2 = \left(\tilde{A}_2 - L_1 C_2\right) P_4^+ \tag{1.264}$$

și se înlocuiește în prima ecuație (1.262). Se obțin

$$L_{1} = \left(\tilde{A}_{1} - \tilde{A}_{2}P_{4}^{+}P_{3}\right)\left(C_{1} - C_{2}P_{4}^{+}P_{3}\right)^{+}$$
(1.265)

şi

$$N_2 = \left(\tilde{A}_2 - L_1 C_2\right) P_4^+ \tag{1.266}$$

echivalentă cu

$$N_{2} = \left[\widetilde{A}_{2} - \left(\widetilde{A}_{1} - \widetilde{A}_{2}P_{4}^{+}P_{3}\right)\left(C_{1} - C_{2}P_{4}^{+}P_{3}\right)^{+}C_{2}\right]P_{4}^{+}.$$
 (1.267)

Se rezolvă similar și sistemul (1.263) și se determină necunoscutele  $L_2$  și  $N_4$ 

$$L_{2} = \left(\widetilde{A}_{3} - \widetilde{A}_{4}P_{4}^{+}P_{3}\right)\left(C_{1} - C_{2}P_{4}^{+}P_{3}\right)^{+}, \qquad (1.268)$$

$$N_4 = \left[\widetilde{A}_4 - \left(\widetilde{A}_3 - \widetilde{A}_4 P_4^+ P_3\right) \left(C_1 - C_2 P_4^+ P_3\right)^+ C_2\right] P_4^+ .$$
(1.269)

După determinarea matricelor  $N_2$  și  $N_4$  ( $N_1$  și  $N_3$  au fost alese aleator), se construiește matricea N – ecuația (1.258). Aceasta trebuie să fie stabilă. În cazul în care N nu este stabilă, se aleg alte 2 matrice  $N_1$ ,  $N_3$  și se rezolvă din nou sistemul de ecuații (1.260).

Metoda de proiectare a observerului din [18], [187] prezintă unele dezavantaje față de metoda inovativă găsită de autor. În [18], [187], matricea K și, implicit, N – ecuația (1.254), se determină impunând valori proprii dorite pentru matricea PA - KC. Acest lucru nu se poate face tot timpul și pot exista cazuri când este greu sau chiar imposibil de determinat matricea K. Acest neajuns este complet eliminat în cadrul algoritmului propus de autor (algoritmul O'Reilly îmbunătățit). Un alt dezavantaj al algoritmului din [18], [187] este acela că observerul (1.257) există dacă și numai dacă sunt îndeplinite simultan condițiile:

1) 
$$\operatorname{rang}(CD) = \operatorname{rang}(D) = s$$
;  
2)  $\operatorname{rang}\begin{bmatrix} \mathbf{s}P - PA \\ C \end{bmatrix} = n, (\forall) \mathbf{s} \in C, \operatorname{Re}\{\mathbf{s}\} \ge 0.$ 

Dacă este îndeplinită condiția 1) și, în plus, rang(P) = n - s, următoarele 3 condiții sunt echivalente [18], [187]

1) perechea (PA, C) este observabilă sau cel puțin detectabilă;

2) rang 
$$\begin{bmatrix} \mathbf{s}P - PA \\ C \end{bmatrix} = n, (\forall) \mathbf{s} \in C, \operatorname{Re}\{\mathbf{s}\} \ge 0;$$
  
3) rang  $\begin{bmatrix} \mathbf{s}I_n - A & D \\ C & 0 \end{bmatrix} = n + s, (\forall) \mathbf{s} \in C, \operatorname{Re}\{\mathbf{s}\} \ge 0$ 

Algoritmul O'Reilly îmbunătățit are avantajul unui număr mai mic de constrângeri. Cu alte cuvinte, condițiile necesare sunt:

$$m \ge s$$
, rang $(D) = rang(CD) = s$ , rang $(C) = m$ ,  $(C, A)$  – pereche observabila (1.270)

#### Algoritmul O'Reilly îmbunătățit

**Pasul 1**: Se verifică dacă sunt îndeplinite simultan condițiile (1.270).

**Pasul 2**: Se calculează matricea E cu ecuația (1.250) și apoi matricea P – ecuația (1.248).

**Pasul 3**: Se calculează matricea G utilizând ecuația (1.252).

**Pasul 4**: Se partiționează matricele *N*, *P*, *L*, *C*, *A* conform ecuațiilor (1.258) și (1.259).

**Pasul 5**: Se aleg aleatoriu matricele  $N_1$ ,  $N_3$  și apoi, utilizând ecuația (1.261), se calculează  $\tilde{A}_1, \tilde{A}_2, \tilde{A}_3, \tilde{A}_4$ .

**Pasul 6**: Se rezolvă sistemele de ecuații (1.262) și (1.263) și se obțin matricele  $L_1, L_2, N_2, N_4$  – ecuațiile (1.265), (1.268), (1.267) și (1.269).

**Pasul 7**: Se construiesc matricele N și L – ecuația (1.258) și se verifică dacă N – matrice stabilă. În cazul în care matricea N nu are valorile proprii în semiplanul stâng complex, se reiau pașii 5, 6 și 7 cu alte matrice alese aleator  $N_1$  și  $N_3$  până când se obține o matrice N stabilă.

**Pasul 8**: Se proiectează observerul descris de ecuațiile (1.246).

În cele ce urmează, se validează algoritmul de mai sus pentru două cazuri concrete ale mișcărilor longitudinală, respectiv laterală ale aeronavelor.

Se consideră mișcarea longitudinală a unei aeronave descrisă de ecuațiile de stare (1.47). Parcurgând pas cu pas algoritmul O'Reilly îmbunătățit se obțin matricele



Fig. 1.22. Modelul Matlab/Simulink al observerului O'Reilly îmbunătățit



Fig. 1.23. Erorile de estimare a stării estimatorului O'Reilly îmbunătățit (K = 0)



Fig. 1.24. Variabilele de stare  $x_i(t)$  și  $\hat{x}_i(t)$  - mișcarea longitudinală (K  $\neq 0$ )

Programul Matlab din anexa A1.5 reprezintă implementarea software a procedurii de construcție a estimatorului de stare O'Reilly îmbunătățit. Modelul Matlab/Simulink din fig. 1.22 este utilizat în cadrul programului din anexă pentru obținerea caracteristicilor de timp din fig. 1.23 (erorile de estimare a variabilelor de stare cu estimatorul de stare O'Reilly îmbunătățit pentru u = 0) și caracteristicile de timp din fig. 1.24 pentru legea de comandă  $u = -K\hat{x}$  (K calculată cu algoritmul ALGLX [157]); aceste caracteristici exprimă variabilele de stare  $x_i(t)$  – cu linie continuă și  $\hat{x}_i(t)$  – cu linie întreruptă.



Fig. 1.25. Erorile de estimare a stării estimatorului O'Reilly îmbunătățit (K=0)



Fig. 1.26. Variabilele de stare  $x_i(t)$  și  $\hat{x}_i(t)$  - mișcarea laterală (K  $\neq 0$ )

Se implementează software observerul O'Reilly îmbunătățit și pentru cazul mișcării laterale (1.49). Erorile de estimare a variabilelor de stare sunt prezentate în fig. 1.25 (pentru K=0), iar variabilele de stare  $x_i(t)$  și  $\hat{x}_i(t)$  pentru K calculat cu algoritmul ALGLX [157] sunt prezentate în fig. 1.26. Programul Matlab utilizat este similar celui din anexa A1.5, iar modelul Matlab/Simulink este identic cu cel din fig. 1.22.

În acest caz, în urma simulării, se obțin matricele

$$E = \begin{bmatrix} 1 & 0 \\ 0 & -1 \\ -583.29 & -8.64 \\ 0 & 0 \end{bmatrix}; P = \begin{bmatrix} 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ -583.29 & -8.64 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}; G = 10^{-13} \cdot \begin{bmatrix} 0.0004 & 0 \\ -0.002 & 0 \\ 0.217 & 0.011 \\ 0 & 0 \end{bmatrix}$$
$$L = 10^4 \cdot \begin{bmatrix} 0 & 0 \\ 0 & 0 \\ -2.73 & 0.017 \\ 0.058 & 0.0009 \end{bmatrix}; N = \begin{bmatrix} -6.436 & -10.09 & 0 & 0 \\ 3.803 & -0.195 & 0 & 0 \\ -0.48 & -3.178 & -46.97 & -25.75 \\ 0.000 & 10.95 & 1 & 0 \end{bmatrix}.$$

# 1.6.2.2. Proiectarea observerelor cu ordin redus fără reconstrucția intrărilor necunoscute

În cadrul acestei metode vectorul de stare este împărțit în două părți: prima parte include stările măsurabile (p), iar cea de-a doua include stările nemăsurate (n - p). Deoarece *C* are rang de linie maxim, o transformare de coordonate poate fi găsită astfel încât *C* să aibă forma  $C = [I_p \ 0] [18]; I_p$  este matricea unitate de ordinul *p*. Sistemul de ecuații (1.1), în noile coordonate, se scrie [18]

$$\begin{bmatrix} \dot{y}(t) \\ \dot{w}(t) \end{bmatrix} = \begin{bmatrix} A_{11} & A_{12} \\ A_{21} & A_{22} \end{bmatrix} \begin{bmatrix} y(t) \\ w(t) \end{bmatrix} + \begin{bmatrix} B_1 \\ B_2 \end{bmatrix} u(t) + \begin{bmatrix} D_1 \\ D_2 \end{bmatrix} d(t), \qquad (1.271)$$

în care  $w \in \mathcal{M}^{(n-p)\times 1}$  este vectorul părții nemăsurabile. Cum perechea (C, A) este observabilă, rezultă că perechea  $(A_{12}, A_{22})$  este și ea observabilă și un observer de ordinul (n-p) se construiește. Acesta este descris de ecuația [71]

$$\dot{z}(t) = Fz(t) + Gy(t) + Hu(t) + Jd(t), \qquad (1.272)$$

în care

$$F = A_{22} - LA_{12}, G = FL + A_{21} - LA_{11}, H = B_2 - LB_1, J = D_2 - LD_1. \quad (1.273)$$

În cazul standard în care d(t) este disponibil pentru măsurători, matricea  $L \in \mathcal{M}^{(n-p)\times p}$  se alege astfel încât F să aibă valorile proprii dorite în semiplanul stâng complex. După rezolvarea ecuației matriceale (1.272), estimarea vectorului w(t), adică  $\hat{w}(t)$ , se face astfel [18]

$$\hat{w}(t) = z(t) + Ly(t).$$
 (1.274)

În acest caz, d(t) nu este disponibil măsurătorilor; observerul poate fi implementat dacă și numai dacă există o matrice *L* care să îndeplinească simultan condițiile

$$J = D_2 - LD_1 = 0, F = A_{22} - LA_{11}$$
 este matrice stabila. (1.275)

Calculul matricei L este posibilă dacă rang(CD) = rang(D) = m;  $p \ge m$ . În acest caz [18],

$$L = D_2 D_1^+ + \overline{K} (I_p - D_1 D_1^+), \qquad (1.276)$$

unde  $\overline{K}$  este matrice aleasă aleator de ordinul  $(n - p) \times p$  și  $D_1$  – matrice cu rang de coloană maxim. Deoarece  $\overline{K}$  – matrice aleasă aleatoriu, nu este posibilă, în general, fixarea (alegerea) valorilor proprii pentru matricea F și, de aceea, se face o modificare

a matricei prin intermediul unei matrice ortogonale  $S \in \mathcal{M}^{n \times n}$  astfel încât [70]

$$SD_{1} = \begin{bmatrix} \overline{D}_{1} \\ 0 \end{bmatrix} SA_{12} = \begin{bmatrix} \overline{A}_{12}^{1} \\ \overline{A}_{22}^{2} \end{bmatrix} KS^{T} = \begin{bmatrix} \overline{K}_{1} & \overline{K}_{2} \end{bmatrix}, \qquad (1.277)$$

unde  $D_1 \in \mathcal{M}^{m \times n}$  – matrice nesingulară,  $\overline{A}_{12}^1$  are *m* linii,  $\overline{K}_1$  are *m* coloane. Conform [84], matricea *F* se obține astfel

$$F = F_1 - \overline{K}_2 \overline{A}_{12}^2 , \qquad (1.278)$$

cu

$$F_1 = A_{22} - D_2 \left(\overline{D}_1\right)^{-1} \overline{A}_{12}^1; \qquad (1.279)$$

 $\overline{K}_2$  – matrice aleasă arbitrar.

## 1.6.2.3. Proiectarea observerelor cu ordin redus cu reconstrucția intrărilor necunoscute

Și în acest caz, vectorul de stare se împarte în două părți [19]: o parte asociată intrărilor necunoscute și o altă parte ce depinde de intrările cunoscute ale sistemului în cauză. Sistemul (1.1) este echivalent cu [18]

$$\begin{cases} \dot{\overline{x}} = \overline{A}\overline{x} + \overline{B}u + \overline{D}d ,\\ y = \overline{C}\overline{x} , \end{cases}$$
(1.280)

unde  $T = [N \ D]$  – matrice nesingulară cu  $N \in \mathcal{M}^{n \times (n-m)}$ ,

$$x = T\overline{x} = T\left[\overline{x}_1^T \ \overline{x}_2^T\right]^T, \qquad (1.281)$$

 $\overline{x}_1 \in \mathcal{M}^{(n-m) \times 1}, \overline{x}_2 \in \mathcal{M}^{m \times 1}$  și

$$\overline{A} = T^{-1}AT = \begin{bmatrix} \overline{A}_{11} & \overline{A}_{12} \\ \overline{A}_{21} & \overline{A}_{22} \end{bmatrix}, \overline{B} = T^{-1}B = \begin{bmatrix} \overline{B}_1 \\ \overline{B}_2 \end{bmatrix},$$

$$\overline{D} = T^{-1}D = \begin{bmatrix} 0 \\ I_m \end{bmatrix}, \overline{C} = CT = \begin{bmatrix} CN & CD \end{bmatrix} = \begin{bmatrix} \overline{C}_1 & \overline{C}_2 \end{bmatrix}.$$
(1.282)

Sistemul de ecuații (1.280) este echivalent cu

$$\begin{cases} \dot{\bar{x}}_{1} = \overline{A}_{11}\overline{x}_{1} + \overline{A}_{12}\overline{x}_{2} + \overline{B}_{1}u, \\ \dot{\bar{x}}_{2} = \overline{A}_{21}\overline{x}_{1} + \overline{A}_{22}\overline{x}_{2} + \overline{B}_{2}u + I_{m}d, \\ y = \overline{C}_{1}\overline{x}_{1} + \overline{C}_{2}\overline{x}_{2}. \end{cases}$$
(1.283)

 $\bar{x}_2$  depinde de intrarea necunoscută d(t), în timp ce  $\bar{x}_1$  nu depinde de aceasta; este, deci, mai convenabil să estimăm  $\bar{x}_1$  în loc să estimăm  $\bar{x}_2$ ; sistemul de ecuații devine

$$\begin{cases} \dot{\overline{x}}_1 = \overline{A}_{11}\overline{x}_1 + \overline{A}_{12}\overline{x}_2 + \overline{B}_1 u, \\ y = \overline{C}_1\overline{x}_1 + \overline{C}_2\overline{x}_2. \end{cases}$$
(1.284)

În continuare, se presupune că există o matrice nesingulară

$$U = [CD \ Q]; \tag{1.285}$$

 $Q \in \mathcal{M}^{p \times (p-m)}$ .  $U^{-1}$  se partiționează după cum urmează [18]:

$$U^{-1} = \begin{bmatrix} U_1^T & U_2^T \end{bmatrix}^T,$$
(1.286)

cu  $U_1 \in \mathcal{M}^{m \times p}, U_2 \in \mathcal{M}^{(p-m) \times p}. U$  și  $U^{-1}$  trebuie să îndeplinească condiția

$$U^{-1}U = \begin{bmatrix} U_1 \\ U_2 \end{bmatrix} \begin{bmatrix} CD & Q \end{bmatrix} = \begin{bmatrix} U_1CD & U_1Q \\ U_2CD & U_2Q \end{bmatrix} = \begin{bmatrix} I_m & 0 \\ 0 & I_{p-m} \end{bmatrix}.$$
 (1.287)

Înmulțind la stânga cu  $U^{-1}$ , membru cu membru, a doua ecuație (1.284) se obține

$$\begin{cases} U_1 y = U_1 \overline{C}_1 \overline{x}_1 + U_1 \overline{C}_2 \overline{x}_2 , \\ U_2 y = U_2 \overline{C}_1 \overline{x}_1 + U_2 \overline{C}_2 \overline{x}_2 , \end{cases}$$
(1.288)

sau, ținând cont de (1.287), adică

$$\begin{cases} U_1 \overline{C}_2 = U_1 CD = I_m, \\ U_2 \overline{C}_2 = U_2 CD = 0, \end{cases}$$
(1.289)

rezultă [18]

$$U_1 y = U_1 C N \overline{x}_1 + \overline{x}_2, U_2 y = U_2 C N \overline{x}_1.$$
(1.290)

Din prima ecuație (1.290) rezultă

$$\bar{x}_2 = U_1 y - U_1 C N \bar{x}_1 . \tag{1.291}$$

Aşadar, determinarea lui  $\bar{x}_2$  se face după ce se determină  $\bar{x}_1$ . Înlocuind  $\bar{x}_2$  cu foma (1.291) în sistemul de ecuații (1.284), rezultă [18]

$$\begin{cases} \dot{\overline{x}}_1 = \overline{A}_{11}\overline{x}_1 + \overline{A}_{12}(U_1y - U_1CN\overline{x}_1) + \overline{B}_1u, \\ y = \overline{C}_1\overline{x}_1 + \overline{C}_2(U_1y - U_1CN\overline{x}_1) \end{cases}$$
(1.292)

sau

$$\begin{cases} \dot{\overline{x}}_1 = (\overline{A}_{11} - \overline{A}_{12}U_1CN)\overline{x}_1 + \overline{B}_1u + \overline{A}_{12}U_1y, \\ y = \overline{C}_1\overline{x}_1 + \overline{C}_2U_1y - \overline{C}_2U_1CN\overline{x}_1, \end{cases}$$
(1.293)

echivalentă cu

$$\begin{cases} \dot{\overline{x}}_1 = \widetilde{A}_1 \overline{\overline{x}}_1 + \overline{B}_1 u + E_1 y, \\ \overline{y} = \widetilde{C}_1 \overline{\overline{x}}_1, \end{cases}$$
(1.294)

unde

$$\widetilde{A}_1 = \overline{A}_{11} - \overline{A}_{12}U_1CN, E_1 = \overline{A}_{12}U_1, \widetilde{C}_1 = U_2CN, \overline{y} = U_2y.$$
(1.295)

În obținerea celei de-a doua ecuații (1.294) s-a folosit a doua ecuație (1.293), înmulțită la stânga cu $U_2$ , precum și ecuațiile (1.289). Astfel,

$$U_2 y = U_2 \overline{C_1} \overline{x_1} + \underbrace{U_2 \overline{C_2}}_{=0} U_1 y - U_2 \overline{C_2} U_1 C N \overline{x_1} \Leftrightarrow U_2 y = \underbrace{U_2 \overline{C_1}}_{U_2 C N} \overline{x_1} \Leftrightarrow \overline{y} = \widetilde{C_1} \overline{x_1}.$$
(1.296)

Sistemul pentru care se dorește construcția unui observer de stare cu ordin redus este sistemul (1.294). Construcția observerului este posibilă dacă perechea  $(\tilde{A}_1, \tilde{C}_1)$  este observabilă [18]. Din a doua ecuație (1.294) rezultă  $y = CN\bar{x}_1$ , care, înlocuită în prima ecuație (1.294), conduce la ecuația observerului cu ordin redus

$$\dot{\overline{x}}_1 = \left(\widetilde{A}_1 - L\widetilde{C}_1\right) \dot{\overline{x}}_1 + \overline{B}_1 u + \widetilde{L}y, \qquad (1.297)$$

în care

$$\widetilde{L} = LU_2 + E_1;$$
 (1.298)

matricea L se calculează impunând valori proprii dorite pentru matricea  $(\widetilde{A}_1 - L\widetilde{C}_1)$ .

Ecuația matriceală diferențială (1.297) are ca soluție vectorul  $\hat{x}_1$  și apoi, cu ecuația (1.291), se calculează

$$\hat{\bar{x}}_2 = U_1 y - U_1 C N \hat{\bar{x}}_1 .$$
(1.299)

Vectorul de stare estimat  $\hat{x}$  se află prin concatenarea vectorilor  $\hat{x}_1$  și  $\hat{x}_2$ , iar vectorul de stare  $\hat{x}$  se determină astfel [18]:

$$\hat{x} = T\hat{x} = T\left[\hat{x}_1^T \ \hat{x}_2^T\right]^T;$$
 (1.300)

vectorul aproximat al intrărilor necunoscute (d(t)) se determină din ecuația (1.283)

$$\hat{d} = \dot{\bar{x}}_2 - \bar{A}_{21}\hat{\bar{x}}_1 - \bar{A}_{22}\hat{\bar{x}}_2 - \bar{B}_2 u \,. \tag{1.301}$$

În ecuația (1.301)  $\hat{x}_2$  se înlocuiește cu forma din ecuația (1.299), iar  $\dot{\hat{x}}_2$  se înlocuiește cu

$$\dot{\overline{x}}_2 = U_1 \dot{y} - U_1 C N \dot{\overline{x}}_1 = U_1 \dot{y} - U_1 C N \Big[ \Big( \widetilde{A}_1 - L \widetilde{C}_1 \Big) \dot{\overline{x}}_1 + \overline{B}_1 u + \widetilde{L} y \Big].$$
(1.302)

După efectuarea tuturor calculelor se obține [18]

$$\hat{d} = U_1 \dot{y} + G_1 \hat{x}_1 + G_2 y + G_3 u, \qquad (1.303)$$

unde

$$G_{1} = U_{1}CNLU_{2}CN + U_{1}CN\overline{A}_{12}U_{1}CN - U_{1}CN\overline{A}_{11} - \overline{A}_{21} + \overline{A}_{22}U_{1}CN ,$$
  

$$G_{2} = -U_{1}CNLU_{2} - U_{1}CN\overline{A}_{12}U_{1} - \overline{A}_{22}U_{1} , G_{3} = -U_{1}CN\overline{B}_{1} - \overline{B}_{2} .$$
(1.304)

Observerul cu ordin redus se poate construi dacă sunt îndeplinite simultan condițiile

$$\operatorname{rang}(CD) = \operatorname{rang}(D); \operatorname{rang}\begin{bmatrix}\mathbf{s}I_n - \overline{A}_{11} & -\overline{A}_{12}\\CN & CD\end{bmatrix} = n, (\forall)\mathbf{s} \in C, \operatorname{Re}\{\mathbf{s}\} \ge 0. \quad (1.305)$$

A doua condiție (1.305) este echivalentă cu observabilitatea perechii  $(\widetilde{A}_1, \widetilde{C}_1)$  [84].

#### **Algoritmul Boubaker**

**Pasul 1**: Se alege o matrice  $N \in \mathcal{M}^{n \times (n-m)}$  astfel încât matricea T = [N D] să fie inversabilă. Se verifică condiția necesară rang $(CD) = \operatorname{rang}(D)$ .

**Pasul 2**: Se calculează matricele  $\overline{A}, \overline{B}, \overline{C}, \overline{D}$  cu ecuația (1.282) și apoi se partiționează aceste matrice; rezultă  $\overline{A}_{11}, \overline{A}_{12}, \overline{A}_{21}, \overline{A}_{22}, \overline{B}_1, \overline{B}_2, \overline{C}_1, \overline{C}_2$ .

**Pasul 3**: Se alege arbitrar o matrice  $Q \in \mathcal{M}^{p \times (p-m)}$  și se formează matricea  $U = [CD \ Q]$ care trebuie să fie inversabilă, cu inversa  $U^{-1} = \begin{bmatrix} U_1^T & U_2^T \end{bmatrix}^T$  ce îndeplinește condiția (1.287); rezultă matricele  $U_1$  și  $U_2$ .

**Pasul 4**: Se calculează  $\widetilde{A}_1, E_1, \widetilde{C}_1$  cu ecuația (1.295).

**Pasul 5**: Se verifică dacă perechea  $(\widetilde{A}_1, \widetilde{C}_1)$  este observabilă. În caz contrar observerul de stare cu ordin redus nu se poate construi.

**Pasul 6**: În cazul în care  $(\widetilde{A}_1, \widetilde{C}_1)$  este observabilă, se construiește observerul de stare cu ordin redus (1.297), în care *L* se calculează impunând valori proprii în semiplanul stâng complex pentru matricea  $\widetilde{A}_1 - L\widetilde{C}_1$ , iar  $\widetilde{L}$  se calculează cu ecuația (1.298).

**Pasul 7**: Se determină  $\hat{\bar{x}}_1$  și apoi  $\hat{\bar{x}}_2$  cu ecuația (1.299). Estimarea vectorului intrărilor necunoscute  $(\hat{d})$  se face cu ecuația (1.303); u și y se cunosc. Matricele  $G_1, G_2$  și  $G_3$  din ecuația (1.303) au fost calculate, în prealabil, cu ajutorul relațiilor (1.304).

**Pasul 8**: Vectorul de stare estimat  $\hat{x}$  se determină cu (1.300) în funcție de  $\hat{x}_1$  și  $\hat{x}_2$ .

Un alt observer pentru estimarea stării și, în același timp, a intrărilor necunoscute (algoritm conceput de autorul lucrării) este prezentat în continuare. Proiectarea observerului presupune combinarea algoritmului Boubaker [18] și a algoritmului Hou & Muller [84]. Și de această dată, vectorul de stare se împarte în două [19]: o parte asociată intrărilor necunoscute și o alta ce depinde de intrările necunoscute.

Se consideră mișcarea aeronavei descrisă de ecuațiile de stare-ieșire (1.245) în

care  $x \in \mathcal{M}^{n \times 1}, u \in \mathcal{M}^{p \times 1}, d \in \mathcal{M}^{s \times 1}, y \in \mathcal{M}^{m \times 1}; A \in \mathcal{M}^{n \times n}, B \in \mathcal{M}^{n \times p}, C \in \mathcal{M}^{m \times n}, D \in \mathcal{M}^{n \times s}$ . Se alege o matrice  $N \in \mathcal{M}^{n \times (n-s)}$ , astfel încât matricea  $T = [N \ D]$  să fie nesingulară. Se face schimbarea de coordonate (1.281) cu  $\overline{x}_1 \in \mathcal{M}^{m \times 1}, \overline{x}_2 \in \mathcal{M}^{(n-m) \times 1}$ . Sistemul ecuațiilor de stare devine de forma (1.280), în care [18]

$$\overline{A} = T^{-1}AT = \begin{bmatrix} \overline{A}_{11} & \overline{A}_{12} \\ \overline{A}_{21} & \overline{A}_{22} \end{bmatrix}, \overline{B} = T^{-1}B = \begin{bmatrix} \overline{B}_1 \\ \overline{B}_2 \end{bmatrix}, \overline{D} = T^{-1}D = \begin{bmatrix} 0 \\ I_s \end{bmatrix}, \overline{C} = CT = \begin{bmatrix} \overline{C}_1 & \overline{C}_2 \end{bmatrix}; (1.306)$$

 $\overline{A}_{11} \in \mathcal{M}^{m \times m}, \overline{A}_{12} \in \mathcal{M}^{m \times (n-m)}, \overline{A}_{21} \in \mathcal{M}^{(n-m) \times m}, \overline{A}_{22} \in \mathcal{M}^{(n-m) \times (n-m)}, \overline{B}_{1} \in \mathcal{M}^{m \times p}, \overline{B}_{2} \in \mathcal{M}^{(n-m) \times p}, \overline{C}_{1} \in \mathcal{M}^{m \times m}, \overline{C}_{2} \in \mathcal{M}^{m \times (n-m)}.$  Aşadar, dinamica sistemului devine

$$\begin{cases} \dot{\bar{x}}_{1} = \bar{A}_{11}\bar{x}_{1} + \bar{A}_{12}\bar{x}_{2} + \bar{B}_{1}u, \\ \dot{\bar{x}}_{2} = \bar{A}_{21}\bar{x}_{1} + \bar{A}_{22}\bar{x}_{2} + \bar{B}_{2}u + I_{m}d, \\ y = \bar{C}_{1}\bar{x}_{1} + \bar{C}_{2}\bar{x}_{2}. \end{cases}$$
(1.307)

Algoritmul funcționează în continuare dacă matricea  $\overline{C}_2$  are rang de coloană maxim. În acest caz, această matrice se scrie [84], [168]

$$\overline{C}_2 = H_2 \begin{bmatrix} R_2 \\ 0 \end{bmatrix} K_2^T, \qquad (1.308)$$

unde  $H_2 \in \mathcal{M}^{m \times n}, R_2 \in \mathcal{M}^{(n-m) \times (n-m)}, K_2 \in \mathcal{M}^{(n-m) \times (n-m)}$ ; întrucât matricea nulă din ecuația (1.308) este  $0_{m \times (n-m)}$ , rezultă o condiție necesară pentru construirea observerului

$$n-m>0 \Leftrightarrow n>m. \tag{1.309}$$

În ecuația (1.308), matricea  $H_2$  este matrice ortogonală  $(H_2 H_2^T = I_m)$ , iar matricea  $R_2$  trebuie să fie nesingulară.

În continuare, se partiționează matricea  $H_2$  astfel [84], [168]:

$$H_2 = [H_{21} \ H_{22}]; \tag{1.310}$$

 $H_{21} \in \mathcal{M}^{m \times (n-m)}, H_{22} \in \mathcal{M}^{m \times m}$ . Dacă se face notația [84]
$$\overline{y} = H_2^T y = \begin{bmatrix} H_{21}^T \\ H_{22}^T \end{bmatrix} y = \begin{bmatrix} \overline{y}_1 \\ \overline{y}_2 \end{bmatrix},$$
(1.311)

a treia ecuație (1.307) devine

$$y = \overline{C}_1 \overline{x}_1 + H_2 \begin{bmatrix} R_2 \\ 0 \end{bmatrix} K_2^T \overline{x}_2 .$$
 (1.312)

Se înmulțește această ultimă ecuație la stânga cu $H_2^{\scriptscriptstyle T}\,$ și rezultă

$$H_{2}^{T}y = H_{2}^{T}\overline{C}_{1}\overline{x}_{1} + \underbrace{H_{2}^{T}H_{2}}_{I_{m}} \begin{bmatrix} R_{2} \\ 0 \end{bmatrix} K_{2}^{T}\overline{x}_{2} \Leftrightarrow \begin{bmatrix} H_{21}^{T} \\ H_{22}^{T} \end{bmatrix} y = \begin{bmatrix} H_{21}^{T} \\ H_{22}^{T} \end{bmatrix} \overline{C}_{1}\overline{x}_{1} + \begin{bmatrix} R_{2} \\ 0 \end{bmatrix} K_{2}^{T}\overline{x}_{2} \qquad (1.313)$$

echivalentă cu

$$\begin{cases} \overline{y}_1 = H_{21}^T \overline{C}_1 \overline{x}_1 + R_2 K_2^T \overline{x}_2, \\ \overline{y}_2 = C_1 \overline{x}_1, \end{cases}$$
(1.314)

unde

$$C_1 = H_{22}^T \overline{C}_1 \,. \tag{1.315}$$

Ținând cont de expresia

$$\overline{y}_1 = \begin{bmatrix} I_{n-m} & 0 \end{bmatrix} \begin{bmatrix} \overline{y}_1^T & \overline{y}_2^T \end{bmatrix}^T \Leftrightarrow \overline{y}_1 = G^T \overline{y}, \qquad (1.316)$$

din prima ecuație (1.314) se scrie [84]

$$\overline{x}_{2} = \left(R_{2}K_{2}^{T}\right)^{-1}\left[\overline{y}_{1} - H_{21}^{T}\overline{C}_{1}\overline{x}_{1}\right] = \left(R_{2}K_{2}^{T}\right)^{-1}\left[G^{T}\underbrace{H_{2}^{T}y}_{\overline{y}} - H_{21}^{T}\overline{C}_{1}\overline{x}_{1}\right]$$
(1.317)

echivalentă cu

$$\bar{x}_2 = K_2 R_2^{-1} G^T H_2^T \Big[ y - \bar{C}_1 \bar{x}_1 \Big];$$
(1.318)

în ecuația de mai sus s-a ținut cont de

$$\left(R_2 K_2^T\right)^{-1} = K_2 R_2^{-1}, \qquad (1.319)$$

întrucât  $K_2$  este matrice ortogonală, dar și de relația

$$G^{T}H_{2}^{T} = \begin{bmatrix} I_{n-m} & 0 \end{bmatrix} \begin{bmatrix} H_{21}^{T} \\ H_{22}^{T} \end{bmatrix} = H_{21}^{T}.$$
 (1.320)

În continuare, se introduce  $\bar{x}_2$  cu forma (1.318) în prima ecuație (1.307) și rezultă [84]

$$\dot{\overline{x}}_{1} = \left(\overline{A}_{11} - \overline{A}_{12}K_{2}R_{2}^{-1}G^{T}H_{2}^{T}\overline{C}_{1}\right)\overline{x}_{1} + \overline{B}_{1}u + \overline{A}_{12}K_{2}R_{2}^{-1}G^{T}H_{2}^{T}y$$
(1.321)

sau

$$\dot{\overline{x}}_1 = \widetilde{A}_1 \, \overline{x}_1 + \widetilde{B}_1 u + \widetilde{E}_1 y, \qquad (1.322)$$

în care

$$\widetilde{A}_1 = \overline{A}_{11} - \overline{A}_{12}K_2R_2^{-1}G^TH_2^T\overline{C}_1, \widetilde{B}_1 = \overline{B}_1, \widetilde{E}_1 = \overline{A}_{12}K_2R_2^{-1}G^TH_2^T.$$
(1.323)

Pentru estimarea vectorului  $\bar{x}_1$  se construiește un observer de tip Luenberger bazat pe ecuația (1.321). Acest observer poate fi construit dacă și numai dacă perechea  $(\tilde{A}_1, C_1)$  este observabilă [84], [168]; ecuația asociată observerului este

$$\dot{\widetilde{x}}_{1} = \left(\widetilde{A}_{1} - LC_{1}\right)\dot{\widetilde{x}}_{1} + \left(LH_{22}^{T} + \widetilde{E}_{1}\right)y + \widetilde{B}_{1}u.$$
(1.324)

În proiectarea observerului s-a avut în vedere faptul că  $LC_1\bar{x}_1 = L\bar{y}_2 = LH_{22}^T y$ ; matricea L se alege astfel încât matricea  $\tilde{A}_1 - LC_1$  să fie stabilă. Din ecuația (1.324) se determină  $\hat{x}_1$  și apoi, cu ecuația (1.318), rezultă

$$\hat{\bar{x}}_2 = K_2 R_2^{-1} G^T H_2^T \left( y - \overline{C}_1 \hat{\bar{x}}_1 \right);$$
(1.325)

vectorul intrărilor necunoscute d se obține din ecuația (1.307) astfel:

$$\hat{d} = \dot{\bar{x}}_2 - \bar{A}_{21}\dot{\bar{x}}_1 - \bar{A}_{22}\dot{\bar{x}}_2 - \bar{B}_2 u, \qquad (1.326)$$

în care  $\dot{\bar{x}}_2$  are forma

$$\dot{\hat{x}}_{2} = K_{2}R_{2}^{-1}G^{T}H_{2}^{T}\left(\dot{y} - \overline{C_{1}}\dot{\hat{x}_{1}}\right)^{(1.324)} = K_{2}R_{2}^{-1}G^{T}H_{2}^{T}\dot{y} - K_{2}R_{2}^{-1}G^{T}H_{2}^{T}\left[\overline{C_{1}}\left(\widetilde{A_{1}} - LC_{1}\right)\dot{\hat{x}_{1}} + \overline{C_{1}}\left(LH_{22}^{T} + \widetilde{E_{1}}\right)y + \overline{C_{1}}\widetilde{B_{1}}u\right].$$

$$(1.327)$$

Din ecuațiile (1.326) și (1.327) rezultă una dintre formele

$$\hat{d} = K_2 R_2^{-1} G^T H_2^T \dot{y} - \left[ K_2 R_2 G^T H_2^T \overline{C_1} \left( L H_{22}^T + \widetilde{E_1} \right) + \overline{A_{22}} K_2 R_2^{-1} G^T H_2^T \right] y - \left[ K_2 R_2^{-1} G^T H_2^T \overline{C_1} \left( \widetilde{A_1} - L C_1 \right) + \overline{A_{21}} - \overline{A_{22}} K_2 R_2^{-1} G^T H_2^T \overline{C_1} \right] \hat{x}_1 - \left( K_2 R_2^{-1} G^T H_2^T \overline{C_1} \widetilde{B_1} + \overline{B_2} \right) u$$
(1.328)

$$\hat{d} = U_1 \dot{y} - U_2 y - U_3 \hat{\overline{x}}_1 - U_4 u, \qquad (1.329)$$

unde

$$U_{1} = K_{2}R_{2}^{-1}G^{T}H_{2}^{T},$$

$$U_{2} = K_{2}R_{2}G^{T}H_{2}^{T}\overline{C_{1}}(LH_{22}^{T} + \widetilde{E_{1}}) + \overline{A}_{22}K_{2}R_{2}^{-1}G^{T}H_{2}^{T},$$

$$U_{3} = K_{2}R_{2}^{-1}G^{T}H_{2}^{T}\overline{C_{1}}(\widetilde{A_{1}} - LC_{1}) + \overline{A}_{21} - \overline{A}_{22}K_{2}R_{2}^{-1}G^{T}H_{2}^{T}\overline{C_{1}},$$

$$U_{4} = K_{2}R_{2}^{-1}G^{T}H_{2}^{T}\overline{C_{1}}\widetilde{B_{1}} + \overline{B}_{2}.$$
(1.330)

## <u>Observații</u>

Observerul de stare prezentat anterior estimează starea sistemului  $(\hat{x})$ , dar estimează și intrarea necunoscută a sistemului (*d*). Vectorul  $\hat{x}$  se află prin concatenarea vectorilor  $\hat{x}_1$  și  $\hat{x}_2$ , iar vectorul de stare estimat  $\hat{x}$  se determină cu formula (1.300). Condițiile necesare pentru construcția observerului cu ordin redus sunt:

a) 
$$rang(CD) = rang(D);$$

b) perechea  $(\widetilde{A}_1, C_1)$  este observabilă;

c) *n>m* (numărul stărilor sistemului este mai mare ca numărul ieșirilor);

d) matricea  $R_2$  - nesingulară, iar matricea  $H_2$  - ortogonală;

e) matricea  $\overline{C}_2$  are rang de coloană maxim.

Condițiile a) și c) se îndeplinesc ușor prin alegerea convenabilă a matricei C (implicit a vectorului de ieșire y); condițiile b), d) și e) se îndeplinesc prin alegerea convenabilă a matricei N. Cu alte cuvinte, alegând convenabil matricea C (implicit vectorul de ieșire y) și matricea N până când condițiile b), d) și e) sunt îndeplinite, toate cele 5 condiții necesare pentru proiectarea observerului vor fi îndeplinite.

În cele ce urmează, sunt prezentați pașii algoritmului pentru proiectarea observerului cu ordin redus (ALGLIN) prezentat anterior.

#### **Algoritmul ALGLIN**

**Pasul 1**: Se verifică dacă rang(CD) = rang(D) și n > m; în caz contrar, pentru ca algoritmul să poată fi folosit, se aleg alte ieșiri ale sistemului (altă matrice *C*) până la satisfacerea celor două condiții.

**Pasul 2**: Se alege o matrice N și se construiește matricea nesingulară T = [N D].

**Pasul 3**: Se face schimbarea de coordonate (1.281) și se calculează matricele  $\overline{A}, \overline{B}, \overline{C}, \overline{D}$ ; aceste matrice sunt partiționate și se obțin  $\overline{A}_{11}, \overline{A}_{12}, \overline{A}_{21}, \overline{A}_{22}, \overline{B}_1, \overline{B}_2, \overline{C}_1, \overline{C}_2$ .

**Pasul 4**: Se verifică dacă  $\overline{C}_2$  are rang de coloană maxim; în caz contrar ne întoarcem la pasul 2 și se reiau pașii 2-4 până la satisfacerea acestei condiții. În cazul în care  $\overline{C}_2$  are rang de coloană maxim, această matrice se scrie sub forma (1.308); rezultă, deci, matricele  $H_2, R_2$  și  $K_2$ . Alegerea celor trei matrice se face până când se obține o matrice ortogonală  $H_2$  și o matrice nesingulară (inversabilă)  $R_2$ .

**Pasul 5**: Se partiționează matricea  $H_2$  conform ecuației (1.310), rezultând astfel matricele  $H_{21}$  și  $H_{22}$ .

**Pasul 6**: Se calculează matricea  $C_1$  utilizând ecuația (1.315).

**Pasul 7**: Se calculează matricele  $\widetilde{A}_1, \widetilde{B}_1$  și  $\widetilde{E}_1$  cu ecuația (1.323). Se verifică dacă perechea  $(\widetilde{A}_1, C_1)$  este observabilă. În caz afirmativ, se trece la pasul următor; în caz contrar, ne întoarcem la pasul 2 și se reiau pașii 2-7 până la satisfacerea tuturor condițiilor necesare.

**Pasul 8**: Se proiectează observerul de tip Luenberger descris de ecuația (1.324); matricea L se alege astfel încât matricea  $\tilde{A}_1 - LC_1$  să fie stabilă (se impun valori proprii dorite în semiplanul stâng complex pentru matricea  $\tilde{A}_1 - LC_1$ ). Estimatorul de stare cu ordin redus estimează vectorul  $\bar{x}_1$ , furnizând, deci, estimarea acestuia  $(\hat{x}_1)$ .

**Pasul 9**: Se calculează  $\hat{\bar{x}}_2$  în funcție de  $\hat{\bar{x}}_1$ , aflat la pasul anterior, și de ieșirea sistemului y (ecuația (1.325)).

**Pasul 10**: Se calculează matricele  $U_1, U_2, U_3, U_4$  (ecuația (1.330)) și apoi se estimează

vectorul intrărilor necunoscute  $\hat{d}$  utilizând relația (1.329).

**Pasul 11**: Se determină  $\hat{x}$  prin concatenarea vectorilor  $\hat{x}_1, \hat{x}_2$  și apoi se determină vectorul de stare estimat  $\hat{x}$  – ecuația (1.300).

Algoritmul ALGLIN se validează pentru cazul mișcării longitudinale a unui mini-UAV [193]. Ecuația de stare presupune 6 variabile de stare și 2 mărimi de comandă (bracajele profundorului și comanda aplicată motorului prin intermediul manetei de gaze). Astfel, ecuația de stare asociată sistemului cu 2 intrări necunoscute este de forma (1.245) cu

unde  $V_x$ ,  $V_z$  sunt componentele orizontală respectiv verticală ale vitezei UAV-ului,  $\omega_y$  – viteza unghiulară de tangaj,  $\theta$  – unghiul de tangaj, H – altitudinea de zbor,  $\omega_e$  – viteza unghiulară de rotație a elicei aparatului de zbor,  $\delta_p$  – bracajul profundorului și  $\delta_I$  - comanda aplicată motorului prin intermediul manetei de gaze.

Programul Matlab din anexa A1.6 reprezintă implementarea software a procedurii de construcție a estimatorului de stare ALGLIN. Modelul Matlab/Simulink din fig. 1.27 este utilizat în cadrul programului din anexă pentru obținerea caracteristicilor de timp din fig. 1.28 (erorile de estimare a variabilelor de stare cu estimatorul de stare ALGLIN pentru u=0) și caracteristicile de timp din fig. 1.29 pentru legea de comandă  $u = -K\hat{x}$  (K calculată cu algoritmul ALGLX [157]); aceste caracteristici exprimă variabilele de stare  $x_i(t)$  – cu linie continuă și  $\hat{x}_i(t)$  – cu linie întreruptă,  $i = \overline{1, 6}$ .



Fig. 1.27. Modelul Matlab/Simulink al observerului ALGLIN



Fig. 1.28. Erorile de estimare a stării estimatorului ALGLIN (K = 0)



Fig. 1.29. Variabilele de stare  $x_i(t)$  și  $\hat{x}_i(t)$  - mișcarea longitudinală (K  $\neq 0$ )

Parcurgând pas cu pas algoritmul ALGLIN se obțin matricele

 $T = \begin{bmatrix} -2.2 & 0.6 & 0 & 0.7 & 0 & 0 \\ -0.1 & -0.6 & -0.3 & 0.6 & -4 & 0 \\ -1 & 0.4 & 1.1 & 0 & -106 & 0 \\ 0.6 & -1 & -1.9 & 0.7 & 0 & 100 \\ 0.5 & 0 & 0.4 & 0.6 & 0 & 0 \\ 1.7 & 0 & 0.9 & 0.3 & 0 & 3894 \end{bmatrix}, H_2 = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 \end{bmatrix}, K_2 = \begin{bmatrix} -0.09 & 0 \\ -0.24 & 0 \end{bmatrix}^T, L_2 = \begin{bmatrix} -22.47 & 52.28 & 0 & 0 \\ -71.22 & 143.67 & 0 & 0 \\ 25.11 & -47.10 & 0 & 0 \\ -13.60 & 41.66 & 0 & 0 \end{bmatrix}.$ 

# 1.7. TEHNICI DE PROIECTARE A OBSERVERELOR NELINIARE

### **1.7.1. CHESTIUNI GENERALE**

Teoria pentru proiectarea observerelor neliniare este departe de a fi atât de dezvoltată ca cea pentru sistemele liniare. Aplicarea teoriei observerelor și la sistemele neliniare a avut succes; ca dovadă - filtrul Kalman extins pentru sistemele neliniare. Alte observere neliniare au fost proiectate de Thau în 1973 [224], Baumann și Rugh în 1986 [8], Krener [129], Zeitz [244] etc.

Se consideră sistemul [197]

$$\dot{x} = f(x), y = h(x),$$
 (1.332)

unde  $x \in \mathbb{R}^n$  este vectorul de stare,  $y \in \mathbb{R}^p$  este vectorul de ieșire, iar f și h – funcții neliniare. Se poate încerca metoda de proiectare a observerelor liniare și în cazul observerelor neliniare. Astfel, ecuațiile asociate observerului neliniar sunt [197]

$$\hat{x} = f(\hat{x}) + L(\hat{y} - y), \, \hat{y} = h(x),$$
(1.333)

unde  $\hat{x} \in \mathbb{R}^n$  este vectorul de stare estimat,  $\hat{y} \in \mathbb{R}^p$  – vectorul de ieşire estimat, iar  $L \in \mathbb{R}^{n \times p}$  este matricea de amplificare a observerului (cea care trebuie determinată).

Alegând ca eroare a observerului

$$e = \hat{x} - x, \qquad (1.334)$$

se calculează  $\dot{e}$  și se obține [197]

$$\dot{e} = \dot{\hat{x}} - \dot{x} = f(\hat{x}) - f(x) + L[h(\hat{x}) - h(x)].$$
(1.335)

Dinamica erorii este neliniară; deoarece stabilitatea unui sistem liniarizat într-un punct fix implică stabilitatea sistemului neliniar corespunzător în punctul considerat, se va încerca liniarizarea dinamicii erorii în punctul fix e = 0 [197]

$$\dot{e} = f(x+e) - f(x) + L\left[h(x+e) - h(x)\right] \Leftrightarrow$$
  
$$\Leftrightarrow \dot{e} = e\left[\frac{\partial f}{\partial x}(x) + L\frac{\partial h}{\partial x}(x)\right] + O(e^2) \cong e\left[\frac{\partial f}{\partial x}(x) + L\frac{\partial h}{\partial x}(x)\right],$$
(1.336)

unde  $\frac{\partial f}{\partial x}(x)$ , respectiv  $\frac{\partial h}{\partial x}(x)$  reprezintă matrice Jacobi.

Considerând

$$f = [f_1 \ f_2 \ \cdots \ f_m]^T, h = [h_1 \ h_2 \ \cdots \ h_q]^T,$$
(1.337)

matricele Jacobi  $(J_f \text{ si } J_h)$  sunt

$$J_{f} = \frac{\partial f}{\partial x}(x) = \begin{bmatrix} \frac{\partial f_{1}}{\partial x_{1}} & \frac{\partial f_{1}}{\partial x_{2}} & \cdots & \frac{\partial f_{1}}{\partial x_{n}} \\ \vdots & & \vdots \\ \frac{\partial f_{m}}{\partial x_{1}} & \frac{\partial f_{m}}{\partial x_{2}} & \cdots & \frac{\partial f_{m}}{\partial x_{n}} \end{bmatrix},$$
(1.338)

respectiv,

$$J_{h} = \frac{\partial h}{\partial x}(x) = \begin{bmatrix} \frac{\partial h_{1}}{\partial x_{1}} & \frac{\partial h_{1}}{\partial x_{2}} & \cdots & \frac{\partial h_{1}}{\partial x_{n}} \\ \vdots & & \vdots \\ \frac{\partial h_{q}}{\partial x_{1}} & \frac{\partial h_{q}}{\partial x_{2}} & \cdots & \frac{\partial h_{q}}{\partial x_{n}} \end{bmatrix}.$$
 (1.339)

Din păcate, derivata erorii ( $\dot{e}$  – ecuația (1.336)) este funcție de vectorul de stare x ce trebuie estimat și nu este o cantitate fixă (vectorul x este un vector necunoscut). Așadar, este nevoie de o altă metodă [197].

## **1.7.2. METODE BAZATE PE TEORIA LYAPUNOV**

În proiectarea observerelor bazate pe teoria Lyapunov se utilizează următoarele 2 teoreme [197]:

#### <u>Teorema 1</u>

Se consideră sistemul neliniar (1.332), observerul neliniar (1.333) și dinamica erorii (1.335); dacă există o matrice constantă  $L \in \mathbb{R}^{n \times m}$  pozitiv definită și o matrice simetrică  $P \in \mathbb{R}^{n \times m}$  astfel încât

$$P\left[\frac{\partial f}{\partial x}(x) + L\frac{\partial h}{\partial x}(x)\right] < 0, (\forall)x, \qquad (1.340)$$

atunci sistemul (1.333), cu matricea L satisfăcând ecuația (1.340) și cu estimarea inițială  $\hat{x}(t_0)$ , este un observer exponențial pentru sistemul (1.332) și

$$\|\hat{x}(t) - x(t)\| \le \alpha_1 \|\hat{x}(t_0) - x(t_0)\| \cdot \exp[-\alpha_2(t - t_0)], \qquad (1.341)$$

cu  $\alpha_1$ ,  $\alpha_2$  – constante pozitive.

Pentru demonstrație [197], se consideră funcția Lyapunov

$$V(e) = e^T P e \tag{1.342}$$

și se calculează

$$\dot{V}(e) = 2e^{T}P\dot{e} = 2e^{T}P[f(\hat{x}) - f(x) + L(h(\hat{x}) - h(x))].$$
(1.343)

Se consideră curba

$$c(t) = t\hat{x} + (1-t)x, t \in [0,1];$$
(1.344)

în 0 și 1 funcția c(t) ia valorile x, respectiv  $\hat{x}$ ; se obține

$$f(\hat{x}) - f(x) = \int_0^1 \frac{\partial f}{\partial x} (c(t)) \cdot c'(t) dt = \int_0^1 \frac{\partial f}{\partial x} (t\hat{x} + (1-t)x) (\hat{x} - x) dt.$$
(1.345)

Analog,

$$h(\hat{x}) - h(x) = \int_{0}^{1} \frac{\partial h}{\partial x} (t\hat{x} + (1 - t)x)(\hat{x} - x) dt; \qquad (1.346)$$

rezultă una din formele echivalente [197]

$$\dot{V}(e) = 2e^{T}P\int_{0}^{1}e^{T}P\left[\frac{\partial f}{\partial x}(t\hat{x} + (1-t)x)(\hat{x} - x) + L\frac{\partial h}{\partial x}(t\hat{x} + (1-t)x)(\hat{x} - x)\right]dt \qquad (1.347)$$

$$\dot{V}(e) = 2e^{T}P\int_{0}^{1}e^{T}P\left[\frac{\partial f}{\partial x}(t\hat{x} + (1-t)x)e + L\frac{\partial h}{\partial x}(t\hat{x} + (1-t)x)e\right]dt =$$

$$= 2\int_{0}^{1}e^{T}P\left(\frac{\partial f}{\partial x} + L\frac{\partial h}{\partial x}\right)e dt < 0.$$

$$(1.348)$$

Aşadar, e = 0 este punct de stabilitate globală [197].

#### Teorema 2

Se consideră sistemul neliniar

$$\dot{x} = f(x), f(0) = 0.$$
 (1.349)

Dacă  $\frac{\partial f}{\partial x}(x) < 0$ ,  $(\forall)x$  (adică matricea Jacobi asociată lui f și x este negativ definită pentru orice vector de stare x)  $\Rightarrow x = 0$  este punct asimptotic stabil pentru sistemul (1.349) [197]. Thau, în 1973, a construit un observer neliniar pentru estimarea stării sistemelor [8]

$$\dot{x} = Ax + f(x), y = Cx,$$
 (1.350)

 $x \in \mathbb{R}^n, y \in \mathbb{R}^p, f$  – funcție continuă și neliniară,  $A \in \mathbb{R}^{n \times n}, C \in \mathbb{R}^{p \times n}$ . Se presupune că (C, A) – pereche observabilă. Acest lucru ne permite să găsim o matrice  $L \in \mathbb{R}^{n \times p}$ astfel încât valorile proprii ale matricei A + LC să se afle în semiplanul stâng complex. Observerul se construiește astfel [8], [197]:

$$\dot{\hat{x}} = A\hat{x} + f(\hat{x}) + L(\hat{y} - y), \, \hat{y} = C\hat{x} \,.$$
(1.351)

Fie  $e = \hat{x} - x$ ; rezultă

$$\dot{e} = A\hat{x} + f(\hat{x}) + L(\hat{y} - y) - Ax - f(x) \Leftrightarrow \dot{e} = (A + LC)e + f(x + e) - f(x). \quad (1.352)$$

Stabilitatea liniară implică stabilitate neliniară în vecinătatea punctului fix. În acest caz, punctul fix asociat ecuației (1.351) este e = 0 [197]. Dacă f nu are termeni neliniari, alegând L astfel încât matricea (A + LC) să fie stabilă, se asigură convergența  $e \rightarrow 0$ . Dar f(x) este funcție neliniară; deci, stabilitatea matricei (A + LC)nu mai este suficientă. Cum (A + LC) matrice stabilă  $\Rightarrow$  pentru orice matrice  $Q \in R^{n \times n}$  pozitiv definită există o matrice pozitiv definită  $P \in R^{n \times n}$  astfel încât [197]

$$(A + LC)^{T} P + P(A + LC) = -2Q.$$
(1.353)

Fie  $V(e) = e^T P e$ . Derivata funcției Lyapunov V(e) este

$$\dot{V}(e) = \dot{e}^T P e + e^T P \dot{e} = -2e^T Q e + 2e^T P [f(x+e) - f(x)].$$
(1.354)

Trebuie ca  $\dot{V}(e) < 0$ ; de aceea se impune ca f să fie Lipschitz în origine, adică să existe o constantă pozitivă M astfel încât

$$\|f(x_1) - f(x_2)\| \le M \|x_1 - x_2\|, \qquad (1.355)$$

pentru orice  $x_1, x_2$  aflate într-o vecinătate W a originii. Dacă e se află în W, sunt valabile inegalitățile

$$\dot{V}(e) \leq -2e^{T}Qe + 2M ||Pe|| \cdot ||e|| \leq [-2\sigma_{\min}(Q) + 2M\sigma_{\max}(P)] ||e||^{2},$$
 (1.356)

unde  $\sigma_{\min}(Q)$  este valoarea singulară minimă a lui Q, iar  $\sigma_{\max}(P)$  este valoarea singulară maximă a lui P [197].

Astfel, dacă

$$\sigma_{\min}(Q) / \sigma_{\max}(P) > M , \qquad (1.357)$$

rezultă e = 0 este punct de echilibru stabil și  $\hat{x} \rightarrow x$ .

Teoremele anterioare furnizează condiții suficiente pentru un observer asimptotic stabil, dar satisfacerea teoremelor nu constituie o procedură constructivă pentru determinarea matricei L. Alegerea lui L pentru satisfacerea teoremelor este un proces dificil și chiar imposibil pentru sisteme de ordin mare [197].

## **1.7.3. DIVERSE TIPURI DE OBSERVERE NELINIARE**

## 1.7.3.1. Observere Krener & Isidori

Observerul următor a fost proiectat de către Krener & Isidori în 1983. Acesta este un observer nelinair asociat unui sistem de forma [138], [185]:

$$\dot{x} = f(x, u), y = h(x),$$
 (1.358)

unde vectorul de stare,  $u(t) \in R^m$  este vectorul intrărilor și  $y(t) \in R^p$  – vectorul ce conține ieșirile sistemului. Krener & Isidori au proiectat un estimator de stare neliniar folosind transformările

$$z = \varphi(x), w = \gamma(y); \tag{1.359}$$

cu acestea, ecuațiile de stare ce descriu sistemul devin [138], [185]

$$\dot{z} = Az + Bu + \alpha(y, u), w = Cz.$$
 (1.360)

După liniarizarea sistemului, se proiectează observerul [185]

$$\dot{\hat{z}} = A\hat{z} + Bu + \alpha(y, u) + L(w - C\hat{z}),$$
 (1.361)

unde  $\alpha(y, u)$  – termen de "injecție", L – matricea de amplificare a observerului,  $\hat{z}$  – estimarea vectorului z; s-a presupus că perechea (A, C) este observabilă. Dinamica erorii sistemului este

$$\dot{e} = (A - LC)e, \qquad (1.362)$$

unde

$$e = \hat{z} - z \,. \tag{1.363}$$

#### 1.7.3.2. Observere Kazantzis & Kravaris

Se consideră o clasă de sisteme neliniare [128]

$$\dot{x} = f(x), y = h(x),$$
 (1.364)

cu  $f : \mathbb{R}^n \to \mathbb{R}^n, y : \mathbb{R}^n \to \mathbb{R}^m$  – câmpuri de vectori. Originea (x = 0) este punct de echilibru (f(0) = h(0) = 0). Metoda va determina o transformare de stare neliniară care să transforme dinamica observerului într-una liniară. Transformarea neliniară  $z = \theta(x)$  se alege astfel încât [185]

$$\dot{z} = \frac{\partial \theta}{\partial x} \cdot \frac{\partial x}{\partial t} = \frac{\partial \theta}{\partial x} \dot{x} = Az - \beta(y).$$
(1.365)

Transformarea neliniară  $\theta(x)$  trebuie să verifice ecuația [128]

$$\frac{\partial \theta}{\partial x}(x) \cdot f(x) = A\theta(x) - \beta(h(x)) = Az - \beta(y).$$
(1.366)

Fie F – matricea Jacobi asociată câmpului f(x) cu valorile proprii  $k_i$ ,  $i = \overline{1, n}$ . Fie, de asemenea, matricea  $n \times n$ 

$$H = \left[\frac{\partial h_1}{\partial x}(0) \cdots \frac{\partial h_m}{\partial x}(0)\right]; \qquad (1.367)$$

rangul matricei  $[H \ HF \ \cdots \ HF^{n-1}]$  este n.

Din teorema auxiliară a lui Lyapunov [185], rezultă

$$\frac{\partial w}{\partial x}\,\phi(x,w) = \psi(x,w). \tag{1.368}$$

Considerând valabilă ecuația (1.368), se consideră cazul liniar

$$\varphi(x,w) = Fx, \quad \psi(x,w) = Aw - BHx, \quad (1.369)$$

unde  $\beta = \frac{\partial \beta}{\partial x}(0); F, A, H -$  matrice constante. Soluția unică a ecuației (1.366) este

$$w = Tx, \qquad (1.370)$$

unde T este soluția ecuației [185]

$$TF + AT = BH. \tag{1.371}$$

Considerând  $z = \theta(x)$  soluția inversabilă a ecuației (1.366), observerul se construiește astfel [128], [185]:

$$\dot{\hat{x}} = f(\hat{x}) - \left[\frac{\partial \theta}{\partial \hat{x}}(\hat{x})\right]^{-1} \left[\beta(y) - \beta(h(\hat{x}))\right].$$
(1.372)

Ecuația asociată erorii observerului este (1.363), iar dinamica erorii este [185]

$$\dot{e} = \frac{\mathrm{d}}{\mathrm{d}t} \left[ \theta(\hat{x}) - \theta(x) \right] = A \left[ \theta(\hat{x}) - \theta(x) \right] = A e \,. \tag{1.373}$$

#### 1.7.3.3. Observere Yannick Morel

Se consideră sistemul de forma

$$\dot{x}(t) = f(x(t), t), y(t) = Cx(t),$$
 (1.374)

unde  $x \in \mathbb{R}^n$ ,  $y \in \mathbb{R}^m$ ,  $m \ge n/2$ , p = n - m,  $C = \begin{bmatrix} I_m & 0_{m \times p} \end{bmatrix}$ . Din cele *n* variabile de stare, primele *m* vor fi măsurate, urmând ca p=n-m variabile de stare să fie estimate [178].

Scopul proiectării acestui observer [178] este reconstrucția întregului vector de stare x(t) folosind informațiile furnizate de y(t) și de cunoașterea parțială a membrului drept a primei ecuații (1.374). Astfel,

$$y(t) = x_1(t)$$
 (1.375)

reprezintă vectorul de ieșire al sistemului (vectorul ce conține variabilele de stare direct măsurabile), iar vectorul de stare x(t) se împarte în două părți: vectorul  $x_1(t) \in \mathbb{R}^m$  – vectorul variabilelor de stare direct măsurabile și vectorul  $x_2(t) \in \mathbb{R}^{n-m}$  – vectorul de stare ce urmează a fi estimat prin intermediul observerului Yannick Morel [178];

$$x(t) = [x_1^T(t) \ x_2^T(t)]^T.$$
(1.376)

În aceste condiții, dinamica sistemului devine

$$\dot{x}_1(t) = f_1(x_1(t), x_2(t), t)$$
 (1.377)

cu  $x_1(0) = Cx(0) = y(0); f_1(x_1(t), x_2(t), t) = Cf(x(t), t).$ 

Condiția de observabilitate a sistemului este [178]

$$\operatorname{rang}\left[\frac{\partial f_1(x_1, x_2, t)}{\partial x_2}\right] = p.$$
(1.378)

Din (1.374) și (1.377) rezultă

$$\dot{y}(t) = f_1(y(t), x_2(t), t) = 0.$$
 (1.379)

Conform teoremei din [136], dacă este îndeplinită condiția (1.378), există o funcție unică  $g: R^m \times R^m \times R \to R^p$  astfel încât  $g(y, \dot{y}, t) = x_2$ ; a lucra însă direct cu funcția  $g(\cdot)$  nu reprezintă o soluție viabilă pentru construcția observerului care să estimeze  $x_2$ .

În aceste condiții, se va lucra indirect cu funcția  $g(\cdot)$ . Astfel, se va construi  $\hat{x}_2$ (estimarea lui  $x_2$ ) ce va converge într-o vecinătate a lui  $g(y(t), \dot{y}(t), t)$ . Pentru că semnalul  $\dot{y}(t)$  nu se măsoară, el se va estima folosindu-se y(t) (semnal măsurabil) și, eventual, un estimator al derivatei ca cele din [36] și [238]. Se calculează  $\hat{x}_1(t)$ , cu o formulă de tipul (1.377), înlocuindu-se  $x_2(t)$  cu  $\hat{x}_2(t)$  și adăugându-se în plus, în membrul drept, termenul  $-De_1(t)$ 

$$\dot{\hat{x}}_1(t) = f_1(x_1(t), \hat{x}_2(t), t) - De_1(t),$$
 (1.380)

unde  $D \in R^{m \times m}, e_1(t) = x_1(t) - \hat{x}_1(t)$ .

Pentru o mai bună flexibilitate în procedura de proiectare, se va utiliza semnalul auxiliar  $\omega(t) \in \mathbb{R}^m$ , soluție a ecuației [178]

$$\dot{\omega}(t) = W_a(x_1(t), \hat{x}_2(t), t) \cdot v(t), \, \omega(0) = 0_{m \times 1}, \qquad (1.381)$$

unde  $v(t) \in \mathbb{R}^{m-p}$ , iar  $W_a(\cdot) \in \mathbb{R}^{m \times (m-p)}$  este o funcție aleasă astfel încât [178]

$$W_2(x_1, \hat{x}_2, t) \stackrel{\Delta}{=} \begin{bmatrix} \frac{\partial f_1(x_1, \hat{x}_2, t)}{\partial \hat{x}_2} & W_a(x_1, \hat{x}_2, t) \end{bmatrix} \in \mathbb{R}^{m \times m} \text{ să fie nesingulară } (\forall) x_1 \in \mathbb{R}^m, \hat{x}_2 \in \mathbb{R}^p.$$

Se construiește  $\dot{\hat{x}}_{2a} \stackrel{\Delta}{=} \left[ \dot{\hat{x}}_{2}^{T}(t) \quad v^{T}(t) \right]^{T} \in \mathbb{R}^{m}$  astfel încât  $\lim_{t \to \infty} e_{1}(t) = 0$ ; se folosesc notațiile [178]

$$W_{1}(x_{1}, \hat{x}_{2}, t) \stackrel{\Delta}{=} \frac{\partial f_{1}(x_{1}, \hat{x}_{2}, t)}{\partial x_{1}}, W_{3}(x_{1}, \hat{x}_{2}, t) \stackrel{\Delta}{=} \frac{\partial f_{1}(x_{1}, \hat{x}_{2}, t)}{\partial t}.$$
 (1.382)

Se folosește, de asemenea, și lema următoare [75]:

#### <u>Lema 1</u>

Fie  $A, S \in \mathbb{R}^{m \times m}$  – matrice Hurwitz și  $Q \stackrel{\Delta}{=} \mathbb{R}^T \mathbb{R}$ , unde  $\mathbb{R} \in \mathbb{R}^{m \times m}$  are rang maxim. Dacă  $H \stackrel{\Delta}{=} \begin{bmatrix} A & SS^T \\ -Q & -A^T \end{bmatrix}$  nu are valori proprii pe axa imaginară, atunci  $(\exists) P \ge 0$  astfel încât

$$A^{T}P + PA + Q + PSS^{T}P = 0. (1.383)$$

Dacă, în plus, perechea (A, R) este observabilă, atunci P > 0.

Proiectarea observerului Yannick Morel se bazează pe următoarea teoremă [178]:

## <u>Teorema 3</u>

Se consideră sistemul descris de ecuațiile (1.374) și predictorul de stare (1.380). Se presupune că este disponibil un semnal continuu și diferențiabil z(t) astfel încât  $z(t) = \dot{y}(t) + \omega(t) - \varepsilon(t)$ , cu  $\|\varepsilon(t)\| \le \sqrt{\varepsilon/3}, \varepsilon > 0$ . În aceste condiții,  $\hat{x}_2(t)$  este obținut prin intermediul estimatorului de stare:

$$\begin{aligned} \dot{\hat{x}}_{2a}(t) &= W_2^{-1}(x_1(t), \hat{x}_2(t), t) \{ P_2^{-1} P_1 e_1(t) - A_1 \left[ \left( A_1 + P_1^{-1} K \right) e_1(t) - e_2(t) \right] + \dot{z}(t) + A_2 e_2(t) \} - \\ &- W_2^{-1}(x_1(t), \hat{x}_2(t), t) W_1(x_1(t), \hat{x}_2(t), t) \left[ z(t) - \omega(t) + \frac{1}{2} W_1^T(x_1(t), \hat{x}_2(t), t) P_2 e_2(t) \right] - \\ &- W_2^{-1}(x_1(t), \hat{x}_2(t), t) W_3(x_1(t), \hat{x}_2(t), t); \hat{x}_2(t) = \left[ I_p \ 0_{p \times (m-p)} \right] \hat{x}_{2a}(t), \end{aligned}$$

unde  $A_1, A_2, K \in \mathbb{R}^{m \times m}$  sunt matrice Hurwitz,  $e_2(t)$  are expressia [178]

$$e_{2}(t) \stackrel{\scriptscriptstyle \Delta}{=} f_{1}(x_{1}(t), \hat{x}_{2}(t), t) + \omega(t) + a_{1}e_{1}(t) - z(t), \qquad (1.385)$$

iar  $P_1, P_2 \in \mathbb{R}^{m \times m}$  – soluțiile ecuațiilor Riccati

$$A_1^T P_1 + P_1 A_1 + Q_1 + P_1^2 = 0, A_2^T P_2 + P_2 A_2 + Q_2 + P_2 A_1 A_1^T P_2 = 0; \qquad (1.386)$$

 $Q_1 = R_1^T R_1 > 0$  și  $Q_2 = R_2^T R_2 > 0$  se aleg astfel încât matricele  $H_1 \stackrel{\Delta}{=} \begin{bmatrix} A_1 & I_m \\ -Q_1 & -A_1^T \end{bmatrix}$  și

 $H_{2} \stackrel{\text{\tiny \Delta}}{=} \begin{bmatrix} A_{2} & A_{1}A_{1}^{T} \\ -Q_{2} & -A_{2}^{T} \end{bmatrix}$  să nu aibă valori proprii pe axa imaginară, iar perechiile  $(A_{1}, R_{1})$  și  $(A_{2}, R_{2})$  să fie observabile. În plus,  $\omega(t)$  se obține din ecuația (1.381) cu

$$v(t) \stackrel{\Delta}{=} \begin{bmatrix} 0_{(m-p) \times p} & I_{m-p} \end{bmatrix} \dot{\hat{x}}_{2a}(t);$$
(1.387)

matricea *D* se alege de forma [178]:  $D = P_1^{-1}K$ . Demonstrația teoremei precedente este prezentată în continuare [178]. Se calculează mai întâi  $\dot{e}_1(t)$  și se obține

$$\dot{e}_{1}(t) = f_{1}(x_{1}, x_{2}, t) - f_{1}(x_{1}, \hat{x}_{2}, t) + P_{1}^{-1}Ke_{1}(t).$$
(1.388)

Decoarece  $e_2(t) = f_1(x_1, \hat{x}_2, t) + \omega(t) + A_1 e_1(t) - z(t) \Rightarrow f_1(x_1, \hat{x}_2, t) = e_2(t) - \omega(t) - A_1 e_1(t) + z(t);$ înlocuind  $f_1(x_1, \hat{x}_2, t)$  în (1.388), rezultă

$$\dot{e}_1(t) = (A_1 + P_1^{-1}K)e_1(t) - e_2(t) + \varepsilon(t).$$
(1.389)

Se calculează acum  $\dot{e}_2(t)$  și se obține [178]

$$\dot{e}_2(t) = \dot{f}_1(x_1, \hat{x}_2, t) + \dot{\omega}(t) + A_1 \dot{e}_1(t) - \dot{z}(t).$$
(1.390)

Ținând cont de

$$\dot{f}_{1}(x_{1}, \dot{x}_{2}, t) = \frac{df_{1}(x_{1}, \dot{x}_{2}, t)}{dt} = \frac{\partial f_{1}(x_{1}, \dot{x}_{2}, t)}{\partial x_{1}} \frac{\partial x_{1}}{\partial t} + \frac{\partial f_{1}(x_{1}, \dot{x}_{2}, t)}{\partial x_{2}} \frac{\partial x_{2}}{\partial t} + \frac{\partial f_{1}(x_{1}, \dot{x}_{2}, t)}{\partial t} \frac{\partial t}{\partial t} =$$

$$= W_{1}\dot{x}_{1} + \frac{\partial f_{1}(x_{1}, \dot{x}_{2}, t)}{\partial x_{2}} \dot{x}_{2} + W_{3} \stackrel{(2.384)}{=} W_{1}\dot{x}_{1} + \left[I_{p} \ 0_{p\times(m-p)}\right] \dot{x}_{2a}(t) + W_{3}$$

$$(1.391)$$

şi

$$\dot{\omega}(t)^{(1.381)} = W_a(x_1(t), \hat{x}_2(t), t) \cdot v(t)^{(1.387)} = W_a(x_1(t), \hat{x}_2(t), t) \cdot \left[0_{(m-p) \times p} \quad I_{m-p}\right] \dot{\hat{x}}_{2a}(t),$$
(1.392)

se obține succesiv [178]

$$\dot{e}_{2} = W_{1}\dot{x}_{1} + W_{3} + \frac{\partial f_{1}(x_{1}, \hat{x}_{2}, t)}{\partial x_{2}} [I_{p} \quad 0_{p \times (m-p)}] \dot{\hat{x}}_{2a}(t) + [0_{(m-p) \times p} \quad W_{a}(x_{1}(t), \hat{x}_{2}(t), t)] \dot{\hat{x}}_{2a} + A_{1}\dot{e}_{1}(t) - \dot{z}(t) = A_{1}\dot{e}_{1} + W_{1}\dot{x}_{1} + W_{2}\dot{\hat{x}}_{2a} + W_{3} - \dot{z} \stackrel{(1.389)}{=} A_{1}\varepsilon + A_{1}[(A_{1} + P_{1}^{-1}K)e_{1} - e_{2}] + W_{1}\dot{x}_{1} + W_{2}\dot{\hat{x}}_{2a} + W_{3} - \dot{z} = A_{1}\varepsilon + A_{1}[(A_{1} + P_{1}^{-1}K)e_{1} - e_{2}] + W_{1}(z - \omega + \varepsilon) - \dot{z} + W_{3} + W_{2}\dot{\hat{x}}_{2a}$$

$$(1.393)$$

Din prima ecuație (1.384) rezultă

$$\dot{\hat{x}}_{2a} = W_2^{-1} \left\{ P_2^{-1} P_1 e_1 - A_1 \left[ \left( A_1 + P_1^{-1} K \right) e_1 - e_2 \right] + \dot{z} + A_2 e_2 - W_1 \left[ z - \omega + \frac{1}{2} W_1^T P_2 e_2 \right] - W_3 \right\}; (1.394)$$

Eliminând  $\dot{\hat{x}}_{2a}$  între ecuațiile (1.393) și (1.394) se obține [178]

$$\dot{e}_2 = A_1 \varepsilon + P_2^{-1} P_1 e_1 + A_2 e_2 + W_1 \bigg[ \varepsilon - \frac{1}{2} W_1^T P_2 e_2 \bigg].$$
(1.395)

Pentru a demonstra convergența estimatorului de stare, se consideră funcția Lyapunov

$$V(e_1, e_2) = e_1^T P_1 e_1 + e_2^T P_2 e_2$$
(1.396)

cu  $P_1, P_2 > 0$  – soluțiile ecuațiilor (1.386). Se calculează derivata funcției Lyapunov și se obține succesiv [178]

$$\dot{V}(t) = e_{1}^{T} \left( P_{1}A_{1} + A_{1}^{T}P_{1} \right) e_{1} + e_{1}^{T} \left( K + K^{T} \right) e_{1} - 2e_{1}^{T}P_{1}e_{2} + 2e_{1}^{T}P_{1}\varepsilon + e_{2}^{T} \left( A_{2}^{T}P_{2} + P_{2}A_{2} \right) e_{2} + 2e_{2}^{T}P_{2} \left[ A_{1}\varepsilon + W_{1} \left( \varepsilon - \frac{1}{2}W_{1}^{T}P_{2}e_{2} \right) + P_{2}^{-1}P_{1}e_{1} \right] = 2e_{2}^{T}P_{2}W_{1} \left( \varepsilon - \frac{1}{2}W_{1}^{T}P_{2}e_{2} \right) + 2e_{2}^{T}P_{2}A_{1}\varepsilon + 2e_{1}^{T}P_{1}\varepsilon + e_{1}^{T} \left( A_{1}^{T}P_{1} + P_{1}A_{1} + K + K^{T} + P_{1}^{2} - P_{1}^{2} \right) e_{1} + e_{2}^{T} \left( A_{2}^{T}P_{2} + A_{2}P_{2} + P_{2}A_{1}A_{1}^{T}P_{2} \right) - (1.397) - e_{2}^{T} \left( P_{2}A_{1}A_{1}^{T}P_{2}Q_{2} - Q_{2} \right)^{(1.386)} 2e_{2}^{T}P_{2}W_{1} \left( \varepsilon - \frac{1}{2}W_{1}^{T}P_{2}e_{2} \right) + 2e_{2}^{T}P_{2}A_{1}\varepsilon + 2e_{1}^{T}P_{1}\varepsilon - e_{1}^{T} \left( Q_{1} - K - K^{T} + P_{1}^{2} \right) - e_{2}^{T} \left( Q_{2} + P_{2}A_{1}A_{1}^{T}P_{2} \right);$$

pentru obținerea ecuației (1.397) s-au avut în vedere relațiile [178]

$$e_{2}^{T}P_{1}e_{1} = (e_{2}^{T}P_{1}e_{1})^{T} = e_{1}^{T}P_{1}e_{2}, e_{1}^{T}P_{1}\varepsilon = (e_{1}^{T}P_{1}\varepsilon)^{T} = \varepsilon^{T}P_{1}e_{1},$$

$$e_{2}^{T}P_{2}A_{1}\varepsilon = (e_{2}^{T}P_{2}A_{1}\varepsilon)^{T} = \varepsilon^{T}A_{1}^{T}P_{2}e_{2}, e_{2}^{T}P_{2}W_{1}\left(\varepsilon - \frac{1}{2}W_{1}^{T}P_{2}e_{2}\right) = \left(\varepsilon^{T} - \frac{1}{2}e_{2}^{T}P_{2}^{T}w_{1}\right)W_{1}^{T}P_{2}e_{2}$$
(1.398)

Utilizând relația

$$2A^{T}BC = -(B^{T}A - C)^{T}(B^{T}A - C) + A^{T}BB^{T}A + C^{T}C \le A^{T}BB^{T}A + C^{T}C$$
(1.399)

se obțin [178]

$$2e_{1}^{T}P_{1}\varepsilon = -(P_{1}e_{1} - \varepsilon)^{T}(P_{1}e_{1} - \varepsilon) + e_{1}^{T}P_{1}^{2}e_{1} + \varepsilon^{T}\varepsilon \leq e_{1}^{T}P_{1}^{2}e_{1} + \varepsilon^{T}\varepsilon,$$

$$2e_{2}^{T}P_{2}A_{1}\varepsilon = -(A_{1}^{T}P_{2}e_{2} - \varepsilon)^{T}(A_{1}^{T}P_{2}e_{2} - \varepsilon) + e_{2}^{T}P_{2}A_{1}A_{1}^{T}P_{2}e_{2} + \varepsilon^{T}\varepsilon \leq e_{2}^{T}P_{2}A_{1}A_{1}^{T}P_{2}e_{2} + \varepsilon^{T}\varepsilon,$$

$$(1.400)$$

$$2e_{2}^{T}P_{2}W_{1}\varepsilon = -(W_{1}^{T}P_{2}^{T}e_{2} - \varepsilon)^{T}(W_{1}^{T}P_{2}^{T}e_{2} - \varepsilon) + e_{2}^{T}P_{2}W_{1}W_{1}^{T}P_{2}^{T}e_{2} + \varepsilon^{T}\varepsilon \leq e_{2}^{T}P_{2}W_{1}W_{1}^{T}P_{2}^{T}e_{2} + \varepsilon^{T}\varepsilon.$$

Cu acestea,  $\dot{V}(t)$  devine

$$\dot{V}(t) \le -e_1^T \overline{Q}_1 e_1 - e_2^T Q_2 e_2 + \varepsilon,$$
 (1.401)

unde  $\overline{Q}_1 = Q_1 - K - K^T$ . Este evident faptul că funcția  $\dot{V}(t)$  este negativă în afara domeniului  $\{(e_1, e_2) : e_1^T \overline{Q}_1 e_1 + e_2^T Q_2 e_2 \le \varepsilon\}$ , lucru care demonstrază mărginirea perechii  $(e_1(t), e_2(t))(\forall) t > 0$  [52], [131].



Fig. 1.30. Schema bloc a ansamblului sistem-observer-predictor

În cadrul teoremei 3 s-a presupus  $m \ge n/2$ . În cazul particular m = n/2, procedura de proiectare a observerului este mai simplă (K devine matricea nulă,  $\hat{x}_{2a} = \hat{x}_2 (\forall) t > 0$  și nu mai este necesară utilizarea vectorului  $\omega(t)$ ).

Schema bloc a ansamblului sistem-observer-predictor (Yannick Morel) este prezentată în fig. 1.30.

#### 1.7.3.4. Observere optimale

Se consideră sistemul neliniar descris de ecuațiile de stare [214]

$$\begin{cases} \dot{x} = f(x, u, t) + Ew, \\ y = g(x, t) + v, \end{cases}$$
(1.402)

în care f, g sunt funcții neliniare, v, w – procese aleatoare de tip zgomot alb. Sistemul anterior poate fi scris [214]

$$\begin{cases} \dot{x} = A(x)x + Bu + Ew, \\ y = C(x)x + v, \end{cases}$$
(1.403)

în care A(x), C(x), B, E – matrice. Acest observer optimal este o variantă simplificată a filtrului Kalman extins. Astfel, matricea de amplificare a observerului L(x) se calculează cu relația

$$L(x) = P(x)C^{T}(x)R^{-1}, \qquad (1.404)$$

în care P(x) este soluția ecuației Riccati [214]

$$P(x)A^{T}(x) + A(x)P(x) - P(x)C^{T}(x)R^{-1}C(x)P(x) + EQE^{T} = 0.$$
 (1.405)

Observerul de stare optimal este construit pe baza ecuațiilor

$$\begin{cases} \dot{\hat{x}} = A(\hat{x})\hat{x} + L(\hat{x})(y - C\hat{x}) + Bu, \\ \hat{y} = C\hat{x}. \end{cases}$$
(1.406)

După determinarea matricei de amplificare L a observerului, se verifică dacă aceasta conduce la stabilitatea matricei  $(A - LC) = (A - PC^T R^{-1}C)$ ; acest lucru este obligatoriu întrucât dinamica observerului este [214]

$$\dot{e} = \dot{x} - \dot{\hat{x}} = (A - LC)e.$$
 (1.407)

O altă variantă presupune liniarizarea ecuației (1.403) pentru a fi apoi folosit filtrul Kalman extins; dar, cu această metodă, stabilitatea globală nu este garantată

[214]. Pe de altă parte, performanțele observerului depind de alegerea matricelor Q și R. Matricea R poate fi obținută scriind acest sistem într-o formă discretă și utilizând apoi reprezentările în joasă și înaltă frecvență.

## **1.8. PROIECTAREA OBSERVERELOR ADAPTIVE**

## 1.8.1. PROIECTAREA OBSERVERELOR ADAPTIVE ROBUSTE PENTRU SISTEMELE NELINIARE UTILIZÂND NORMA $H_{\infty}$

Observerele adaptive existente pot fi caracterizate de erori chiar și în condițiile în care erorile de estimare rămân mici. Acest lucru se datorează perturbațiilor exterioare și poate fi evitat prin utilizarea observerelor adaptive robuste. Observerul care este prezentat în continuare are drept condiție de stabilitate o inegalitate liniară, iar amplificarea observerului se alege prin rezolvarea uni probleme optimale convexe [124].

Un observer adaptiv este atât un estimator de stare cât și un mijloc de identificare a parametrilor. În aceste 2 scopuri, observerul adaptiv foloseste fie un algoritm de identificare a parametrilor, fie algoritmi de estimare a stării. Algoritmii de identificare a parametrilor folosesc ieșirile sistemului și starea estimată. Există numeroase observere adaptive ce sunt utilizate în cazul sistemelor neliniare [7], [169], [172]. De exemplu, pentru proiectarea unui observer adaptiv pentru un sistem neliniar cu o intrare și o ieșire, sistemul inițial trebuie adus la forma canonică în condițiile mărginirii intrării și stării [7]. În cazul intrărilor multiple și a ieșirii unice, sistemul trebuie adus la forma canonică printr-o schimbare de coordonate [169], [172]. Alte observere adaptive pentru sistemele neliniare Lipschitz sunt formulate în [199] și [38]. Observerele proiectate și menționate mai sus pot însă să nu funcționeze corect în cazul unor perturbații mărginite. Aceste observere adaptive asigură convergența parametrilor către valorile lor dorite, însă, în cazul unor perturbații mici, arbitrare, parametrii pot avea deviații semnificative chiar dacă erorile de estimare rămân mici [101], [170]. Pentru a se evita acest lucru, au fost introduse câteva tehnici pentru modificarea structurii observerelor adaptive [64], [101], [170]. Dintre acestea se pot enumera: introducerea operatorilor de proiectare [64], [101], [170] sau introducerea unui termen de legătură în legea parametrică de adaptare, acesta din urmă făcând ca derivata în timp a unei funcții Lyapunov să rămână negativă atunci când un anumit parametru depășește limita sa normală [101], [230]. O altă metodă de identificare parametrică este metoda  $H_{\infty}$  ce folosește un filtru extern [133]. Se știe că o perturbație mică produce o eroare de estimare mică în cazul în care filtrul este proiectat astfel încât să fie minimizată norma  $H_{\infty}$  dintre perturbații și erorile de estimare.

Metoda ce este prezentată în continuare este asociată proiectării unui observer adaptiv pentru sistemele neliniare afectate de perturbații cu normă limitată [124]. Metoda de proiectare se bazează pe analiza stabilității Lyapunov și limitează norma  $H_{\infty}$  dintre perturbații și eroarea de estimare. Amplificarea observerului adaptiv este aleasă optimal prin rezolvarea problemei de minimizare a normei  $H_{\infty}$ , condiția de stabilitate fiind transformată într-o inegalitatea matriceală liniară [124].

Se consideră sistemul neliniar descris de ecuațiile de stare

$$\begin{cases} \dot{x} = Ax + \Phi(y, u) + b\beta(y, u)\theta + w, \\ y = Cx, \end{cases}$$
(1.408)

în care perechea de matrice (A, C) este observabilă,  $\theta$  este vectorul parametrilor necunoscuți, w – vectorul perturbațiilor, iar  $\Phi$  și  $\beta$  sunt funcții neliniare ce depind de intrare și ieșire.

Se proiectează observerul neliniar adaptiv descris de ecuația [124]

$$\dot{\hat{x}} = A\hat{x} + \Phi(y,u) + b\beta(y,u)\hat{\theta} + L(y - C\hat{x}),$$
 (1.409)

în care  $\hat{\theta}$  este vectorul parametrilor estimați, iar *L* - amplificarea observerului. Înlocuind *y=Cx* în ecuația (1.409) și apoi scăzând din prima ecuație (1.408) ecuația (1.409), rezultă

$$\dot{e} = (A - LC)e + b\beta(y, u)e_{\theta} + w, \qquad (1.410)$$

unde  $e = x - \hat{x}$  este eroarea de estimare a stării, iar  $e_{\theta} = \theta - \hat{\theta}$  este eroarea de estimare parametrică. Făcând abstracție de vectorul perturbațiilor *w*, eroarea *e* scade către zero

dacă există matricele simetrice și pozitiv definite P, Q și o matrice de amplificare L care să satisfacă ecuația [124]

$$(A - LC)^{T} P + P(A - LC) = -Q, \qquad (1.411)$$

 $Pb = C^T$ ; (A - LC) – matrice Hurwitz (matrice pătratică construită folosind coeficienții unui polinom, toți minorii asociați acestei matrice fiind pozitivi).

Pentru obținerea condițiilor de stabilitate a observerului adaptiv robust se utilizează teoria Lyapunov. Relația dintre w(t) și e(t) este [124]

$$w(t) = \Delta(t) C_d \ e(t), \tag{1.412}$$

unde  $\|\Delta(t)\|_2 \le 1, (\forall)t$ . Matricea de amplificare *L* se determină utilizând următoarea teoremă [124]:

#### <u>Teorema 4</u>

 $(\forall) \Delta(t)$  ce satisface ecuația (1.412), există matricea de amplificare *L* care stabilizează dinamica erorii (1.410) dacă există  $P = P^T > 0, S, \tau \ge 0$  astfel încât

$$\begin{bmatrix} A^T P + PA - C^T S - S^T C + \alpha P + \tau C_d^T C_d & P \\ P & -\tau I \end{bmatrix} \le 0;$$
(1.413)

 $\alpha$  este o constantă pozitivă aleasă arbitrar și  $Pb = C^T$ .

#### **Demonstrație**

Se consideră funcția Lyapunov [124]

$$V(e, e_{\theta}) = e^T P e + e_{\theta}^T \Gamma^{-1} e_{\theta} , \qquad (1.414)$$

unde  $P = P^T > 0$  și  $\Gamma = \Gamma^T > 0$ . Pentru stabilitate, derivata în timp a funcției Lyapunov trebuie să fie cel puțin negativă semi-definită  $(\dot{V}(e, e_{\theta}) \le 0);$ 

$$\dot{V} = \dot{e}^{T} P e + e^{T} P \dot{e} + \left( \dot{e}_{\theta}^{T} \Gamma^{-1} e_{\theta} + e_{\theta}^{T} \Gamma^{-1} \dot{e}_{\theta} \right) \Leftrightarrow$$

$$\Leftrightarrow \dot{V} = e^{T} \left( A - LC \right)^{T} P e + e_{\theta}^{T} \beta^{T} \varepsilon + e^{T} P \left( A - LC \right) e + e^{T} P b \beta e_{\theta} + w^{T} P e + e^{T} P w + \left( \dot{e}_{\theta}^{T} \Gamma^{-1} e_{\theta} + e_{\theta}^{T} \Gamma^{-1} \dot{e}_{\theta} \right) \Leftrightarrow$$

$$\Leftrightarrow \dot{V} = e^{T} \left( A - LC \right)^{T} P e + e^{T} P \left( A - LC \right) e + w^{T} P e + e^{T} P w + e_{\theta}^{T} \beta^{T} \varepsilon + \varepsilon^{T} \beta e_{\theta} + \left( \dot{e}_{\theta}^{T} \Gamma^{-1} e_{\theta} + e_{\theta}^{T} \Gamma^{-1} \dot{e}_{\theta} \right);$$

$$(1.415)$$

s-a făcut notația  $\varepsilon = Ce$  și s-a ținut cont de  $b^T P = b^T P^T = C$ , deoarece  $Pb = C^T$ .

Pentru actualizarea parametrică, se consideră următoarea lege adaptivă [124]

$$\dot{e}_{\theta} = -\Gamma \beta^{T} \varepsilon + \Gamma |\sigma|^{\hat{\theta}}; \qquad (1.416)$$

σ se alege astfel încât V > 0. Înlocuind ecuația (1.416) în (1.415),  $\dot{V}$  devine

$$\dot{V} = e^T (A - LC)^T P e + e^T P (A - LC) e + w^T P e + e^T P w + |\sigma| e_{\theta}^T \hat{\theta} + |\sigma| \hat{\theta}^T e_{\theta}, \quad (1.417)$$

deoarece  $|\sigma| = |\sigma|^{T}$ , întrucât  $\sigma$  este o constantă.

În continuare, se înlocuiește în ecuația (1.417)  $\hat{\theta} = \theta - e_{\theta}$  și, ținându-se cont de  $e_{\theta}^{T}\theta = \theta^{T}e_{\theta}$ , se obține relația [124]

$$\dot{V} = e^{T} (A - LC)^{T} P e + e^{T} P (A - LC) e + w^{T} P e + e^{T} P w + |\sigma| [e^{T}_{\theta} \theta - e^{T}_{\theta} e_{\theta} + \theta^{T} e_{\theta} - e^{T}_{\theta} e_{\theta}] \Leftrightarrow (1.418)$$
  
$$\dot{V} = e^{T} (A - LC)^{T} P e + e^{T} P (A - LC) e + w^{T} P e + e^{T} P w - 2|\sigma| (e^{T}_{\theta} e_{\theta} - e^{T}_{\theta} \theta).$$

Dacă se folosește inegalitatea [124]

$$2e_{\theta}^{T}\theta \le e_{\theta}^{T}e_{\theta} + \theta^{T}\theta, \qquad (1.419)$$

rezultă [124]

$$\dot{V} \le e^T (A - LC)^T P e + e^T P (A - LC) e + w^T P e + e^T P w - |\sigma| e_{\theta}^T e_{\theta} + |\sigma| \theta^T \theta; \quad (1.420)$$

în partea stângă a inegalității anterioare se adaugă și se scade  $\alpha V$ , unde  $\alpha > 0$ , și se obține

$$\dot{V} \leq -\alpha V + e^{T} (A - LC)^{T} P e + e^{T} P (A - LC) e + w^{T} P e + e^{T} P w - |\sigma| e_{\theta}^{T} e_{\theta} + |\sigma| \theta^{T} \theta + \alpha e^{T} P e + \alpha e_{\theta}^{T} \Gamma^{-1} e_{\theta}.$$
(1.421)

Considerând că  $V > \frac{|\sigma|\theta^T \theta}{\alpha} \Leftrightarrow -\alpha V + |\sigma|\theta^T \theta \le 0$ , derivata în timp a funcției

Lyapunov  $(\dot{V})$  este negativă dacă și numai dacă

$$e^{T}(A-LC)^{T}Pe+e^{T}P(A-LC)e+w^{T}Pe+e^{T}Pw-|\sigma|e_{\theta}^{T}e_{\theta}+\alpha e^{T}Pe+\alpha e_{\theta}^{T}\Gamma^{-1}e_{\theta}\leq 0.$$
(1.422)

Din ecuația (1.412), ținând cont de  $\|\Delta(t)\|_2 \le 1$ , se obține [124]

$$w \le C_d e, w^T \le e^T C_d^T \Leftrightarrow w^T w \le e^T C_d^T C_d e$$
(1.423)

sau

$$\tau \left( w^T w - e^T C_d^T C_d e \right) \le 0, \qquad (1.424)$$

în care  $\tau$  este o constantă pozitivă. Din ecuațiile (1.422) și (1.424), rezultă

$$e^{T} (A - LC)^{T} Pe + e^{T} P (A - LC)e + w^{T} Pe + e^{T} Pw + ae^{T} Pe - |\sigma|e_{\theta}^{T} e_{\theta} + \alpha e_{\theta}^{T} \Gamma^{-1} e_{\theta} - \tau (w^{T} w - e^{T} C_{d}^{T} C_{d} e) \le 0; \qquad (1.425)$$

constanta  $\tau$  se alege suficient de mare astfel încât

$$\left|\tau\left(w^{T}w-e^{T}C_{d}^{T}C_{d}e\right)\right| < \left|e^{T}\left(A-LC\right)^{T}Pe+e^{T}P\left(A-LC\right)e+w^{T}Pe+e^{T}Pw+\alpha e^{T}Pe-\left|\sigma\right|e_{\theta}^{T}e_{\theta}+\alpha e_{\theta}^{T}\Gamma^{-1}e_{\theta}\right|.$$
 (1.426)

Ecuația (1.425) se scrie sub forma matriceală

$$\begin{bmatrix} e \\ w \\ e_{\theta} \end{bmatrix}^{T} \begin{bmatrix} \Omega + \alpha P + \tau C_{d}^{T} C_{d} & P & 0 \\ P & -\tau I & 0 \\ 0 & 0 & - \left| \sigma \right| + \alpha \Gamma^{-1} \end{bmatrix} \begin{bmatrix} e \\ w \\ e_{\theta} \end{bmatrix} \leq 0, \qquad (1.427)$$

în care

$$\Omega = (A - LC)^T P + P(A - LC) = (A^T - C^T L^T)P + PA - PLC =$$
  
=  $A^T P - C^T \underbrace{L^T P}_{S} + PA - \underbrace{PLC}_{S^T} C \Leftrightarrow \Omega = A^T P + PA - C^T S - S^T C.$  (1.428)

Întrucât vectorul  $\begin{bmatrix} e & w & e_{\theta} \end{bmatrix}^{T}$  este oarecare, condiția (1.427) este echivalentă cu

$$\begin{bmatrix} \Omega + \alpha P + \tau C_d^T C_d & P & 0 \\ P & -\tau I & 0 \\ 0 & 0 & - |\sigma| + \alpha \Gamma^{-1} \end{bmatrix} \le 0$$
(1.429)

sau, ținând cont de (1.428), ecuația (1.429) capătă forma [124]

$$\begin{bmatrix} A^{T}P + PA - C^{T}S - S^{T}C + \alpha P + \tau C_{d}^{T}C_{d} & P & 0\\ P & -\tau I & 0\\ 0 & 0 & -|\sigma| + \alpha\Gamma^{-1} \end{bmatrix} \leq 0.$$
(1.430)

În cazul în care se alege  $|\sigma| \ge \alpha \Gamma^{-1}$ , rezultă  $-|\sigma|e_{\theta}^{T}e_{\theta} + \alpha e_{\theta}^{T}\Gamma^{-1}e_{\theta} \le 0$  și (1.425) devine

$$e^{T}(A - LC)^{T}Pe + e^{T}P(A - LC)e + w^{T}Pe + e^{T}Pw + \alpha e^{T}Pe - \tau(w^{T}w - e^{T}C_{d}^{T}C_{d}e) \le 0 \quad (1.431)$$

sau, sub formă matriceală,

$$\begin{bmatrix} e \\ w \end{bmatrix}^{T} \begin{bmatrix} \Omega + \alpha P + \tau C_{d}^{T} C_{d} & P \\ P & -\tau I \end{bmatrix} \begin{bmatrix} e \\ w \end{bmatrix} \le 0$$
(1.432)

echivalentă cu [124]

$$\begin{bmatrix} A^T P + PA - C^T S - S^T C + \alpha P + \tau C_d^T C_d & P \\ P & -\tau I \end{bmatrix} \le 0.$$
(1.433)

Condiția (1.433) asigură convergența către 0 a erorilor e și  $e_{\theta}$ ; deci, erorile estimării stării și estimării parametrice  $(e, e_{\theta})$  sunt foarte puțin afectate de eventualele perturbații exterioare. Din ecuația  $S = L^T P$  se determină matricea de amplificare L a observerului. Astfel,

$$SP^{-1} = L^T \Leftrightarrow L = \left(P^{-1}\right)^T S^T = P^{-1}S^T \Leftrightarrow L = P^{-1}S^T .$$
(1.434)

În cele ce urmează se prezintă modul în care se alege amplificarea observerului, considerându-se efectul perturbațiilor asupra erorilor de estimare e și  $e_{\theta}$ . O metodă ce poate fi utilizată este cea care folosește norma  $H_{\infty}$  (amplificare  $\mathcal{L}_2$ ). Această amplificare  $\mathcal{L}_2$  asociată perturbațiilor w și erorilor de estimare e și  $e_{\theta}$ , cu ponderile  $\delta_1$  și  $\delta_2$ , sunt definite prin intermediul constantei [124]

$$\gamma = \sup_{\|w\|_{2} \neq 0} \frac{\delta_{1} \|e\|_{2} + \delta_{2} \|e_{\theta}\|_{2}}{\|w\|_{2}}.$$
(1.435)

Prin definiția funcției supremum (sup) și a amplificării  $L_2$  (norma  $H_{\infty}$ ) [20], expresia

(1.435) devine

$$\int_{0}^{T} \left( \delta_{1} e^{T} e + \delta_{2} e_{\theta}^{T} e_{\theta} \right) \mathrm{d}t \leq \gamma^{2} \int_{0}^{T} w^{T} w \, \mathrm{d}t, (\forall) T \geq 0.$$
(1.436)

Se presupune că este valabilă următoarea inegalitate

$$\frac{\mathrm{d}}{\mathrm{d}t}V + \delta_1 e^T e + \delta_2 e_{\theta}^T e_{\theta} - \gamma^2 w^T w \le 0$$
(1.437)

 $(\forall)t, e, e_{\theta}$  și w ce satisfac ecuația (1.410). Prin integrarea ecuației (1.437) de la 0 la T și ținând cont de (1.426), se arată că norma  $\mathcal{L}_2$  este mai mică ca  $\gamma$  [20]. Ca și mai sus, ecuația (1.437) conduce la

$$\begin{bmatrix} \Omega + \alpha P + \tau C_d^T C_d + \delta_1 I & P & 0 \\ P & -\tau I - \gamma^2 I & 0 \\ 0 & 0 & - |\sigma| + \alpha \Gamma^{-1} + \delta_2 \end{bmatrix} \le 0, \qquad (1.438)$$

unde expresia lui  $\Omega$  este tot de tipul (1.428). Ecuația (1.438) este echivalentă, în cazul în care

$$-\left|\sigma\right| + \alpha \Gamma^{-1} + \delta_{2} \le 0 \Leftrightarrow \alpha \Gamma^{-1} + \delta_{2} \le \left|\sigma\right|, \qquad (1.439)$$

cu relația

$$\begin{bmatrix} \Omega + \alpha P + \tau C_d^T C_d + \delta_1 I & P \\ P & -\tau I - \gamma^2 I \end{bmatrix} \le 0.$$
 (1.440)

Amplificarea optimală a observerului adaptiv se calculează prin următorul corolar [124]: Pentru o valoare dată a lui  $\delta_1$  și o constantă pozitivă  $\alpha$ , pentru orice  $\Delta(t)$  ce satisface ecuația (1.412)  $(\forall)t$ , există o amplificare  $L = P^{-1}S^T$  ce stabilizează erorile din ecuația (1.410) și minimizează amplificarea  $\mathcal{L}_2$  (norma  $H_{\infty}$ ) dacă și numai dacă se rezolvă următoarea problemă de optimizare convexă: Se minimizează parametrul  $\delta = \gamma^2$  în raport cu  $P, \tau, \delta$  și S, unde  $P = P^T > 0, \tau \ge 0, \rho \ge 0, Pb = C^T$  și

$$\begin{bmatrix} \Omega + \alpha P + \tau C_d^T C_d + \delta_1 I & P \\ P & -(\tau + \rho)I \end{bmatrix} \le 0.$$
(1.441)

După determinarea matricei L, ecuația observerului neliniar (1.409) devine [124]

$$\dot{\hat{x}} = A\hat{x} + \Phi(y,u) + b\beta(y,u)\hat{\theta} + P^{-1}S^{T}(y - C\hat{x}).$$
(1.442)

Vectorul estimat al parametrilor necunoscuți  $\hat{\theta}$  se determină astfel [124]:

$$\hat{\theta} = \Gamma \beta^{T} (y, u) (y - C\hat{x}) + \Gamma |\sigma| (\overline{\theta} - \theta), \qquad (1.443)$$

unde  $|\sigma| \ge \alpha \Gamma^{-1} + \delta_2$ ,  $\Gamma = \Gamma^t > 0$ . *P* și *S* se determină rezolvând ecuația (1.441), iar  $\overline{\theta}$  este valoarea nominală a lui  $\theta$ .

## **1.8.2. PROIECTAREA OBSERVERELOR ADAPTIVE PENTRU** ESTIMAREA RAPIDĂ A DEFECTELOR

Defectarea senzorilor, actuatoarelor sau altor subsisteme modifică drastic funcționarea unui sistem, putându-se ajunge chiar și la instabilitate [245]. Pentru creșterea eficienței sistemelor se utilizează pe scară tot mai largă controlul defectelor (FTC), acesta presupunând detecția rapidă a defectelor și izolarea lor [6], [15], [34]. Detecția defectelor se poate face fie pasiv, utilizând un model de detecție și izolare a acestora, fie prin reconfigurarea sistemului pentru a păstra "partea sănătoasă" a acestuia. După detecția defectului, este nevoie de determinarea amplitudinii sale, iar, în final, este proiectat un controller pentru compensarea defectului [245]. În prezent, se acordă o atenție deosebită observerelor adaptive pentru detecția defectelor [10], [57], [111], [112], [234], [237].

În cele ce urmează, este prezentat un algoritm pentru estimarea rapidă a defectelor, acesta utilizând un observer adaptiv. Observerul a fost proiectat de către Zhang, Jiang şi Cocquempot [245] şi se bazează pe un algoritm nou de estimare a defectelor utilizând doar măsurarea vectorilor de intrare şi de ieşire ai sistemului; paşii algoritmului se bazează pe tehnica inegalităților matriceale (LMI) [245].

Se consideră cazul unui sistem liniar afectat de defectarea unui actuator; sistemul liniar este descris de ecuațiile de stare [245]

$$\begin{cases} \dot{x}(t) = Ax(t) + Bu(t) + Ef_a(t), \\ y(t) = Cx(t); \end{cases}$$
(1.444)

 $x(t) \in \mathcal{M}^{n \times 1}, u \in \mathcal{M}^{m \times 1}, y(t) \in \mathcal{M}^{p \times 1}$  și  $f_a(t) \in \mathcal{M}^{r \times 1}$  reprezintă defectul actuatorului. *A*, *B*, *C*, *E* sunt matrice constante cunoscute; *E* are rang de coloană maxim, iar perechea (*A*, *C*) este observabilă. Semnalul  $f_a(t)$  poate fi interpretat ca un semnal suplimentar,  $f_a(t) = \beta(t - t_f) \cdot f(t)$ , iar funcția  $\beta(t - t_f)$  are expresia [245]

$$\beta(t - t_f) = \begin{cases} 0, t \le t_f, \\ 1, t \ge t_f, \end{cases}$$
(1.445)

unde  $t_f$  este momentul în care apare defectul. Cu alte cuvinte, semnalul asociat defectului actuatorului se scrie

$$f_a(t) = \begin{cases} 0, t \le t_f, \\ f(t), t \ge t_f. \end{cases}$$
(1.446)

Se presupune că norma derivatei în timp a funcției f(t) este mărginită  $\Leftrightarrow \|\dot{f}(t)\| \le f_1$ ;  $0 \le f_1 < \infty$ . Observerul pentru estimarea defectului se construiește astfel [245]:

$$\begin{cases} \dot{\hat{x}}(t) = A\hat{x}(t) + Bu(t) + E\hat{f}(t) - L[\hat{y}(t) - y(t)], \\ \hat{y}(t) = C\hat{x}(t), \end{cases}$$
(1.447)

unde  $\hat{x}(t)$  este vectorul de stare estimat,  $\hat{y}(t) \in \mathcal{M}^{p \times 1}$  – vectorul de ieşire estimat (ieşirea observerului),  $\hat{f}(t) \in \mathcal{M}^{r \times 1}$  – estimarea semnalului asociat defectului. Dacă perecehea (A, C) este observabilă, matricea L din ecuația (1.447) se alege astfel încât matricea (A-LC) să fie stabilă [245]. Se fac notațiile

$$e_x(t) = \hat{x}(t) - x(t), e_y(t) = \hat{y}(t) - y(t), e_f(t) = \hat{f}(t) - f(t)$$
(1.448)

și, cu acestea, utilizând ecuațiile (1.444) și (1.447), rezultă [245]

$$e_{y}(t) = Ce_{x}(t), \qquad (1.449)$$

$$\dot{e}_x(t) = (A - LC)e_x(t) + Ee_f(t).$$
 (1.450)

Dacă defectul se consideră constant  $\Rightarrow \dot{f}(t) = 0 \Rightarrow \dot{e}_f(t) = \dot{f}(t)$ . În continuare, pentru proiectarea observerului, se utilizează următoarea teoremă [111], [112], [234]:

#### <u>Teorema 5</u>

Considerându-se matricele simetrice și pozitiv definite  $P, Q \in \mathcal{M}^{n \times n}$ , matricea de amplificare L a observerului și o matrice  $F \in \mathcal{M}^{n \times p}$  astfel încât să fie valabile relațiile

$$P(A - LC) + (A - LC)^{T} P = -Q, E^{T} P = FC, \qquad (1.451)$$

atunci

$$\hat{f}(t) = -\Gamma F e_{v}(t) \tag{1.452}$$

și algoritmul de estimare adaptivă a defectului este convergent ( $\lim_{t \to \infty} e_x(t) = 0$  și  $\lim_{t \to \infty} e_f(t) = \lim_{t \to \infty} e_y(t) = 0$ ); în ecuația (1.452),  $\Gamma$  se numește rata de învățare și este o matrice simetrică si pozitiv definită.

Semnalul eroare estimat  $\hat{f}(t)$  se obține ușor din (1.452) prin integrare [245]

$$\hat{f}(t) = -\Gamma \cdot F \int_{t_f}^{t} e_y(\tau) d\tau. \qquad (1.453)$$

Pentru obținerea relației (1.453) s-a presupus că defectul este constant. În acest caz estimarea sa se face ușor; există însă cazuri când defectul nu este constant și, de aceea, algoritmul adaptiv de mai sus trebuie îmbunătățit. Pentru prezentarea algoritmului [245] se fac presupunerile: rang(CE) = r și (A, E, C) nu prezintă zerouri invariante; de asemenea, se utilizează și două leme:

#### <u>Lema 2</u>

Considerând o constantă pozitivă  $\mu$  și o matrice simetrică și pozitiv definită P,

este valabilă următoarea inegalitate [112]:

$$2x^{T} y \leq \frac{1}{\mu} x^{T} P x + \mu y^{T} P^{-1} y ; x, y \in \mathcal{M}^{n \times 1}.$$
(1.454)

## <u>Lema 3</u>

Cele două presupuneri făcute (rang(CE) = r și (A, E, C) nu prezintă zerouri invariante) sunt echivalente cu existența relațiilor (1.451) [47], [54].

Deoarece funcția asociată defectului nu mai este constantă  $(\dot{f}(t) \neq 0)$ , rezultă

$$\dot{e}_f(t) = \dot{f}(t) - \dot{f}(t).$$
 (1.455)

În cazul defectului variabil  $(\dot{f}(t) \neq 0)$ , în proiectarea observerului adaptiv Zhang, Jiang și Cocquempot au folosit următoarea teoremă [245]

#### Teorema 6

Dacă sunt valabile cele două presupuneri făcute, considerându-se în plus constantele pozitive  $\sigma, \mu > 0$ , dacă există matricele simetrice și pozitiv definite  $P \in \mathcal{M}^{n \times n}, G \in \mathcal{M}^{r \times r}$  și matricea  $F \in \mathcal{M}^{n \times p}$  astfel încât

$$\begin{cases} E^{T}P = FC, \\ \begin{bmatrix} PA + A^{T}P - PLC - (PLC)^{T} & -\frac{1}{\sigma} \left( A^{T}PE - (PLC)^{T}E \right) \\ \left( -\frac{1}{\sigma} \left( A^{T}PE - (PLC)^{T}E \right) \right)^{T} & -\frac{2}{\sigma} E^{T}PE + \frac{1}{\sigma\mu}G \end{bmatrix} < 0, \end{cases}$$
(1.456)

funcția asociată defectului se calculează astfel:

$$\dot{\hat{f}}(t) = -\Gamma F\left[\dot{e}_{y}(t) + \sigma e_{y}(t)\right]$$
(1.457)

și sistemul este convergent  $(e_x(t) \rightarrow 0, e_f(t) \rightarrow 0)$ .

#### <u>Demonstrație</u>

Se consideră funcția Lyapunov [245]

$$V(t) = e_x^T(t) P e_x(t) + \frac{1}{\sigma} e_f^T(t) \Gamma^{-1} e_f(t)$$
(1.458)

și se calculează  $\dot{V}(t)$ ; se obține [245]

$$\dot{V}(t) = \dot{e}_{x}^{T}(t)Pe_{x}(t) + e_{x}^{T}(t)P\dot{e}_{x}(t) + \frac{2}{\sigma}e_{f}^{T}(t)\Gamma^{-1}\dot{e}_{f}(t) \Leftrightarrow$$
  
$$\dot{V}(t) = e_{x}^{T}(t)\left[P(A - LC) + (A - LC)^{T}P\right]e_{x}(t) + 2e_{x}^{T}(t)PEe_{f}(t) - (1.459) - \frac{2}{\sigma}e_{f}^{T}(t)\left[\dot{e}_{y}(t) + \sigma e_{y}(t)\right] - \frac{2}{\sigma}e_{f}^{T}(t)\Gamma^{-1}\dot{f}(t).$$

Pentru obținerea relației anterioare s-a avut în vedere ecuația

$$e_{f}^{T}(t)E^{T}Pe_{x}(t) = \left[e_{f}^{T}(t)E^{T}Pe_{x}(t)\right]^{T} = e_{x}^{T}(t)PEe_{f}(t).$$
(1.460)

Dar [245],

$$-\frac{2}{\sigma}e_{f}^{T}(t)F[\dot{e}_{y}(t) + \sigma e_{y}(t)]^{(2.449)} = -\frac{2}{\sigma}e_{f}^{T}(t)\underbrace{FC}_{E^{T}P}[\dot{e}_{x}(t) + \sigma e_{x}(t)]^{(2.451)} = -\frac{2}{\sigma}e_{f}^{T}(t)E^{T}P[\dot{e}_{x}(t) + \sigma e_{x}(t)](1.461)$$

și înlocuind în ecuația (1.459)

$$\dot{e}_{y}(t) = C\dot{e}_{x}(t) = C[(A - LC)e_{x}(t) + Ee_{x}(t)]$$
(1.462)

și ținând cont și de ecuația (1.461), expresia lui  $\dot{V}(t)$  (formula (1.459)) devine [245]

$$\dot{V}(t) = e_x^T(t) \Big[ P(A - LC) + (A - LC)^T P \Big] e_x(t) - \frac{2}{\sigma} e_f^T(t) E^T P(A - LC) e_x(t) - \frac{2}{\sigma} e_f^T(t) E^T P E e_f(t) - \frac{2}{\sigma} e_f^T(t) \Gamma^{-1} \dot{f}(t).$$
(1.463)

Se aplică în continuare proprietatea din lema 2, înlocuind x cu  $e_f(t)$  și y cu  $\Gamma^{-1}\dot{f}(t)$ ; astfel, pentru o matrice G > 0, rezultă

$$-\frac{2}{\sigma}e_{f}^{T}(t)\Gamma^{-1}\dot{f}(t) \leq \frac{1}{\sigma\mu}e_{f}^{T}(t)Ge_{f}(t) + \frac{\mu}{\sigma}\dot{f}^{T}(t)\Gamma^{-1}G^{-1}\Gamma^{-1}\dot{f}(t) \leq$$

$$\leq \frac{1}{\sigma\mu}e_{f}^{T}(t)Ge_{f}(t) + \frac{\mu}{\sigma}f_{1}^{2}\lambda_{\max}\left(\Gamma^{-1}G^{-1}\Gamma^{-1}\right).$$
(1.464)

Înlocuind (1.464) în (1.463), se obține [245]

$$\dot{V}(t) \leq e_{x}^{T}(t) \Big[ P(A - LC) + (A - LC)^{T} P \Big] e_{x}(t) - \frac{2}{\sigma} e_{f}^{T}(t) E^{T} P(A - LC) e_{x}(t) - \frac{2}{\sigma} e_{f}^{T}(t) E^{T} P E e_{f}(t) + \frac{1}{\sigma \mu} e_{f}^{T}(t) G e_{f}(t) + \frac{\mu}{\sigma} f_{1}^{2} \lambda_{\max} \left( \Gamma^{-1} G^{-1} \Gamma^{-1} \right)$$
(1.465)

sau

$$\dot{V}(t) \le \xi^{T}(t) \Phi \xi(t) + \eta, \qquad (1.466)$$

unde

$$\xi(t) = \begin{bmatrix} e_x(t) \\ e_f(t) \end{bmatrix}, \eta = \frac{\mu}{\sigma} f_1^2 \lambda_{\max} (\Gamma^{-1} G^{-1} \Gamma^{-1}), \\ \Phi = \begin{bmatrix} P(A - LC) + (A - LC)^T P & -\frac{1}{\sigma} (A - LC)^T PE \\ (-\frac{1}{\sigma} (A - LC)^T PE)^T & -\frac{2}{\sigma} E^T PE + \frac{1}{\sigma \mu} G \end{bmatrix}.$$
(1.467)

Deoarece *E* are rang de coloană maxim, când  $\Phi < 0 \Rightarrow \dot{V}(t) < \varepsilon \|\xi\|^2 + \eta$ , unde  $\varepsilon = \lambda_{\min}(-\Phi)$ ; rezultă  $\dot{V}(t) < 0$  pentru  $\eta < \varepsilon \|\xi\|^2$ . Așadar, inegalitatea (1.466) este echivalentă cu inegalitatea matriceală (1.456) sau cu LMI

$$\begin{bmatrix} P(A-LC) + (A-LC)^T P & -\frac{1}{\sigma} (A-LC)^T PE \\ \left(-\frac{1}{\sigma} (A-LC)^T PE\right)^T & -\frac{2}{\sigma} E^T PE + \frac{1}{\sigma\mu} G \end{bmatrix} < 0.$$
(1.468)

Aceasta, împreună cu prima ecuație (1.456), asigură convergența la zero a erorilor  $e_x(t)$  și  $e_f(t)$  [245]. Algoritmul prezentat este valabil nu doar în cazul defectului variabil ci și a unui defect constant. În acest caz,  $\dot{f}(t) = 0 \Leftrightarrow f_1 = 0$  și (1.466) devine

$$\dot{V}(t) \le \xi^{T}(t) \Phi \xi(t); \qquad (1.469)$$

este, deci, din nou nevoie ca  $\Phi < 0$ . Estimarea semnalului eroare f(t) în cazul unui

defect constant se face cu ecuația (1.453);  $\hat{f}(t)$  presupune un singur termen – termen integral. În cazul în care defectul nu este constant, observerul adaptiv de estimare a defectului actuatorului are un termen proporțional și unul integral [245]

$$\hat{f}(t) = -\Gamma F\left[e_{y}(t) + \sigma \int_{t_{f}}^{t} e_{y}(\tau) d\tau\right].$$
(1.470)

Introducerea termenului proporțional joacă un rol important în creșterea vitezei de estimare a defectului.

Algoritmul anterior [245] estimează, prin intermediul unui observer adaptiv, defectul asociat unui actuator; metoda poate fi însă extinsă și la cazul defectării unui senzor. În acest caz, ecuațiile de stare sunt

$$\begin{cases} \dot{x}(t) = Ax(t) + Bu(t), \\ y(t) = Cx(t) + Df_s(t); \end{cases}$$
(1.471)

 $x(t) \in \mathcal{M}^{n \times 1}, u \in \mathcal{M}^{m \times 1}, y(t) \in \mathcal{M}^{p \times 1}$  și  $f_s(t) \in \mathcal{M}^{r \times 1}$  reprezintă semnalul asociat defectării unui senzor. Matricele *A*, *B*, *C*, *D* sunt matrice constante cunoscute, iar matricea *D* are rang de coloană maxim; și de această dată perechea (*A*, *C*) este observabilă.

Se construiește un sistem îmbunătățit [54]; astfel, se consideră o nouă stare  $x_s(t) \in \mathcal{M}^{p \times 1}$  care este o versiune filtrată a ieșirii y(t)

$$\dot{x}_{s}(t) = -\widetilde{A}x_{s}(t) + \widetilde{A}Cx(t) + \widetilde{A}Df_{s}(t), \qquad (1.472)$$

unde  $\widetilde{A}$  este o matrice stabilă. Se face notația [245]

$$\bar{x}(t) = \begin{bmatrix} x(t) \\ x_s(t) \end{bmatrix}$$
(1.473)

și ecuațiile de stare ale noului sistem devin

$$\begin{cases} \bar{x}(t) = \overline{A}\bar{x}(t) + \overline{B}u(t) + \overline{D}f_s(t), \\ \bar{y}(t) = \overline{C}\bar{x}(t), \end{cases}$$
(1.474)

în care

$$\overline{A} = \begin{bmatrix} A & 0\\ \widetilde{A}C & -\widetilde{A} \end{bmatrix}, \overline{B} = \begin{bmatrix} B\\ 0 \end{bmatrix}, \overline{D} = \begin{bmatrix} 0\\ \widetilde{A}D \end{bmatrix}, \overline{C} = \begin{bmatrix} 0 & I_p \end{bmatrix}.$$
(1.475)

Sunt și aici valabile presupunerile anterioare și cele două leme utilizate. Astfel, considerând scalarii  $\sigma, \mu > 0$ , dacă există matricele pozitiv definite  $\overline{P} \in \mathcal{M}^{(n+p)\times(n+p)}$ ,  $\overline{G} \in \mathcal{M}^{r\times r}$  și matricea  $\overline{F} \in \mathcal{M}^{r\times p}$  astfel încât [245]

$$\begin{cases} \overline{D}^{T}\overline{P} = \overline{FC}, \\ \left[\overline{PA} + \overline{A}^{T}\overline{P} - \overline{PLC} - (\overline{PLC})^{T} & -\frac{1}{\sigma}\left(\overline{A}^{T}\overline{PD} - (\overline{PLC})^{T}\overline{D}\right) \\ \left(-\frac{1}{\sigma}\left(\overline{A}^{T}\overline{PD} - (\overline{PLC})^{T}\overline{D}\right)\right)^{T} & -\frac{2}{\sigma}\overline{D}^{T}\overline{PD} + \frac{1}{\sigma\mu}\overline{G} \end{cases} < 0,$$
(1.476)

semnalul asociat senzorului defect se estimează astfel

$$\dot{\hat{f}}(t) = -\Gamma \,\overline{F} \left[ \dot{\overline{e}}_{y}(t) + \sigma \overline{e}_{y}(t) \right] \tag{1.477}$$

si  $\overline{e}_x(t) \to 0, \overline{e}_f(t) \to 0.$ 

## **1.8.3. OBSERVER ADAPTIV PENTRU SISTEMELE MIMO** VARIABILE ÎN TIMP

În cele ce urmează este prezentat un nou algoritm de proiectare a observerelor adaptive pentru sistemele MIMO (multi input - multi output), liniar variabile în timp (LTV). Potențialele aplicații ale observerelor adaptive sunt identificarea sistemelor continue în timp, detecția și izolarea defectelor și controlul adaptiv.

Estimarea stării pentru sistemele liniare prezintă soluții viabile prin intermediul observerelor și a filtrului Kalman. Și estimarea stării în cazul parametrilor necunoscuți se face prin intermediul bine-cunoscutelor observere adaptive [7], [11], [137], [171]. Toate aceste lucrări privesc observerele adaptive pentru sistemele SISO (single input - single output); generalizarea algoritmilor obținuți pentru cazurile MIMO este dificil de făcut. Algoritmul prezentat în continuare este un algoritm pentru estimarea sistemelor

MIMO, liniare și variabile în timp [246]; algoritmul este simplu, eficient din punct de vedere computațional, deci este viabil și ușor de implementat software.

Se consideră sistemul descris de ecuațiile de stare [246]

$$\begin{cases} \dot{x}(t) = A(t)x(t) + B(t)u(t) + \psi(t)\Theta, \\ y(t) = C(t)x(t), \end{cases}$$
(1.478)

unde  $x(t) \in \mathcal{M}^{n \times 1}, u(t) \in \mathcal{M}^{t \times 1}, y(t) \in \mathcal{M}^{m \times 1}, A, B, C$  – matrice cunoscute dar variabile în timp,  $\theta \in \mathcal{M}^{p \times 1}$  – vectorul parametrilor necunoscuți considerat constant,  $\psi(t) \in \mathcal{M}^{n \times p}$  – matricea vectorului parametrilor necunoscuți. Scopul algoritmului este estimarea vectorilor x(t) și  $\theta$ , măsurând y(t) și considerând că intrarea sistemului este vectorul măsurabil u(t).

Atât timp cât matricele *A*, *B*, *C* din ecuația (1.478) nu sunt constante, estimarea cu ajutorul filtrului Kalman este dificilă sau poate chiar imposibilă. O idee ar fi obținerea unui sistem extins prin înglobarea vectorului  $\theta$  în cadrul vectorului de stare x(t). Sistemul ar rămâne variabil în timp, pentru estimarea noului vector de stare fiind nevoie de observabilitatea și uniformitatea sistemului [107]. Acesta este motivul pentru care utilizarea filtrului Kalman la sistemele extinse nu este o problemă simplă [246].

Proiectarea unui observer adaptiv pentru sistemele MIMO rezidă din necesitatea identificării on-line a sistemului, scopul principal fiind în acest caz estimarea vectorului parametrilor necunoscuți. Pentru sistemul descris de ecuațiile (1.478) este de dorit ca componentele vectorului parametrilor necunoscuți să fie coeficienții în cadrul unor semnale măsurabile. Această condiție nu este restrictivă pentru că există unele transformări pentru aducerea sistemului la forma dorită. De exemplu, pentru sistemele SISO [246]

$$y^{(n)} = a_1 y^{(n-1)} + a_2 y^{(n-2)} + \dots + a_n y + b_1 u^{(n-1)} + b_2 u^{(n-2)} + \dots + b_n u$$
(1.479)

cu vectorul parametrilor necunoscuți  $\theta = [a_1 \ a_2 \ \cdots \ a_n \ b_1 \ b_2 \ \cdots \ b_n]^T$ .

Sistemul (1.478) poate fi scris sub forma [11]
$$\begin{cases} \dot{x} = \begin{bmatrix} 0 & 1 & \cdots & 0 \\ \vdots & \vdots & \vdots & \vdots \\ 0 & 0 & \cdots & 1 \\ 0 & 0 & \cdots & 0 \end{bmatrix} x + \begin{bmatrix} y & 0 & \cdots & 0 & u & 0 & \cdots & 0 \\ 0 & y & \cdots & 0 & 0 & u & \cdots & 0 \\ \vdots & \vdots \\ 0 & 0 & \cdots & y & 0 & 0 & \cdots & u \end{bmatrix} \theta,$$
(1.480)  
$$y = \begin{bmatrix} 1 & 0 & \cdots & 0 \end{bmatrix} x.$$

O altă utilizare a observerelor adaptive o reprezintă controlul adaptiv. Datorită posibilității de estimare on-line a parametrilor și a vectorului de stare, observerele adaptive pot fi integrate în controllere. O altă utilizare o constituie detecția și izolarea defectelor (FDI). Defectele sunt modelate ca modificări ale parametrilor. Observerele adaptive pentru sistemele liniare au fost studiate încă din 1970 [246]. În [156] un estimator de stare a fost propus, acesta utilizând un algoritm adaptiv ce presupune integrarea ecuației erorii de estimare a stării. Câțiva ani mai târziu, alte observere adaptive cu convergență exponențială au fost propuse [137]; ele se bazau pe minimizarea unui criteriu de performanță. Observerele adaptive de ultimă generație se bazează pe o transformare dinamică, aducând sistemul original la o formă canonică [7], [11], [171].

Sistemele cu o singură ieșire, după transformare, au forma [246]

$$\begin{cases} \dot{z}(t) = A_0 z(t) + B u + \gamma \xi^T(t) \theta, \\ y(t) = c_0 z(t), \end{cases}$$
(1.481)

unde matricea  $A_0$  și vectorul  $c_0$  au o formă specială,  $\gamma \in \mathcal{M}^{n \times 1}$  – vector coloană (vector constant),  $\xi(t) \in \mathcal{M}^{p \times 1}$  – vector al semnalelor ce se obține prin filtrarea semnalelor u(t) și y(t). Vectorul parametrilor necunoscuți  $\theta$  "afectează" ecuația de stare prin produsul scalar  $\xi^T(t)\theta$  și vectorul coloană  $\gamma$ .

Principalul element de noutate al algoritmului prezentat în continuare este însăși proiectarea observerului pentru sistemele liniar variabile în timp de tip MIMO. Algoritmul Zhang [246], până în 2001, a fost doar al doilea algoritm ce estimează starea și vectorul parametrilor necunoscuți pentru sistemele MIMO și LTV. Primul a fost cel al lui Besancon [11], însă cel al lui Zhang se caracterizează printr-o mai bună

convergență și simplitatea. De asemenea, Zhang a reușit corelația, printr-o formulă de tip "unificare", a mai multor observere adaptive bazate pe transformări dinamice [246].

Pentru proiectarea observerului Zhang, prima ecuație (1.478) se scrie

$$\dot{x}(t) = [A(t) - K(t)C(t)]x(t) + B(t)u(t) + K(t)y(t) + \psi(t)\Theta, \qquad (1.482)$$

unde K(t) este matricea de amplificare a observerului. Vectorul de stare x(t) este influențat de 2 "excitații exogene" B(t)u(t) + K(t)y(t) și  $\psi(t)\theta$ . Se împarte x(t) în două părți  $x_u(t)$  și  $x_{\theta}(t)$  [246] astfel:

$$x(t) = x_u(t) + x_{\theta}(t),$$
 (1.483)

cu

$$\begin{cases} \dot{x}_{u}(t) = [A(t) - K(t)C(t)]x_{u}(t) + B(t)u(t) + K(t)y(t), \\ \dot{x}_{\theta}(t) = [A(t) - K(t)C(t)]x_{\theta}(t) + \psi(t)\theta; \end{cases}$$
(1.484)

 $x_u(t)$  se estimează cu ajutorul observerului [246]

$$\dot{\hat{x}}_{u}(t) = \left[A(t) - K(t)C(t)\right]\hat{x}_{u}(t) + B(t)u(t) + K(t)y(t), \qquad (1.485)$$

iar  $x_{\theta}(t)$  se estimează cu estimatorul de stare

$$\dot{\hat{x}}_{\theta}(t) = \left[A(t) - K(t)C(t)\right]\hat{x}_{\theta}(t) + \psi(t)\hat{\theta} + \omega(t), \qquad (1.486)$$

unde  $\hat{\theta}(t)$  este estimarea lui  $\theta$ , iar rolul și semnificația lui  $\omega(t)$  se vor prezenta mai târziu în cadrul demonstrației.

Se presupune că între  $\hat{\theta}(t)$  și  $\hat{x}_{\theta}(t)$  există relația de legătură [246]

$$\hat{x}_{\theta}(t) = \Gamma(t)\hat{\theta}(t), \qquad (1.487)$$

unde  $\Gamma(t) \in \mathcal{M}^{n \times p}$ . Din ecuațiile (1.486) și (1.487) rezultă

.

$$\dot{\Gamma}(t)\hat{\theta}(t) + \Gamma(t)\hat{\theta}(t) = \left[A(t) - K(t)C(t)\right]\Gamma(t)\hat{\theta}(t) + \psi(t)\hat{\theta}(t) + \omega(t).$$
(1.488)

Dacă se consideră [246]:  $\omega(t) = \Gamma(t)\hat{\theta}(t)$ , ecuația (1.488) devine

$$\dot{\Gamma}(t) = \left[A(t) - K(t)C(t)\right]\Gamma(t) + \psi(t); \qquad (1.489)$$

 $\psi(t)$  este matrice cunoscută, deci, prin integrarea ecuației (1.489), se determină  $\Gamma(t)$ .

Vectorul de stare estimat va fi

$$\hat{x}(t) = \hat{x}_u(t) + \hat{x}_{\theta}(t)$$
 (1.490)

și, conform ecuațiilor (1.485) și (1.486), rezultă [246]

$$\dot{\hat{x}}(t) = \left[A(t) - K(t)C(t)\right]\hat{x}(t) + B(t)u(t) + K(t)y(t) + \psi(t)\hat{\theta}(t) + \Gamma(t)\hat{\theta}(t).$$
(1.491)

Se va demonstra în continuare că pentru orice vector al parametrilor  $\theta$ , un observer exponențial poate fi proiectat pentru estimarea stării x(t) a sistemului (1.478); așadar, rezultă un observer adaptiv pentru estimarea simultană a vectorilor x(t) și  $\theta$ .

Se lucrează în următoarele 2 ipoteze (presupuneri):

#### *Ipoteza 1* [246]

Se presupune că perechea de matrice (A(t), C(t)) este de așa natură încât, pentru  $K(t) \in \mathcal{M}^{n \times m}$  – matrice variabilă în timp și mărginită, sistemul

$$\dot{\eta}(t) = [A(t) - K(t)C(t)]\eta(t)$$
(1.492)

este stabil.

### *Ipoteza 2* [246]

Fie  $\Gamma(t) \in \mathcal{M}^{n \times p}$  – matrice a semnalelor generate de ecuația diferențială (1.489). Presupunem că  $\psi(t)$  este permanent excitantă astfel încât există 2 constante pozitive  $\delta, T$  și o matrice simetrică și pozitiv definită  $\Sigma(t) \in \mathcal{M}^{m \times m}$  astfel încât  $(\forall) t$ , următoarea inegalitate este valabilă

$$\int_{t}^{t+T} \Gamma^{T}(\tau) C^{T}(t) \Sigma(t) C(t) \Gamma(\tau) \mathrm{d}\tau \geq \delta I. \qquad (1.493)$$

Ipoteza 1 precizează că, pentru orice vector al parametrilor  $\theta$ , un observer de stare poate fi proiectat pentru sistemul (1.478) utilizând matricea de amplificare K(t). Ipoteza 2 este o condiție de excitație permanentă și este necesară pentru estimarea celor doi vectori. Proiectarea observerului se bazează pe următoarea teoremă [246]:

## Teorema 7

Considerăm  $M \in \mathcal{M}^{p \times p}$  – orice matrice simetrică și pozitiv definită. Dacă sunt valabile ipotezele 1 și 2, pentru orice vector constant  $\theta$ , estimarea vectorului de stare x(t) și a vectorului parametrilor necunoscuți  $\theta$  se face cu ecuațiile [246]

$$\begin{cases} \dot{\hat{x}}(t) = A(t)\hat{x}(t) + B(t)u(t) + \psi(t)\hat{\theta}(t) + [K(t) + \Gamma(t)M\Gamma^{T}(t)C^{T}(t)\Sigma(t)][y(t) - C(t)\hat{x}(t)], \\ \dot{\hat{\theta}}(t) = M\Gamma^{T}(t)C^{T}(t)\Sigma(t)[y(t) - C\hat{x}(t)], \end{cases}$$
(1.494)

ecuații asociate unui observer adaptiv exponențial pentru sistemul (1.478); pentru orice condiții inițiale  $x(t_0), \hat{x}(t_0), \hat{\theta}(t_0)$  și  $(\forall)\theta \in \mathcal{M}^{p\times 1}$ , erorile  $\hat{x}(t) - x(t)$  și  $\hat{\theta}(t) - \theta(t)$  tind exponențial la zero când  $t \to \infty$ . Ecuațiile (1.494) conduc la ecuația (1.491).

Pentru a demonstra teorema se utilizează două leme:

### *Lema 4* [246]

Fie  $\Phi(t) \in \mathcal{M}^{m \times p}$  – matrice continuă și  $M \in \mathcal{M}^{p \times p}$  – matrice simetrică și pozitiv definită. Dacă există constantele pozitive  $T, \alpha, \beta$  astfel încât  $(\forall)t$  este valabilă inegalitatea

$$\alpha I \leq \int_{t}^{t+T} \Phi^{T}(\tau) \Phi(\tau) d\tau \leq \beta I, \qquad (1.495)$$

atunci sistemul

$$\dot{z}(t) = -M\Phi^{T}(t)\Phi(t)z(t)$$
(1.496)

este exponențial stabil.

#### *Lema 5* [246]

Dacă sistemul liniar și variabil în timp

$$\dot{\zeta}(t) = F(t)\zeta(t) \tag{1.497}$$

este exponențial stabil, u(t) – semnal mărginit și integrabil și  $\lim_{t\to\infty} u(t) = 0$ , atunci z(t) descris de ecuația

$$\dot{z}(t) = F(t)z(t) + u(t)$$
(1.498)

va converge la zero  $\lim_{t\to\infty} z(t) = 0$ .

Demonstrația celor două leme sunt prezentate pe larg în [246]. Pentru demonstrația teoremei 7, pentru început, se elimină  $M\Gamma^{T}(t)C^{T}(t)\Sigma(t)[y(t) - C\hat{x}(t)]$  între cele două ecuații (1.494) și se obține [246]

$$\dot{\hat{x}} = A\hat{x} + Bu + \psi\hat{\theta} + K(y - C\hat{x}) + \Gamma\hat{\theta}.$$
(1.499)

Fie

$$\widetilde{x} = \widehat{x} - x, \widetilde{\Theta} = \widehat{\theta} - \theta \tag{1.500}$$

și, ținând seama că  $\dot{\theta} = 0 \Leftrightarrow \dot{\widetilde{\theta}} = \dot{\hat{\theta}}$ , rezultă

$$\begin{cases} \dot{\hat{x}} = A\hat{x} + Bu + \psi\hat{\theta} + K(y - C\hat{x}) + \Gamma\dot{\hat{\theta}}, \\ \dot{x} = Ax + Bu + \psi\theta \end{cases}$$
(1.501)

sau, prin scăderea celor două ecuații de mai sus,

$$\dot{\widetilde{x}} = (A - KC)\widetilde{x} + \psi\widetilde{\theta} + \Gamma\widetilde{\theta}.$$
(1.502)

Se definește  $\eta(t)$  ca o combinație liniară a vectorilor eroare  $\tilde{x}(t)$  și  $\tilde{\theta}(t)$  [246]

$$\eta(t) = \widetilde{x}(t) - \Gamma(t)\widetilde{\Theta}(t). \tag{1.503}$$

Derivând ecuația (1.503) se obține

$$\dot{\eta} = (A - KC)\eta + \left[ (A - KC)\Gamma + \Psi - \dot{\Gamma} \right] \widetilde{\theta} .$$
(1.504)

Din ecuația (1.489) rezultă  $\dot{\Gamma} = (A - KC)\Gamma + \psi$  și ecuația (1.504) devine

$$\dot{\eta} = (A - KC)\eta. \tag{1.505}$$

Lucrând în ipoteza 1, sistemul (1.505) este stabil și convergent la zero  $(\lim_{t \to \infty} \eta(t) = 0)$ . În continuare se calculează  $\dot{\tilde{\theta}}$  [246]

$$\dot{\widetilde{\theta}} = \dot{\widetilde{\theta}} - \dot{\theta} = \dot{\widetilde{\theta}}^{(1.494)} M \Gamma^T C^T \Sigma (y - C\hat{x}) = -M \Gamma^T C^T \Sigma C \widetilde{x}^{(1.503)} = -M \Gamma^T C^T \Sigma C (\eta + \Gamma \widetilde{\theta}).$$
(1.506)

Aşadar, partea omogenă a sistemului (1.506) este

$$\tilde{\tilde{\boldsymbol{\theta}}} = -M\Gamma^T C^T \Sigma C \Gamma \tilde{\boldsymbol{\theta}}.$$
(1.507)

Dacă  $\psi$  - mărginită, iar  $\Gamma$  este generată de sistemul exponențial stabil (1.489), rezultă  $\Gamma$ - mărginită. Din condiția (1.493) a excitației permanente și din Lema 4, cu  $\Phi = \Sigma^{1/2}C\Gamma$ , rezultă că sistemul (1.507) este stabil [246]. S-a arătat că sistemul (1.507) este exponențial stabil și  $\lim_{t\to\infty} \eta(t) = 0$ ; rezultă, conform lemei 5, cu  $F = -M\Gamma^T C^T \Sigma C\Gamma$ ,  $\lim_{t\to\infty} \widetilde{\Theta}(t) = 0$ . Deoarece  $\eta \to 0, \widetilde{\Theta} \to 0$ , conform (1.503), rezultă  $\widetilde{x} \to 0$  [246].

Dacă condiția de excitație (ipoteza 2) nu este îndeplinită, algoritmul nu garantează că  $\tilde{\theta}(t) \rightarrow 0$  și  $\tilde{x}(t) \rightarrow 0$ . Se poate doar arăta că  $C(t)\tilde{x}(t) \rightarrow 0$  [248], adică convergența la zero doar a erorii de predicție  $C(t)\hat{x}(t) - y(t)$ . Matricea K(t) stabilizează procesul de estimare a stării;  $\Sigma(t)$  poate fi orice matrice mărginită și pozitiv definită, iar M poate fi orice matrice constantă și pozitiv definită. Alegerea celor două matrice influențează viteza de estimare a stării și a vectorului necunoscutelor  $\theta$  [246].

Teorema 7 de proiectare a observerului adaptiv presupune, în prealabil, calculul matricei K(t). În cazul sistemelor variabile în timp, acest lucru nu este ușor de realizat; se poate folosi metodologia de la filtrul Kalman pentru determinarea matricei K(t), însă anumite condiții trebuie respectate [246]. Astfel,

$$K(t) = P(t)C^{T}(t)R^{-1}(t), \qquad (1.508)$$

unde P(t) este soluția ecuației Riccati

$$\dot{P}(t) = A(t)P(t) + P(t)A^{T}(t) - P(t)C^{T}(t)R^{-1}(t)C(t)P(t) + Q(t), \qquad (1.509)$$

în care  $Q \in \mathcal{M}^{n \times n}$ ,  $R \in \mathcal{M}^{m \times m}$  sunt matrice simetrice și pozitiv definite.

O altă metodă de determinare a matricei K(t) ar putea fi tehnica poziționării polilor pentru a se obține o matrice (*A-KC*) stabilă [246]. Schema bloc a ansamblului sistem - observer adaptiv Zhang (Fig. 1.31) se construiește utilizând ecuațiile (1.478), (1.489), (1.494), (1.508) și (1.509).



Fig. 1.31. Schema bloc a ansamblului sistem - observer adaptiv Zhang

În cele ce urmează, se validează algoritmul Zhang de proiectare a observerelor adaptive pentru două cazuri concrete ale mișcărilor longitudinală, respectiv laterală ale aeronavelor.

Pentru început, se consideră mișcarea longitudinală a unei aeronave, descrisă de ecuația în variabile adimensionale [157]

$$\begin{bmatrix} \dot{\hat{V}} \\ \dot{\hat{\alpha}} \\ \dot{\hat{\theta}} \\ \dot{\hat{\omega}}_{y} \end{bmatrix} = \begin{bmatrix} -0.026 & 0.025 & -0.1 & 0 \\ -0.36 & -3 & 0 & 1 \\ 0 & 0 & 0 & 1 \\ 0.4212 & -38.49 & 0 & -3.67 \end{bmatrix} \begin{bmatrix} \hat{V} \\ \hat{\alpha} \\ \hat{\theta} \\ \hat{\omega}_{y} \end{bmatrix} + \begin{bmatrix} 0 \\ 0 \\ 0 \\ 1 \end{bmatrix} \delta_{p} , \qquad (1.510)$$

unde

$$\hat{V} = \frac{\Delta V}{V^*}, \hat{t} = \frac{t}{\tau_a}, \hat{\omega}_y = \frac{\overline{b}}{V^*} \omega_y, \hat{\theta} = \Delta \theta, \hat{\alpha} = \Delta \alpha; \qquad (1.511)$$

 $\tau_a = 2.1 \text{sec}$  - constanta de timp aerodinamică. Programul Matlab ce urmărește pas cu pas algoritmul Zhang (mișcarea longitudinală) este prezentat în anexa A1.7. Programul apelează modelul Matlab/Simulink *Zhang\_sch\_long* (Fig. 1.32) - model ce a fost construit pe baza schemei bloc din Fig. 1.31.



Fig. 1.32. Modelul Matlab/Simulink (Zhang sch long) asociat mişcării longitudinale

Ca mărime de intrare a sistemului (*u*) se poate considera un semnal de tip treaptă unitate, un semnal de tip sinusoidal sau orice alt semnal de tip aleator. În cadrul simulării s-a calculat, prin intermediul algoritmului ALGLX [157], matricea de amplificare a sistemului  $\overline{K}$  și s-a considerat ca vector de intrare  $u = \delta_p = -\overline{K}\hat{x}$ . Prin rularea programului se obțin caracteristicile grafice din Fig. 1.33 (dependențele de timp ale erorilor de estimare a vectorului de stare  $\tilde{x}_i, i = \overline{1,4}$ , variația în timp a erorii de estimare a vectorului parametrilor necunoscuți  $\tilde{\theta}$  și variația în timp a vectorului  $\theta$ ) și Fig. 1.34 (cele 4 componente ale vectorului de stare  $x_i$ ,  $i = \overline{1, 4}$  – cu linie continuă și cele 4 componente ale vectorului de stare estimat  $\hat{x}_i$ ,  $i = \overline{1, 4}$  – cu linie întreruptă).



Fig. 1.33. Erorile de estimare a stării și vectorului parametrilor necunoscuți (miscarea longitudinală)



Fig. 1.34. Variabile de stare  $(x_i)$  și variabilele de stare estimate  $(\hat{x}_i)$  - mișcarea longitudinală

După cum se poate observa, erorile de estimare a vectorului de stare și vectorului parametrilor necunoscuți tind către zero, iar graficele variabilelor de stare  $x_i$ ,  $i = \overline{1, 4}$  se suprapun peste graficele variabilelor de stare estimate  $\hat{x}_i$ ,  $i = \overline{1, 4}$ . Singurul inconvenient al algoritmului pare să fie valoarea ridicată a duratei regimului tranzitoriu. În realitate, procesul este mult mai rapid, în cadrul simulării alegerea matricelor M,  $\Sigma$ , Q și Rinfluențând mult caracteristicile dinamice ale sistemului. Algoritmul Zhang nu stabilește o modalitate de alegere a acestor matrice pentru o convergență cât mai rapidă, lucru care reprezintă un dezavantaj al metodei. Vectorul parametrilor necunoscuți are în acest caz o singură componentă și anume  $\theta=2$ . Matricea  $\overline{K}$  din legea de conducere  $u = \delta_p = -\overline{K}\hat{x}$  (notată cu KK în cadrul modelului Matlab/ Simulink) se determină prin rularea programului Matlab *prog1sec*.

În continuare, se studiază mișcarea laterală a unui avion Boeing 747 - ecuația (1.49). Programul Matlab ce urmărește pas cu pas algoritmul Zhang (mișcarea laterală) este similar celui din anexa A1.7. Programul apelează modelul Matlab/ Simulink Zhang\_sch\_lat - model similar celui din Fig. 1.32. În cadrul simulării s-a calculat, prin intermediul algoritmului ALGLX [157], matricea de amplificare a sistemului  $\overline{K}$  și s-a considerat ca vector de intrare  $u = [\delta_d \ \delta_e]^T = -\overline{K}\hat{x}$ . Matricea  $\overline{K}$  se determină prin rularea programului Matlab *prog3sec*.



Fig. 1.35. Erorile de estimare a stării și vectorului parametrilor necunoscuți (mișcarea laterală)

Rulând programul, se obțin caracteristicile grafice din Fig. 1.35 (dependențele de timp ale erorilor de estimare a vectorului de stare  $\tilde{x}_i, i = \overline{1, 4}$  și variația în timp a erorii de estimare a vectorului parametrilor necunoscuți  $\tilde{\theta}$ ) și Fig. 1.36 (cele 4 componente ale vectorului de stare  $x_i, i = \overline{1, 4}$  – cu linie continuă și cele 4 componente ale vectorului de stare estimat  $\hat{x}_i, i = \overline{1, 4}$  – cu linie întreruptă). Vectorul parametrilor necunoscuți are în acest caz 2 componente -  $\theta = \begin{bmatrix} 0.9 & 3 \end{bmatrix}^T$ .

Se pot face aceleași observații ca în cazul mișcării longitudinale cu privire la convergența estimatorului de stare adaptiv și viteza de convergentă a acestuia.



Fig. 1.36. Variabile de stare  $(x_i)$  și variabilele de stare estimate  $(\hat{x}_i)$  - mișcarea laterală

# **1.9. PROIECTAREA OBSERVERELOR ADAPTIVE BAZATE PE REȚELE NEURONALE**

## **1.9.1. NEURO-OBSERVER ADAPTIV PENTRU SISTEME NELINIARE**

În cele ce urmează se proiectează un observer pentru sistemele neliniare ce utilizează rețele neuronale (NN) [145]. Acesta va avea în componență o rețea neuronală de tip feed-forward, cu 3 straturi de neuroni, ce va fi antrenată cu algoritmul de propagare inversă a erorii utilizându-se un termen de corecție ce garantează buna antrenare a rețelei neuronale. Stabilitatea neuro-observerului obținut se analizează utilizându-se metoda directă a lui Lyapunov [145].

În multe cazuri, doar intrarea (intrările) și ieșirea (ieșirile) unui sistem sunt măsurabile și, de aceea, estimarea variabilelor de stare joacă un rol important în controlul procesului [66], [225]. În ultimii ani au fost propuse numeroase observere neliniare precum observerele cu amplificare mare (high-gain observer), "sliding mode observers" [1], [2], [105] etc.; acestea sunt însă complexe și pot fi utilizate pentru sisteme la care se cunoaște structura. Utilizarea NN în identificarea și controlul sistemelor dinamice este pe larg prezentată în articolele de specialitate [181], [175], [204]. Rezultatele bune pe care le au rețelele neuronale se datorează capacității lor de aproximare a funcțiilor neliniare [186], [190].

Majoritatea sistemelor sunt neliniare și este dificilă proiectarea unui controller sau observer. Până în prezent, tehnicile de liniarizare au fost folosite pentru depășirea acestor inconveniente. Liniarizarea limitează însă performanțele controllerului sau observerului proiectat; în astfel de cazuri se folosesc rețelele neuronale pentru aproximarea funcțiilor neliniare [145].

Pentru rețeaua neuronală a neuro-observerului (fig. 1.37) se alege o configurație feed-forward cu 3 straturi de neuroni (un singur strat ascuns). Fiecare neuron de intrare este conectat printr-o pondere cu fiecare neuron din stratul ascuns, iar fiecare neuron din stratul ascuns este conectat printr-o pondere cu neuronii de ieșire. Astfel, ieșirea neuronului j din stratul ascuns este [145]

$$a_j = \sigma(z_j) \tag{1.512}$$

cu

$$z_{j} = \sum_{i} v_{ji} x_{i} + \mu_{j}; \qquad (1.513)$$

 $v_{ji}$  este ponderea între intrarea *i* și neuronul *j* din stratul ascuns,  $\mu_j$  – biasul pentru neuronul *j* din stratul ascuns, iar  $\sigma(\cdot)$  este funcția de activare a neuronilor din stratul ascuns (funcția sigmoidală)



Fig. 1.37. Structura NN din cadrul neuro-observerului

Ieșirea neuronului k din stratul de ieșire este

$$y_k = \sum_j w_{kj} a_j;$$
 (1.515)

 $w_{ij}$  este ponderea între neuronul j din stratul ascuns și neuronul de ieșire k.

Dacă NN are *n* neuroni de intrare (pseudo-neuroni), *s* neuroni pe stratul ascuns și *m* neuroni de ieșire, ecuația asociată rețelei neuronale se poate scrie și sub formă matriceală considerând vectorul intrărilor  $x^T = [x_1 \ x_2 \ \cdots \ x_n]$ , vectorul ieșirilor  $y^T = [y_1 \ y_2 \ \cdots \ y_m]$  și matricele ponderilor și biasurilor  $W^T = [w_{kj}], V = [v_{ji}],$   $\mu = [\mu_1 \ \mu_2 \ \cdots \ \mu_s]$ . Vectorul biasurilor  $\mu$  poate fi inclus ca primă coloană în matricea *V*. Astfel,  $W \in \mathcal{M}^{s \times m}, V \in \mathcal{M}^{s \times n}$  și ieșirea *y* a NN are forma [145]

$$y = W^T \sigma(V^T x). \tag{1.516}$$

Există câțiva algoritmi pentru antrenarea NN; cel mai des utilizat este algoritmul de propagare inversă a erorii [69]. Antrenarea este astfel privită ca o problemă de optimizare a unei funcții neliniare. Se vor modifica permanent ponderile și biasul rețelei neuronale astfel încât să se minimizeze eroarea medie pătratică dintre ieșirea NN și ieșirea dorită a NN [175].

În cele ce urmează, se proiectează un neuro-observer pentru estimarea stării; în cadrul său, o rețea neuronală este folosită pentru estimarea funcției neliniare necunos-

(1.514)

cute. Se consideră sistemul [145]

$$\begin{cases} \dot{x}(t) = Ax(t) + g(x, u), \\ y(t) = Cx(t); \end{cases}$$
(1.517)

 $x(t) \in \mathcal{M}^{n \times 1}$  este vectorul de stare,  $u(t) \in \mathcal{M}^{m_u \times 1}$  – vectorul intrărilor,  $y(t) \in \mathcal{M}^{m_y \times 1}$  – vectorul ieșirilor, g(x, u) – funcție neliniară necunoscută. Matricea A este o matrice Hurwitz, iar perechea (A, C) trebuie să fie observabilă pentru a putea fi construit neuroobserverul. Se proiectează estimatorul de stare descris de ecuația [145]

$$\begin{cases} \dot{\hat{x}}(t) = A\hat{x}(t) + \hat{g}(\hat{x}, u) + L(y - \hat{y}), \\ \hat{y}(t) = C\hat{x}(t), \end{cases}$$
(1.518)

unde  $\hat{x}$  – starea observerului și  $\hat{y}$  – ieșirea observerului pentru sistemul neliniar. Matricea de amplificare *L* a observerului se alege astfel încât (*A*-*LC*) să fie matrice Hurwitz (stabilă). Schema bloc a neuro-observerului este cea din fig. 1.38 [145].



Fig. 1.38. Schema bloc a neuro-observerului

După cum se observă în fig. 1.38, o rețea neuronală este utilizată pentru estimarea funcției neliniare necunoscute g. Principala proprietate a NN, utilizată aici, este deci aproximarea funcțiilor [82].

Se consideră funcția  $\gamma(x): \mathbb{R}^n \to \mathbb{R}^m$ ; s-a arătat în [203] că pentru un număr suficient de neuroni din stratul ascuns (*s*) există ponderile și biasul astfel încât orice funcție continuă pe un set compact poate fi reprezentată astfel [225]:

$$\gamma(x) = W\sigma(Vx) + \varepsilon(x), \qquad (1.519)$$

unde  $\varepsilon(x)$  este eroarea de aproximare a funcției neliniare;  $\|\varepsilon(x)\| \le \varepsilon_N$ . Mai mult, pentru  $\varepsilon_N > 0$  se poate găsi o rețea neuronală astfel încât  $\|\varepsilon(x)\| \le \varepsilon_N$  ( $\forall$ )x [149], [203]. Se presupune că ponderile W și V sunt mărginite de valori cunoscute astfel încât  $\|W\| \le W_M$ și  $\|V\| \le V_M$  [132], [149]. În concluzie, funcția g(x, u), din prima ecuație (1.517), poate fi aproximată de o NN cu matricele ponderilor W și V [145]

$$g(x, u) = W\sigma(Vz) + \varepsilon(x), \qquad (1.520)$$

unde  $z = [x \ u]$  și  $\varepsilon(x) = g(x, u) - \hat{g}(\hat{x}, u)$ . Estimata  $\hat{g}(\hat{x}, u)$  a funcției g(x, u) se scrie

$$\hat{g}(\hat{x},u) = \hat{W}\sigma(\hat{V}\hat{z}), \qquad (1.521)$$

unde  $\hat{z} = [\hat{x} \ u]$ .

Aşadar, ecuațiile neuro-observerului (1.518) devin

$$\begin{cases} \dot{\hat{x}}(t) = A\hat{x}(t) + \hat{W}\sigma(\hat{V}\hat{z}) + L(y - \hat{y}), \\ \hat{y}(t) = C\hat{x}(t). \end{cases}$$
(1.522)

Se definesc erorile

$$e_x = x - \hat{x}, e_y = y - \hat{y}, e_W = W - \hat{W}$$
 (1.523)

și, utilizând ecuațiile (1.517), (1.520) și (1.522), rezultă [145]

$$\dot{e}_x = Ge_x + e_W \sigma(\hat{V}\hat{z}) + \xi(t), \qquad (1.524)$$

unde

$$G = A - LC, \xi(t) = W \left[ \sigma(Vz) - \sigma(\hat{V}\hat{z}) \right] + \varepsilon(x); \qquad (1.525)$$

 $\xi(t)$  este termen de tip perturbație mărginită;  $\|\xi(t)\| \le \overline{\xi} = ct$ . datorită mărginirii funcției și matricelor ponderilor *W* și *V* [229]. În consecință,

$$\begin{cases} \dot{e}_{x}(t) = Ge_{x}(t) + e_{W}\sigma(\hat{V}\hat{z}) + \xi(t), \\ \dot{e}_{y}(t) = Ce_{x}(t). \end{cases}$$
(1.526)

Pentru antrenarea NN este nevoie de o regulă (lege) de învățare astfel încât să fie garantată stabilitatea observerului. Mai mult, mecanismul de actualizare a ponderilor, folosind tehnica Lyapunov standard, se bazează pe algoritmul propagării inverse a erorii în cadrul căruia s-au mai adăugat câțiva termeni pentru stabilitatea observerului și a erorilor asociate ponderilor NN [145]. Actualizarea ponderilor este prezentată în [2], făcându-se în cadrul lucrării [145] câteva modificări asupra ecuațiilor diferențiale asociate ponderilor NN. Mai mult, termenii corecție sunt preluați din [203]. Astfel, în cadrul lucrării [145], s-au obținut următoarele ecuații diferențiale pentru determinarea ponderilor  $\hat{W}$  și  $\hat{V}$  [145]:

$$\begin{cases} \hat{W} = Se_x \sigma^T (\hat{V}\hat{z}) - k \|e_x\| S\hat{W}, \\ \hat{V} = \left[ \hat{W} \sigma (\hat{V}\hat{z}) (1 - \sigma (\hat{V}\hat{z})) \right]^T Fe_x \hat{z}^T - k \|e_x\| F\hat{V}, \end{cases}$$
(1.527)

unde matricele simetrice și pozitiv definite S și F (S=S<sup>T</sup>>0, F=F<sup>T</sup>>0) au expresiile

$$S = -\eta_1 G^{-T} C^T C, F = -\eta_2 G^{-T} C^T C; \qquad (1.528)$$

 $\eta_1, \eta_2 > 0$  sunt ratele de învățare ale NN, iar k > 0 este o constantă pozitivă mică.

Introducerea matricelor S și F în ecuațiile (1.527) permite simplificarea studiului stabilității neuro-observerului. Acest studiu este prezentat pe larg în [145] și, în cele ce urmează, nu se insistă pe el.



Fig. 1.39. Modelul Matlab/Simulink al neuro-observerului

Testarea algoritmului mai sus prezentat pentru estimarea stării unui sistem neliniar utilizând un neuro-observer (observer cu rețea neuronală) se face, în continuare, pentru cazul mișcării longitudinale a unui avion cu unghi de incidență mare. Astfel, dinamica mișcării longitudinale, în general instabile, a unui astfel de avion este descrisă în [56] și [165] de ecuația de stare

$$\dot{x} = Af(x) + Bu, \tag{1.529}$$

în care

$$f^{T}(x) = [x_{1} \ x_{2} \ x_{3} \ x_{4} \ x_{5} \ x_{2}x_{5} \ x_{1}^{1/3} \ x_{1}^{3} \ x_{2}^{1/3} \ x_{2}^{2} \ x_{2}^{3} \ x_{3}^{1/3} \ x_{3}^{3} \ x_{4}^{3} \ x_{5}^{3}], \quad (1.530)$$

 $x_1 = \Delta V, x_2 = \Delta \alpha, x_3 = \Delta \omega_y, x_4 = \Delta c_p$  (variația coeficientului de portanță),  $x_5 = \Delta C_m$ (variația coeficientului momentului aerodinamic de tangaj),  $u = \delta_p$  (bracajul profundorului) și

Modelul anterior este echivalent cu următorul:

$$\dot{x} = Ax + g(x, u), u = \delta_p, x^T = \left[\Delta V \ \Delta \alpha \ \Delta \omega_y \ \Delta c_p \ \Delta C_m\right], \tag{1.532}$$

unde

$$A = \begin{bmatrix} a_{11} & a_{12} & a_{13} & 0 & 0 \\ a_{21} & a_{22} & a_{23} & a_{24} & 0 \\ a_{31} & a_{32} & a_{33} & 0 & a_{35} \\ a_{41} & a_{42} & a_{43} & a_{44} & 0 \\ a_{51} & a_{52} & a_{53} & 0 & a_{55} \end{bmatrix}, g(x, u) = \begin{bmatrix} b_{11}u \\ b_{12}u \\ b_{13}u + g_3(x) \\ b_{14}u + g_4(x) \\ b_{15}u + g_5(x) \end{bmatrix}, (1.533)$$

$$g_{3}(x) = a_{36}x_{2}x_{5},$$

$$g_{4}(x) = a_{47}x_{1}^{1/3} + a_{48}x_{1}^{3} + a_{49}x_{2}^{1/3} + a_{4,10}x_{2}^{2} + a_{4,11}x_{2}^{3} + a_{4,12}x_{3}^{1/3} + a_{4,13}x_{3}^{3} + a_{4,14}x_{4}^{3}, (1.534)$$

$$g_{5}(x) = a_{57}x_{1}^{1/3} + a_{58}x_{1}^{3} + a_{59}x_{2}^{1/3} + a_{5,10}x_{2}^{2} + a_{5,11}x_{2}^{3} + a_{5,12}x_{3}^{1/3} + a_{5,13}x_{3}^{3} + a_{5,15}x_{5}^{3}.$$



Fig. 1.40. Modelul Matlab/Simulink al subsistemului "Bloc formare g"



Fig. 1.41. Modelul Matlab/Simulink al subsistemului "Retea neuronala"



Fig. 1.42. Modelul Matlab/Simulink al subsistemului "Actualizare ponderi NN"



Fig. 1.43. Cele 5 componente ale erorii de estimare

Validarea algoritmului s-a făcut utilizând mediul Matlab/Simulink. În acest sens, s-a elaborat programul Matlab din anexa A1.8 și modelul Matlab/Simulink din fig. 1.39. În cadrul modelului Matlab/Simulink din fig. 1.39 se observă prezența a două subsisteme: *Bloc formare g* (subsistemul prin intermediul căruia se construiește vectorul *g* utilizând vectorul de stare *x* și vectorul intrărilor *u* - ecuația (1.533)) – fig. 1.40 și *Retea neuronala* (subsistemul prin care se aproximează funcția neliniară g; acest subsistem are 3 intrări:  $\hat{x}$  (xc), *u* (u) și  $e_x$  (e\_x), precum și o singură ieșire  $\hat{g}$  (gc)) - fig.2.41. Subsistemul *Retea neuronala* are, la rândul ei, un subsistem - *Actualizare ponderi NN* (fig. 1.42). Acesta calculează ponderile  $\hat{W}$  și  $\hat{V}$  (Wc și Vc) utilizând, conform ecuațiilor (1.527), semnalele  $\hat{z}$  (zc),  $e_x$  (e\_x) și matricele *S*, *F*. Structura NN a fost aleasă astfel: rețea neuronală feed-forward, cu 3 straturi (stratul de intrare conține 6 neuroni, stratul ascuns are 5 neuroni, iar stratul de ieșire are un singur neuron). Funcția de activare utilizată pentru neuronul din stratul de ieșire este funcția sigmoidală. Ponderile  $\hat{W}$  și  $\hat{Y}$  se actualizează la fiecare pas de calcul, în final rezultănd:



Fig. 1.44. Variabilele de stare  $(x_i)$  și variabilele de stare estimate  $(\hat{x}_i)$ 

$$\hat{W}^{T} = \begin{bmatrix} 1.162 \ 1.173 \ - \ 0.035 \ 0.325 \ 0.173 \end{bmatrix}, \\ \hat{V} = \begin{bmatrix} -\ 0.179 \ 0.11 \ 0.284 \ 0.836 \ - \ 0.387 \ 0.651 \\ 0.716 \ 1.052 \ - \ 1.318 \ 1.237 \ 0.68 \ 1.175 \\ -\ 0.581 \ 0.058 \ 0.707 \ - \ 1.579 \ 0.809 \ - \ 1.191 \\ 2.168 \ - \ 0.095 \ 1.612 \ - \ 1.431 \ 0.707 \ - \ 0.019 \\ -\ 0.135 \ - \ 0.827 \ - \ 0.688 \ 0.568 \ 1.283 \ - \ 0.155 \end{bmatrix};$$
(1.535)

prima coloană a matricei ponderilor  $\hat{V}$  este vectorul biasurilor pentru neuronii din stratul ascuns. Rețeaua neuronală a neuro-observerului estimează funcția neliniară necunoscută g(x, u), urmând ca apoi neuro-observerul să estimeze vectorul de stare x, calculând  $\hat{x}$ . Sunt reprezentate în același sistem de axe (fig. 1.44) dependențele de timp ale celor 5 variabile de stare  $(x_i, i = \overline{1,5})$  și ale celor 5 variabile de stare estimate  $(\hat{x}_i, i = \overline{1,5})$ . Variațiile în timp a celor 5 componente ale erorii  $e_x = x - \hat{x}$  sunt reprezentate în fig. 1.43. Toate cele 5 componente  $e_{x_i}, i = \overline{1,5}$ , tind către zero într-un timp foarte scurt, lucru care dovedește atât funcționarea corectă a rețelei neuronale (estimarea funcției neliniare a sistemului (1.532)) cât și estimarea foarte bună a variabilelor de stare (fig. 1.43, fig. 1.44).

# 1.9.2. NEURO-OBSERVER ADAPTIV BAZAT PE FILTRUL KALMAN PENTRU SISTEMELE NELINIARE

Rețelele neuronale se folosesc pentru aproximarea funcțiilor (de obicei a celor neliniare) sau pentru compensarea erorilor ce rezultă în urma inversării dinamice, aproximării funcțiilor sau liniarizării modelelor neliniare asociate mișcărilor.

Unul dintre cele mai utilizate observere este estimatorul (filtrul) Kalman-Bucy; acesta însă nu are rezultate foarte bune în cazul prezenței în sistem a unor neliniarități (dinamica neliniară a sistemului). De aceea, în cele ce urmează, se construiește un observer adaptiv [205] bazat pe filtrul Kalman la care se adaugă o rețea neuronală pentru compensarea erorilor de liniarizare a ecuațiilor neliniare asociate sistemului. Ca rețea neuronală se utilizează o rețea cu funcții radiale [210], antrenarea sa făcându-se pe baza unui algoritm de adăugare și/sau eliminare a unui număr de neuroni din stratul ascuns al rețelei neuronale [205].

Se consideră sistemul neliniar descris de ecuațiile

$$\begin{cases} \dot{x} = f(x, u), \\ y = h(x, u) \cong Cx + Du, \end{cases}$$
(1.536)

în care x este vectorul de stare, y - vectorul de ieșire, u - vectorul format din intrările sistemului, iar f și h sunt funcții liniare. Sistemul (1.536) trebuie liniarizat, în acest sens, existând numeroși algoritmi în literatura de specialitate pentru liniarizarea dinamicii unui sistem. În urma liniarizării sistemului neliniar se obțin ecuațiile de stare

$$\begin{cases} \dot{x} = Ax + Bu, \\ y = Cx + Du, \end{cases}$$
(1.537)

unde

$$A = \left[\frac{\partial f(x,u)}{\partial x}\right]_{x_0,u_0}, B = \left[\frac{\partial f(x,u)}{\partial u}\right]_{x_0,u_0}, C = \left[\frac{\partial h(x,u)}{\partial x}\right]_{x_0,u_0}, D = \left[\frac{\partial h(x,u)}{\partial u}\right]_{x_0,u_0}; \quad (1.538)$$

 $x_0$  și  $u_0$  sunt valorile asociate punctului în jurul căruia se face liniarizarea sistemului.

Pentru ca neuro-observerul bazat pe filtrul Kalman-Bucy (neuro-observer Shankar

& Yedavally [205]) să poată fi proiectat este necesar ca perechea (A, B) să fie controlabilă și perechea (A, C) să fie detectabilă (observabilă). Dacă liniarizarea sistemului neliniar s-ar face perfect (fără erori de liniarizarare) și ar fi îndeplinite cele două condiții anterioare, s-ar construi observerul descris de ecuațiile [205]

$$\begin{cases} \dot{\hat{x}} = A\hat{x} + Bu + L(y - \hat{y}), \\ \hat{y} = C\hat{x} + Du, \end{cases}$$
(1.539)

dinamica erorii observerului  $(e = x - \hat{x})$  fiind

$$\dot{e} = (A - LC)e; \qquad (1.540)$$

matricea L a observerului se calculează astfel încât matricea (A-LC) să fie stabilă. Dacă (A-LC) – stabilă, eroarea tinde asimptotic la zero. În ecuația (1.540)  $\dot{e}$  s-a calculat scăzând din  $\dot{x}$  (având forma dată de prima ecuație (1.537)) pe  $\dot{\hat{x}}$  (având forma dată de prima ecuație (1.539)); dacă însă  $\dot{x} = f(x, u)$ , ecuația ce descrie dinamica erorii observerului este [205]

$$\dot{e} = f(x, u) - A\hat{x} - Bu - L(y - \hat{y}).$$
(1.541)

Din ecuația (1.541) se observă că  $\dot{e}$  are forma (1.540), adică eroarea e converge la zero, dacă liniarizarea dinamicii sistemului se face fără erori  $(f(x, u) \cong Ax + Bu)$ . În realitate, liniarizarea se face cu erori și, scriind pe  $\dot{x}$  și  $\dot{\dot{x}}$  sub forma

$$\begin{aligned}
\dot{x} &= f(x, u) + Ax - Ax + Bu - Bu, \\
\dot{x} &= A\hat{x} + Bu + L(y - \hat{y}),
\end{aligned}$$
(1.542)

se obține ecuația erorii [205]

$$\dot{e} = (A - LC)e + \Delta(x, u), \qquad (1.543)$$

în care

$$\Delta(x,u) = f(x,u) - Ax - Bu \tag{1.544}$$

este eroarea de liniarizare. Pentru ca  $\dot{e} = (A - LC)e$ , ecuația observerului adaptiv (prima

ecuație (1.539)) trebuie completată cu termenul  $\psi(y, u)$  ce reprezintă aproximarea erorii de liniarizare. Astfel, ecuația observerului adaptiv devine [205]

$$\hat{x} = A\hat{x} + Bu + L(y - \hat{y}) + \psi(y, u);$$
 (1.545)

în aceste condiții, ecuația asociată erorii este

$$\dot{e} = (A - LC)e + \Delta(x, u) - \psi(y, u).$$
 (1.546)

În acest caz, chiar dacă liniarizarea sistemului nu se face perfect, rezultând o eroare de liniarizare, observerul adaptiv funcționează corect întrucât  $\psi(y, u) \cong \Delta(x, u)$ și  $\dot{e}$  va avea forma (1.540). Componenta adaptivă  $\psi(y, u)$  a observerului este furnizată de către o rețea neuronală cu funcții radiale, aceasta fiind antrenată off-line pentru aproximarea erorii de liniarizare [205]. Rețeaua neuronală (NN) are 3 straturi (un strat de intrare, un strat ascuns și un strat de ieșire). Neuronii din stratul ascuns furnizează un set de funcții neliniare ce sunt baza pentru vectorii de intrare. Se consideră că NN are *p* neuroni de intrare, *q* neuroni în stratul ascuns și *r* neuroni de ieșire. Actualizarea ponderilor asociate neuronilor din stratul ascuns ( $W_{k,j}$ ) și a ponderilor asociate neuronilor de ieșire ( $b_k$ ) se face cu formulele [205]

$$W_{k,j}(n+1) = W_{k,j}(n) + \eta(\bar{y}_k - y_k)\varphi_j, \ b_k(n+1) = b_k(n) + \eta(\bar{y}_k - y_k), \ (1.547)$$

unde  $W_{k,j}$  reprezintă ponderea între neuronul *j* din stratul ascuns și neuronul de ieșire *k*, *b<sub>k</sub>* - biasul neuronului *k* din stratul de ieșire,  $y_k, \bar{y}_k$  – ieșirea, respectiv ieșirea dorită a neuronului *k* din stratul de ieșire,  $\eta$  - rata de învățare a NN, iar  $\varphi_j$  - funcția neliniară asociată neuronului *j* din stratul ascuns. Expresia funcției  $\varphi_j$  este [205]:

$$\varphi_{j} = \exp\left[\sum_{i=1}^{p} -(c_{j,i} - I_{i})^{2} / \sigma_{j}^{2}\right], \qquad (1.548)$$

în care  $c_{j,i}$  reprezintă centrul neuronului *j* corespunzător intrării  $i(I_i)$ , iar  $\sigma_j$  este variația sa. Antrenarea rețelei neuronale se face prin minimizarea diferenței dintre ieșirea dorită  $\overline{y}_k$  și ieșirea  $y_k$  pentru toți neuronii de ieșire  $k = \overline{1, r}$  [205].

Schema bloc a neuro-observerului adaptiv pentru sistemele neliniare se bazează pe filtrul Kalman (observer Shankar & Yedavally [205]) și este prezentată în fig. 1.45.



Fig. 1.45. Schema bloc a neuro-observerului pentru sistemele neliniare bazat pe filtrul Kalman

Antrenarea NN se face prin intermediul algoritmului de "adăugare și tăiere". Acesta presupune adăugarea sau ștergerea (reducerea) de neuroni din stratul ascuns în funcție de intrările NN și de actualizarea ponderilor stratului de ieșire. Așadar, algoritmul presupune adăugarea sau ștergerea de neuroni din stratul ascuns concomitent cu actualizarea centrelor neuronilor rămași în stratul ascuns. Actualizarea centrelor neuronilor rămași în stratul ascuns se face prin metoda propagării inverse [205]

$$c_{j,i}(n+1) = c_{j,i}(n) + \frac{2\eta}{\sigma_j} \left( I_i - c_{j,i}(n) \right) \varphi_j \left[ \sum_{k=1}^r \left( \overline{y}_k - y_k \right) W_{k,j} \right].$$
(1.549)

#### Adăugarea de neuroni

Dacă intrarea, de exemplu *I*, este de așa natură încât există o distanță mai mare decât o distanță predefinită  $d_{ad}$  de la centrul fiecărui neuron din stratul ascuns, un nou neuron cu acea intrare ca centru este adăugat. Parametrii noului neuron adăugat sunt

$$c_{nou,i} = I_i; \sigma_{nou} = k_{ad} \ d_{\min}; W_{k,new} = \overline{y}_k - y_k; b_{k,nou} = 0.$$
(1.550)

 $k_{ad}$  este o constantă predefinită, iar  $d_{\min}$  este distanța minimă între centrele neuronilor existenți în stratul ascuns și intrarea  $I^{nou}$  [205].

## Stergerea (reducerea) de neuroni

Dacă intrările ce ajung la NN sunt de așa natură astfel încât sunt apropiate de

centrele unor neuroni dar depărtate de centrele altor neuroni, ultimul set de neuroni se șterge. Procesul este finalizat prin verificarea distanței absolute de la intrare a centrelor neuronilor în raport cu pragul sub care orice neuron ce primește această intrare nu va furniza vreo ieșire [205]. Pragul pentru ștergerea neuronilor este

$$d_{stergere} = M_{stergere} d_{\min}, \qquad (1.551)$$

unde  $M_{stergere} > 1$  și  $d_{min}$  - distanța minimă de la neuroni la intrare. Ștergerea se face la finalul fiecărui ciclu de antrenare [205].

# 1.9.3. NEURO-OBSERVER BAZAT PE UTILIZAREA REȚELELOR NEURONALE ORTOGONALE PENTRU ESTIMAREA STĂRII SISTEMELOR HAOTICE

În domeniul analizei și controlului haosului, un subiect interesant și mult studiat îl reprezintă sincronizarea și supresia haosului, acest lucru având multiple aplicații inginerești precum comunicația sigură, reacții chimice etc [113]. Multe dintre eforturi au fost făcute în direcția sincronizării și supresiei haosului [113]; majoritatea cercetărilor făcute consideră că informația de la toate stările unui sistem este disponibilă, lucru care nu se întâmplă în realitate, doar informațiile de la mărimile de ieșire fiind disponibile. În acest sens, au fost proiectate recent câteva observere.

În practică, majoritatea sistemelor haotice au necunoscute și observerele clasice nu pot fi folosite cu succes [113]. De aceea, este nevoie de un nou observer adaptiv pentru sincronizarea și controlul sistemelor haotice. Acest observer adaptiv are în componență o rețea neuronală ortogonală, eficiența observerului putând fi analizată prin intermediul teoriei Lyapunov. Legea de actualizare a ponderilor NN derivă din analiza funcțiilor Lyapunov.

Se consideră cazul general al unor sisteme haotice

$$\begin{cases} \dot{x} = Ax + B^* g(x) + Bu, \\ y = Cx; \end{cases}$$
(1.552)

*u*, *y* sunt vectorii de intrare, respectiv de ieșire,  $x \in \mathcal{M}^{n \times 1}$  – vectorul de stare, A, B, C –

matrice constante,  $g(x) \in \mathcal{M}^{m \times 1}$  – funcție neliniară necunoscută.

Se presupune că perechea (C, A) este observabilă și se alege matricea L astfel încât (A-LC) să fie stabilă. Din lema lui Kalman & Yakubovich rezultă o matrice M și 2 matrice pozitiv definite P și Q astfel încât să fie verificate următoarele 2 ecuații matriceale [113]

$$(A - LC)^{T} P + P(A - LC) = -Q, \qquad (1.553)$$

$$B^{*T}P = MC. (1.554)$$

Ecuațiile (1.553) și (1.554) sunt valabile pentru multe sisteme neliniare, inclusiv sistemele haotice.

Unul dintre cele mai cunoscute tipuri de rețele neuronale este rețeaua neuronală ortogonală (ONN); aceasta are 3 straturi cu neuroni: un strat de intrare, un strat ascuns și un strat de ieșire. Intrarea rețelei neuronale este vectorul de stare estimat  $\hat{x} \in \mathcal{M}^{n \times 1}$ ; fie *p* numărul neuronilor din stratul ascuns. În aceste condiții se calculează [113]

$$net = \sum_{i=1}^{n} \hat{x}_i, X = \left[1 + e^{-\sigma \cdot net}\right]^{-1},$$
(1.555)

unde  $\sigma$  este o constantă pozitivă.

Ieșirile stratului ascuns a rețelei neuronale ortogonale se bazează pe polinoame Chebyshev și sunt

$$G_1(\hat{x}) = 1, G_2(\hat{x}) = X, G_i(\hat{x}) = 2XG_{i-1}(\hat{x}) - G_{i-2}(\hat{x}), \qquad (1.556)$$

cu  $i = \overline{1, p}$ . Ieșirea rețelei neuronale  $(\tilde{y})$  se calculează astfel [113]:

$$\widetilde{y} = WG(\widehat{x}), \tag{1.557}$$

unde W este matricea ponderilor NN.

Având în vedere că funcția neliniară g(x) este necunoscută, ea poate fi aproximată (modelată) utilizând o rețea neuronală, neuro-observerul ce rezultă fiind descris de ecuațiile

$$\begin{cases} \dot{\hat{x}} = A\hat{x} + L(y - C\hat{x}) + B^* [WG(\hat{x}) + v] + Bu, \\ \hat{y} = C\hat{x}, \end{cases}$$
(1.558)

în care  $v \in \mathcal{M}^{m \times 1}$  este legea de comandă. Scopul neuro-observerului este acela de a estima vectorul de stare  $x(\hat{x} \to x)$  printr-o proiectare prealabilă a lui v și W.

Legea de actualizare a matricei ponderilor (W) și legea de comandă (v) au expresiile [113]

$$\dot{W} = -\eta M e_y G^T(\hat{x}), v = -k \operatorname{sgn}(M e_y), \dot{k} = \gamma (M e_y)^T \operatorname{sgn}(M e_y), \qquad (1.559)$$

unde  $e_y = \hat{y} - y$ , iar  $\gamma$  și  $\eta$  sunt constante pozitive ce trebuie alese.

Schema bloc a estimatorului de stare este prezentată în fig. 1.46.



Fig. 1.46. Schema bloc a observerului pentru estimarea stării sistemelor haotice



Fig. 1.47. Modelul Matlab/Simulink a neuro-observerului cu rețea neuronală ortogonală

Testarea algoritmului mai sus prezentat pentru estimarea stării unui sistem haotic utilizând un neuro-observer (observer cu rețea neuronală ortogonală) se face, și în acest caz, utilizându-se dinamica mișcării longitudinale a unui avion cu unghi de incidență mare [56], [165]. Astfel, dinamica mișcării longitudinale, în general instabile, a unui astfel de avion este descrisă de ecuația de stare

$$\dot{x} = Ax + B^* g(x) + Bu, \tag{1.560}$$

în care  $u = \delta_p, x^T = [\Delta V \ \Delta \alpha \ \Delta \omega_y \ \Delta c_p \ \Delta C_m], g(x)$  are forma

$$g(x) = \begin{bmatrix} 0 & 0 & g_3(x) & g_4(x) & g_5(x) \end{bmatrix}^T,$$
 (1.561)

cu  $g_3(x), g_4(x), g_5(x)$  având forma (1.534); matricele *A*, *B*<sup>\*</sup> și *B* din ecuația (1.560) sunt de forma

$$A = \begin{bmatrix} a_{11} & a_{12} & a_{13} & 0 & 0 \\ a_{21} & a_{22} & a_{23} & a_{24} & 0 \\ a_{31} & a_{32} & a_{33} & 0 & a_{35} \\ a_{41} & a_{42} & a_{43} & a_{44} & 0 \\ a_{51} & a_{52} & a_{53} & 0 & a_{55} \end{bmatrix}, B^{T} = \begin{bmatrix} b_{11} \\ b_{12} \\ b_{13} \\ b_{14} \\ b_{15} \end{bmatrix}, B^{*} = I_{n};$$
(1.562)

elementele matricelor de mai sus sunt constante cu valorile prezentate în programul din anexa A.2.9.

Validarea algoritmului s-a făcut utilizând mediul Matlab/Simulink. În acest sens, s-a elaborat programul Matlab din anexa A.2.9 și modelul Matlab/Simulink din fig. 1.47. În cadrul modelului Matlab/Simulink din fig. 1.47 se observă prezența a trei subsisteme: *Bloc formare g* (subsistemul prin intermediul căruia se construiește funcția g(x)) - fig. 1.48, *Retea neuronala* (subsistemul prin care se aproximează funcția neliniară g(x) - ecuațiile (1.555)-(1.557) și prima ecuație (1.559)) – fig. 1.49 și *Bloc determinare v* (subsistemul prin care se construiește legea de comandă v - ultimele două ecuații (1.559)) – fig. 1.50. Subsistemul *Bloc formare g* are o singură intrare (x) și o singură ieșire (g(x)); subsistemul *Retea neuronala* are 2 intrări:  $\hat{x}$  (xc),  $e_y$  (e\_y) și două ieșiri:  $\hat{g}$  (gc) și W (W)); subsistemul *Bloc determinare v* are o singură intrare  $e_y$ (e\_y) și două ieșiri: constanta k și legea de comandă v.



Fig. 1.48. Modelul Matlab/Simulink al subsistemului "Bloc formare g"



Fig. 1.49. Modelul Matlab/Simulink al subsistemului "Retea neuronala"



Fig. 1.50. Modelul Matlab/Simulink al subsistemului "Bloc determinare v"



Fig. 1.51. Variabilele de stare  $(x_i)$  și variabilele de stare estimate  $(\hat{x}_i)$ 



Fig. 1.52. Variabilele de stare  $(x_i)$  și variabilele de stare estimate  $(\hat{x}_i)$ 

Structura NN a fost aleasă astfel: rețea neuronală ortogonală, cu 3 straturi (stratul de intrare conține 5 neuroni, stratul ascuns are 5 neuroni, iar stratul de ieșire are un singur neuron). Matricea *W* se actualizează la fiecare pas de calcul, în final obținându-se

$$W = \begin{bmatrix} 0.567 & 0.566 & 0.565 & 0.560 & 0.554 \\ -0.099 & -0.1 & -0.1 & -0.1 & -0.1 \\ 3.382 & 0.982 & -2.052 & -0.805 & 1.754 \\ 0.167 & 0.151 & 0.125 & 0.119 & 0.129 \\ 0.253 & 0.196 & 0.117 & 0.130 & 0.181 \end{bmatrix};$$
 (1.563)

constanta k, la finalul simulării, este k=3,1045.

Rețeaua neuronală ortogonală a neuro-observerului estimează funcția neliniară necunoscută g(x), urmând ca apoi neuro-observerul să estimeze vectorul de stare x, calculând  $\hat{x}$ . Sunt reprezentate în același sistem de axe (fig. 1.51) dependențele de timp ale celor 5 variabile de stare  $(x_i, i = \overline{1,5})$  și ale celor 5 variabile de stare estimate  $(\hat{x}_i, i = \overline{1,5})$ . Variația în timp a celor 5 componente ale erorii  $e_x = x - \hat{x}$  este reprezentată în fig. 1.52. Toate cele 5 componente  $e_{x_i}, i = \overline{1,5}$ , tind către zero într-un timp foarte scurt, lucru care dovedește atât funcționarea corectă a rețelei neuronale ortogonale (estimarea funcției neliniare a sistemului (1.552)), cât și estimarea foarte bună a variabi-lelor de stare (fig. 1.51, fig. 1.52).

# 1.9.4. OBSERVER ADAPTIV PENTRU ESTIMAREA STĂRII PROCESELOR NELINIARE MĂRGINITE

În cele ce urmează, un observer liniar este îmbunățațit prin adăugarea unui element adaptiv (2 rețele neuronale ce sunt antrenate on-line). Scopul adăugării elementelor adaptive este îmbunătățirea performanțelor observerului liniar [480].

Se consideră dinamica unui proces (sistem) observabil și mărginit [480]

$$\begin{cases} \dot{x}_0 = f_0(x_0, u, v), \\ y = g_0(x_0, u, v), \end{cases}$$
(1.564)

unde  $x_0 \in \mathcal{M}^{n_0 \times 1}$  este vectorul de stare,  $u \in \mathcal{M}^{m \times 1}$ ,  $y \in \mathcal{M}^{l \times 1}$  – vectorii de intrare, respectiv ieșire ai sistemului,  $v \in \mathcal{M}^{k \times 1}$  – intrare necunoscută de tip perturbație;  $f_0$  și  $g_0$ sunt funcții continue parțial cunoscute. Se presupune că perturbațiile aparțin unei clase de funcții continue descrisă de ecuațiile [480]

$$\dot{x}_{v} = f_{v}(x_{0}, x_{v}), v = g_{v}(x_{0}, x_{v}), \qquad (1.565)$$

în care  $x_v \in \mathcal{M}^{n_v \times 1}$ . Cu notațiile  $x = \begin{bmatrix} x_0^T & x_v^T \end{bmatrix}^T \in \mathcal{M}^{n \times 1}, n = n_0 + n_v, \bar{f} = \begin{bmatrix} f_0^T & f_v^T \end{bmatrix}^T \in \mathcal{M}^{n \times 1},$ ecuațiile (1.564) și (1.565) conduc la [480]

$$\begin{aligned}
\dot{x} &= \bar{f}(x, u), \\
y &= g_0(x, u).
\end{aligned}$$
(1.566)

Ecuațiile (1.566) sunt echivalente cu

$$\begin{cases} \dot{x} = Ax + Bu + f(x, u), \\ y = Cx + Du + g(x, u), \end{cases}$$
(1.567)

unde

$$\begin{cases} f(x,u) = \bar{f}(x,u) - Ax - Bu, \\ g(x,u) = g_0(x,u) - Cx - Du. \end{cases}$$
(1.568)

Sistemul de ecuații (1.567) conține o parte liniară și una neliniară descrisă de funcțiile neliniare f(x, u) și g(x, u). Pentru partea liniară [480]

$$\begin{cases} \dot{x}_L = Ax_L + Bu, \\ y_L = Cx_L + Du, \end{cases}$$
(1.569)

se construiește observerul liniar

$$\begin{cases} \dot{\hat{x}}_{L} = A\hat{x}_{L} + Bu + K(y_{L} - \hat{y}_{L}), \\ \dot{y}_{L} = C\hat{x}_{L} + Du \end{cases}$$
(1.570)

prin intermediul căruia se estimează vectorul de stare  $x_L$  astfel încât  $\hat{x}_L - x_L \rightarrow 0$  când  $t \rightarrow \infty$ . Obiectivul lucrării [480] a fost acela de a îmbunătății observerul liniar (1.570) cu un element adaptiv astfel încât estimarea să fie mai bună, având în vedere că  $\hat{x}_L$  reprezintă vectorul de stare estimat al subsistemului liniar (1.569) și nu al întregului

sistem (1.567).

Principala utilizare a rețelelor neuronale o reprezintă aproximarea funcțiilor. Astfel, funcția neliniară f(x,u) poate fi aproximată cu ajutorul unei rețele neuronale cu un singur strat ascuns [481]

$$f(x, u) = M_1^T \sigma(N_1^T \mu) + \varepsilon_1(\mu), \qquad (1.571)$$

unde  $M_1$  și  $N_1$  sunt matricele ponderilor asociate NN,  $\sigma$  este funcția de activare a neuronilor din stratul ascuns (de exemplu funcția sigmoidală  $\sigma(x) = 1/(1 + e^{-x})$ ), iar vectorul  $\mu$  (vector de intrare) are forma [480]

$$\mu(t) = \begin{bmatrix} 1 \ \overline{y}_d^T(t) \ \overline{u}_d^T(t) \end{bmatrix}^T, \tag{1.572}$$

în care  $\overline{y}_d$  și  $\overline{u}_d$  conțin valori ale ieșirii, respectiv intrării la momente anterioare;  $\varepsilon_1$  este eroarea de reconstrucție (eroarea de aproximare) a funcției *f*. Dacă observerul liniar este îmbunătățit cu o singură rețea neuronală (pentru aproximarea funcției *f*(*x*, *u*)) se poate considera, pentru simplitate, *g*(*x*, *u*)=0 și dinamica sistemului descris de ecuațiile (1.567) devine [480]

$$\begin{cases} \dot{x} = Ax + Bu + M_1^T \sigma(N_1^T \mu) + \varepsilon_1(\mu), \\ y = Cx + Du, \end{cases}$$
(1.573)

iar observerul pentru estimarea lui x este

$$\begin{cases} \hat{x} = A\hat{x} + Bu + \hat{M}_{1}^{T}\sigma(\hat{N}_{1}^{T}\mu) + K(y - \hat{y}), \\ \hat{y} = C\hat{x} + Du, \end{cases}$$
(1.574)

în care  $\hat{M}_1$  și  $\hat{N}_1$  sunt estimările matricelor pondere  $M_1$  și  $N_1$  (ponderi ajustate on-line).

Observerul poate fi privit ca unul liniar pentru partea liniară a dinamicii liniare (1.567), îmbunătățit cu o rețea neuronală pentru modelarea funcției f (ecuația (1.571)). Cu notațiile  $E = \hat{x} - x, z = \hat{y} - y$ , se obțin ecuațiile [480]

$$\begin{cases} \dot{E} = \overline{A}E + \hat{M}_1^T \sigma(\hat{N}_1^T \mu) - M_1^T \sigma(N_1^T \mu) - \varepsilon_1(\mu), \\ z = CE, \end{cases}$$
(1.575)

unde  $\overline{A} = A - KC$ ; K se calculează astfel încât  $\overline{A}$  să fie stabilă.

Este nevoie de legile de actualizare a ponderilor NN. Pentru aceasta, se introduce mai întâi observerul liniar descris de ecațiile [480]

$$\begin{cases} \dot{\hat{E}} = \overline{A}\hat{E} + \overline{K}(z - \hat{z}), \\ \hat{z} = C\hat{E}, \end{cases}$$
(1.576)

unde  $\overline{K}$  este o matrice de amplificare ce se calculează astfel încât  $\widetilde{A} = \overline{A} - \overline{K}C$  să fie asimptotic stabilă. Acest lucru este utilizat doar pentru a genera un semnal de eroare ce este necesar pentru actualizarea ponderilor NN. Considerând  $\widetilde{E} = \hat{E} - E$ , rezultă

$$\dot{\widetilde{E}} = \widetilde{A}\widetilde{E} - \hat{M}_{1}^{T}\sigma(\hat{N}_{1}^{T}\mu) + M_{1}^{T}\sigma(N_{1}^{T}\mu) + \varepsilon_{1}(\mu).$$
(1.577)

Ponderile rețelei neuronale  $\hat{M}_1$  și  $\hat{N}_1$  se actualizează utilizând următoarele legi de adaptare [480]:

$$\dot{\hat{N}}_{1} = -G_{1} \Big[ 2\mu \hat{E}^{T} P \hat{M}_{1}^{T} \hat{\sigma}' + k_{1} \Big( \hat{N}_{1} - N_{1_{0}} \Big) \Big], \\ \dot{\hat{M}}_{1} = -F_{1} \Big[ 2 \Big( \hat{\sigma} - \hat{\sigma}' \hat{N}_{1}^{T} \mu \Big) \hat{E}^{T} P + k_{1} \Big( \hat{M}_{1} - M_{1_{0}} \Big) \Big],$$
(1.578)

în care P este soluția ecuației Lyapunov

$$\overline{A}^T P + P\overline{A} + Q = 0, \qquad (1.579)$$

 $Q, G_1, F_1$  – matrice pozitiv definite,  $\hat{\sigma} = \sigma(\hat{N}_1\mu), \hat{\sigma}' = \sigma'(\hat{N}_1\mu)$  – Jacobianul vectorului  $\hat{\sigma}$ ,  $M_{1_0}$  și  $N_{1_0}$  – valorile inițiale ale ponderilor NN;  $k_1 > 0$  - constantă de actualizare [480].

Analiza stabilității estimatorului de stare (1.574) este prezentată pe larg în [482]. Observerul construit până acum (observer liniar îmbunătățit cu o NN) s-a obținut pentru cazul g(x, u)=0. În cazul în care această funcție neliniară nu se neglijează, este nevoie de o a doua rețea neuronală pentru estimarea ei [480]. Ca și în cazul anterior, g(x, u) se obține astfel:

$$g(x, u) = M_2^T \sigma(N_2^T \mu) + \varepsilon_2(\mu); \qquad (1.580)$$

în aceste condiții dinamica sistemului descris de ecuațiile (1.567) devine

$$\begin{cases} \dot{x} = Ax + Bu + M_1^T \sigma(N_1^T \mu) + \varepsilon_1(\mu), \\ y = Cx + Du + M_2^T \sigma(N_2^T \mu) + \varepsilon_2(\mu). \end{cases}$$
(1.581)

Pentru sistemul anterior se obține dinamica observerului

$$\begin{cases} \dot{\hat{x}} = A\hat{x} + Bu + \hat{M}_{1}^{T}\sigma(\hat{N}_{1}^{T}\mu) + K(y - \hat{y}), \\ \dot{y} = C\hat{x} + Du + \hat{M}_{2}^{T}\sigma(\hat{N}_{2}^{T}\mu); \end{cases}$$
(1.582)

 $\hat{M}_2$  și  $\hat{N}_2$  sunt estimările ponderilor  $M_2$  și  $N_2$  ale celei de-a doua rețele neuronale. Folosind aceleași notații  $E = \hat{x} - x, z = \hat{y} - y$ , rezultă [480]

$$\begin{cases} \dot{E} = \overline{A}E + \hat{M}_{1}^{T}\sigma(\hat{N}_{1}^{T}\mu) - M_{1}^{T}\sigma(N_{1}^{T}\mu) - \varepsilon_{1}(\mu) - K[\hat{M}_{2}^{T}\sigma(\hat{N}_{2}^{T}\mu) - M_{2}^{T}\sigma(N_{2}^{T}\mu) - \varepsilon_{2}(\mu)], \\ z = CE + \hat{M}_{2}^{T}\sigma(\hat{N}_{2}^{T}\mu) - M_{2}^{T}\sigma(N_{2}^{T}\mu) - \varepsilon_{2}(\mu). \end{cases}$$
(1.583)

Ponderile celei de-a doua rețele neuronale se actualizează cu legi de adaptare de tipul (1.578):

$$\dot{\hat{N}}_{2} = -G_{2} \Big[ 2\mu \hat{E}^{T} \widetilde{P} \widetilde{K} \hat{M}_{2}^{T} \hat{\sigma}' + k_{2} \hat{N}_{2} \Big], \\ \dot{\hat{M}}_{2} = -F_{2} \Big[ 2 \Big( \hat{\sigma} - \hat{\sigma}' \hat{N}_{2}^{T} \mu \Big) \hat{E}^{T} \widetilde{P} \widetilde{K} + k_{2} \hat{M}_{2} \Big]; \quad (1.584)$$

de această dată  $\hat{\sigma} = \sigma(\hat{N}_2\mu), \hat{\sigma}' = \sigma'(\hat{N}_2\mu), k_2 > 0 - \text{constantă de actualizare}, F_2, G_2 > 0.$ 

Schema bloc asociată observerului descris de ecuațiile (1.582) este prezentată în Fig. 1.53.



Fig. 1.53. Schema bloc a observerului adaptiv pentru procese neliniare mărginite

# **CAPITOLUL 2**

# **PROIECTAREA OBSERVERELOR MULTIPLE**

# 2.1. OBSERVERUL MULTIMPLU AKHENAK (VARIANTA 1)

Deoarece majoritatea sistemelor sunt neliniare și este dificil de sintetizat un observer pentru astfel de sisteme, în [5] sistemele neliniare au fost reprezentate prin intermediul unor modele multiple. Ideea modelului multiplu se leagă de necesitatea înțelegerii comportamentului sistemelor prin intermediul unor modele locale liniare, fiecare model local caracterizând comportamentul unui sistem într-o anumită regiune de funcționare [5]. Un model multiplu poate fi obținut prin identificare [72], liniarizare în jurul diverselor puncte de funcționare sau prin intermediul transformărilor convexe politopice [205]; în cazul obținerii modelului multiplu prin liniarizare în jurul unor puncte de funcționare, fiecare model local este un sistem liniar, afin și invariant în timp ca urmare a prezenței constantelor de liniarizare. În cazul sistemelor neliniare afectate de intrări necunoscute, se utilizează observerele multiple, observerele de tip alunecător [6], [34] sau combinații ale acestora.

## 2.1.1. STRUCTURA MODELULUI MULTIPLU

Modelul multiplu este obținut prin interpolarea câtorva modele liniare;

$$\begin{cases} \dot{x}(t) = \sum_{i=1}^{M} \mu_i(\xi(t)) [A_i x(t) + B_i u(t) + d_i], \\ y(t) = C x(t), \end{cases}$$
(2.1)

unde  $x(t) \in \mathcal{M}^{n \times 1}$  este vectorul de stare al sistemului,  $u(t) \in \mathcal{M}^{m \times 1}$  – vectorul intrărilor,  $y(t) \in \mathcal{M}^{p \times 1}$  – vectorul de ieșire, iar  $C \in \mathcal{M}^{p \times n}$  este matricea de ieșire a sistemului. Pentru
modelul local "*i*",  $A_i \in \mathcal{M}^{n \times n}$  este matricea asociată stării,  $B_i \in \mathcal{M}^{n \times m}$  – matricea de intrare, iar  $d_i \in \mathcal{M}^{n \times 1}$  – vectori constanți. Funcțiile de activare  $\mu_i(\xi(t)), i = \overline{1, M}$ , au proprietățile următoare [5]

$$\sum_{i=1}^{M} \mu_i(\xi(t)) = 1, 0 \le \mu_i(\xi(t)) \le 1, (\forall) \ i = \overline{1, M};$$
(2.2)

vectorul  $\xi(t)$  se numește vector de decizie și depinde de intrări și/sau variabilele măsurabile. Numărul modelelor locale (*M*) depinde de precizia cu care se face modelarea, de complexitatea sistemului neliniar aproximat prin modelul multiplu, precum și de structura funcțiilor de activare.

În cazul în care modelul multiplu este afectat de intrări necunoscute și incertitudini, ecuațiile asociate acestuia sunt [5]

$$\begin{cases} \dot{x}(t) = \sum_{i=1}^{M} \mu_i(\xi(t)) [(A_i + \Delta A_i(t))x(t) + B_i u(t) + D_i v(t) + d_i], \\ y(t) = Cx(t). \end{cases}$$
(2.3)

Intrările necunoscute se consideră mărginite  $(||v(t)|| < \rho)$ ,  $\rho$  fiind o constantă pozitivă; matricele variabile în timp  $\Delta A_i(t)$  fiind, de asemenea, mărginite  $\Leftrightarrow ||\Delta A_i(t)|| < \delta_i$ . În ecuațiile (2.3),  $D_i \in \mathcal{M}^{n \times q}$  se numesc matrice de trasmisie. În cele ce urmează, pentru ușurința notațiilor, dependența de timp (t) este omisă.

### 2.1.2. PROIECTAREA OBSERVERULUI MULTIPLU

În [5] estimarea stării modelului multiplu (2.1) se face prin intermediul unui observer multiplu bazat pe combinarea observerelor de tip Luenberger și a unor termeni de alunecare cu rol în compensarea incertitudinilor  $\Delta A_i(t)$  și a intrărilor necunoscute. Se presupune că perechile  $(A_i, C)$  sunt observabile și că există matricele  $G_i \in \mathcal{M}^{n \times p}$ astfel încât  $\overline{A}_i = A_i - G_i C$ ,  $i = \overline{1, M}$ , sunt matrice stabile; cu alte cuvinte, se presupune că există matricele simetrice și pozitiv definite P și  $Q_i$ , precum și matricele  $F_i \in \mathcal{M}^{q \times p}$  care satisfac condițiile (constrângerile [5])

$$\begin{cases} \overline{A}_i^T P + P \overline{A}_i = -Q_i ,\\ C^T F_i^T = P D_i , i = \overline{1, M} . \end{cases}$$
(2.4)

Observerul multiplu propus pentru estimarea stării modelului multiplu (2.3) este de forma [5]

$$\begin{cases} \dot{\hat{x}} = \sum_{i=1}^{M} \mu_i(\xi) [A_i \ \hat{x} + B_i u + d_i + G_i(y - C\hat{x}) + \alpha_i + D_i \gamma_i], \\ \hat{y} = C\hat{x}. \end{cases}$$
(2.5)

Vectorii  $\gamma_i \in \mathcal{M}^{q \times 1}$  compensează erorile datorate intrărilor necunoscute, iar  $\alpha_i \in \mathcal{M}^{n \times 1}$ compensează erorile datorate incertitudinilor sistemului. Pentru proiectarea observerului (2.5) este nevoie de calculul matricelor  $G_i$ ,  $i = \overline{1, M}$  și a vectorilor  $\alpha_i$ ,  $\gamma_i$ ,  $i = \overline{1, M}$ . Pentru a realiza acest lucru, se definesc erorile

$$e = x - \hat{x}, r = y - \hat{y} = C(x - \hat{x}) = Ce;$$
 (2.6)

cu acestea, dinamica erorii observerului multiplu este [5]

$$\dot{e} = \sum_{i=1}^{M} \mu_i(\xi) [(A_i - G_i C)e + \Delta A_i x + D_i v - R_i \gamma_i - \alpha_i].$$

$$(2.7)$$

Proiectarea observerului multiplu (2.5) este concentrată în următoarea teoremă:

#### *<u>Teorema 2.1</u>* [5]

Eroarea de estimare a stării observerului (2.5) converge asimptotic la zero dacă

$$\begin{split} \gamma_{i} &= \begin{cases} \rho \frac{F_{i}r}{\|F_{i}r\|}, \ r \neq 0\\ 0, \ r = 0 \end{cases} \\ \alpha_{i} &= \begin{cases} \beta_{1}(1+\beta_{2})\delta_{i}^{2} \frac{\hat{x}^{T}\hat{x}}{2r^{T}r} P^{-1}C^{T}r, \ r \neq 0\\ 0, \ r = 0 \end{cases} \end{split}$$
(2.8)

și dacă există o matrice P>0, matricele  $F_i$  și scalarii pozitivi  $\beta_1$  și  $\beta_2$  care satisfac urmă-

toarele constrângeri

$$\begin{cases} \overline{A}_{i}^{T}P + P\overline{A}_{i} + \beta_{1}^{-1}P^{2} + \beta_{1}(1 + \beta_{2}^{-1})\delta_{i}^{2} I < 0, \\ C^{T}F_{i}^{T} = PD_{i}, i = \overline{1, M}, \end{cases}$$
(2.9)

unde

$$\overline{A}_{i} = A_{i} - G_{i}C, i = 1, M, \qquad (2.10)$$

sunt matrice stabile.

În cadrul demonstrației acestei teoreme, se folosește următoarea lemă

*Lema 2.1* [5]

Pentru orice matrice X și Y și orice scalar  $\beta > 0$ , este valabilă inegalitatea

$$X^T Y + Y^T X \le \beta X^T X + \beta^{-1} Y^T Y.$$
(2.11)

Pentru demonstrația teoremei 2.1, se consideră funcția Lyapunov

$$V(e) = e^T P e \tag{2.12}$$

și se calculează

$$\dot{V} = \sum_{i=1}^{M} \mu_i(\xi) \Big[ e^T \big( \overline{A}_i^T P + P \overline{A}_i \big) e - 2\alpha_i^T P e + 2e^T P D_i v - 2e^T P D_i R_i \gamma_i \Big]$$

$$+ \sum_{i=1}^{M} \mu_i(\xi) \big( x^T \Delta A_i^T P e + e^T P \Delta A_i x \big);$$
(2.13)

s-a ținut cont de relațiile

$$\begin{cases} v^{T} D_{i}^{T} P e + e^{T} P D_{i} v = 2e^{T} P D_{i} v, \\ \alpha_{i}^{T} P e + e^{T} P \alpha_{i} = 2\alpha_{i}^{T} P e, \\ \gamma_{i}^{T} D_{i}^{T} P e + e^{T} P D_{i} \gamma_{i} = 2e^{T} P D_{i} \gamma_{i}. \end{cases}$$

$$(2.14)$$

Folosind lema 2.1, particularizată pentru  $X = \Delta A_i x$ , Y = Pe,  $\beta = \beta_1$ , rezultă [5]

$$\dot{V} \leq \sum_{i=1}^{M} \mu_i(\xi) \Big[ e^T \big( \overline{A}_i^T P + P \overline{A}_i \big) e - 2\alpha_i^T P e + 2e^T P D_i v - 2e^T P D_i R_i \gamma_i \Big] + \\ + \sum_{i=1}^{M} \mu_i(\xi) \big( \beta_1 x^T \Delta A_i^T \Delta A_i x + \beta_1^{-1} e^T P^2 e \big).$$

$$(2.15)$$

Utilizând prima expresie (2.6), termenul  $\beta_1 x^T \Delta A_i^T \Delta A_i x$  devine

$$\beta_{1}x^{T}\Delta A_{i}^{T}\Delta A_{i}x = \beta_{1}\left[\left(e+\hat{x}\right)^{T}\Delta A_{i}^{T}\Delta A_{i}\left(e+\hat{x}\right)\right] =$$

$$= \beta_{1}\left[e^{T}\Delta A_{i}^{T}\Delta A_{i}\left(e+\hat{x}\right)+\hat{x}^{T}\Delta A_{i}^{T}\Delta A_{i}\left(e+\hat{x}\right)\right] =$$

$$= \beta_{1}\left[e^{T}\Delta A_{i}^{T}\Delta A_{i}e+e^{T}\Delta A_{i}^{T}\Delta A_{i}\hat{x}+\hat{x}^{T}\Delta A_{i}^{T}\Delta A_{i}e+\hat{x}^{T}\Delta A_{i}\hat{x}\right];$$

$$(2.16)$$

se obține

$$\dot{V} \leq \sum_{i=1}^{M} \mu_{i}(\xi) \Big[ e^{T} \Big( \overline{A}_{i}^{T} P + P \overline{A}_{i} + \beta_{1}^{-1} P^{2} \Big) e + 2 e^{T} P D_{i} v - 2 \alpha_{i}^{T} P e - 2 e^{T} P D_{i} R_{i} \gamma_{i} \Big] + \\ + \sum_{i=1}^{M} \mu_{i}(\xi) \Big[ \beta_{1} \delta_{i}^{2} \Big( \hat{x}^{T} \hat{x} + e^{T} e \Big) + \beta_{1} \delta_{i}^{2} \Big( e^{T} \hat{x} + \hat{x}^{T} e \Big) \Big].$$

$$(2.17)$$

Se folosește din nou lema 2.1, particularizată pentru  $X = \hat{x}, Y = e, \beta = \beta_2$ ; astfel, utilizând inegaliatea  $\hat{x}^T e + e^T \hat{x} \le \beta_2 \hat{x}^T \hat{x} + \beta_2^{-1} e^T e$ , expresia (2.17) capătă forma [5]

$$\begin{split} \dot{V} &\leq \sum_{i=1}^{M} \mu_{i}(\xi) \Big[ e^{T} \Big( \overline{A_{i}}^{T} P + P \overline{A_{i}} + \beta_{1}^{-1} P^{2} + \beta_{3} \delta_{i}^{2} I \Big) e + 2 e^{T} P D_{i} v - 2 e^{T} P D_{i} R_{i} \gamma_{i} \Big] + \\ &+ \sum_{i=1}^{M} \mu_{i}(\xi) \Big[ \beta_{1} (1 + \beta_{2}) \delta_{i}^{2} \hat{x}^{T} \hat{x} - 2 \alpha_{i}^{T} P e \Big], \end{split}$$

$$(2.18)$$

unde  $\beta_3 = \beta_1 (1 + \beta_2^{-1}).$ 

Folosind proprietățile inversei matricelor  $((XY)^{-1} = Y^{-1}X^{-1}, (X^T)^{-1} = (X^{-1})^T)$ , se demonstrează, pentru  $r \neq 0$ , cea de-a doua expresie (2.8); aceasta conduce la anularea celei de-a doua sume din inecuația (2.18). În consecință, se obține [5]

$$\dot{V} \leq \sum_{i=1}^{M} \mu_i(\xi) \Big[ e^T \Big( \overline{A_i}^T P + P \overline{A_i} + \beta_1^{-1} P^2 + \beta_3 \delta_i^2 I \Big) e + 2 e^T P D_i v - 2 e^T P D_i R_i \gamma_i \Big].$$
(2.19)

Utilizând acum a doua condiție de existență a observerului, adică  $C^T F_i^T = PD_i$ , rezultă

$$2e^{T}PD_{i}v - 2e^{T}PD_{i}R_{i}\gamma_{i} = 2\underbrace{e^{T}C^{T}}_{r^{T}}F_{i}^{T}v - 2\underbrace{e^{T}C^{T}}_{r^{T}}F_{i}^{T}\gamma_{i} = 2r^{T}F_{i}^{T}v - 2r^{T}F_{i}^{T}\gamma_{i}.$$
 (2.20)

Înlocuind în (2.20) pe  $\gamma_i$  cu expresia (2.8), rezultă [5]

$$2e^{T}PD_{i}v - 2e^{T}PD_{i}R_{i}\gamma_{i} = 2r^{T}F_{i}^{T}v - 2\rho \left\|F_{i}r\right\| < 0; \qquad (2.21)$$

s-au folosit  $\|v\| < \rho$  și  $\|r^T F_i^T\| = \|(F_i r)^T\| = \|F_i r\|$ . În aceste condiții, inegalitatea (2.19) devine

$$\dot{V} \leq \sum_{i=1}^{M} \mu_i(\xi) \Big[ e^T \Big( \overline{A}_i^T P + P \overline{A}_i + \beta_1^{-1} P^2 + \beta_3 \delta_i^2 I \Big) e \Big].$$
(2.22)

Același rezultat se obține și pentru r=0. Analizând expresia (2.22), se concluzionează că observerul multiplu este convergent ( $\dot{V} < 0$ ) și eroarea de estimare a stării converge asimptotic la zero dacă sunt îndeplinite condițiile (2.8) și (2.9). Cu alte cuvinte, rămâne de rezolvat inecuația matriceală

$$\overline{A}_{i}^{T}P + P\overline{A}_{i} + \beta_{1}^{-1}P^{2} + \beta_{1}(1 + \beta_{2}^{-1})\delta_{i}^{2}I < 0.$$
(2.23)

Ținând cont de (2.10), inecuația matriceală (2.9) este neliniară în raport P și  $G_i$ . Pentru rezolvarea sa prin metode specifice inecuațiilor matriceal-liniare (LMI), este nevoie de transformarea sa dintr-o inecuație neliniară într-una liniară; pentru aceasta, se utilizează tehnica schimbării de variabilă. Astfel, utilizând schimbarea de variabilă [5]

$$W_i = PG_i , \qquad (2.24)$$

inegalitatea (2.23) devine

$$A_i^T P + PA_i - C^T W_i^T - W_i C + \beta_1^{-1} P^2 + \beta_1 (1 + \beta_2^{-1}) \delta_i^2 I < 0$$
(2.25)

sau

$$\begin{bmatrix} A_i^T P + PA_i - C^T W_i^T - W_i C + \beta_1 (1 + \beta_2^{-1}) \delta_i^2 I & P \\ P & -\beta_1 I \end{bmatrix} < 0.$$
(2.26)

Echivalența inecuațiilor (2.25) și (2.26) s-a obținut ținând cont de lema Schur scrisă sub forma:  $\begin{bmatrix} Q & S \\ S^T & R \end{bmatrix} < 0$  dacă și numai dacă R < 0 și  $Q - SR^{-1}S^T < 0$ ; lema Schur a fost particularizată astfel:  $Q = A_i^T P + PA_i - C^T W_i^T - W_i C + \beta_1 (1 + \beta_2^{-1}) \delta_i^2 I$ , S = P,  $R = -\beta_1 I$ . Inecuația matriceal-liniară (2.26) se rezolvă în raport cu P și  $W_i$ ; apoi, prin intermediul ecuației (2.24), se determină  $G_i = P^{-1} W_i$ .

Schema bloc ce modelează ecuațiile (2.3), (2.5) și (2.9) este prezentată în fig. 2.1.

O problemă ce poate apărea în procesul de implementare a observerului multiplu (2.5) este asociată cazului când, deși  $r = y - \hat{y} \rightarrow 0$ ,  $\alpha_i$  și  $\gamma_i$  sunt nemărginite. În [5] este rezolvată această problemă astfel:  $\alpha_i$  și  $\gamma_i$  sunt nule când  $||r|| < \varepsilon$ , unde  $\varepsilon > 0$  este o constantă cu valori mici, aleasă de proiectantul estimatorului de stare.



Fig. 2.1. Schema bloc de modelare a observerului multiplu Akhenak

În acest caz, eroarea de estimare nu mai converge asimptotic la zero ci aproape de zero în funcție de valoarea aleasă pentru ε. Proiectarea observerului multiplu din [5] se face prin parcurgerea următorilor pași:

### Algoritmul Akhenak (varianta 1)

**Pasul 1**: Se declară matricele  $A_i, B_i, D_i, d_i, C, i = \overline{1, M}$ , limitele superioare  $\rho$  și  $\delta_i$ , și

se alege valoarea constantei pozitive  $\varepsilon$ . Se stabilesc expresiile vectorului de decizie  $\xi(t)$ și expresiile funcțiilor de activare  $\mu_i(\xi(t)), i = \overline{1, M}$ .

**Pasul 2**: Se aleg scalarii pozitivi  $\beta_1$  și  $\beta_2$  și se rezolvă inecuația matriceal-liniară (2.26) cu necunoscutele *P* și  $W_i$ ,  $i = \overline{1, M}$ .

**Pasul 3**: Pentru fiecare  $i = \overline{1, M}$ , se calculează  $G_i = P^{-1}W_i$  și apoi se verifică dacă matricele  $\overline{A}_i = A_i - G_i C$  sunt stabile.

**Pasul 4**: Se calculează  $F_i$  din ecuația (2.9) după cum urmează  $F_i = (PD_i)^T C^+$ . În continuare, utilizând ecuațiile (2.8), se determină vectorii  $\gamma_i$  (cu rol de compensare a erorilor datorate intrărilor necunoscute) și  $\alpha_i$  (cu rol de compensare a erorilor datorate incertitudinilor sistemului).

**Pasul 5**: Utilizând matricele și vectorii calculați la pașii 3 și 4, se proiectează observerul descris de ecuațiile (2.5); pentru validarea estimatorului de stare, se utilizează și ecuațiile ce descriu dinamica modelului multiplu (ecuațiile de stare - ieșire (2.3)).

# 2.1.3. VALIDAREA OBSERVERULUI MULTIPLU AKHENAK

Observerul Akhenak este validat în Matlab/Simulink; a fost aleasă, pentru validarea observerului, mișcarea longitudinală a unei aeronave, dinamica acesteia fiind descrisă de ecuațiile (2.3) în care

$$A_{1} = \begin{bmatrix} -0.007 \ 0.012 \ -9.81 \ 0 \\ -0.128 \ -0.54 \ 0 \ 1 \\ 0 \ 0 \ 0 \ 1 \\ 0.065 \ 0.96 \ 0 \ -0.99 \end{bmatrix}, B_{1} = \begin{bmatrix} 0 \\ -0.04 \\ 0 \\ -12.5 \end{bmatrix}, D_{1} = \begin{bmatrix} 0.25 \\ 0.25 \\ 0.25 \\ 0.25 \end{bmatrix}, d_{1} = \begin{bmatrix} 0.2 \\ 0.2 \\ 0.2 \\ 0.2 \end{bmatrix}, d_{1} = \begin{bmatrix} 0.2 \\ 0.2 \\ 0.2 \\ 0.2 \end{bmatrix}, d_{1} = \begin{bmatrix} 0.2 \\ 0.2 \\ 0.2 \\ 0.2 \end{bmatrix}, d_{1} = \begin{bmatrix} 0.2 \\ 0.2 \\ 0.2 \\ 0.2 \end{bmatrix}, d_{1} = \begin{bmatrix} 0.2 \\ 0.2 \\ 0.2 \\ 0.2 \end{bmatrix}, d_{2} = \begin{bmatrix} 0.2 \\ 0.2 \\ 0.2 \\ 0.2 \end{bmatrix}, d_{2} = \begin{bmatrix} 0.3 \\ 0.3 \\ 0.3 \\ 0.3 \\ 0.3 \end{bmatrix}, d_{2} = \begin{bmatrix} 0.3 \\ 0.3 \\ 0.3 \\ 0.3 \\ 0.3 \end{bmatrix}, d_{2} = \begin{bmatrix} 0.3 \\ 0.3 \\ 0.3 \\ 0.3 \\ 0.3 \end{bmatrix}, d_{2} = \begin{bmatrix} 0.3 \\ 0.3 \\ 0.3 \\ 0.3 \\ 0.3 \end{bmatrix}, d_{2} = \begin{bmatrix} 1 \ 0 \ 0 \ 0 \\ 0 \ 1 \ 0 \ 0 \end{bmatrix}.$$

Vectorul intrărilor necunoscute v a fost ales aleatoriu; pentru matricele de mai sus, au rezultat M = 2, n = 4, m = q = 1, p = 2. Funcția de decizie și funcțiile de activare au fost alese de forma:  $\xi(t) = u(t)$ ,  $\mu_1(\xi(t)) = 0.5(1 - \tanh(\xi(t)))$ ,  $\mu_2(\xi(t)) = 0.5(1 + \tanh(\xi(t)))$ . Așa cum se observă din ecuația (2.27), s-a considerat că incertitudinile  $\Delta A_1$  și  $\Delta A_2$  reprezintă variații de 1% ale matricelor  $A_1$  și  $A_2$ . Marginile superioare  $\delta_i$  sunt superioare normelor variațiilor  $\Delta A_1$  și  $\Delta A_2$ ; s-au obținut  $\delta_1 = \delta_2 = 0.1$ . Eroarea maximă de convergență a erorii a fost aleasă  $\varepsilon = 0.25$ . Într-o primă fază, se aleg  $\beta_1 = \beta_2 = 0.5$ , după care, aceste valori se micșorează pentru a analiza influența acestor constante asupra vitezei de convergență a observerului multiplu Akhenak.

Rezolvarea inecuației matriceal-liniare (2.26) se face în Matlab/Simulink, în raport cu necunoscutele P și  $W_i$ , i=1, 2, utilizând LMI tool (instrucțiuniele *setlmis*, *newlmi*, *lmivar*, *lmiterm*, *getlmis*, *feasp* și *dec2mat*); s-au obținut matricele

$$P = \begin{bmatrix} 0.279 & 0 & 0.042 & 0.029 \\ 0 & 0.279 & -0.003 & -0.027 \\ 0.042 & -0.003 & 0.273 & -0.024 \\ 0.029 & -0.027 & -0.024 & 0.333 \end{bmatrix}, W_1 = \begin{bmatrix} 0.424 & -0.016 \\ 0.01 & 0.247 \\ -2.738 & -0.021 \\ 0.038 & 0.639 \end{bmatrix}, W_2 = \begin{bmatrix} 0.512 & 0 \\ -0.001 & 0.337 \\ -2.742 & -0.027 \\ 0.032 & 0.735 \end{bmatrix}.$$
(2.28)

Apoi, în cadrul pașilor 3 și 4, se determină matricele  $G_1 = P^{-1}W_1$ ,  $G_2 = P^{-1}W_2$ ,  $F_1 = (PD_1)^T C^+$  și  $F_2 = (PD_2)^T C^+$ ;

$$G_{1} = \begin{bmatrix} 3.245 & -0.296 \\ -0.173 & 1.090 \\ -10.625 & 0.164 \\ -0.969 & 2.043 \end{bmatrix}, G_{2} = \begin{bmatrix} 3.579 & -0.271 \\ -0.219 & 1.444 \\ -10.700 & 0.171 \\ -1.025 & 2.358 \end{bmatrix}; F_{1}^{T} = \begin{bmatrix} 0.087 \\ 0.062 \end{bmatrix}, F_{2}^{T} = \begin{bmatrix} 0.114 \\ 0.133 \end{bmatrix}.$$
(2.29)

Matricele  $F_1$  și  $F_2$  sunt apoi folosite pentru calculul termenilor compensatori  $\gamma_i$ , în timp ce, pentru calculul termenilor compensatori  $\alpha_i$ , se utilizează semnalele  $r(t), \hat{x}(t)$ , precum și matricele P și C; s-au obținut caracteristicilor de timp din fig. 2.2 și fig. 2.3.



Fig. 2.2. Erorile de estimare ale observerului Akhenak (intrare aleatoare)

Parcurgerea paşilor algoritmului se face pentru două cazuri: intrarea aleatoare (fig. 2.2) și intrare de tipul  $u = -K\hat{x}$  (fig. 2.3), unde *K* este matricea de amplificare determinată printr-un algoritm optimal (de exemplu algoritmul ALGLX [140]). În fig. 2.2 sunt reprezenate grafic erorile de estimare ale observerului multiplu Akhenak (cazul 1: intrarea *u* de tip aleator) pentru 4 valori ale constantelor de proiectare  $\beta_1$  și  $\beta_2$  ( $\beta_1=\beta_2=$ 0.2,  $\beta_1=\beta_2=0.15$ ,  $\beta_1=\beta_2=0.1$ ,  $\beta_1=\beta_2=0.05$ ); se observă că alegerea acestor două constante influentează viteza de convergență a observerului multiplu. Cu cât se aleg valori mai mici pentru constantele pozitive  $\beta_1$  și  $\beta_2$ , cu atât viteza de convergență a observerului scade. Același lucru se observă și analizând fig. 2.3 (erorile de estimare ale observerului Akhenak pentru intrare de tipul  $u = -K\hat{x}$ ).

În fig. 2.4 sunt reprezentate grafic variabilele de stare  $x_i(t)$  – cu linie continuă și variabilele de stare estimate  $\hat{x}_i(t)$  – cu linie întreruptă asociate observerului Akhenak pentru  $\beta_1=\beta_2=0.2$  și intrare de tipul  $u = -K\hat{x}$ . În figurile 2.2-2.4 se observă anularea erorilor de estimare a variabilelor de stare, deci o bună funcționare a observerului mul-

tiplu de tip Akhenak. Singurul dezavantaj îl constituie suprareglajele mari; motivul este legat de necunoașterea valorilor inițiale ale variabilelor de stare, aceste valori inițiale fiind alese de autorii lucrării. O îmbunătățire a suprareglajului și a vitezei de convergență se poate obține micșorând constantele de proiectare  $\beta_1$  și  $\beta_2$  și modificând expresiile funcției de decizie și funcțiilor de activare.



Fig. 2.3. Erorile de estimare ale observerului Akhenak (intrare de tipul  $u = -K\hat{x}$ )



Fig. 2.4. Variabilele de stare  $x_i(t)$  și variabilele de stare estimate  $\hat{x}_i(t)$ 

# **2.2. OBSERVERUL MULTIMPLU JAMEL**

Un alt observer multiplu ce permite estimarea stării unui sistem neliniar este prezentat în [96]; sistemului neliniar, pentru care se proiectează observerul multiplu, îi corespunde un model multiplu Takagi-Sugeno, acesta fiind influențat de necunoscute de modelare (incertitudini) și de intrări necunoscute.

Există două structuri pentru modelele multiple în funcție de conexiunea ce există între modelele locale. Pentru primul dintre acestea, modelele locale au același vector de stare și, în consecință, modelul multiplu, numit și model multiplu Takagi-Sugeno, se compune din submodele omogene [103]. Pentru cel de-al doilea tip de model multiplu, modelele locale nu au aceeași stare și modelul multiplu folosește modele locale heterogene. Dintre cele două tipuri de modele multiple, primul este mai utilizat; acesta a fost propus de Takagi & Sugeno [200] în cadrul modelării fuzzy și de către Johansen & Foss [104] în cadrul modelării ce utilizează noțiunea de model multiplu.

### 2.2.1. STRUCTURA MODELULUI MULTIPLU TAKAGI-SUGENO

Reprezentarea modelului multiplu de tip Takagi-Sugeno se face prin intermediul următoarelor ecuații

$$\begin{cases} \dot{x}(t) = \sum_{i=1}^{M} \mu_i(\xi(t)) [A_i x(t) + B_i u(t) + d_i], \\ y(t) = \sum_{i=1}^{M} \mu_i(\xi(t)) [C_i x(t) + E_i u(t) + N_i], \end{cases}$$
(2.30)

unde semnificațiile vectorilor  $x(t), u(t), \xi(t), d_i$ , ale matricelor  $A_i, B_i$  și ale funcțiilor de activare  $\mu_i$  sunt aceleași ca în cazul ecuațiilor (2.1); dacă  $E_i = N_i$ , ieșirea sistemului este liniară, adică [96]:  $C_1 = C_2 = \cdots = C_M = C$  și ecuațiile ce descriu dinamica modelului multiplu sunt de tipul (2.1). Ca și în cazul observerului multiplu proiectat în [5],  $x(t) \in \mathcal{M}^{n \times 1}, u(t) \in \mathcal{M}^{n \times 1}, y(t) \in \mathcal{M}^{p \times 1}, A_i \in \mathcal{M}^{n \times n}, B_i \in \mathcal{M}^{n \times m}, C \in \mathcal{M}^{p \times n}$ , iar M este numărul modelelor locale, acesta depinzând de precizia de modelare și de complexitatea sistemului neliniar. Matricele  $A_i$ ,  $B_i$ , C și vectorii  $d_i$  pot fi obținuți prin liniarizarea directă a modelului neliniar în jurul câtorva puncte de funcționare (operare) sau prin utilizarea procedurii de identificare [3], [105]. Funcțiile de activare  $\mu_i(\xi(t))$ ,  $i = \overline{1, M}$ , cuantifică contribuția relativă a fiecărui model local la modelul multiplu; aceste funcții sunt neliniare în raport cu  $\xi(t)$  și verifică condițiile (2.2). Expresiile funcțiilor de activare pot fi [96]

$$\mu_i(\xi(t)) = \frac{\omega_i(\xi(t))}{\sum_{j=1}^M \omega_j(\xi(t))},$$
(2.31)

unde

$$\omega_{i}(\xi(t)) = \exp\left[\frac{-\xi(t) - (\xi(t)^{(i)})^{2}}{\sigma^{2}}\right]; \qquad (2.32)$$

vectorul de decizie  $\xi(t)$  este accesibil în timp real și depinde de intrările și de ieșirile sistemului în cauză, adică  $\xi(t) = f(u(t), y(t))$ .

În continuare, este prezentată o nouă structură de observer multiplu pentru modelele multiple afectate de intrări necunoscute (ecuațiile (2.3)).

# 2.2.2. PROIECTAREA OBSERVERULUI MULTIPLU

Se consideră modelul multiplu afectat de intrări necunoscute  $(v(t) \in \mathcal{M}^{q \times 1})$ , a cărui dinamică este [96]

$$\begin{cases} \dot{x}(t) = \sum_{i=1}^{M} \mu_i(\xi(t)) [A_i x(t) + B_i u(t) + Dv(t) + d_i], \\ y(t) = C x(t); \end{cases}$$
(2.33)

s-a considerat, față de dinamica (2.3), că  $D_1 = D_2 = \cdots = D_M = D$ .

Fie observerul multiplu [96]

$$\begin{cases} \dot{z}(t) = \sum_{i=1}^{M} \mu_i(\xi(t)) [N_i z(t) + G_{i1} u(t) + G_{i2} + L_i y(t)], \\ \hat{x}(t) = z(t) - Ey(t), \end{cases}$$
(2.34)

unde  $N_i \in \mathcal{M}^{n \times n}, G_{i1} \in \mathcal{M}^{n \times m}, L_i \in \mathcal{M}^{n \times p}$  (amplificarea observerului local "*i*"),  $G_{i2} \in \mathcal{M}^{n \times 1}$ este un vector constant, iar  $E \in \mathcal{M}^{n \times p}$  – matrice de transformare. Matricele  $N_i, G_{i1}$  $L_i, E$  și vectorii  $G_{i2}$  trebuie determinați astfel încât vectorul de stare estimat  $\hat{x}(t)$  să tindă către x(t). Pentru uşurința notației, în continuare, se omite dependența de timp (*t*).

Se consideră eroarea observerului multiplu  $e = x - \hat{x}$ , care se exprimă, utilizând ecuațiile (2.34) și notația Q=I+EC, după cum urmează [96]

$$e = x - \hat{x} = x - z + ECx = Qx - z.$$
 (2.35)

Dinamica erorii observerului este [96]

$$\dot{e} = \sum_{i=1}^{M} \mu_i(\xi) [N_i e + (QA_i - N_i - K_i C)x] + \sum_{i=1}^{M} \mu_i(\xi) [(QB_i - G_{i1})u + QDv + Qd_i - G_{i2}], (2.36)$$

în care  $K_i = N_i E + L_i$ . Analizând dinamica (2.36) și având în vedere notațiile utilizate până acum, adică

$$Q = I + EC, K_i = N_i E + L_i, \qquad (2.37)$$

dinamica (2.36) se reduce la

$$\dot{e} = \sum_{i=1}^{M} \mu_i(\xi) N_i e$$
(2.38)

dacă și numai dacă sunt îndeplinite simultan condițiile [96]

$$QA_i - N_i - K_i C = 0, QD = 0, Qd_i - G_{i2} = 0, QB_i - G_{i1}.$$
 (2.39)

Dacă, în plus,

$$\widetilde{N} = \sum_{i=1}^{M} \mu_i(\xi) N_i$$
(2.40)

este o matrice stabilă, eroarea estimatorului de stare tinde la zero.

În continuare, se derivează funcția Lyapunov (2.12) și rezultă

$$\dot{V} = \sum_{i=1}^{M} \mu_i(\xi) e^T (N_i^T P + P N_i) e; \qquad (2.41)$$

 $\dot{V} < 0$ , deci convergența la zero a erorii observerului multiplu este garantată dacă sunt îndeplinite simultan condițiile (2.37) și (2.39) și, în plus, există o matrice simetrică și pozitiv definită *P* astfel încât,  $(\forall)i = \overline{1,M}$ ,

$$N_i^T P + P N_i < 0. (2.42)$$

Sintetizând, eroarea observerului multiplu (2.34) tinde la zero, dacă  $(\forall)i = \overline{1, M}$ , perechile  $(A_i, C)$  sunt observabile, matricea (2.40) este stabilă și sunt îndeplinite simultan condițiile [96]

$$\begin{cases} N_i^T P + PN_i < 0, N_i = QA_i - K_i C, \\ Q = I + EC, QD = 0, L_i = K_i - N_i E, \\ G_{i1} = QB_i, G_{i2} = Qd_i. \end{cases}$$
(2.43)

Rezolvarea sistemului de ecuații (2.43), pentru determinarea matricelor  $Q, E, K_i$ ,  $P, N_i, L_i, G_{i1}$  și a vectorilor  $G_{i2}$ , se face în 3 etape după cum urmează:

# <u>Etapa 1:</u>

Din ecuațiile 3 și 4 ale sistemului (2.43), dacă rang(CD) = rang(D), se obține [96]

$$E = -D(CD)^{+} + H_0 \Big[ I - (CD)(CD)^{+} \Big], \qquad (2.44)$$

sau, pentru  $H_0 = 0_{n \times p}$ ,

$$E = -D(CD)^+;$$
 (2.45)

cu aceasta, se determină expresia matricei Q

$$Q = I + EC = I - D(CD)^{+}C.$$
 (2.46)

### Etapa 2:

Din primele trei relații (2.43) se obține [96]

$$(QA_i - K_iC)^T P + P(QA_i - K_iC) < 0, i = \overline{1, M};$$
 (2.47)

inecuația matriceală (2.47) este neliniară în raport cu necunoscutele P și  $K_i$ . Pentru rezolvarea sa prin metode specifice inecuațiilor matriceal-liniare (LMI), este nevoie de transformarea sa într-o inecuație liniară, pentru aceasta utilizându-se metoda schimbării de variabilă. Astfel, utilizând schimbarea de variabilă  $W_i = PK_i$ , se obține

$$(QA_i)^T P + P(QA_i) - C^T W_i^T - W_i C < 0$$
(2.48)

sau

$$\begin{bmatrix} (QA_i)^T P + P(QA_i) - C^T W_i^T - W_i C & 0\\ 0 & -I \end{bmatrix} < 0.$$
 (2.49)

Echivalența inecuațiilor (2.48) și (2.49) s-a obținut ținând cont de lema Schur scrisă sub forma:  $\begin{bmatrix} \widetilde{Q} & \widetilde{S} \\ \widetilde{S}^T & \widetilde{R} \end{bmatrix} < 0$  dacă și numai dacă  $\widetilde{R} < 0$  și  $\widetilde{Q} - \widetilde{S}\widetilde{R}^{-1}\widetilde{S}^T < 0$ ; lema Schur a fost particularizată astfel:  $\widetilde{Q} = (QA_i)^T P + P(QA_i) - C^T W_i^T - W_i C$ ,  $\widetilde{S} = 0$ ,  $\widetilde{R} = -I$ . Inecuația matriceal-liniară (2.49) se rezolvă în raport cu P și  $W_i$  și apoi se determină matricele

$$K_i = P^{-1} W_i . (2.50)$$

### <u>Etapa 3:</u>

Cunoscând matricele E (ecuația (2.45)), Q (ecuația (2.46)) și  $K_i$  (ecuația (2.50)), din a doua ecuație (2.43) se obțin  $N_i$ ,  $i = \overline{1, M}$ ; din a 5-a ecuație se calculează  $L_i$ ,  $i = \overline{1, M}$ , iar din ultimele două ecuații (2.43) se determină matricele  $G_{i1}$  și vectorii  $G_{i2}$ ,  $i = \overline{1, M}$ .

Schema bloc ce modelează ecuațiile (2.33) și (2.34) este prezentată în fig. 2.5; proiectarea observerului multiplu Jamel se face prin parcurgerea următorilor pași:

### **Algoritmul Jamel**

**Pasul 1**: Se declară matricele  $A_i, B_i, d_i, C, D, i = \overline{1, M}$  și se stabilesc expresiile vectorului

de decizie  $\xi(t)$  și expresiile funcțiilor de activare  $\mu_i(\xi(t)), i = \overline{1, M}$ .

**Pasul 2**: Se determină matricele Q și E utilizând ecuațiile (2.45) și (2.46).

**Pasul 3**: Se rezolvă inecuația matricel-liniară (2.49) în raport cu necunoscutele P și  $W_i$ , și, pentru fiecare  $i = \overline{1, M}$ , se calculează  $K_i = P^{-1}W_i$ .

**Pasul 4**: Se calculează matricele  $N_i$  din a doua ecuație (2.43),  $L_i$  - a 5-a ecuație (2.43),  $G_{i1}, G_{i2}$  – ultimele două ecuații (2.43).

**Pasul 5**: Se verifică dacă matricea  $\tilde{N}$  (expresia (2.40)) este stabilă și, de asemenea, se verifică dacă toate condițiile (2.43) sunt verificate.

**Pasul 6**: Utilizând matricele și vectorii calculați la pașii 4 și 5, se proiectează observerul descris de ecuațiile (2.34); pentru validarea estimatorului de stare, se utilizează și ecuațiile ce descriu dinamica modelului multiplu (ecuațiile de stare – ieșire (2.33)).



Fig. 2.5. Schema bloc de modelare a observerului multiplu Jamel

# 2.2.3. CREȘTEREA ROBUSTEȚEI OBSERVERULUI MULTIPLU

Dacă modelul multiplu este afectat de necunoscute de modelare (incertitudini),

dinamica sa este reprezentată prin intermediul următoarelor ecuații [96]

$$\begin{cases} \dot{x}(t) = \sum_{i=1}^{M} \mu_i(\xi(t)) [(A_i \pm \Delta A_i) x(t) + (B_i \pm \Delta B_i) u(t) + d_i], \\ y(t) = Cx(t) \end{cases}$$
(2.51)

sau

$$\begin{cases} \dot{x}(t) = \sum_{i=1}^{M} \mu_i(\xi(t)) [A_i \ x(t) + B_i u(t) + \overline{u}_i(t) + d_i], \\ y(t) = C x(t), \end{cases}$$
(2.52)

unde

$$\overline{u}_i(t) = \pm \Delta A_i \ x(t) \pm \Delta B_i \ u(t); \tag{2.53}$$

 $\Delta A_i$  reprezintă matricele incertitudinilor de modelare, iar  $\Delta B_i$  – incertitudinile legate de intrările sistemului.

În [96], pentru cazul modelului multiplu afectat de incertitudini, estimarea stării se face considerând vectorii  $\overline{u}_i(t)$ , formați din erorile de modelare și erorile de intrare, ca vectori asociați intrărilor necunoscute. În acest caz, dinamica (2.26) este de tipul (2.33) cu modificările:  $D \rightarrow I_{n \times q}, v(t) \rightarrow \overline{u}_i(t)$ ; rezultatele obținute mai sus rămân valabile cu modificările tocmai menționate.

O altă metodă de estimare a stării în condițiile modelului multiplu afectat de incertitudini este descrisă pe scurt în continuare [96]. Se consideră dinamica (2.51) și observerul multiplu (2.34); dinamica erorii devine în acest caz

$$\dot{e} = \sum_{i=1}^{M} \mu_i(\xi) [N_i e + (QA_i - N_i - K_i C)x] + \sum_{i=1}^{M} \mu_i(\xi) [(QB_i - G_{i1})u + Q\overline{u}_i + Qd_i - G_{i2}].$$
(2.54)

Dacă sunt îndeplinite simultan condițiile

$$Q = I + EC, N_i = QA_i - K_iC, L_i = K_i - N_iE, G_{i1} = QB_i, G_{i2} = Qd_i$$
(2.55)

și matricea (2.40) este stabilă, dinamica erorii estimatorului de stare este

$$\dot{e} = \sum_{i=1}^{M} \mu_i(\xi) (N_i e + Q \,\overline{u}_i).$$
(2.56)

Se consideră din nou funcția Lyapunov (2.12) și se calculează  $\dot{V}(t)$ . Problema proiectării observerului multiplu robust pentru estimarea stării și defectelor constă în determinarea matricelor  $Q, E, K_i, P, N_i, L_i, G_{i1}, G_{i2}$  astfel încât, pentru  $\overline{u}_i(t) = 0$ , eroarea de estimare să fie nulă  $\Leftrightarrow \lim_{t \to \infty} e(t) = 0$  și, pentru  $\overline{u}_i(t) \neq 0$ , eroarea de estimare a stării să fie mărginită, adică

$$\| e(t) \| Q_e \leq \lambda \| \overline{u}_i(t) \| Q_u , \qquad (2.57)$$

unde  $\lambda > 0$  se numește nivel de atenuare, iar  $Q_e$  și  $Q_u$  sunt 2 matrice pozitiv definite. Pentru a satisface condiția  $\lim_{t \to \infty} e(t) = 0$ , este suficientă determinarea funcției Lyapunov V(t) astfel încât [96]

$$\dot{V}(t) + e^{T}(t)Q_{e}e(t) - \lambda^{2}\overline{u}_{i}^{T}(t)Q_{u}(t)\overline{u}_{i}(t) < 0; \qquad (2.58)$$

conform [117], inegalitatea (2.58) se scrie sub forma

$$\psi^T(t)\Omega\,\psi(t) < 0\,,\tag{2.59}$$

cu

$$\psi(t) = \begin{bmatrix} e(t) \\ \overline{u}_i(t) \end{bmatrix}, \Omega = \begin{bmatrix} N_i^T P + P N_i + Q_e & P Q \\ Q^T P & -\lambda^2 Q_u \end{bmatrix}.$$
 (2.60)

Inegalitatea (2.59) este adevărătă dacă  $\Omega < 0$ ; cu alte cuvinte, este nevoie de rezolvarea inecuației matriceal-neliniare

$$\begin{bmatrix} N_i^T P + P N_i + Q_e & P Q \\ Q^T P & -\lambda^2 Q_u \end{bmatrix} < 0.$$
(2.61)

Ținând cont de a doua ecuație (2.55) și utilizând notațiile  $W_i = PK_i$ ,  $n = \lambda^2$ , inecuația (2.61) se transformă în inecuația matriceal-liniară

$$\begin{bmatrix} (QA_i)^T P + P(QA_i) - C^T W_i^T - W_i C + Q_e & PQ \\ Q^T P & -mQ_u \end{bmatrix} < 0, \qquad (2.62)$$

inecuație ușor revolvabilă utilizând LMI tool. Prin rezolvarea acesteia, se determină  $W_i$ , P și m; apoi, se determină ușor  $K_i$  cu ecuația (2.50). Determinarea celorlalte matrice necunoscute din ecuațiile observerului robust se face rezolvând ecuațiile (2.55).

# 2.2.4. VALIDAREA OBSERVERULUI MULTIPLU

Observerul Jamel este validat în Matlab/Simulink; a fost aleasă, pentru validarea observerului, mișcarea longitudinală a unei aeronave, dinamica acesteia fiind descrisă de ecuațiile (2.3) și (2.27), cu modificarea  $D_1 = D_2 = D = \begin{bmatrix} 0.5 & 0.5 & 0.5 & 0.5 \end{bmatrix}^T$ . Validarea observerului se face pentru două cazuri: 1) dinamica modelului multiplu fără necunoscute de modelare (incertitudini) dar cu intrări necunoscute (modelulul multiplu (2.33)); 2) dinamica modelului multiplu cu necunoscute de modelare, acestea fiind interpretate ca intrări necunoscute (modelulul multiplu (2.52)). Pentru primul caz, vectorul intrărilor necunoscute v a fost ales aleatoriu; pentru matricele de mai sus, au rezultat M=2, n=4, m=q=1, p=2. Funcția de decizie și funcțiile de activare au fost alese de forma

$$\begin{aligned} \xi(t) &= u(t), \\ \mu_1(\xi(t)) &= 1.2 \left( 1 - \tanh(\xi(t)) \right), \\ \mu_2(\xi(t)) &= 1 - \mu_1(\xi(t)), \end{aligned}$$
(2.63)

însă, la fel de bine, ele puteau fi descrise de ecuațiile (2.31) și (2.32). Pentru cazul al doilea de simulare, s-a considerat că incertitudinile  $\Delta A_1, \Delta A_2, \Delta B_1, \Delta B_2$  reprezintă variații de 5% ale matricelor  $A_1, A_2, B_1$  și  $B_2$ ; în primul caz de simulare, aceste incertitudini sunt nule. Creșterea robusteței observerului multiplu (2.34) se face utilizând prima metodă prezentată anterior deoarece aceasta are mulți pași comuni cu algoritmul Jamel pentru cazul fără incertitudini. Rezolvarea inecuației matriceal-liniare (2.49) se face în Matlab/Simulink, în raport cu necunoscutele P și  $W_i$ , i=1, 2, prin intermediul instrucțiunilor: *setlmis, newlmi, lmivar, lmiterm, getlmis, feasp* și *dec2mat*.

Pentru cazul 1 de simulare (dinamică fără incertitudini) s-au obținut matricele

$$\mathcal{Q} = \begin{bmatrix} 0.5 & -0.5 & 0 & 0 \\ -0.5 & 0.5 & 0 & 0 \\ -0.5 & -0.5 & 1 & 0 \\ -0.5 & -0.5 & 0 & 1 \end{bmatrix}, \\ \mathcal{E} = \begin{bmatrix} -0.5 & -0.5 \\ -0.5 & -0.5 \\ -0.5 & -0.5 \\ -0.5 & -0.5 \end{bmatrix}, \\ \mathcal{P} = \begin{bmatrix} 1.051 & -0.000 & 0.229 & 0.064 \\ -0.000 & 1.051 & -0.229 & -0.064 \\ 0.229 & -0.229 & 0.591 & -0.235 \\ 0.064 & -0.064 & -0.235 & 0.284 \end{bmatrix}, \\ \mathcal{W}_1 = \begin{bmatrix} 0.613 & 7.375 \\ -7.033 & 0.096 \\ -3.678 & 3.710 \\ -0.476 & 0.828 \end{bmatrix}, \\ \mathcal{W}_2 = \begin{bmatrix} 0.957 & -0.070 \\ 0.500 & 0.419 \\ -3.691 & 3.677 \\ -0.503 & 0.934 \end{bmatrix}, \\ \mathcal{K}_1 = \begin{bmatrix} 7.957 & 4.081 \\ -14.065 & 3.026 \\ -25.913 & 10.308 \\ -28.061 & 11.193 \end{bmatrix}, \\ \mathcal{K}_2 = \begin{bmatrix} 5.957 & -5.673 \\ -4.570 & 6.005 \\ -17.824 & 19.505 \\ -18.876 & 22.040 \end{bmatrix}, \\ \mathcal{N}_1 = \begin{bmatrix} -7.896 & -3.805 & -4.905 & -0.500 \\ 14.004 & -3.302 & 4.905 & 0.500 \\ 25.980 & -10.044 & 4.905 & 0.500 \\ 26.02 & -2.545 & 4.905 & -2.000 \end{bmatrix},$$

în timp ce, pentru cazul 2 de simulare (dinamică cu incertitudini) au rezultat matricele

$$\begin{split} & \mathcal{Q} = \begin{bmatrix} 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}, E = \begin{bmatrix} -1 & 0 \\ 0 & 0 \\ 0 & 0 \\ 0 & 0 \end{bmatrix}, P = 10^8 \begin{bmatrix} 3.402 & 0.129 & -0.064 & -0.036 \\ 0.129 & 3.842 & -1.482 & -1.162 \\ -0.064 & -1.482 & 2.019 & 0.541 \\ -0.036 & -1.162 & 0.541 & 4.503 \end{bmatrix}, W_1 = 10^8 \begin{bmatrix} 3.529 & -0.104 \\ -0.104 & 2.677 \\ 0.225 & 1.320 \\ 0.104 & 1.896 \end{bmatrix}, W_2 = 10^8 \cdot \begin{bmatrix} 5.053 & -0.126 \\ -0.126 & 3.965 \\ 0.233 & 1.392 \\ 0.145 & 2.337 \end{bmatrix}, K_1 = \begin{bmatrix} 1.040 & -0.051 \\ -0.005 & 1.497 \\ 0.137 & 1.586 \\ 0.013 & 0.616 \end{bmatrix}, K_2 = \begin{bmatrix} 1.488 & -0.069 \\ -0.022 & 2.037 \\ 0.140 & 1.966 \\ 0.021 & 0.807 \end{bmatrix}, \\ N_1 = \begin{bmatrix} -1.040 & 0.051 & 0 & 0 \\ -0.122 & -2.037 & 0 & 1 \\ -0.137 & -1.586 & 0 & 1 \\ 0.051 & 0.343 & 0 & -0.990 \end{bmatrix}, N_2 = \begin{bmatrix} -1.488 & 0.069 & 0 & 0 \\ -0.105 & -2.637 & 0 & 1 \\ -0.140 & -1.966 & 0 & 1 \\ 0.078 & 0.392 & 0 & -1.5 \end{bmatrix}, L_1 = \begin{bmatrix} 0 & -0.051 \\ -0.128 & 1.497 \\ 0 & 1.586 \\ 0.065 & 0.616 \end{bmatrix}, \\ L_2 = \begin{bmatrix} 0 & -0.069 \\ -0.128 & 2.037 \\ 0 & 1.966 \\ 0..1 & 0.807 \end{bmatrix}, G_{11} = \begin{bmatrix} 0 \\ -0.04 \\ 0 \\ -12.5 \end{bmatrix}, G_{21} = \begin{bmatrix} 0 \\ -0.1 \\ 0 \\ -10.8 \end{bmatrix}, G_{11} = \begin{bmatrix} 0 \\ 0.2 \\ 0.2 \\ 0.2 \end{bmatrix}, G_{21} = \begin{bmatrix} 0 \\ 0.3 \\ 0.3 \\ 0.3 \\ 0.3 \end{bmatrix}. \end{split}$$

S-au obținut caracteristicile de timp din fig. 2.6 – erorile  $e_i(t) = \hat{x}_i(t) - x_i(t)$ ; în

primul dintre cele două grafice 2.6 sunt prezentate erorile de estimare asociate vectorului de stare pentru primul caz de simulare (model multiplu fără incertitudini), în timp ce în cel de-al doilea grafic 2.6 sunt prezentate erorile de estimare asociate vectorului de stare pentru al doilea caz de simulare (model multiplu cu incertitudini).



Fig. 2.6. Erorile de estimare ale observerului Jamel (cu și fără incertitudini)

Un alt observer multiplu ce permite estimarea stării unui sistem neliniar este prezentat în [7]; sistemului neliniar, pentru care se proiectează observerul multiplu, îi corespunde modelul multiplu Takagi-Sugeno (2.33), observerul asociat acestuia fiind descris de ecuațiile (2.34). Autorii lucrării [7] folosesc același observer multiplu pentru estimarea stării, diferența fiind făcută de modul în care se determină matricele P și  $K_i$ , precum și de modul în care se verifică stabilitatea matricei (2.40). Astfel, utilizând din nou notația Q=I+EC, în [7] se arată că eroarea observerului (ecuația (2.35)) tinde la zero dacă sunt îndeplinite simultan condițiile (2.43) și dacă este asigurată stabilitatea matricei  $\tilde{N}$  (expresia (2.40)). În [96], determinarea matricelor P și  $K_i$  se face prin rezolvarea inecuației matriceale (2.42), care, utilizând a doua ecuație (2.43) și notația  $W_i=PK_i$ , conduce la inecuația matriceal-liniară (2.49) - inecuație cu necunoscutele P și  $W_i$ . În cadrul lucrărilor [7] și [31], se arată că rezolvarea inecuației (2.42) este echivalentă cu rezolvarea inecuației

$$\frac{1}{2} \left( N_i + N_i^T \right) P + \frac{1}{2} P \left( N_i + N_i^T \right) < 0, \qquad (2.64)$$

care, prin înlocuirea matricelor  $N_i$  cu  $QA_i - K_iC$ , conduce la

$$\frac{1}{2}\left[\left(QA_{i}-K_{i}C\right)+\left(QA_{i}-K_{i}C\right)^{T}\right]P+\frac{1}{2}P\left[\left(QA_{i}-K_{i}C\right)+\left(QA_{i}-K_{i}C\right)^{T}\right]<0.$$
 (2.65)

Inecuația (2.65) este neliniară în raport cu P și  $W_i$ ; în locul utilizării notației  $W_i = PK_i$ , pentru a transforma inecuația într-una liniară, se poate folosi procedura din [31]. Procedura se bazează pe liniarizarea în jurul unor valori inițiale  $K_{0i}$  și  $P_0$ . Astfel [7],

$$K_{i} = K_{0i} + \Delta K_{i}, P = P_{0} + \Delta P_{i}; \qquad (2.66)$$

cu acestea, inecuația (2.65) conduce la sistemul de inecuații

$$\begin{cases} \frac{1}{2} \left\{ \left[ QA_{i} - \left(K_{0i} + \Delta K_{i}\right)C \right] + \left[ QA_{i} - \left(K_{0i} + \Delta K_{i}\right)C \right]^{T} \right\} (P_{0} + \Delta P) + \\ + \frac{1}{2} (P_{0} + \Delta P) \left\{ \left[ QA_{i} - \left(K_{0i} + \Delta K_{i}\right)C \right] + \left[ QA_{i} - \left(K_{0i} + \Delta K_{i}\right)C \right]^{T} \right\} < 0, \qquad (2.67)\\ P_{0} + \Delta P > 0. \end{cases}$$

În continuare, negljijând termenii de ordinul 2, prima inecuație (2.67) devine

$$\left[ \left( QA_{i} - K_{0i}C \right) + \left( QA_{i} - K_{0i}C \right)^{T} \right] \Delta P + \Delta P \left[ \left( QA_{i} - K_{0i}C \right) + \left( QA_{i} - K_{0i}C \right)^{T} \right] - \Delta K_{i}CP_{0} - P_{0}^{T}C^{T}\Delta K_{i}^{T} - C^{T}\Delta K_{i}^{T}P_{0} + \left[ \left( QA_{i} - K_{0i}C \right) + \left( QA_{i} - K_{0i}C \right)^{T} \right] P_{0} + P_{0} \left[ \left( QA_{i} - K_{0i}C \right) + \left( QA_{i} - K_{0i}C \right)^{T} \right] - P_{0}\Delta K_{i}C < 0 .$$

$$(2.68)$$

Rezolvarea inecuației (2.68) în raport cu  $\Delta P$  și  $\Delta K_i$  este o operațiune destul de dificilă datorită faptului că nu există o metodă efectivă de alegere a valorilor inițiale  $K_{0i}$  și  $P_0$ , putând astfel exista alegeri nefavorabile pentru care inecuația matricealliniară (2.68) nu conduce la o soluție. Pentru a limita variația lui  $K_i$  și P, în [7] se introduc câteva constrângeri suplimentare:

$$\begin{cases} \left\|\Delta K_{i}\right\| \leq \varepsilon \left\|\Delta K_{0i}\right\|, \\ \left\|\Delta P\right\| \leq \varepsilon \left\|\Delta P_{0}\right\|; \end{cases}$$

$$(2.69)$$

constrângerile (2.69) pot fi scrise și sub forma inecuațiilor matriceale

$$\begin{cases} \begin{bmatrix} \varepsilon \|P_0\| I_n & \Delta P \\ \Delta P & \varepsilon \|P_0\| I_n \end{bmatrix} > 0, \\ \begin{bmatrix} \varepsilon \|K_{0i}\| I_n & \Delta K_i \\ \Delta K_i^T & \varepsilon \|K_{0i}\| I_p \end{bmatrix} > 0. \end{cases}$$
(2.70)

În consecință, determinarea matricei simetrice și pozitiv definite P și a matricelor  $K_i$  se face rezolvând inecuațiile matriceal-liniare (2.68) și (2.70) în raport cu  $\Delta P$  și  $\Delta K_i$  și apoi utilizând ecuațiile (2.66).

Tot în [7] este analizată viteza de convergență a observerului multiplu (2.34) și se arată că această viteză depinde de valorile proprii ale matricei  $\widetilde{N} = \sum_{i=1}^{M} \mu_i(\xi) N_i$ ; mai

mult, este prezentată o metodă de îmbunătățire a performanțelor observerului multiplu. În acest sens, se utilizează o proprietate din [176], conform căreia observerul multiplu (2.34) este observabil local dacă perechiile  $(QA_i, C), i = \overline{1, M}$ , sunt observabile. Pentru a fi siguri de convergența erorii de estimare a observerului, se definește, în planul complex, o zonă  $S(\alpha,\beta)$  care este intersecția dintre cercul de centru (0,0) și rază  $\beta$  și semiplanul stâng complex delimitat de verticala cu ecuația  $x=-\alpha$ , unde  $\alpha$  este o constantă pozitivă. În [7] se arată că valorile proprii ale matricei  $\tilde{N}$  aparțin zonei  $S(\alpha, \beta)$  dacă există matricele  $\Delta P$  și  $\Delta K_i$  astfel încât,  $(\forall)i = \overline{1, M}$ ,

$$\begin{cases} -\beta (P_{0} + \Delta P) & N_{0i}^{T} P - C^{T} \Delta K_{i}^{T} P_{0} \\ PN_{0i} - P_{0} \Delta K_{i} C & -\beta (P_{0} + \Delta P) \\ N_{0i}^{T} \Delta P + \Delta P N_{0i} - C^{T} \Delta K_{i}^{T} P_{0} - P_{0} \Delta K_{i} C + N_{0i}^{T} P_{0} + P_{0} N_{0i} + 2\alpha (P_{0} + \Delta P) < 0 , \end{cases}$$

$$(2.71)$$

unde  $N_{0i} = QA_i - K_{0i}C$ .

# 2.3. OBSERVERUL MULTIMPLU AKHENAK (VARIANTA 2)

Un alt observer multiplu a fost proiectat în [8]; față de cazurile prezentate până acum, observerul din [8] este dedicat sistemelor neliniare cu intrări necunoscute ce influențează atât vectorul de stare cât și vectorul de ieșire. Scopul estimatorului de stare este acela de a estima vectorul de stare și vectorul intrărilor necunoscute. Metodologia de proiectare a observerului multiplu din [8] este prezentată în continuare.

# 2.3.1. STRUCTURA MODELULUI MULTIPLU

Se consideră modelul multiplu descris de ecuațiile [8]

$$\begin{cases} \dot{x}(t) = \sum_{i=1}^{M} \mu_i(\xi(t)) [A_i x(t) + B_i u(t) + D_i v(t)], \\ y(t) = C x(t) + F v(t), \end{cases}$$
(2.72)

unde  $x(t) \in \mathcal{M}^{n\times 1}$  este vectorul de stare al sistemului,  $u(t) \in \mathcal{M}^{n\times 1}$  – vectorul intrărilor cunoscute,  $v(t) \in \mathcal{M}^{q\times 1}$  – vectorul intrărilor necunoscute,  $y(t) \in \mathcal{M}^{p\times 1}$  – vectorul de ieșire, iar  $C \in \mathcal{M}^{p\times n}$  este matricea de ieșire a sistemului. Pentru modelul local "*i*",  $A_i \in \mathcal{M}^{n\times n}$ este matricea asociată stării,  $B_i \in \mathcal{M}^{n\times m}$  – matricea de intrare,  $D_i \in \mathcal{M}^{n\times q}$  și  $F \in \mathcal{M}^{p\times q}$  – matrice de trasmisie. Funcțiile de activare  $\mu_i(\xi(t)), i = \overline{1, M}$ , au proprietățile (2.2). În cele ce urmează, pentru ușurința notațiilor, dependența de timp (*t*) este omisă.

### 2.3.2. PROIECTAREA OBSERVERULUI MULTIPLU

Se consideră observerul multiplu [8]

$$\begin{cases} \dot{z} = \sum_{i=1}^{M} \mu_i(\xi) (N_i z + G_i u + L_i y), \\ \hat{x} = z - Ey, \end{cases}$$
(2.73)

unde  $N_i \in \mathcal{M}^{n \times n}, G_i \in \mathcal{M}^{n \times m}, L_i \in \mathcal{M}^{n \times p}$  sunt matrice de amplificare ale observerului local "*i*", iar  $E \in \mathcal{M}^{n \times p}$  – matrice de transformare. Matricele  $N_i, G_i, L_i$  și E trebuie determinate astfel încât vectorul de stare estimat  $\hat{x}$  să tindă către x.

Se consideră eroarea observerului multiplu  $e = x - \hat{x}$ , care se exprimă, utilizând ecuațiile (2.72), (2.73) și notația Q = I + EC, după cum urmează [8]

$$e = x - \hat{x} = x - z + E(Cx + Fv) = x - z + ECx + EFv = Qx - z + EFv.$$
(2.74)

Utilizând ecuațiile (2.72)-(2.74), dinamica erorii observerului este [8]

$$\dot{e} = \sum_{i=1}^{M} \mu_i (\xi) [N_i e + (QA_i - N_i - K_i C) x + (QB_i - G_i) u + (QD_i - K_i F) v] + EF\dot{v}, \quad (2.75)$$

unde  $K_i$  are forma (2.37). Dacă sunt îndeplinite simultan condițiile

$$QD_i = K_i F, G_i = QB_i, N_i = QA_i - K_i C, EF = 0,$$
(2.76)

eroarea are dinamica (2.38) și tinde la zero dacă există o matrice simetrică și pozitiv definită *P* astfel încât,  $(\forall)i = \overline{1, M}$ , inecuația (2.42) este verificată. Așadar, constrângerile (2.76) și (2.42) conduc la determinarea completă a observerului multiplu; în plus, matricea *F* trebuie să aibă rang de coloană maxim, adică rang(F) < p [8]. Sinteza constrângerilor și ecuațiilor prezentate până acum poate fi făcută în cadrul teoremei:

# *<u>Teorema 2.2</u>* [8]

Eroarea de estimare dintre modelul multiplu (2.72) și observerul (2.73) converge asimptotic global la zero dacă există matricele P>0, S și  $W_i$  astfel încât,  $(\forall)i = \overline{1, M}$ , sunt îndeplinite simultan condițiile

$$\begin{cases} A_{i}^{T}P + PA_{i} + A_{i}^{T}C^{T}S^{T} + SCA_{i} - W_{i}C - C^{T}W_{i}^{T} < 0, \\ (P + SC)D_{i} = W_{i}F, \\ SF = 0. \end{cases}$$
(2.77)

În aceste condiții, observerul multiplu (2.73) este definit prin intermediul matricelor

$$\begin{cases} E = P^{-1}S, \\ G_i = (I + P^{-1}SC)B_i, \\ N_i = (I + P^{-1}SC)A_i - P^{-1}W_iC, \\ L_i = P^{-1}W_i - N_iE. \end{cases}$$
(2.78)

### **Demonstrație**

Inecuația matriceal-neliniară (2.42), prin înlocuirea lui  $N_i$  cu a treia expresia (2.76) și utilizând notațiile [8]

$$W_i = PK_i, S = PE, (2.79)$$

se transformă în inecuația matriceal-liniară (2.77) – inecuație cu necunoscutele P și  $W_i$ ; matricele  $A_i$  și C sunt cunoscute, iar matricea S se determină din a treia condiție (2.77) în funcție de matricea F. Astfel, dacă numărul de coloane asociat matricei C este egal cu numărul de linii asociat matricei F, matricea S se calculează cu expresia [7]

$$S = I - F(CF)^{+}C; \qquad (2.80)$$

o alternativă o reprezintă utilizarea metodei prezentate în [210]. După determinarea matricelor P, S și  $W_i$  (care trebuie să verifice și a doua condiție (2.77)), se calculează  $K_i$  din prima ecuație (2.79), scrisă sub forma (2.50), și apoi matricea E utilizând a doua ecuație (2.79).



Fig. 2.7. Schema bloc de modelare a observerului multiplu Akhenak (varianta 2)A doua ecuație (2.77) se obține simplu înmulțind la stânga cu *P* prima ecuație (2.76), în

timp ce a treia ecuație (2.77) se obține înmulțind la stânga cu *P* a patra ecuație (2.76). Au fost, așadar, demonstrate ecuațiile (2.77) și prima ecuație (2.78). Obținerea ultimelor 3 ecuații (2.78) se face înlocuind în expresiile (2.76) pe *Q* cu *I*+*EC*, pe *E* cu  $P^{-1}S$ , pe *K<sub>i</sub>* cu expresia (2.50) și ținând cont de ecuația (2.37).

Pentru rezolvarea inecuației matriceal-liniare (2.77), se utilizează lema Schur sub forma:  $\begin{bmatrix} \widetilde{Q} & \widetilde{S} \\ \widetilde{S}^T & \widetilde{R} \end{bmatrix} < 0$  dacă și numai dacă  $\widetilde{R} < 0$  și  $\widetilde{Q} - \widetilde{S}\widetilde{R}^{-1}\widetilde{S}^T < 0$ ; lema Schur a fost

particularizată astfel:

$$\widetilde{Q} = A_i^T P + P A_i + A_i^T C^T S^T + S C A_i - W_i C - C^T W_i^T, \widetilde{S} = 0, \widetilde{R} = -I.$$
(2.81)

Schema bloc ce modelează ecuațiile (2.72) și (2.73) este prezentată în fig. 2.10.

# 2.3.3. ESTIMAREA INTRĂRILOR NECUNOSCUTE

S-a demonstrat până acum că estimatorul de stare (2.73) este convergent dacă sunt satisfăcute condițiile din teorema 2.2. În regim staționar, eroarea e tinde la zero; înlocuind x cu  $\hat{x}$  în ecuațiile (2.72), se obține [8]

$$\begin{cases} \dot{\hat{x}} = \sum_{i=1}^{M} \mu_i(\xi) (A_i \hat{x} + B_i u + D_i \hat{v}), \\ \hat{y} = C \hat{x} + F \hat{v}, \end{cases}$$
(2.82)

unde  $\hat{v}$  este estimarea vectorului intrărilor necunoscute (v), iar  $\hat{y}$  este estimarea ieșirii sistemului (v).  $\hat{v}$  se calculează în [8] după cum urmează:

$$\hat{v} = (W^T W)^{-1} W^T \begin{bmatrix} \dot{\hat{x}} - \sum_{i=1}^M \mu_i(\xi) (A_i \hat{x} + B_i u) \\ \hat{y} - C \hat{x} \end{bmatrix},$$
(2.83)

$$W = \begin{bmatrix} \dot{\hat{x}} - \sum_{i=1}^{M} \mu_i(\xi) D_i \\ F \end{bmatrix};$$
(2.84)

*W* trebuie să aibă rang de coloană maxim pentru a putea calcula  $W^+ = (W^T W)^{-1} W^T$ . Dacă *F* are rang de coloană maxim, estimarea intrărilor necunoscute se face astfel [8]:

$$\hat{v} = (F^T F)^{-1} F^T (y - \hat{y}).$$
(2.85)

Proiectarea observerului din [8] se face prin parcurgerea următorilor pași:

### Algoritmul Akhenak (varianta 2)

**Pasul 1**: Se declară matricele  $A_i$ ,  $B_i$ ,  $D_i$ , C, F,  $i = \overline{1, M}$ ; de asemenea, se stabilesc expresiile vectorului de decizie  $\xi(t)$  și expresiile funcțiilor de activare  $\mu_i(\xi(t))$ ,  $i = \overline{1, M}$ .

Pasul 2: Se determină matricea S din a treia ecuație (2.77).

**Pasul 3**: Se rezolvă inecuația matriceal-liniară (2.77) - inecuație cu necunoscutele P și  $W_i$ ; matricele S, P și  $W_i$  determinate anterior trebuie să verifice a doua ecuație (2.77).

**Pasul 4**: Pentru fiecare  $i = \overline{1, M}$ , se determină matricele  $K_i$  (ecuația (2.50)) și apoi, se calculează matricea E (prima ecuație (2.78)) și Q=I+EC.

**Pasul 5**: Se calculează matricele  $G_i$ ,  $N_i$  și  $L_i$  (ecuațiile (2.78)) și se verifică dacă sunt îndeplinite simultan condițiile (2.76) și dacă matricea  $\tilde{N}$  (ecuația (2.40)) este stabilă.

**Pasul 6**: Utilizând matricele calculate la pașii anteriori, se proiectează observerul descris de ecuațiile (2.73); pentru validarea estimatorului de stare, se utilizează și ecuațiile ce descriu dinamica modelului multiplu (ecuațiile de stare – ieșire (2.72)). Se estimează vectorul intrărilor necunoscute utilizând ecuațiile (2.83) și (2.84), dacă F are rang de coloană maxim, sau ecuația (2.85) în caz contrar.

# 2.3.4. VALIDAREA OBSERVERULUI MULTIPLU

Observerul Akhenak (varianta 2) este validat în mediul Matlab/Simulink; a fost aleasă, pentru validarea observerului, mișcarea longitudinală a unei aeronave, dinamica acesteia fiind descrisă de ecuațiile (2.72) în care

$$A_{1} = \begin{bmatrix} -0.007 \ 0.012 \ -9.81 \ 0 \\ -0.128 \ -0.54 \ 0 \ 1 \\ 0 \ 0 \ 0 \ 1 \\ 0.065 \ 0.96 \ 0 \ -0.99 \end{bmatrix}, B_{1} = \begin{bmatrix} 0 \\ -0.04 \\ 0 \\ -12.5 \end{bmatrix}, D_{1} = \begin{bmatrix} 0.07 \\ 0.02 \\ 0.07 \\ 0.08 \end{bmatrix}, A_{2} = \begin{bmatrix} -0.01 \ 0.01 \ -9.81 \ 0 \\ -0.128 \ -0.6 \ 0 \ 1 \\ 0 \ 0 \ 0 \ 1 \\ 0.1 \ 1.2 \ 0 \ -1.5 \end{bmatrix}, B_{2} = \begin{bmatrix} 0 \\ 0.07 \\ 0.08 \\ 0.1 \ 1.2 \ 0 \ -1.5 \end{bmatrix}, B_{2} = \begin{bmatrix} 0.1 \\ 0.1 \\ 0.1 \ 1.2 \ 0 \ -1.5 \end{bmatrix}, X^{T} = \begin{bmatrix} \Delta V_{x} \ \Delta \alpha \ \Delta \Theta \ \Delta \omega_{y} \end{bmatrix}, u = \delta_{p}, C = I_{4}, F = \begin{bmatrix} 0.01 \ 0 \ 0.01 \ 0 \ 0.01 \ 0 \end{bmatrix}^{T}.$$

Vectorul intrărilor necunoscute v a fost ales aleatoriu; pentru matricele de mai sus, au rezultat M = 2, n = p = 4, m = q = 1. Funcția de decizie și funcțiile de activare au fost alese de aceeași formă ca și în cazul celuilalt observer multiplu Akhenak, adică:  $\xi(t) = u(t), \mu_1(\xi(t)) = 0.5(1 - \tanh(\xi(t))), \mu_2(\xi(t)) = 0.5(1 + \tanh(\xi(t)))$ . Se determină, în cadrul pasului 2, matricea *S* din a treia ecuație (2.77); apoi, se rezolvă inecuația matriceal-liniară (2.77) - inecuație cu necunoscutele  $P, W_1$  și  $W_2$ . Pentru fiecare  $i = \overline{1,2}$ , se calculează matricele  $K_i$  (ecuația (2.50)) și apoi, se determină matricea *E* (prima ecuație (2.78)) și Q=I+EC. În cadrul pasului 5, se determină matricele  $G_1, G_2, N_1, N_2, L_1, L_2$  – ecuațiile (2.78); s-au obținut

$$S = \begin{bmatrix} 0.5 & 0 - 0.5 & 0 \\ 0 & 1 & 0 & 0 \\ -0.5 & 0 & 0.5 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}, P = 1.933 \cdot I_4, W_1 = \begin{bmatrix} 0.949 & -3.332 & -13.282 & -2.162 \\ 2.985 & -0.617 & 0.266 & 29.357 \\ -10.586 & -0.272 & 5.871 & 1.633 \\ 1.852 & -23.607 & 0.800 & -1.937 \end{bmatrix},$$
$$W_2 = \begin{bmatrix} 0.723 & -0.101 & -7.822 & 0.043 \\ -0.250 & -0.793 & -0.001 & 2.453 \\ -16.000 & -0.003 & 5.871 & 0.433 \\ -0.250 & 4.000 & 2.000 & -3.433 \end{bmatrix}, E = \begin{bmatrix} 0.258 & 0 & -0.258 & 0 \\ 0 & 0.517 & 0 & 0 \\ -0.258 & 0 & 0.258 & 0 \\ 0 & 0 & 0 & 0.517 \end{bmatrix},$$
$$Q = \begin{bmatrix} 1.258 & -0.258 & 0 & 0 \\ 0 & 1.517 & 0 & 0 \\ -0.258 & 0 & 1.258 & 0 \\ 0 & 0 & 0 & 1.517 \end{bmatrix}, G_1 = \begin{bmatrix} 0 \\ -0.06 \\ 0 \\ -18.96 \end{bmatrix}, G_2 = \begin{bmatrix} 0.12 \\ -0.15 \\ -0.02 \\ -16.38 \end{bmatrix},$$

$$N_{1} = \begin{bmatrix} -0.500 & 1.738 & -5.477 & 0.859 \\ -1.738 & -0.500 & -0.138 & -13.666 \\ 5.477 & 0.138 & -0.500 & 0.413 \\ -0.859 & 13.666 & -0.413 & -0.500 \end{bmatrix}, N_{2} = \begin{bmatrix} -0.500 & 0.064 & -8.301 & -0.281 \\ -0.064 & -0.500 & 0.000 & 0.248 \\ 8.301 & 0.000 & -0.500 & 1.034 \\ 0.281 & -0.248 & -1.034 & -0.500 \end{bmatrix}, L_{1} = \begin{bmatrix} -0.796 & -2.622 & -5.582 & -1.562 \\ 1.958 & -0.060 & -0.275 & 22.252 \\ -7.021 & -0.212 & 4.582 & 0.630 \\ 1.073 & -19.278 & 0.298 & -0.743 \end{bmatrix}, L_{2} = \begin{bmatrix} -1.643 & -0.085 & -2.028 & 0.167 \\ -0.112 & -0.151 & -0.017 & 1.140 \\ -10.551 & -0.001 & 5.312 & -0.310 \\ -0.469 & 2.197 & 1.374 & -1.517 \end{bmatrix}.$$

S-au obținut caracteristicile grafice din fig. 2.8 și fig. 2.9.



Fig. 2.8. Erorile de estimare ale observerului Akhenak (intrare aleatoare)



Fig. 2.9. Variabilele de stare  $x_i(t)$  și variabilele de stare estimate  $\hat{x}_i(t)$ 

Simularea se face pentru două cazuri: intrare aleatoare (fig. 2.8) și intrare de tipul  $u = -K\hat{x}$  (fig. 2.9), unde *K* este matricea de amplificare determinată printr-un algoritm optimal (de exemplu algoritmul ALGLX [140]). În fig. 2.8 sunt reprezenate grafic erorile de estimare ale observerului multiplu Akhenak (cazul 1: intrarea u de tip aleator); în fig. 2.9 sunt reprezentate grafic variabilele de stare  $x_i(t)$  – cu linie continuă și variabilele de stare estimate  $\hat{x}_i(t)$  – cu linie întreruptă asociate observerului Akhenak

(varianta 2) pentru intrare de tipul  $u = -K\hat{x}$ . Din figurile 2.8 și 2.9 se remarcă anularea erorilor de estimare a variabilelor de stare, deci buna funcționare a observerului multiplu de tip Akhenak (varianta 2).

# **2.4. OBSERVERE MARX**

Dacă unui sistem, pentru care se dorește estimarea vectorului de stare și, eventual, a intrărilor necunoscute, i se atașază un descriptor de tip Takagi-Sugeno, ecuațiile modelului multiplu sunt diferite față de cele de până acum și, implicit, metodologia de proiectare a observerelor este alta. Astfel de observere pentru sistemele descriptor de tip Takagi-Sugeno sunt prezentate în cadrul lucrării [157].

# 2.4.1. DINAMICA SISTEMELOR DESCRIPTOR DE TIP TAKAGI-SUGENO

Ecuațiile generale asociate unui sistem descriptor de tip Takagi-Sugeno (variantă continuă) sunt [157]

$$\begin{cases} E\dot{x}(t) = \sum_{i=1}^{M} \mu_i(\xi(t)) [A_i x(t) + B_i u(t) + D_i v(t)], \\ y(t) = Cx(t) + Gv(t), \end{cases}$$
(2.86)

sau, în variantă discretă,

$$\begin{cases} Ex_{k+1} = \sum_{i=1}^{M} \mu_i (\xi_k) [A_i x_k + B_i u_k + D_i v_k], \\ y_k = Cx_k + Gv_k, \end{cases}$$
(2.87)

unde  $x(t) \in \mathcal{M}^{p \times 1}$  este vectorul de stare al sistemului,  $u(t) \in \mathcal{M}^{m \times 1}$  – vectorul intrărilor cunoscute,  $v(t) \in \mathcal{M}^{p \times 1}$  – vectorul intrărilor necunoscute,  $y(t) \in \mathcal{M}^{p \times 1}$  – vectorul de ieșire, iar matricele  $E, A_i, B_i, D_i, C$  și G se consideră reale, cunoscute și constante; matricea E poate fi nesingulară. Funcțiile de activare  $\mu_i(\xi(t)), i = \overline{1, M}$ , pentru varianta continuă a ecuațiilor de stare-ieșire, verifică condițiile (2.2), iar pentru varianta discretă, condițiile

$$\sum_{i=1}^{M} \mu_i(\xi_k) = 1, 0 \le \mu_i(\xi_k) \le 1, (\forall) k.$$
(2.88)

### 2.4.2. PROIECTAREA OBSERVERULUI MULTIPLU

Forma observerului multiplu propus în [157] este

$$\begin{cases} \dot{z}(t) = \sum_{i=1}^{M} \mu_i(\xi(t)) [N_i z(t) + M_i u(t) + L_i y(t)], \\ \hat{x}(t) = z(t) + T_2 y(t), \end{cases}$$
(2.89)

în variantă continuă, sau

$$\begin{cases} z_{k+1} = \sum_{i=1}^{M} \mu_i(\xi_k) [N_i z_k + M_i u_k + L_i y_k], \\ \hat{x}_k = z_k + T_2 y_k, \end{cases}$$
(2.90)

în variantă discretă.

Ecuațiile (2.86) sunt asemănătoare cu cele ale modelului multiplu prezentat în [8]; diferența este reprezentată de prezența matricei E, care, nu întotdeauna este matricea unitate astfel încăt modelul (2.86) să fie de tipul (2.72).

Pentru a cunoaște în totalitate observerul multiplu, este nevoie de calculul matricelor  $N_i$ ,  $M_i$ ,  $L_i$  și  $T_2$  astfel încât vectorul de stare estimat  $\hat{x}(t)$  să tindă către vectorul de stare x(t). Dacă se definește eroarea  $e(t) = x(t) - \hat{x}(t)$ , sau, în variantă discretă,  $e_k = x_k - \hat{x}_k$ , scopul este acela de a determina matricele  $N_i$ ,  $M_i$ ,  $L_i$  și  $T_2$  astfel încât  $\lim_{t\to\infty} e(t) = 0$  sau  $\lim_{k\to\infty} e_k = 0$ .

Se presupune că există matricele  $T_1$  și  $T_2$  astfel încât [157]

$$T_1 E + T_2 C = I_n ,$$
  

$$T_2 G = 0 ;$$
(2.91)

cu acestea, ținând cont de ecuațiile (2.86) și (2.89), eroarea estimatorului de stare devine

$$e(t) = T_1 Ex(t) - z(t).$$
 (2.92)

Prin derivare, se obține dinamica erorii observerului multiplu [157]

$$\dot{e}(t) = \sum_{i=1}^{M} \mu_i(\xi(t)) [N_i e(t) + (T_1 A_i - N_i T_1 E - L_i C) x(t) + (T_1 B_i - M_i) u(t) + (T_1 D_i - L_i G) v(t)].$$
(2.93)

Dinamica erorii este de tipul (2.38) dacă sunt îndeplinite simultan condițiile [157]

$$T_{1}E + T_{2}C = I_{n}, T_{2}G = 0,$$
  

$$T_{1}A_{i} - N_{i}T_{1}E - L_{i}C = 0,$$
  

$$T_{1}B_{i} - M_{i} = 0, T_{1}D_{i} - L_{i}G = 0;$$
  
(2.94)

utilizând notația  $K_i = N_i T_2 - L_i$ , constrângerile (2.94) se scriu sub forma

$$N_{i} = T_{1}A_{i} + K_{i}C, T_{1}E + T_{2}C = I_{n}, T_{2}G = 0,$$
  

$$T_{1}D_{i} + K_{i}G = 0, M_{i} = T_{1}B_{i}, L_{i} = N_{i}T_{2} - K_{i}.$$
(2.95)

Primele 4 condiții (2.95) înseamnă a determina o matrice  $\Omega \in \mathcal{M}^{n \times (n+p(M+1))}$  astfel încât [157]

$$\begin{cases} \Omega R = S, \\ N_i = \Omega S_i, \end{cases}$$
(2.96)

unde

$$\Omega = \begin{bmatrix} \widetilde{\Omega}_{1} & \widetilde{\Omega}_{2} \end{bmatrix}, R = \begin{bmatrix} \widetilde{R}_{1} & \widetilde{R}_{2} \\ \widetilde{R}_{3} & \widetilde{R}_{4} \end{bmatrix}, S = \begin{bmatrix} \widetilde{S}_{1} & \widetilde{S}_{2} \end{bmatrix}, S_{i} = \begin{bmatrix} \widetilde{S}_{i,1} \\ \widetilde{S}_{i,2} \end{bmatrix},$$

$$\widetilde{\Omega}_{1} = \begin{bmatrix} T_{1} & T_{2} \end{bmatrix}, \widetilde{\Omega}_{2} = \begin{bmatrix} K_{1} & K_{2} & \dots & K_{M} \end{bmatrix},$$

$$\widetilde{R}_{1} = \begin{bmatrix} E & 0_{n \times q} \\ C & G \end{bmatrix}, \widetilde{R}_{2} = \begin{bmatrix} \begin{bmatrix} D_{1} & \dots & D_{M} \\ 0_{p \times q} & \dots & 0_{p \times q} \end{bmatrix}, \widetilde{R}_{3} = \begin{bmatrix} 0_{pM \times n} & 0_{pM \times q} \end{bmatrix}, \widetilde{R}_{4} = I_{M} \otimes G,$$

$$\widetilde{S}_{1} = \begin{bmatrix} I_{n} & 0_{n \times q} \end{bmatrix}, \widetilde{S}_{2} = 0_{n \times Mq}, \widetilde{S}_{i,1} = \begin{bmatrix} A_{i}^{T} & 0_{n \times p} \end{bmatrix}^{T}, \widetilde{S}_{i,2} = e_{i} \otimes C;$$

$$(2.97)$$

 $e_i \in \mathcal{M}^{M \times 1}$  sunt vectori coloană cu toate componentele=0 cu excepția componentei "*i*" care este egală cu 1. Considerând 2 matrice  $\alpha \in \mathcal{M}^{\alpha_1 \times \alpha_2}, \beta \in \mathcal{M}^{\beta_1 \times \beta_2}$  și  $\alpha_{j,l}$  – elementele matricei  $\alpha$ , produsul Kronecker a celor 2 matrice este

$$\alpha \otimes \beta = \begin{bmatrix} \alpha_{1,1}\beta & \dots & \alpha_{1,\alpha_2}\beta \\ \vdots & \vdots & \vdots \\ \alpha_{\alpha_1,1}\beta & \dots & \alpha_{\alpha_1,\alpha_2}\beta \end{bmatrix} \in \mathcal{M}^{\alpha_1\beta_1 \times \alpha_2\beta_2}.$$
 (2.98)

Determinarea matricei  $\Omega$  înseamnă a determina matricele  $T_1, T_2$  și  $K_i, i = \overline{1, M}$ ; după calculul acestor matrice,  $M_i$  se determină din a 5-a ecuație (2.95),  $N_i$  - din prima ecuație (2.95), iar  $L_i$  - din ultima ecuație (2.95). Rezolvarea primei ecuații (2.96), deci determinarea matricei  $\Omega$ , este posibilă doar dacă [157]

$$\operatorname{rang}\begin{bmatrix} R\\ S \end{bmatrix} = \operatorname{rang}(R), \tag{2.99}$$

condiție echivalentă cu

$$\operatorname{rang}(R) = \operatorname{rang}\begin{bmatrix} D_1 & \dots & D_M \end{bmatrix} \\ I_M \otimes G \end{bmatrix} + n + \operatorname{rang}(G);$$
(2.100)

demonstrația se găsește în [157].

Dacă este îndeplinită condiția (2.100), cunoscând matricele R și S, se rezolvă prima ecuație matriceală (2.96) și rezultă

$$\Omega = SR^+ + TR^\perp, \qquad (2.101)$$

în care "+" este simbolul pseudo-inversei,  $R^{\perp} = I - RR^+$ , iar  $T \in \mathcal{M}^{n \times (n+p(M+1))}$  este determinată mai jos prin rezolvarea unei inecuații matriceal-liniare (LMI). Astfel, înlocuind  $\Omega$  cu forma (2.101) în a doua ecuație (2.96), se obține [157]

$$N_{i} = SR^{+}S_{i} + TR^{\perp}S_{i}; \qquad (2.102)$$

așadar, matricele  $N_i$  se determină fie utilizând ecuația (2.102), fie cu ajutorul primei ecuații (2.95), după ce, în prealabil, s-a determinat  $\Omega$  și, deci, matricele  $T_1$ ,  $T_2$  și  $K_i$ .

Eroarea observerului multiplu (ecuația (2.38)) tinde la zero dacă există o matrice simetrică și pozitiv definită *P* astfel încât,  $(\forall)i = \overline{1, M}$ , este îndeplinită condiția (2.42). Înlocuind în (2.42) pe  $N_i$  (ecuația (2.102)), se obține inecuația matriceal-liniară [157]

$$\left(SR^{+}S_{i}\right)^{T}P+P\left(SR^{+}S_{i}\right)+\left(R^{\perp}S_{i}\right)^{T}\overline{T}^{T}+\overline{T}\left(R^{\perp}S_{i}\right)<0,$$
(2.103)

în care s-a făcut notația  $\overline{T} = PT \in \mathcal{M}^{n \times (n+p(M+1))}$ , iar matricele  $R \in \mathcal{M}^{(n+p(M+1)) \times (n+q(M+1))}$ ,  $S \in \mathcal{M}^{n \times (n+q(M+1))}$  și  $S_i \in \mathcal{M}^{(n+p(M+1)) \times n}$  sunt definite de ecuațiile (2.97).

Rezultatul poate fi extins și pentru cazul descrierii discrete; astfel, inecuația (2.103), utilizând lema Schur, se scrie sub forma [157]

$$\begin{bmatrix} \Phi_i & \left(R^{\perp}S_i\right)^T \overline{T}^T \\ \overline{T} \left(R^{\perp}S_i\right) & -P \end{bmatrix} < 0, \qquad (2.104)$$

unde

$$\Phi_i = \left(R^{\perp}S_i\right)^T \overline{T}^T \left(SR^+S_i\right) + \left(SR^+S_i\right)^T \overline{T} \left(R^{\perp}S_i\right) + \left(SR^+S_i\right)^T P\left(SR^+S_i\right) - P.$$
(2.105)

Schema bloc ce modelează ecuațiile (2.86) și (2.89) este prezentată în fig. 2.10.



Fig. 2.10. Schema bloc de modelare a observerului multiplu Marx

Sintetizând, algoritmul de proiectare a observerului multiplu prezentat mai sus (observerul multiplu Marx – varianta 1) este următorul:

### **Algoritmul Marx (algoritmul 1)**

**Pasul 1**: Se declară matricele  $A_i$ ,  $B_i$ ,  $D_i$ , C, G, E,  $i = \overline{1, M}$  și se stabilesc expresiile vec-

torului de decizie  $\xi(t)$  și expresiile funcțiilor de activare  $\mu_i(\xi(t)), i = \overline{1, M}$ .

**Pasul 2**: Se calculează matricele R, S și  $S_i$  - ecuațiile (2.97) și se verifică îndeplinirea condiției (2.100); în caz contrar, acest estimator de stare nu poate fi construit.

**Pasul 3**: Se rezolvă inecuația matriceal-liniară (2.103), sau (2.104) pentru varianta discretă, în raport cu necunoscutele P și  $\overline{T}$ ; apoi, se obține matricea  $T = P^{-1}\overline{T}$ .

**Pasul 4**: Se determină matricea  $\Omega$  utilizând ecuația (2.101); prin partiționarea ei, conform (2.97), se obțin matricele  $T_1, T_2$  și  $K_i, i = \overline{1, M}$ ;

**Pasul 5**: Se calculează matricele  $N_i$  fie utilizând ecuația (2.102), fie cu ajutorul primei ecuații (2.95); utilizând ultimele două ecuații (2.95), se determină matricele  $M_i$  și  $L_i$ . Se verifică dacă matricea  $\tilde{N}$  (expresia (2.40)) este stabilă și, de asemenea, se verifică dacă toate condițiile (2.95) sunt verificate.

**Pasul 6**: Utilizând matricele și vectorii calculați la pașii anteriori, se proiectează observerul descris de ecuațiile (2.89) – varianta continuă sau (2.90) – varianta discretă; pentru validarea estimatorului de stare, se utilizează și ecuațiile ce descriu dinamica sistemului descriptor de tip Takagi-Sugeno (ecuațiile de stare – ieșire (2.86) sau (2.87)).

Observerul Marx (algoritmul 1) este validat în mediul Matlab/Simulink; a fost aleasă, pentru validarea observerului, mișcarea longitudinală a unei aeronave, dinamica acesteia fiind descrisă de ecuațiile (2.86) în care

Vectorul intrărilor necunoscute v a fost ales aleatoriu; pentru matricele de mai sus, au
rezultat M = 2, n = p = 4, m = q = 1. Funcția de decizie și funcțiile de activare au fost alese de forma:  $\xi(t) = u(t), \mu_1(\xi(t)) = 1.4(1 - \tanh(\xi(t))), \mu_2(\xi(t)) = 1 - \mu_1(\xi(t))$ . Se determină matricele R, S și  $S_i$  - ecuațiile (2.97) și se verifică îndeplinirea condiției (2.100). Se rezolvă (2.103) în raport cu P și  $\overline{T}$ ; apoi, se obține matricea  $T = P^{-1}\overline{T}$ . Au rezultat:

$$P = \begin{bmatrix} 1.405 & -0.328 & -0.328 & -0.328 \\ -0.328 & 1.405 & -0.328 & -0.328 \\ -0.328 & -0.328 & 1.405 & -0.328 \\ -0.328 & -0.328 & -0.328 & 1.405 \end{bmatrix},$$

$$T = 10^{3} \begin{bmatrix} 2.38 & 1.23 & 5.42 & -0.90 & -3.73 & -1.29 & -2.68 & -0.59 & 1.45 & 1.43 & 1.47 & 1.48 & -2.22 & -2.20 & -2.23 & -2.19 \\ 2.388 & 1.128 & 5.399 & -1.199 & -3.735 & -1.27 & -2.71 & -0.24 & 1.43 & 1.48 & 1.34 & 1.41 & -2.20 & -2.09 & -2.24 & -2.16 \\ 2.38 & 1.23 & 5.41 & -0.88 & -3.73 & -1.24 & -2.65 & -0.65 & 1.31 & 1.37 & 1.33 & 1.36 & -2.12 & -2.09 & -2.13 & -2.09 \\ 2.39 & 1.11 & 5.32 & -0.97 & -3.74 & -1.58 & -2.60 & -0.47 & 1.51 & 1.55 & 1.53 & 1.37 & -2.07 & -2.05 & -2.04 & -2.25 \end{bmatrix}$$

În cadrul pasului 4, se determină matricele  $T_1$ ,  $T_2$  și  $K_i$ ,  $i = \overline{1, M}$ ; acestea sunt utilizate pentru calculul matricelor  $N_i$  - prima ecuație (2.95),  $M_i$  și  $L_i$  - ultimele două ecuații (2.95). S-au obținut

$$T_{1} = \begin{bmatrix} -0.449 - 14.232 & 5.343 & 11.137 \\ 0.612 & 54.783 & -19.077 & -38.766 \\ -0.799 & -36.935 & 13.377 & 27.553 \\ 1.225 & 94.647 & -33.183 & -67.591 \end{bmatrix}, T_{2} = \begin{bmatrix} 1.899 & 19.925 & -10.687 & -11.137 \\ -1.224 & -75.696 & 38.154 & 38.766 \\ 1.598 & 51.709 & -25.754 & -27.553 \\ -2.450 & -132.50 & 66.366 & 68.591 \end{bmatrix},$$
$$N_{1} = \begin{bmatrix} -4.934 & -5.536 & 14.919 & -0.063 \\ 4.290 & 2.688 & -77.279 & 64.934 \\ -26.295 & 73.525 & -7.441 & -32.196 \\ 3.220 & -54.154 & 32.846 & 7.091 \end{bmatrix}, M_{1} = \begin{bmatrix} -138.647 \\ 482.389 \\ -342.939 \\ 841.107 \end{bmatrix}, L_{1} = \begin{bmatrix} 29 & 1125 & -557 & -595 \\ 292 & -12788 & 6428 & 6649 \\ 40 & -2235 & 1157 & 1121 \\ 88 & 4860 & -2521 & -2433 \end{bmatrix},$$
$$N_{2} = \begin{bmatrix} -7.217 & 32.917 & -11.544 & -9.015 \\ -35.397 & 3.736 & -78.414 & 101.204 \\ -5.492 & 72.331 & -10.820 & -46.270 \\ 12.862 & -86.403 & 46.513 & 10.063 \end{bmatrix}, M_{2} = \begin{bmatrix} -118.905 \\ 413.260 \\ -293.962 \\ 720.645 \end{bmatrix}, L_{2} = \begin{bmatrix} 40 & -2049 & 1048 & 1040 \\ -421 & -18536 & 9329 & 9634 \\ 10 & -30 & 45 & -29 \\ 148 & 7817 & -4023 & -3931 \end{bmatrix}.$$

De asemenea, au fost obținute caracteristicile grafice din fig. 2.11.



Fig. 2.11. Erorile de estimare ale observerului Marx (algoritmul 1)

### 2.4.3. PROIECTAREA UNUI OBSERVER PENTRU ATENUAREA INFLUENȚEI INTRĂRILOR NECUNOSCUTE ASUPRA SISTEMELOR DESCRIPTOR DE TIP TAKAGI-SUGENO

În [157] este proiectat, pe lăngă observerul multiplu prezentat mai sus, și un observer pentru sistemele descriptor Takagi-Sugeno care să minimizeze influența intrărilor necunoscute asupra procesului de estimare a stării în cazul în care decuplarea de sistemul descriptor a intrărilor necunoscute nu este posibilă; cu alte cuvinte, nu este posibilă proiectarea unui observer multiplu de tipul (2.89) în care să nu apară vectorul intrărilor necunoscute v(t). Metoda este mai puțin restrictivă decât cea prezentată anterior deoarece condiția (2.100) nu mai trebuie îndeplinită.

În [220] se demonstrează că sistemul descriptor având ecuațiile

$$\begin{cases} \dot{x}(t) = \sum_{i=1}^{M} \mu_i(\xi(t)) [A_i x(t) + B_i u(t)], \\ y(t) = \sum_{i=1}^{M} \mu_i(\xi(t)) C_i x(t), \end{cases}$$
(2.106)

în variantă continuă, sau descris de

$$\begin{cases} x_{k+1} = \sum_{i=1}^{M} \mu_i(\xi_k) [A_i x_k + B_i u_k], \\ y_k = \sum_{i=1}^{M} \mu_i(\xi_k) C_i x_k, \end{cases}$$
(2.107)

în variantă discretă, este stabil și verifică inegalitatea  $||y||_2 < \gamma ||u||_2$  dacă există o matrice simetrică și pozitiv definită  $P \in \mathcal{M}^{n \times n}$  astfel încât, pentru varianta continuă,

$$\begin{bmatrix} A_i^T P + PA_i + C_i^T C_i & PB_i \\ B_i^T P & -\gamma^2 I \end{bmatrix} < 0$$
(2.108)

iar, pentru varianta discretă,

$$\begin{bmatrix} A_i^T P A_i + C_i^T C_i - P & A_i^T P B_i \\ B_i^T P A_i & B_i^T P B_i - \gamma^2 I \end{bmatrix} < 0;$$
(2.109)

 $\gamma$  este o constantă pozitivă. În acest caz, un observer pentru atenuarea influenței intrărilor necunoscute se poate proiecta dacă eroarea de estimare e(t) și vectorul intrărilor necunoscute v(t) verifică condiția [157]

$$\|e\|_{2} < \gamma \|v\|_{2}. \tag{2.110}$$

Proiectarea observerului pentru atenuarea intrărilor necunoscute este sintetizat în cadrul următoarei teoreme:

#### Teorema 2.3 [157]

Un observer de tipul (2.89), pentru atenuarea influenței intrărilor necunoscute asupra sistemele descriptor având ecuațiile (2.86) există dacă este satisfăcută condiția

$$\operatorname{rang} \begin{bmatrix} E & 0 \\ C & G \end{bmatrix} = n + \operatorname{rang}(G)$$
(2.111)

și dacă, în plus, există o matrice simetrică și pozitiv definită  $P \in \mathcal{M}^{n \times n}$  și matricele  $\overline{T} \in \mathcal{M}^{n \times (n+p)}$  și  $\overline{K_i} \in \mathcal{M}^{n \times p}$  care,  $(\forall)i = \overline{1, M}$ , verifică inecuația matriceal-liniară

$$\begin{bmatrix} \Psi_{i,1} & \Psi_{i,2} \\ \Psi_{i,2}^T & -\gamma^2 I_q \end{bmatrix} < 0,$$
 (2.112)

unde

$$\Psi_{i,1} = PSR_1^+A_i + \overline{T}R_1^\perp A_i + \overline{K}_i C + \left(PSR_1^+A_i + \overline{T}R_1^\perp A_i + \overline{K}_i C\right)^T + I_n,$$

$$\Psi_{i,2} = PSR_1^+D_i + \overline{T}R_1^\perp D_i + \overline{K}_i G,$$
(2.113)

 $R_1^+ \in \mathcal{M}^{(n+q) \times n}, R_2^+ \in \mathcal{M}^{(n+q) \times p}, R_1^\perp \in \mathcal{M}^{(n+p) \times n}, R_2^\perp \in \mathcal{M}^{(n+p) \times p}$  sunt definite prin intermediul relațiilor

$$\begin{bmatrix} E & 0 \\ C & G \end{bmatrix}^+ = \begin{bmatrix} R_1^+ & R_2^+ \end{bmatrix}, \begin{bmatrix} E & 0 \\ C & G \end{bmatrix} \begin{bmatrix} E & 0 \\ C & G \end{bmatrix}^+ - I_{n+p} = \begin{bmatrix} R_1^\perp & R_2^\perp \end{bmatrix},$$
(2.114)

iar  $\overline{K}_i = PK_i$  și  $\overline{T} = PT$ .

În [157] se demonstrează că dacă este îndeplinită condiția (2.111), există matricele  $T_1$  și  $T_2$  astfel încât

$$[T_1 \ T_2]R = S, (2.115)$$

în care

$$R = \begin{bmatrix} E & 0 \\ C & G \end{bmatrix}, S = \begin{bmatrix} I_n & 0_{n \times q} \end{bmatrix};$$
(2.116)

expresiile matricelor  $T_1$  și  $T_2$  se obțin astfel [157]:

$$T_1 = SR_1^+ + TR_1^\perp, T_2 = SR_2^+ + TR_2^\perp, \qquad (2.117)$$

unde  $T = P^{-1}\overline{T}$ ,  $K_i = P^{-1}\overline{K}_i$ , iar P și  $\overline{T}$ , alături de  $\overline{K}_i$ , sunt soluțiile inecuației (2.112). Pentru determinarea matricelor  $N_i$ ,  $M_i$  și  $L_i$  se utilizează prima și ultimele 2 relații (2.95).

Pentru descrierea discretă (descriptorul (2.87)), teorema 2.3 se scrie ca mai jos:

#### Teorema 2.4 [157]

Un observer de tipul (2.90), pentru atenuarea influenței intrărilor necunoscute asupra sistemele descriptor cu ecuațiile (2.87) există dacă este îndeplinită condiția (2.111)

și dacă există o matrice simetrică și pozitiv definită  $P \in \mathcal{M}^{n \times n}$  și matricele  $\overline{T} \in \mathcal{M}^{n \times (n+p)}$ și  $\overline{K_i} \in \mathcal{M}^{n \times p}$  care,  $(\forall)i = \overline{1, M}$ , verifică inecuația matriceal-liniară

$$\begin{bmatrix} I_n - P & 0 & \Phi_{i,1}^T \\ 0 & -\gamma^2 I_n & \Phi_{i,2}^T \\ \Phi_{i,1} & \Phi_{i,1} & -P \end{bmatrix} < 0,$$
(2.118)

unde  $\Phi_{i,1}$  și  $\Phi_{i,2}$  sunt definite prin intermediul relațiilor

$$\Phi_{i,1} = PSR_1^+A_i + \overline{T}R_1^\perp A_i + \overline{K}_i C,$$
  

$$\Phi_{i,2} = PSR_1^+D_i + \overline{T}R_1^\perp D_i + \overline{K}_i G;$$
(2.119)

expresiile matricelor  $R_1^+$ ,  $R_2^+$ ,  $R_1^\perp$ ,  $R_2^\perp$ ,  $T_1$ ,  $T_2$ ,  $K_i$  și T sunt la fel ca mai sus.

Algoritmul pentru proiectarea observerului Marx pentru atenuarea influenței intrărilor necunoscute asupra sistemelor descriptor de tip Takagi-Sugeno este următorul:

### Algoritmul Marx (algoritmul 2)

**Pasul 1**: Se declară matricele  $A_i, B_i, D_i, C, G, E, i = \overline{1, M}$  și se stabilesc expresiile vectorului de decizie  $\xi(t)$ , precum și expresiile funcțiilor de activare  $\mu_i(\xi(t)), i = \overline{1, M}$ .

**Pasul 2**: Se verifică îndeplinirea condiției (2.111); în caz contrar, estimatorul de stare nu poate fi construit.

**Pasul 3**: Se calculează  $R_1^+, R_2^+, R_1^\perp, R_2^\perp$  – ecuațiile (2.114) și se rezolvă LMI (2.112), sau (2.118) pentru varianta discretă, în raport cu necunoscutele  $P, \overline{T}$  și  $\overline{K}_i$ ; se utilizează expresiile (2.113) sau (2.119). Se calculează apoi  $K_i = P^{-1}\overline{K}_i$  și  $T = P^{-1}\overline{T}$ .

**Pasul 4**: Se calculează matricele  $T_1$  și  $T_2$  folosind ecuațiile (2.117).

**Pasul 5**: Se calculează matricele  $N_i$  cu ajutorul primei ecuații (2.95) și matricele  $M_i$  și  $L_i$ - ultimele două ecuații (2.95). Se verifică dacă matricea  $\tilde{N}$  (expresia (2.40)) este stabilă și, de asemenea, se verifică dacă toate condițiile (2.95) sunt verificate.

**Pasul 6**: Utilizând matricele și vectorii calculați la pașii anteriori, se proiectează observerul descris de ecuațiile (2.89) – varianta continuă sau (2.90) – varianta discretă; pentru

validarea estimatorului de stare, se utilizează și ecuațiile ce descriu dinamica sistemului descriptor de tip Takagi-Sugeno (ecuațiile de stare – ieșire (2.86) sau (2.87)).

Observerul Marx (algoritmul 2) este validat în Matlab/Simulink, fiind ales, același model al mișcării longitudinale ca în paragraful 2.4.2; vectorul intrărilor necunoscute *v* și funcțiile de activare sunt, și ele, aceleași. Se verifică, în cadrul pasului 2, îndeplinirea condiției (2.111), iar, în cadrul pasului 3 al algoritmului Marx - varianta 2, se calculează  $R_1^+, R_2^+, R_1^\perp, R_2^\perp$ , și se rezolvă LMI (2.112) în raport cu necunoscutele *P*,  $\overline{T}$  și  $\overline{K}_i$ ; apoi, se obțin matricele  $K_i = P^{-1}\overline{K}_i$  și  $T = P^{-1}\overline{T}$ . Au rezultat matricele

 $P = \begin{bmatrix} 1.199 & -0.005 & -0.005 & -0.005 \\ -0.005 & 1.199 & -0.005 & -0.005 \\ -0.005 & -0.005 & 1.199 & -0.005 \\ -0.005 & -0.005 & -0.005 & 1.199 \end{bmatrix}, T = \begin{bmatrix} 55.42 & -92.44 & 2.24 & 89.98 & 39.05 & 167.51 & -84.63 & -56.00 \\ -34.01 & -133.03 & -22.98 & 79.48 & 27.06 & -1.65 & 10.48 & 87.46 \\ 413.72 & 406.83 & 238.62 & 238.11 & -70.70 & -363.87 & 8.61 & 229.98 \\ -44.13 & -119.69 & -62.16 & 114.09 & -76.95 & -40.46 & -130.13 & -13.37 \end{bmatrix}, K_1 = \begin{bmatrix} 17.825 & 50.894 & 61.705 & -124.471 \\ 84.924 & 28.983 & -74.548 & -38.077 \\ -76.248 & -144.755 & -27.229 & 237.839 \\ -12.410 & 64.223 & 17.555 & -66.730 \end{bmatrix}, K_2 = \begin{bmatrix} 20.710 & 71.355 & 2.645 & -106.902 \\ 90.029 & 34.634 & -62.782 & -64.730 \\ -22.060 & -198.992 & -27.283 & 268.836 \\ -67.895 & 93.235 & 53.520 & -84.423 \end{bmatrix}.$ 

În cadrul pașilor 4 și 5, se determină  $T_1$ ,  $T_2$  care, împreună cu matricele  $K_i$ ,  $i = \overline{1,2}$ , sunt utilizate pentru calculul matricelor  $N_i$ ,  $M_i$  și  $L_i$ . S-au obținut

$$\begin{split} T_1 &= \begin{bmatrix} 1.762 & 106.706 & -37.476 & -76.960 \\ 0.496 & 24.372 & -8.343 & -17.427 \\ -2.670 & -181.424 & 64.477 & 131.380 \\ 0.863 & 48.280 & -16.802 & -34.714 \end{bmatrix}, \\ T_2 &= \begin{bmatrix} -2.525 & -149.388 & 74.953 & 76.960 \\ -0.991 & -33.121 & 16.686 & 17.427 \\ 5.340 & 253.994 & -127.954 & -131.380 \\ -1.727 & -67.592 & 33.605 & 35.714 \end{bmatrix}, \\ N_1 &= \begin{bmatrix} -0.848 & -80.588 & 44.413 & 20.948 \\ 80.668 & -0.901 & -79.414 & -4.795 \\ -44.467 & 79.306 & -1.035 & -9.173 \\ -20.852 & 4.837 & 9.082 & -0.886 \end{bmatrix}, \\ M_1 &= \begin{bmatrix} 957.7 \\ 216.9 \\ -1635 \\ 432 \end{bmatrix}, \\ L_1 &= \begin{bmatrix} 265 & 12610 & -6449 & -6432 \\ -704 & -31897 & 16106 & 16493 \\ 120 & 4518 & -2158 & -2470 \\ 110 & 5257 & -2692 & -2679 \end{bmatrix}, \\ N_2 &= \begin{bmatrix} -0.819 & -85.004 & -14.646 & 77.768 \\ 85.117 & -0.896 & -67.647 & -22.560 \\ 14.567 & 67.491 & -1.089 & -45.180 \\ -77.633 & 22.619 & 45.046 & -0.874 \end{bmatrix}, \\ M_2 &= \begin{bmatrix} 820.7 \\ 185.8 \\ -1401 \\ 370.2 \end{bmatrix}, \\ L_2 &= \begin{bmatrix} -147 & -6110 & 3005 & 3264 \\ -626 & -28378 & 14325 & 14682 \\ -9 & -1435 & 866 & 558 \\ 484 & 22256 & -11288 & -11446 \end{bmatrix}. \end{split}$$



Fig. 2.12. Erorile de estimare ale observerului Marx (algoritmul 2)

S-au obținut caracteristicile de timp din fig. 2.12 (erorile de estimare a celor 4 variabile de stare ale modelului (2.86)).

### 2.4.4. PROIECTAREA OBSERVERELOR PENTRU DECUPLAREA ȘI ATENUAREA INFLUENȚEI INTRĂRILOR NECUNOSCUTE ASUPRA SISTEMELOR DESCRIPTOR TAKAGI-SUGENO

Al treilea observer prezentat în [157] este destinat estimării stării sistemelor descriptor de tip Takagi-Sugeno, în condițiile decuplării și atenuării influenței intrărilor necunoscute. Dacă intrările necunoscute sunt prea numeroase și decuplarea lor nu este posibilă (condiția (2.100) nu este îndeplinită), se poate face un compromis în proiectarea observerului astfel încât să fie asigurate atât decuplarea cât și atenuarea intrărilor necunoscute prin condiții cât mai puțin restrictive. Într-o prima etapă, estimarea vectorului de stare este independentă (decuplată) de vectorul intrărilor necunoscute; apoi, în a doua etapă a proiectării estimatorului de stare, norma erorii de estimare este minimizată, adică este îmbunătățită robustețea observerului [157].

Vectorul intrărilor necunoscute se împarte în v(t) și  $\overline{v}(t)$ , matricele asociate lor fiind  $D_i$  și, respectiv,  $\overline{D}_i$ ; astfel, ecuațiile (2.86) devin

$$\begin{cases} E\dot{x}(t) = \sum_{i=1}^{M} \mu_i(\xi(t)) \left[ A_i x(t) + B_i u(t) + D_i v(t) + \overline{D}_i \overline{v}(t) \right], \\ y(t) = C x(t) + G v(t) + \overline{G} \overline{v}(t), \end{cases}$$
(2.120)

unde  $v(t) \in \mathcal{M}^{q \times 1}$  și  $\overline{v}(t) \in \mathcal{M}^{\overline{q} \times 1}$ . Scindarea intrărilor necunoscute în v(t) și  $\overline{v}(t)$  se face astfel încât să fie îndeplinite condițiile (2.100). Condițiile de existență ce trebuie satisfăcute pentru a putea proiecta noul observer sunt prezentate în cadrul următoarei teoreme:

### Teorema 2.5 [157]

Un observer de tipul (2.89), ce asigură decuplarea vectorului v(t) și robustețe maximă în raport cu  $\overline{v}(t)$ , există dacă este îndeplinită condiția

$$\operatorname{rang}(\overline{R}) = n + \operatorname{rang}[G \ \overline{G}] + \operatorname{rang}\begin{bmatrix} D_1 \ \dots \ D_M \end{bmatrix}$$

$$I_M \otimes G$$
(2.121)

și dacă, în plus, există o matrice simetrică și pozitiv definită  $P \in \mathcal{M}^{n \times n}$  și matricea  $\overline{T} \in \mathcal{M}^{n \times (n+(M+1)p)}$  – soluții ale inecuației matriceal-liniare

$$\begin{bmatrix} \overline{\Psi}_{i,1} & \overline{\Psi}_{i,2} \\ \overline{\Psi}_{i,2}^T & -\gamma^2 I \end{bmatrix} < 0$$
(2.122)

și a procesului de minimizare a constantei pozitive  $\gamma$ , unde matricele  $\overline{\Psi}_{i,1}$  și  $\overline{\Psi}_{i,2}$  au expresiile

$$\overline{\Psi}_{i,1} = P\overline{S} \ \overline{R}^+ S_i + \overline{T} \ \overline{R}^\perp S_i + \left(\overline{S} \ \overline{R}^+ S_i\right)^T P + \left(\overline{R}^\perp S_i\right)^T \overline{T}^{\ T} + I_n,$$

$$\overline{\Psi}_{i,2} = P\overline{S} \ \overline{R}^+ \overline{S}_i + \overline{T} \ \overline{R}^\perp \overline{S}_i,$$
(2.123)

iar  $\overline{R}$ ,  $\overline{S}$ ,  $S_i$  și  $\overline{S}_i$  sunt

$$\overline{R} = \begin{bmatrix} \overline{\widetilde{R}}_{1} & \overline{\widetilde{R}}_{2} \\ \overline{\widetilde{R}}_{3} & \overline{\widetilde{R}}_{4} \end{bmatrix}, \overline{S} = \begin{bmatrix} \overline{\widetilde{S}}_{1} & \overline{\widetilde{S}}_{2} \\ \overline{\widetilde{S}}_{2} \end{bmatrix}, \overline{S}_{i} = \begin{bmatrix} \overline{\widetilde{S}}_{i,1} \\ \overline{\widetilde{S}}_{i,2} \end{bmatrix}, S_{i} = \begin{bmatrix} \widetilde{S}_{i,1} \\ \overline{\widetilde{S}}_{i,2} \end{bmatrix},$$

$$\overline{\widetilde{R}}_{1} = \begin{bmatrix} E & 0_{n \times q} & 0_{n \times \overline{q}} \\ C & G & \overline{G} \end{bmatrix}, \overline{\widetilde{R}}_{2} = \begin{bmatrix} \begin{bmatrix} D_{1} & \dots & D_{M} \\ 0_{p \times q} & \dots & 0_{p \times q} \end{bmatrix}, \overline{\widetilde{R}}_{3} = \begin{bmatrix} 0_{pM \times n} & 0_{pM \times q} & 0_{pM \times \overline{q}} \end{bmatrix}, \quad (2.124)$$

$$\overline{\widetilde{R}}_{4} = I_{M} \otimes G, \overline{\widetilde{S}}_{1} = \begin{bmatrix} I_{n} & 0_{n \times (q + \overline{q})} \end{bmatrix}, \overline{\widetilde{S}}_{2} = 0_{n \times Mq}, \quad \overline{\widetilde{S}}_{i,1} = \begin{bmatrix} D_{i}^{T} & 0_{\overline{q} \times p} \end{bmatrix}^{T},$$

$$\overline{\widetilde{S}}_{i,2} = e_{i} \otimes \overline{G}, \quad \widetilde{S}_{i,1} = \begin{bmatrix} A_{i}^{T} & 0_{n \times p} \end{bmatrix}^{T}, \quad \widetilde{S}_{i,2} = e_{i} \otimes C;$$

 $e_i \in \mathcal{M}^{M \times 1}$  sunt vectori coloană cu toate componentele = 0 cu excepția componentei "*i*" care este egală cu 1.

#### <u>Demonstrație</u>

În [157] se demonstrează că dacă sunt îndeplinite condițiile (2.95) și  $T_2\overline{G} = 0$ , dinamica erorii noului observer este

$$\dot{e}(t) = \sum_{i=1}^{M} \mu_i(\xi(t)) \Big[ N_i e(t) + \left( T_1 \overline{D}_i + K_i \overline{G} \right) \overline{v}(t) \Big].$$
(2.125)

Constrângerile anterioare echivalează cu a determina o matrice  $\Omega$  astfel încât [157]

$$\Omega \,\overline{R} = \overline{S} \,. \tag{2.126}$$

Rezolvarea acestei ecuații matriceale este posibilă doar dacă  $\operatorname{rang}\left[\overline{R}^{T} \quad \overline{S}^{T}\right]^{T} = \operatorname{rang}\left(\overline{R}\right)$ , condiția fiind echivalentă cu (2.121). Soluția ecuației (2.126) este [157]

$$\Omega = \overline{S} \ \overline{R}^+ + T\overline{R}^\perp \,, \tag{2.127}$$

în care *T* urmează a fi determinată. Deoarece matricele  $N_i$  și  $(T_1\overline{D}_i - L_i\overline{G})$  pot fi scrise sub forma [157]

$$N_{i} = \Omega S_{i} = \overline{S} \,\overline{R}^{+} S_{i} + T \overline{R}^{\perp} S_{i} ,$$
  

$$T_{1} \overline{D}_{i} - L_{i} \overline{G} = \Omega \overline{S}_{i} = \overline{S} \,\overline{R}^{+} \overline{S}_{i} + T \overline{R}^{\perp} \overline{S}_{i} ,$$
(2.128)

stabilitatea dinamicii (2.125) urmează pașii teoremei 2.2 din [157]. Rescriind inecuația (2.108) pentru tripletul  $(N_i, (T_1\overline{D}_i - L_i\overline{G}), I_n)$  și alegând  $\overline{T} = PT$ , se obține LMI (2.122).

Condiția (2.121) este mai puțin restrictivă decât (2.100). Pentru obținerea decuplării perfecte a tuturor intrărilor necunoscute în (2.120),  $D_i$  și G trebuie înlocuite cu  $\left[D_i \ \overline{D}_i\right]$  și, respectiv,  $\left[G \ \overline{G}\right]$  în (2.121) și (2.124); se obține o constrângere mai ușor de îndeplinit [157]. Pentru sistemul (2.120) în descriere discretă, adică

$$\begin{cases} Ex_{k+1} = \sum_{i=1}^{M} \mu_i (\xi_k) [A_i x_k + B_i u_k + D_i v_k + \overline{D}_i \overline{v}_k], \\ y_k = Cx_k + Gv_k + \overline{G} \overline{v}_k , \end{cases}$$
(2.129)

observerul (2.90), ce asigură decuplarea vectorului  $v_k$  și robustețe maximă în raport cu  $\overline{v}_k$ , există dacă este îndeplinită condiția (2.121) și dacă există o matrice simetrică și pozitiv definită  $P \in \mathcal{M}^{n \times n}$  și o matrice  $\overline{T} \in \mathcal{M}^{n \times (n+(M+1)p)}$  – soluții ale inecuației [157]

$$\begin{bmatrix} I_n - P & 0 & \overline{\Phi}_{i,1}^T \\ 0 & -\gamma^2 I_n & \overline{\Phi}_{i,2}^T \\ \overline{\Phi}_{i,1} & \overline{\Phi}_{i,1} & -P \end{bmatrix} < 0$$
(2.130)

și a procesului de minimizare a constantei  $\gamma$ , unde matricele  $\overline{\Phi}_{i,1}$  și  $\overline{\Phi}_{i,2}$  au expresiile

$$\overline{\Phi}_{i,1} = P\overline{S} \,\overline{R}^+ S_i + \overline{T} \,\overline{R}^\perp S_i, 
\overline{\Phi}_{i,2} = P\overline{S} \,\overline{R}^+ \overline{S}_i + \overline{T} \,\overline{R}^\perp \overline{S}_i.$$
(2.131)

Sintetizând, algoritmul pentru proiectarea observerului Marx pentru decuplarea și atenuarea influenței intrărilor necunoscute asupra sistemelor descriptor de tip Takagi-Sugeno este următorul:

#### Algoritmul Marx (algoritmul 3)

**Pasul 1**: Se declară matricele  $A_i, B_i, D_i, \overline{D}_i, C, G, \overline{G}, E, i = \overline{1,M}$  și se stabilesc expresiile vectorului de decizie  $\xi(t)$  și expresiile funcțiilor de activare  $\mu_i(\xi(t)), i = \overline{1,M}$ .

**Pasul 2**: Se verifică îndeplinirea condiției (2.121); în caz contrar, acest estimator de stare nu poate fi construit.

**Pasul 3**: Se calculează  $\overline{R}$ ,  $\overline{S}$ ,  $\overline{S}_i$ ,  $S_i$  – ecuațiile (2.124) și se rezolvă LMI (2.122), sau (2.130) pentru varianta discretă, în raport cu P și  $\overline{T}$ ; apoi, se calculează  $T = P^{-1}\overline{T}$ .

**Pasul 4**: Utilizând ecuația (2.127), se determină matricea  $\Omega$ ; aceasta este de forma (2.97), deci, prin partiționarea ei, se obțin matricele  $T_1, T_2$  și  $K_i, i = \overline{1, M}$ ;

**Pasul 5**: Se calculează matricele  $N_i$  cu ajutorul primei ecuații (2.95) și matricele  $M_i$  și  $L_i$ - ultimele două ecuații (2.95). Se verifică dacă matricea  $\tilde{N}$  (expresia (2.40)) este stabilă și, de asemenea, se verifică dacă toate condițiile (2.95) sunt verificate.

**Pasul 6**: Utilizând matricele și vectorii calculați la pașii anteriori, se proiectează observerul descris de ecuațiile (2.89) – varianta continuă sau (2.90) – varianta discretă; pentru

validarea estimatorului de stare, se utilizează și ecuațiile ce descriu dinamica sistemului descriptor de tip Takagi-Sugeno (ecuațiile de stare – ieșire (2.120) sau (2.129)).

Observerul Marx (algoritmul 3) este validat în Matlab/Simulink; a fost aleasă, pentru validarea observerului, același model al mișcării longitudinale ca în paragraful 2.4.2; vectorul intrărilor necunoscute v și funcțiile de activare sunt, și ele, aceleași. Matricele  $\overline{D}_i$ , $i=\overline{1,2}$ , și noile matrice  $D_i$  se determină prin partiționarea vechilor matrice  $D_i$ ; la fel se întâmplă și în cazul matricelor G și  $\overline{G}$ . Se verifică, în cadrul pasului 2, îndeplinirea condiției (2.121), iar, în cadrul pasului 3 al algoritmului Marx – varianta 3, se calculează  $\overline{R}$ ,  $\overline{S}$ ,  $\overline{S}_i$ ,  $S_i$  și se rezolvă LMI (2.112) în raport cu necunoscutele P și  $\overline{T}$ ; apoi, se calculează  $T = P^{-1}\overline{T}$ . Au rezultat matricele

$$P = \begin{bmatrix} 1.252 & 0 & 0 & 0 \\ 0 & 1.252 & 0 & 0 \\ 0 & 0 & 1.252 & 0 \\ 0 & 0 & 0 & 1.252 \end{bmatrix}, T = \begin{bmatrix} T_{11} & T_{12} & T_{13} & T_{14} \end{bmatrix}, T_{11} = \begin{bmatrix} 34.13 & 33.97 & 87.24 & 42.54 \\ -70.02 & -196.12 & 35.62 & -326.54 \\ -103.61 & -89.28 & -294.98 & 554.43 \\ 30.12 & -232.60 & -17.32 & 141.03 \end{bmatrix}, T_{12} = \begin{bmatrix} -81.42 & 38.86 & -165.14 & 122.53 \\ 74.03 & 161.39 & -28.09 & 93.17 \\ 69.84 & -292.89 & 252.18 & 266.83 \\ -110.05 & -247.12 & -148.38 & -17.16 \end{bmatrix}, T_{13} = \begin{bmatrix} 3.04 & -31.12 & 105.22 & -45.94 \\ 102.41 & 106.09 & 43.12 & -163.01 \\ -28.12 & 25.59 & -358.28 & 109.54 \\ -19.69 & 22.25 & 33.60 & 48.72 \end{bmatrix}, T_{14} = \begin{bmatrix} 33.38 & 138.64 & 61.02 & -106.02 \\ -130.23 & 21.87 & -2.57 & -264.27 \\ 119.53 & 12.55 & -272.56 & 253.16 \\ -32.96 & -119 & 1.26 & -4.01 \end{bmatrix}.$$

În cadrul pasului 4, se determină matricele  $T_1$ ,  $T_2$  și  $K_i$ ,  $i = \overline{1,2}$ ; acestea fiind utilizate pentru calculul matricelor  $N_i$ ,  $M_i$  și  $L_i$ . S-au obținut

$$T_1 = \begin{bmatrix} 12.438 & -41.683 & 54.988 & -75.496 \\ 20.364 & -59.547 & 85.911 & -128.184 \\ -30.887 & 128.031 & -142.875 & 169.280 \\ -0.662 & -19.091 & 6.650 & 15.751 \end{bmatrix}, \\ T_2 = \begin{bmatrix} -23.876 & 58.356 & -109.976 & 75.496 \\ -40.728 & 84.366 & -171.822 & 128.184 \\ 61.774 & -179.244 & 286.750 & -169.280 \\ 1.324 & 26.728 & -13.301 & -14.751 \end{bmatrix}, \\ N_1 = \begin{bmatrix} -0.899 & -85.231 & -21.084 & 37.811 \\ 85.231 & -0.899 & -172.980 & -26.080 \\ 21.084 & 172.980 & -0.899 & -18.503 \\ -37.811 & 26.080 & 18.503 & -0.899 \end{bmatrix}, \\ M_1 = \begin{bmatrix} 945.4 \\ 1604.7 \\ -2121.1 \\ -196.1 \end{bmatrix}, \\ L_1 = \begin{bmatrix} 2242 & -2418 & 8094 & -7932 \\ -12805 & 35117 & -58501 & 36166 \\ -7655 & 15411 & -31749 & 24026 \\ 1024 & -3347 & 4983 & -2658 \end{bmatrix}, \\ N_2 = \begin{bmatrix} -0.899 & 42.357 & -91.822 & -10.300 \\ -42.357 & -0.899 & -107.230 & 49.473 \\ 91.822 & 107.230 & -0.899 & -46.935 \\ 10.30 & -49.473 & 46.935 & -0.899 \end{bmatrix}, \\ M_2 = \begin{bmatrix} 820.8 \\ 1392.4 \\ -1844.1 \\ -168.3 \end{bmatrix}, \\ L_2 = \begin{bmatrix} -7392 & 19597 & -33402 & 21194 \\ -5476 & 17878 & -26686 & 14278 \\ -6766 & 13331 & -27853 & 21300 \\ 4661 & -11930 & 20798 & -13531 \end{bmatrix}.$$



Fig. 2.13. Erorile de estimare ale observerului Marx (algoritmul 3)

S-au obținut caracterisiticile de timp din fig. 2.13 (erorile de estimare a variabilelor de stare ale modelului (2.86)).



Fig. 2.14. Erorile de estimare asociate celor 3 variante de observer multiplu Marx

Evoluțiile în timp ale erorilor asociate celor 4 variabile de stare sunt, așadar, pre-

zentate în fig. 2.11 (algoritmul Marx – varianta 1), fig. 2.12 (algoritmul Marx – varianta 2) și, respectiv, fig. 2.13 (algoritmul Marx – varianta 3). Toate cele trei variante de observer multiplu Marx au fost implementate software pentru același tip de avion, aceeași dinamică, funcții de activare, etc. În aceste condiții, se pot compara vitezele de convergență ale celor trei variante de observer Marx reprezentând grafic, în același sistem de coordonate, cele 4 erori de estimare – fig. 2.14. Vitezele de convergență ale celor 3 observere Marx sunt apropiate, cu un mic avantaj pentru varianta 1.

### 2.4.5. PROIECTAREA UNUI OBSERVER PENTRU DETECȚIA DEFECTELOR

În cadrul acestui paragraf, observerele pentru decuplarea și atenuarea intrărilor necunoscute sunt utilizate pentru detectarea defectelor. Se consideră un sistem desscriptor de tip Takagi-Sugeno afectat de defectele  $f(t) \in \mathcal{M}^{q \times 1}$  și perturbațiile  $w(t) \in \mathcal{M}^{\bar{q} \times 1}$ ; ecuațiile asociate acestui sistem sunt [157]

$$\begin{cases} E\dot{x}(t) = \sum_{i=1}^{M} \mu_i(\xi(t)) [A_i x(t) + B_i u(t) + D_{f_i} f(t) + D_{w_i} w(t)], \\ y(t) = C x(t) + G_f f(t) + G_w w(t), \end{cases}$$
(2.132)

în variantă continuă, sau

$$\begin{cases} Ex_{k+1} = \sum_{i=1}^{M} \mu_i(\xi_k) [A_i x_k + B_i u_k + D_{f_i} f_k + D_{w_i} w_k], \\ y_k = Cx_k + G_f f_k + G_w w_k, \end{cases}$$
(2.133)

în variantă discretă. Se presupune că perturbațiile sunt mărginite, adică  $|w_i(t)| < \delta_i$ , respectiv  $|w_{ik}| < \delta_i$ ,  $(\forall)i = \overline{1, q}$  și  $(\forall)k$ . Detectarea defectelor se poate face utilizând metoda prezentată în [230]; în cadrul acestei metode, sunt proiectate "q" observere pentru decuplarea și atenuarea intrărilor necunoscute. Observerul "r" este proiectat consi-derându-se că defectul "r" este intrare necunoscută. Un subset al perturbațiilor  $\Sigma_r$  este considerat în [157] astfel încât să fie îndeplinită constrângerea (2.121); cu alte cuvinte, observerul "r" este proiectat pentru sistemul descris de ecuațiile (2.120), unde, de data aceasta [157],

$$D_{i} = \begin{bmatrix} D_{f_{i}}^{r} & D_{w_{i}}^{j} \end{bmatrix}, j \in \Sigma_{r}, \overline{D}_{i} = \begin{bmatrix} D_{w_{i}}^{j} \end{bmatrix}, j \in \overline{\Sigma}_{r},$$
  

$$G = \begin{bmatrix} G_{f}^{r} & G_{w}^{j} \end{bmatrix}, j \in \Sigma_{r}, \overline{G} = \begin{bmatrix} G_{w}^{j} \end{bmatrix}, j \in \overline{\Sigma}_{r},$$
(2.134)

unde notația  $M^r$  este asociată coloanei "*r*" a unei matrice M, iar  $\overline{\Sigma}_r$  reprezintă complementul lui  $\Sigma_r$ . Ca o consecința, estimarea ieșirii observerului "*r*" este sensibilă la toate defectele, insensibilă la defectul "*r*" și la un set de perturbații  $\Sigma_r$  și are robustețe maximă la toate perturbațiile ce aparțin setului  $\overline{\Sigma}_r$ . Metoda clasică de detecție a defectelor se bazează pe faptul că defectul "*r*" apare dacă semnalele reziduale, cu excepția celui al "*r*"-lea sunt mult diferite de zero. Astfel, pentru fiecare defect  $f_r(t)$ , respectiv  $f_{r_k}$ , se proiectează un observer de tipul celui din paragraful anterior, acesta fiind sensibil la toate defectele cu excepția  $f_r(t)$ , respectiv  $f_{r_k}$ , insensibil la  $w_i(t)$ , respectiv  $w_{i_k}$ ,  $i \in \Sigma_r$ și având robustețe maximă în raport cu  $w_i(t)$ , respectiv  $w_{i_k}$ ,  $i \in \overline{\Sigma}_r$ . Apoi, se calculează marginea superioară a perturbațiilor [157]

$$\varepsilon_r = \sqrt{\sum_{i \in \overline{\Sigma}_r} \rho_i^2}; \qquad (2.135)$$

pentru fiecare componentă a ieșirii  $y_j(t)$ , respectiv  $y_{j_k}$ , se calculează norma  $L_2$ , notată cu  $g_{r_j}$  utilizând perturbațiile  $\{w_i(t), i \in \Sigma_r\}$ , respectiv  $\{w_{i_k}, i \in \overline{\Sigma}_r\}$ , eroarea de ieșire și vectorul boolean

$$b_r(t) = [b_{r_1}(t) \ b_{r_2}(t) \ \dots \ b_{r_p}(t)],$$
 (2.136)

pentru varianta continuă, respectiv

$$b_{r_k} = \begin{bmatrix} b_{r_1 k} & b_{r_2 k} & \cdots & b_{r_p k} \end{bmatrix},$$
(2.137)

pentru varianta discretă;  $b_{r_i}(t)$ , respectiv  $b_{r_i k}$ , se definesc astfel [157]:

$$b_{r_{j}}(t) = \begin{cases} 1, \text{ daca } |\hat{y}_{r_{j}}(t) - y_{j}(t)| > \alpha g_{r_{j}} \rho_{r}, \\ 0, \text{ daca } |\hat{y}_{r_{j}}(t) - y_{j}(t)| \le \alpha g_{r_{j}} \rho_{r}, \end{cases}$$

$$b_{r_{jk}} = \begin{cases} 1, \text{ daca } |\hat{y}_{r_{jk}} - y_{jk}| > \alpha g_{r_{j}} \rho_{r}, \\ 0, \text{ daca } |\hat{y}_{r_{jk}} - y_{jk}| \le \alpha g_{r_{j}} \rho_{r}, \end{cases}$$
(2.138)

unde  $\hat{y}_{r_j}(t)$ , respectiv  $\hat{y}_{r_{jk}}$ , reprezintă componenta "*j*" a estimatei ieșirii observerului "*r*";  $\alpha$  este o constantă pozitivă. În continuare, se calculează semnalele "alarmă"  $a_r(t)$ , respectiv  $a_{r_k}$ , afectate de  $f_r(t)$ , respectiv  $f_{r_k}$ , definite, în cazul continuu de [157]

$$a_{r}(t) = \begin{cases} 1, \text{ daca } b_{i}(t)b_{i}^{T}(t) \ge 1, (\forall)i \neq r \text{ si } b_{r}(t)b_{r}^{T}(t) = 0, \\ 0, \text{ in caz contrar }, \end{cases}$$
(2.139)

sau, în variantă discretă, de

$$a_{r_k} = \begin{cases} 1, \text{ daca } b_{i_k} \ b_{i_k}^T \ge 1, (\forall) i \neq r \text{ si } b_{r_k} \ b_{r_k}^T = 0, \\ 0, \text{ in caz contrar }. \end{cases}$$
(2.140)

În [157] se demonstrează că această structură generalizată de observer este eficientă în procesul de detecție și izolare a defectelor; structura reprezintă o modificare a observerului prezentat anterior; astfel, pentru sistemele descriptor de tipul (2.120), respectiv (2.129), se modifică matricele  $D_i$ ,  $\overline{D}_i$  și  $\overline{G}$  după cum urmează [157]:

$$D_{i} = \begin{bmatrix} D_{i,1} & D_{i,2} \end{bmatrix}, G = \begin{bmatrix} G_{1} & G_{2} \end{bmatrix}, \overline{D}_{i} = \begin{bmatrix} D_{w_{i}}^{j} \end{bmatrix}, j \in \overline{\Sigma}_{r}, \overline{G} = \begin{bmatrix} G_{w}^{j} \end{bmatrix}, j \in \overline{\Sigma}_{r},$$

$$D_{i,1} = \begin{bmatrix} D_{f_{i}}^{1} & \dots & D_{f_{i}}^{r-1} & D_{f_{i}}^{r+1} & \dots & D_{f_{i}}^{q} \end{bmatrix}, D_{i,2} = D_{w_{i}}^{j}, j \in \Sigma_{r},$$

$$G_{1} = \begin{bmatrix} G_{f_{i}}^{1} & \dots & G_{f_{i}}^{r-1} & G_{f_{i}}^{r+1} & \dots & G_{f_{i}}^{q} \end{bmatrix}, G_{2} = G_{w_{i}}^{j}, j \in \Sigma_{r}.$$
(2.141)

## 2.5. OBSERVER MULTIPLU DE TIP ALUNECĂTOR PENTRU DETECȚIA ȘI IZOLAREA DEFECTELOR

## 2.5.1. UTILITATEA OBSERVERELOR MULTIPLE DE TIP ALUNECĂTOR ÎN PROCESUL DE DETECȚIE ȘI IZOLARE A DEFECTELOR

Procedura generală pentru utilizarea observerelor pentru detecția și izolarea defectelor constă în 3 etape: 1) estimarea ieșirii sistemului prin intermediul unui observer; 2) compararea ieșirii estimate cu ieșirea măsurată și, deci, obținerea semnalelor reziduale; 3) analiza semnalelor reziduale pentru a vedea dacă a apărut sau nu un defect în cadrul sistemului [6]. Procesul de decizie se bazează fie pe un test simplu cu prag, fie pe utilizarea unui criteriu ce folosește o medie a semnalelor reziduale. Atunci când siste-mul în cauză este influențat de intrări necunoscute, este nevoie de decuplarea intrărilor necunoscute, aceasta conducând la evitarea unor alarme false în procedura de detecție a defectelor. Această problematică poartă în literatura de specialitate numele de "problemă robustă de detecție a defectelor" și se rezolvă prin utilizarea observerelor pentru sistemele cu intrări necunoscute [6], [175]. Multe observere [79], [217] au fost proiectate pentru sistemele cu intrări necu-noscute, însă puține lucrări vizează estimatoarele de stare pentru sistemele neliniare afec-tate de intrări necunoscute [4], [121]. Pintre cele mai utilizate observere pentru siste-mele neliniare se numără observerele multiple pentru sistemele descriptor Takagi-Sugeno [220] sau observerele de tip alunecător [6].

Conceptul de "alunecare" provine din fosta Uniune Sovietică, anii `60, când efectul introducerii discontinuităților în procesul de control al sistemelor dinamice a fost folosit. S-a demonstrat atunci că, printr-o alegere convenabilă a legilor de control, stările unui sistem atingeau și apoi se mențineau într-o suprafată predefinită din spațiul stărilor. Această "mișcare", numită "mișcare de alunecare", s-a dovedit a fi insensibilă la necunoscute sau semnale perturbatoare externe [6]. A rezultat așa-numitul "control robust de tip alunecător", care apoi a fost extins și la procesul de estimare a stării. Primul cercetător în acest domeniu a fost Utkin, care a obținut o structură discontinuă pentru observerul descris în [212]; Walcott și Zak au utilizat metoda Lyapunov pentru a proiecta un observer pentru care eroarea de estimare a stării scade asimptotic către zero în prezența unor neliniarități mărginite și incertitudini (necunoscute de modelare) [217]. Edwards și Spugeon au proiectat observere asemănătoare cu cel al lui Walcott & Zak, obținând algoritmi expliciți de proiectare; a fost utilizată, de asemenea, sinteza regulatoarelor prin intermediul metodei modelelor continue [24].

### 2.5.2. PROIECTAREA OBSERVERELOR MULTIPLE DE TIP ALUNECĂTOR

Se consideră un sistem neliniar reprezentat prin intermediul modelului multiplu (2.3), în care se neglijează necunoscutele de modelare  $(\Delta A_i(t))$ ; semnificația și dimensi-

unile matricelor  $A_i$ ,  $B_i$ ,  $D_i$ , C,  $i = \overline{1, M}$ , și vectorilor x(t), u(t), v(t), y(t),  $d_i$ ,  $\xi(t)$  sunt aceleași ca în cazul modelului multiplu prezentat în [5]. Mai mult, funcțiile de activare  $\mu_i(\xi(t))$ ,  $i = \overline{1, M}$ , respectă, și în acest caz, proprietățile (2.2).

Observerul propus în [6] este o combinație liniară de observere locale, fiecare dintre acestea având structura din [217]. În cadrul proiectării estimatorului de stare, se presupune că intrările necunoscute sunt mărginite  $(||v(t)|| < \rho)$  și că există matricele  $G_i \in \mathcal{M}^{n \times p}$  astfel încât  $A_{0_i} = A_i - G_i C$  au valorile proprii stabile și există perechile Lyapunov  $(P, Q_i)$  astfel încât sunt satisfăcute constrângerile [6]

$$\begin{cases} A_{0_i}^T P + P A_{0_i} = -Q_i , \\ C^T F_i^T = P D_i , i = \overline{1, M} . \end{cases}$$
(2.142)

Observerul propus în [6] are forma

$$\begin{cases} \dot{\hat{x}}(t) = \sum_{i=1}^{M} \mu_i(\xi(t)) \{A_i \ \hat{x}(t) + B_i u(t) + G_i[y(t) - C\hat{x}(t)] + K_i \gamma_i(t)\}, \\ \hat{y}(t) = C\hat{x}(t). \end{cases}$$
(2.143)

Proiectarea observerului presupune determinarea matricelor  $G_i$ ,  $K_i$  și a vectorilor  $\gamma_i \in \mathcal{M}^{q \times 1}$  ce garantează convergența exponențială a lui  $\hat{x}(t)$  către x(t). Ecuațiile (2.142) sunt necesare pentru a putea separa vectorul intrărilor necunoscute v(t) de restul sistemului. Primul pas ce trebuie făcut în cadrul procesului de estimare a stării modelului multiplu este o primă schimbare de coordonate [6].

Se presupune că perechile  $(A_i, C)$  sunt observabile; deoarece ieșirile sistemului sunt luate în considerare în cadrul proiectării observerului, este logic ca acestea să afecteze schimbările de coordonate astfel încât ieșirile să apară ca și componente ale noului vector de stare. Fără micșorarea generalității, matricea de distribuție *C* se poate scrie întotdeauna sub forma [6]

$$C = \begin{bmatrix} C_1 & C_2 \end{bmatrix}, \tag{2.144}$$

unde  $C_1 \in \mathcal{M}^{p \times (n-p)}, C_2 \in \mathcal{M}^{p \times p}$  și  $\det(C_2) \neq 0$ .

Se face schimbarea de coordonate  $\tilde{x}(t) = \tilde{T}x(t)$ , în care

$$\widetilde{T} = \begin{bmatrix} I_{n-p} & 0_{(n-p)\times p} \\ C_1 & C_2 \end{bmatrix};$$
(2.145)

 $\widetilde{T} \in \mathcal{M}^{n \times n}$  este o matrice nesingulară. În aceste condiții, noua matrice C, adică  $\widetilde{C}$ , este

$$\widetilde{C} = C\widetilde{T}^{-1} = \begin{bmatrix} 0 & I_p \end{bmatrix}, \qquad (2.146)$$

în timp ce celelalte matrice ale sistemului sunt [6]

$$\widetilde{A}_{i} = \widetilde{T}A_{i}\widetilde{T}^{-1} = \begin{bmatrix} \widetilde{A}_{11_{i}} & \widetilde{A}_{12_{i}} \\ \widetilde{A}_{21_{i}} & \widetilde{A}_{22_{i}} \end{bmatrix}, \widetilde{B}_{i} = \widetilde{T}B_{i} = \begin{bmatrix} \widetilde{B}_{1_{i}} \\ \widetilde{B}_{2_{i}} \end{bmatrix}, \widetilde{d}_{i} = \widetilde{T}d_{i} = \begin{bmatrix} \widetilde{d}_{1_{i}} \\ \widetilde{d}_{2_{i}} \end{bmatrix}, \widetilde{D}_{i} = \widetilde{T}D_{i} = \begin{bmatrix} \widetilde{D}_{1_{i}} \\ \widetilde{D}_{2_{i}} \end{bmatrix}.$$
(2.147)

După schimbarea de coordonate  $\tilde{x}(t) = \tilde{T}x(t)$ , ecuațiile (2.142) conduc la

$$\widetilde{P} = \left(\widetilde{T}^{-1}\right)^T P \widetilde{T}^{-1}, \widetilde{Q}_i = \left(\widetilde{T}^{-1}\right)^T Q_i \widetilde{T}^{-1}, \widetilde{C}^T F_i^T = \widetilde{P} \widetilde{D}_i.$$
(2.148)

Conform ecuației (2.146), rezultă  $y(t) = \widetilde{C} [\widetilde{x}_1(t) \ \widetilde{x}_2(t)]^T = [0 \ I_p] [\widetilde{x}_1(t) \ \widetilde{x}_2(t)] = \widetilde{x}_2(t);$  de asemenea, conform (2.147), modelul multiplu (2.3), cu  $\Delta A_i(t) = 0$ , se scrie acum [6]

$$\begin{cases} \dot{\widetilde{x}}(t) = \sum_{i=1}^{M} \mu_i(\xi(t)) \Big[ \widetilde{A}_i \ \widetilde{x}(t) + \widetilde{B}_i u(t) + \widetilde{D}_i v(t) + \widetilde{d}_i(t) \Big], \\ y(t) = \widetilde{x}_2(t), \end{cases}$$
(2.149)

unde  $\tilde{x}(t) = [\tilde{x}_1(t) \ \tilde{x}_2(t)]^T$ . În consecință, această primă schimbare de coordonate permite exprimarea directă a vectorului de ieșire ca parte a noului vector de stare [6].

Se utilizează, în continuare, principiile observerelor robuste din [217], acestea fiind adaptate pentru cazul observerelor multiple. Astfel, se consideră modelele locale  $(\tilde{A}_i, \tilde{B}_i, \tilde{D}_i, \tilde{C})$  – ecuațiile (2.149), unde  $\tilde{A}_i$  sunt matrice stabile, și modelele descrise de  $(\overline{A}_i, \overline{B}_i, \overline{D}_i, \overline{C})$ , legătura dintre cele două seturi de matrice făcându-se prin intermediul unei alte transformări de coordonate  $\overline{T}$ , adică

$$\overline{x}(t) = \overline{T}\widetilde{x}(t); \qquad (2.150)$$

în aceste condiții, se obțin [6], [217]

$$\overline{A}_{i} = \overline{T}\widetilde{A}_{i}\overline{T}^{-1} = \begin{bmatrix} \overline{A}_{11_{i}} & \overline{A}_{12_{i}} \\ \overline{A}_{21_{i}} & \overline{A}_{22_{i}} \end{bmatrix}, \overline{B}_{i} = \overline{T}\widetilde{B}_{i} = \begin{bmatrix} \overline{B}_{1_{i}} \\ \overline{B}_{2_{i}} \end{bmatrix}, \overline{C} = \widetilde{C}\overline{T}^{-1},$$

$$\overline{d}_{i} = \overline{T}\widetilde{d}_{i} = \begin{bmatrix} \overline{d}_{1_{i}} \\ \overline{d}_{2_{i}} \end{bmatrix}, \overline{D}_{i} = \overline{T}\widetilde{D}_{i} = \begin{bmatrix} \overline{D}_{1_{i}} \\ \overline{D}_{2_{i}} \end{bmatrix}.$$
(2.151)

<u>Teorema 2.6</u> [6]

Fie  $(\widetilde{A}_i, \widetilde{B}_i, \widetilde{D}_i, \widetilde{C})$  un model local pentru care există perechea  $(\widetilde{P}, F_i)$  definită prin intermediul celei de-a treia ecuații (2.148). În acest caz, există o matrice de transformare nesingulară  $\overline{T}$  astfel încât setul de matrice  $(\overline{A}_i, \overline{B}_i, \overline{D}_i, \overline{C})$  are proprietățile:

1)  $\overline{A}_{0_{i}} = \overline{A}_{i} - \overline{G}_{i}\overline{C} = \begin{bmatrix} \overline{A}_{011_{i}} & \overline{A}_{012_{i}} \\ \overline{A}_{021_{i}} & \overline{A}_{022_{i}} \end{bmatrix}$ , unde  $\overline{A}_{011_{i}} = \overline{A}_{11i} \in \mathcal{M}^{(n-p)\times(n-p)}$  sunt matrice stabile; 2)  $\overline{D}_{i} = \begin{bmatrix} 0 \\ P_{22}^{*}F_{i}^{T} \end{bmatrix}$ , unde  $P_{22}^{*} \in \mathcal{M}^{p\times p}$  și  $P_{22}^{*} = (P_{22}^{*})^{T} > 0$ ; 3)  $\overline{C} = \widetilde{C}\overline{T}^{-1} = \begin{bmatrix} 0 & I_{p} \end{bmatrix}$ ; 4)  $\overline{P} = (\overline{T}^{-1})^{T}\widetilde{P}\overline{T}^{-1} = \begin{bmatrix} \overline{P}_{1} & 0 \\ 0 & \overline{P}_{2} \end{bmatrix}$ .

#### <u>Demonstrație</u>

Se consideră perechea  $(\widetilde{P}, F_i)$  asociată modelului local  $(\widetilde{A}_i, \widetilde{B}_i, \widetilde{D}_i, \widetilde{C})$  și matricea simetrică și pozitiv definită (matrice Lyapunov)  $\widetilde{P}$  scrisă sub forma [6]

$$\widetilde{P} = \begin{bmatrix} \widetilde{P}_{11} & \widetilde{P}_{12} \\ \widetilde{P}_{21} & \widetilde{P}_{22} \end{bmatrix}, \qquad (2.152)$$

în care  $\widetilde{P}_{11} \in \mathcal{M}^{(n-p)\times(n-p)}$  – matrice Lyapunov,  $\widetilde{P}_{12} \in \mathcal{M}^{(n-p)\times p}$ ,  $\widetilde{P}_{22} \in \mathcal{M}^{p\times p}$ . Se definește o schimbare de coordonate prin intermediul transformării

$$\overline{T} = \begin{bmatrix} \widetilde{P}_{11} & \widetilde{P}_{12} \\ 0 & I_p \end{bmatrix}, \qquad (2.153)$$

matrice nesingulară deoarece det  $(\overline{T}) = \det(\widetilde{P}_{11}) \neq 0$  întucât  $\widetilde{P}_{11} = \widetilde{P}_{11}^T > 0$ .

În demonstrația proprietăților 1) - 4) se utilizează următoarea lemă:

<u>Lema 2.2</u>

Inversul unei matrice de forma 
$$T = \begin{bmatrix} A & B \\ 0 & I \end{bmatrix}$$
 este  $T^{-1} = \begin{bmatrix} A^{-1} & -A^{-1}B \\ 0 & I \end{bmatrix}$ .

Utilizând lema 2.2,  $\overline{C}$  din proprietatea 3) devine succesiv

$$\overline{C} = \widetilde{C}\overline{T}^{-1} = \begin{bmatrix} 0 & I_p \end{bmatrix} \begin{bmatrix} \widetilde{P}_{11}^{-1} & -\widetilde{P}_{11}^{-1}\widetilde{P}_{12} \\ 0 & I_p \end{bmatrix} = \begin{bmatrix} 0 & I_p \end{bmatrix}.$$
(2.154)

De asemenea, din a 3-a ecuație (2.148), se obține  $\widetilde{D}_i = \widetilde{P}^{-1}\widetilde{C}^T F_i^T$ ; dacă  $\widetilde{P}^{-1}$  se consideră

de forma [6]:  $\tilde{P}^{-1} = \begin{bmatrix} \tilde{P}_{11} & \tilde{P}_{12} \\ \tilde{P}_{21} & \tilde{P}_{22} \end{bmatrix}^{-1} = \begin{bmatrix} P_{11}^* & P_{12}^* \\ P_{21}^* & P_{22}^* \end{bmatrix}$ , rezultă

$$\widetilde{D}_{i} = \begin{bmatrix} P_{11}^{*} & P_{12}^{*} \\ P_{21}^{*} & P_{22}^{*} \end{bmatrix} \begin{bmatrix} 0 \\ I_{p} \end{bmatrix} F_{i}^{T} = \begin{bmatrix} P_{12}^{*} \\ P_{22}^{*} \end{bmatrix} F_{i}^{T} \Rightarrow \overline{D}_{i} = \overline{T}\widetilde{D}_{i} = \begin{bmatrix} \widetilde{P}_{11} & \widetilde{P}_{12} \\ 0 & I_{p} \end{bmatrix} \begin{bmatrix} P_{12}^{*} \\ P_{22}^{*} \end{bmatrix} F_{i}^{T} = \begin{bmatrix} \widetilde{P}_{11}P_{12}^{*} + \widetilde{P}_{12}P_{22}^{*} \\ P_{22}^{*} \end{bmatrix} F_{i}^{T} = \begin{bmatrix} 0 \\ P_{22}^{*} \end{bmatrix} F_{i}^{T},$$
(2.155)

deoarece se poate demonstra ușor că  $\tilde{P}_{11}P_{12}^* + \tilde{P}_{12}P_{22}^* = 0$ .

Pentru demonstrația condiției 4), se procedează după cum urmează: dacă există o matrice simetrică și pozitiv definită  $\tilde{P}$  ce verifică prima ecuație (2.148), matricea  $\overline{P} = (\overline{T}^{-1})^T \tilde{P} \overline{T}^{-1} = (\overline{T}^{-1})^T (\tilde{T}^{-1})^T P \widetilde{T}^{-1} \overline{T}^{-1}$  este simetrică și pozitiv definită pentru  $\overline{A}_{0_i}$ și satisface constrângerea  $\overline{C}^T F_i^T = \overline{P} \overline{D}_i$ ,  $(\forall) i = \overline{1, M}$ . Folosind partiționarea matricelor  $\widetilde{P}$  și  $\overline{T}$ , se obține [6]

$$\overline{P} = \begin{bmatrix} \widetilde{P}_{11}^{-1} & 0 \\ -\widetilde{P}_{12}^{-1}\widetilde{P}_{11}^{-1} & I_p \end{bmatrix} \begin{bmatrix} \widetilde{P}_{11} & \widetilde{P}_{12} \\ \widetilde{P}_{12}^{T} & \widetilde{P}_{22} \end{bmatrix} \begin{bmatrix} \widetilde{P}_{11}^{-1} & -\widetilde{P}_{11}^{-1}\widetilde{P}_{12} \\ 0 & I_p \end{bmatrix} = \begin{bmatrix} I_{n-p} & -\widetilde{P}_{11}^{-1}\widetilde{P}_{12} \\ 0 & -\widetilde{P}_{12}^{T}\widetilde{P}_{11}^{-1}\widetilde{P}_{12} + \widetilde{P}_{22} \end{bmatrix} \cdot \\
\cdot \begin{bmatrix} \widetilde{P}_{11}^{-1} & -\widetilde{P}_{11}^{-1}\widetilde{P}_{12} \\ 0 & I_p \end{bmatrix} = \begin{bmatrix} \widetilde{P}_{11}^{-1} & -\widetilde{P}_{11}^{-1}\widetilde{P}_{12} + \widetilde{P}_{11}^{-1}\widetilde{P}_{12} \\ 0 & -\widetilde{P}_{12}^{T}\widetilde{P}_{11}^{-1}\widetilde{P}_{12} + \widetilde{P}_{22} \end{bmatrix} = \begin{bmatrix} \overline{P}_{1} & 0 \\ 0 & \overline{P}_{2} \end{bmatrix},$$
(2.156)

unde

$$\overline{P}_{1} = P_{11}^{-1}, 
\overline{P}_{2} = \widetilde{P}_{22} - \widetilde{P}_{12}^{T} \widetilde{P}_{11}^{-1} \widetilde{P}_{12}.$$
(2.157)

De asemenea, în [6] se demonstrează că  $\overline{A}_{0_{11i}}$  și  $\overline{A}_{0_{22i}}$  sunt stabile. Într-adevăr, din prima ecuație (2.142) și ecuația (2.156), se obține

$$A_{0_i}^T P + P A_{0_i} < 0 (2.158)$$

sau

$$\begin{bmatrix} \overline{A}_{0_{11i}} & \overline{A}_{0_{12i}} \\ \overline{A}_{0_{21i}} & \overline{A}_{0_{22i}} \end{bmatrix}^T \begin{bmatrix} \overline{P}_1 & 0 \\ 0 & \overline{P}_2 \end{bmatrix} + \begin{bmatrix} \overline{P}_1 & 0 \\ 0 & \overline{P}_2 \end{bmatrix} \begin{bmatrix} \overline{A}_{0_{11i}} & \overline{A}_{0_{12i}} \\ \overline{A}_{0_{21i}} & \overline{A}_{0_{22i}} \end{bmatrix} < 0 \Leftrightarrow \begin{cases} \overline{A}_{011i}^T \overline{P}_1 + \overline{P}_1 \overline{A}_{011i} < 0, \\ \overline{A}_{022i}^T \overline{P}_2 + \overline{P}_2 \overline{A}_{022i} < 0. \end{cases}$$
(2.159)

Dar,  $\overline{A}_{0_{11i}} = \overline{A}_{11i} - (\overline{G}_i \overline{C})_{11} = \overline{A}_{11i}$  deoarece  $(\overline{G}_i \overline{C})_{11} = 0, (\forall) \overline{G}_i \in \mathcal{M}^{n \times p}$  întrucât  $\overline{C} = \begin{bmatrix} 0 & I_p \end{bmatrix}$ . Ca urmare, matricele  $\overline{A}_{0_{11i}} = \overline{A}_{11i}$  sunt stabile și, deci, condiția 1) a fost și ea demonstrată.

Se presupune că există o pereche de matrice Lyapunov  $(\tilde{P}, \tilde{Q}_i)$  ce verifică constrângerea (2.148) pentru fiecare model local "*i*" descris de matricele  $(\tilde{A}_i, \tilde{B}_i, \tilde{D}_i, \tilde{C})$ . Prin intermediul transformării de coordonate (2.150), cu  $\overline{T}$  de forma (2.153), unde  $\tilde{P}_{11}$ și  $\tilde{P}_{22}$  – submatrice ale matricei  $\tilde{P}$  (ecuația (2.152)), modelul multiplu descris de ecuația (2.149) devine [6]

$$\begin{cases} \dot{\overline{x}}(t) = \sum_{i=1}^{M} \mu_i(\xi(t)) \left[ \overline{A_i} \ \overline{x}(t) + \overline{B_i} u(t) + \overline{D_i} v(t) + \overline{d_i}(t) \right], \\ y(t) = \overline{x_2}(t) \end{cases}$$
(2.160)

sau

$$\begin{cases} \dot{\bar{x}}_{1}(t) = \sum_{i=1}^{M} \mu_{i}(\xi(t)) \left[ \overline{A}_{11i} \ \bar{x}_{1}(t) + \overline{A}_{12i} \ \bar{x}_{2}(t) + \overline{B}_{1i}u(t) + \overline{d}_{1i}(t) \right], \\ \dot{\bar{x}}_{2}(t) = \sum_{i=1}^{M} \mu_{i}(\xi(t)) \left[ \overline{A}_{21i} \ \bar{x}_{1}(t) + \overline{A}_{22i} \ \bar{x}_{2}(t) + \overline{B}_{2i}u(t) + \overline{D}_{2i}v(t) + \overline{d}_{2i}(t) \right], \quad (2.161) \\ y(t) = \overline{x}_{2}(t). \end{cases}$$

După cum se observă în (2.161),  $\bar{x}_1(t)$  nu depinde de vectorul v(t) – vectorul intrărilor necunoscute, în timp ce  $\bar{x}_2(t)$  depinde de v(t); în schimb,  $\bar{x}_2(t)$  se măsoară  $(y(t) = \bar{x}_2(t))$ . S-a reușit, așadar, decuplarea intrărilor necunoscute de vectorul de stare ce urmează a fi estimat  $(\bar{x}_1(t))$ . Observerul multiplu propus în [6] pentru estimarea lui  $\bar{x}_1(t)$ , deci a vectorului  $\bar{x}(t) = [\bar{x}_1(t) \ \bar{x}_2(t)]^T$ , este descris de ecuațiile [6]

$$\begin{cases} \hat{\overline{x}}(t) = \sum_{i=1}^{M} \mu_i(\xi(t)) \Big[ \overline{A}_i \ \hat{\overline{x}}(t) + \overline{B}_i u(t) + \overline{d}_i(t) - \overline{G}_i e_y(t) + \overline{K}_i \gamma_i(t) \Big], \\ \hat{y}(t) = \overline{C} \hat{\overline{x}}_2(t), \end{cases}$$
(2.162)

cu

$$\overline{G}_{i} = \begin{bmatrix} \overline{A}_{12i} \\ \overline{A}_{22i} - \overline{A}_{22}^{s} \end{bmatrix}, \overline{K}_{i} = \begin{bmatrix} 0 \\ P_{2}^{-1} \overline{D}_{2i} \end{bmatrix};$$
(2.163)

 $\overline{A}_{22}^{s}$  este o matrice stabilă, iar vectorii  $\gamma_{i}(t)$  se definesc astfel [6]:

$$\gamma_{i}(t) = \begin{cases} -\rho E_{i}^{T} (E_{i} E_{i}^{T})^{-1} \| e_{y}^{T}(t) P_{2} \overline{D}_{2i} \|, \text{ daca } e_{y}(t) \neq 0 \\ 0, \text{ daca } e_{y}(t) = 0 \end{cases}$$
(2.164)

cu  $e_y(t) = \hat{y}(t) - y(t), E_i(t) = e_y^T(t)P_2\overline{D}_{2i}, (\forall)i = \overline{1, M}$  şi  $P_2 \in \mathcal{M}^{p \times p}$  – matrice simetrică și pozitiv definită, soluție a ecuației Lyapunov

$$P_2 \overline{A}_{22}^s + (\overline{A}_{22}^s)^T P_2 = -Q_2.$$
 (2.165)

Expresia matricei  $\overline{A}_{22}^s$  va fi dedusă ulterior. Fie  $e_1(t) = \hat{\overline{x}}_1(t) - \overline{x}_1(t)$  și  $e_2(t) = \hat{\overline{x}}_2(t) - \overline{x}_2(t) = \hat{y}(t) - y(t) = e_y(t)$ . Prin derivarea acestor erori în raport cu timpul, se obține [6]

$$\begin{split} \dot{e}_{1}(t) &= \dot{\bar{x}}_{1}(t) - \dot{\bar{x}}_{1}(t) = \sum_{i=1}^{M} \mu_{i}(\xi(t)) \overline{A}_{11i} e_{1}(t), \dot{e}_{2}(t) = \dot{\bar{y}}(t) - \dot{\bar{y}}(t) = \\ &= \sum_{i=1}^{M} \mu_{i}(\xi(t)) \Biggl\{ \overline{C} \Biggl[ \overline{A}_{i} \dot{\bar{x}}(t) + \overline{B}_{i} u(t) + \overline{d}_{i} - \overline{G}_{i} e_{y}(t) + \overline{K}_{i} \gamma_{i}(t) - \overline{A}_{21i} \overline{x}_{1}(t) - \\ - \overline{A}_{22i} \overline{x}_{2}(t) - \overline{B}_{2i} u(t) - \overline{D}_{2i} v(t) - \overline{d}_{2i} \Biggr\} \Biggr\} = (2.166) \\ &= \sum_{i=1}^{M} \mu_{i}(\xi(t)) \Biggl[ \overline{A}_{21i} e_{1}(t) + \overline{A}_{22}^{s} e_{2}(t) + P_{2}^{-1} \overline{D}_{2i} \gamma_{i}(t) - \overline{D}_{2i} v(t) \Biggr]. \end{split}$$

Pentru a demonstra convergența asimptotică a observerului multiplu, se consideră funcția Lyapunov [6]

$$V(e_1, e_2) = e_1^T P_1 e_1 + e_2^T P_2 e_2; \qquad (2.167)$$

se calculează  $\dot{V}(e_1, e_2)$  ținând cont de (2.142) și (2.165); se obține [6]

$$\dot{V}(e_{1},e_{2}) = \sum_{i=1}^{M} \mu_{i}(\xi) \begin{cases} e_{1}^{T} \left(\overline{A}_{11i}^{T} P_{1} + P_{1} \overline{A}_{11i}\right) e_{1} + e_{2}^{T} \left[\left(\overline{A}_{22}^{s}\right)^{T} P_{2} + P_{2} \overline{A}_{22}^{s}\right] e_{2} + \\ + e_{1}^{T} \overline{A}_{21i}^{T} P_{2} e_{2} + e_{2}^{T} P_{2} \overline{A}_{21i} e_{1} + 2e_{2}^{T} \overline{D}_{2i} \gamma_{i} - 2e_{2}^{T} P_{2} \overline{D}_{2i} \nu \end{cases}.$$
(2.168)

#### *Teorema 2.7* [6]

Dacă există o matrice simetrică și pozitiv definită  $P_2$  ce verifică (2.165), dinamica erorilor  $e_1(t)$  și  $e_2(t)$  este asimptotic stabilă.

#### **Demonstrație**

Fie  $Q_{1i} \in \mathcal{M}^{(n-p)\times(n-p)}$  și  $Q_2 \in \mathcal{M}^{p\times p}$  – matrice pozitiv definite; se consideră, de asemenea, matricele Lyapunov  $\hat{Q}_i \in \mathcal{M}^{(n-p)\times(n-p)}$  definite astfel [6]:

$$\hat{Q}_i = \overline{A}_{21i}^T P_2 Q_2^{-1} P_2 \overline{A}_{21i} + Q_{1i} .$$
(2.169)

Se consideră, de asemenea,  $P_1 \in \mathcal{M}^{(n-p)\times(n-p)}$  – matrice simetrică și pozitiv definită, soluție unică a ecuației Lyapunov

$$\overline{A}_{11i}^T P_1 + P_1 \overline{A}_{11i} = -\hat{Q}_i .$$
(2.170)

Se arată că  $\dot{V}$  (expresia (2.168)) se poate exprima și sub forma

$$\dot{V}(e_1, e_2) = \sum_{i=1}^{M} \mu_i(\xi) \begin{pmatrix} -e_1^T \hat{Q}_i e_1 - e_2^T Q_2 e_2 + e_1^T \overline{A}_{21i}^T P_2 e_2 + \\ +e_2^T P_2 \overline{A}_{21i} e_1 + 2e_2^T \overline{D}_{2i} \gamma_i - -2e_2^T P_2 \overline{D}_{2i} \nu \end{pmatrix}.$$
(2.171)

Se demonstrează ușor că [6]

și, în aceste condiții,  $\dot{V}$  devine

$$\dot{V} = \sum_{i=1}^{M} \mu_i(\xi) \left[ -e_1^T \left( \hat{Q}_i - \overline{A}_{21i}^T P_2 Q_2^{-1} P_2 \overline{A}_{21i} \right) e_1 - \widetilde{e}_{2i}^T Q_2 \widetilde{e}_{2i} + 2e_2^T \overline{D}_{2i} \gamma_i - 2e_2^T P_2 \overline{D}_{2i} \nu \right],$$
(2.173)

cu

$$\widetilde{e}_{2i} = e_2 - Q_2^{-1} P_2 \overline{A}_{21i} e_1 . (2.174)$$

Folosind acum ecuația (2.169),  $\dot{V}$  capătă forma [6]

$$\dot{V} = \sum_{i=1}^{M} \mu_i(\xi) \Big( -e_1^T Q_{1i} e_1 - \tilde{e}_{2i}^T Q_2 \tilde{e}_{2i} + 2e_2^T \overline{D}_{2i} \gamma_i - 2e_2^T P_2 \overline{D}_{2i} v \Big).$$
(2.175)

Se presupune că  $e_2 \neq 0$ . Folosind acum ecuația (2.164),  $\dot{V}$  devine

$$\dot{V} = \sum_{i=1}^{M} \mu_i(\xi) \left( -e_1^T Q_{1i} e_1 - \tilde{e}_{2i}^T Q_2 \tilde{e}_{2i} - 2\rho \left\| e_2^T P_2 \overline{D}_{2i} \right\| - 2e_2^T P_2 \overline{D}_{2i} v \right).$$
(2.176)

Având în vedere că v este mărginit, rezultă

$$\dot{V} = \sum_{i=1}^{M} \mu_{i}(\xi) \left( -e_{1}^{T} Q_{1i} e_{1} - \widetilde{e}_{2i}^{T} Q_{2} \widetilde{e}_{2i} - 2\rho \left\| e_{2}^{T} P_{2} \overline{D}_{2i} \right\| + 2\rho \left\| e_{2}^{T} P_{2} \overline{D}_{2i} \right\| \right) =$$

$$= \sum_{i=1}^{M} \mu_{i}(\xi) \left( -e_{1}^{T} Q_{1i} e_{1} - \widetilde{e}_{2i}^{T} Q_{2} \widetilde{e}_{2i} \right) < 0, (\forall) e_{1}, \widetilde{e}_{2i} \neq 0 \text{ si } (\forall) i = \overline{1, M}.$$
(2.177)

Dacă  $e_2 = 0$ ,  $\dot{V}$  devine [6]

$$\dot{V} = \sum_{i=1}^{M} \mu_i(\xi) \Big( -e_1^T Q_{1i} e_1 - \tilde{e}_{2i}^T Q_2 \tilde{e}_{2i} \Big) < 0, (\forall) e_1, \tilde{e}_{2i} \neq 0 \text{ si } (\forall) i = \overline{1, M};$$
(2.178)

s-a demonstrat, așadar, că erorile  $e_1(t)$  și  $e_2(t)$  tind către zero în mod exponențial. În concluzie, observerul multiplu de tip alunecător se scrie [6]

$$\begin{cases} \dot{\hat{x}}(t) = \sum_{i=1}^{M} \mu_i(\xi(t)) \{A_i \ \hat{x}(t) + B_i u(t) + d_i + G_i[y(t) - C\hat{x}(t)] + K_i \gamma_i(t)\}, \\ \hat{y}(t) = C\hat{x}(t), \end{cases}$$
(2.179)

unde

$$G_{i} = \left(\overline{T}\widetilde{T}\right)^{-1} \begin{bmatrix} \overline{A}_{12i} \\ \overline{A}_{22i} - \overline{A}_{22}^{s} \end{bmatrix}, K_{i} = \left(\overline{T}\widetilde{T}\right)^{-1} P_{2}^{-1} \left(\overline{T}\widetilde{T}\right) D_{i},$$
  

$$\gamma_{i}(t) = \begin{cases} -\rho E_{i}^{T} \left(E_{i} E_{i}^{T}\right)^{-1} \| e_{y}^{T}(t) P_{2} \overline{D}_{2i} \|, \text{ daca } e_{y}(t) \neq 0 \\ 0, \text{ daca } e_{y}(t) = 0 \end{cases}$$

$$(2.180)$$

$$e_{y}(t) = C\hat{x}(t) - y(t), E_{i}(t) = e_{y}^{T}(t)\overline{D}_{2i}, (\forall)i = \overline{1, M}.$$
(2.181)

## 2.6. ESTIMAREA PARAMETRILOR NECUNOSCUȚI DIN ECUAȚIILE DE STARE PRIN INTERMEDIUL OBSERVERELOR MULTIPLE

Observerele multiple pot avea și altă utilizare pe lângă estimarea vectorului de stare și a vectorului intrărilor necunoscute. De exemplu, în [163], observerele multiple sunt utilizate pentru estimarea parametrilor necunoscuți din ecuațiile de stare asociate unui sistem liniar și invariant în timp. Matricele ce conțin necunoscute se scriu, mai întâi, ca și combinații liniare a câtorva matrice virtuale, ponderile utilizate fiind în strânsă legătură cu parametrii ce trebuie estimați. Se va demonstra că ieșirea unui sistem liniar este combinația liniară a estimărilor ieșirilor generate de observerele multiple cu aceleași ponderi cu cele utilizate pentru scrierea elementelor matricelor necunoscutelor. Astfel, se determină ponderile combinației liniare și formula de estimare pentru parametrii necunoscuți [163].

Se consideră ecuația de stare

$$\dot{x}(t) = A(a_1, a_2, \dots, a_p)x(t) + B(b_1, b_2, \dots, b_q)u(t), \qquad (2.182)$$

unde x(t) este vectorul de stare, iar u(t) – vectorul intrărilor sistemului. În cadrul matricelor A și B,  $a_i$ ,  $i = \overline{1, p}$  și  $b_j$ ,  $j = \overline{1, q}$  reprezintă parametrii necunoscuți ce urmează a fi estimați. În [163] se utilizează relațiile

$$A(a_1, a_2, \dots, a_p) = A_0 + \sum_{i=1}^p a_i A_i, B(b_1, b_2, \dots, b_q) = B_0 + \sum_{i=1}^q b_j B_j; \quad (2.183)$$

 $A_0$  și  $B_0$  sunt matrice obținute din  $A(a_1, a_2, ..., a_p)$  și  $B(b_1, b_2, ..., b_q)$  înlocuind cu 0 toate elementele  $a_i$  și  $b_j$ ; matricele  $A_i$ ,  $i = \overline{1, p}$  și  $B_j$ ,  $j = \overline{1, q}$  se obțin din  $A(a_1, a_2, ..., a_p) - A_0$ și, respectiv,  $B(b_1, b_2, ..., b_q) - B_0$  făcând toate elementele  $a_i$  și  $b_j$  egale cu 1 și toate celelalte elemente egale cu 0 [163]. Ieșirea sistemului este

$$y(t) = Cx(t);$$
 (2.184)

matricea *C* nu conține parametrii necunoscuți. Se face presupunerea  $(C, A(a_1, a_2, ..., a_p))$ – pereche detectabilă  $(\forall) a_i, i = \overline{1, p}$ .

Se dorește, în continuare, estimarea parametrilor necunoscuți  $a_i$  și  $b_j$  utilizând doar semnalul de intrare u(t) și cel de ieșire y(t). În acest sens, se utilizează transformarea [163]

$$\begin{bmatrix} a_1 \cdots a_p \ b_1 \cdots b_q \ 1 \end{bmatrix}^T = \widetilde{T} \begin{bmatrix} \theta_1 \ \theta_2 \cdots \theta_r \end{bmatrix}^T,$$
(2.185)

transformare ce face legătura între  $a_i$ ,  $b_j$  și  $\theta_k$ ,  $k = \overline{1, r}$ , unde r = p + q + 1; matricea  $\widetilde{T}$  din ecuația (2.5) are forma [163]

$$\widetilde{T} = \begin{bmatrix} T \\ 1 \cdots 1 \end{bmatrix}, \qquad (2.186)$$

unde  $T \in \mathcal{M}^{(p+q) \times (p+q+1)}$  se alege astfel încât  $\widetilde{T}$  să fie nesingulară. Ținând cont de ecuația (2.185), expresiile (2.183) devin

$$A(a_{1}, a_{2}, ..., a_{p}) = \sum_{k=1}^{r} \Theta_{k} \overline{A}_{k}, B(b_{1}, b_{2}, ..., b_{q}) = \sum_{k=1}^{r} \Theta_{k} \overline{B}_{k}, \qquad (2.187)$$

în care  $\overline{A}_k$  și  $\overline{B}_k$  sunt matrice obținute din  $A(a_1, a_2, ..., a_p)$  și  $B(b_1, b_2, ..., b_q)$  prin înlocuirea valorilor  $a_1, a_2, ..., a_p, b_1, b_2, ..., b_q$  cu valorile calculate cu ajutorul ecuației (2.185) cu particularizarea  $\theta_k = 1, \theta_l = 0 (l \neq k)$  [163]. În aceste condiții, matricele  $\overline{A}_k$ și  $\overline{B}_k$  au expresiile

$$\overline{A}_{k} = A_{0} + \sum_{i=1}^{p} t_{i\,k} A_{i}, \overline{B}_{k} = B_{0} + \sum_{j=1}^{q} t_{(p+j)k} B_{j}, k = \overline{1, r}, \qquad (2.188)$$

unde  $t_{ik}$  este elementul de pe linia ,,*i*" și coloana ,,*k*" a matricei *T* (ecuația (2.186)).

Relațiile (2.187) reprezintă combinații liniare între  $\overline{A}_k$  și  $\overline{B}_k$ , ponderile asociate acestor combinații, adică  $\theta_k$ ,  $k = \overline{1, r}$  satisfăcând condiția [163]:

$$\sum_{k=1}^{r} \Theta_k = 1.$$
 (2.189)

Ecuațiile de stare-ieșire și stare-intrare (ecuațiile (2.182) și (2.184)), utilizând formele (2.187), devin

$$\begin{cases} \dot{x}(t) = \sum_{k=1}^{r} \left[ \theta_{k} \,\overline{A}_{k} x\left(t\right) + \theta_{k} \overline{B}_{k} u\left(t\right) \right], \\ y(t) = C \, x\left(t\right). \end{cases}$$
(2.190)

Determinarea ponderilor  $\theta_k$ ,  $k = \overline{1, r}$  echivalează cu determinarea necunoscutelor  $a_i$ ,  $i = \overline{1, p}$  și  $b_j$ ,  $j = \overline{1, q}$ .

Alegând  $\theta_k = 1$  și  $\theta_l = 0 (l \neq k)$ , se consideră sistemele virtuale

$$\begin{cases} \dot{x}_k(t) = \overline{A}_k x_k(t) + \overline{B}_k u(t), \\ y(t) = C x_k(t). \end{cases}$$
(2.191)

Se presupune că există matricele  $L_k$ ,  $k = \overline{1, r}$  care satisfac ecuațiile [163]

$$\overline{A}_1 - L_1 C = \overline{A}_2 - L_2 C = \dots = \overline{A}_r - L_r C$$
(2.192)

și  $(\overline{A}_k - L_k C)$  – matrice stabile. Pentru sistemele virtuale (2.191), se introduc observerele:

$$O_{k} :\begin{cases} \dot{\hat{x}}_{k}(t) = (\overline{A}_{k} - L_{k}C)\hat{x}_{k}(t) + L_{k}y(t) + \overline{B}_{k}u(t), \\ \hat{y}(t) = C\hat{x}_{k}(t), k = \overline{1, r}, \end{cases}$$
(2.193)

unde u(t) și y(t) sunt intrările observerelor (2.193). Estimarea stărilor  $x_k(t)$  înseamnă

determinarea semnalelor  $\hat{x}_k(t)$  și  $\hat{y}_k(t)$ . Dependența între vectorul ieșirilor măsurabile y(t) și cel asociat ieșirilor estimate  $\hat{y}_k(t)$  ale sistemelor virtuale (2.191) este de forma [163]:  $\lim_{t \to \infty} y(t) = \lim_{t \to \infty} \hat{y}_{\theta}(t)$ , în care

$$\hat{y}_{\theta}(t) = \theta_1 \hat{y}_1(t) + \theta_2 \hat{y}_2(t) + \dots + \theta_r \hat{y}_r(t).$$
(2.194)

În regim staționar,  $y(t) \rightarrow \hat{y}_{\theta}(t)$ .

Pentru proiectarea observerelor  $O_k, k = \overline{1, r}$ , este nevoie de determinarea matricelor  $L_k, k = \overline{1, r}$ , ce satisfac ecuațiile (2.192). Detectabilitatea perechii  $(C, \overline{A}_k)$  este necesară pentru ca  $(\overline{A}_k - L_kC)$  să fie matrice stabile; dar  $\overline{A}_k$  sunt dependente de  $t_{ik}, i = \overline{1, p}$  (ecuațiile (2.188)). Deci, matricea T (ecuația (2.186)) trebuie aleasă astfel încât perechile  $(C, \overline{A}_k)$  să fie detectabile. Existența unei astfel de matrice este garantată de presupunerea conform căreia  $(C, A(a_1, a_2, ..., a_p))$  este detectabilă pentru valorile  $a_i, i = \overline{1, p}$ ; de exemplu,  $t_{ik}$  se află în vecinătatea parametrilor necunoscuți  $a_i$ . În acest caz,  $\overline{A}_k$  este apropiată de  $A(a_1, a_2, ..., a_p)$  şi  $(C, \overline{A}_k)$  detectabile încât  $(C, \overline{A}_k)$  – perechi detectabilă. În consecință, T se alege astfel încât  $(C, \overline{A}_k)$  – pentru orice  $k = \overline{1, r}$ , se determină  $L_k$  astfel încât  $(\overline{163}]$ 

$$\overline{A}_k - L_k C = \overline{A}_1 - L_1 C. \qquad (2.195)$$

Utilizând ecuațiile (2.188), ecuația anterioară se reduce la [163]

$$\sum_{i=1}^{p} (t_{i1} - t_{ik}) A_i = (L_1 - L_k C), \ k = \overline{2, r}.$$
(2.196)

Identificarea parametrilor  $a_i$  și  $b_j$  se face prin intermediul estimării parametrilor  $\theta_k$ . Această operațiune se face fie în prezența, fie în absența zgomotului de măsurare.

Pentru estimarea parametrilor  $\theta_k$  în absența zgomotului de măsurare, se definesc vectorul parametric [163]

$$\Theta = \begin{bmatrix} \theta_1 & \theta_2 & \cdots & \theta_r \end{bmatrix}^T$$
(2.197)

și matricele

$$\hat{Y}(t) = \begin{bmatrix}
\hat{y}_{1}(t) & \hat{y}_{2}(t) & \cdots & \hat{y}_{r}(t) \\
\hat{y}_{1}(t-\tau_{1}) & \hat{y}_{2}(t-\tau_{1}) & \cdots & \hat{y}_{r}(t-\tau_{1}) \\
\vdots & \vdots & \cdots & \vdots \\
\hat{y}_{1}(t-\tau_{l}) & \hat{y}_{2}(t-\tau_{l}) & \cdots & \hat{y}_{r}(t-\tau_{l})
\end{bmatrix},$$

$$Y(t) = \begin{bmatrix}
y^{T}(t) & y^{T}(t-\tau_{1}) & \cdots & y^{T}(t-\tau_{l})
\end{bmatrix}^{T},$$
(2.198)

unde  $0 < \tau_1 < \tau_2 < ... < \tau_l$ . Utilizând ecuațiile (2.189) și (2.194), se demonstrează în [163] că, în regim staționar  $(t \rightarrow \infty)$ ,

$$\begin{bmatrix} f \\ \hat{Y}^{T}(t) \end{bmatrix}^{T} \Theta \rightarrow \begin{bmatrix} 1 \\ Y(t) \end{bmatrix}, \qquad (2.199)$$

unde  $f = \begin{bmatrix} 1 & 1 & \cdots \end{bmatrix}$ ; de asemenea, dacă  $\begin{bmatrix} f^T & \hat{Y}^T(t) \end{bmatrix}^T$  are rang de coloană maxim, rezultă

$$\hat{\Theta}(t) = \left( \begin{bmatrix} f^T & \hat{Y}^T(t) \end{bmatrix} \begin{bmatrix} f \\ \hat{Y}(t) \end{bmatrix} \right)^{-1} \begin{bmatrix} f^T & \hat{Y}^T(t) \end{bmatrix} \begin{bmatrix} f \\ Y(t) \end{bmatrix}, \qquad (2.200)$$

în care  $\hat{\Theta}(t)$  este estimarea vectorului parametric  $\Theta(t)$ . Aşadar, estimarea lui  $\Theta(t)$  se face prin intermediul relației (2.200), aceasta însemnând obținerea estimărilor  $\hat{\theta}_k$  (estimările parametrilor  $\theta_k$ ). Utilizând ecuațiile (2.185) și (2.197), se obțin parametrii necunoscuți  $a_i$  și  $b_j$  după cum urmează [163]:

$$\begin{bmatrix} a_1 \cdots a_p & b_1 \cdots b_q \end{bmatrix}^T = T \hat{\Theta}.$$
(2.201)

Dacă semnalul de măsurare este perturbat de un vector de tip zgomot (w(t)), ecuația de ieșire (2.11) este de tipul [163]

$$\widetilde{y}(t) = Cx(t) + w(t); \qquad (2.202)$$

în ecuațiile (2.193), y(t) va fi înlocuit cu  $\tilde{y}(t)$ . În aceste condiții, relația (2.194) devine

$$\lim_{t \to \infty} \hat{y}_{\theta}(t) = \lim_{t \to \infty} \left[ \widetilde{y}(t) + \widetilde{w}(t) \right], \tag{2.203}$$

în care  $\widetilde{w}(t)$  este ieșirea sistemului

$$\begin{cases} \dot{z}(t) = A_s z(t) + \sum_{k=1}^{r} \Theta_k L_k w(t), \\ \widetilde{w}(t) = C z(t) - w(t), \end{cases}$$
(2.204)

cu z(0) = 0; ecuația (2.203) implică [163]

$$\begin{bmatrix} f\\ \hat{Y} \end{bmatrix} \Theta = \begin{bmatrix} 1\\ \widetilde{Y} \end{bmatrix} + \begin{bmatrix} 0\\ W \end{bmatrix}, \hat{Y}(t) = \begin{bmatrix} \hat{y}_1(t_1) & \hat{y}_2(t_1) & \cdots & \hat{y}_r(t_1) \\ \hat{y}_1(t_2) & \hat{y}_2(t_2) & \cdots & \hat{y}_r(t_2) \\ \vdots & \vdots & \cdots & \vdots \\ \hat{y}_1(t_N) & \hat{y}_2(t_N) & \cdots & \hat{y}_r(t_N) \end{bmatrix},$$
(2.205)  
$$\widetilde{Y}(t) = \begin{bmatrix} \widetilde{y}^T(t_1) & \widetilde{y}^T(t_2) & \cdots & \widetilde{y}^T(t_N) \end{bmatrix}^T, W = \begin{bmatrix} \widetilde{w}^T(t_1) & \widetilde{w}^T(t_2) & \cdots & \widetilde{w}^T(t_N) \end{bmatrix}^T.$$

Deoarece W nu este cunoscută, se aplică metoda celor mai mici pătrate pentru minimizarea normei  $\left\| \begin{bmatrix} f \\ \hat{Y} \end{bmatrix} \Theta - \begin{bmatrix} 1 \\ \widetilde{Y} \end{bmatrix} \right\|$  pentru estimarea vectorului  $\hat{\Theta}(t)$  [163]:

$$\hat{\Theta}(t) = \left( \begin{bmatrix} f^T & \hat{Y}^T(t) \end{bmatrix} \begin{bmatrix} f \\ \hat{Y}(t) \end{bmatrix} \right)^{-1} \begin{bmatrix} f^T & \hat{Y}^T(t) \end{bmatrix} \begin{bmatrix} f \\ \widetilde{Y}(t) \end{bmatrix}.$$
(2.206)

### CAPITOLUL 3

# OBSERVERE OPTIMALE PENTRU ESTIMAREA STĂRII APARATELOR DE ZBOR

### **3.1. INTRODUCERE**

În trecut, una dintre principalele aplicabilități ale soluțiilor problemelor liniare de control optimal stochastic a fost legată de faptul că dimensiunea și complexitatea soluțiilor depășește ceea ce este important pentru o lege de control satisfăcătoare. Astfel, pentru un sistem descris de n ecuații diferențiale ce includ și zgomote albe, soluția necesită un filtru de ordinul n. Dacă nu există surse excitante de tip zgomot alb pentru sistem, este necesară o dimensiune chiar mai mare pentru filtru.

Atunci când, din diferite cauze (perturbații stochastice, absența unor senzori etc.), este imposibilă cunoașterea perfectă a variabilelor de stare asociate unui sistem, utiliza-rea estimatoarelor de stare este esențială pentru controlul ulterior al sistemului. Lucră-rile în care se abordează această tematică utilizează două tipuri de modele dinamice: deterministe și stochastice. În situația în care dinamica sistemului este afectată de in-certitudini (necunoscute) sau aceasta este parțial cunoscută, implementarea observerelor deterministe este o soluție viabilă. Dintre aceste observere, un loc important îl ocupă observerele cu amplificare mare (high-gain observers); în cadrul majorității observerelor cu amplificare mare, se presupune fie că sistemul nu este afectat de perturbații externe, fie că acesta nu are o dinamică nemodelată. În cazul sistemelor stochastice neliniare, chiar dacă informația este completă, estimarea optimală a stării este complexă întrucât este nevoie de rezolvarea așa-numitelor ecuații

diferențiale Duncan-Mortensen-Zakai cu soluții dimensional finite pentru modelele liniare, lucru care corespunde, în special, filtrelor Kalman. Proiectarea oricărui observer cu dimensiune finită necesită câteva aproximații în cadrul procesului de minimizare a limitei superioare a erorii de estimare.

Dintre observerele optimale, cel mai cunoscut este filtrul Kalman-Bucy ce presupune minimizarea unui criteriu de calitate ce implică eroarea de estimare. În consecință, proiectanții trebuie să proiecteze adesea observere cu ordin redus pentru satisfacerea constrângerilor ce apar datorită complexității filtrelor. Un alt motiv este acela că, deși modelul unui sistem are multe grade de libertate, este necesară estimarea numai a unui număr mic de variabile de stare. Un alt element important în teoria estimării optimale a stării unui sistem o constituie problematica observării asimptotice. Este bine cunoscut faptul că filtrul Kalman este și un observer asimptotic. Oricum, în teoria estimatoarelor de stare cu ordin redus, operațiile de estimare și cele de observare sunt distincte, adică un estimator de stare cu ordin redus nu este neapărat și observer. În multe aplicații practice, este însă nevoie de proiectarea unor estimatoare de stare cu ordin redus care să fie, în același timp, și observere pentru o parte dintre stările sistemului.

În cadrul acestui capitol, sunt prezentate câteva dintre cele mai importante proceduri de proiectare a observerelor optimale atât pentru sistemele afectate de perturbații stochastice cât și pentru cele afectate de perturbații deterministe.

# 3.2. ESTIMAREA STĂRII UTILIZÂND METODA CELOR MAI MICI PĂTRATE

Dinamica aparatului de zbor este descrisă de ecuația de stare

$$\dot{x} = Ax + Bu, \tag{3.1}$$

cu  $x_0$  – vectorul valorilor staționare ale variabilelor de stare; pentru estimarea lui x se minimizează indicatorul de performantă [50]

$$\mathcal{I}_{c} = (x - x_{0})^{T} \mathcal{Q}_{c} (x - x_{0}) + n^{T} R_{c} n, \qquad (3.2)$$

unde  $Q_c$  și  $R_c$  sunt matrice simetrice  $(Q_c = Q_c^T, R_c = R_c^T)$ , pozitiv definite și nesingu-lare, iar *n* este vectorul zgomotelor senzorilor din ecuația

$$y = Cx + n. \tag{3.3}$$

Cu aceasta,  $\mathcal{I}_c$  devine

$$\mathcal{I}_{c} = (x - x_{0})^{T} \mathcal{Q}_{c} (x - x_{0}) + (y - Cx)^{T} R_{c} (y - Cx).$$
(3.4)

Vectorul de stare estimat  $\hat{x}$  se calculează din condiția de minim a lui  $\mathcal{I}_c$  în ra-

port cu 
$$x \left( \frac{\partial g_c}{\partial x} \Big|_{x=\hat{x}} = 0 \right)$$
  
 $(y - C\hat{x})^T R_c C - (\hat{x} - x_0)^T Q_c = 0.$  (3.5)

Pentru calculul lui  $\hat{x}$ , se transpune ecuația (3.5) și se obține

$$\hat{x} = LQ_c x_0 + LC^T R_c y, \qquad (3.6)$$

unde matricea L este

$$L = (Q_c + C^T R_c C)^{-1}.$$
 (3.7)

Din ecuația  $ZZ^{-1} = I$ , cu

$$Z = \begin{bmatrix} Q_c & C^T \\ C & -R_c^{-1} \end{bmatrix}, Z^{-1} = \begin{bmatrix} L & N \\ O^T & M \end{bmatrix},$$
(3.8)

se obțin ecuațiile

$$Q_c L + C^T O^T = I, O^T = R_c CL, \qquad (3.9)$$

din care, prin eliminarea lui  $O^T$ , se obține matricea

$$L = Q_c^{-1} - Q_c^{-1} C^T \left( C Q_c^{-1} C^T + R_c^{-1} \right)^{-1} C Q_c^{-1}.$$
(3.10)

Cu aceasta, ecuația (3.6) devine [50]

$$\hat{x} = x_0 + H(y - Cx_0), \tag{3.11}$$

unde

$$H = Q_c^{-1} C^T \left( C Q_c^{-1} C^T + R_c^{-1} \right)^{-1}.$$
 (3.12)

Sistemul descris de ecuațiile (3.1), (3.3) și (3.11) (aparat de zbor, senzori și observer) este modelat de schema bloc din fig. 3.1.



Fig. 3.1. Modelul sistemului aparat de zbor - senzori - observer

## 3.3. CHESTIUNI GENERALE DE PROIECTARE A OBSERVERELOR OPTIMALE

Considerând sistemul descris de ecuația (3.1) – dinamica aparatutului de zbor și sistemul de măsurare descris de ecuația

$$y = Cx, \tag{3.13}$$

se proiectează un observer optimal care să furnizeze un vector de stare estimat  $\hat{x} \rightarrow x$ . Observerul de stare liniar este descris de ecuația [50]

$$\hat{x} = A\hat{x} + Bu + L(y - \hat{y}),$$
(3.14)

cu y de forma (3.13) și  $\hat{y}$  – vectorul de ieșire estimat,

$$\hat{y} = C\hat{x}.\tag{3.15}$$

Cu (3.13) și (3.15), ecuația (3.14) devine

$$\hat{x} = (A - LC)\hat{x} + Bu + LCx$$
 (3.16)

și, cu Bu exprimat din ecuația de stare (3.1) și eroarea (abaterea)  $e = \hat{x} - x$ , se obține ecuația

$$\dot{e} = \overline{A}e, \overline{A} = A - LC. \tag{3.17}$$

Matricea de amplificare L a observerului de stare se poate calcula din condiția ca  $\overline{A}$  să fie stabilă. Cu notația  $z = \hat{y} - y$  și ecuațiile (3.13), (3.15), rezultă ecuația

$$z = Ce. \tag{3.18}$$

Dacă  $\overline{A}$  este matrice Hurwitz, atunci, pentru fiecare matrice  $Q_c > 0$  și  $Q_c = Q_c^T$ , există o matrice P>0 care verifică ecuația Lyapunov

$$\overline{A}^T P + P\overline{A} + Q_c = 0. \tag{3.19}$$

Matricea P din funcția Lyapunov

$$V(t) = e^{T}(t)Pe(t)$$
(3.20)

asigură realizarea condiției  $\dot{V}(t) > 0$  iar ecuația Lyapunov (3.19) asigură realizarea condiției de stabilitate ( $\dot{V}(t) < 0$ ). Într-adevăr, derivând funcția (3.20) și ținând seama de ecuațiile (3.17) și (3.19), rezultă succesiv



Fig. 3.2. Schema bloc de modelare a sistemului de comandă optimală a A cu observer liniar de stare

$$\dot{V}(t) = e^T P \dot{e} + \dot{e}^T P e = e^T P \overline{A} e + \left(\overline{A} e\right)^T P e = e^T \left(P \overline{A} + \overline{A}^T P\right) e = -e^T Q_c e < 0.$$
(3.21)

În fig. 3.2 este prezentată schema bloc de modelare a sistemului de comandă optimală a mișcării aparatului de zbor, constituită din următoarele subsisteme: modelul dinamic al aparatului de zbor, sistemul de măsurare, observerul liniar de stare și subsistemul de comandă optimală (matricea de amplificare K). Precizăm că w = v = 0.

Fie cazul mişcării longitudinale a A descrisă de ecuația (1.47) și sistemul de măsurare y = Cx, cu  $C = \begin{bmatrix} 0 & 0 & 1 & 0 \\ 0 & -1 & 1 & 0 \end{bmatrix}$ ; deci, variabilele de stare măsurate sunt  $\alpha$  și  $\theta$ , implicit  $y = \begin{bmatrix} \theta & 9 \end{bmatrix}, 9 = \theta - \alpha$  fiind panta traiectoriei. Se calculează matricea de amplificare L a observerului prin metoda poziționării polilor (impunerea valorilor proprii ale matricei  $\overline{A} = (A - LC)$  a observerului în circuit închis). Polii observerului se aleg astfel încât partea lor reală minimă să fie de 5÷10 ori mai mare decât partea reală maximă a polilor sistemului condus (dinamicii longitudinale a aparatului de zbor), adică

$$\left|\operatorname{Re}\left\{\lambda_{\min}\right\}_{\operatorname{observer}}\right| > 5 \div 10 \left|\operatorname{Re}\left\{\lambda_{\max}\right\}_{\operatorname{sistem}}\right|.$$
(3.22)

S-au impus următoarele valori proprii ale matricei  $\overline{A}$ : -60.15, -2.84, -18.90, -15.11; rezultă matricea  $L^{T} = 10^{3} \cdot \begin{bmatrix} 1.45 & 0.06 & 0.07 & 0.92 \\ -0.26 & -0.04 & -0.02 & -0.40 \end{bmatrix}$ .

Anterior calculului lui L, trebuie verificat dacă perechea (A, C) este observabilă și dacă perechea (A, B) este controlabilă; în Matlab/Simulink se pot utiliza instrucțiunile obsv, respectiv ctrb; au rezultat două matrice cu rangul egal cu 4; deoarece n=4, rezultă că modelul mișcării longitudinale a aeronavei este controlabil și observabil.

Folosind schema bloc din fig. 3.2, se calculează erorile de estimare a variabilelor de stare folosind observerul descris de ecuația (3.16), în absența legii de comandă (K=0); aceste erori sunt reprezentate în fig. 3.3. Cu vectorul de stare astfel estimat, se realizează comanda mișcării longitudinale ( $u = -K\hat{x}$ , cu matricea K obținută cu algoritmul ALGLX [140]); K = [2.225 - 0.316 - 10.736 - 1.428]. Utilizând din nou
sche-ma bloc din fig. 3.2, se construiesc caracteristicile de timp din fig. 3.4, care exprimă variabilele de stare  $x_i(t)$  – cu linie continuă și  $\hat{x}_i(t)$  – cu linie întreruptă; se constată că  $\hat{x}_i(t) \rightarrow x_i(t) \rightarrow 0$  într-un interval de timp scurt.



Fig. 3.3. Erorile de estimare a variabilelor de stare (u=0)



Fig. 3.4. Variabilele de stare  $x_i(t)$  și  $\hat{x}_i(t)$  - mișcarea longitudinală  $(K \neq 0)$ 

În cazul mișcării laterale descrisă de ecuația (1.49), cu  $C = \begin{bmatrix} 0 & 0 & 1 \end{bmatrix}$ , alegând valorile proprii ale matricei  $\overline{A}$  conform (3.22), adică -66.27,-3.97,-10.36,-1.58, rezultă

matricea  $L^{T} = 10^{4} \cdot [1.21 - 0.05 \ 0.11 \ 0.008]$ . Folosind aceeaşi schemă bloc ca mai sus, se obțin succesiv caracteristicile de timp din fig. 3.5 (erorile de estimare a variabilelor de stare ale observerului, pentru K=0) și din fig. 3.6 (variabilele de stare  $x_{i}(t)$  – cu linie continuă și  $\hat{x}_{i}(t)$  – linie întreruptă).



Fig. 3.5. Erorile de estimare a variabilelor de stare (u=0)



Fig. 3.6. Variabilele de stare  $x_i(t)$  și  $\hat{x}_i(t)$  - mișcarea laterală  $(K \neq 0)$ 

## **3.4. FILTRUL KALMAN**

În cazul în care aparatul de zbor evoluează în condiții de perturbații aleatoare, se folosesc observerele optimale de tipul filtrului Kalman-Bucy. Pentru proiectarea acestui filtru, se consideră dinamica aeronavei descrisă de ecuația

$$\begin{cases} \dot{x}(t) = A(t)x(t) + B(t)u(t) + B^{*}(t)w(t), \\ y(t) = C(t)x(t) + v(t), \end{cases}$$
(3.23)

în care  $x \in \mathcal{M}^{n \times 1}$  este vectorul de stare,  $u \in \mathcal{M}^{m \times 1}$  – vectorul de comandă,  $A \in \mathcal{M}^{n \times n}$ ,  $B \in \mathcal{M}^{n \times m}, B^* \in \mathcal{M}^{n \times l}$  – matrice;  $w \in \mathcal{M}^{l \times 1}$  este un proces aleator de tip zgomot alb,  $y \in \mathcal{M}^{m \times 1}$  – vector măsurat,  $C \in \mathcal{M}^{m \times n}$  – matrice de selectare și  $v \in \mathcal{M}^{m \times 1}$  – zgomot asociat senzorilor (proces aleator de tip zgomot alb).

Procesele aleatoare w și v sunt descrise cu ajutorul matricelor de corelație

$$Q^{*}(t) = \mathbf{M}[w(t)w^{T}(t')], R^{*}(t) = \mathbf{M}[v(t)v^{T}(t')],$$
(3.24)

unde M[·] reprezintă media,  $Q^*, R^*$  – matrice simetrice și pozitiv semidefinite care exprimă intensitățile zgomotelor w și v [88], [140]

$$Q^{*}(t) = \begin{bmatrix} q_{1}(t) & 0 & 0 & \cdots & 0 \\ 0 & q_{2}(t) & 0 & \cdots & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ 0 & 0 & 0 & \cdots & q_{l}(t) \end{bmatrix}, R^{*}(t) = \begin{bmatrix} r_{1}(t) & 0 & 0 & \cdots & 0 \\ 0 & r_{2}(t) & 0 & \cdots & 0 \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ 0 & 0 & 0 & \cdots & r_{m}(t) \end{bmatrix}.$$
(3.25)

O covarianță mică implică intrări tip zgomot aproape de medie (zero în acest caz), iar o covarianță mare conduce la intrări zgomot departe de medie.

Procesele aleatoare w și v sunt necorelate între ele, adică

$$N(t) = \mathbf{M} \left[ w(t) v^{T}(t') \right] = 0.$$
(3.26)

În aplicații practice, dacă  $B^*$  nu se cunoaște, se poate considera  $B^* = B$ .

Filtrul Kalman-Bucy are drept scop determinarea vectorului de stare estimat  $(\hat{x}(t))$ , funcție de măsurătorile  $y(\tau)(0 \le \tau < t)$ , care să minimezeze funcția [88]

$$J = \operatorname{trace}(L(t)), \qquad (3.27)$$

în care L(t) este covarianța pentru eroarea de estimare

$$L(t) = M\left[ (x(t) - \hat{x}(t))(x(t) - \hat{x}(t))^T \right].$$
(3.28)

Estimatorul cuadratic liniar (LQE) se numește filtru Kalman-Bucy și este descris de ecuațiile  $\dot{\hat{x}}(t) = A\hat{x}(t) + Bu(t) + L(y(t) - \hat{y}(t)), \hat{y}(t) = C\hat{x}(t)$ , în care

$$L(t) = P^{*}(t)C^{T}(t)R^{*}(t); \qquad (3.29)$$

 $P^{*}(t)$  este o matrice pozitiv definită - soluție a ecuației Riccati [88]

$$\dot{P}^{*}(t) = A(t)P^{*}(t) + P^{*}(t)A^{T}(t) - P^{*}(t)C^{T}(t)R^{*-1}(t)C(t)P^{*}(t) + B^{*}(t)Q^{*}(t)B^{*T}(t)$$
(3.30)

sau

$$A(t)P^{*}(t) + P^{*}(t)A^{T}(t) - P^{*}(t)C^{T}(t)R^{*-1}(t)C(t)P^{*}(t) + B^{*}(t)Q^{*}(t)B^{*T}(t) = 0, \qquad (3.31)$$

dacă sistemul este considerat invariant în timp. Considerând  $e(t) = x(t) - \hat{x}(t) -$  eroarea de estimare a filtrului, se poate determina ecuația asociată dinamicii erorii

$$\dot{e}(t) = A(t)x(t) + B(t)u(t) + B^{*}(t)w(t) - A(t)\hat{x}(t) - B(t)u(t) - L(t)[C(t)x(t) - C(t)\hat{x}(t)] - L(t)v(t) = [A(t) - L(t)C(t)]e(t) + B^{*}(t)w(t) - L(t)v(t).$$
(3.32)

Aşadar, viteza de convergență este dependentă de valorile proprii (părțile reale ale valorilor proprii) ale matricei (A(t) - L(t)C(t)) dar și de zgomotul senzorilor. Asupra estimatorului cuadratic liniar (LQE) întotdeauna va exista o influență a zgomotului procesului (w) și o influență a zgomotului senzorilor (v). Alegerea matricei A(t) va accentua/diminua efectul lui v(t) asupra lui  $\hat{x}(t)$  [88].

Dacă  $Q^*(t)$  și  $R^*(t)$  sunt matrice simetrice și pozitiv semidefinite, dinamica sistemului este considerată constantă în timp,  $(A,B^*)$ – pereche controlabilă și (A,C)– pereche detectabilă, se poate determina  $P^*(t)$  ca soluție a ecuației (3.31) și apoi matri-

cea de amplificare a observerului L(t). Pentru filtrul Kalman-Bucy de tip optimal, se obține funcția de transfer [88]

$$\frac{\hat{X}(s)}{Y(s)} = \frac{L}{sI - (A - LC)}.$$
 (3.33)

Funcția de transfer face legătura între "măsurători" și "starea estimată.

Schema bloc de modelare a sistemului de comandă optimală a mişcării aparatului de zbor este prezentată în fig. 3.2; aceasta este constituită din următoarele subsisteme: modelul dinamic al aparatului de zbor, sistemul de măsurare, observerul optimal de tip filtru Kalman-Bucy și subsistemul de comandă optimală (matricea de amplificare K).

Se consideră mișcarea aeronavei descrisă de ecuația de stare (1.47) [140] și de ecuația de ieșire y = Cx + v cu  $C = \begin{bmatrix} 0 & 0 & 1 & 0 \\ 0 & -1 & 1 & 0 \end{bmatrix}$ , adică  $y^T = \begin{bmatrix} 0 & 9 \end{bmatrix}$ ,  $9 = \theta - \alpha$ . Alegând  $Q^* = \begin{bmatrix} 0.01 \end{bmatrix}$  și  $R^* = \begin{bmatrix} 0.01 & 0 \\ 0 & 0.01 \end{bmatrix}$ , se rezolvă ecuația Riccati (3.31) și rezultă

$$P^{*} = \begin{bmatrix} 1.73 & -0.20 & -0.11 & -0.02 \\ -0.20 & 0.04 & 0.04 & 0.08 \\ -0.11 & 0.04 & 0.04 & 0.09 \\ -0.02 & 0.08 & 0.09 & 0.44 \end{bmatrix}, L = \begin{bmatrix} -11.01 & 9.58 \\ 4.01 & -0.93 \\ 4.26 & 0.24 \\ 9.11 & 0.57 \end{bmatrix}.$$
 (3.34)

Matricele  $P^*$  și L se calculează utilizând instrucțiunea LQE, având sintaxa [L,P,E]=LQE(A,G,C,Q,R,N), în care:  $P = P^*, Q = Q^*, R = R^*$ , G=B\*, N este matricea din ecuația  $N(t) = M[w(t)v^T(t')] = 0$ , iar E reprezintă vectorul ce conține valorile proprii ale matricei A-LC. Rezultă caracteristicile de timp din fig. 3.7 (erorile de estimare a variabilelor de stare cu estimatorul de stare Kalman-Bucy pentru u=0) și caracteristicile de timp din fig. 3.8 pentru legea de comandă  $u = -K\hat{x}$  (K calculată cu algoritmul ALGLX [140]); caracteristicile exprimă variabilele de stare  $x_i(t)$  – cu linie continuă și  $\hat{x}_i(t)$  – cu linie întreruptă.

Se implementează software filtrul Kalman-Bucy și pentru cazul mișcării laterale



a unei aeronave Boeing 747; ecuația de stare a mișcării laterale este (1.49). Se obțin

Fig. 3.7. Erorile de estimare a stării estimatorului Kalman-Bucy (K = 0)



Fig. 3.8. Variabilele de stare  $x_i(t)$  și  $\hat{x}_i(t)$  - mișcarea longitudinală  $(K \neq 0)$ 

$$P^{*} = \begin{bmatrix} 0.0087 & -0.0004 & 0.0016 & 0.0002 \\ -0.0004 & 0.0055 & 0.0027 & 0.0023 \\ 0.0016 & 0.0027 & 0.0104 & 0.0070 \\ 0.0002 & 0.0023 & 0.0070 & 0.0120 \end{bmatrix}, \ L = \begin{bmatrix} 0.0238 \\ 0.2340 \\ 0.6993 \\ 1.1985 \end{bmatrix};$$
(3.35)

erorile de estimare a variabilelor de stare sunt prezentate în fig. 3.9 (pentru K=0), iar variabilele de stare  $x_i(t)$  și  $\hat{x}_i(t)$  pentru K calculată cu algoritmul ALGLX sunt prezentate în fig. 3.10.



Fig. 3.9. Erorile de estimare a stării estimatorului Kalman-Bucy (K=0)



Fig. 3.10. Variabilele de stare  $x_i(t)$  și  $\hat{x}_i(t)$  - mișcarea laterală ( $K \neq 0$ )

# 3.5. PROIECTAREA OBSERVERELOR $H_{\infty}$ PENTRU SISTEME SINGULARE NELINIARE

## **3.5.1. INTRODUCERE**

Proiectarea observerelor pentru sistemele neliniare reprezintă o preocupare con-

stantă în ultimele 2 decenii. Acest lucru se datorează faptului că eroarea de estimare este în general necesară pentru controlul sistemului atunci când nu sunt disponibile măsurătorile tuturor stărilor sistemului. Pentru sistemele neliniare există câteva metode de proiectare a observerelor ce se bazează, de exemplu, pe transformări de coordonate [114], [125], [222]. În cadrul altor lucrări [13], nu este nevoie de astfel de transformări pentru proiectarea observerelor. O clasă importantă de sisteme neliniare (sisteme Lipschitz) sunt analizate pe larg în [186] și [236].

În literatura de specialitate, se proiectează observere și pentru sistemele singulare (cunoscute și sub numele de descriptoare generalizate sau sisteme algebrice diferențiale [46]). Astfel de observere au fost proiectate în cadrul lucrărilor [30], [40], [139] etc; pe de altă parte, există și observere proiectate special pentru sistemele singulare cu intrări necunoscute [45], [47], [49]. În ultimii ani, o metodă nouă pentru proiectarea observerelor a fost utilizată pentru o clasă de sisteme singulare neliniare, în cadrul cărora neliniaritățile se consideră a fi compuse dintr-o neliniaritate Lipschitz și una ale-atorie, ultima fiind interpretată ca perturbație (intrare necunoscută) [46]. Metoda se ba-zează pe parametrizarea observerelor cu ordin întreg, ordin redus sau cu ordin minimal.

Problema estimării stării pentru sistemele liniare în prezența zgomotelor este subiectul mai multor studii în ultimele decenii. Se disting aici metode precum metoda filtrului Kalman și metoda  $H_{\infty}$ . În cadrul primei metode, sistemul și zgomotele se presupun a fi de tip Gausian [48], [167], [168]. Când zgomotul este un semnal arbitrar și mărginit, filtrarea  $H_{\infty}$  permite atingerea unui anumit nivel de atenuare a zgomotului. Dintre lucrările ce abordează filtrarea  $H_{\infty}$  pentru sistemele singulare, se remarcă [226] și [227]. În carul acestor lucrări, estimarea stării și intrărilor necunoscute se face simultan pentru sistemele singulare rectangulare; lucrarea [41] este prima în cadrul căreia este prezentată filtrarea robustă  $H_{\infty}$  pentru sistemele liniare singulare rectangulare. În cadrul acestei lucrări, sunt prezentate observere cu ordin întreg, cu ordin redus sau cu ordin minimal pentru sistemele continue sau discrete.

În lucrarea [46] este proiectat un observer  $H_{\infty}$  pentru sistemele singulare nelini-

are de tip Lipschitz pentru cazul în care modelul și măsurătorile sunt afectate de zgomote; metoda din [46] unifică tehnicile de proiectare asociate observerelor cu ordin întreg, ordin redus și ordin minimal.

#### **3.5.2. DESCRIEREA SISTEMULUI**

Se consideră sistemul singular neliniar [46]

$$\begin{cases} E\dot{x}(t) = Ax(t) + Bu(t) + Df(t, F_L x, u) + D_1 w(t), \\ y(t) = Cx(t) + D_2 w(t), \end{cases}$$
(3.36)

cu starea inițială  $x(0) = x_0$ ; în ecuațiile (3.36),  $x(t) \in \mathcal{M}^{n \times 1}$  este semi-vectorul de stare,  $u(t) \in \mathcal{M}^{m \times 1}$  – vectorul intrărilor necunoscute,  $w(t) \in \mathcal{M}^{n_w \times 1}$  – vectorul perturbațiilor ce conține atât zgomotele sistemului cât și zgomotele de măsurare,  $y(t) \in \mathcal{M}^{p \times 1}$  – vectorul măsurătorilor (ieșirilor). Matricea  $E \in \mathcal{M}^{n_1 \times n}$  este singulară în cazul în care  $n_1 = n$ ; dimensiunile celorlalte matrice sunt:  $A \in \mathcal{M}^{n_1 \times n}, B \in \mathcal{M}^{n_1 \times m}, C \in \mathcal{M}^{p \times n}, D \in \mathcal{M}^{n_1 \times n_f}$ ,  $D_1 \in \mathcal{M}^{n_1 \times n_w}$  și  $D_2 \in \mathcal{M}^{p \times n_w}$ . Neliniaritatea  $f(t, F_L x, u)$  verifică condiția Lipschitz

$$\|f(t, F_L x_1, u) - f(t, F_L x_2, u)\| \le \lambda \|F_L(x_1 - x_2)\|,$$
(3.37)

unde  $\lambda$  este o constantă Lipschitz cunoscută, iar matricea FL are elemente reale.

Ecuațiile (3.36) descriu o clasă largă de sisteme neliniare; de fapt, dacă se consideră sistemul [44], [80]

$$\begin{cases} E\dot{x}(t) = Ax(t) + Bu(t) + \varphi(t, F_L x, u) + D_1 w(t), \\ y(t) = Cx(t) + D_2 w(t), \end{cases}$$
(3.38)

în care neliniaritatea  $\varphi(t, F_L x, u)$  este de forma [46]

$$\varphi(t, F_L x, u) = Df(t, F_L x, u) + D_d d(t), \qquad (3.39)$$

unde  $f(t, F_L x, u)$  este neliniaritate Lipschitz,  $d(t) \in \mathcal{M}^{n_d \times 1}$  – vectorul intrărilor necunoscute, iar  $D_d$  – matrice cu rang de coloană maxim (rang  $D_d = n_d$ ), sistemul de ecuații (3.38) este echivalent cu sistemul (3.36) dacă se înmulțește acesta la stânga cu matricea cu rang de coloană maxim  $\begin{bmatrix} \pi_{D_d} \\ D_d^+ \end{bmatrix}$ , unde  $\pi_{D_d}$  este matricea de anulare la stânga a matricei Dd  $(\pi_{D_d} \cdot D_d = 0)$ , iar  $D_d^+$  este inversa generalizată (pseudo-inversa) a matricei Dd ; aceasta satisface proprietatea  $D_d D_d^+ D_d = D_d$ . În aceste condiții, prima ecuație (3.38) devine [46]

$$\pi_{D_d} E\dot{x}(t) = \pi_{D_d} A x(t) + \pi_{D_d} B u(t) + \pi_{D_d} D f(t, F_L x, u) + \pi_{D_d} D_1 w(t), \qquad (3.40)$$

sau

$$D_{d}^{+}E\dot{x}(t) = D_{d}^{+}Ax(t) + D_{d}^{+}Bu(t) + D_{d}^{+}Df(t, F_{L}x, u) + d(t) + D_{d}^{+}D_{1}w(t); \qquad (3.41)$$

a doua ecuație (3.38) nu se modifică. În deducerea ecuațiilor (3.40) și (3.41) s-a ținut seama de relația  $D_d^+D_d = I$  întrucât Dd are rang de coloană maxim. În acest caz, sistemul format din ecuația (3.40) și ce de-a doua ecuație (3.38) este un sistem de forma (3.36). Ecuația (3.41) poate fi ulterior utilizată pentru determinarea vectorului intrărilor necunoscute d(t). Când intrările necunoscute afectează ieșirea y(t), este ușor de demonstrat că sistemul

$$\begin{cases} E\dot{x}(t) = Ax(t) + Bu(t) + Df(t, F_L x, u) + D_d d(t) + D_1 w(t), \\ y(t) = Cx(t) + G_d d(t) + D_2 w(t), \end{cases}$$
(3.42)

în care d(t) este vectorul intrărilor necunoscute și rang $G_d = q_1$ , poate fi adus la forma (3.36). În [46] se demonstrează că, fără micșorarea generalității,  $G_d = \begin{bmatrix} I_{q_1} & 0 \\ 0 & 0 \end{bmatrix}$ ,  $d(t) = \begin{bmatrix} d_1(t) \\ d_2(t) \end{bmatrix}$ ,  $y(t) = \begin{bmatrix} y_1(t) \\ y_2(t) \end{bmatrix}$ ,  $C = \begin{bmatrix} C_1 \\ C_2 \end{bmatrix}$ ,  $D_2 = \begin{bmatrix} D_{21} \\ D_{22} \end{bmatrix}$ ,  $D_d = \begin{bmatrix} D_{d_1} & D_{d_2} \end{bmatrix}$  sunt matricele  $G_d$  din ecuațiile (3.39), precum și partiționările vectorilor d(t), y(t) și a matricelor  $C, D_2$  și, respectiv,  $D_d$ .

În acest caz, sistemul (3.42) este echivalent cu [46]

$$\begin{cases} E\dot{x}(t) = (A - D_{d_1}C_1)x(t) + \overline{B}\overline{u}(t) + Df(t, F_L x, u) + D_{d_2}d_2(t) + (D_1 - D_{d_1}D_{21})w(t), \\ y_2(t) = C_2x(t) + D_{22}w(t), \end{cases}$$
(3.43)

cu  $d_1(t) = y_1(t) - C_1 x(t) - D_{21} w(t), \overline{B} = \begin{bmatrix} B & D_{d_1} \end{bmatrix}, \overline{u}(t) = \begin{bmatrix} u(t) \\ y_1(t) \end{bmatrix}$ . Demonstrația se face folosind

ecuațiile (3.38)-(3.41), precum și matricea de anulare pentru  $D_{d_2}$ .

Modelul (3.36) este unul general și poate fi utilizat pentru estimarea simultană a semi-vectorului de stare (x(t)) și a vectorului intrărilor necunoscute. Astfel, dacă se con-sideră sistemul [46]

$$\begin{cases} E\dot{x}(t) = Ax(t) + Bu(t) + F_d d(t) + Df(t, x, u) + D_1 w(t), \\ y(t) = Cx(t) + G_d d(t) + D_2 w(t), \end{cases}$$
(3.44)

unde d(t) este vectorul intrărilor necunoscute ce urmează a fi estimat împreună cu x(t). Utilizând notațiile  $\mathbf{x} = \begin{bmatrix} x(t) \\ d(t) \end{bmatrix}, \mathbf{E} = \begin{bmatrix} E & 0 \end{bmatrix}, \mathbf{A} = \begin{bmatrix} A & F_d \end{bmatrix}, \mathbf{C} = \begin{bmatrix} C & G_d \end{bmatrix}, F_L = \begin{bmatrix} I & 0 \end{bmatrix}$ , sistemul

(3.44) poate fi adus la forma (3.36); se obține [46]

$$\begin{cases} \boldsymbol{E}\dot{\boldsymbol{x}}(t) = \boldsymbol{A}\boldsymbol{x}(t) + \boldsymbol{B}\boldsymbol{u}(t) + \boldsymbol{D}\boldsymbol{f}(t, F_{L}\boldsymbol{x}, \boldsymbol{u}) + \boldsymbol{D}_{1}\boldsymbol{w}(t), \\ y(t) = \boldsymbol{C}\boldsymbol{x}(t) + \boldsymbol{D}_{2}\boldsymbol{w}(t). \end{cases}$$
(3.45)

Pentru proiectarea observerului, se consideră  $\phi \in \mathcal{M}^{r_1 \times n_1}$  – o matrice cu rang de linie maxim astfel încât [44]

$$\phi \begin{bmatrix} E & D \end{bmatrix} = 0 \Leftrightarrow \phi E = 0 \text{ si } \phi D = 0. \tag{3.46}$$

În aceste condiții, înmulțind la stânga prima ecuație (3.36) cu  $\phi$ , rezultă

$$\phi Ax(t) + \phi Bu(t) + \phi D_1 w(t) = 0. \tag{3.47}$$

Dacă se face presupunerea

$$\operatorname{rang}\begin{bmatrix} E\\ \phi A\\ C \end{bmatrix} = n, \qquad (3.48)$$

în [46] se demonstrează că sistemul liniar singular (E,A,B,C) este observabil, adică

 $\operatorname{rang} \begin{bmatrix} E & A \\ 0 & C \\ 0 & E \end{bmatrix} = n + \operatorname{rang} E, \text{ dacă și numai dacă este îndeplinită condiția (3.48). Întrucât s-$ 

a făcut deja această presupunere, se poate concluziona că sistemul (3.36) este observabil (condiție necesară pentru construirea unui estimator de stare).

### **3.5.3. PROIECTAREA OBSERVERULUI**

Se urmărește proiectarea unui observer pentru sistemul (3.36) utilizându-se metoda  $H_{\infty}$ . În [46], pentru estimarea vectorului de stare asociat sistemului (3.36), se proiectează observerul

$$\begin{aligned} \dot{\zeta}(t) &= N\zeta(t) + Jy(t) + Hu(t) + TDf(t, F_L \hat{x}, u), \\ \hat{x}(t) &= P\zeta(t) - Q\phi Bu(t) + Fy(t), \end{aligned} (3.49)$$

cu  $\zeta(0) = \zeta_0$ . Vectorul  $\zeta(t) \in \mathcal{M}^{q \times 1}$  este vectorul de stare al observerului, iar  $\hat{x}(t) \in \mathcal{M}^{n \times 1}$  – vectorul de stare estimat. Matricele N, J, H, T, Q, P și F urmează a fi determinate astfel încât, pentru w(t) = 0, eroarea de estimare  $e(t) = \hat{x}(t) - x(t)$  converge asimptotic la zero și pentru  $w(t) \neq 0, e(t) \rightarrow 0$ .

Se consideră [46]

$$\varepsilon(t) = \zeta(t) - TEx(t); \qquad (3.50)$$

dinamica erorii  $\varepsilon(t)$  se calculează utilizând ecuațiile (3.36) și (3.49); se obține [46]

$$\dot{\varepsilon}(t) = \dot{\zeta}(t) - TE\dot{x}(t) = N\varepsilon(t) + (NTE - TA + JC)x(t) + (H - TB)u(t) + + TD\Delta f + (JD_2 - TD_1)w(t),$$
(3.51)

în care  $\Delta f = f(t, F_L \hat{x}, u) - f(t, F_L x, u)$ . De asemenea, eliminând  $\zeta(t)$  între a doua ecu-ație (3.49) și ecuația (3.50) și ținând seama de relația (3.47), rezultă

$$\hat{x}(t) = P\varepsilon(t) + PTEx(t) - Q\phi Bu(t) + FCx(t) + FD_2w(t) \Leftrightarrow$$

$$\hat{x}(t) = P\varepsilon(t) + \begin{bmatrix} P & Q & F \end{bmatrix} \begin{bmatrix} TE \\ \phi A \\ C \end{bmatrix} x(t) + (Q\phi D_1 + FD_2)w(t). \tag{3.52}$$

Dacă, pe lângă presupunerea (3.48), sunt valabile și relațiile

$$NTE - TA + JC = 0, N = TB, \begin{bmatrix} P & Q & F \end{bmatrix} \begin{bmatrix} TE \\ \phi A \\ C \end{bmatrix} = I, \qquad (3.53)$$

ecuațiile (3.51) și (3.52) devin [46]

$$\begin{cases} \dot{\varepsilon}(t) = N\varepsilon(t) + TD\Delta f + (JD_2 - TD_1)w(t), \\ e(t) = P\varepsilon(t) + (Q\phi D_1 + FD_2)w(t). \end{cases}$$
(3.54)

Cu notațiile  $\varphi_1 = JD_2 - TD_1$  și  $\varphi_2 = Q\phi D_1 + FD_2$ , ecuațiile (3.54) devin [46]

$$\begin{cases} \dot{\varepsilon}(t) = N\varepsilon(t) + TD\Delta f + \varphi_1 w(t), \\ e(t) = P\varepsilon(t) + \varphi_2 w(t). \end{cases}$$
(3.55)

În continuare, se determină cele 7 matrice necunoscute (N, J, H, P, Q, F și T) astfel încât condițiile (3.53) să fie satisfăcute și efectul vectorului perturbațiilor asupra erorii de estimare a observerului să fie minimizat.

#### 3.5.3.1. Condiții de stabilitate

Problema proiectării unui observer  $H_{\infty}$  poate fi formulată astfel [46]: Pentru un sistem neliniar singular având dinamica (3.36) și un nivel al zgomotului  $\gamma > 0$ , trebuie determinat un observer de forma (3.49) astfel încât: 1) sistemul erorilor (3.55) să fie stabil; 2) în condiții inițiale nule, norma L2 a vectorului eroare e(t) este mai mică ca norma L2 a vectorului w(t) ponderată cu nivelul de zgomot  $\gamma$ , adică  $||e(t)||_2 < \gamma ||w(t)||_2$ .

În ceea ce privește analiza stabilității sistemului (3.55), în [46] se arată că stabilitatea asimptotică a lui  $\varepsilon(t)$  este suficientă pentru ca  $\lim_{t \to \infty} e(t) = 0$  întrucât, pentru w(t)=0, se obține  $e(t) = P\varepsilon(t)$ . De asemenea, stabilitatea lui e(t), pentru w(t)=0, este verificată dacă există matricele pozitiv definite X și  $\Pi$  care verifică inegalitatea matriceal-liniară (LMIs)

$$\begin{cases} \Pi < I, \\ \begin{bmatrix} N^T X + XN + \lambda^2 P^T F_L^T F_L P & XTD \\ (TD)^T X & -\Pi \end{bmatrix} < 0. \end{cases}$$
(3.56)

Pentru demonstrație [46], se consideră funcția Lyapunov  $V(t) = \varepsilon^T(t)X\varepsilon(t)$  și se derivează aceasta în raport cu timpul; rezultă

$$\begin{split} \dot{V}(t) &= \dot{\varepsilon}(t)X\varepsilon(t) + \varepsilon^{T}(t)X\dot{\varepsilon}(t) \stackrel{(3.55)}{=} [N\varepsilon(t) + TD\Delta f]^{T} X\varepsilon(t) + \varepsilon^{T}(t)X [N\varepsilon(t) + TD\Delta f] = \\ &= \varepsilon^{T}(t)[N^{T}X + XN]\varepsilon(t) + \Delta f^{T}(TD)^{T} X\varepsilon(t) + \varepsilon^{T}(t)XTD\Delta f + \underbrace{\Delta f^{T}\Pi\Delta f}_{\leq \Delta f^{T}L\Delta f} - \Delta f^{T}\Pi\Delta f \leq \\ &\leq \varepsilon^{T}(t)[N^{T}X + XN]\varepsilon(t) + \Delta f^{T}(TD)^{T} X\varepsilon(t) + \varepsilon^{T}(t)XTD\Delta f + \underbrace{\Delta f^{T}\Delta f}_{\leq \lambda^{2}\varepsilon^{T}P^{T}F_{L}^{T}F_{L}P\varepsilon} - \Delta f^{T}\Pi\Delta f \leq \\ &\leq \left[\varepsilon(t)\right]^{T}\left[N^{T}X + XN + \lambda^{2}P^{T}F_{L}^{T}F_{L}P \quad XTD\\ &(TD)^{T}X \quad -\Pi\right]\left[\varepsilon(t)\right], \end{split}$$

$$\end{split}$$

$$\begin{aligned} &(3.57)$$

Pentru a demonstra că  $\Delta f^T \Delta f \le \lambda^2 \varepsilon^T P^T F_L^T F_L P \varepsilon$ , se particularizează (3.37) pentru  $x_1 = \hat{x}$  și  $x_2 = x$  și rezultă

$$\|f(t, F_L \hat{x}, u) - f(t, F_L x, u)\| \le \lambda \|F_L(\hat{x} - x)\| \Leftrightarrow \|\Delta f\| \le \lambda \|F_L e\|;$$
(3.58)

deoarece  $\|\Delta f^T \Delta f\| = \|\Delta f\|^2 \le \lambda^2 \|F_L e\|^2 \le \lambda^2 \|F_L e^T\| \cdot \|F_L e\| \le \lambda^2 \|F_L \varepsilon^T P^T\| \cdot \|F_L P\varepsilon\|$ , se obține  $\Delta f^T \Delta f \le \lambda^2 \varepsilon^T P^T F_L^T F_L P\varepsilon$ . S-a demonstrat, așadar, că  $\dot{V}(t) < 0$ ; este, deci, îndeplinită LMI (3.56). Mai mult, în [46], se arată că inegalitatea matriceal liniară (3.56), pentru orice scalar  $\mu > 0$ , este echivalentă cu

$$\begin{bmatrix} N^T X + XN + \lambda^2 \mu P^T F_L^T F_L P & XTD \\ (TD)^T X & -\mu I \end{bmatrix} < 0.$$
(3.59)

Demonstrația se face alegând  $\Pi = \mu I$  și  $0 < \mu < 1$  [46].

#### 3.5.3.2. Proiectarea observerului $H_{\infty}$

În cadrul acestui paragraf, este prezentată procedura de proiectare a observerului  $H_{\infty}$ . Următoarea teoremă furnizează condițiile suficiente pentru ca sistemul (3.55) să fie stabil pentru w(t)=0 și  $||e(t)||_2 < \gamma ||w(t)||_2$  pentru  $w(t) \neq 0$ .

### TEOREMA 3.1 [46]

Lucrând cu presupunerea (3.48), dinamica (3.55) este asimptotic stabilă pentru w(t)=0 și  $||e(t)||_2 < \gamma ||w(t)||_2$  pentru  $w(t) \neq 0$  dacă există matricele simetrice și pozitiv definite X și  $\Pi$  astfel încât, pentru matricele  $T, N, P, \varphi_1$  și  $\varphi_2$ , sunt îndeplinite simultan condițiile

$$\begin{cases} \Pi < I, \\ \Sigma = \begin{bmatrix} N^{T}X + XN + P^{T}\rho P & X(TD) & X\phi_{1} + P^{T}\rho\phi_{2} \\ (TD)^{T}X & -\Pi & 0 \\ \phi_{1}^{T}X + \phi_{2}^{T}\rho P & 0 & \phi_{2}^{T}\rho\phi_{2} - \gamma^{2}I \end{bmatrix} < 0, \end{cases}$$
(3.60)

unde  $\rho = I + \lambda^2 F_L^T F_L$ .

### DEMONSTRAȚIE [46]

Mai întâi, se observă că dacă  $\Sigma < 0$ , din teorema Schur, se obține inecuația matriceal-liniară (3.56), deci sistemul (3.55) este stabil pentru w(t)=0. În cazul în care  $w(t) \neq 0, \dot{V}(t)$  devine [46]

$$\dot{V}(t) = \dot{\varepsilon}(t)X\varepsilon(t) + \varepsilon^{T}(t)X\dot{\varepsilon}(t) = [N\varepsilon(t) + TD\Delta f + \varphi_{1}w(t)]^{T}X\varepsilon(t) +$$

$$+ \varepsilon^{T}(t)X[N\varepsilon(t) + TD\Delta f + \varphi_{1}w(t)] = \varepsilon^{T}(t)[N^{T}X + XN]\varepsilon(t) + \Delta f^{T}(TD)^{T}X\varepsilon(t) +$$

$$+ \varepsilon^{T}(t)X(TD)\Delta f + w^{T}(t)\varphi_{1}^{T}X\varepsilon(t) + \varepsilon^{T}(t)X\varphi_{1}w(t) + \Delta f^{T}\Pi\Delta f - \Delta f^{T}\Pi\Delta f$$

$$\leq \varepsilon^{T}(t)[N^{T}X + XN]\varepsilon(t) + \Delta f^{T}(TD)^{T}X\varepsilon(t) + \varepsilon^{T}(t)X(TD)\Delta f + w^{T}(t)\varphi_{1}^{T}X\varepsilon(t) +$$

$$+ \varepsilon^{T}(t)X\varphi_{1}w(t) + \lambda^{2}e^{T}F_{L}^{T}F_{L}e - \Delta f^{T}\Pi\Delta f \leq \varepsilon^{T}(t)[N^{T}X + XN]\varepsilon(t) + \Delta f^{T}(TD)^{T}X\varepsilon(t) +$$

$$+ \varepsilon^{T}(t)X(TD)\Delta f + w^{T}(t)\varphi_{1}^{T}X\varepsilon(t) + \varepsilon^{T}(t)X\varphi_{1}w(t) + \lambda^{2}e^{T}F_{L}^{T}F_{L}e - \Delta f^{T}\Pi\Delta f \leq$$
(3.61)

Utilizând notația  $\eta = \begin{bmatrix} \varepsilon(t) \\ \Delta f \\ w(t) \end{bmatrix}$ , ecuația (3.61) și a doua ecuație (3.55), rezultă

$$\dot{V} + e^T e - \gamma^2 w^T w \le \eta^T \Sigma \eta; \qquad (3.62)$$

dacă  $\Sigma < 0$  (LMI (3.60)), inecuația (3.62) devine  $\dot{V} \le \gamma^2 w^T w - e^T e$ , care, integrată între 0 și  $\infty$ , conduce la [46]

$$\int_{0}^{\infty} \dot{V}(\tau) d\tau < \int_{0}^{\infty} \gamma^{2} w^{T}(\tau) w(\tau) d\tau - \int_{0}^{\infty} e^{T}(\tau) e(\tau) d\tau, \qquad (3.63)$$

echivalentă cu

$$V(\infty) - V(0) < \gamma^2 \|w(t)\|_2^2 - \|e(t)\|_2^2.$$
(3.64)

În condiții inițiale nule, se obține

$$V(\infty) < \gamma^{2} \|w(t)\|_{2}^{2} - \|e(t)\|_{2}^{2} \Leftrightarrow \|e(t)\|_{2}^{2} < \gamma^{2} \|w(t)\|_{2}^{2}.$$
(3.65)

Determinarea matricelor observerului se face utilizând, în principal, ecuațiile (3.53); cu notația  $\tilde{T} = T + \psi \phi$ , unde  $\psi$  este o matrice aleasă aleator, ecuațiile (3.53) devin

$$\begin{bmatrix} N & \psi & J \\ P & Q & F \end{bmatrix} \begin{bmatrix} \widetilde{T}E \\ \phi A \\ C \end{bmatrix} = \begin{bmatrix} \widetilde{T}A \\ I_n \end{bmatrix}.$$
 (3.66)

Ecuația (3.66) are soluție dacă și numai dacă este îndeplinită condiția [46]

$$\operatorname{rang}\begin{bmatrix} \widetilde{T}E\\ \phi A\\ C\\ \widetilde{T}A\\ I_n \end{bmatrix} = \operatorname{rang}\begin{bmatrix} \widetilde{T}E\\ \phi A\\ C \end{bmatrix} = n.$$
(3.67)

Deoarece s-a făcut presupunera (3.48), rezultă rang $\begin{bmatrix} \widetilde{T}E \\ \phi A \\ C \end{bmatrix} = \operatorname{rang} \begin{bmatrix} E \\ \phi A \\ C \end{bmatrix} = n$ . Fie acum R –

o matrice cu rang de linie maxim aleasă aleator astfel încât

$$\operatorname{rang}\begin{bmatrix} R\\ \phi A\\ C \end{bmatrix} = \operatorname{rang}\begin{bmatrix} E\\ \phi A\\ C \end{bmatrix} = \operatorname{rang}\begin{bmatrix} \widetilde{T}E\\ \phi A\\ C \end{bmatrix} = n; \qquad (3.68)$$

În [46] se arată că există întot deauna matricele K și  $\widetilde{T}\,$  astfel încât

$$\widetilde{T}E = R - K \begin{bmatrix} \phi A \\ C \end{bmatrix} \Leftrightarrow \begin{bmatrix} \widetilde{T} & K \end{bmatrix} \begin{bmatrix} E \\ \phi A \\ C \end{bmatrix} = R.$$
(3.69)

Soluția ecuației (3.69) este [46]

$$\begin{bmatrix} \widetilde{T} & K \end{bmatrix} = R \begin{bmatrix} E \\ \phi A \\ C \end{bmatrix}^+, \qquad (3.70)$$

ecuație echivalentă cu

$$\widetilde{T} = R \begin{bmatrix} E \\ \phi A \\ C \end{bmatrix}^{+} \begin{bmatrix} I \\ 0 \end{bmatrix}, K = R \begin{bmatrix} E \\ \phi A \\ C \end{bmatrix}^{+} \begin{bmatrix} 0 \\ I \end{bmatrix}.$$
(3.71)

Aşadar, se poate acum determina soluția ecuației (3.66) [46]:

$$\begin{bmatrix} N & \psi & J \\ P & Q & F \end{bmatrix} = \begin{bmatrix} \widetilde{T}A \\ I_n \end{bmatrix} \Omega^+ - \begin{bmatrix} Y_1 \\ Y_2 \end{bmatrix} (I - \Omega \Omega^+), \qquad (3.72)$$

în care  $\Omega = \begin{bmatrix} \widetilde{T}E \\ \phi A \\ C \end{bmatrix}$  și  $\begin{bmatrix} Y_1 \\ Y_2 \end{bmatrix}$  – matrice aleasă în mod aleator. Cu notațiile:

$$\Lambda_{P} = \Omega^{+} \begin{bmatrix} I \\ 0 \\ 0 \end{bmatrix}, \Lambda_{Q} = \Omega^{+} \begin{bmatrix} 0 \\ I \\ 0 \end{bmatrix}, \Lambda_{F} = \Omega^{+} \begin{bmatrix} 0 \\ 0 \\ I \end{bmatrix}, \Lambda_{N} = \widetilde{T}A\Lambda_{P}, \Lambda_{\Psi} = \widetilde{T}A\Lambda_{Q},$$

$$\Lambda_{J} = \widetilde{T}A\Lambda_{F}, \Lambda_{N} = \left(I - \Omega\Omega^{+}\right) \begin{bmatrix} I \\ 0 \\ 0 \end{bmatrix}, \Lambda_{\Psi} = \left(I - \Omega\Omega^{+}\right) \begin{bmatrix} 0 \\ I \\ 0 \end{bmatrix}, \Lambda_{J} = \left(I - \Omega\Omega^{+}\right) \begin{bmatrix} 0 \\ 0 \\ I \end{bmatrix}$$
(3.73)

ecuațiile (3.72) devin [46]

$$N = \Lambda_N - Y_1 \Delta_N, \psi = \Lambda_{\psi} - Y_1 \Delta_{\psi},$$
  

$$J = \Lambda_J - Y_1 \Delta_J, P = \Lambda_P - Y_2 \Delta_N,$$
  

$$Q = \Lambda_Q - Y_2 \Delta_{\psi}, F = \Lambda_F - Y_2 \Delta_J.$$
(3.74)

Cu acestea, se obțin

$$\varphi_1 = \Lambda_{\varphi_1} - Y_1 \Delta_{\varphi_1}, \varphi_2 = \Lambda_{\varphi_2} - Y_2 \Delta_{\varphi_2}, TD = \Lambda_{TD} - Y_1 \Delta_{TD}, \qquad (3.75)$$

în care

$$\Lambda_{\varphi_{1}} = \Lambda_{J}D_{2} - \widetilde{T}D_{1} - \Lambda_{\psi}\phi D_{1}, \Delta_{\varphi_{1}} = \Delta_{J}D_{2} - \Delta_{\psi}\phi D_{1},$$
  

$$\Lambda_{\varphi_{2}} = \Lambda_{\varrho}\phi D_{1} + \Lambda_{F}D_{2}, \Delta_{\varphi_{2}} = \Delta_{\varrho}\phi D_{1} - \Delta_{J}D_{2},$$
  

$$\Lambda_{TD} = \widetilde{T}D + \Lambda_{\psi}\phi D, \Delta_{TD} = \Delta_{\psi}\phi D.$$
(3.76)

În cazul standard (E=I), rezultă  $\phi = 0$  și presupunera (3.48) este întotdeauna verificată. Rezultatele obținute pot fi aplicate în cadrul proiectării observerelor cu ordin întreg și cu ordin redus.

## 3.6. PROIECTAREA OBSERVERELOR PENTRU SISTEME CU INCERTITUDINI DETERMINISTE ȘI STOCHASTICE

### **3.6.1. INTRODUCERE**

Inconvenientul utilizării observerelor este legat de faptul că erorile acestora pot fi interpretate ca alarme false. Cauza o reprezintă incertitudinile în cadrul sistemelor, acestea putând fi grupate după cum urmează: incertitudini deterministe și incertitudini stochastice. Prima categorie este legată de eroarea de estimare inițială, eroarea de modelare și bias, în timp ce incertitudinile stochastice includ zgomote albe sau zgomote ale senzorilor. Deoarece observerele sunt afectate de ambele tipuri de incertitudini, în etapa de proiectare a observerului, acestea trebuie luate în considerație. Observere ce iau în considerație incertitudinile deterministe au fost proiectate de Spugeon (1990) [198], Bhattacharyya 1976 [23], Stefani 1982 [199], Huh & Stein (1994) [90], Shafai & Carrol (1985) [191] etc. Observere ce iau în calcul incertitudinile stochastice au fost proiectate de-a lungul ultimelor decenii de către Bernstein & Haddad (1989) [20], Chen & Zhou (2002) [35] (filtre  $H_2/H_{\infty}$ ), Pettersen & Fcfarlane (1994) [182], Xie & Soh (1994) [223], Fu & co. (2001) [68], Shaked & co. (2001) [192] etc. (filtre robuste de tip Kalman); aceste metode garantează mărginirea erorri medii pătratice a observerului [109].

### **3.6.2. PROIECTAREA OBSERVERULUI**

Se consideră un sistem liniar, variabil în timp, descris de ecuațiile [109]

$$\begin{cases} \dot{x} = (A + \Delta A)x + Bu + w, \\ y = Cx + v, \end{cases}$$
(3.77)

unde  $x \in \mathcal{M}^{n \times 1}, u \in \mathcal{M}^{m \times 1}, y \in \mathcal{M}^{p \times 1}$  sunt, respectiv, vectorii de stare, intrare și ieșire ai sistemului;  $\Delta A$  este incertitudine deterministă, iar vectorii w și v sunt incertitudini stochastice ce se consideră a fi necorelate. Se notează cu  $Q \in \mathcal{M}^{n \times n}$  și  $R \in \mathcal{M}^{p \times p}$  – matricele de covarianță asociate acestor vectori. De asemenea, se consideră că perechea (A, C) este observabilă. În aceste condiții, se poate construi observerul [109]

$$\dot{\hat{x}} = A\hat{x} + B(u + \delta u) + L(y + \delta y - C\hat{x}), \qquad (3.78)$$

în care L este matricea de amplificare a sistemului,  $\delta u$  și  $\delta y$  sunt biasurile de măsurare asociate intrărilor (u) și ieșirilor (y); acestea pot fi interpretate ca semnale deterministe.

Scăzând membru cu membru ecuațiile (3.77) și (3.78), se obține dinamica erorii

$$\dot{e} = (A - LC)e + w - Lv + \Delta Ax - B\delta u - L\delta y, \qquad (3.79)$$

unde  $e = x - \hat{x}$  este eroarea de estimare a observerului.

Dacă sistemul nu ar fi afectat de semnale deterministe, dinamica erorii observerului ar fi

$$\dot{e} = (A - LC)e + w - Lv; \qquad (3.80)$$

în [109] se arată că dacă matricea (A-LC) este asimptotic stabilă, matricea de covarianță a erorii staționare (notată mai jos cu X) este soluția ecuației Lyapunov [111]

$$(A - LC)X + X(A - LC)^{T} + Q + LRL^{T} = 0, (3.81)$$

cu soluția [109]

$$X = \int_{0}^{\infty} e^{(A-LC)t} \left( Q + LRL^{T} \right) e^{(A-LC)^{T}t} dt; \qquad (3.82)$$

matricea X se mai numește și gramian de controlabilitate, variația erorii observerului măsurându-se prin [109]

$$\operatorname{tr}(X) = \operatorname{tr}\left[\left(Q + LRL^{T}\right)\int_{0}^{\infty} e^{(A-LC)t}\left(Q + LRL^{T}\right)e^{(A-LC)^{T}t} dt\right] \leq$$

$$\leq \operatorname{tr}\left(Q + LRL^{T}\right) \cdot \lambda_{\max}\left[\int_{0}^{\infty} e^{(A-LC)^{T}t} e^{(A-LC)t} dt\right];$$

$$(3.83)$$

aceasta reprezintă suma elementelor de pe diagonala principală a matricei de covarianță.

Considerând un scalar pozitiv  $\alpha$ , limita superioară a variației erorii observerului este exprimată prin intermediul relației [109]

$$\operatorname{tr}(X) \leq \operatorname{tr}(Q + LRL^{T}) \cdot \int_{0}^{\infty} e^{-2\alpha t} \, \mathrm{d}t = \operatorname{tr}(Q + LRL^{T}) \cdot \frac{1}{2\alpha}.$$
(3.84)

 $\alpha$  se numește marginea inferioară a ratei de scădere a observerului; altfel spus, viteza

de convergență a matricei (A-LC) este cel puțin  $\alpha$ . Așadar, limita superioară (tr(*X*)) poate fi minimizată prin maximizarea lui  $\alpha$  și minimizarea lui L. De aceea,  $\alpha$  și L se consideră factori de robustețe stochastică pentru observer [109].

Robustețea deterministă a fost studiată în [90]. În cadrul acestei lucrări a fost definit indicatorul

$$\mu(V) = \|V\|_2 \|V^{-1}\|_2, \qquad (3.85)$$

unde  $\mu(V)$  este o funcție de matricea vectorilor proprii ai observerului (V) (vectorii proprii asociați matricei A-LC). Se arată în [90] că numărul de condiționare  $\mu(V)$  este factor de robustețe deterministă, el trebuind minimizat pentru asigurarea unei robusteți deterministe; o valoare mare a acestui factor echivalează cu sensibilitate mare a observerului la condiții inițiale, erori de modelare sau biasuri, în timp ce o valoare mai mică a acestui factor echivalează cu o influență redusă a incertitudinilor deterministe asupra procesului de estimare a stării.

Pentru a asigura atât robustețe stochastică cât și robustețe deterministă, este nevoie de maximizarea limitei inferioare a ratei observerului ( $\alpha$ ), minimizarea amplificării observerului (L), precum și de minimizarea indicatorului  $\mu(V)$ . Este însă nevoie și de obținerea unor relații între factorii de robustețe și amplificarea observerului, deci a unor relații între  $\alpha$  și L, pe de o parte, și  $\alpha$  și  $\mu(V)$ , pe de altă parte. În [109] și [90] se precizează că numărul de condiționare nu poate fi exprimat explicit ca funcție de amplificarea observerului și nici invers, dar acest număr de condiționare are o limită superioară ce poate fi modificată prin modificarea valorilor proprii asociate matricei (A-LC). Mai mult, această limită superioară este o funcție crescătoare de raportul

$$\beta = \frac{\left\|M\right\|_{F}}{\min_{i \neq j} \left|\lambda_{i} - \lambda_{j}\right|},$$
(3.86)

unde M se numește matrice de nenormalitate și este o sub-matrice a matricei diagonale

ce se calculează în funcție de transformarea Schur. Numărătorul din ecuația (3.86) reprezintă norma Frobenius a matricei M, iar  $\min_{i \neq j} |\lambda_i - \lambda_j|$  reprezintă distanța minimă între valorile proprii. În locul calculului numărului de condiționare, raportul (3.86) este utilizat pentru a obține o dependență de amplificarea observerului pentru robustețea deterministă.

În [109] este formulată o teoremă pentru condiția de stabilitate asociată estimatorului de stare; condiția de stabilitate a observerului se bazează pe teoria Lyapunov [29], [89] și este cuprinsă în cadrul următoarei teoreme:

### TEOREMA 3.2 [109]

Pentru constantele  $\delta_1, \delta_2$  și v0, există o matrice de amplificare a observerului (L) ce stabilizează dinamica erorii (3.80) dacă există  $P > 0, \tau_1 \ge 0, \tau_2 \ge 0$  astfel încât

$$\begin{bmatrix} A^{T}P + PA - C^{T}C + P & P & -\frac{1}{2}C^{T} \\ P & -\tau_{1}I & 0 \\ -\frac{1}{2}C & 0 & -\tau_{2}I \end{bmatrix} < 0$$
(3.87)

şi

$$\tau_1 \delta_1 + \tau_2 \delta_2 < v_0. \tag{3.88}$$

În aceste condiții, observerul este descris de ecuația (3.78), cu

$$L = \frac{1}{2} P^{-1} C^T \,. \tag{3.89}$$

#### **DEMONSTRATIE** [109]

Se consideră funcția Lyapunov

$$v(e,t) = e^{T}(t)Pe(t),$$
 (3.90)

cu P – matrice simetrică și pozitiv definită. Condiția de stabilitate pentru convergența la zero a erorii observerului este  $\dot{v}(e,t) < 0$ , aceasta devenind [109]

$$e^{T} \Big[ (A - LC)^{T} P + P (A - LC) \Big] e + w^{T} P e + e^{T} P w - v^{T} L^{T} P e - e^{T} P L v < 0.$$
(3.91)

Dacă se presupune că zgomotele w și v satisfac condițiile

$$w^T w \le \delta_1, v^T v \le \delta_2, \tag{3.92}$$

adică normele zgomotelor procesului și a celor de măsurare sunt mărginite, relațiile (3.92) sunt echivalente cu tr $(Q) \le S_1$  și tr $(R) \le S_2$ . În cadrul demonstrației, se presupune și că funcția Lyapunov este mărginită inferior, adică

$$v(e,t) \ge v_0, \tag{3.93}$$

unde v0 este o constantă pozitivă. De aici rezultă că dinamica erorii este stabilă în domeniul  $\{|e| \ge v_0 / \lambda_{max}(P)\}$  dacă  $\dot{v}(e,t) < 0$  [109]. Dacă se folosește procedura din [29] și se introduce o nouă variabilă  $S = L^T P$ , inegalitățile (3.91), (3.92) și (3.93) pot fi com-binate și rezultă o nouă inegalitate de tipul

$$\begin{bmatrix} e \\ w \\ v \end{bmatrix}^{T} \begin{bmatrix} A^{T}P + PA - C^{T}S - S^{T}C + \tau_{3}P & P & -S^{T} \\ P & -\tau_{1}I & 0 \\ -S & 0 & -\tau_{2}I \end{bmatrix} \begin{bmatrix} e \\ w \\ v \end{bmatrix} + \tau_{1}\delta_{1} + \tau_{2}\delta_{2} - \tau_{3}v_{0} < 0$$
(3.94)

pentru  $\tau_1 \ge 0, \tau_2 \ge 0$  și  $\tau_3 \ge 0$ . Inegalitatea (3.94) este echivalentă cu [109]

$$\begin{bmatrix} A^{T}P + PA - C^{T}S - S^{T}C + P & P & -S^{T} & 0 \\ -S^{T}C + \tau_{3}P & -\tau_{1}I & 0 & 0 \\ -S & 0 & -\tau_{2}I & 0 \\ 0 & 0 & 0 & \tau_{1}\delta_{1} + \tau_{2}\delta_{2} - \tau_{3}v_{0} \end{bmatrix} < 0.$$
(3.95)

Inegalitatea (3.95) este echivalentă cu următoarele 2 inegalități matriceal-liniare [109]

$$\begin{bmatrix} A^{T}P + PA - C^{T}S - S^{T}C + \tau_{3}P & P & -S^{T} \\ P & -\tau_{1}I & 0 \\ -S & 0 & -\tau_{2}I \end{bmatrix} < 0, \tau_{1}\delta_{1} + \tau_{2}\delta_{2} < v_{0}; \qquad (3.96)$$

fără micșorarea generalității, s-a ales  $\tau_3 = 1$ . Bazându-ne pe teorema lui Finsler [29],

[89], în cadrul lucrării [109] a fost eliminată matricea S din ecuația (3.96) și s-a obținut

$$\begin{vmatrix} A^{T}P + PA - \sigma C^{T}C + P & P & -\frac{\sigma}{2}C^{T} \\ P & -\tau_{1}I & 0 \\ -\frac{\sigma}{2}C & 0 & -\tau_{2}I \end{vmatrix} < 0,$$
(3.97)

în care, fără micșorarea generalității, se poate alege  $\sigma = 1$ , obținându-se astfel inegalitatea (3.87). Demonstrația teoremei 3.2 este acum completă. Proiectarea observerului (3.78) nu este însă completă fără rezolvarea problemei de optimizare legată de termenii de robustețe deterministă și stochastică. Așadar, scopul procesului de optimizare este minimizarea amplificării observerului, maximizarea limitei inferioare și minimizarea indicatorului de robustețe deterministă  $\mu(V)$  - ecuația (3.85) [109].

Pentru început, problema minimizării amplificării observerului poate fi rezolvată prin minimizarea valorii singulare maxime a matricei de amplificare. Cum L depinde de  $P^{-1}$  (ecuația (3.89)), minimizarea lui L este echivalentă cu maximizarea valorilor proprii minime ale matricei P, ceea ce înseamnă maximizarea unei noi variabile k astfel încât P > kI [29]. Bazându-se pe această proprietate, autorii lucrării [109] au formu-lat problema minimizării matricei L sub forma unei probleme de maximizate a varia-bilei k (teorema 3.3).

#### <u>TEOREMA 3.3</u> [109]

Pentru constantele  $\delta_1, \delta_2$  și v0, există o matrice de amplificare a observerului (L) ce stabilizează dinamica erorii (3.80) dacă este maximizat k, în condițiile

$$P = P^{T} > kI, \tau_{1} \ge 0, \tau_{2} \ge 0, k > 0, \tau_{1}\delta_{1} + \tau_{2}\delta_{2} < v_{0}$$
(3.98)

şi

$$\begin{bmatrix} A^{T}P + PA - C^{T}C + P & P & -\frac{1}{2}C^{T} \\ P & -\tau_{1}I & 0 \\ -\frac{1}{2}C & 0 & -\tau_{2}I \end{bmatrix} < 0;$$
(3.99)

în aceste condiții, matricea L se determină tot prin intermediul ecuației (3.89).

Pentru maximizarea limitei superioare a ratei observerului ( $\alpha$ ), se utilizează condițiile de stabilitate din [29]. Astfel, dacă este îndeplinită condiția [109]

$$\dot{v}(e,t) \le -2\alpha v(e,t) \tag{3.100}$$

pentru orice traiectorie, funcția Lyapunov converge exponențial cu o viteză cel puțin egală cu  $2\alpha$ , iar viteza de scădere a erorii este cel puțin egală cu  $\alpha$ . În plus, cea mai mare valoare pentru limita superioară poate fi determinată prin rezolvarea unei probleme optimale de maximizare a lui  $\alpha$  [29].

În al treilea rând, este nevoie și de minimizarea indicatorului de robustețe deterministă  $\mu(V)$ . Matricea vectorilor proprii V se obține din analiza modală a matricei observerului și este determinată în mod unic de către P. Astfel, indicatorul de robustețe  $\mu(V)$  poate fi ales ca funcție obiectiv și minimizat.

În [109] este formulată o teoremă ce însumează optimizarea tuturor celor 3 funcții obiectiv prezentate anterior (teorema 3.4).

### TEOREMA 3.4 [109]

Pentru constantele  $\delta_1, \delta_2$  și v0, există o matrice de amplificare a observerului (L) ce minimizează cele 3 funcții obiectiv și stabilizează dinamica erorii (3.80) dacă se poate minimiza  $\frac{w_1 \mu(V)}{\mu(V)^*} - \frac{(1-w_1)k}{k^*}$ , în condițiile

$$P = P^{T} - kI > 0, \tau_{1} \ge 0, \tau_{2} \ge 0, k > 0, \tau_{1}\delta_{1} + \tau_{2}\delta_{2} - v_{0} < 0$$
(3.101)

şi

$$\begin{bmatrix} A^{T}P + PA - C^{T}C + (2\alpha + 1)P & P & -\frac{1}{2}C^{T} \\ P & -\tau_{1}I & 0 \\ -\frac{1}{2}C & 0 & -\tau_{2}I \end{bmatrix} < 0, \qquad (3.102)$$

unde  $0 \le w_1 \le 1$ . Matricea vectorilor proprii V este obținută din analiza modală a ma-

tricei observerului  $A - \frac{1}{2}P^{-1}C^{T}C$ , iar matricea de amplificare a observerului rezultat se calculează tot prin intermediul ecuației (3.89). Valorile țintă  $\mu(V)^{*}$  și  $t^{*}$  sunt introduse pentru normalizarea funcțiilor obiectiv, acestea alegându-se ca valori dorite pentru fiecare funcție obiectiv în parte.

Alegerea valorilor țintă depinde de cerințele de estimare. De exemplu, dacă acuratețea de estimare este mai importantă ca erorile și biasurile de modelare, valoarea țintă pentru  $\mu(V)^*$  se alege aproape de 1 pentru asigurarea robusteței deterministe.

## 3.7. METODE OPTIMALE PENTRU DETERMINAREA MATRICEI DE AMPLIFICARE A OBSERVERELOR

În cadrul procesului de proiectare a estimatoarelor de stare, există numeroase metode pentru determinarea matricei de amplificare a observerului, scopul principal fiind asigurarea stabilității asimptotice a erorii. Dintre aceste metode, cele mai importante sunt: tehnica poziționării polilor [37], [138], [172], [209], metoda ecuațiilor algebrice Lyapunov [102], [126], metoda inegalităților matriceal liniare [11], [202], [207], și metoda optimizării prin minimizarea unui indicator pătratic de calitate [26], [151]. Întrucât acest indicator de calitate este construit în funcție de un sistem dual, acesta nu exprimă performanțele reale ale observerului, chiar dacă rezultatele obținute sunt satisfăcătoare.

## 3.7.1. DETERMINAREA AMPLIFICĂRII OPTIMALE FOLOSIND SISTEME DUALE

Se consideră sistemul

$$\begin{cases} \dot{x}(t) = Ax(t) + Bu(t), \\ y(t) = Cx(t) + Du(t), \end{cases}$$
(3.103)

unde  $x(t) \in \mathcal{M}^{n \times 1}$  este vectorul de stare,  $u(t) \in \mathcal{M}^{p \times 1}$  - vectorul intrărilor,  $y(t) \in \mathcal{M}^{m \times 1}$  -

vectorul ieșirilor, iar matricele A, B, C, D sunt matrice constante. Presupunând că perechea (A, C) este observabilă, se poate construi observerul Luenberger pentru sistemul (1) de forma [10]

$$\begin{cases} \dot{\hat{x}}(t) = A\hat{x}(t) + Bu(t) + L[y(t) - \hat{y}(t)], \\ y(t) = C\hat{x}(t) + Du(t), \end{cases}$$
(3.104)

unde  $\hat{x}(t) \in \mathcal{M}^{n \times m}$  este vectorul de stare estimat, iar  $L \in \mathcal{M}^{n \times m}$  este matricea de amplificare a observerului.

Dinamica erorii observerului  $(e(t) = x(t) - \hat{x}(t))$  este de forma

$$\dot{e}(t) = A_0 e(t),$$
 (3.105)

unde  $A_0 = A - LC$ . Printre tehnicile de determinare a matricei L se numără și minimizarea indicatorului pătratic de calitate [10]

$$\overline{J} = \int_{0}^{\infty} \left[ \overline{e}^{T}(t) Q \overline{e}(t) + \overline{u}^{T}(t) R \overline{u}(t) \right] dt$$
(3.106)

 $\operatorname{cu} Q = Q^T \ge 0 \quad \text{si} \quad R = R^T > 0.$ 

Pentru sistemele duale, se scrie [26]

$$\dot{\overline{e}}(t) = \overline{A}\overline{e}(t) + \overline{B}\overline{u}(t), \qquad (3.107)$$

unde  $\overline{A} = A^T$  și  $\overline{B} = C^T$ . Minimizarea lui  $\overline{J}$  conduce la obținerea matricei

$$L = \overline{M}C^T R^{-1}, \qquad (3.108)$$

în care  $\overline{M} = \overline{M}^T > 0$  este soluția ecuației matriceale algebrice Riccati

$$\overline{M}A^{T} + A\overline{M} - \overline{M}C^{T}R^{-1}C\overline{M} = -Q.$$
(3.109)

Dezavantajul acestei metode este acela că  $\overline{J}$ , care a fost minimizat, nu are o interpretare fizică directă în raport cu eroarea e(t). În cele ce urmează, este prezentată o metodă de optimizare ce exprimă performanțele dorite ale estimatorului de stare în

funcție de di-namica erorii [10].

## 3.7.2. DETERMINAREA MATRICEI DE AMPLIFICARE PENTRU OBSERVERELE CU ORDIN ÎNTREG

Dinamica erorii (3.105) poate fi pusă sub forma [10]

$$\begin{cases} \dot{e}(t) = Ae(t) + \varepsilon(t), \\ \mu(t) = Ce(t) \\ \varepsilon(t) = -L\mu(t), \end{cases}$$
(3.110)

în care  $\varepsilon(t) \in \mathcal{M}^{n \times 1}, \mu(t) \in \mathcal{M}^{m \times 1}; \varepsilon(t)$  este privit în [10] ca reacție negativă după vectorul de ieșire  $\mu(t), e(t)$  echivalând, în acest caz, cu starea sistemului. În aceste condiții, indicatorul de calitate ce trebuie minimizat este

$$J = \int_{0}^{\infty} \left[ e^{T}(t) Q e(t) + \varepsilon^{T}(t) R \varepsilon(t) \right] \mathrm{d}t, \qquad (3.111)$$

cu Q și R - matrice simetrice și pozitiv definite.

Minimizarea lui J poate fi interpretată drept determinarea unui compromis între minimizarea erorii observerului, reprezentată prin termenul  $e^{T}(t)Qe(t)$ , și minimizarea amplificării L, cuprinsă în termenul  $\varepsilon^{T}(t)R\varepsilon(t)$ . În aceste condiții, J poate fi scris sub una din formele succesive

$$J = \int_{0}^{\infty} \left[ e^{T}(t)Qe(t) + (L\mu(t))^{T}R(L\mu(t)) \right] dt = \int_{0}^{\infty} \left[ e^{T}(t)Qe(t) + \mu^{T}(t)L^{T}RL\mu(t) \right] dt =$$
  
=  $\int_{0}^{\infty} \left[ e^{T}(t)Qe(t) + e^{T}(t)C^{T}L^{T}RLCe(t) \right] dt = \int_{0}^{\infty} \left[ e^{T}(t)(Q + C^{T}L^{T}RLC)e(t) \right] dt =$  (3.112)  
=  $\int_{0}^{\infty} \left[ e^{T}(t)F(L)e(t) \right] dt,$ 

unde  $F(L) = Q + C^T L^T RLC$ . Utilizând acum soluția ecuației (3.105), adică  $e(t) = e^{A_0 t} e_0$ , în care  $e_0 = e(0)$ , ultima formă a ecuației (3.112) devine [10]

$$J = \int_{0}^{\infty} \left[ e_{0}^{T} e^{A_{0}^{T} t} F(L) e^{A_{0} t} e_{0} \right] \mathrm{d}t, \qquad (3.113)$$

expresie ce poate fi scrisă sub forma

$$J = \operatorname{tr} \begin{bmatrix} M & e_0 e_0^T \end{bmatrix}, \tag{3.114}$$

cu  $M = \int_{0}^{\infty} \left[ e^{A_0^T t} F(L) e^{A_0 t} \right] dt$  și tr $\left[ M e_0 e_0^T \right] -$  urma matricei  $\left[ M e_0 e_0^T \right]$ . Pe de altă parte,  $A_0^T M + M A_0 = \int_{0}^{\infty} \left[ A_0^T e^{A_0^T t} F(L) e^{A_0 t} + e^{A_0^T t} F(L) e^{A_0 t} A_0 \right] dt$ ; de aceea, matricea M satisface

ecuația Lyapunov

$$S(L,M) = A_0^T M + M A_0 + F(L) = 0.$$
(3.115)

Considerând  $E(e_0e_0^T) = I_n$ , indicatorul J și, implicit, soluția optimală nu vor mai depinde de valoarea lui e0. Condițiile necesare pentru minimizarea indicatorului de calitate (3.114) în raport cu L și M (soluția ecuației Lyapunov (3.115)) sunt obținute în [10] utilizând operațiile cu gradient pentru Lagrangianul

$$\mathcal{F}(L,M,T) = \operatorname{tr}(M) + \operatorname{tr}(T^{T}S(L,M)), \qquad (3.116)$$

unde  $T \in \mathcal{M}^{n \times n}$  – matricea Lagrangian. Condițiile necesare se scriu  $\frac{\partial F}{\partial L} = 0, \frac{\partial F}{\partial M} = 0,$ 

 $\frac{\partial \mathcal{F}}{\partial T} = 0$ , acestea conducând la [10]

$$\begin{cases} (RLC - M)TC^{T} = 0, \\ A_{0}T + TA_{0}^{T} + I_{n} = 0, \\ A_{0}^{T}M + MA_{0} + F(L) = 0. \end{cases}$$
(3.117)

Din prima ecuație (3.117) se obține

$$L = R^{-1} M T C^{T} (C T C^{T})^{-1}, \qquad (3.118)$$

matricele M și T determinându-se, în prealabil, din celelalte 2 ecuații (3.117).

## 3.7.3. DETERMINAREA MATRICEI DE AMPLIFICARE PENTRU OBSERVERELE CU ORDIN REDUS

Sistemul descris de ecuațiile (3.103), cu presupunerile  $\operatorname{rang}(C) = m$  și  $D = 0_{m \times p}$ , devine [26]

$$\begin{cases} \dot{x}_{1}(t) = A_{11}x_{1}(t) + A_{12}x_{2}(t) + B_{1}u(t), \\ \dot{x}_{2}(t) = A_{21}x_{1}(t) + A_{22}x_{2}(t) + B_{2}u(t), \\ y(t) = x_{1}(t), \end{cases}$$
(3.119)

 $\text{ în care } A = \begin{bmatrix} A_{11} & A_{12} \\ A_{21} & A_{22} \end{bmatrix}, A_{11} \in \mathcal{M}^{m \times m}, B = \begin{bmatrix} B_1 \\ B_2 \end{bmatrix}, B_1 \in \mathcal{M}^{m \times p}, x(t) = \begin{bmatrix} x_1(t) \\ x_2(t) \end{bmatrix}, x_1(t) \in \mathcal{M}^{m \times 1},$ 

 $C = \begin{bmatrix} I_m & 0_{m \times (n-m)} \end{bmatrix}$ ; aşadar, ieşirile sistemului sunt componentele vectorului de stare  $x_1(t)$ (vector ce nu va fi estimat întrucât este direct măsurabil), componentele vectorului de stare  $x_2(t)$  fiind cele ce urmează a fi estimate prin intermediul observerului cu ordin redus. Ecuațiile asociate observerului liniar pentru estimarea vectorului  $x_2(t)$  sunt [10]

$$\begin{cases} \dot{z}(t) = \hat{A}_{21}y(t) + \hat{A}_{22}z(t) + \hat{B}_{2}u(t), \\ \hat{x}_{2}(t) = z(t) + L_{2}y(t), \end{cases}$$
(3.120)

în care L2 este matricea de amplificare a observerului cu ordin redus, iar matricele  $\hat{A}_{21}, \hat{A}_{22}$  și  $\hat{B}_2$  se exprimă în funcție de L2 după cum urmează [10]

$$\hat{A}_{22} = A_{22} - L_2 A_{12}, \\ \hat{A}_{21} = A_{21} + A_{22} L_2 - L_2 A_{11} - L_2 A_{12} L_2, \\ \hat{B}_2 = B_2 - L_2 B_1.$$
(3.121)

Dinamica erorii  $e_2(t)$  (expresia lui  $\dot{e}_2(t)$ ) este  $\dot{e}_2(t) = (A_{22} - L_2A_{12})e_2(t) = \hat{A}_{22}e_2(t)$ , unde L2 – matrice ce trebuie determinată optimal astfel încât  $\lim_{t\to\infty} e_2(t) = 0, (\forall)e_2(0)$ . În multe lucrări, determinarea lui L2 se face utilizând tehnica poziționării polilor; în [10], L2 se determină prin rezolvarea unei probleme optimale, adică prin minimizarea indicatorului pătratic de calitate

$$J_{2} = \int_{0}^{\infty} \left[ e_{2}^{T}(t) Q_{2} e_{2}(t) + \varepsilon_{2}^{T}(t) R_{2} \varepsilon_{2}(t) \right] \mathrm{d}t, \qquad (3.122)$$

unde  $Q_2$  și  $R_2$  sunt matrice simetrice și pozitiv definite, iar  $\varepsilon_2(t)$  și  $e_2(t)$  joacă rolul lui  $\varepsilon(t)$  și, respectiv, e(t) din paragraful anterior; astfel, dinamica erorii observerului cu ordin redus se scrie

$$\begin{cases} \dot{e}_{2}(t) = A_{22}e_{2}(t) + \varepsilon_{2}(t), \\ \mu_{2}(t) = A_{12}e_{2}(t) \\ \varepsilon_{2}(t) = -L_{2}\mu_{2}(t). \end{cases}$$
(3.123)

Se observă o analogie cu cazul proiectării optimale a observerelor cu ordin întreg; aici, A22 joacă rolul lui A, L2 joacă rolul lui L, iar A12 pe cel al matricei C. Utilizând din nou pașii algoritmului anterior, rezultă [10]

$$L_2 = R_2^{-1} M_2 T_2 A_{12}^T (A_{12} T_2 A_{12}^T)^{-1}, \qquad (3.124)$$

în care M2 și T2 sunt soluțiile sistemului neliniar

$$\begin{cases} (R_2 L_2 A_{12} - M_2) T_2 A_{12}^T = 0, \\ \hat{A}_{22} T_2 + T_2 \hat{A}_{22}^T + I_{n-m} = 0, \\ \hat{A}_{22}^T M_2 + M_{222} \hat{A}_{22} + F(L_2) = 0, \end{cases}$$
(3.125)

în care  $F(L_2) = Q_2 + A_{12}^T L_2^T R_2 L_2 A_{12}, T_2 \in \mathcal{M}^{(n-m)\times(n-m)}$  matrice Lagrangian asociată observerului cu ordin redus (3.120), iar  $M_2 = \int_0^\infty \left[ e^{\hat{A}_{22}^T t} F(L_2) e^{\hat{A}_{22}t} \right] dt$  – soluția ecuației Lyapunov  $S(L_2, M_2) = \hat{A}_{22}^T M_2 + M_2 \hat{A}_{22} + F(L_2) = 0$  [10]. Matricele L și M, pentru obser-verele cu ordin întreg, respectiv L2 și M2, pentru observerele cu ordin redus, pot fi calculate în Matlab/Simulink utilizănd funcția fmincon. Deoarece rezolvarea siste-melor (3.117) și (3.125) se face iterativ, este nevoie de valori inițiale pentru matricele M și M2; în [10], aceste valori inițiale se aleg identice cu  $\overline{M}$  și  $\overline{M}_2$ , adică cu soluțiile ecuațiilor Lyapunov

$$\overline{M}A^{T} + A\overline{M} - \overline{M}C^{T}R^{-1}C\overline{M} = -Q, \overline{M}_{2}A_{22}^{T} + A_{22}\overline{M}_{2} - \overline{M}_{2}A_{12}^{T}R_{2}^{-1}A_{12}\overline{M}_{2} = -Q_{2}.$$
(3.126)

# 3.8. PROIECTAREA OPTIMALĂ A OBSERVERELOR ALUNECĂTOARE

Observerele alunecătoare diferă de observerele Luenberger printr-un termen de injectie (discontinuitate liniară) ce depinde de eroarea de estimare a iesirii. Acest tip de observer este mai robust decât observerele Luenberger deoarece termenul de tip discontinuitate permite observerului să respingă (anuleze) perturbatiile sistemului. Termenul de injecție este proiectat astfel încât eroarea de estimare a stării să aparțină unei anumite suprafete din spatiul erorilor. În majoritatea cazurilor, această suprafață, numită și suprafată de alunecare, este aleasă ca fiind diferenta dintre ieșirea observerului și ieșirea sistemului; de aceea, aceasta trebuie să fie zero. Utkin (1992) a proiectat un observer simplu cu reacție doar după termenul de tip discontinuitate [211]; Walcott & Zak (1987) au proiectat un observer cu reacție după eroarea de estimare a ieșirii, metoda Lyapunov fiind apoi utilizată pentru a demonstra stabilitatea estimatorului de stare [216]. Edwards & Spurgeon (1994) au propus o formă canonică pentru observerele alunecătoare, precum si conditiile ce dau legătura dintre matricele de distributie asociate intrării, respectiv ieșirii [58]. Unul dintre cei mai performanti algoritmi de proiectare a observerelor alunecătoare a fost propus de Tan & Edwards (2001). În cadrul lucrării acestor autori [203], este prezentată o metodă de proiectare a observerelor alunecătoare utilizând inegalitățile matriceal-liniare, fiind demonstrată o relatie între componenta liniară a observerului alunecător si un sub-observer optimal ce ia naștere din teoria lini-ară quadratică Gaussiană [203]. Metodologia de proiectare a observerului alunecător Tan & Edwards este prezentată în continuare.

#### **3.8.1. CHESTIUNI PRELIMINARE**

Se consideră sistemul dinamic

$$\begin{cases} \dot{x}(t) = Ax(t) + Bu(t) + D\xi(t, x, u), \\ y(t) = Cx(t), \end{cases}$$
(3.127)

unde  $A \in \mathcal{M}^{n \times n}, B \in \mathcal{M}^{n \times m}, C \in \mathcal{M}^{p \times n}$  și  $D \in \mathcal{M}^{n \times q} (p \ge q)$ . Se presupune că matricele C și D au rang maxim și  $\xi : R_+ \times \mathcal{M}^{n \times 1} \times \mathcal{M}^{m \times 1} \to \mathcal{M}^{q \times 1}$  este un termen necunoscut dar mărginit [203]

$$\|\xi(t, x, u)\| \le r_1 \|u\| + \alpha(t, y), \tag{3.128}$$

în care r1 este o constantă cunoscută, iar  $\alpha: R_+ \times \mathcal{M}^{p \times 1} \to R_+$  este o funcție cunoscută.

Se consideră observerul de forma [203]

$$\begin{cases} \dot{\hat{x}}(t) = A\hat{x}(t) + Bu(t) - G_{l}e_{y}(t) + G_{n}v, \\ \hat{y}(t) = C\hat{x}(t), \end{cases}$$
(3.129)

unde  $G_l \in \mathcal{M}^{n \times p}$  și  $G_n \in \mathcal{M}^{n \times p}$ . Vectorul de tip discontinuitate v se definește astfel [203]

$$v = \begin{cases} -\rho(t, y, u) \|D_2\| (P_2 e_y / \|P_2 e_y\|), & \text{daca } e_y \neq 0, \\ 0, & \text{daca } e_y = 0, \end{cases}$$
(3.130)

unde  $e_y = \hat{y} - y; P_2 \in \mathcal{M}^{p \times p}$  – matrice simetrică și pozitiv definită, iar  $D_2 \in \mathcal{M}^{p \times q}$  satisface condiția [203]

$$\rho(t, y, u) \ge r_1 ||u|| + \alpha(t, y) + \gamma_0$$
, (3.131)

cu  $\gamma_0$  – scalar pozitiv. Notând eroarea de estimare cu  $e = \hat{x} - x$ , din ecuațiile (3.127) și (3.129), se obține

$$\dot{e}(t) = \dot{x}(t) - \dot{x}(t) = A\hat{x}(t) + Bu(t) - G_l e_y(t) + G_n v - Ax(t) - Bu(t) - D\xi(t, x, u) =$$
  
=  $A_0 e(t) + G_n v - D\xi(t, x, u),$  (3.132)

unde  $A_0 = A - G_l C$ .

Pentru un sistem dinamic cu forma generală  $\dot{x} = Ax + Bu$ , y = Cx + Du, zerourile invariante sunt valorile complexe ale numărului complex "s" pentru care rangul matricei  $F = \begin{bmatrix} A - sI & B \\ C & D \end{bmatrix}$  scade față de valoarea sa normală; valoarea normală a rangului matricei F este rangul pentru valori ale lui "s" altele decât zerourile de transmisie (caz particular al zerourilor invariante).

Utilizând conceptul enunțat mai sus (zerouri invariante ale unui sistem), în [58] se demonstrează că există 2 condiții necesare și suficiente pentru existența unei mișcări de alunecare stabile pe  $S = \{e \in \mathcal{M}^{n \times 1} : e_y = Ce = 0\}$ , suprafață ce depinde de  $\xi$ ; aces-tea sunt:

1) rang(CD) = q;

2) zerourile invariante ale tripletului (A, D, C) se află poziționate în semiplanul stâng complex.

Matricele  $G_l$ ,  $G_n$  și  $P_2$  trebuie determinate astfel încât mișcarea de alunecare să se realizeze pe *S*; de aceea, în continuare, se consideră că cele 2 condiții enunțate anterior sunt îndeplinite. În [58] s-a demonstrat că dacă matricea (CD) are rang maxim, există o schimbare de coordonate, realizată prin intermediul unei matrice  $T_0$ , astfel încât sistemul descris de ecuațiile (3.127) se poate scrie

$$\begin{cases} \dot{\overline{x}}(t) = \overline{A}\overline{x}(t) + \overline{B}u(t) + \overline{D}\xi(t, x, u), \\ y(t) = \overline{C}\overline{x}(t), \end{cases}$$
(3.133)

cu  $\overline{x} = T_0 x$ , iar tripletul  $(\overline{A}, \overline{D}, \overline{C})$  are următoarea structură [203]

$$\overline{A} = \begin{bmatrix} \overline{A}_{11} & \vdots & \overline{A}_{12} \\ \cdots & \cdots & \cdots \\ \overline{A}_{211} & \vdots & \overline{A}_{22} \end{bmatrix}, \overline{A}_{11} = \begin{bmatrix} \overline{A}_{11}^{0} & \overline{A}_{12}^{0} \\ 0 & \overline{A}_{22}^{0} \end{bmatrix}, \overline{A}_{211} = \begin{bmatrix} 0 & \overline{A}_{21}^{0} \end{bmatrix}, \overline{D} = \begin{bmatrix} 0 \\ D_2 \end{bmatrix}, D_2 = \begin{bmatrix} 0 \\ \overline{D}_2 \end{bmatrix}, \overline{C} = \begin{bmatrix} 0 & T \end{bmatrix}, \quad (3.134)$$

cu  $\overline{A}_{11} \in \mathcal{M}^{(n-p) \times (n-p)}, \overline{A}_{211} \in \mathcal{M}^{(n-q) \times (n-p)}, \overline{A}_{11}^0 \in \mathcal{M}^{r \times r}, \overline{A}_{21}^0 \in \mathcal{M}^{(p-q) \times (n-p-r)}, r \ge 0$ , perechea  $\left(\overline{A}_{22}^0, \overline{A}_{21}^0\right)$  este observabilă,  $\overline{D}_2 \in \mathcal{M}^{q \times q}$  – nesingulară,  $T \in \mathcal{M}^{p \times p}$  – ortogonală  $\left(T^T = T^{-1}\right)$ .

## 3.8.2. PROIECTAREA OBSERVERULUI ALUNECĂTOR

Aplicând schimbarea de coordonate T0 observerului descris de ecuațiile (3.129),

se obține [203]

$$\begin{cases} \dot{\bar{x}}(t) = \overline{A}\,\hat{\bar{x}}(t) + \overline{B}\,u(t) - \overline{G}_l e_y(t) + \overline{G}_n v, \\ \hat{y}(t) = \overline{C}\,\hat{\bar{x}}(t); \end{cases}$$
(3.135)

se definește  $\overline{A}_0 = \overline{A} - \overline{G}_l \overline{C}$ . Matricea  $\overline{G}_l$  urmează a fi determinată și se presupune că

$$\overline{G}_n = \begin{bmatrix} -\overline{L}T^T \\ T^T \end{bmatrix}, \qquad (3.136)$$

unde  $\overline{L} \in \mathcal{M}^{(n-p) \times p}$  și  $\overline{L} = \begin{bmatrix} L & 0 \end{bmatrix}$ , cu  $L \in \mathcal{M}^{(n-p) \times (p-q)}$  [203].

### TEOREMA 3.5 [203]

Dacă există o matrice pozitiv definită  $\overline{P}$ , ce satisface  $\overline{PA_0} + \overline{A_0}^T \overline{P} < 0$  și a cărei formă este

$$P = \begin{bmatrix} \overline{P}_1 & \overline{P}_1 \overline{L} \\ \overline{L}^T \overline{P}_1 & \overline{P}_2 + \overline{L}^T \overline{P}_1 \overline{L} \end{bmatrix} > 0, \qquad (3.137)$$

unde  $\overline{P}_1 \in \mathcal{M}^{(n-p)\times(n-p)}$  și  $\overline{P}_2 \in \mathcal{M}^{p\times p}$ , atunci dinamica erorii (3.132) este quadratic stabilă.

#### DEMONSTRATIE [109]

Se consideră funcția Lyapunov

$$\mathcal{V}(\overline{e}) = \overline{e}\overline{P}\overline{e}\,,\tag{3.138}$$

în care  $\overline{e} = T_0 e$ . Dacă  $\overline{P_1} > 0$  și  $\overline{P_2} > 0$ , din teorema Schur rezultă  $\overline{P} > 0$  [203]. Derivând  $\mathcal{V}(\overline{e})$ , se obține

$$\dot{\psi} = \bar{e}^{T} \left( \overline{P} \overline{A}_{0} \bar{e} + \overline{P} \overline{D} \xi \right) + \left( \bar{e}^{T} \overline{A}_{0}^{T} + v^{T} \overline{G}_{n}^{T} - \xi^{T} D^{T} \right) \overline{P} \bar{e} =$$

$$= \bar{e}^{T} \left( \overline{P} \overline{A}_{0} + \overline{A}_{0}^{T} \overline{P} \right) \bar{e} + 2 \bar{e}^{T} \overline{P} \overline{G}_{n} v - 2 \bar{e}^{T} \overline{P} \overline{D} \xi; \qquad (3.139)$$

s-a ținut cont de egalitatea constantelor  $2\overline{e}^T \overline{P} \overline{G}_n v = (2\overline{e}^T \overline{P} \overline{G}_n v)^T = v^T \overline{G}_n^T \overline{P}^T \overline{e}$ . Din ecuațiile (3.134), (3.136) și (3.137), rezultă [203]

$$\overline{P}\overline{G}_{n} = \begin{bmatrix} \overline{P}_{1} & \overline{P}_{1}\overline{L} \\ \overline{L}^{T}\overline{P}_{1} & \overline{P}_{2} + \overline{L}^{T}\overline{P}_{1}\overline{L} \end{bmatrix} \begin{bmatrix} -\overline{L}T^{T} \\ T^{T} \end{bmatrix} = \begin{bmatrix} 0 \\ \overline{P}_{2}T^{T} \end{bmatrix} = \begin{bmatrix} 0 \\ T^{T}T\overline{P}_{2}T^{T} \end{bmatrix} = \begin{bmatrix} 0 \\ T^{T}\end{bmatrix} P_{2} = \overline{C}P_{2}, \qquad (3.140)$$

unde  $P_2 = T\overline{P_2}T^T$ . Folosind structura matricelor  $\overline{L}$  și  $D_2$ , rezultă  $\overline{L}D_2 = 0$  și se obține

$$\overline{PD} = \begin{bmatrix} \overline{P_1} & \overline{P_1L} \\ \overline{L}^T \overline{P_1} & \overline{P_2} + \overline{L}^T \overline{P_1L} \end{bmatrix} \begin{bmatrix} 0 \\ D_2 \end{bmatrix} = \begin{bmatrix} \overline{P_1L}D_2 \\ \overline{P_2D_2} + \overline{L}^T \overline{P_1L}D_2 \end{bmatrix} = \begin{bmatrix} 0 \\ \overline{P_2D_2} \end{bmatrix} = \begin{bmatrix} 0 \\ T^T P_2TD_2 \end{bmatrix} = \begin{bmatrix} 0 \\ T^T \end{bmatrix} P_2TD_2 = C^T P_2 D_2, \qquad (3.141)$$

în care  $\mathcal{D}_2 = TD_2$ ; de asemenea,  $\|\mathcal{D}_2\| = \|D_2\|$ .

În continuare, ținând cont de egalitatea  $e_y = \hat{y} - y = \overline{C}\hat{x} - \overline{C}\overline{x} = \overline{C}(\hat{x} - \overline{x}) = \overline{C}\overline{e}$ , de definiția vectorului discontinuitate (3.130), de expresiile (3.140) și (3.141), ecuația (3.139) capătă forma

$$\dot{\psi} = \overline{e}^{T} \left( \overline{A}_{0}^{T} \overline{P} + \overline{P} \overline{A}_{0} \right) \overline{e} + 2e_{y}^{T} P_{2} \psi - 2e_{y}^{T} P_{2} \mathcal{D}_{2} \xi \leq \\ \leq \overline{e}^{T} \left( \overline{A}_{0}^{T} \overline{P} + \overline{P} \overline{A}_{0} \right) \overline{e} - 2\rho \|\mathcal{D}_{2}\| \|P_{2} e_{y}\| - 2e_{y}^{T} P_{2} \mathcal{D}_{2} \xi.$$

$$(3.142)$$

Utilizând mărginirea termenului  $\xi(t, x, u)$  (ecuația (3.128)), rezultă [203]

$$\begin{aligned} \dot{\psi} &\leq \overline{e}^{T} \left( \overline{A}_{0}^{T} \overline{P} + \overline{P} \overline{A}_{0} \right) \overline{e} - 2\rho \|\mathcal{D}_{2}\| \|P_{2} e_{y}\| - 2\|\mathcal{D}_{2}\| (r_{1}\|u\| + \alpha) \|P_{2} e_{y}\| \\ &\leq \overline{e}^{T} \left( \overline{A}_{0}^{T} \overline{P} + \overline{P} \overline{A}_{0} \right) \overline{e} - 2\gamma_{0} \|\mathcal{D}_{2}\| \|P_{2} e_{y}\| \end{aligned}$$

$$(3.143)$$

în care  $\gamma_0 = \rho + r_1 \| u \| + \alpha > 0$ . Întrucât  $\overline{A}_0^T \overline{P} + \overline{PA}_0 < 0$ , rezultă  $\dot{\psi} \le 0 (\forall) \overline{e} \ne 0$  și teo-rema 5 [203] este acum complet demonstrată.

În [203] se demonstrează că dinamica de alunecare este furnizată de matricea  $\overline{A}_{11} + L\overline{A}_{211}$ ; de asemenea, deoarece perechea  $(\overline{A}_{11}, \overline{A}_{211})$  este detectabilă (ecuația (3.134)), există o familie de matrice  $L \in \mathcal{M}^{(n-p) \times (p-q)}$  astfel încât  $\overline{A}_{11} + L\overline{A}_{211}$  este stabilă. Dacă se efectuează o nouă schimbare de coordonate

$$T_L = \begin{bmatrix} I_{n-p} & \overline{L} \\ 0 & T \end{bmatrix}$$
(3.144)
pentru tripletul  $(\overline{A}, \overline{D}, \overline{C})$  și matricea Lyapunov  $\overline{P}(\overline{A} \to A, \overline{D} \to D, \overline{C} \to C)$ , rezultă

$$\mathcal{A} = \begin{bmatrix} \mathcal{A}_{11} & \mathcal{A}_{12} \\ \mathcal{A}_{21} & \mathcal{A}_{22} \end{bmatrix}, \mathcal{D} = \begin{bmatrix} 0 \\ \mathcal{D}_2 \end{bmatrix}, C = \begin{bmatrix} 0 & I_p \end{bmatrix},$$
(3.145)

în care  $\mathcal{A}_{11} = \overline{A}_{11} + L\overline{A}_{211}$  și  $\mathcal{D}_2 = TD_2$ ; conversia  $\overline{P} \to \mathcal{P}$  conduce la matricea [203]:  $\mathcal{P} = \left(T_L^{-1}\right)^T \overline{P}\left(T_L^{-1}\right)$  sau

$$\mathcal{P} = \begin{bmatrix} \overline{P}_1 & 0\\ 0 & T\overline{P}_2 T^T \end{bmatrix}.$$
 (3.146)

Prin poziționarea noului vector eroare, se obține  $\begin{bmatrix} e_1^T & e_y^T \end{bmatrix}^T$ , cu  $e_1 \in \mathcal{M}^{(n-p)\times 1}$ ; vectorul eroare e1 este asociat cu mișcarea de alunecare cu ordin redus. În [58] se demonstrează că  $\mathcal{A}_{11}$  este stabilă și, deci, mișcarea de alunecare este stabilă.

## **3.8.3. DETERMINAREA MATRICELOR** $\overline{P}$ **ŞI** $\overline{G}_l$

În cadrul acestui paragraf,  $\overline{P}$  și  $\overline{G}_l$  sunt determinate astfel încât [203]

$$\overline{A}_{0}^{T}\overline{P} + \overline{P}\overline{A}_{0} < -\overline{P}W\overline{P} - \overline{P}\overline{G}_{l}V\overline{G}_{l}\overline{P}, \qquad (3.147)$$

matricele W și V – matrice simetrice și pozitiv definite, iar  $\overline{P}$  – de forma (3.137). Înlocuind în (3.147) pe  $\overline{A}_0$  cu  $\overline{A} - \overline{G}_l \overline{C}$ , inegalitatea (3.147) devine

$$\begin{aligned} &\left(\overline{A} - \overline{G}_{l}\overline{C}\right)^{T}\overline{P} + \overline{P}\left(\overline{A} - \overline{G}_{l}\overline{C}\right) < -\overline{P}W\overline{P} - \overline{P}\overline{G}_{l}V\overline{G}_{l}^{T}\overline{P} \Leftrightarrow \\ &\Leftrightarrow \overline{A}^{T}\overline{P} - \overline{C}^{T}\overline{G}_{l}^{T}\overline{P} + \overline{P}\overline{A} - \overline{P}\overline{G}_{l}\overline{C} < -\overline{P}W\overline{P} - \overline{P}\overline{G}_{l}V\overline{G}_{l}^{T}\overline{P} \Leftrightarrow \\ &\Leftrightarrow \overline{A}^{T}\overline{P} + \overline{P}\overline{A} - \left(\overline{Y}\overline{C}\right)^{T} + \overline{P}W\overline{P} + \overline{Y}V\overline{Y}^{T} < 0, \end{aligned}$$

$$(3.148)$$

unde s-a făcut notația  $\overline{Y} = \overline{P}\overline{G_l}$ . În [203] se arată că (3.148) este echivalentă cu

$$\overline{A}^{T}\overline{P} + \overline{PA} + \left(\overline{Y}^{T} - V^{-1}\overline{C}\right)^{T}V\left(\overline{Y}^{T} - V^{-1}\overline{C}\right) - \overline{C}^{T}V^{-1}\overline{C} + \overline{P}W\overline{P} < 0; \qquad (3.149)$$

o condiție necesară și suficientă pentru a fi îndeplinită inegalitatea (3.149) și, implicit,

(3.148) este [203]

$$\overline{A}^{T}\overline{P} + \overline{P}\overline{A} + \overline{C}^{T}V^{-1}\overline{C} + \overline{P}W\overline{P} < 0$$
(3.150)

dacă și numai dacă se alege

$$\overline{Y}^T = V^{-1}\overline{C}. \tag{3.151}$$

Deoarece  $\overline{Y} = \overline{P}\overline{G}_l$ , dacă se minimizează tr $(\overline{P}^{-1})$  și dacă  $\overline{P}$  verifică inegalitatea (3.150), se poate determina ușor  $\overline{G}_l$  astfel:

$$\overline{G}_l = \overline{P}^{-1} \overline{C}^T V^{-1}. \tag{3.152}$$

Inegalitatea matriceal-liniară (3.150), utilizând teorema Schur, se scrie

$$\begin{bmatrix} \overline{A}^T \overline{P} + \overline{P}\overline{A} + \overline{C}^T V^{-1}\overline{C} & \overline{P} \\ \overline{P} & -W^{-1} \end{bmatrix} < 0.$$
(3.153)

Considerând  $\overline{X} \in \mathcal{M}^{n \times n}$  – o matrice simetrică și pozitiv definită, inecuația matriceal-liniară (LMI)

$$\begin{bmatrix} -\overline{P} & I\\ I & -\overline{X} \end{bmatrix} < 0 \tag{3.154}$$

este echivalentă cu  $\overline{X} > \overline{P}^{-1}$ ; în acest caz, minimizarea lui tr $(\overline{P}^{-1})$ , în condițiile verificării LMI (3.150) este echivalentă cu minimizarea lui tr $(\overline{X})$  în condițiile verificării inegalităților matriceal-liniare (3.153) și (3.154). Inegalitatea (3.137) poate fi scrisă și sub forma [203]

$$\overline{P} = \begin{bmatrix} P_{11} & P_{12} \\ P_{12}^T & P_{22} \end{bmatrix} > 0, \qquad (3.155)$$

unde  $P_{11} \in \mathcal{M}^{(n-p) \times (n-p)}, P_{22} \in \mathcal{M}^{p \times p}$  și  $P_{12} = \begin{bmatrix} P_{121} & 0 \end{bmatrix}$  cu  $P_{121} \in \mathcal{M}^{(n-p) \times (p-q)}$ ; relațiile de legătură sunt următoarele:  $\overline{P_1} = P_{11}, \overline{L} = P_{11}^{-1}P_{121}$  și  $\overline{P_2} = P_{22} - P_{12}^T P_{11}^{-1}P_{12}$ . În aceste con-diții, problema de minimizare reprezintă o problemă de optimizare convexă în raport cu

 $P_{11}, P_{121}, P_{22}$  și  $\overline{X}$ . Așadar, se dorește minimizarea lui tr $(\overline{X})$  în raport cu variabilele  $P_{11}, P_{121}, P_{22}$  și  $\overline{X}$  în condițiile verificării inegalităților matriceal-liniare (3.153), (3.154) și (3.155).

Cu schimbarea de coordonate (3.144),  $\overline{G}_l \to G_l$ , care este de forma (3.152), adică  $G_l = \mathcal{P}^{-1}C^T V^{-1}$ , se arata că [203]

$$G_l = \begin{bmatrix} 0\\ T\overline{P_2}^{-1}T^T V^{-1} \end{bmatrix}.$$
 (3.156)

Motivația alegerii inegalității (3.147) și minimizării tr $(\overline{P}^{-1})$ , în condițiile verificării (3.150) și (3.154), este că, în absența incertitudinilor ( $\gamma_0 \rightarrow 0$ ), observerul are o structură LQG (Linear Quadratic Gaussian). Pentru a demonstra acest lucru, se definește  $\overline{Q} = \overline{P}^{-1}$  și se înmulțește la stânga și apoi la dreapta inegalitatea (3.150) cu  $\overline{Q}$ ; se obține [203]

$$\overline{A}\overline{Q} + \overline{Q}\overline{A}^{T} - \overline{Q}\overline{C}^{T}V^{-1}\overline{C}\overline{Q} + W < 0; \qquad (3.157)$$

obiectivul este minimizarea lui tr $(\overline{Q})$  în condițiile verificării inegalității (3.157). Metoda standard de proiectare a observerelor optimale LQG este prezentată în [150]; în cadrul metodei, se folosește soluția stabilizatoare  $\tilde{Q}$  a ecuației algebrice Riccati

$$\overline{A}\overline{\widetilde{Q}} + \overline{\widetilde{Q}}\overline{A}^{T} - \overline{\widetilde{Q}}\overline{C}^{T}V^{-1}\overline{C}\overline{\widetilde{Q}} + W = 0.$$
(3.158)

Cu soluția  $\tilde{\overline{Q}}$  se calculează ulterior  $\tilde{\overline{G}}_l = \tilde{\overline{Q}} \overline{\overline{C}}^T V^{-1}$ . În inegalitatea (3.157), W - matrice de ponderare a observerului, iar V - matrice de covarianță a zgomotelor senzorilor.

#### TEOREMA 3.6 [203]

Fie  $\overline{Q}$  – matrice simetrică și pozitiv definită ce satisface inegalitatea (3.157); fie, de asemenea,  $\overline{\widetilde{Q}}$  – soluția ecuației Riccati (3.158). În acest caz,  $\overline{Q} > \overline{\widetilde{Q}}$  și, deci, tr $(\overline{Q}) > tr(\overline{\widetilde{Q}})$ . Demonstrația teoremei 3.6 este prezentată în [203].

# ANEXE

#### ANEXA A1.1

% Proiectarea observerelor utilizand metoda Bass-Gura (miscarea longitudinala n=4,s=1)

clear all;run prog2sec;close all;

clear A;clear B;clear C;clear D;clear e;clear e;clear R;clear r1;clear contor;

% Declararea matricelor sistemului

A=[-0.007 0.012 -9.81 0;-0.128 -0.54 0 1;0 0 0 1;0.065 0.96 0 -0.99];

B=[0;-0.04;0;-12.5];C=[0 0 1 0];

n=size(A,1);m=size(B,2);s=size(C,1);

x0=[100;1;0;10];	% Starea initiala (x0)
xc0=[70;0;-5;2];	% Starea initiala a observerului (xc0)
q1=-1;q2=-2;q3=-3;q4=-4;	% Valorile proprii dorite ale observerului
OB=obsv(A,C);	% Calculul matricei de observabilitate
r1=rank(OB);	% Calculul rangului matricei de observabilitate

% Calculul polinoamelor caracteristice asociate matricelor A si Ac

a=(poly(A))';

ac=[1 -(q1+q2+q3+q4) (q1\*q2+q1\*q3+q1\*q4+q2\*q3\*q2\*q4+q3\*q4) (-q3\*q4\*(q1+q2)-q1\*q2\*(q3+q4)) (q1\*q2\*q3\*q4)]'; Dif=ac(2:length(ac))-a(2:length(a)); % Dif=ac-a% Calculul matricei asociate observerului  $Ta=[1 \ 0 \ 0 \ 0; a(2) \ 1 \ 0 \ 0; a(3) \ a(2) \ 1 \ 0; a(4) \ a(3) \ a(2) \ 1]$  L=(inv(Ta\*OB))\*Dif Aobs=A-L\*C;eig(Aobs);% Simularea schemei fara controler (K=0) K=zeros(m,n);sim('Sch\_Bass\_Gura'); subplot(221);plot(t,x1-xc1);grid;subplot(222);plot(t,x2-xc2);grid; subplot(223);plot(t,x3-xc3);grid;subplot(224);plot(t,x4-xc4);grid; % Simularea schemei cu controler (K=K) K=KK;sim('Sch\_Bass\_Gura');h=figure; subplot(221);plot(t,x1,'b',t,xc1,'r--');grid;subplot(222);plot(t,x2,'b',t,xc2,'r--');grid; subplot(223);plot(t,x3,'b',t,xc3,'r--');grid;subplot(224);plot(t,x4,'b',t,xc4,'r--');grid;

#### ANEXA A1.2

```
% Observer cu ordin redus de tip Luenberger - miscarea longitudinala (n=4,m=1)
```

clear all;run prog2sec;close all;clear A;clear B;clear C;clear D;

clear e;clear e;clear R;clear r1;clear contor;clear i;KK=K;

% Declararea matricelor sistemului

A=[-0.007 0.012 -9.81 0;-0.128 -0.54 0 1;0 0 0 1;0.065 0.96 0 -0.99];B=[0;-0.04;0;-12.5];

n=size(A,1);m=size(B,2);C=[eye(2) zeros(2)];s=size(C,1);D=zeros(s,m);

pp=eig(A-B\*K); % Valorile proprii ale sistemul in circuit inchis (A-B\*K)

% Pasul 1: Calculul lui p si partitionarea matricelor A, B si C

p=rank(C);

A11=A(1:p,1:p);A12=A(1:p,(p+1):n);A21=A((p+1):n,1:p);A22=A((p+1):n,(p+1):n);

B1=B(1:p,1:m);B2=B((p+1):n,1:m);C1=C(:,1:p);C2=C(:,(p+1):n);

% Pasul 2: Calculul matricei T

T=[C1 C2;zeros(p) eye(n-p)];

r\_T=rank(T); % rangul matricei T trebuie sa fie n=rank(A)

if  $r_T \sim = rank(A)$ 

disp('Observerul nu poate fi construit');

end

% Pasul 3: Caclulul matricelor Ab11, Ab12, Ab21, Ab22, Bb1, Bb2, Ab, Bb, Cb Ab11=(C1\*A11+C2\*A21)\*(inv(C1));Ab12=-Ab11\*C2+C1\*A12+C2\*A22; Ab21=A21\*(inv(C1));Ab22=A22-A21\*(inv(C1))\*C2; Bb1=C1\*B1+C2\*B2;Bb2=B2; Ab=[Ab11 Ab12;Ab21 Ab22];Bb=[Bb1;Bb2];Cb=[eye(p) zeros(n-p)];

```
% Pasul 4: Observabilitatea perechii (Ab22,Ab12) si calculul matricei L
```

OB=obsv(Ab22,Ab12);r\_OB=rank(OB);

if r\_OB~=p

disp('Observerul nu poate fi construit');

end

q=[-0.7;-0.7]; % valorilor proprii dorite ale observerului (q)

L=place(Ab22',Ab12',q);L=L';

% Pasul 5: Calculul matricelor Mb, Nb, Pb

Mb=Ab22-L\*Ab12;Nb=Bb2-L\*Bb1;

Pb=Ab21+Ab22\*L-L\*Ab11-L\*Ab12\*L;

```
% Pasii 6,7: Constructia observerului
```

```
x0=[10;1;0;2];xb0=T*x0;zc0=zeros(p,1); % x(0), xb(0) si zc(0)
```

% Simularea schemei fara controler (K=0)

```
K=zeros(m,n);sim('Luenberger_sch_long');
```

for j=1:size(xc,3);

```
xxc1(j)=xc(1,:,j);xxc2(j)=xc(2,:,j);xxc3(j)=xc(3,:,j);xxc4(j)=xc(4,:,j);
xx1(j)=x(1,:,j);xx2(j)=x(2,:,j);xx3(j)=x(3,:,j);xx4(j)=x(4,:,j);
```

end

```
subplot(221);plot(t,xx1,'b',t,xxc1,'r--');grid;subplot(222);plot(t,xx2,'b',t,xxc2,'r--');grid;
subplot(223);plot(t,xx3,'b',t,xxc3,'r--');grid;subplot(224);plot(t,xx4,'b',t,xxc4,'r--');grid;
```

% Simularea schemei cu controler (K=K)

K=KK;sim('Luenberger\_sch\_long');h=figure;

for j=1:size(xc,3);

```
xxc1(j)=xc(1,:,j);xxc2(j)=xc(2,:,j);xxc3(j)=xc(3,:,j);xxc4(j)=xc(4,:,j);
```

$$xx1(j)=x(1,:,j);xx2(j)=x(2,:,j);xx3(j)=x(3,:,j);xx4(j)=x(4,:,j);$$

end

```
subplot(221);plot(t,xx1,'b',t,xxc1,'r--');grid;subplot(222);plot(t,xx2,'b',t,xxc2,'r--');grid;
subplot(223);plot(t,xx3,'b',t,xxc3,'r--');grid;subplot(224);plot(t,xx4,'b',t,xxc4,'r--');grid;
```

### ANEXA A1.3

```
% Identificarea miscarii longitudinale (n=4, m=1) folosind filtrul Kalman
clear all;run prog2sec;close all;
clear A;clear B;clear C;clear D;clear e;clear e;clear R;clear r1;clear contor;clear
L;clear O;
% Declararea matricelor sistemului
A=[-0.007 0.012 -9.81 0;-0.128 -0.54 0 1;0 0 0 1;0.065 0.96 0 -0.99];
B=[0;-0.04;0;-12.5];C=[0 0 1 0;0 -1 1 0];Bs=B;
n=size(A,1);s=size(B,2);m=size(C,1);N=zeros(s,m);D=zeros(m,m);
w=0.1*rand(s,1);v=0.1*rand(m,1);
% Starile initiale ale vectorului de stare si vect. de stare estimat
x0=[100;1;0;10]; xc0=zeros(n,1);
% Determinarea matricelor P si L folosind filtrul Kalman
Qs=0.01*eye(s);Rs=0.01*eye(m);KK=K;
[L,Ps,E] = LQE(A,Bs,C,Qs,Rs,N)
% Simularea schemei fara controler (K=0)
K=zeros(s,n);sim('Kalm long sch');
subplot(221);plot(t,x1-xc1,'r');grid;xlabel('Timp [s]');
subplot(222);plot(t,x2-xc2,'r');grid;xlabel('Timp [s]');
subplot(223);plot(t,x3-xc3,'r');grid;xlabel('Timp [s]');
subplot(224);plot(t,x4-xc4,'r');grid;xlabel('Timp [s]');
% Simularea schemei cu controler (K=K)
K=KK;sim('Kalm long sch');h=figure;
subplot(221);plot(t,x1,'b',t,xc1,'r--');grid;xlabel('Timp [s]');
subplot(222);plot(t,x2,'b',t,xc2,'r--');grid;xlabel('Timp [s]');
subplot(223);plot(t,x3,'b',t,xc3,'r--');grid;xlabel('Timp [s]');
subplot(224);plot(t,x4,'b',t,xc4,'r--');grid;xlabel('Timp [s]');
```

#### ANEXA A1.4

% Filtru Kalman - Bucy de tip discret pentru miscarea longitudinala (n=4) close all:clear all: % Declararea matricelor sistemului si a zgomotelor albe A=[-0.007 0.012 -9.81 0;-0.128 -0.54 0 1;0 0 0 1;0.065 0.96 0 -0.99];B=[0;-0.04;0;-12.5]; C=eye(4); n=size(A,1); m=size(B,2); s=size(C,1); D=zeros(s,m); Bs=B; H=zeros(s,m); w=0.1\*rand(m,m);v=0.1\*rand(s,m); Ts=0.01; sysc=ss(A,B,C,D); Rv=0.01\*eye(s); Rw=0.01\*eye(m); % Discretizarea sistemului sysd=c2d(sysc,Ts,'zoh');[Ad,Bd,Cd,Dd,Ts]=ssdata(sysd); % Determinarea maticei de amplificare K R=eye(m);Q=eye(n);[K,S,E]=DLQR(Ad,Bd,Q,R);K1=K;K2=zeros(m,n);% Initializarea sistemului si observerului x0=[100;1;0;10];xc0=zeros(4,1);u(1)=0;P=zeros(n);w0=w;x1(1)=x0(1);x2(1)=x0(2);x3(1)=x0(3);x4(1)=x0(4);xc1(1)=xc0(1);xc2(1)=xc0(2);xc3(1)=xc0(3);xc4(1)=xc0(4);x=[x1(1);x2(1);x3(1);x4(1)];xc=[xc1;xc2;xc3;xc4];% FOR-ul general for k=2:3000 xb=Ad\*xc+Bd\*u(k-1); N=Ad\*P\*Ad'+Bs\*Rw\*Bs'; P=N-N\*Cd'\*(inv(Cd\*N\*Cd'+Rv))\*Cd\*N;L0=P\*Cd'\*(inv(Rv));x=Ad\*x+Bd\*u(k-1)+Bs\*w;y=Cd\*x+v;x1(k)=x(1);x2(k)=x(2);x3(k)=x(3);x4(k)=x(4);xc=Ad\*xb+L0\*(y-Cd\*xb);xc1(k)=xc(1);xc2(k)=xc(2);xc3(k)=xc(3);xc4(k)=xc(4);u(k)=-K1\*xc;end t1=1:length(x1);t=t1\*Ts;

subplot(221); plot(t,x1,t,xc1,'r--'); grid; subplot(222); plot(t,x2,t,xc2,'r--'); grid; subplot(223); plot(t,x3,t,xc3,'r--'); grid; subplot(224); plot(t,x4,t,xc4,'r--'); grid; h=figure; subplot(221); plot(t,x1-xc1,'r'); grid; subplot(222); plot(t,x2-xc2,'r'); grid; subplot(223); plot(t,x3-xc3,'r'); grid; subplot(224); plot(t,x4-xc4,'r'); grid; subplot(223); plot(t,x3-xc3,'r'); grid; subplot(224); plot(t,x4-xc4,'r'); grid; subplot(224); plot(t,x4-xc4,'r'); grid; subplot(224); plot(t,x4-xc4,'r'); grid; gr

#### ANEXA A1.5

% Observer O'Reilly îmbunătățit, miscarea longitudinala n=4

clear all;run prog2sec;close all;clear A;clear B;clear C;clear D;clear e;clear e;clear R;clear r1;clear contor;clear i;KK=K;

% Declararea matricelor sistemului

A=[-0.007 0.012 -9.81 0;-0.128 -0.54 0 1;0 0 0 1;0.065 0.96 0 -0.99];B=[0;-0.04;0;-12.5];D=B;

n=size(A,1);p=size(B,2);s=size(D,2);d=randn(s,1);C=eye(2,n);m=size(C,1);

% Pasul 1: Verificarea conditiilor de existenta ale observerului

OB=obsv(A,C);

if  $s \ge m | \operatorname{rank}(D) \ge s | \operatorname{rank}(C) \ge m | \operatorname{rank}(C*D) \ge s | \operatorname{rank}(OB) \ge n$ 

disp('Observerul nu poate fi construit');

end

% Pasul 2: Calculul matricelor E si P

E=-D\*(pinv(C\*D));P=eye(n)+E\*C;

% Pasul 3: Calculul matricei G

G=P\*B;

% Pasul 4: Partitionarea matricelor N,P,L,C,A

P1=P(1:(n-m),1:(n-m));P2=P(1:(n-m),(n-m+1):n);

P3=P((n-m+1):n,1:(n-m));P4=P((n-m+1):n,(n-m+1):n);

A1=A(1:(n-m),1:(n-m));A2=A(1:(n-m),(n-m+1):n);

A3=A((n-m+1):n,1:(n-m));A4=A((n-m+1):n,(n-m+1):n);

C1=C(:,1:(n-m));C2=C(:,(n-m+1):n);

```
vp=[1;1;1;1]; % valori proprii necesare ciclului while
```

while real(vp(1))>0 | real(vp(2))>0 | real(vp(3))>0 | real(vp(4))>0

```
% Pasul 5: Calculul matricelor A1t,A2t,A3t,A4t
```

N1=7\*randn((n-m),(n-m));N3=2\*randn(m,(n-m));

A1t=P1\*A1+P2\*A3-N1\*P1;A2t=P1\*A2+P2\*A4-N1\*P2;

```
A3t=P3*A1+P4*A3-N3*P1;A4t=P3*A2+P4*A4-N3*P2;
```

```
% Pasul 6: Calculul matricelor L1,L2,N2,N4
```

```
PP4=pinv(P4);
```

```
L1=(A1t-A2t*PP4*P3)*pinv(C1-C2*PP4*P3);L2=(A3t-A4t*PP4*P3)*pinv(C1-
```

```
C2*PP4*P3);
```

N2=(A2t-L1\*C2)\*PP4;N4=(A4t-L2\*C2)\*PP4;

% Verificari intermediare

```
ANS1=N1*P1+N2*P3+L1*C1-P1*A1-P2*A3
```

```
ANS2=N1*P2+N2*P4+L1*C2-P1*A2-P2*A4
```

ANS3=N3\*P1+N4\*P3+L2\*C1-P3\*A1-P4\*A3

```
ANS4=N3*P2+N4*P4+L2*C2-P3*A2-P4*A4
```

```
% Pasul 7: Calculul matricelor N,L
```

```
N=[N1 N2;N3 N4];L=[L1;L2];
```

% Verificari

```
M1=N*P+L*C-P*A % M1 trebuie sa fie zero
```

```
M2=G-P*B % M2 trebuie sa fie zero
```

```
M3=(eye(n)+E*C)*D % M3 trebuie sa fie zero
```

vp=eig(N) % matricea N trebuie sa fie stabila

```
end % end while
```

% Simularea schemei fara controler (K=0)

```
x0=[100;1;0;10];xc0=zeros(n,1);z0=xc0+E*C*x0;
```

```
K=zeros(p,n);sim('OR_L_sch');
```

```
subplot(221);plot(t,x1,'b',t,xc1,'r--');grid;subplot(222);plot(t,x2,'b',t,xc2,'r--');grid;
```

```
subplot(223);plot(t,x3,'b',t,xc3,'r--');grid;subplot(224);plot(t,x4,'b',t,xc4,'r--');grid;
h=figure;
```

```
subplot(221);plot(t,x1-xc1);grid;subplot(222);plot(t,x2-xc2);grid;

subplot(223);plot(t,x3-xc3);grid;subplot(224);plot(t,x4-xc4);grid;

% Simularea schemei cu controler (K=K)

K=KK;h=figure;sim('OR_L_sch');

subplot(221);plot(t,x1,'b',t,xc1,'r--');grid;subplot(222);plot(t,x2,'b',t,xc2,'r--');grid;

subplot(223);plot(t,x3,'b',t,xc3,'r--');grid;subplot(224);plot(t,x4,'b',t,xc4,'r--');grid;

h=figure;

subplot(221);plot(t,x1-xc1);grid;subplot(222);plot(t,x2-xc2);grid;

subplot(223);plot(t,x3-xc3);grid;subplot(224);plot(t,x4-xc4);grid;
```

### ANEXA A1.6

% Observer ALGLIN (miscarea longitudinala - 6 variabile de stare)

close all;clear all;

% Introducerea datelor (matricele A,B,C,D din ecuatiile de stare)

```
A=[-0.444 0.594 -0.362 -9.794 0.000 0.014;-0.983 -7.804 15.322 0.481 0.001 0.000;
```

0.180 -8.310 -35.203 0.000 -0.000 0.000;0.000 0.000 1.000 0.000 0.000 0.000;

```
0.000 0.000 0.000 0.000 0.000 0.000;136.660 2.962 0.000 0.000 0.054 -8.501];
```

B=1000\*[-0.000 0.000;-0.004 0.000;-0.106 0.000;0.000 0.000;0.000 0.000;0.000 3.894];

```
C=[1.000 0.022 0.000 0.000 0.000 0.000;-0.001 0.059 0.000 0.000 0.000 0.000;
```

```
0.000 0.000 1.000 0.000 0.000 0.000;0.000 0.000 0.000 1.000 0.000 0.000];
```

```
D=1000*[-0.000 0.000;-0.004 0.000;-0.106 0.000;0.000 0.100;0.000 0.000;0.000 3.894];
```

```
n=size(A,1);m=size(C,1);p=size(B,2);s=size(D,2);
```

```
Q=0.1*eye(n); R=10*eye(2); [K,P,E] = LQR(A,B,Q,R); KK=K; qq=eig(A-B*K)
```

```
% Pasul 1: Verificare rang(C*D)=rang(D)
```

```
r1=rank(C*D);r2=rank(D);
```

```
if r1 \sim = r2
```

disp('Observerul nu poate fi cosntruit');

end

% Pasul 2: Alegerea matricei N

r3=1;

while r3~=n

N=randn(n,(n-s));T=[N D];r3=rank(T);

Ab=(inv(T))\*A\*T;Bb=(inv(T))\*B;Db=(inv(T))\*D;Cb=C\*T;

while Db-[zeros((n-s),s);eye(s)]~=zeros(n,s);

disp('Observerul nu poate fi cosntruit. Trebuie aleasa o alta matrice N');r3=1;

end

```
% Pasul 3: Calculul matricelor Ab, Bb, Cb, Db, Ab11, Ab12, Ab21, Ab22, Bb1, Bb2, Cb1, Cb2
```

Ab11=Ab(1:m,1:m);Ab12=Ab(1:m,m+1:n);

Ab21=Ab(1:(n-m),1:m);Ab22=Ab(1:(n-m),1:(n-m));

Bb1=Bb(1:m,1:p);Bb2=Bb(m+1:n,1:p);Cb1=Cb(1:m,1:m);Cb2=Cb(1:m,m+1:n);

% Pasul 4: Verificare rang Cb2 si determinare H2, R2, K2

if rank(Cb2)-size(Cb2,2)~=0

disp('Cb2 nu are rang de coloana maxim. Trebuie aleasa o alta matrice N');r3=1; end

H2=eye(m,n);R2=eye(n-m);R20=[R2;zeros(m,(n-m))];

K2=transpose((pinv(R20))\*(pinv(H2))\*Cb2);

if rank(R2)~=(n-m) | H2\*transpose(H2)~=eye(m)

disp('Observerul nu poate fi cosntruit. Trebuie aleasa o alta matrice N');r3=1;

end

M\_nula=H2\*R20\*(transpose(K2))-Cb2

% Pasul 5: Partitionarea matricei H2

H21=H2(:,1:(n-m));H22=H2(:,(n-m+1):n);

% Pasul 6: Calculul matricei Cl

C1=(transpose(H22))\*Cb1;

% Pasul 7: Calculul matrielor At1, Bt1, Et1

Gt=[eye(n-m) zeros((n-m),m)];

```
At1=Ab11-Ab12*K2*inv(R2)*Gt*transpose(H2)*Cb1;
```

```
Bt1=Bb1;Et1=Ab12*K2*inv(R2)*Gt*transpose(H2);
```

OB=obsv(At1,C1);

```
if rank(OB)~=size(At1,1)
```

disp('Observerul nu poate fi cosntruit. Trebuie aleasa o alta matrice N');r3=1;

end

% Pasul 8: Se proiecteaza observerul Luenberger

q=1\*qq(2:5); % valorilor proprii dorite ale observerului (q)

L=place(At1',C1',q);L=L';eig(At1-L\*C1)

% Pasii 9,10,11: Se proiecteaza observerul Luenberger

U1=K2\*(inv(R2))\*Gt\*(transpose(H2));

```
U2=K2*R2*Gt*transpose(H2)*Cb1*(L*transpose(H22)+Et1)+
```

```
Ab22*K2*(inv(R2))*Gt*transpose(H2);
```

```
U3=K2*(inv(R2))*Gt*transpose(H2)*Cb1*(At1-L*C1)+Ab21-
```

```
Ab22*K2*(inv(R2))*Gt*transpose(H2)*Cb1;
```

```
U4=K2*(inv(R2))*Gt*transpose(H2)*Cb1*Bt1+Bb2;
```

% Valorile de trimare

```
Vx0=17;Vy0=3/100;Vz0=3.7/10;
                                                % Componentele vitezei [m/s]
wx0=0*(pi/180);wy0=0*pi/180;wz0=0*pi/180;
                                                % Componentele vitezei unghiulare
[rad/s]
fi0=0.1*(pi/180);teta0=0.25*(pi/180);psi0=-43.6*(pi/180);
                                                             % Unghiurile Euler
[rad]
H0=100;
                                                             % Altitudinea de zbor
[m]
omega e0=5.09*100;
                                                              % Viteza unghiulara
elice [grd/s]
delta e0=1.01/100;delta d0=-6.7/100;delta p0=9.1/100;
                                                           % Bracajele la trimare
[rad]
delta T0=42.5;
                                                          % [%]
% Simularea schemei fara controler (K=0)
```

```
x0=[Vx0;Vz0;wy0;teta0;0;omega_e0];xbc10=zeros(m,1);
```

```
K=zeros(p,n);sim('ALGLIN_sch');
```

for j=1:size(xc,3);

```
xxc1(j)=xc(1,:,j);xxc2(j)=xc(2,:,j);xxc3(j)=xc(3,:,j);
xxc4(j)=xc(4,:,j);xxc5(j)=xc(5,:,j);xxc6(j)=xc(6,:,j);
xx1(j)=x(1,:,j);xx2(j)=x(2,:,j);xx3(j)=x(3,:,j);
xx4(j)=x(4,:,j);xx5(j)=x(5,:,j);xx6(j)=x(6,:,j);
```

end

```
subplot(321); plot(t,xx1,'b',t,xxc1,'r--'); grid; subplot(322); plot(t,xx2,'b',t,xxc2,'r--'); grid; subplot(323); plot(t,xx3,'b',t,xxc3,'r--'); grid; subplot(324); plot(t,xx4,'b',t,xxc4,'r--'); grid; subplot(325); plot(t,xx5,'b',t,xxc5,'r--'); grid; subplot(326); plot(t,xx6,'b',t,xxc6,'r--'); grid; h=figure;
```

```
subplot(321);plot(t,xx1-xxc1);grid;subplot(322);plot(t,xx2-xxc2);grid;
```

```
subplot(323);plot(t,xx3-xxc3);grid;subplot(324);plot(t,xx4-xxc4);grid;
```

```
subplot(325);plot(t,xx5-xxc5);grid;subplot(326);plot(t,xx6-xxc6);grid;
```

```
% Simularea schemei cu controler (K=KK)
```

```
h=figure;K=KK;sim('ALGLIN_sch');
```

for j=1:size(xc,3);

```
xxc1(j)=xc(1,:,j);xxc2(j)=xc(2,:,j);xxc3(j)=xc(3,:,j);
xxc4(j)=xc(4,:,j);xxc5(j)=xc(5,:,j);xxc6(j)=xc(6,:,j);
xx1(j)=x(1,:,j);xx2(j)=x(2,:,j);xx3(j)=x(3,:,j);
xx4(j)=x(4,:,j);xx5(j)=x(5,:,j);xx6(j)=x(6,:,j);
```

end

subplot(321); plot(t,xx1,'b',t,xxc1,'r--'); grid; subplot(322); plot(t,xx2,'b',t,xxc2,'r--'); grid; subplot(323); plot(t,xx3,'b',t,xxc3,'r--'); grid; subplot(324); plot(t,xx4,'b',t,xxc4,'r--'); grid; subplot(325); plot(t,xx5,'b',t,xxc5,'r--'); grid; subplot(326); plot(t,xx6,'b',t,xxc6,'r--'); grid; h=figure;

```
subplot(321);plot(t,xx1-xxc1);grid;subplot(322);plot(t,xx2-xxc2);grid;
subplot(323);plot(t,xx3-xxc3);grid;subplot(324);plot(t,xx4-xxc4);grid;
subplot(325);plot(t,xx5-xxc5);grid;subplot(326);plot(t,xx6-xxc6);grid;
```

end % end ciclul while (alegere matricei N)

#### ANEXA A1.7

```
% Proiectarea observerelor utilizand algoritmul Zhang (miscarea longitudinala
n=4, p=1)
clear all:close all:
run prog1sec;close all;KK=K;
% KK=[0.5478 -5.0206 6.8979 0.5399]; % mat. K de amplificare a sist.
clear A;clear B;clear C;clear D;clear e;clear e;clear R;clear K;
% Declararea matricelor sistemului
A=[-0.026 0.025 -0.1 0;-0.36 -3 0 1;0 0 0 1;0.4212 -38.42 0 -3.67];B=[0;0;0;1];Psi=B;
n=size(A,1);p=size(Psi,2);n=size(A,1);
C=[0\ 0\ 1\ 0];m=size(C,1);Ct=transpose(C);
                         % Starea initiala (x0)
x0=[100;1;0;10];
xc0=[90;2;0;11];
                        % Starea initiala a observerului (xc0)
%xc0=zeros(n,1);
                         % Starea initiala a observerului (xc0)
% Rezolvarea ecuatiei Riccati cu necunoscuta P si calculul matricei K
Q=1.2*eye(4);R=[80];[KKK,P,E]=lqr(A,Ct,Q,R);K=P*Ct*inv(R);
eig(A-K*C);GAMA0=zeros(n,p);
Teta=2;M=[3];S=20*eye(m,m); % Alegerea matricelor M si Sigma(S)
Tetac0=zeros(p,1);
                                       % Valoarea initiala a vectorului parametrilor
necunoscuti
% Simularea schemei bloc si realizarea catracteristicilor de timp
sim('ZHANG sch long');
subplot(2,3,1);plot(t,xc1-x1);grid;xlabel('Timp[s]');ylabel('x1c-x1[m/s]');
subplot(2,3,2);plot(t,xc2-x2);grid;xlabel('Timp[s]');ylabel('x2c-x2[grd]');
subplot(2,3,3);plot(t,xc3-x3);grid;xlabel('Timp[s]');ylabel('x3c-x3[grd]');
subplot(2,3,4);plot(t,xc4-x4);grid;xlabel('Timp[s]');ylabel('x4c-x4[grd/s]');
subplot(2,3,5);plot(t,Tetac-Teta);grid;xlabel('Timp[s]');ylabel('Tetac-Teta[grd]');
```

subplot(2,3,6);plot(t,Tetac);grid;xlabel('Timp[s]');ylabel('Tetac[grd]');

h=figure;

subplot(2,2,1);plot(t,x1,'b',t,xc1,'--r');grid;subplot(2,2,2);plot(t,x2,'b',t,xc2,'--r');grid; subplot(2,2,3);plot(t,x3,'b',t,xc3,'--r');grid;subplot(2,2,4);plot(t,x4,'b',t,xc4,'--r');grid;

#### ANEXA A1.8

% Estimator adaptiv (Lakhal) cu retea neuronala (misc. long. - avion cu unghi de *incidenta mare*) close all;clear all; % Declararea matricelor sistemului AA=[-1.85 -2.9 -0.85 0 0 0 0 0 0 0 0 0 0 0 0; -5 -3 18.1 30 0 0 0 0 0 0 0 0 0 0 0 0 0 0 -0.25 8 - 0.1 0 - 14 - 350 0 0 0 0 0 0 0 0 0;-0.15 0.08 -0.2 -3.9 0 0 -0.1 0.19 0.34 0.25 0.15 -0.12 0.2 -0.12 0; 0.1 -0.04 -0.1 0 -4.3 0 0.058 0.16 0.29 0.2 -0.05 0.12 -0.05 0 -0.09]; A=AA(1:5,1:5); % numarul variabilelor de stare nn=size(A,1); B=[3.1;2.9;1;1;1];C=eye(nn); % Structura retelelei neuronale n=size(A,1)+size(B,2) % numar neuroni de intrare % numar neuroni din stratul ascuns s=nn; % numar neuroni din stratul de iesire m=1; ita1=1;ita2=1;k=0.5; % declararea constantelor NN q=25\*[-1;-2;-3;-4;-5]; % valori proprii dorite pentru matricea G=A-L\*C % determinarea matricei observerului L L=place(A,C,q); % Verificarea alegerii matricei L ee=eig(A-L\*C);if  $ee(1) \sim = q(5) | ee(2) \sim = q(4) | ee(3) \sim = q(3) | ee(4) \sim = q(2) | ee(5) \sim = q(1)$ disp('Matricea L nu a fost bine aleasa');

else

disp('Matricea L a fost bine aleasa');

end

G=A-L\*C;Gt=transpose(G);Ct=transpose(C);

% Declararea matricelor S si F ale NN

S=-ita1\*((inv(Gt))\*Ct\*C);F=-ita2\*((inv(Gt))\*Ct\*C);

% Verificarea alegerii matricelor S si F

d=randn(1,s);

```
if d*S*(transpose(d))<0 | d*F*(transpose(d))<0
```

disp('S si/sau F nu au fost alese bine');

else

disp('S si/sau F au fost alese bine');

end

```
x0=[4;0.5;1;1;1];xc0=zeros(nn,1);
```

Wc0=randn(s,m);Vc0=randn(s,n); % valorile initiale ale ponderilor NN

sim('neuro obsv sch');timp=t;

for i=1:length(t)

```
xcc1(i)=xc1(:,:,i);xcc2(i)=xc2(:,:,i);xcc3(i)=xc3(:,:,i);xcc4(i)=xc4(:,:,i);xcc5(i)=xc5(:,:,i)
```

% valorile initiale ale starii si starii estimate

);

end

```
% Trasarea caracteristicilor grafice
```

subplot(3,2,1);plot(timp,x1,timp,xcc1,'r--');grid;xlabel('Timp');

subplot(3,2,2);plot(timp,x2,timp,xcc2,'r--');grid;xlabel('Timp');

subplot(3,2,3);plot(timp,x3,timp,xcc3,'r--');grid;xlabel('Timp');

subplot(3,2,4);plot(timp,x4,timp,xcc4,'r--');grid;xlabel('Timp');

subplot(3,2,5);plot(timp,x5,timp,xcc5,'r--');grid;xlabel('Timp');

h=figure;

subplot(3,2,1);plot(timp,x1-xcc1');grid;xlabel('Timp');

subplot(3,2,2);plot(timp,x2-xcc2');grid;xlabel('Timp');

subplot(3,2,3);plot(timp,x3-xcc3');grid;xlabel('Timp');

subplot(3,2,4);plot(timp,x4-xcc4');grid;xlabel('Timp'); subplot(3,2,5);plot(timp,x5-xcc5');grid;xlabel('Timp'); % Afisarea ponderilor NN dupa terminarea procesului de antrenare Wc\_final=Wc(:,:,size(Wc,3)) Vc\_final=Vc(:,:,size(Wc,3))

#### ANEXA A1.9

% Estimator adaptiv (Jing) cu retea neuronala ortogonala (avion cu incidenta mare) close all;clear all; % Matricele din ecuatiile de stare AA=[-1.85 -2.9 -0.85 0 0 0 0 0 0 0 0 0 0 0 0;-5 -3 18.1 30 0 0 0 0 0 0 0 0 0 0; -0.25 8 - 0.1 0 - 14 - 350 0 0 0 0 0 0 0 0 0;-0.15 0.08 -0.2 -3.9 0 0 -0.1 0.19 0.34 0.25 0.15 -0.12 0.2 -0.12 0; 0.1 -0.04 -0.1 0 -4.3 0 0.058 0.16 0.29 0.2 -0.05 0.12 -0.05 0 -0.09]; A=AA(1:5,1:5);nn=size(A,1);B=[3.1;2.9;1;1;1];Bs=eye(nn);C=eye(nn); % Determinarea matricelor L,P.M % valori proprii dorite pentru matricea A-L\*C q=[-1;-2;-3;-4;-5]; L=place(A,C,q);ee=eig(A-L\*C); if  $ee(1) \sim = q(5) | ee(2) \sim = q(4) | ee(3) \sim = q(3) | ee(4) \sim = q(2) | ee(5) \sim = q(1)$ disp('Matricea L nu a fost bine aleasa'); else disp('Matricea L a fost bine aleasa'); end Q=eye(nn);P=lyap(A-L\*C,Q); % determinarea matricei P % determinarea matricei M M=transpose(Bs)\*P\*pinv(C); % Introducerea constantelor

G1=1;sigma=5;ita=10;gama=2;k0=2;

W0=zeros(nn,nn); % valorile initiale ale ponderilor NN

x0=[4;0.5;1;1;1]; % valorile initiale ale starilor

xc0=[3;1;0.5;0.7;0.5]; % valorile initiale ale starilor estimate

sim('Jing\_obsv\_sch');timp=t;

% Trasarea caracteristicilor grafice

subplot(3,2,1);plot(timp,x1-xc1);grid;xlabel('Timp');

subplot(3,2,2);plot(timp,x2-xc2);grid;xlabel('Timp');

subplot(3,2,3);plot(timp,x3-xc3);grid;xlabel('Timp');

subplot(3,2,4);plot(timp,x4-xc4);grid;xlabel('Timp');

```
subplot(3,2,5);plot(timp,x5-xc5);grid;xlabel('Timp');
```

h=figure;

subplot(3,2,1);plot(timp,x1,timp,xc1,'r--');grid;xlabel('Timp');

subplot(3,2,2);plot(timp,x2,timp,xc2,'r--');grid;xlabel('Timp');

subplot(3,2,3);plot(timp,x3,timp,xc3,'r--');grid;xlabel('Timp');

```
subplot(3,2,4);plot(timp,x4,timp,xc4,'r--');grid;xlabel('Timp');
```

subplot(3,2,5);plot(timp,x5,timp,xc5,'r--');grid;xlabel('Timp');

```
% Afisarea ponderilor NN dupa terminarea procesului de antrenare si afisarea lui k
```

W\_final=W(:,:,size(W,3))

k=k(length(k))

#### **BIBLIOGRAFIE**

- Abdollahi, F., Talebi, H.A., A stable neural network observer with application to flexible joint manipulators, 9<sup>th</sup> International Conference on Neural Information Processing (ICONIP'O2), vol. 4, 2002, pag. 1910-1914.
- [2] Abdollahi, F., Talebi, H.A., *A stable neural network-based observer with application to flexible joint manipulators*. IEEE Transactions on Neural Network, vol 1, 2006, pag. 118-129.
- [3] Angelov, P., Filev, D., An Approach to Online Identification of Takagi-Sugeno Fuzzy Models. IEEE Transactions on systems, Man and Cybernetics, Part B, vol. 34, nr. 1, 2004, pag. 484-498.
- [4] Akhenak, A., Chadli, M., Maquin, D., Ragot, J., *Multiple observer with unknown inputs. Application to a three tank system.* IAR Annual Meeting, 2002.
- [5] Akhenak, A., Chadli, M., Maquin, D., Ragot, J., State estimation of uncertain multiple model with unknown inputs. 43r<sup>th</sup> IEEE Conference on Decision and Control (CDC), 14-17 Dec. 2004, pag. 3563-3568.
- [6] Akhenak, A., Chadli, M., Maquin, D., Ragot, J., Sliding mode multiple observer for fault detection and isolation. 42th IEEE Conference on Decision and Control, Hawaii, December 9-12, 2003.
- [7] Akhenak, A., Chadli, M., Maquin, D., Ragot, J., *State estimation via multiple observer. Three tank system.* 5<sup>th</sup> IFAC Symposium on Fault Detection, Supervision and Safety for Technical Processes, Washington, 2003, pag. 1227-1232.
- [8] Akhenak, A., Chadli, M., Ragot, J., Maquin, D., Unknown input multiple observer based-approach - application to secure communications. 1<sup>st</sup> IFAC Conference on analysis and Control of Chaotic Systems, Reims, France, 2006.
- [9] Akhenak, A., Chadli, M., Ragot, J., Maquin, D., Design of sliding mode unknown input observer for uncertain Takagi-Sugeno model. 15<sup>th</sup> Mediteranean Conference on Control and Automation (MED'07), Grecia, 2007.

- [10] Aloui, R., Braiek, N.B., On the determination of an optimal state observer gain for multivariable systems: Application to induction motors. Journal of Automation and Systems Engineering, vol. 2, nr. 3, 2008, pag. 206-218.
- [11] Aloui, R., Tlili, A.S., Braiek, N.B., Observateurs d'etat non lineaires et/ou robustes a mode glissant d'une machine asyncrone. Conf. Int. Francophone d'Auto. CIFA 2006, Bordeaux, France.
- [12] Antsaklis, P.J., Michel, A.N., *Linear systems*. Editura McGraw Hill, 1997.
- [13] Arcak, M., Kokotovic, P., *Nonlinear observers: a circle criterion design and robustness analysis.* Automatica, vol. 37, nr. 12, 2001, pag. 1923-1930.
- [14] Astrom, K., Wittenmark, B., Computer-Controlled Systems: Theory and Design. Prentice Hall, 1997.
- [15] Basseville, M., Nikiforov, I.V., Detection of Abrupt Changes: Theory and Application. Prentice-Hall, Englewood Cliffs, NJ, 1993.
- [16] Bastin, G., Gevers, M.R., Stable adaptive observers for nonlinear time-varying systems. IEEE Transactions on Automatic Control, vol. 33, 1988, pag. 650-658.
- [17] Baumann, W.T., Rugh, W.J., *Feedback control of nonlinear systems extended linearization*. IEEE Transactions on Automatic Control, AC-31, pag. 40-46.
- Berdjag, D., Christophe, C., Cocquempot, V., Jiang, B., Nonlinear model decomposition for robust fault detection and isolation using algebraic tools. International Journal of Innovative Computing, Information and Control, vol. 2, nr. 6, 2006, pag. 1337-1354.
- [19] Bergsten, P., Palm, R., Driankov, D., Observers for Takagi-Sugeno fuzzy systems. IEEE Transactions on Systems, Man, and Cybernetics – Part B: Cybernetics, vol. 32, nr. 1, 2002, pag. 114-121.
- [20] Bernstein, D.S., Haddad, W., Steady-state Kalman filtering with an H1 error bound. Syst. Con. Let., vol. 12, 1989, pag. 9-16.
- [21] Besançon, G., *Remarks on nonlinear adaptive observer design*. Systems & Control Letters, vol. 41, 2000, pag. 271-280.
- [22] Bhattacharyya, S.P., *Observer design for linear system with unknown inputs*. IEEE Transactions on Automatic Control, vol. AC-23, 1978, pag. 483-484.

- [23] Bhattacharyya, S.P., *The structure of robust observers*. IEEE Trans. Auto. Con., vol. 21, 1976, pag. 581-588.
- [24] Blanco, Y., Gouaisbaut, F., Perruquetti, W., Borne, P., Sliding mode controller design using polytopic formulation. IEEE Conference on Decision and Control, CDC'2001, Orlando USA, December 2001.
- [25] Blanke, M., Kinnaert, M., Lunze, J., Staroswiecki, M., *Diagnosis and Fault-Tolerant Control* (Second edition), Springer Verlag, Berlin Heidelberg, 2006.
- [26] Borne, P. Tanguy, G.D., Richard, J.P., Rotella, F., Zambettakis, I., *Commande et optimisation des processus*. Technip, vol. 1, 1990.
- [27] Boubaker, O., *Robust Observers for Linear Systems with Unknown Inputs: a Review.* ASCE Journal, vol. 5, Issue II, June, 2005, pag. 45-51.
- [28] Boubaker, O., Sfaihi, B., *Robust Observers for Linear Systems with Unknown Inputs: a comparative sudy.* IEEE SSD'2005, Sousse, Tunisia, 2005.
- [29] Boyd, S., Ghaoui, L.E., Feron, E., Balakrishnan, V., *Linear Matrix Inequals*. Syst Cont Theory, PA: Society for Industrial and Applied Mathematics, 1994.
- [30] Campbell, S.L., *Singular systems of differential equations*. Pitman, 1982.
- [31] Chadli, M., Maquin, D., Ragot, J., *On the stability analysis on multiple model systems*. European Control Conference, Portugal, 2001.
- [32] Chen, J., Patton, R.J., *Robust Model-Based Fault Diagnosis for Dynamic Systems*. Publisher: Springer; 1st Edition, ISBN-10: 0792384113.
- [33] Chen, J., Patton, R.J., Zhang, H., Design of unknown input observers and robust fault detection filters. International Journal of Control, vol. 63, 1996, pag. 85-105.
- [34] Chen, J., Zhang, H., *Robust detection of faulty actuators via unknown input observers*. International Journal of Systems Science, vol. 22, nr. 10, 1980.
- [35] Chen, X., Zhou, K., *H-inf Gaussian filter on infinite time horizon*. IEEE Trans. Circuits and Syst.: Fundamental Theory and Applications, vol. 49, 2002, pag. 674-679.
- [36] Cheng, C., Chang, M., Design of derivative estimator using adaptive sliding mode. Proceedings of 2006 IEEE American Control Conference, (Minneapolis,

MN), 2006, pag. 2611-2615.

- [37] Chilali, M., Gahinet, P., *H-inf design with pole placement constraints an LMI approach*. IEEE Trans. Aut. Control, 1996, pag. 358-367.
- [38] Cho Y.M., Rajamani, R., A systematic approach to adaptive observer synthesis for nonlinear systems. IEEE Transaction on Automatic Control, vol. 42, nr. 4, 1997, pag. 534-537.
- [39] Corless, M., Tu, J., *State and input estimation for a class of uncertain systems*. Automatica, vol. 34, nr.6, 1998, pag. 757-764.
- [40] Dai, L., *Singular control systems*. New York: Springer-Verlag, 1989.
- [41] Darouach, M.,  $H_{\infty}$  unbiased filtering for descriptor systems via LMI. IEEE Transactions on Automatic Control, vol. 54, nr. 8, 2009, pag. 1966-1972.
- [42] Darouch, M., *Linear Functional Observers for Systems with Delays in Stable Variables*. IEEE Transactions on Automatic Control, vol. 46, 2001, pag. 491-496.
- [43] Darouach, M., Functional Observers for Systems with Unknown Inputs. Proceedings of the 16<sup>th</sup> International Symposium on Mathematical Theory of Networks and Systems, Leuven, Belgia, 2004.
- [44] Darouach, M., Boutat-Baddas, L., Observer for a class of nonlinear singular systems. IEEE Transactions on Automatic Control, vol. 53, nr. 11, 2008, pag. 2627-2633.
- [45] Darouach, M., Boutayeb, M., Design of observers for descriptor systems. IEEE Transactions on Automatic Control, vol. 40, nr. 7, 1995, pag. 1323-1327.
- [46] Darouach, M., Boutat-Baddas, L., Zerrougui, M.,  $H_{\infty}$  observers design for a class of nonlinear singular systems. Automatica, vol. 47, 2011, pag. 2517-2525.
- [47] Darouach, M., Zasadzinski, M., Hayar, M., Reduced-order observer design for descriptor systems with unknown inputs. IEEE Transactions on Automatic Control, vol. 41, nr. 7, 1996, pag. 1068-1072.
- [48] Darouach, M., Zasadzinski, M., Mehdi, D., State estimation of stochastic singular linear systems. International Journal of Systems Science, vol. 24, 1993, pag. 345-354.
- [49] Darouach, M., Zasadzinski, M., Xu, S.J., Full-order observers for linear

systems with unknown inputs. IEEE Transactions on Automatic Control, vol. 39, 1994, pag. 606-609.

- [50] Donald, McL., Automatic Flight Control Systems. Prentice Hall Publisher, 1990.
- [51] Dorato, P., Abdallah, C.T., Cerone, V., *Linear Quadratic Control, An Introduction.* Malabar, FL: Krieger, 2000.
- [52] Duan, G.R., Solution to matrix equation AV+BW=VF and their application to eigenstructure assignment in linear systems. IEEE Transactions on Automatic Control, vol. 38, 1993, pag. 276-280.
- [53] Duan, G.R., Patton, R.J., Robust fault detection using Luenberger-type unknown input observers - a parametric approach. International Journal of Systems Science, vol. 32, nr. 4, 2001, pag. 533-540.
- [54] Duan, G.R., Patton, R.J., Robust fault detection in linear systems using Luenberger observers. Proceedings of International Conference on Control, Swansea, 1-4 Septembrie 1998, pag. 1468-1473.
- [55] Edwards, C., A comparison of sliding mode and unknown input observers for fault reconstruction. Proceedings of the 43<sup>th</sup> IEEE Conference on Decision and Control, 2004, pag. 5279- 5284.
- [56] Edwards, C., Spurgeon, S.K., *On the development of discontinuous observers*. International Journal of Control, nr. 59, 1994, pag. 1211-1229.
- [57] Edwards, C., Spurgeon, S.K., *Sliding mode observers for fault detection and isolation*. Automatica, vol. 36, nr. 6, 2000, pag. 541-553.
- [58] Edwards, C., Spurgeon, S.K., *Sliding Mode Control: Theory and Applications*. Taylor and Francis, 1998.
- [59] Edwards, C., Spurgeon, S.K., Patton, R.J., *Sliding mode observers for fault detection and isolation*. Automatica, nr. 36, 2000, pag. 541-553.
- [60] Etkin, B., Reid, L., *Vehicle Stability and Pitch*. 5<sup>th</sup> Conference on Mathematics and Computers, Australia, 14-16 June, 2000.
- [61] Fekih, A., Xu, H., Chowdhury, F.N., Neural networks based system identification techniques for model based fault detection of nonlinear systems. International Journal of Innovative Computing, Information and Control, vol.

3, nr. 5, 2007, pag. 1073-1085.

- [62] Fernando, T., Jennings, L., Trinh, H., Generality of Functional Observer Structures. Proceedings of the 50<sup>th</sup> IEEE Conference on Decision and Control, Orlando, USA, 2011, pag. 4000-4004.
- [63] Fernando, T., MacDougall, S., Sreeram, V., Trinh, H., *Existence conditions for unknown input functional observers*. International Journal of Control, vol. 86, nr. 1, 2013, pag. 22-28.
- [64] Floquet, T., Barbot, J.P., *An observability form for linear systems with unknown inputs.* International Journal of Control, vol. 79, 2006, pag. 132-139.
- [65] Frank, P.M., Fault diagnosis in dynamic systems using analytical and knowledge-based redundancy a survey and some new results. Automatica, vol. 26, 1994, pag. 955-981.
- [66] FRANKLIN, G.F., POWELL, J.D., WORKMAN, M.L., DIGITAL CONTROL OF DYNAMIC (3<sup>RD</sup> ED.). ADDISON WESLEY, 850 PAG., 2006.
- [67] Friedland, B., *Full-Order State Observers*. Physical Sciences, Engineering & Technology Resources-Sample Chapter (http://www.eolss.net/EolssSample Chapters).
- [68] Fu, M., De Souza, C., Luo, Z.Q., *Finite-horizon robust Kalman filter design*. IEEE Trans. Signal Process., vol. 49, 2001, pag. 2103-2112.
- [69] Fu, M.Y., Duan, G.R., Song, S.M., Design of Unknown Input Observer for Linear Time-Delay Systems. International Journal of Control, Automation, and Systems, vol. 2, nr. 4, 2004, pag. 530-535.
- [70] Funahashi, K., On the approximate realization of continuous mapping by neural networks. Neural networks, vol. 2, 1989, pag.183-192.
- [71] Garimella, P., Yao, B., Nonlinear adaptive robust observer design for a class of nonlinear systems. Proceedings of the 2003 American Control Conference, pag. 4391-4396.
- [72] Gasso, K., Mourot, G., Ragot, J., Structure identification in multiple model representation: elimination and merging of local models. IEEE Conference on Decision and Control, CDC'2001, Orlando, USA, 2001.

- [73] Gejic, Z., Introduction to Linear and Nonlinear Observers. Rutgers University.
- [74] Germani, A., Manes, C., Pepe, P., A new approach to state observation of nonlinear systems with delayed output. IEEE Transactions on Automatic Control, vol. 47, 2002.
- [75] Ghinea, M., Fireteanu, V., *Matlab-calcul numeric-grafica-aplicatii*. Editura Teora, 2001.
- [76] Godoy, M., Bose, K., Neural network based estimation of feedback signals for a vector controlled induction motor drive. IEEE Transaction on Industry applications, vol 31, 1995, pag. 620-629.
- [77] Golub, G., Numerical methods for solving least squares problems. Numerische Mathematik, vol. 7, 1965, pag. 206-216.
- [78] Gopinath, B., *On the control of linear multiple input-output systems*. Bell Syst. Tech. J., 1971.
- [79] Guan, Y., Saif, M., A Novel Approach to the Design of Unknown Input Observers. IEEE Transactions on Automatic Control, vol. 36, nr. 5, 1991, pag. 632-635.
- [80] Ha, Q.P., Trinh, H., State and input simultaneous estimation for a class of nonlinear systems. Automatica, vol. 40, 2004, pag. 1779-1785.
- [81] Hanlon, P.D., Maybeck, P.S., Multiple-Model Adaptive Estimation Using a Residual Correlation Kalman Filter Bank. IEEE Transactions on Aerospace and Electronic Systems, vol. 36, nr. 2, 2000, pag. 393-406.
- [82] Hautus, M.L., Strong detectability and observers. Linear Algebra & Applications, vol. 50, 1983, pag. 353-368.
- [83] Haddad, W.M., Chellaboina, V., Nonlinear Dynamical Systems and Control. Princeton, 2008.
- [84] Hornik, K., Stinchombe, M., White, H., *Multilayer feedforward networks are universal approximators*. Neural Networks, 1989, pag. 359-366.
- [85] Hou, M., Muller, P.C., Design of Observers for Linear Systems with Unknown Inputs. IEEE Transactions on Automatic Control, vol. 37, 1992, pag. 871-875.
- [86] Hou, M., Zitek, P., Patton, R.J., An Observer Design for Linear Time-Delay

Systems. IEEE Transactions on Automatic Control, vol. 47, 2002, pag. 121-125.

- [87] Hovakimyan, N., Calise, A.J., Madyastha, V.K., An adaptive observer design methodology for bounded nonlinear processes. Proceedings of 41<sup>st</sup> IEEE Conference on Decision & Control, vol. 4, 2002, pag. 4700-4705.
- [88] How, J., *Feedback control systems*. Course materials, 2007 (http://ocw.mit.edu).
- [89] Howell, A., Hedrick, J.K., *Nonlinear observer design via convex optimization*.Proceedings of the American Control Conference, 2002, pag. 2088-2093.
- [90] Huh, K., Stein, J.L., A quantitative performance index for observer-based monitoring systems. Trans. ASME, J. Dynam. Syst. Meas. Con., vol. 116, 1994, pag. 487-497.
- [91] Hui, S., Zak, S.H., Observer Design for Systems with Unknown Inputs. Int. J. Appl. Math. Comput. Sci., vol. 15, nr. 4, 2005, pag. 431-446.
- [92] HTTP://EN.WIKIPEDIA.ORG/WIKI/STATE\_OBSERVER.
- [93] Ioannou, P.A., Sun, J., Robust Adaptive Control, Prentice Hall, 1996.
- [94] IDAN, M., CALISE, A.J., KUTAY, A.T., ADAPTIVE NEURAL NETWORK BASED APPROACH FOR ACTIVE FLOW CONTROL. ASME FLUIDS ENGENEERING DIVISION SUMMER MEETING, NEW ORLEANS, LOUISIANA, MAY 29 – JUNE 3, 2001.
- [95] Jain, K., Artificial neural networks, a tutorial, IEEE, 31-44.
- [96] Jamel, W., Khedher, A., Bouguila, N., Othman, K., State Estimation via Observers with Unknown Inputs: Application to a Particular Class of Uncertain Takagi-Sugeno Systems. Studies in Informatics and Control, vol. 19, nr. 3, 2010, pag. 219-228.
- [97] Jazwinski, A., Stochastic Processes and Filtering Theory. Mathematics in Scince and Engineering. Academic Press, New York, vol. 64, 1970.
- [98] Jeong, C.S., Yaz, E.E., Bahakeem, A., Yaz, I., Nonlinear Observer Design with General Criteria. International Journal of Innovative Computing, Information and Control, vol. 2, nr. 4, 2006.
- [99] Jiang, B., Staroswiecki, M., Cocquempot, V., Fault accommodation for nonlinear dynamic systems. IEEE Transactions on Automatic Control, vol. 51, nr. 9,

September 2006, pag. 1578-1583.

- [100] Jiang, B., Wang, J.L., Soh, Y.C., An adaptive technique for robust diagnosis of faults with independent effects on system outputs. International Journal of Control, vol. 75, nr. 11, 2002, pag. 792-802.
- [101] Jing, W., Tan, Z., Ma, X., Gao, J., A Novel Adaptive Observer-Based Control Scheme for Synchronization and Suppression of a Class of Uncertain Chaotic Systems. Chinese Physics Letters, vol. 26, nr. 5, 2009.
- [102] Jo, N.H., Seo, J.H., Input output linearization approach to state observer design for nonlinear system. IEEE Transactions on Automatic Control, vol. 45, 2000, pag. 2388-2393.
- [103] Johansen, T.A., Foss, A.B., Constructing NARMAX using ARMAX Models. International Journal of Control, vol. 58, nr. 5, 1993, pag. 1125-1153.
- [104] Johansen, T., Foss, A., Nonlinear Local Model Representation for Adaptive Systems. International Conference on Intelligent Control and Instrumentation, Singapore, February 17-21, 1992.
- [105] Johansen, T.A., Rabuska, R., Multiobjective Identification of Takagi-Sugeno Fuzzy Models. IEEE Transactions on Fuzzy Systems, vol. 11, nr. 6, 2003, pag. 847-860.
- [106] Johnson, C.D., An observer for linear systems with unknown and inaccessible inputs. International Journal of Control, vol. 21, 1975, pag. 825-831.
- [107] Juloski, A.L., Mihajlovic, W.P., Heemels, M.H., Nijmeijer, H., Observer Design for Experimental Rotor with Discontinous Friction. Proceedings of the 2006 American Control Conference, Mineapolis, 2006.
- [108] Jung, J., Huh, K., Fathy, H., Stein, L., Optimal Robust Adaptive Observer Design for a Class of Nonlinear Systems via an H-Infinity Approach. Proceedings of the 2006 America Control Conference, Minnesota, June 14-16, 2006, pag. 3637-3642.
- [109] Jung, J., Huh, K., Lee, T.H., Observer design methodology for stochastic and deterministic robustness. International Journal of Control, vol. 81, nr. 7, pag. 1172-1182.

- [110] Kaczorek, T., Vectors and Mattrices in Control and Electrical Engineering, Warssaw, 1998.
- [111] Kalman, R.E., Bucy, R.S., New results in linear filtering and prediction theory. Trans. ASME Series D: J. Basic Eng., vol. 83, 1961, pag. 95-108.
- [112] Kalman, R.E., Falb, P.L., Arbib, M.A., *Teoria sistemelor dinamice*. Editura Tehnică, Bucureşti, 1975.
- [113] Kazantzis, N., Kravaris, C., *Nonlinear Observer Design using Lyapunov's Auxiliary Theore*. CDC, San Diego, 1997.
- [114] Keller, H., Nonlinear observer design by transformation into generalized observer canonical form. International Journal of Control, vol. 46, nr. 6, 1987, pag. 1915-1930.
- [115] Khalil, H.K., *Nonlinear Systems*. Upper Saddle River, NJ: Prentice Hall, Third edition, 2002.
- [116] Khedher, A., Benothman, K., Maquin, D., Benrejeb, M., State and unknown input estimation via a proportional integral observer. 9<sup>th</sup> International Conference on Sciences and Techniques of Automatic Control and Computer Engineering (STA'2008), Sousse, Tunisia, 2008.
- [117] Khedher, A., Benothman, K., Maquin, D., Benrejeb, M., Adaptive observer for fault estimation in nonlinear systems described by a Takagi-Sugeno model. Mediterranean Conference on Control & Automation, 2010, pag. 261-266.
- [118] Kim, B.S., Calise, A.J., Nonlinear Flight Control Using Neural Networks. Proceedings of the AIAA Guidance, Navigation and Control Conference, Scottsdale, AZ, pag. 930-940, 1994.
- [119] Kim, Y.M., Lewis, F., Abdallah, C.T., A dynamic recurrent neural network based adaptive observer for a class of nonlinear systems. Automatica, vol 33, 1997, 1539-1543.
- [120] Kiriakidis, K., O'Brien, J.R., *H-infinity parameter estimation for state-space models*. Proceedings of the 2004 American Control Conference, pag. 2836-2839.
- [121] Koenig, D., Mammar, S., Design of the class of reduced order unknown inputs

nonlinear observer for fault diagnosis. American Control Conference, ACC' 2001, Arlington, USA, June 2001.

- [122] Krantz, S., Parks, H., *The Implicit Function Theorem: History, Theory, and Applications*. Boston, MA: BirkhÄauser, 2008.
- [123] Kreisselmeier, G., *Adaptive observers with exponential rate of convergence*. IIEEE Transaction on automatic Control, vol. 22, nr. 1, 1977, pag. 2-8.
- [124] Krener A., Isidori, A., Linearization by Output Injection and Nonlinear Observers. Systems and Control Letters, nr. 3, 1983, pag. 47-52.
- [125] Krener, J., Respondek, W., Nonlinear observer design with linearizable error dynamics. SIAM Journal on Control and Optimization, vol. 23, nr. 2, 1985, pag. 197-216.
- [126] Krener, A.J., Xiao, M.Q., Observers for linearly unobservable nonlinear systems. Int. Journal of control, vol. 74, 2001, pag. 1559-1567.
- [127] Krzeminsky, S., Kaczorec, T., Perfect Reduced Order Unknown Input Observer for Standard Systems. Buletin of the Polish Academy of Sciences Technical Sciences, vol. 52, nr. 2, 2004, pag. 103-107.
- [128] KRZEMINSKI, S., KACZOREC, T., PERFECT REDUCED ORDER UNKNOWN – INPUT OBSERVER FOR DESCRIPTOR SYSTEMS. 7<sup>TH</sup> INTERNATIONAL MULTICONFERENCE ON INFORMATICS, SYSEMICS AND CYBERNETICS, ORLANDO, 2003.
- [129] Kudva, P. Viswandam, N., Ramakrishna, A., Observers for linear systems with unknown inputs. IEEE Transactions on Automatic Control, vol. AC-25, 1980, pag. 113-115.
- [130] Kulcsar, B., LQR/LTR Controller Design for An Aircraft Model. Periodica Politechnica Ser. Transp. Eng., vol. 28, nr. 1-3, 2000, pag. 131-142.
- [131] Lakhal, A.N., Tlili, A.S., Benhadj, B., Neural Network Observer for Nonlinear Systems Application to Induction Motors. International Journal of control and Automation, vol. 3, nr. 1, March 2010.
- [132] Lavretky, E., Hovakimyan, N., Calise, A.J., *Reconstruction of Continous-Time* Dynamics Using Delayed Output and Feedforward Neural Networks. IEEE

Transactions on Automatic Control, sept. 2003.

- [133] Lee, S.H., Hong, J., See, J.H., Observers for bilinear systems with unknown inputs and application to superheater temperature control. Control Engineering Practice, vol. 5, nr. 4, 1997, pag. 493-506.
- [134] Lewis, F., Liu, K., Yesildirek, A., Neural net robot controller with guaranteed tracking performance. IEEE Transaction on Neural Network, vol. 6., 1995, pag. 703-715.
- [135] Leyva-Ramos, J., Pearson, A.E., An asymptotic model observer for linear autonomous time lag systems. IEEE Transactions on Automatic Control, vol. 40, nr. 7, 1995, pag. 1291-1294.
- [136] Lin, S.F., Wang, A.P., Unknown Input Observers Designed by Eigenstructure Assignment. Systems Analysis Modelling Simulation, vol. 42, nr. 3, 2002, pag. 415-428.
- [137] Luders, G., Narendra, K., *An adaptive observer and identifier for a linear system*. IEEE Transaction on automatic Control, vol. 18, 1973, pag. 496-499.
- [138] Luenberger, D., An introduction to observers. IEEE Transactions on Automatic Control, vol. AC-16, 1971, pag. 596-603.
- [139] Luenberger, D., Nonlinear descriptor systems. Journal of Economics Dynamics and Control, vol. 1, 1979, pag. 219–242.
- [140] Lungu, M., Sisteme de conducere a zborului. Editura Sitech, Craiova, 2008.
- [141] Lungu, M., Algoritmi si structuri pentru identificarea, estimarea si conducerea zborului aeronavelor si rachetelor. Editura Sitech, Craiova, 2013.
- [142] Lungu, M., Lungu, R., Full-Order Observer Design for Linear Systems with Unknown Inputs. International Journal of Control, vol. 85, nr. 10, 2012, pag. 1602-1615.
- [143] Lungu, R., *Echipamente şi sisteme giroscopice*. Editura Universitaria, Craiova, 1997.
- [144] Lungu, R., *Automatizarea aparatelor de zbor*. Editura Universitaria, Craiova, 2000.
- [145] Lungu, R., Sisteme de dirijare aerospațială. Editura Sitech, Craiova, 2002.

- [146] Lungu, R., Corcău, J., Lungu, M. Gyroscopic Stabilization System with Kalman-Bucy State Estimator. XIII-th International Sysposium on Electrical Apparatus and Tehnologies, 29-30 May 2003, Plovdiv, Bulgaria, pag. 129-134.
- [147] Lungu, R., Grigorie, L., *Traductoare accelerometrice şi girometrice*. Editura Sitech, Craiova, 2005.
- [148] LUNGU, R., LUNGU, M., OPTIMAL CONTROL OF THE ROCKET'S LATERAL DEVIATION IN RAPPORT WITH EQUAL SIGNAL LINE. A
  6-A CONFERINȚĂ INTERNAȚIONALĂ DE SISTEME ELECTROMECANICE ȘI ENERGETICE, SIELMEN, 2007, CHIŞINAU, REPUBLICA MOLDOVA.
- [149] Lyshevski, S.E., Nonlinear Identification of Control Systems. Proceedings of the American Control Conference, Philadelphia, PA, 1998, pag. 2366-2370.
- [150] Maciejowski, J.M., Multivariable Feedback Design. Addison-Wesley, 1989.
- [151] Maeda, H., Hino, H., *Design of optimal observers for linear time-invariant systems*. Int. J. Control, vol. 19, nr. 5, 1975, pag. 993-1004.
- [152] Maquin, D., Gaddouna, B., Ragot, J., *Estimation of unknown inputs in linear systems*. American Control Conference, vol. 1, 1994, pag. 1195-1197.
- [153] Marino, R., Adaptive observers for single output nonlinear systems. IEEE Transactions on Automatic Control, vol. 35, 1990, pag. 1054-1058.
- [154] Marino, R., Santosuosso, G.L., Tomei, P., Robust adaptive observers for nonlinear systems with bounded disturbances. IEEE Transaction on Automatic Control, vol. 46, nr. 6, 2001, pag. 967-972.
- [155] Marino, R., Tomei, P., Adaptive observers with arbitrary exponential rate of convergence for nonlinear systems. IEEE Transactions on Automatic Control, vol. 40, nr. 7, 1995, pag. 1300-1304.
- [156] Marino, R., Tomei, P., Global adaptive observers for nonlinear systems via filtered transformations. IEEE Transactions on Automatic Control, vol. 37, nr. 8, 1992, pag. 1239-1245.
- [157] Marx, B., Koenig, D., Ragot, J., Design of observers for Takagi-Sugeno descriptor systems with unknown inputs and application to fault diagnosis.

IET Control Theory and Applications, vol. 5, 2007, pag. 1487-1495.

- [158] Meditch, J.S., Hostetter, G.H., *Observers for systems with unknown and inaccessible inputs*. International Journal of Control, vol. 19, 1974, pag. 473-480.
- [159] Meyer, C.D., Matrix analysis and applied linear algebra: solutions manual, SIAM, vol. 2, 2000.
- [160] Michael, T., Harley, R., Identification and control of induction machines using artificial neural networks. IEEE Transaction on Industry Applications, vol 31, 1995, pag. 612-619.
- [161] Monahemi, M., Barlow, J., O'Leary, D., Design of Reduced-Order Observers with Precise Loop Transfer Recovery. Journal of Guidance, Control, and Dynamics, vol. 15, nr. 6, 1992.
- [162] Morel, Y., Applied Nonlinear Control of Unmanned Vehicles with Uncertain Dynamics. Dissertation submitted to the Faculty of the Virginia Polytechnic Institute and State, 2009, Blacksburg, Virginia.
- [163] Muramatsu, E., Ikeda, M., Estimation of Parameters in State Equations via Multiple Observers. 39<sup>th</sup> IEEE Conference on Decision and Control, December 2000, pag. 197-202.
- [164] Murray-Smith, R., Johansen, T., Multiple model approaches to modeling and control. Editura Taylor and Francis, London, 1997.
- [165] Nakade, P., Galgate, G.G., Design of Linear Functional Observer for MIMO LTI Systems. International Journal of Computer Applications, vol. 1, nr. 6, 2010.
- [166] Narendra, K., Parthasarathy, K., Identification and control of dynamic system using neural networks. IEEE Transaction on Neural Network, vol. 1, 1990, pag. 4-27.
- [167] Nikoukhah, R., Campbell, S., Delebecque, F., Kalman filtering for general discrete-time systems. IEEE Transactions on Automatic Control, vol. 34, nr. 10, 1999, pag. 1829-1839.
- [168] Nikoukhah, R., Willsky, A., Levy, B., Kalman filtering and Riccati equations for descriptor systems. IEEE Transactions on Automatic Control, vol. 37, nr. 9, pag. 1325-1342.

- [169] Oară, C., *Teoria sistemelor automate*. Suport de curs, Universitatea Politehnica Bucureşti, 2005.
- [170] Oliveira, P., Nonlinear Observers with Linearizable Error Dynamics. Journal Automatica (Journal IFAC), vol. 43, nr. 8, August, 2007.
- [171] Olivera, J., Guan, X., Manry, M., *Theory of monomial networks*. Proceedings of Implicit and Nonlinear Systems, 1992, pag. 96-101.
- [172] O'Reilly, J., Observers for Linear Systems. New York: Academic, 1983.
- [173] Orjuela, R., Marx, B., Ragot, J., Maquin, D., Proportional-Integral observer design for nonlinear uncertain systems modelled by a multiple model approach. 47<sup>th</sup> IEEE Conference on Decision and Control, Mexic, 2008.
- [174] Park, J., Sandberg, I.W., Universal approximation using radial-basis function networks. Neural Comp., vol. 3, 1991, pag. 246-257.
- [175] Patton, R.J., Chen, J., *Observer-based fault detection and isolation: robustness and applications*. Contr. Eng. Practice, vol. 5, nr. 5, 1997, pag. 671-682.
- [176] Patton, R.J., Chen, C., Lopez-Toribio, J., *Fuzzy observer for nonlinear dynamic systems*. IEEE Conference on Decision and Control, Florida, 1998.
- [177] Patton, R.J., Chen, J., Zhang, H., Modelling methods for improving robustness in fault diagnosis of jet engine system. Proceedings of the 31<sup>th</sup> IEEE Conference on Decision and Control, Arizona: Tucson, 1992, pag. 2330-2335.
- [178] Patton, R.J., Frank, P.M., Clark, R.N., Fault Diagnosis in Dynamic Systems, Theory and Applications. Prentice-Hall Publisher, Englewood CliOEs, New Jersey, 1989.
- [179] Paw, Y.C., Synthesis and Validation of Flight Control for UAV. Dissertation submitted to the Faculty of the Graduate School of the University of Minnesota, Decembrie, 2009.
- [180] Pearson, A.E., Fiagbedzi, Y.A., *An observer for time lag systems*. IEEE Transactions on Automatic Control, vol. 34, nr. 4, 1989, pag. 775-777.
- [181] Pertew, A.M., Marquez, H.J., Zhao, Q.,  $H_{\infty}$  synthesis of unknown input observers for non-linear Lipschitz systems. International Journal of Control, vol. 78, nr.15, 2005, pag. 1155-1165.

- [182] Petersen, I.R., Mcfarlane, D.C., Optimal guaranteed cost control and filtering for uncertain linear systems. IEEE Transactions on Automatic Control, vol. 39, 1994, pag. 1971-1977.
- [183] PHILIPS, C., NAGLE, H.T., *DIGITAL CONTROL SYSTEM ANALYSIS AND DESIGN.* PRENTICE HALL, 1995.
- [184] Plimbs, J., Survey of Nonlinear Observer design Techniques, 1 Iunie 1996.
- [185] Rachik, M., Laarabi, H., El Kahlaoui, O., Saadi, S., Observer for Perturbed Linear Continuous Systems. Applied Mathematical Sciences, vol. 4, nr. 14, 2010, pag. 681-689.
- [186] Rajamani, R., Observers for Lipschitz nonlinear systems. IEEE Transactions on Automatic Control, AC-43, 1998, pag. 397-401.
- [187] Rajamani R., Hedrick, J.K., Adaptive observers for active automotive suspensions: Theory and experiment. IEEE Transactions on Control Systems Technology, vol. 3, nr. 1, 1995, pag. 86-93.
- [188] Selmic, R., Lewis, L., Multimodel neural networks identification and failure detection of nonlinear systems. Proceeding of the 40th IEEE Conference on Decision and Control, Florida, USA, 2001, pag. 3128-3133.
- [189] Sename, O., Unknown input robust observer for time delay system. Proceedings of the 36<sup>th</sup> IEEE Conference on Decision and Control, 1997, pag. 1629-1630.
- [190] Seong-Hwan, K., Tae-Sik, P., Ji-Yoon, Y., Gwi-Tae, P., Speed sensorless vector control of an introduction motor using neural network speed estimation. IEEE Transaction on Industrial Electronics, vol 48, 2001, pag. 609-614.
- [191] Shafai, B., Carrol, R.L., Design of proportional-integral observer for linear time-varying multivariable systems. Proceedings of the IEEE Conference on Decision and Control, vol. 24, 1985, pag. 597-599.
- [192] Shaked, U., Xie, L., Soh, Y.C., New approaches to robust minimum variance filter design. IEEE Trans. Signal Process., vol. 49, 2001, pag. 2620-2629.
- [193] Shankar, P., Yedavalli, R.K., A neural network based adaptive observer for turbine engine parameter estimation. Proceedings of GT2006, ASME Turbo Expo 2006: Power for Land, Sea and Air, May 8-11, Barcelona, 2006.

- [194] Sharma, R., Aldeen, M., *Estimation of unknown disturbances in nonlinear systems*. Control 2004, University of Bath, UK, 2004.
- [195] Singh, D., Pandey, J., Chauhan, D., Radial basis neural network state estimation of electric power networks. IEEE International Conference on Electric Utility Deregulation, Restructuring and Power Technologies, pag. 90-95.
- [196] Sîngeorzan, D., Regulatoare adaptive. Editura Militară, București, 1992.
- [197] Snijders, J.G., *Wave Filtering and Thruster Allocation for Dynamic Positioned Ships.* Master's Thesis, 2005.
- [198] Spurgeon, S.K., *Pole placement extensions for multivariable systemsa survey*. American Control Conference, vol. 27, 1990, pag. 1660-1665.
- [199] Stefani, R.T., *Reducing the sensitivity to parameter variations of a minimumorder reduced-order observer*. Int. J. Cont., vol. 35, 1982, pag. 983-995.
- [200] Takagi, T., Sugeno, M., Fuzzy Identification of Systems and its Application to Modelling and Control. IEEE Transaction Systems, Man and Cybernetics, vol. 15, nr. 1, 1985, pag. 116–132.
- [201] Tan, C., Crusca, F., Aldeen, M., Extended results on robust state estimation and fault detection. Automatica, nr. 44, 2008, pag. 2027-2033.
- [202] Tan, C., Edwards, C., An LMI approach for designing mode observers for full detection and isolation. European Control Conference (ECC 2001), Portugalia, 2001, pag. 481-486.
- [203] Tan, C., Edwards, C., An LMI approach for designing sliding mode observers. International Journal of Control, vol. 74, nr. 16, 2001, pag. 1559-1568.
- [204] Tan, C., Edwards, C., Sliding mode observers for robust detection and reconstruction of actuator and sensor faults. International Journal of Robust and Nonlinear Control, nr. 13, 2003, pag. 443-463.
- [205] Tanaka, K., Ikeda, T., Wnag, O., Fuzzy regulator and fuzzy observer: relaxed stability conditions and LMI based design. IEEE Trans on Fuzzy Systems, vol. 6, nr. 2, 1998, pag. 250-256.
- [206] Teel, A., Praly, L., *Global stabilization and observability imply semi-global stabilizability by output feedback.* Systems Control Letters, vol. 22, 1994, pag.
313-325.

- [207] Thau, F.E., Observing the State of Nonlinear Dynamic Systems. International Journal of Control, vol. 17, 1973, pag. 471-479.
- [208] Theocharis, J., Petridis, V., Neural network observer for induction motor control. IEEE Control Systems, 1994.
- [209] Tlili, A.S., Braiek, N.B., On the multimodel approaches for state observation of induction motors. Transaction on Systems, Signals and Devices, vol. 1, nr. 2, 2006, pag. 141-155.
- [210] Trinh, H., Ha, Q., Design of linear functional observers for linear systems with unknown inputs. International Journal of Systems Science, vol. 31, nr. 6, 2000, pag. 741-749.
- [211] Utkin, V.I., Sliding Modes in Control Optimization. Springer-Verlag, 1992.
- [212] Utkin, V.I., Principles of identification using sliding regimes. Soviet Physic: Doklady, Sliding mode in control optimisation. Berlin: Springer-Verlag, vol. 26, 1992, pag. 271-272.
- [213] Vargas, J., Hemerly, E.M., Nonlinear adaptive observer design for uncertain dynamical systems. Proceedings of the 39<sup>th</sup> IEEE Conference on Decision and Control, 2000, pag. 1307-1308.
- [214] Vargas. J., Hemerly, E., Robust neural adaptive observer for MIMO nonlinear systems. Proceedings of the IEEE International Conference on Systems, Man and Cybernetics, 1999.
- [215] Vasile, I., Automatica.http://facultate.regielive.ro/cursuri/automatica/estimatoare.
- [216] Walcott, B.L., Zak, S.H., State observation of nonlinear uncertain dynamical systems. IEEE Transactions on Automatic Control, vol. 32, 1987, pag. 166-170.
- [217] Walcott, B.L., Zak, S.H., Observation of dynamical systems in the presence of bounded nonlinearities/uncertainties. CDC'1988, pag. 961-966.
- [218] Wang, H., Daley, S., *Actuator fault diagnosis: An adaptive observer-based technique*. IEEE Trans. on Automatic Control, vol. 41, 1996, pag. 1073-1078.
- [219] Wang, Z.D., James, L., Burnham, K.J., Stability Analysis and Observer Design for Neutral Delay Systems. IEEE Transactions on Automatic Control, vol. 47,

nr. 3, 2002, pag. 478-482.

- [220] Wang, Y., Zhang, Q.L., Liu, W.Q., Stability Analysis and Design for T-S Fuzzy Descriptor Systems. Proceedings of the IEEE Conference on Decision and Control, USA, 2001, pag. 3962-3967.
- [221] Wilkinson, J.H., *The Algebraic eigenvalue Problem*. Oxford University Press, 1965.
- [222] Xiao, X.H., Gao, W., Nonlinear observer design by observer error linearization. SIAM Journal on Control and Optimization, vol. 27, 1989, pag. 199-216.
- [223] Xie, L., Soh, Y.C., Robust Kalman filtering for uncertain systems. Syst. Cont. Letts., vol. 22, 1994, pag. 123-129.
- [224] Xu, A., Zhang, Q., Residual generation for fault diagnosis in linear timevarying systems. IEEE Transactions on Automatic Control, vol. 49, nr. 5, 2004, pag. 767-772.
- [225] Xu, J.X., Jia, Q.W., Lee, T.H., On the design of a nonlinear adaptive variable structure derivative estimator. IEEE Trans. on Automatic Control, vol. 45, nr. 5, 2000, pag. 1028-1033.
- [226] Xu, S., Lam, J., Reduced-orde  $H_{\infty}$  filtering for singular systems. Systems & Control Letters, vol. 56, 2007, pag. 48-57.
- [227] Xu, S., Lam, J., Zou, Y., H<sub>∞</sub> filtering for singular systems. IEEE Transactions on Automatic Control, vol. 48, nr. 12, 2003, pag. 2217-2222.
- [228] Yang, F., Wilde, R.W., *Observers for linear systems with unknown inputs*. IEEE Transactions on Automatic Control, vol. AC-33, 1988, pag. 677-681.
- [229] Yao, Y.X., Zhang, Y.M., Parameterization of observers for time delay systems and its application in observer design. IEEE Processing Control Theory Applications, vol. 143, nr. 3, 1996, pag. 225-232.
- [230] Yoneyama, J., Ichikawa, I., *H-inf Control for Takagi-Sugeno Fuzzy Descriptor Systems*. Proceedings of the IEEE Int. Conf. Syst. Man Cybern., Tokyo, Japonia, 1999, pag. 28-33.
- [231] Yuan, Y., Yu, P., Librescu, L., Marzocca, P., Aeroelasticity of Time-Delayed Feedback Control of Two-Dimensional Supersonic Lifting Surfaces. Journal of

Guidance, Control and Dynamics. vol. 27, nr. 5, 2004, pag. 795-804.

- [232] Zeitz, M., The extended Luenberger observer for nonlinear systems. Systems and Control Letters, vol. 9, 1987, pag. 149-56.
- [233] Zhang, K., Jiang, B., Cocquempot, V., Adaptive Observer-based Fast Fault Estimation. International Journal of Control, Automation, and Systems, vol. 6, nr. 3, 2008, pag. 320-326.
- [234] Zhang, Q., Adaptive observer for MIMO linear time varying systems. Raport de cercetare, Proiect: Sigma2, Institut National de Recherche en Informatique et en Automatique, 2001.
- [235] Zhang, Q., Delyon, B., A new approach to adaptive observer design for MIMO systems. ACC'2001, Arlington.
- [236] Zhu, F., Han, Z., *A note on observers for Lipschitz nonlinear systems*. IEEE Transactions on Automatic Control, vol. 47, 2002, pag. 1751-1754.