

IMPLEMENTAREA ÎN MATLAB – SIMULINK A UNOR STRATEGII TIPICE DE IDENTIFICARE BAZATE PE MODELE NEURALE

1. Considerații generale, motivație și obiectiv

Identificarea sistemelor dinamice bazată pe modele neurale s-a conturat ca direcție de cercetare la începutul anilor '90, drept urmare a investigațiilor matematice asupra proprietăților de aproximare ale rețelelor neuronale. Evoluția noului domeniu a fost impulsionată de contribuțiile remarcabile ale unor nume de prestigiu în Automatică, ca, de exemplu, K. Narendra, K. Parthasarathy, P.J. Gawthorp, T.J. McAvoy, L. Ljung. Totuși, firmele producătoare de software tehnico-științific au demarat dezvoltarea de facilități specifice rețelelor neuronale, astfel încât apariția în 1992 a primei versiuni a *Neural Network Toolbox* încorporată în mediul MATLAB 4.2 a avut un impact major asupra interesului acordat de către automatiști acestei direcții de cercetare.

2. Cunoștințe prealabile necesare

- Capitolul "Aplicații ale rețelelor feedforward multistrat în identificarea și controlul sistemelor dinamice" din cursul "Aplicații ale rețelelor neuronale în automatică".
- Experiență de programare în MATLAB-Simulink.

3. Breviar teoretic

3.1. Identificarea sistemelor dinamice utilizând rețele neurale

Modelele generale de identificare parametrică a sistemelor dinamice (liniare sau neliniare) se pot implementa, atât hard cât și soft, cu ajutorul rețelelor neuronale artificiale. Parametrii modelului neural sunt reprezentați de ponderile sinaptice ale neuronilor și deplasările acestora. Teoria generală privind identificarea sistemelor se poate aplica direct pentru obținerea modelului neural ținând cont de echivalențele:

- *structura modelului = arhitectura rețelei neurale*
- *estimare = antrenare*
- *validare = generalizare*
- *set de date de estimare = set de date de antrenare*
- *set de date de validare = set de date de generalizare*

Structura modelelor neurale

Considerăm un sistem dinamic cu o intrare și o ieșire (figura 6.1.1) pentru care se măsoară semnalele de intrare u și de ieșire y la momentele discrete de timp $t_k = kt$ (unde T reprezintă perioada de eșantionare a semnalelor, $k \in N$), notând $u[k] = u(kT)$, $y[k] = y(kT)$, $k = \overline{1, N}$.




Figura 1. Sistem dinamic SISO

În problema identificării sistemelor dinamice, unde neliniaritatea care trebuie modelată depinde de timp, problema care se pune este cea a reprezentării explicite a timpului în structura rețelei neurale. Pentru ca o rețea neurală să fie dinamică, ea trebuie să posede o memorie. Ideea de la care s-a pornit la începutul anilor 1990 a fost cea de a se utiliza rețele neurale statice împreună cu un

sistem extern de întârziere a semnalelor de intrare în rețea, obținând așa numitele *rețele neurale cu dinamică externă*.

Un interes practic deosebit îl prezintă obținerea modelelor neurale de tip ARX (NNARX) în timp discret, cu perioadă de eșantionare dată:

$$\hat{y}[k] = f(y[k-1], y[k-2], \dots, y[k-n], u[k-d], u[k-d-1], \dots, u[k-d-m]) \quad (1)$$

unde $d, n \in N^*, m \in N$ și

$$f: R^{n+m+1} \rightarrow R \quad (2)$$

este o aplicație (liniară sau neliniară, netedă) ce descrie transferul intrare-ieșire al unei rețele neurale statice cu topologie adecvată. Această funcție poate fi reprezentată cu ajutorul unei rețele neurale statice cu propagare înainte a semnalului cu funcții de activare liniare (ADALINE) sau neliniare (MLP). Rețeaua are ca intrări valorile de la momentele anterioare de timp ale intrării și ieșirii procesului. Valorile semnalelor de intrare și de ieșire la momentele anterioare de timp formează vectorul *regresorilor* care este notat:

$$\phi[k] = [y[k-1], y[k-2], \dots, y[k-n], u[k-d], u[k-d-1], \dots, u[k-d-m]]^T \quad (3)$$

și se obține utilizând un sistem de întârziere (*Tapped Delay Line*) plasat în afara rețelei neurale propriu-zise.

Configurația prezentată în formula xx este cunoscută și sub denumirea de *modelul serie-paralel* (SPM) deoarece în raport cu intrarea rețeaua neurală este conectată paralel cu procesul, iar în raport cu ieșirea conectarea este în serie. Eroarea de predicție, diferența dintre ieșirea reală a procesului și ieșirea estimată cu ajutorul rețelei neurale, este utilizată pentru antrenarea rețelei aplicând algoritmi de antrenare uzuali, independenți de timp. În această figură, z^{-1} reprezintă operatorul de întârziere cu un pas, $z^{-1}u[k] = u[k-1]$, iar ZOH notează extrapolatorul de ordin zero (*Zero Order Hold*) utilizat pentru discretizarea, cu perioada de eșantionare dorită, a unui proces continuu.




Figura 2. Modelul neural de tip ARX(NNARX) – modelul serie-paralel

După antrenarea rețelei neurale, modelul identificat poate fi folosit independent de proces, aducând la intrarea rețelei ieșirea acesteia, printr-o conexiune inversă externă. O astfel de configurație poartă numele de *modelul paralel* și este utilizată pentru simularea proceselor dinamice. Configurația poate fi utilizată și în faza de antrenare a rețelei neurale, modelul obținut în acest fel fiind de fapt modelul neural de tip *output error* (NNOE) (figura 3)

$$\hat{y}[k] = f(\hat{y}[k-1], \hat{y}[k-2], \dots, \hat{y}[k-n], u[k-d], u[k-d-1], \dots, u[k-d-m]) \quad (4)$$




Figura 3. Modelul neural OE (NNOE) – modelul paralel

În mod asemănător se pot obține și modelele neurale de tip ARMAX (NNARMAX) sau Box-Jenkins (NNBJ). Dezavantajele modelelor recursive de tip NNOE, NNARMAX sau NNBJ sunt posibila instabilitate a modelului și necesitatea unui efort suplimentar pentru a calcula gradientul ce intervine în procedura iterativă de antrenare a rețelei.

Pentru reprezentarea modelelor neliniare de tip NNARX cu o singură intrare și o singură ieșire Narendra și Parthasarathy (1990) au introdus patru modele. Modelele propuse de ei sunt descrise de ecuațiile:

Modelul 1:	$\hat{y}[k+1] = \sum_{i=0}^{n-1} \alpha_i \cdot y[k-i] + g(u[k], u[k-1], \dots, u[k-m+1])$	(5)
Modelul 2:	$\hat{y}[k+1] = f(y[k], y[k-1], \dots, y[k-n+1]) + \sum_{i=0}^{m-1} \beta_i \cdot u[k-i]$	(6)
Modelul 3:	$\hat{y}[k+1] = f(y[k], y[k-1], \dots, y[k-n+1]) + g(u[k], u[k-1], \dots, u[k-m+1])$	(7)
Modelul 4:	$\hat{y}[k+1] = f(y[k], y[k-1], \dots, y[k-n+1], u[k], u[k-1], \dots, u[k-m+1])$	(8)

Se presupune că funcțiile f și g sunt diferențiabile în raport cu toate argumentele lor. Aceste funcții pot fi approximate cu ajutorul unor rețele neurale statice. Alegerea modelului adecvat depinde de informația despre procesul considerat disponibilă a priori. În modelele 1 (figura 4) și 2 (figura 5) se presupune că neliniaritatea procesului implică numai intrarea, respectiv numai ieșirea.




Figura 4. Reprezentarea modelului 1




Figura 5. Reprezentarea modelului 2.

Modelul 3 (figura 6) rezultă ca suma a două funcții neliniare distincte care depind numai de semnalul de intrare, respectiv ieșire. Modelul 4 (figura 7), cel mai general, reprezintă proiecția neliniară atât a intrărilor cât și a ieșirilor procesului de identificat.

Modelele de tip NNARX pot fi utilizate pentru probleme simple, dar utilizarea lor nu este avantajoasă pentru probleme ce implică dependența semnalului de ieșire al sistemului de un număr mare de valori trecute ale semnalului de intrare. Pentru modelarea unor asemenea sisteme se recomandă utilizarea modelelor recursive.




Figura 6. Reprezentarea modelului 3




Figura 7. Reprezentarea modelului 4

O altă posibilitate de modelare a unui sistem dinamic neliniar revine la a construi în prima etapă un model liniar al sistemului. Reziduurile obținute ca diferență între ieșirile actuale ale sistemului și ieșirile estimate pe baza modelului liniar vor conține evident neliniaritățile nemodelate. Pentru a modela aceste neliniarități se construiește apoi un model neural având ca intrări intrările sistemului și reziduurile.

Estimarea modelelor neurale

Aplicația f din relația (2) este parametrizată de ponderile și deplasările rețelei. Indiferent de topologia rețelei, identificarea pe baza așa-numitei scheme serie-paralel (figura 2) asigură stabilitatea algoritmului iterativ de minimizare a funcțiilor obiectiv definite cu ajutorul erorii

$$e[k] = y[k] - \hat{y}[k-1] \quad (9)$$

Formularea concretă a funcțiilor obiectiv este corelată cu modul de obținere și exploatare a datelor experimentale corespunzătoare procesului. În acest sens, literatura evidențiază două categorii de metode de antrenare a rețelei neuronale din schema serie-paralel:

- pe lot (*batch*) sau *off-line*, care utilizează funcții obiectiv de forma (până la o constantă multiplicativă):

$$J = \frac{1}{N} \cdot \sum_{k=1}^N e^2[k] \leq \varepsilon \quad (10)$$

unde N notează numărul total de elemente disponibile în lot și ε este valoarea de prag dorită;

- pe eșantioane (*pattern*) sau *on-line*, care utilizează funcții obiectiv de forma (până la o constantă multiplicativă):

$$J(i) = \frac{1}{N_E} \cdot \sum_{k=i}^{i+N_E-1} e^2[k] \leq \varepsilon, i \in N \quad (11)$$

unde NE notează numărul de eșantioane conținute în fereastra mobilă de selectare a elementelor, i este indicele iterației curente și ε este valoarea de prag dorită.

Minimizarea operează în spațiul parametrilor rețelei (ponderi și deplasări) și poate fi condusă prin tehnicile clasice de optimizare fără restricții, adaptate la specificul organizării matriceal-vectoriale a parametrilor aplicației f . În limbajul propriu rețelelor neuronale, determinarea parametrilor funcției f ca rezultat al minimizării funcțiilor obiectiv (5.6) sau (5.7) (estimarea modelului parametric) este referită drept proces de antrenare sau învățare.

Observație:

Determinarea modelului neural urmează pașii prezentați în capitolul 2: alegerea regresorilor modelului, a tipului neuronilor din structura rețelei neurale, alegerea numărului de neuroni din stratul intern și apoi determinarea ponderilor rețelei (adică determinarea parametrilor modelului). Principiul care se aplică este de a porni de la simplu la complex (lama lui Occam): se încearcă întâi cu un număr redus de regresori și de neuroni în stratul de intrare și apoi se crește progresiv numărul neuronilor până la un număr rezonabil. Dacă nu se determină un model suficient de bun se crește numărul regresorilor și se încearcă, din nou, valori crescute progresiv ale numărului de neuroni. Dacă nici în acest caz nu se determină un model corespunzător, se alege un alt tip de model pentru sistemul respectiv.

3.2. Controlul predictiv al sistemelor dinamice neliniare utilizând modele neurale

Principiul de bază al algoritmilor de control predictiv constă în prezicerea ieșirii procesului, pe baza unui model (obținerea predictorilor), și pe minimizarea unei anumite funcții de cost. Diferențele dintre diverșii algoritmi sunt date de modelul folosit de controller și de forma funcției de cost. În cazul sistemelor liniare, majoritatea modelelor dinamice utilizate în controlul predictiv se obțin prin teste aplicate proceselor sau prin metode de identificare. Pentru controlul predictiv neliniar testarea și identificarea proceselor devin mult mai dificile. Datorită proprietății rețelelor neurale de a fi aproximatori generali, utilizarea unui model neuronal pentru obținerea predictorilor prezintă un foarte mare interes.

O reprezentare grafică a strategiei de control predictiv este prezentată în figura 8. La fiecare moment de eșantionare k se determină strategia optimă de control, fiind calculate valorile viitoare ale intrării $u[k + 1], u[k + 2], \dots, u[k + N_u]$ (N_u – orizontul de control), astfel încât ieșirea procesului y să urmărească cu eroare cât mai mică referința r pe intervalul de predicție (N_1 – orizontul minim de predicție, N_2 – orizontul de predicție).




Figura 8. Strategia controlului predictive bazat pe model

Valorile viitoare ale ieșirii procesului sunt determinate folosind un model neural, iar pe baza erorilor între ieșirile prezise și referință este calculată o funcție de cost. Această funcție de cost urmează a fi minimizată cu scopul obținerii unei strategii de control optime ce vor fi aplicate procesului. Una din formele posibile ale funcției de cost, folosită în majoritatea algoritmilor de control predictiv, este dată de relația:

$$J = \sum_{i=N_1}^{N_2} (r[k+i] - y[k+i])^2 + \lambda \cdot \sum_{i=1}^{N_u} (u[k+i] - u[k+i-1])^2 \quad (12)$$

De multe ori, în practică, ponderea λ asupra comenzii are valoarea 0, iar orizontul minim de predicție (N_1) ia valoarea 1.

Funcția de cost J urmează a fi minimizată la orice moment de timp k în funcție de vectorul $= [u[k+1], u[k+2], \dots, u[k+N_u]]^T$, ce conține valorile viitoare ale intrării.

Modelul neural folosit în calculul ieșirilor viitoare ale procesului este un model de tip ARX de forma prezentată în (figura 1). Pentru vectorii conținând intrările, respectiv ieșirile viitoare ale procesului vom folosi următoarele notații:

$$\begin{aligned} u[k+i-d] &= [u[k+i-d], u[k+i-d-1], \dots, u[k+i-d-m]]^T \\ y[k+i-1] &= [y[k+i-1], y[k+i-2], \dots, y[k+i-n]]^T \end{aligned} \quad (13)$$

unde $i = N_1, \dots, N_2$, reprezintă ordinul predictorului, k este momentul curent de timp, iar d , m și n reprezintă parametrii considerați pentru modelul NNARX antrenat: d - timpul mort, m și n ordinele de întârziere ale intrării, respectiv ieșirii. Aplicând vectorii (13) modelului neural, se obține predictorul de ordin i al ieșirii, $y[k+i]$, după cum rezultă și din figura 9.

În calculul predictorilor ieșirii, dacă orizontul de predicție este mai mare decât orizontul de control sumat cu timpul mort considerat în modelul procesului ($N_2 > N_u + d$), după iterația $N_u + d$, intrarea va fi considerată constantă, având valoarea $u[k+N_u]$.




Figura 9. Calculul predictorilor neurali

Algoritmul iterativ de control predictiv poate fi ușor înțeles prin descrierea pașilor ce sunt parcurși la orice moment de timp (iterație) k :

- în iterația anterioară (momentul de timp $k-1$) prin minimizarea funcției de cost, a fost obținut vectorul comenzii:

$$\mathbf{u}_{old} = [u[k], u[k+1], \dots, u[k+N_u-1]]^T \quad (14)$$

- primul element al acestui vector, $u[k]$, reprezintă intrarea procesului la momentul de timp curent;
- sunt calculați predictorii ieșirii $y[k+1]$ de ordin $i = N_1, \dots, N_2$, folosind ca intrări ale modelului neural perechile de vectori $u[k+i-d]$ și $y[k+i-1]$
- se calculează funcția de cost J la pasul curent, după formula (12);
- noua secvență optimă de control se obține prin minimizarea funcției de cost J în raport cu vectorul comenzii

$$\mathbf{u}_{new} = [u[k+1], u[k+2], \dots, u[k+N_u]]^T \quad (15)$$

La momentul de timp următor ($k+1$), primul element din vectorul , $\mathbf{u}_{\text{new}}$ $u[k+1]$, este aplicat la intrarea procesului și algoritmul de control predictiv continuă cu iterația $k+1$. La startarea algoritmului, utilizatorul trebuie să aleagă valoarea inițială $u[0]$ a intrării procesului.

Intrările ce urmează a fi aplicate procesului real pot fi supuse unor restricții ce decurg din natura fizică a acestuia. Unii algoritmi de control predictiv permit ca aceste restricții să fie luate în considerație la minimizarea funcției de cost.




Figura 10. Structura de bază a unui controller predictiv

Având în vedere principiile MBPC prezentate, structura unui bloc de control ce implementează un astfel de algoritm poate fi prezentată ca în figura 10:

Viteza de calcul a unui astfel de controller trebuie să fie suficient de ridicată, pentru a permite efectuarea pașilor corespunzători unei iterații a algoritmului de control într-un timp mai mic decât perioada de eșantionare aleasă pentru interfațarea cu procesul real.

3.3. Blocuri simulink pentru aplicații ale rețelelor neurale în identificarea și conducerea sistemelor

Figura 11 prezintă o bibliotecă de blocuri Simulink pentru identificarea, simularea și controlul predictiv al sistemelor pe baza modelelor neurale




Figura 11. Bibliotecă de blocuri Simulink pentru identificarea, simularea și controlul predictiv al sistemelor pe baza modelelor neurale.

Dezvoltarea acestei biblioteci de blocuri Simulink pentru identificarea, simularea și controlul predictiv al sistemelor pe baza modelelor neurale a fost motivată de dorința de a ușura descrierea procesului supus identificării (așa cum se va vedea în continuare), lăsând utilizatorului, în același timp, flexibilitate în organizarea simulării. Mai mult chiar, posibilitatea executării simulărilor în timp real, prin utilizarea Real-Time Workshops, extinde aria de aplicabilitate a procedurilor de identificare la procese reale, interfațate adecvat prin cartele de achiziție.

Biblioteca Simulink din figura 11 constă din blocuri ce permit identificarea și simularea modelelor neurale cu o singură intrare și o singură ieșire (SISO) de forma (figura 1) și anume:

(i) pentru funcția f liniară:

- blocul *LI_N_ID* (*LI*near *N*eural *ID*entifier) folosit pentru antrenarea unei rețele ADALINE,
- blocul *LI_N_SI* (*LI*near *N*eural *SI*mulator) folosit pentru simularea transferului intrare-ieșire a unui model neural cu topologie ADALINE, identificat anterior,
- blocul *LI_D_SI* (*LI*near *D*elay *SI*mulator) folosit pentru simularea transferului intrare-ieșire a unui model neural de tip ADALINE, cu timp mort, identificat anterior;

(ii) pentru funcția f neliniară:

- blocul *MLP_N_ID* (*MLP* Neural *ID*entifier) servește la antrenarea rețelelor de tip MLP,
- blocul *MLP_N_SI* (*MLP* Neural *SI*mulator) servește pentru simularea transferului intrare-ieșire a unui model neural cu topologie MLP, identificat anterior,
- blocul *MLP_D_SI* (*MLP* Delay *SI*mulator) utilizat pentru simularea transferului intrare-ieșire a unui model neural cu topologie MLP, cu timp mort, identificat anterior.

Pentru identificarea și simularea modelelor neurale neliniare cu mai multe intrări și ieșiri (MIMO), această bibliotecă Simulink mai include:

- blocul *MLP_MIMO_TR* (*MLP* MIMO *TR*ainer) servește la antrenarea rețelelor de tip MLP utilizând matrice din spațiul de lucru Matlab,
- blocul *MLP_MIMO_SI* (*MLP* MIMO *SI*mulator) servește pentru simularea transferului intrare-ieșire a unui model neural cu topologie MLP, identificat anterior, cu ajutorul blocului *MLP_MIMO_TR*.

În plus, blocul *PRED_CTRL* permite implementarea unui controller predictiv pentru un sistem SISO utilizând un model neural, identificat anterior cu folosind blocul *MLP_N_ID*.




Figura 12. Caseta de dialog a blocului *LIN_N_ID*




Figura 13. Caseta de dialog a blocului *LIN_D_SI*

Casetele de dialog ale blocurilor *LI_N_ID* și *MLP_N_ID* pentru identificarea modelelor SISO sunt prezentate în figurile 12 și, respectiv, 14. Aceste blocuri permit atât antrenarea pe lot (*off-line*), în concordanță cu (10), cât și antrenare pe eșantioane (*on-line*), în concordanță cu (11), cu un număr de eșantioane N_E specificat de utilizator în caseta de dialog. Utilizatorul poate seta valoarea de prag pentru eroarea pătratică medie utilizată în antrenare și modul în care se formează vectorii regresorilor.

Casetele de dialog ale blocurilor *LIN_D_SI* și *MLP_N_SI*, utilizate în simulare, sunt prezentate în figurile 13 și, respectiv, 15. Parametrii rețelelor pot fi setați manual sau pot fi încărcăți automat din spațiul de lucru al Matlab-ului.

În găsirea regresorilor optimi pentru vectorii de intrare și ieșire este recomandată o strategie *bottom-up*, în sensul că arhitectura rețelei va fi inițializată cu un număr redus de regresori. Pentru blocul de tip MLP se va porni cu un număr redus de neuroni pe stratul de intrare. Aceste valori vor incrementate succesiv până la obținerea rezultatului dorit.




Figura 14. Caseta de dialog a blocului *MLP_N_ID*




Figura 15. Caseta de dialog a blocului *MLP_D_SI*

Blocul *PRED_CTRL* poate fi folosit pentru controlul proceselor neliniare ce au drept model neuronal o rețea de tip MLP. Caseta de dialog a acestui bloc este prezentată în figura 16, parametrii ce pot fi aleși de utilizator privind atât rețeaua neurală (presupusă deja antrenată), cât și algoritmul de control predictiv. Vectorul ce conține parametrii modelului neuronal are aceeași organizare ca și vectorul obținut în urma identificării folosind blocurile *MLP_N_ID*. Valorile întârzierilor intrării și ieșirii, precum și valoarea timpului mort, trebuie să fie aceleași cu cele considerate la crearea și antrenarea modelului NNARX.




Figura 16. Caseta de dialog a blocului **PRED_CTRL**

Parametrilor corespunzători algoritmului de control predictiv ce pot fi setați de către utilizator sunt în concordanță cu notațiile utilizate în paragraful 3.2. Traectoria referinței este presupusă a fi cunoscută apriori, fiind specificată sub forma unui vector.

Ieșirea ‘u’ a blocului de control furnizează valoarea intrării de control la fiecare pas de simulare, iar ieșirea ‘ref’ poate fi utilă pentru a aprecia modul în care ieșirea procesului urmărește referința dorită pe durata simulării.




Figura 17. Structura internă a blocului **PRED_CTRL**

În structura internă a blocului **PRED_CTRL** (figura 17) intră funcția-S denumită **predctrl** care este responsabilă atât de organizarea datelor interne pe baza parametrilor specifici modelului neuronal și algoritmului de control, cât și de minimizarea funcției de cost J (12). La fiecare pas de simulare (iterație a algoritmului de control predictiv) această funcție apelează o rutină **cost.m**, care realizează calculul predictorilor neuronali și al funcției de cost. Pentru crearea modelului neuronal s-au folosit funcțiile specifice din *Neural Network Toolbox*, iar pentru minimizarea funcției de cost s-a făcut apel la funcția **fmincon** din *Optimal Toolbox*, care permite impunerea unor limite (restricții) pentru variabila în raport cu care se efectuează minimizarea. La fiecare iterație a algoritmului este

memorat vectorul obținut prin minimizarea lui J , iar acest vector va constitui punctul de start al minimizării la iterația următoare.

Conectarea blocului într-o schemă Simulink în vederea simulării controlului unui oarecare proces dinamic neliniar (pentru care se dispune de un model neuronal) este ilustrată în figura 18. În timpul simulării, poate fi urmărită evoluția intrării de control și urmărirea referinței de către ieșirea procesului.




Figura 18. Modul de conectare a blocului **PRED_CTRL** într-o schema Simulink

3.4. Studii de caz

Deși utilizarea modelelor neuronale este atractivă îndeosebi în cazul neliniar, luăm în discuție, pentru început, construcția unui model liniar, deoarece acesta permite comparații relevante (de natură parametrică) cu reprezentările standard de tip funcție de transfer, discretă în timp. Al doilea exemplu ilustrează construcția unui model neliniar pentru care discuția privind validitatea se limitează doar la analiza comparativă a răspunsurilor obținute de la proces și respectiv model, în condițiile aceluiași semnal de test aplicat la intrare. În nici unul dintre cazuri nu abordăm problematica validării modelelor cu ajutorul testelor statistice.

Pentru ambele exemple, funcționarea procesului supus identificării este simulată în mediul Simulink, antrenarea rețelelor nefăcând însă uz de cunoașterea ordinului modelelor de simulare (ipoteză absolut firească în desfășurarea aplicațiilor reale). Totodată, pentru fiecare din exemple au fost considerate, separat, două situații ce urmează a fi detaliate mai jos:

- (a) ieșirea procesului nu este afectată de perturbații;
- (b) ieșirea procesului este afectată aditiv de perturbații de tip Gaussian care pot atinge 1% din amplitudinea maximă a semnalului util (corespunzând, de exemplu, zgomotului de conversie al unui convertor A/D cu rezoluție scăzută).

3.4.1. Construcția unui model liniar

În figura 6.4.1 se prezintă schema Simulink (aferentă situației (b) menționate la începutul secțiunii curente) utilizată pentru construirea unui model liniar de forma (figura 1) cu perioada de eșantionare secundă, cu ajutorul blocului LI_N_ID. Procesul ce face obiectul identificării este descris în Simulink prin funcția de transfer continuă în timp:

$$G(s) = \frac{400 \cdot e^{-15 \cdot s}}{300 \cdot s^2 + 40 \cdot s + 1} \quad (16)$$

procesul fiind excitat cu o sursă de zgomot alb de bandă limitată, adecvat aleasă. Singurele informații presupuse cunoscute apriori sunt comportarea liniară a procesului și valoarea timpul mort (identificabil, de exemplu, de pe un răspuns la semnal treaptă), adică în (figura 19) pentru secundă.




Figura 19. Schema Simulink de identificare a modelului liniar corespunzător exemplului din secțiunea A.

Selectăm drept complet edificatoare doar o parte din rezultate, prezentate în tabelul 1 pe care le exprimăm (dată fiind liniaritatea modelului) sub formă de funcții de transfer discrete (ale căror coeficienți sunt, până la un semn cunoscut, chiar parametrii furnizați de blocul LI_N_ID). Această exprimare facilitează analiza calității modelului provenit din identificare, prin comparație directă cu discretizată cu $T = 1$ secundă a lui $G(s)$, obținută prin metoda Euler predictor

$\tilde{G}(z^{-1}) = z^{-15} \frac{0.6378 \cdot z^{-1} + 0.6101 \cdot z^{-2}}{1 - 1.872 \cdot z^{-1} + 0.8752 \cdot z^{-2}}$	(17)
--	------

Toate cazurile comentate se referă la aceleași condiții de antrenare on-line cu $NE=50$ eșantioane în funcția obiectiv J din (13), maxim 100 epoci/fereastră și rată de învățare variabilă. Rezultatele din tabelul 6.4.1 evidențiază rolul jucat de valoarea obținută în antrenare pentru funcția obiectiv J în aprecierea convergenței parametrilor rețelei și, totodată, în evaluarea calității modelului identificat.

Figurile 20.a și 20.b furnizează reprezentările grafice ale evoluțiilor parametrilor rețelei pentru o durată de 150 de secunde corespunzătoare cazului (b) pentru $n=2$, $m=2$ și, respectiv, pentru $n=2$ și $m=1$. Aceste reprezentări grafice ilustrează totodată și capacitatea blocurilor Simulink utilizate de a furniza on-line informații cantitative ce caracterizează progresul antrenării. Mai subliniem ca elemente importante în construcția modelului neuronal faptul că în toate situațiile de convergență a parametrilor coeficientul termenului în z^0 al numărătorului (în exprimarea sub formă de funcție de transfer) rezultă numeric nul (raportat la precizia de calcul).

Tabelul 1. Prezentare sintetică a rezultatelor antrenării pentru opt teste de identificare selectate cu relevanțe pentru secțiunea 3.4.1.

Cazul (a) – leșire neperturbată				
d	n	m	J(150)	Exprimare sub formă de funcție de transfer
15	2	1	10^{-2}	Parametrii nu converg la valori staționare
15	2	2	10^{-9}	$z^{-15} \cdot \frac{0.6377 \cdot z^{-1} + 0.6102 \cdot z^{-2}}{1 - 1.872 \cdot z^{-1} + 0.8751 \cdot z^{-2}}$
15	3	2	10^{-2}	Parametrii nu converg la valori staționare
15	3	3	10^{-9}	$z^{-15} \cdot \frac{0.6378 \cdot z^{-1} + 0.9392 \cdot z^{-2} + 0.3148 \cdot z^{-3}}{1 - 1.356 \cdot z^{-1} + 0.0907 \cdot z^{-2} + 0.4515 \cdot z^{-3}} =$ $= z^{-15} \cdot \frac{0.6378 \cdot (z + \mathbf{0.5160}) \cdot (z + 0.9566)}{(z + \mathbf{0.5159}) \cdot (z - 0.9665) \cdot (z - 0.9054)}$
Cazul (b) – leșire perturbată				
d	n	m	J(150)	Exprimare sub formă de funcție de transfer
15	2	1	10^{-2}	Parametrii nu converg la valori staționare
15	2	2	10^{-9}	$z^{-15} \cdot \frac{0.637 \cdot z^{-1} + 0.6158 \cdot z^{-2}}{1 - 1.8711 \cdot z^{-1} + 0.8742 \cdot z^{-2}}$
15	3	2	10^{-2}	Parametrii nu converg la valori staționare
15	3	3	10^{-9}	$z^{-15} \cdot \frac{0.6378 \cdot z^{-1} + 0.9448 \cdot z^{-2} + 0.3144 \cdot z^{-3}}{1 - 1.3552 \cdot z^{-1} + 0.0922 \cdot z^{-2} + 0.4521 \cdot z^{-3}} =$ $= z^{-15} \cdot \frac{0.6378 \cdot (z + \mathbf{0.5048}) \cdot (z + 0.9766)}{(z + \mathbf{0.5167}) \cdot (z - 0.9043) \cdot (z - 0.9676)}$

Redundanța în stabilirea numărului de regresori conduce la apariția perechilor pol-zero cu valori numerice identice (raportate la precizia de calcul), fapt ilustrat în tabelul 1 pentru $n=m=3$ în ambele cazuri (a) și (b).




Figura 20. Evoluția parametrilor rețelei neuronale pentru exemplul din secțiunea xxx corespunzând unui interval de 150 secunde:
a) Cazul $n=2$ și $m=2$ (parametrii converg),
b) Cazul $n=2$ și $m=1$ (parametrii nu converg).

3.4.2. Construcția unui model neliniar

Exemplul prezentat în continuare ilustrează utilizarea blocului **MLP_N_ID** în identificarea unui model neliniar de tipul (17) cu perioada de eșantionare $T = 1$ secundă. Procesul ce urmează a fi identificat este simulat în Simulink pe baza următoarei ecuații cu diferențe (recomandată în literatură ca exemplu relevant pentru identificare neurală (Liu, *et al.*, 1998)):

$$y(k) = 2.5 \cdot \frac{y(k-2) \cdot y(k-1)}{1 + y^2(k-1) + y^2(k-2)} + 0.3 \cdot \cos(0.5 \cdot [y(k-1) + y(k-2)]) + 1.2 \cdot u(k-1) \quad (18)$$




Figura 21. Schema Simulink de identificare a modelului neliniar corespunzător exemplului din secțiunea B.

Figura 21 prezintă diagrama Simulink utilizată pentru identificare. Semnalul de intrare este de tip „zgomot alb” adecvat ales. Toate cazurile ce vor fi comentate (extrase dintr-un set amplu de teste) se referă la aceleași condiții de antrenare on-line cu $N_E = 200$ eșantioane în funcția obiectiv J din (10), utilizând algoritmul Levenberg-Marquardt. Criteriile de oprire a antrenării au fost fie atingerea unui număr maxim de 100 epoci/fereastră sau o acuratețe de aproximare $\varepsilon = 10^{-9}$ pentru funcția obiectiv (10). Stratul de intrare conține 10 neuroni sigmoidali. Rezultatele obținute pentru $d=0$, $m=1$, $n=2$, în (1) sunt comparabile, din punct de vedere al acurateței, pentru cazurile (a) și (b) având valori de ordinul 10^{-5} pentru $J(250)$ în cazul (a) și respectiv 10^{-3} în cazul (b). Cazurile cu d , m , n ce nu îndeplinesc condițiile menționate anterior pot fi ușor separate ele furnizând valori pentru $J(250)$ de ordinul $10^{-1} - 10^{-2}$.

Pentru a ilustra calitatea modelului neural rezultat din identificare, figura 6.4.4 prezintă grafice comparative pentru răspunsul procesului și a modelului pentru o intrare sinusoidală cu amplitudinea 0.7 (figura 22.a) și un semnal de intrare aleator, uniform distribuit în intervalul $[-1, 1]$ (figura 22.b). Parametrii modelului neural sunt cei obținuți în situația (b) cu $d=0$, $m=1$, $n=2$ (adică numărul minim de regresori în (1) capabili să asigure valori favorabile pentru $J(250)$). Semnalele de test utilizate nu au fost „văzute” în timpul identificării. Folosirea

numărului exact de regresori prezenți în ecuația (21) ($d=1$, $m=0$, $n=2$) nu a adus îmbunătățiri vizibile în acuratețea de aproximare a modelului obținut în comparație cu o serie de teste nedetaliat în această lucrare.




Figura 22. Grafice comparative cu răspunsurile procesului (linie continuă) și modelului neural MLP (linie întreruptă):

a) intrare sinusoidală de amplitudine 0.7; b) semnal aleator uniform distribuit în $[-1,1]$.

În general vorbind, testele efectuate au arătat că modelele neurale nu sunt afectate semnificativ de folosirea regresorilor suplimentari în comparație cu folosirea numărului exact de regresori specificat anterior. Totuși, redundanța crește complexitatea modelului neural fără nici un beneficiu real, de aceea e preferabil de căutat un model apropiat de cel minimal.

3.4.3. Controlul predictiv bazat pe model neural

Modelul neliniar identificat în secțiunea precedentă, corespunzător sistemului descris de ecuația cu diferențe (3.4.2) este utilizat în continuare pentru a proiecta un controller predictiv pentru acest sistem utilizând blocul **PRED_CTRL**. Schema Simulink utilizată este prezentată în figura 23.

Parametrii utilizați de algoritmul de control predictiv au următoarele valori:

- orizontul minim de predicție $N_1 = 1$;
- orizontul de predicție $N_2 = 3$;
- orizontul de control $N_u = 2$;
- factorul de ponderare $\lambda = 0$ și
- valoarea inițială a intrării $u_{init} = 0$.




Figura 23. Modelul Simulink utilizat pentru controlul predictiv al sistemului neliniar.

Figura 24 ilustrează urmărirea unei referințe sinusoidale, cu amplitudine 1, fază 0, offset 0,2 și frecvență 0,005 Hz, iar figura 25 urmărirea unei referințe de formă unghiulară, cu valori cuprinse în intervalul [-1,1].




Figura 24. Grafice comparative ale unei referințe sinusoidale și a ieșirii sistemului neliniar controlat de un regulator predictiv.




Figura 25. Grafice comparative ale unei referințe unghiulare și a ieșirii sistemului neliniar controlat de un regulator predictiv.

4. Problematika propusă pentru studiu

Problema 1.

Pe baza exemplului prezentat în secțiunea xxxx să se construiască modelul Simulink pentru identificarea sistemului liniar descris de funcția de transfer

$$G(s) = \frac{125 \cdot e^{-3s}}{100 \cdot s^2 + 40 \cdot s + 3}$$

considerând perioada de eșantionare a semnalelor de 1 secundă.

Să se ruleze experimentele de identificare off-line și on-line în următoarele condiții:

a. ieșirea procesului nu este afectată de perturbații;

b. ieșirea procesului este afectată aditiv de perturbații de tip Gaussian care pot atinge 1% din amplitudinea maximă a semnalului util (corespunzând, de exemplu, zgomotului de conversie al unui convertor A/D cu rezoluție scăzută).

Corespunzător ecuației (6.1.1), se vor lua în discuție următoarele cazuri:

- (i) $d = 4, n = 2, m = 1$;
- (ii) $d = 4, n = 2, m = 2$;
- (iii) $d = 4, n = 3, m = 2$;
- (iv) $d = 4, n = 3, m = 3$;

Pentru fiecare din cazurile (i)-(iv) se va fixa valoarea de prag a erorii pătratice medii utilizată în antrenarea rețelei (*mean squared error goal*) la valorile 10^{-2} și apoi 0; în fiecare caz în parte se va comenta legătura dintre parametrii rețelei neurale și coeficienții funcției de transfer discrete corespunzătoare sistemului, obținută prin apelarea funcției Matlab `c2d`.

După rularea unui experiment de identificare, se va rula, pentru validarea modelului, un experimentul de simulare, considerând ca semnal de intrare în sistem și în modelul neural obținut atât un semnal de tip zgomot alb, cât și un semnal determinist, de tip treaptă unitară sau sinusoidal.

Problema 2.

Să se reprezinte următoarele sisteme discrete sub forma unei rețele neuronale dinamice constituită dintr-o ADALINE și întârzierile adecvate:

- a) $G_1(z) = 10 \cdot \frac{(z+1) \cdot (z-1)}{(z-\frac{1}{2}) \cdot (z-\frac{1}{3})}$
 $z^{-5} - 0.3 \cdot z^{-6}$
- b) $G_2(z) = \frac{1}{1 - 0.5 \cdot z^{-1} + 0.06 \cdot z^{-2}}$
- c) $G_3(z) = \frac{b_2 \cdot z^2 + b_1 \cdot z + b_0}{b_3 \cdot z^3 + b_2 \cdot z^2 + b_1 \cdot z + b_0}, a_i, b_j \neq 0, i = \overline{0,3}, j = \overline{0,2}$
- d) $G_4(z) = z^{-3} \cdot G_3(z)$

Problema 3.

Se consideră rețeaua neuronală cu dinamică externă din figura 7.18.1, unde rețeaua ADALINE are parametrii:

$$w = [2 \quad 0 \quad -18 \quad \eta \quad -1] \quad b = 0$$

Iar q^{-1} notează operatorul de întârziere în domeniul timp.

- a. Să se determine funcția de transfer a rețelei.
- b. Să se discute stabilitatea IMEM în funcție de valoarea parametrului $\eta \in \mathbf{R}$.
- c. Pentru valorile lui η pentru care sistemul este stabil IMEM să se arate că există rețele dinamice cu o configurație mai simplă care realizează același transfer intrare-ieșire și să se reprezinte grafic aceste configurații.

Problema 4.

Se consideră sistemul neliniar în timp discret descris de ecuația cu diferențe (pentru o perioadă de eșantionare $T=1$ secundă):

$$y(k) = \frac{y[k-1] + y[k-2]}{1 + 2y[k-1] \cdot y[k-2]} - 1.5 \cdot u[k-1] + u[k-2]$$

1. Folosind blocurile Simulink prezentate în secțiunea 6.3, să se obțină un model neuronal de tip MLP pentru procesul dat, efectuând experimente de identificare off-line și on-line în următoarele condiții:

- (a) ieșirea procesului nu este afectată de perturbații;

(b) ieșirea procesului este afectată aditiv de perturbații de tip Gaussian care pot atinge 1% din amplitudinea maximă a semnalului util (corespunzând, de exemplu, zgomotului de conversie al unui convertor A/D cu rezoluție scăzută).

Corespunzător modelului NNARX, se va lua în discuție atât cazul când întârzierile rețelei neuronale sunt egale cu întârzierile reale ale procesului, cât și cazul introducerii unor regresori suplimentari în modelul neuronal.

2. Calitatea modelelor neuronale obținute va fi apreciată din punct de vedere al analizei comparative a răspunsurilor obținute de la proces și respectiv model, pentru următoarele cazuri:

(a) semnal de intrare aleator cu distribuție uniformă în intervalul $[-1, 1]$;

(b) semnal de intrare aleator binar de nivele 1 și -1.

3. Modelele obținute vor fi folosite pentru a realiza controlul predictiv al procesului considerat în următoarele cazuri:

(a) referință sinusoidală, cu amplitudine 1, fază inițială 0 și pulsație 2250π rad/sec.;

(b) referință în formă de dinți de ferăstrău de amplitudine 1, offset 0.5 și perioadă 100 secunde.

Pentru algoritmul de control predictiv, se vor considera următorii parametrii:

- orizont de control $N_u = 2$;
- orizont minim de predicție $N_1 = 1$;
- orizont de predicție $N_2 = 3$ și
- ponderea asupra comenzii $\lambda = 0,2$.

Problema 5.

Se consideră o instalație având funcția de transfer

$$G(s) = \frac{5 \cdot e^{-20 \cdot s}}{10 \cdot s + 1}$$

pentru care se determină un model discret folosind o rețea neurală dinamică constituită dintr-o rețea ADALINE și întârzierile necesare.

Să se reprezinte grafic structura rețelei neuronale dinamice și să se precizeze parametrii rețelei ADALINE considerând că discretizarea lui $G(s)$ se realizează exact, adică:

$$G_d(s) = (1 - z^{-1}) \cdot Z\left\{\frac{G(s)}{s}\right\}$$

pentru:

- perioada de eșantionare de 1 sec;
- perioada de eșantionare de 2 sec.

Problema 6.

Se consideră un proces având funcția de transfer

$$G(s) = \frac{30 \cdot s + 1}{35 \cdot s^2 + 12 \cdot s + 1}$$

Pentru care se determină un model discret folosind o rețea neuronală dinamică alcătuită dintr-o rețea ADALINE și întârzierile adecvate. Să se reprezinte grafic structura rețelei neuronale dinamice și parametrii rețelei ADALINE presupunând că discretizarea lui $G(s)$ se realizează pentru o perioadă de eșantionare $T = 1$ sec, folosind:

- metoda dreptunghiului în avans, care folosește

$$s \cong \frac{z - 1}{T}$$

- metoda dreptunghiului în întârziere, care folosește

$$s \cong \frac{z - 1}{T \cdot z}$$

- metoda trapezului, care folosește

$$s \cong \frac{2}{T} \cdot \frac{z - 1}{z + 1}$$