

**UNIVERSITATEA „ȘTEFAN CEL MARE” SUCEAVA
FACULTATEA DE INGINERIE ELECTRICĂ ȘI ȘTIINȚA CALCULATOARELOR
DOMENIUL: ȘTIINȚA CALCULATOARELOR**

TEZĂ DE DOCTORAT

**Contribuții la modelarea comportamentelor
sistemelor haotice**

- Rezumat -

**Conducător științific,
Prof. Univ. dr. ing. Ștefan-Gheorghe PENTIUC**

**Doctorand,
Sorin VLAD**

SUCEAVA 2015



Universitatea
Ștefan cel Mare
Suceava

DECIZIA D 119 / 4.09.2015

privind constituirea comisiei pentru susținerea publică a unei teze de doctorat

În conformitate cu prevederile H.G. nr. 26 din 14.01.2015 privind organizarea și funcționarea Ministerului Educației și Cercetării Științifice, Anexa 3, punctul 39, prin care se instituționalizează Universitatea Ștefan cel Mare din Suceava;
În conformitate cu HG 681 din 29.06.2011 - Codul Studiilor universitare de doctorat;
Având în vedere aprobarea conducerii Universității;

Rectorul Universității "Ștefan cel Mare" din Suceava emite prezenta decizie:

Art. 1 - Se numește comisia de doctorat pentru susținerea publică a tezei de doctorat în data de **23.09.2015**, cu titlul: **„CONTRIBUȚII LA MODELAREA COMPORAMENTULUI SISTEMELOR HAOTICE”**,

elaborată de **VLAD M. Sorin**,
înmatriculat la data de 1.11.2004,
forma de învățământ: fără frecvență, conform HG 37/1999
DOMENIUL: **Știința calculatoarelor**

PREȘEDINTE:
Prof. univ. dr. ing. Valentin POPA, reprezentant al Universității „Ștefan cel Mare” din Suceava;

CONDUCĂTOR ȘTIINȚIFIC
Prof. univ. dr. ing. Ștefan Gheorghe PENTIUC, Universitatea „Ștefan cel Mare” din Suceava;

REFERENȚI:

1. Prof. univ. dr. ing. Sergiu NEDEVSCHI, Universitatea Tehnică Cluj Napoca;
2. Prof. univ. dr. ing. Sergiu-Viorel CARAMAN, Universitatea „Dunărea de Jos” din Galați;
3. Prof. univ. dr. ing. Dorin-Mircea POPOVICI, Universitatea „Ovidius” din Constanța.

Art. 2. – Direcția Economică și Resurse Umane și serviciul Secretariat - doctorat vor duce la îndeplinire dispozițiile prezentei decizii.

RECTOR,
Prof. univ. dr. ing. Valentin POPA



C.Sk./C.Sk./ 1 ex.

SECRETAR ȘEF UNIV.,
Jurist Maria MUSCĂ

Muscă

Cuprinsul tezei de doctorat

Lista tabelor

Lista figurilor

INTRODUCERE

CAPITOLUL I. ELEMENTE DE DINAMICĂ NELINIARĂ ȘI TEORIA HAOSULUI

1.1 SISTEME LINIARE ȘI SISTEME NELINIARE

1.1.1 Modelul Lorenz

1.2 HAOS DETERMINIST ȘI HAOS NEDETERMINIST

1.3. ATRACTORI STRANII ÎN SPAȚIUL STĂRII

1.4. CARACTERUL UNIVERSAL AL HAOSULUI. NUMĂRUL LUI FEIGENBAUM

1.3.1 Diagrame de bifurcație

1.3.2. Numărul lui Feigenbaum

1.4 FRACTALI

1.5 FUNCȚIA LOGISTICĂ

1.6. CUANTIFICAREA HAOSULUI

1.6.1 Exponentul Lyapunov

1.6.2. Scalarea universală a exponentului Lyapunov

CAPITOLUL II. STADIUL ACTUAL ÎN MODELAREA SISTEMELOR HAOTICE

2.1 SISTEME ȘI MODELE

2.2. MODELAREA SISTEMELOR HAOTICE CU REȚELE NEURONALE

2.3. MODELAREA FUZZY A COMPORTAMENTULUI HAOTIC

2.3.1 Moduri și tehnici de abordare

2.3.2 Mulțimi fuzzy

2.3.3 Modelarea funcției logistice

2.4. MODELAREA SISTEMELOR HAOTICE CU MODELE MARKOV ASCUNSE

2.5. ANALIZA COMPARATIVĂ A INSTRUMENTELOR DE MODELARE PREZENTATE

CAPITOLUL III. ANALIZA CLASICĂ A SERIILOR DE TIMP

3.1. OBIECTIVELE ANALIZEI SERIEI DE TIMP

3.2 MODELE DE SERII DE TIMP

3.2.1 Modelul mediei alunecătoare (MA)

3.2.2 Modelul cu netezire exponențială (ES)

3.2.3 Modelul cu dublă netezire exponențială (Metoda lui Holt)

2.2.4 Regresia simplă

3.2.5. Metoda cu triplă netezire exponențială (Winter)

3.2.6 Metoda Box-Jenkins

CAPITOLUL IV. ANALIZA NELINIARĂ A SERIILOR DE TIMP

4.1 ETAPELE ANALIZEI NELINIARE

4.2 RECONSTRUCȚIA SPAȚIULUI FAZEI. TEOREMA LUI TAKENS

4.2.1 Dimensiunea de includere

4.2.2 Alegerea parametrului de întârziere

4.3 DETECTAREA HAOSULUI ÎN SERIILE DE TIMP

4.3.1 Teste de neliniaritate. Testul BDS

4.3.2. Testul 0-1

4.3.3. Teste vizuale de detectare a haosului

4.3.4. Teste numerice de detectare a haosului

4.4. ANALIZA NELINIARĂ A RATEI DE SCHIMB LEU-EURO

4.5 ANALIZA NELINIARĂ A SERIEI DE TIMP A PREȚULUI SPOT AL ENERGIEI ELECTRICE

4.6 ANALIZA NELINIARĂ A SERIEI DE TIMP A DEBITELOR ZILNICE PENTRU RÂUL SIRET

CAPITOLUL V. ELEMENTE DE TEORIA HAOSULUI ÎN PREDICȚIA SERIILOR DE TIMP.

5.1 PREDICȚIA SERIILOR DE TIMP

5.2. PREDICȚIA SERIILOR DE TIMP HAOTICE

5.2.1. Rolul exponentului Lyapunov în predicția seriilor de timp haotice

5.2.2 Metode globale

5.2.3 Metode locale

5.3 REȚELELE NEURONALE ȘI AVANTAJELE UTILIZĂRII ACESTORA

5.4. PREDICȚIA SERIILOR DE TIMP HAOTICE CU REȚELE NEURONALE DE TIP PERCEPTRON MULTISTRAT

5.4.1. Propagarea înapoi a erorii

5.4.2. Rezultatele predicției

5.5. PREDICȚIA SERIILOR DE TIMP CU MAȘINI CU VECTORI DE SUPT (SVM-SUPPORT VECTOR MACHINES)

4.5 MODEL NEURONAL DE PREDICȚIE A SERIILOR DE TIMP

CAPITOLUL VI. STUDII DE CAZ: MODELAREA SERIILOR DE TIMP ALE PREȚULUI ENERGIEI ELECTRICE ȘI ALE DEBITULUI RÂULUI SIRET

6.1 MODELAREA HIBRIDĂ ARIMA – REȚELE NEURONALE

6.1.2 Modelarea prețului spot al energiei electrice

6.1.3 Modelarea seriei de timp a debitelor râului Siret

6.2. MODELAREA CU ECHO STATE NETWORKS

6.2.1 Rețele Echo State Networks

6.2.2. Antrenarea rețelei

6.2.3 Modelarea seriei de timp a debitelor râului Siret

6.2.4 Modelarea seriei de timp a prețului spot

CONCLUZII

CONTRIBUȚII

BIBLIOGRAFIE

Cuvinte – cheie

Teoria haosului, dinamica neliniară, analiza neliniară a seriilor de timp, identificarea haosului, exponent Lyapunov, dimensiunea de corelație, reconstrucția spațiului stării, rețele neuronale, predicția seriilor de timp haotice, multistrat, rețele neuronale de tip vectori de support, algoritmul celor mai apropiați vecini, rețele neuronale cu ecou al stării (Echo state network), model ARIMA sezonier

1. Motivație

Realitatea înconjurătoare poate fi privită ca rezultat al interacțiunii unor sisteme dinamice neliniare complexe. S-a demonstrat însă că, totuși, și unele sisteme foarte simple pot avea comportamente complicate și aparent aleatoare. Teoria haosului urmărește să explice și să predicționeze pe timp scurt comportamentul aparent aleatoriu și impredictibil al sistemelor neliniare.

Deși ideile premergătoare apariției teoriei haosului existau de mai mult timp, acestea au fost cristalizate pentru prima dată de către Lorenz în lucrarea *Deterministic nonperiodic flow* (1963). Lorenz a creat un model matematic al circulației curenților atmosferici de convecție și a observat că atunci când există o infimă diferență între condițiile inițiale se obțin rezultate complet diferite redescoperind astfel fenomenul de sensibilitate la variația condițiilor inițiale. Fenomenul observat a devenit o paradigmă foarte populară a teoriei haosului numită „efectul fluture” și care afirmă că dacă bătaiea aripilor unui fluture modifică de o manieră infimă condițiile atmosferice în jungla amazoniană, acest fapt poate avea ca efect, la finalul unui complex lanț causal, apariția unei tornade în Texas.




Figura 1. Atractorul Lorenz de timp dublă rulare, asemănător unui fluture.

Paradigma „efectul fluture” surprinde esența fenomenelor ce caracterizează haosul: în primul rând sensibilitatea față de condițiile inițiale și în al doilea rând caracterul determinist al acestora prin evidențierea unor structuri în spațiul fazei, structuri numite atractorii haotici. Un sistem al cărui comportament era considerat până nu demult aleatoriu devine predictibil pe termen scurt. Calitatea predicției scade pe măsură ce dinamica unui sistem haotic evoluează în timp datorită divergenței traiectoriilor inițiale. Pentru a predicționa comportamentul viitor al unui sistem, starea curentă a sistemului trebuie cunoscută cu precizie infinită – lucru de altfel imposibil în realitate.

2. Obiective și structura tezei

Obiectivul principal al tezei constă din elaborarea modelelor care să simuleze cât mai exact comportamentul sistemelor care au generat seriile de timp analizate, și anume cea a debitelor zilnice ale râului Siret și cea a variației prețului pe spot al energiei electrice consumate în

România. În seriile de timp studiate au fost evidențiate prezența unor indicii ale existenței haosului. Identificarea haosului a fost posibilă prin determinare unor mărimi ale căror valori sugerează existența unor actori haotici de dimensiune redusă.

Pentru atingerea acestui obiectiv s-a pornit de la analiza stadiului actual în modelarea sistemelor haotice, s-au parcurs etapele necesare identificării haosului în seriile de timp prin aplicarea metodelor analizei neliniare și în final s-a realizat modelarea propriu-zisă prin utilizarea a două tehnici: modelarea hibridă ARIMA-rețea neuronală de timp perceptron multistrat și modelarea cu rețea de tip ESN (Echo State Network).

Până la fundamentarea teoriei haosului, evoluția complicată și inexplicabilă și impredictibilă a unui sistem era considerată comportament aleatoriu. Odată cu apariția teoriei haosului și a instrumentelor acesteia, a devenit vizibilă o nouă lume, iar lucrurile au putut fi explicate dintr-o altă perspectivă. Principalul avantaj al teoriei haosului este constă din faptul că permite predicția pe termen scurt a evoluției sistemelor haotice și oferă explicații ale tipului de comportament dinamic respectiv.

Teza este structurată pe șase capitole, începând cu capitolul 1 în care se prezintă în mare principalele noțiuni legate de teoria haosului în sistemele neliniare. Sunt prezentate unele tipare care se repetă în cazul sistemelor haotice datorită chiar mecanismului de producere a haosului - fenomenului de dublare a perioadei. Numărul lui Feigenbaum permite realizarea unor predicții privitoare la momentul când se va produce o schimbare calitativă în evoluția dinamică a sistemului ca urmare a unei bifurcații. Tot aici este prezentată pe scurt una dintre cele mai importante noțiuni ale teoriei haosului, noțiune care derivă direct din proprietatea sistemelor haotice de a fi sensibile la variația valorilor inițiale, și anume exponentul Lyapunov. Modul de determinare a acestuia va fi prezentat detaliat în capitolul IV.

În capitolul 2, intitulat *Stadiul actual în modelarea sistemelor haotice*, sunt prezentate principalele instrumente de modelare a evoluției acestor sisteme, iar la final este realizată o analiză comparativă a acestora. Se prezintă diverse exemple din literatura de specialitate care descriu modelarea funcției logistice cu ajutorul logicii fuzzy, modelarea cu ajutorul rețelelor neuronale a unui set de date de test, utilizarea lanțurilor Markov în modelarea statistică a atractorului Henon.

Capitolul III descrie tehnicile clasice de modelare și predicție a seriilor de timp. Sunt prezentate, însoțite de exemple ilustrative, regresia simplă, metoda mediei alunecătoare, metoda Holt, metoda Winter și, în final, modelarea ARIMA aplicabilă sistemelor liniare.

Capitolul IV încearcă să sintetizeze întregul procedeu al modelării neliniare a seriilor de timp, conform unei proceduri prezentată schematic la începutul capitolului și elaborată pe baza consultării literaturii de specialitate. Sunt prezentate pe larg principalele metode de indentificare vizuală a manifestării haosului în seriile de timp, metode și mărimi care permit identificarea numerică a dinamicii haotice, precum și principala teoremă pe care se bazează studiul sistemelor haotice. Reconstituirea spațiului fazei se bazează pe teorema lui Takens și permite reconstituirea dinamicii sistemului inițial fără a cunoaște nimic referitor la sistemul inițial, având la dispoziție doar o serie de timp univariată. Scopul reconstrucției spațiului fazei este de a caracteriza comportamentul unui sistem dinamic ce se manifestă prin intermediul unui proces necunoscut și evidențierea existenței unui atractor cu dimensiune fractală. Sunt prezentate rezultatele obținute în urma analizei neliniare în cazul a trei serii de timp culese de autor.

Capitolul V prezintă diverse procedee de predicție a seriilor de timp din perspectiva teoriei haosului. Predicția este realizată cu ajutorul unor rețele neuronale de tip Support Vector Machines și perceptron multistrat. Este prezentat și un model de predicție a seriilor de timp bazat

pe definierea unei mărimi pe spațiul formelor ce reprezintă date de intrare pentru o rețea neuronală de timp perceptron multistrat.

În ultimul capitol se realizează modelarea seriilor de timp în al căror caz s-a putut pune în evidență existența unei dinamici haotice. Modelarea se realizează printr-o metodă hibridă ARIMA-rețele neuronale și, ca variantă ce permite realizarea unei analize comparative, cu ajutorul unui tip de rețele neuronale, apărute relativ recent, numite rețele cu ecoul stării (Echo State Network).

Teza se încheie cu concluzii și direcții viitoare de cercetare și cu enumerarea surselor bibliografice consultate pentru elaborarea acestei teze de doctorat..

3. Concepte principale prezentate în teză

3.1. Analiza neliniară a seriilor de timp

Comportamentul neliniar permite o mai bună înțelegere a fenomenelor naturale complexe. Dinamica neliniară a introdus un set de concepte și instrumente noi ce permit analiza și investigarea dinamicii generate de către procesele neliniare. Se poate afirma că, la momentul de față, există o unificare conceptuală a noțiunilor (atractori, dublare a perioadei, bifurcații, exponent Lyapunov, sensibilitate la condițiile inițiale). Tehnicile ce studiază conceptele introduse de dinamica neliniară sunt grupate sub denumirea generică de prelucrarea semnalelor neliniare sau analiză neliniară.

Comportamentul unui sistem dinamic neliniar este figurat în spațiul stării sau spațiul fazei – un spațiu conceptual în care dimensiunile corespund variabilelor din sistem. Modificările în timp ale sistemului descrise prin ecuații diferențiale sunt reflectate prin mișcările unui punct în spațiul stării, mișcări denumite traiectorii. O imagine a modificării stării unui sistem pe mai multe intervale de timp se numește portretul fazei. Portretele fazei relevă existența unor atractori care sunt regiuni sau puncte ale spațiului fazei spre care converg toate traiectoriile apropiate. Un atractor straniu va ocupa o regiune a spațiului fazei în care vor fi capturate toate traiectoriile care, aparent aleatoriu vor acoperi toată suprafața acestuia fără a se repeta. Un spațiu al stării poate fi creat pornind de la o serie de timp prin reprezentarea grafică a observațiilor decalate cu un anumit interval de timp, procedeu numit reconstrucția spațiului stării.

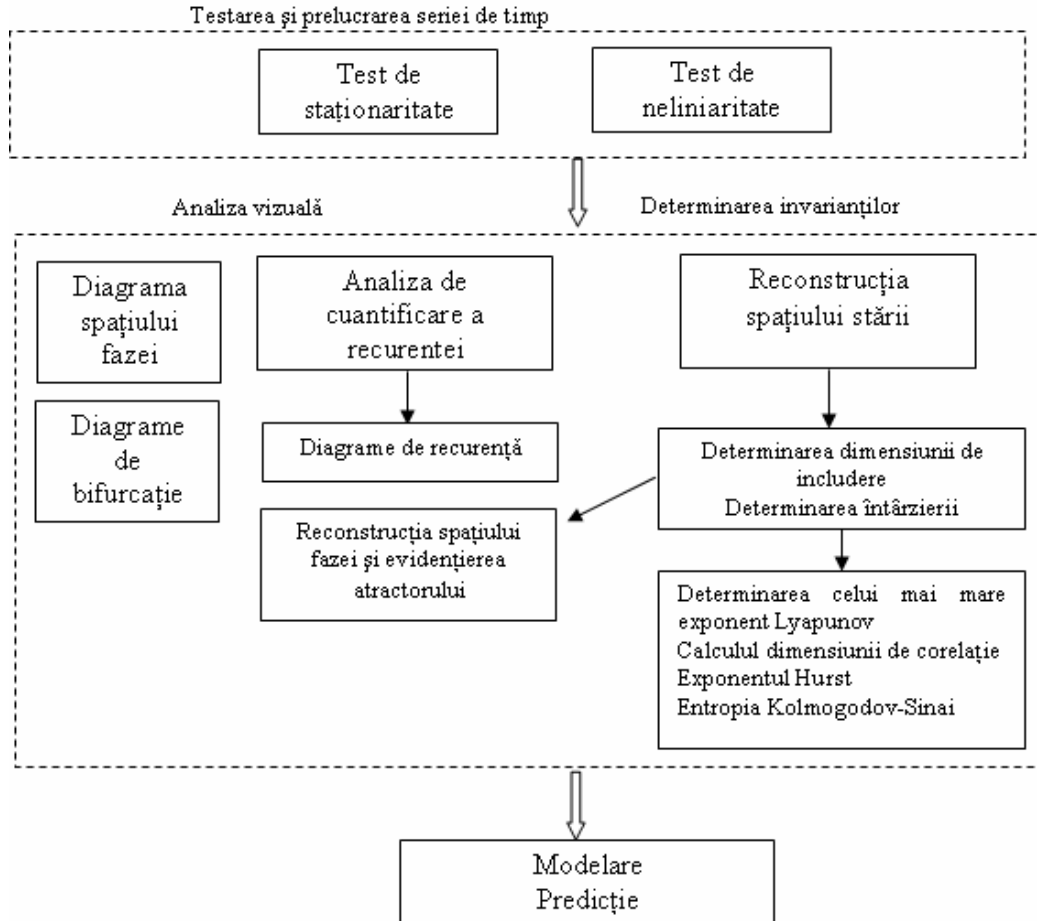


Figura 2.. Etapele și instrumentele utilizate în analiza neliniară a seriilor de timp.

Reconstrucția spațiului fazei. Teorema lui Takens

În ultimii 20 de ani au fost elaborate diverse tehnici pentru analiza și prelucrarea semnalelor încadrate în categoria dinamicilor neliniare de tip haotic. Aceste tehnici sunt denumite generic „tehnici de prelucrare a semnalelor neliniare” și se bazează îndeosebi pe teorema Takens [TAK81].

Teorema permite reconstrucția unei traiectorii unidimensionale sau multidimensionale echivalentă traiectoriei inițiale extrasă din spațiul fazei seriei de timp de la care s-a plecat. Ideea a fost utilizată însă cu mult înaintea publicării acesteia. În 1927 Yule a folosit un grafic în coordonatele $x(t)$, $x(t+1)-x(t-1)$ pentru analiza seriei de timp a petelor solare.

Includerea în spațiul fazei este un proces prin care o serie de timp este transformată într-o serie de coordonate în spațiul fazei reconstruit. Setul de coordonate reconstruite definește o traiectorie în spațiul fazei reconstruit. Dacă spațiul fazei reconstruit are m dimensiuni, atunci fiecare coordonată spațială reconstruită X_i este un vector de dimensiune m obținut din seria de timp inițială, luându-se în considerare doar unele componente ale seriei de timp originale separate printr-un interval de timp numit întârziere [GCT07].

În practică apar două probleme importante în ceea ce privește metoda întârzierii ca metodă de reconstrucție a spațiului fazei. Prima problemă, comună de altfel tuturor metodelor de reconstrucție este cea a stabilirii dimensiunii minime de includere. Această dimensiune minimă este necunoscută și trebuie determinată.

Pentru determinarea dimensiunii de includere minime se folosesc în principal trei metode: metoda falșilor cei mai apropiați vecini și cea a saturației invarianților atractorului și metoda descompunerii în valori singulare.

Metoda falșilor cei mai apropiați vecini se bazează pe proprietatea generală a atractorului menționată anterior și anume că punctele îndepărtate în spațiul original al fazei sunt apropiate în spațiul reconstruit (vecini apropiați falși), dacă dimensiunea de includere este aleasă incorect.

Dimensiunea de includere minimă se mai poate determina și prin metoda saturării invarianților atractorului. Această tehnică se bazează pe faptul că, odată atractorul desfășurat complet, dimensiunea fractală a acestuia este independentă de dimensiunea de includere. Prin urmare, atunci când atractorul este reprezentat într-o dimensiune de includere incorectă, dimensiunea acestuia este dependentă de dimensiunea de includere.

Pentru determinarea întârzierii se folosește metoda informației mutuale și metoda funcției de autocorelație.

Modelarea hibridă ARIMA – rețele neuronale

Procesul de determinarea a modelului ARIMA constă din două etape:

- Identificarea – se determină modelul care corespunde cel mai bine comportamentului seriei de timp. În cazul în care seria de timp este afectată de componenta sezonieră, modelul care trebuie determinat se numește SARIMA (Seasonal ARIMA) și se reprezintă ca $ARIMA(p, d, q)(P; D, Q)_s$, unde d și D reprezintă ordinal diferențelor sezoniere și nesezoniere, p și P reprezintă ordinele termenilor autoregresivi sezonieri și nesezonieri, iar q și Q reprezintă ordinal termenilor medie mobilă. S semnifică diferența sezonieră. Determinarea parametrilor modelului se realizează prin studierea graficelor funcție de autocorelație (ACF) și al celei de corelație parțială (PACF).
- Verificarea – constă din evaluarea performanțelor modelului în descrierea comportamentului seriei de timp. Dacă performanțele nu sunt satisfăcătoare se va reveni la etapa anterioară, modificând structura modelului până în momentul în care aceasta devine adecvată capturării dinamicii seriei de timp.

Se consideră consideră seria de timp inițială ca fiind formată dintr-o componentă liniară autocorelată și o componentă neliniară, astfel încât seria de timp inițială poate fi descompusă astfel:

$$y_t = L_t + N_t$$

În urma modelării ARIMA, seria de timp va fi formată din componenta liniară modelată și reziduurile obținute:

$$y_t = L_t^m + e_t$$

Reziduurile obținute vor conține de fapt relațiile neliniare care nu au putut fi capturate prin modelul ARIMA. Componenta neliniară a seriei de timp va fi modelată cu ajutorul unei rețele neuronale de tip perceptron multistrat.

Rețele neuronale Echo state networks

O problemă generală care apare în cazul antrenării rețelelor recurente este aceea că, deoarece ponderile conexiunilor între neuroni au valori variabile, spațiul soluțiilor este vast, iar posibilitatea atingerii unui minim local în locul minimului global, este semnificativă. Rețelele ESN tind să rezolve această problemă, prin antrenarea ponderilor conexiunilor neuronilor dintre rezervor și neuronii din stratul de ieșire. În consecință, rezervoarele care conțin mai puțin neuroni tind să generalizeze mai bine în cazul unor date noi față de rezervoarele cu mai mulți neuroni,

indicând faptul că, la fel ca în cazul rețelelor FNN, poate apărea fenomenul de supraspecializare sau de memorare a rezultatelor . [JAE01]

În problemele de predicție s-a dovedit că rețelele neuronale recurente (cu reacție înapoi) au performanțe superioare rețelelor neuronale feedforward. Performanțele predictive superioare se datorează capacității RNN de a forma modele temporale mai complexe prin utilizarea unităților de întârziere între ieșiri și stratul ascuns. Conexiunile recurente și elementele de întârziere trebuie utilizate în problemele în care informația este corelată temporal deoarece acestea joacă rolul unei memorii pe termen scurt, memorie care, ținând cont de faptul că informația anterioară influențează starea prezentă a rețelei care, la rândul ei, determină valorile viitoare de la ieșirile rețelei, contribuie la îmbunătățirea generalizării și astfel, la obținerea unor foarte bune rezultate în problemele de predicție. Aceleași conexiuni însă, determină creșterea complexității interacțiunii dinamice între neuroni, ceea ce va necesita algoritmi foarte complecși de antrenare a rețelei care converg parțial.

ESN și o altă alternativă la antrenarea și utilizarea rețelelor recurente, Liquid State Machine (LSM) au pus bazele unor tehnici de procesare a datelor incluse în domeniul denumit Reservoir Computing. ESN reprezintă o nouă paradigmă de utilizare a rețelelor neuronale recurente antrenate cu un algoritm de instruire mult mai simplu decât cele clasice. Ideea care a dus la crearea acestui tip de rețea se bazează pe faptul că, în anumite condiții, starea rețelei devine asimptotic independentă de valorile de intrare, influența acestora se diminuându-se în timp.

Ideea de bază de la care s-a plecat în cercetările din domeniul rețelelor ESN implică generarea unei rețele neuronale recurente la ale cărei intrări este prezentat un semnal care determină crearea unui spectru larg de dinamici în rezervorul de neuroni ce formează semnale neliniare de ieșire. Combinația liniară dintre acestea și semnalul de intrare determină obținerea unei funcții de citire, adică a unei predicții a semnalului de ieșire dorit.

Motivul principal al utilizării din ce în ce mai frecvente al acestui tip de rețea neuronală îl constituie algoritmul foarte simplu de învățare. Singurele ponderi care se actualizează sunt cele dintre rezervorul dinamic, figura 6.10 (stratul ascuns) și ieșiri, evitându-se astfel situația în care rețeaua antrenată ajunge într-un punct de minim local, alterându-se astfel calitatea învățării, rezultatele acesteia și mai ales ale generalizării fiind suboptimale[]. Actualizarea selectivă a ponderilor elimină situația în care actualizarea simultană a tuturor ponderilor determină apariția comportamentului haotic al rețelei, caz în care o modificare infimă a valorii intrărilor produce un rezultat complet diferit la ieșirea rețelei. Apariția unui asemenea fenomen împiedică atingerea convergenței rețelei.

Contribuții

Contribuțiile personale sunt următoarele :

1. Realizarea unei sinteze în domeniul foarte vast al analizei și predicției seriilor de timp. Am insistat în special asupra analizei neliniare a seriilor de timp în scopul identificării manifestării haosului conform unei metodologii ce presupune parcurgerea unor etape succesive. În acest scop, am analizat seria de timp corespunzătoare ratei de schimb leu-euro. Deși studiile referitoare la acest tip de problemă abundă și majoritatea pun în evidență existența unei dinamici haotice, în cazul acestei serii de timp nu există indicii care să confirme ipoteza de la care am plecat.
2. Am aplicat metode și tehnici de analiză neliniară asupra seriei de timp a prețului spot a energiei electrice și a seriei de timp a debitelor zilnice în cadrul râului Siret și am evidențiat existența unei dinamici haotice. Dinamica haotică implică existența unei relații cauzale deterministe și garantează posibilitatea predicției pe termen scurt a valorilor viitoare.
3. În cadrul tezei, am realizat o comparație între două tipuri de rețele neuronale care se încadrează în categoria metodelor globale de predicție a seriilor de timp haotice și anume rețeaua de tip MLP (Multilayer Perceptron) și rețeaua SVM (Support Vector Machines) mașini cu vector de suport. M-am axat pe aceste instrumente de predicție deoarece rețeaua MLP este aproximativ universal, putând să învețe relații neliniare între intrări pentru a putea predicționa valorile viitoare. Am testat performanțele acestor două tipuri de rețele neuronale pe un set de trei serii de timp: seria de timp Mackey-Glass, seria de timp Lorenz și cea corespunzătoare evoluției zilnice a prețului spot al energiei electrice. În urma analizei rezultatelor s-a stabilit că rețelele de timp MLP au performanțe mai bune, iar performanțele depind de numărul de intrări al rețelei neuronale.
4. Am demonstrat empiric faptul că, în cazul seriilor de timp haotice, numărul de intrări ale rețelei neuronale MLP, pentru care se obțin predicții optime, trebuie să fie aproximativ egal cu produsul dintre dimensiunea de includere și parametrul de întârziere folosit pentru reconstrucția spațiului stării.
5. Am realizarea unui model neuronal ce permite predicția creșterii sau descreșterii economice având în vedere evoluția individuală a unui set de indicatori. Reprezentarea grafică a evoluției activității într-un sistem de axe xOy poate fi obținută astfel: fiecare formă reprezintă un punct în plan în care x este perioada de timp corespunzătoare formei, iar y este clasa la care aparține forma. Acuratețea reprezentării este funcție de numărul de clase. Această reprezentare presupune mai întâi realizarea unei ordonări a claselor și renumerotarea lor corespunzătoare în sensul de la evoluție negativă către evoluție pozitivă și apoi definirea unei mărimi care caracterizează fiecare clasă. În studiul realizat, am luat în considerare un set de indicatori de descriu performanța economică a României în perioada 2000-2010.
6. Am determinat modelele ale celor două serii de timp aplicând câte două metode de modelare: modelarea hibridă ce implică elaborarea unui model ARIMA valid și utilizarea apoi a unui perceptron multistrat și a doua metodă care implică utilizarea unui tip de rețea neuronală numită rețea neuronală cu ecoul stării (Echo State Network). Am utilizat seria de timp a debitelor zilnice a râului Siret și seria de timp a prețurilor pentru o zi înainte

(spot) a energiei electrice pentru piața din România. Această a doua serie de timp este în mod special mai dificil de modelat deoarece prezintă caracteristici speciale (revenirea la medie, valori atipice, sezonabilitate, prețuri negative).

7. Am conceput un program, scris în limbajul Matlab, pentru simularea rețelelor de timp ESN.

După părerea mea, cercetările viitoare care să extindă pe cele din prezenta teză se pot axa pe următoarele direcții:

- Modelarea seriilor de timp luate în considerare în teză utilizând asimilarea datelor cu ajutorul filtrelor Kalman Unscented și rețele neuronale Wavelet;
- Identificarea haosului și în alte serii de timp corespunzătoare manifestărilor unor procese din lumea reală și stabilirea unor eventuale corelații între apariția haosului și modificări calitative în evoluția sistemului;
- Crearea unui algoritm de predicție care să utilizeze capacitățile combinate ale rețelelor neuronale de tip ESN și ale celor de tip wavelet;
- Identificarea ordinului optim al modelului neuronal utilizat pentru modelarea și predicția seriilor de timp haotice.

Bibliografie

1. [AND00] Andras P., *Rețele neuronale pentru aproximarea și predicția seriilor de timp*, Presa Universitară Clujeană, 2000.
2. [BER10] Bezrutscho, B. P., *Extracting knowledge from time series-An introduction to empirical nonlinear modelling*, Springer, 2010
3. [BOX75] Box E.P., Jenkins G., *Time series analysis, forecasting and control*, San Francisco, Holden Day, 1970.
4. [BRS87] Brandstater A., Swinney L., *Strange attractor in weakly turbulent Couette-Taylor flow*, Phisycal Review A, 1987
5. [BRO98] Brock, W. A. Hommes, C. H., *Heterogeneous beliefs and routes to chaos in a simple asset pricing model*, Journal of Economic Dynamics and Control, Elsevier, vol. 22(8-9), 1998
6. [BDS87] Brock, W. A., W. Dechert, & J. Scheinkman., *A test for independence based on the correlation dimension. Working paper*, University of Winconsin at Madison, University of Houston, and University of Chicago, 1987
7. [BRO98] Brooks. C., *Chaos in Foreign Exchange Markets: A skeptical View*, Computational Economics 11: 265-281, Kluwer Academic Publishers, 1998
8. [BUR04] Burger M., Bernhard K., Muller A., Schindlmayr G., *A spot market model for pricing derivatives in electricity markets*, Journal of Quantitative Finance, vol4(1), 2004.
9. [CAS89] Casdagli M., *Nonlinear prediction of chaotic time series*, Physica D: Nonlinear Phenomena, Volume 35, Issue 3, 1989
10. [CAO97] Cao L., *Practical Method for determining the minimum embedding dimension of a scalar time series*, Physica, 1997
11. [CREE94] Creedy J., *Chaos and Non-Linear Models in Economics: Theory and Applications*, Edward Elgar Publishing, 1994
12. [DDR02] Das, P. Das, A.B. Roy, *Nonlinear data analysis: a comparison between experimental EEG data and theoretical ANN data*, Complexity 7 (3) (2002) 30–40.
13. [DESC01] Deco G., Scurmann B., *Information Dynamics*, Springer Verlag, 2001
14. [DER11] Derek A., *An Introduction to Nonlinearity in Control Systems*, DA& Ventus Publishing ApS 2011
15. [DOH11] Donner R.V., Heitz J., *The geometry of chaotic dynamics – a complex network perspective*, The european journal of Physics B, 2011
16. [EKR87] Eckhman J. P., Kamphorst S. O., Ruelle D., *Recurrence plots of dynamical systems*, Europhysics Letters, 1987.
17. [FAS87] Farmer J. D., and Sidorowich J. J., *Predicting Chaotic Time Series*, Phys. Rev. Lett. 59(8) (1987)
18. [FED02] Federici D., *Chaos and the exchange rate*, Journal of International Trade and Economic Development, Vol. 11, No. 2, pp. 111-142, June 2002
19. [FEI78] Feigenbaum M. J., *Quantitative universality for a class of*

- nonlinear transformation, Journal of Statistical Physics, no. 19.
20. [FRS86] Fraser A., Swinney H., *Independent coordinates for strange attractors from mutual information*, Physical review, vol. 33, 1986
 21. [GCT07] Gao J., Cao Y., Tung W., Hu J., *Multiscale analysis of complex time series. Integration of chaos and Random Fractal Theory and Beyond*, Wiley, 2007
 22. [GON00] Gonzales S., *Neural Networks for Macroeconomical Forecasting: a complementary approach to linear regression model*, 2000.
 23. [GOM05] Gottwald G., Melbourne I., *Testing for chaos in deterministic systems with noise*, Physica D 212, 2005.
 24. [GRP83] Grassberger P. and Procaccia I., *Estimation of the Kolmogorov entropy from a chaotic signal*, Physical Review A, 28(4):2591-2593, October 1983.
 25. [HAI97] Haidu I., *Analiza seriilor de timp. Aplicații în hidrologie*, H*G*A București, 1997
 26. [HAR06] Harvey A., *Forecasting with unobserved components model*, Handbook of economic Forecasting, North Holland 2006
 27. [HAY03] Haykin S., *Neural Networks.*, A Comprehensive Foundation. Prentice Hall, 2003.
 28. [HEN14] Hense A., *On the possible existence of a strange attractor for the southern oscillations*, BPA, 60(1): 34-47,2014.
 29. [HILL00] Hilborn R.C., *Chaos and Nonlinear Dynamics*, second Edition, Oxford University Press, 2000
 30. [HUH07] Huisman R., Huurman C., Mahieu R., *Hourly electricity prices in day – ahead market*, Energy Economics, 29, p. 240-248, 2007
 31. [IWB98] Iwanski S. J., Bradley E., *Recurrence plots of experimental data. To embed or not to Embed*, 1998.
 32. [JACZ01] Jacobus van Zyl, *Modeling chaotic systems with Neural Networks*, 2001
 33. [JAE01] Jaeger H., *The echo state approach to analyzing and training neural networks*, 2001
 34. [JAS11] Jakasa T., Androcec I., Sprcic P., *Electricity price forecasting – ARIMA model approach*, 2011 8th International Conference on the European Energy Market, 25-27 May 2011, Zagreb
 35. [JAY02] Jayawardena A., Li W. K., Xu P., *Neighbourhood selection for local modeling and prediction of hydrological time series*, Journal of Hydrology, 258(2002) 40-57.
 36. [JAL02] Jayawardena A.W, Lai F., *Analysis and Prediction of chaos in rainfall and stream flow time series*, Journal of Hydrology, 153, 1994
 37. [JOP12] Johnsson T., Pinson, P. *Forecasting Electricity Spot Prices Accounting for Wind Power Predictions*, Sustainable Energy, vol. 4 Issue 1, p.210-218, 2012,
 38. [KAH05] Kahn S., Ganguly A. R., Saigal S., *Detection and predictive*

- modeling of chaos in finite hydrological time series, *Nonlinear Processes in Geophysics* (2005),12 (41-53).
39. [KAN04] Kantz H., Schreiber T., *Nonlinear time series analysis*, Cambridge University Press, 2004.
 40. [KAN94] Kanz, H., *A robust method to estimate de maximum Lyapunov exponent of a time series*, *Physics Letter A*, Volume 185, Issue 1, 1994, Elsevier Science.
 41. [KAB99] Kapitaniak T., Bishop S. R., *The illustrated dictionary of nonlinear dynamics and chaos*, John Wiley and Sons, 1999.
 42. [KAC08] Karakasidis E. T., Charakopoulo A., *Detection of low-dimensional chaos in wind time series*, *Chaos Solitons and Fractals* no. 41, Elsevier 2008.
 43. [KASA96] Kasabov N. K., *Foundations of Neural Networks, Fuzzy Systems and Knowledge Engineering*, MIT Press, 1996
 44. [LIYO75] Li T,Y, Yorke J.A, *Period tree implies chaos*, *American Mathematical Monthly*, December 1975.
 45. [ZLI06] Li Z., *Fuzzy chaotic systems, Modeling, Control and Applications*, Springer, 2006
 46. [LIHC06] Li Z., Holang W.A., Chen G., *Integration of Fuzzy Logic and Chaos Theory*, Springer, 2006
 47. [LIE13] Liebl D., *Modeling and forecasting electricity spot prices: a functional data perspective*, *The Annals of Applied Statistics*, vol. 7, no. 3, p. 1562-1592, 2013
 48. [LIEB98] Liebovich L.S., *Fractals and Chaos Simplified for the Life Sciences*, Oxford University Press, 1998
 49. [LOR93] Lorenz D., *The essence of chaos*, University of Washington Press, 1993
 50. [MAC12] Machiwal D., *Hydrologic time series analysis: Theory and Practice*, Springer, 2012, ISBN 978- 94- 007- 1860-9
 51. [MIV09] Morariu N., Iancu E., Vlad S., *Neural Model for time series forecasting*, *Romanian Journal of Economic Forecasting*, *Romanian Journal of Economic Forecasting*, volume 12, issue 4, 2009.
 52. [MORR91] Morrison F., *The Art of Modeling Dynamic Systems: Forecasting for Chaos, Randomness, and Determinism*, John Wiley & Sons, 1991
 53. [MSS92] Myers C., Singer A., Shin F., *Modeling chaotic systems with hidden Markov models*, *IEEE*, 1992
 54. [NEG05] Negnetivski M., *Artificial Intelligence. A guide to intelligent systems*, Addison Wesley, 2005.
 55. [NEGN05] Negnevitsky M., *Artificial Intelligence – A guide to Intelligent Systems*, Addison Wesley, 2005
 56. [OSIN00] Osinga H., *Nonlinear Dynamics and Chaos (Lecture notes)*, 2000
 57. [PAL06] Pai P. F., Lin C. S., *A SVM Regression for Exchange Rate prediction*, *Information and Management Sciences*, Volume 17, Number 2, 2006

58. [PANA06] Panaitescu Gh. M., *Modelarea și simularea sistemelor*, Note de Curs, 2006
59. [PSW00] Perry J.N, Smith R. H, Woiwod I. P., *Chaos in real Data. The analysis of nonlinear dynamics from short ecological time series*, Springer, 2000
60. [POI10] Poincare H., *Science and Method*, Cosimo Inc, 2010
61. [WASS89] Philip D. Wasserman, *Neural Computing – theory and practice*, Van Nostram Reinhold, 1989
62. [POP00] Popescu T., *Serii de timp. Aplicații în analiza sistemelor*, Editura Tehnică, 2000.
63. [POR97] Porporato A., Ridolfi L., *Nonlinear analysis of river flow secvences*, Water Resources Research, volume 33, no. 6, 1353-1367, 1997.
64. [PRG83] Procaccia I., Grassberger P., *Measuring the strangeness of a strange attractor*, Physica D: Nonlinear Phenomena **9** (1-2), 1983
65. [QUIR98] Quiroga R.C., *Quantitative analysis of EEG signals: Time – frequency methods and Chaos Theory*, 1998
66. [SCAM02] Scarlat E., Mărăcine V., *Dinamică Economică, volumul I Dinamica sistemelor haotice*, Matrix Rom, București, 2002
67. [SCH10] Schneider S., *Power spot price models with negative prices*, 2010, <http://mpira.ub-uni-muenchen.de/29958/>
68. [SEVE01] Severance F. L., *System modeling and simulation, An introduction*, John Wiley and Sons, 2001
69. [SGM90] Skinner J. E., Goldberg A., Mayer-Kress G., *Chaos in the heart: Implications for Clinical Cadiology*, Nature Biotechnology, 1990.
70. [SIV02] Sivakumar, B., Persson M., Berndtsson R., and Uvo C. B., *Is correlation dimension a reliable indicator of low-dimensional chaos in short hydrological time series?*, Water Resour. Res., 38(2), 2002.
71. [SISD07] Sivanandam S. N., Sumathi S. and Deepa S. N., *Introduction to Fuzzy Logic using MATLAB*, Spinger, 2007
72. [SIW99] Siwakumar B., *A systematic approach to noise reduction in chaotic hydrological time series*, Journal of Hydrology, 1999.
73. [SIW01] Siwakumar B., Berndtsson R., *Evidence of chaos in rainfall-runoff process*, Journal des Sciences Hydrologiques, 46(1),2001.
74. [SMA05] Small M., *Appiled nonlinear time series analysis. Applications in physics, physiology and finance*, Word Scientific, 2005
75. [SMIT98] Smith P., *Explaining chaos*, CUP, 1998
76. Soren B., *Time series analysis and forecasting by example*, Wiley, 2011
77. [SPRO03] Sprott J. C., *Chaos and Time Series Analisys*, Oxford University Press, 2003
78. [SPRO00] Sprott J. C., *Strange Attractors: Creating Pattern in Chaos*, 2000

79. [SPR03] Sprott J.C., *Chaos and time series analysis*, Oxford University Press, 2003.
80. [STC09] Stan C., Cristescu C., *Dinamici neliniare, haos și zgomot în sisteme experimentale*, Matrixrom, 2009
81. [STRO94] Strogatz S.H., *Nonlinear Dynamics and Chaos with Applications to Physics, Biology, Chemistry and Engineering*, Perseus Books 1994
82. [TAK81] Takens F., *Detecting strange attractors in turbulence in Dynamical systems and turbulence. Lecture notes in mathematics.*, Springer, Berlin, 1971.
83. [THS02] Thompson J.M.T., Steward H.B., *Nonlinear Dynamics and Chaos*, John Wiley and Sons LTD., 2002
84. [UZM10] Unsihuay Vila C., Zambroni de Souza A. C., Maragon J. W., *Lima Electricity demand and spot price forecasting using evolutionary computation combined with chaotic nonlinear dynamic model*, *Electrical Power and Energy Systems* 32(2010).
85. [VIAL05] Vialar T., *Dynamiques non lineaires chaotiques en Finance et Economie*, Economica Paris, 2005
86. [VLA10] Vlad S., *Investigation of Chaotic Behavior in Euro-Leu exchange rate*, *Journal of Applied Computer Science and Mathematics*, ISSN: 2066-4273, 8, 2010.
87. [VLMO07] Vlad S., Morariu N., *Chaos models in Economics*, in press
88. Vlad S., Paul P., Morariu N., *Chaos models in Economics*, în *Models and Applications of Chaos Theory in Modern Sciences*, CRC Press, Taylor and Francis Group, 2011.
89. [VLA09] Vlad S., Pentiu G., *Nonlinear analysis of BETFI Index Time Series Data*, The 8th International Symposium “PROSPECTS FOR THE 3rd MILLENNIUM AGRICULTURE”, Bulletin UASVM nr. 66, 2009.
90. [BRA74] Brass W., *Perspectives in population prediction*, *Journal of Royal Statistical Society*, 1974
91. [WER14] Weron R., *Electricity price forecasting: a review of the state-of-the-art with a look into the future*, *International Journal of Forecasting*, vol. 30, Issue 4, 2014.
92. [WER06] Weron R., *Modeling and forecasting electricity loads and prices – a statistical approach*, Wiley Finance 2006, ISBN 978-0-470-05753-7
93. [WILL97] Williams G.P., *Chaos Theory Tamed*, Joseph Henry Press, 1997
94. [WIN05] <http://winsvm.martinsewell.com/>
95. [WSS85] Wolf A., Swift J. B., Swinney H. L., *Determining Lyapunov exponent from a time series*, *Physica* 16D, 1985, North Holland, Amsterdam
96. [ZAG00] Zaldivar J.M, Gutierrez A., *Forecasting high waters at Venice Lagoon using chaotic time series analysis and nonlinear neural networks*, *Journal of Hydroinformatics*, 02.1, 2000
97. [ZERF99] Zerfus E., *Metode fractale folosite pentru studierea proceselor*

98. [ZHA03] *economice*, Revista Informatica Economica, nr. 9/1999
Zhang G. P., *Time series forecasting using hybrid ARIMA and neural network model*, Neurocomputing 50, p. 159-175, 2003
99. Zhao P., Xing L., Yu J., *Chaotic time series prediction: From one to another*, Physics Letters A, 2009
100. [ZIB03] Zibluth J. P., *Unstable Singularities and Randomness*, Terir Importance in Complexity of Physical, Biological and Social Sciences, Elsevier B.V., 2003
101. [TIS03] ***http://www.mpipks-dresden.mpg.de/~tisean/Tisean_3.0.1/index.html, pachetul de programe pentru analiza neliniară a seriilor de timp TISEAN.
102. [TIP11] Tina Jakasa, Ivan Androcec, Petar Sprcic, *Electricity price forecasting – ARIMA model approach*, 8th International Conference on the European Energz Market, 25-27 May 2011, Zagreb
103. [SEV07] *** *Science et Vie*, Fevrier 2007