

**Academia
Oamenilor de Știință
din România**



**Academy
of Romanian
Scientists**

Add: Splaiul Independenței nr. 54 sector 5, 050094, București, ROMANIA, Cod Fiscal: 5091859
Tel. 00-4021/314.74.91; Fax. 00-4021/314.75.39, Web-site: www.aos.ro, E-mail: aosromania@yahoo.com



UTILIZAREA INTELIGENȚEI ARTIFICIALE ÎN PREDICȚIA DATELOR DIN SISTEMELE AUTOMATIZATE INDUSTRIALE

RAPORT 1 - 28.06.2018

Autor:

A handwritten signature in blue ink, appearing to be 'DI Tudose'.

Șef lucrări dr.ing. Daniela Ioana TUDOSE

Profesor coordonator:

Prof.univ.dr.ing. Miron ZAPCIU

A handwritten signature in blue ink, appearing to be 'Miron Zapciu'.

CUPRINS

METODOLOGIA CERCETĂRII	2
APLICAREA RNA-BP ÎN CAZUL PREDICȚIEI PARAMETRILOR UNUI SISTEM AUTOMATIZAT INDUSTRIAL ..	4
1. Predicția a două variabile de ieșire având o variabilă de intrare.....	5
2. Predicția unei variabile de ieșire având o variabilă de intrare	9
CONCLUZII	12
BIBLIOGRAFIE	13

METODOLOGIA CERCETĂRII

În această etapă a fost considerat un studiu de caz /sistem, ce constă dintr-o masa rotativă care are o singură axă ce poate fi controlată și anume axa de rotație a arborelui motorului electric de acționare (ME).

Parametrii măsurăți sunt prezentați în Tabelul 1:

Tabelul 1. Parametrii măsurăți

Denumire	Simbol	UM
timp	t	[ms]
turație	n	[rot/min]
poziția	α	[°]
cuplu	M	[Nm]
putere consumată	P	[kW]
tensiune	U	[V]
frecvență	f	[Hz]
temperatura ME	T	[°C]

Caracteristicile experimentului sunt prezentate în Tabelul 2.

Tabelul 2. Caracteristicile experimentului

Nr. Măsuratori efectuate	Timp [ms]	Greutate Masă Rotativă [gr]	Nr. Măsuratori selectate	Nr. balansuri [-20, 20] ale mesei rotative
12891	51560	0	160	2
11786	47140	500	161	2
12275	49096	4500	189	2.5

Seturile de date de intrare selectate (nr. măsurători selectate), pentru fiecare greutate a mesei rotative, sunt din grad în grad. Sistemul de achiziții de date a realizat pentru două grade între 13 și 1750 măsurători. Numărul de măsurători între două grade consecutive depinde de stabilitatea sistemului reprezentat de greutatea și poziția mesei rotative.

Pentru predicție se utilizează softul Visual Gene Developer 1.7 (VGD) [45] – RNA cu propagare înapoi (backpropagation - BP).

Seturile de date selectate pentru cele 3 greutăți ale mesei rotative sunt utilizate ca și variabile de intrare și ieșire pentru stratul de intrare, respectiv de ieșire al RNA. Dorim să determinăm gradul de generalizare al unei anumite arhitecturi a RNA pentru predicție. De exemplu, să aflăm dacă arhitectura specifică a RNA pentru o rotire a mesei rotative în domeniul $[0^0, -20^0]$ este valabilă și pentru $[-20^0, 0^0]$ precum și extinderea la celelalte greutăți adăugate mesei rotative de 500 [gr] și 4.500 [gr].

În această lucrare este propus un model de predicție utilizând RNA-BP, fiind necesare parcurgerea următoarelor etape:

1. Stabilirea variabilelor de intrare pentru stratul de intrare.
2. Stabilirea variabilelor de ieșire pentru stratul de ieșire pentru care se dorește predicția.
3. Stabilirea caracteristicilor RNA-BP: număr straturi ascunse, număr noduri per strat ascuns, rata de învățare, funcția de transfer, număr de cicluri de instruire (se realizează prin experimentare).
4. Instruirea și validarea arhitecturii RNA-BP.
5. Utilizarea arhitecturii RNA-BP validate în predicția parametrilor la celelate două greutateți ale mesei rotative de 500 [gr] și 4.500 [gr].

APLICAREA RNA-BP ÎN CAZUL PREDICȚIEI PARAMETRILOR UNUI SISTEM AUTOMATIZAT INDUSTRIAL

S-a realizat un stand experimental alcătuit dintr-o masă rotativă ce cuprinde următoarele elemente: ansamblul mesei rotative, motorul electric Siemens 1FK7042-5AF71-1FH0, convertizorul SINAMICS S120 6SL3040-1LA01-0AA0, sursa SITOP PSU200M 6EP1333-3BA10 și diferite siguranțe [46]. Ansamblul mesei rotative a fost realizat din aluminiu, iar acesta împreună cu motorul electric au o greutate totală de 35 [kg]. Partea mobilă a mesei rotative are o masă totală de 11,5 [kg]. În Figura 1 este prezentat standul experimental.




Figura 1. Standul experimental

Secvențele de poziție α sunt următoarele:

- a) α pentru masă 0 [gr]: -1_-20_0_20_0_-20_0_20_0;
- b) α pentru masă 500 [gr]: 0_-20_0_20_0_-20_0_20_0;
- c) α pentru masă 4.500 [gr]: -9_-20_0_20_0_-20_0_20_0_-18_-6_-13;

Predicția se realizează cu următoarele arhitecturi de RNA (Figura 2):

- A. o variabilă de intrare și două variabile de ieșire (a));
- B. o variabilă de intrare și o variabilă de ieșire (b)).




Figura 2 Arhitectura RNA-BP utilizate în experimentul de predicție

Tabelul 1 Caracteristicile RNA-BP pentru care s-au obținut cele mai bune precizii ale predicției

	Experiment predicție	
	A	B
Tipologia setărilor - Parametrii		
Număr variabile intrare	1	1
Număr variabile ieșire	2	1
Număr straturilor ascunse	5	
Numărul de noduri la primul strat ascuns	10	
Numărul de noduri la al doilea strat ascuns	10	
Numărul de noduri la al treilea strat ascuns	10	
Numărul de noduri la al patrulea strat ascuns	10	
Numărul de noduri la al cincilea strat ascuns	10	
Setările de instruire - Parametrii		
Rata de învățare	0,01	
Momentul de impuls	0,1	
Fucția de transfer	Tangentă Hiperbolică	
Numărul maxim de cicluri de antrenare	175.000	300.000
Eroarea țintă	0,00001	
Metoda de inițializare a pragului	Aleator	
Metoda de inițializare a importanței (greutății)	Aleator	
Intervalul de analiză pentru evoluție (cicluri)	500	
Stările de instruire - Parametrii		
Suma erorilor	0,00332859	0,00047000
Eroarea medie per ieșire per set de date	0,00008321	0,00002350
Timp procesare (sec)	232	873

1. Predicția a două variabile de ieșire având o variabilă de intrare

Setul de date de intrare este reprezentat de valorile măsurate pentru parametrul *putere consumată* iar pentru tensiunea de alimentare a motorului electric și cuplu dorim să aflăm predicția. Instruirea RNA-BP se realizează pentru setul de date din partea stângă.

Tabelul 2 Setul de date de intrare și de instruire

Putere consumată [kW]	Tensiune [V]	Cuplu [Nm]	Putere consumată [kW]	Tensiune [V]	Cuplu [Nm]
0,00000000	0,00000000	-0,00036905	0,03425755		
0,00099230	0,06328006	-0,03128152	0,02786221		
0,00121498	0,05120925	-0,03313291	0,02665282		
0,00356930	0,08037100	-0,05088685	0,02119440		
0,00527461	0,06824102	-0,06642690	0,01504110		
0,00631492	0,06855066	-0,07572371	0,01780396		
0,00923714	0,08535340	-0,09858611	0,01440219		
0,01455119	0,10388416	-0,11737162	0,01045006		
0,01462487	0,08717130	-0,12936966	0,01334459		
0,01738447	0,10607197	-0,14048848	0,00677833		
0,01744896	0,10320084	-0,14552225	0,00976990		
0,01517768	0,09230233	-0,13326703	0,00324468		
0,02514975	0,12621210	-0,16965181	0,00493979		
0,02508267	0,11777279	-0,17351912	0,00123903		
0,03309459	0,13318257	-0,20274467	0,00302142		
0,03103888	0,12940058	-0,19771177	0,00004840		
0,04294271	0,16116758	-0,23547153	0,00102315		
0,03566536	0,13826797	-0,20900552	-0,00007276		
0,04985620	0,16050680	-0,24684658			

Setul de date de intrare și de instruire corespunde pentru o deplasare a poziției mesei rotative $\alpha = [0, \dots, -20]$, iar predicția se realizează pentru o deplasare a poziției mesei rotative $\alpha = [-20, \dots, 0]$.

Tabelul 3. Comparație între setul de date măsurat și cel predicționat

Măsurat		Predicționat	
Tensiune [V]	Cuplu [Nm]	Tensiune [V]	Cuplu [Nm]
0,134066	-0,212067	0,134489	-0,202501
0,120079	-0,189134	0,122700	-0,180983
0,120977	-0,181048	0,120483	-0,176648
0,115145	-0,161574	0,110484	-0,155619
0,093379	-0,138491	0,098307	-0,127471
0,101379	-0,151713	0,104041	-0,140883
0,108755	-0,136701	0,096875	-0,124143
0,079872	-0,113673	0,086525	-0,101105
0,093904	-0,124415	0,094383	-0,118414
0,074862	-0,085062	0,073200	-0,074743
0,084545	-0,102189	0,084391	-0,096634
0,061025	-0,057589	0,054827	-0,043197
0,082670	-0,073983	0,064467	-0,059192
0,045589	-0,034513	0,041093	-0,021979
0,058479	-0,052878	0,053429	-0,040962
0,043454	-0,009432	0,031597	-0,008117
0,061913	-0,030280	0,039450	-0,019539
0,034408	0,008359	0,030571	-0,006650
1,514503	-1,846382	1,441311	-1,698779

Concluzia 1:

- a) eroarea pentru parametrul **tensiune** între măsurat și predicționat este de **5,08%**.
- b) eroarea pentru parametrul **cuplu** între măsurat și predicționat este de **8,69%**.

Caracteristicile RNA-BP pentru care s-a obținut această predicție sunt următoarele:

Tabelul 4 Caracteristicile coeficientului de regresie pentru 0 [gr]

Categorie	Variabila de ieșire	Coef. de regresie	Panta	Interceptarea axei - y
Instruire	tensiune	0,923	0,938249	0,00409611
Instruire	cuplu	0,996	1,010523	0,00473886

Coeficientul de determinare fiind la pătrat, r^2 , este întotdeauna un număr pozitiv și variază între 0 și 1. Cu cât valoarea coeficientului de determinare este mai apropiată de valoarea maximă 1, cu atât variația variabilei de răspuns poate fi explicată prin variabile explicative, diferența putând fi atribuită unor variabile necunoscute sau variabile inerente [47]. Coeficienții de regresie pentru cei doi parametri au valori de peste 0,92 fapt ce denotă că variația variabilei de răspuns poate fi explicată prin variabile explicative într-un procent de peste 92%. Se remarcă faptul că coeficientul de regresie pentru cuplu are o valoare apropiată de 1.

Concluzia 2: făcând comparație între erori și coeficientul de regresie se observă următoarea situație:

- ↳ Tensiune: eroare 5,08 % cu un coeficient de regresie de 0,923;
- ↳ Cuplu: eroare 8,69 % cu un coeficient de regresie de 0,996.

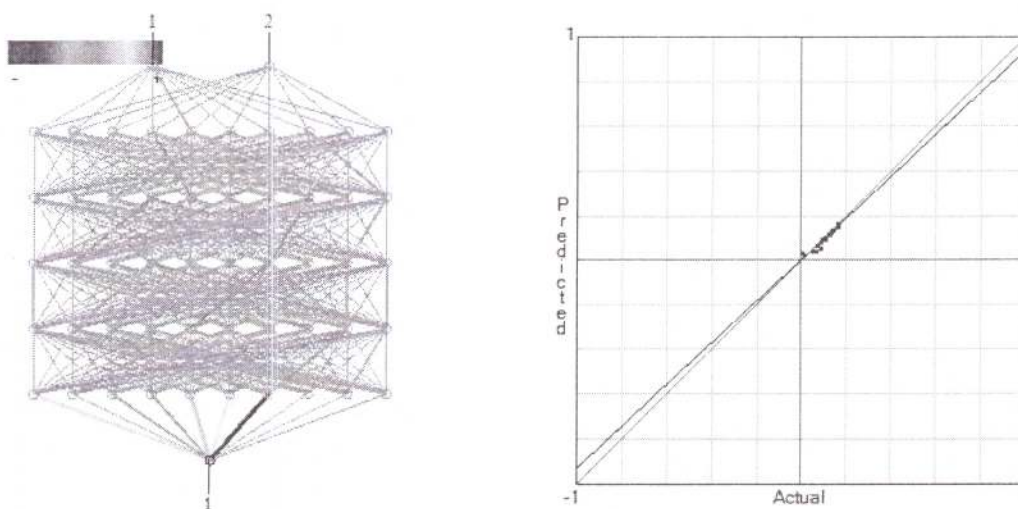


Figura 3 Arhitectura RNA-BP, fluxul de date intrare-ieșire și dispunerea setului de date predicționat pe panta de regresie pentru masa rotativă de 0 [gr]

RNA-BP utilizează un flux de date cuprins aproximativ între $\pm 0,75$, ($-0,75$ – flux negativ evidențiat cu albastru și $0,75$ – flux pozitiv evidențiat cu portocaliu).

Concluzia 3: pentru predicționarea a două variabile pentru un balans $\alpha = [0, \dots, -20, \dots, 0]$ al mesei rotative se obține o **precizie de peste 90%** (eroare sub 10%).

În continuare utilizăm această arhitectură de RNA-BP cu 175.000 de cicluri de instruire pentru predicția *tensiunii* și *cuplului* în cazul meselor de 500 [gr] și 4.500 [gr] pentru același balans, respectiv $\alpha = [0, \dots, -20, \dots, 0]$.

Tabelul 5 Caracteristicile coeficientului de regresie pentru 500 [gr]

Categorie	Variabila de ieșire	Coef. de regresie	Panta	Interceptarea axei - y
Instruire	tensiune	0,9267	0,92971	0,00670843
Instruire	cuplu	0,9957	1,00369	0,00276906

Concluzia 4:

- eroarea pentru parametrul **tensiune** între măsurat și predicționat este de **12,02%**.
- eroarea pentru parametrul **cuplu** între măsurat și predicționat este de **8,51%**.

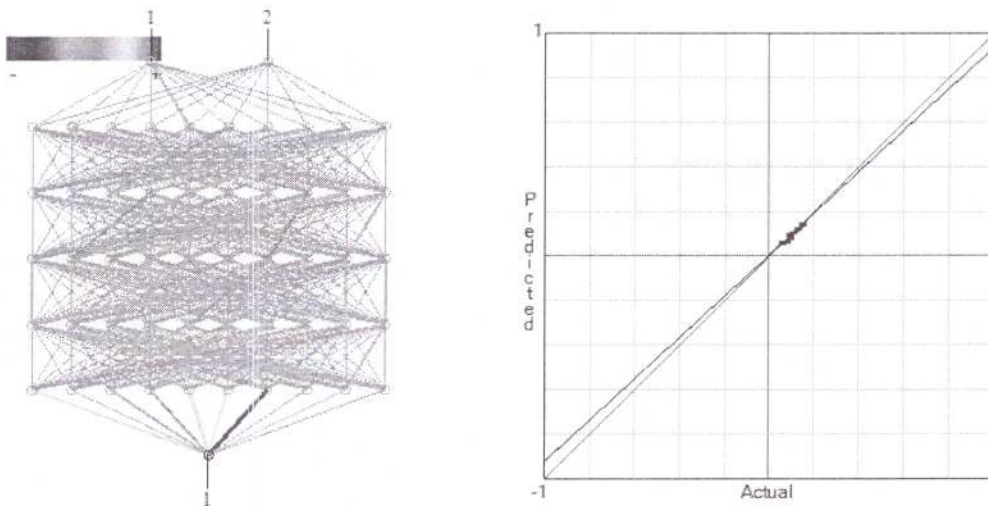


Figura 4 Arhitectura RNA-BP, fluxul de date intrare-ieșire și dispunerea setului de date predicționat pe panta de regresie pentru masa rotativă de 500 [gr]

Tabelul 6 Caracteristicile coeficientului de regresie pentru 4.500 [gr]

Categorie	Variabila de ieșire	Coef. de regresie	Panta	Interceptarea axei - y
Instruire	tensiune	0,5323	0,41752	0,03875933
Instruire	cuplu	0,1704	0,13223	-0,02502337

Concluzia 5:

- eroarea pentru parametrul **tensiune** între măsurat și predicționat este de **0,009%**.
- eroarea pentru parametrul **cuplu** între măsurat și predicționat este de **1,614%**.




Figura 5 Arhitectura RNA-BP, fluxul de date intrare-ieșire și disponerea setului de date predicționat pe panta de regresie pentru masa rotativă de 4.500 [gr]

Concluzie generală I, deoarece:

- a) eroarea pentru parametrul **tensiune** între măsurat și predicționat este în domeniul 0,009-12,02 [%].
- b) eroarea pentru parametrul **cuplu** între măsurat și predicționat este în domeniul 1,614-8,69 [%].

putem utiliza aceeași arhitectură de RNA-BP pentru a predicționa tensiunea de alimentare și cuplul pentru o masă rotativă cu o greutate cuprinsă între 0 și 4500 [gr] pentru un balans $\alpha = [0, \dots, -20, \dots, 0]$.

2. Predicția unei variabile de ieșire având o variabilă de intrare

La setul de date de intrare și instruire prezentat în Tabelul 2 și la setul de date de ieșire (predicție) prezentat în Tabelul 3 **renunțăm la parametrul tensiune** și utilizăm arhitectura RNA-BP din Figura 2 b) cu caracteristicile prezentate Tabelul 1 experimentul B.

Tabelul 7 Caracteristicile coeficientului de regresie pentru 0 [gr]

Categorie	Variabila de ieșire	Coef. de regresie	Panta	Interceptarea axei - y
Instruire	cuplu	0,9957	0,995629	-0,000566475

Concluzia 6: eroarea pentru parametrul **cuplu** între măsurat și predicționat este de **4,6%**.




Figura 6 Arhitectura RNA-BP, fluxul de date intrare-ieșire și dispunerea setului de date predicționat pe panta de regresie pentru masa rotativă de 0 [gr]

Tabelul 8 Caracteristicile coeficientului de regresie pentru 500 [gr]

Categorie	Variabila de ieșire	Coef. de regresie	Panta	Interceptarea axei - y
Instruire	cuplu	0.9960	1.001503	0.001661217

Concluzia 7: eroarea pentru parametrul **cuplu** între măsurat și predicționat este de **8,64%**.

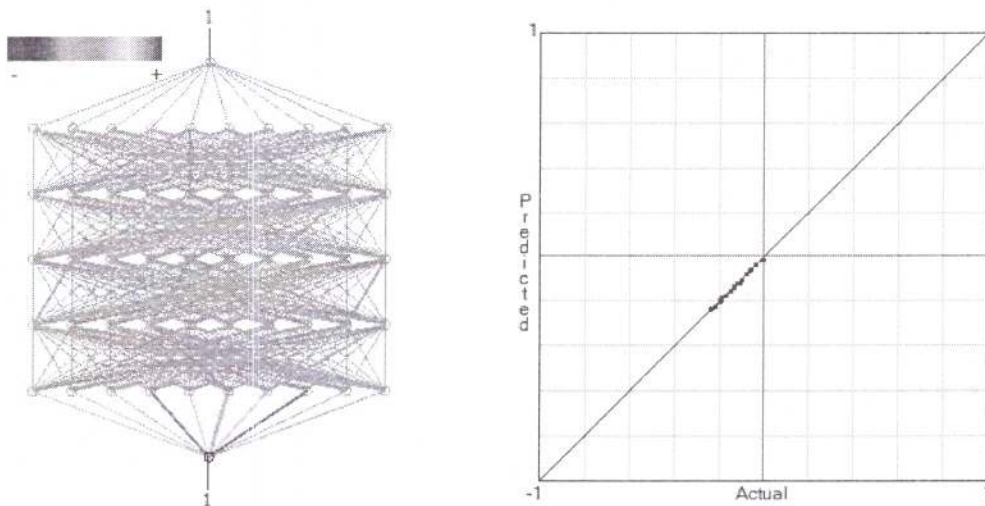


Figura 7 Arhitectura RNA-BP, fluxul de date intrare-ieșire și dispunerea setului de date predicționat pe panta de regresie pentru masa rotativă de 0 [gr]

Tabelul 9 Caracteristicile coeficientului de regresie pentru 4500 [gr]

Categorie	Variabila de ieșire	Coef. de regresie	Panta	Interceptarea axei - y
Instruire	cuplu	0.1720	0.16727	-0.008497994

Concluzia 8: eroarea pentru parametrul **cuplu** între măsurat și predicționat este de **254,54%**.

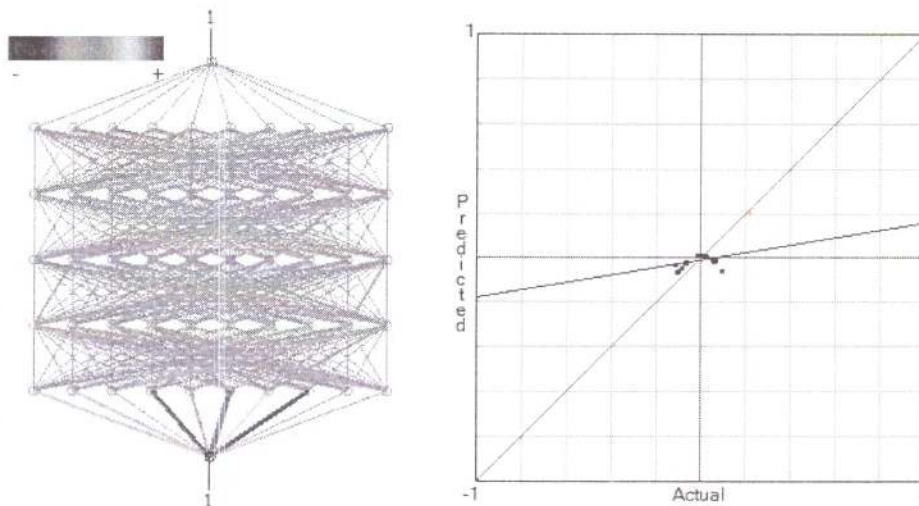


Figura 8 Arhitectura RNA-BP, fluxul de date intrare-ieșire și dispunerea setului de date predicționat pe panta de regresie pentru masa rotativă de 4500 [gr]

Concluzia generală I

Eroarea se datorează faptului că RNA-BP a fost aplicată la $\alpha: -9_{-20_0_20_0_-20_0_20_0_-18_-6_-13}$ (4500 [gr]) deci la a doua efectuare a rotației și nu la prima mișcare. Se observă că poziția α (4500 [gr]) pleacă de la (-9) și nu de la 0, motiv pentru care a fost selectată a doua rotație pentru $\alpha 0_{-20_0}$. Eroarea este susținută de coeficientul de regresie care are o valoare extrem de mică (0,172) și dispunerea finală a valorilor pe panta de regresie (forma de semicerc nu de linie cum este normal). În primul caz, cu utilizarea a doi parametri de ieșire, a reușit să obțină predicția către valorile reale.

Concluzia generală II

Eroarea pentru parametrul **cuplu** între valorile măsurate și predicționate este situată în domeniul **4,6-8,64 [%]** pentru o greutate suplimentară a mesei rotative de 0 [gr] respectiv 500[gr], deci putem utiliza aceeași arhitectură de RNA-BP pentru a predicționa tensiunea de alimentare și cuplul pentru o masă rotativă cu o greutate cuprinsă între 0 și 500 [gr] pentru o mișcare de rotație $\alpha = [0, \dots, -20, \dots, 0]$.

CONCLUZII

Se observă, din studiul de caz prezentat, că alegerea setului de date supus analizei trebuie să fie realizat pe baza mai multor considerații, asigurând interdependențele dintre parametri, dar și a modului cum aceștia se influențează reciproc.

Studiul bazat pe RNA-BP, pentru predicția a 1 sau 2 parametri, a demonstrat că poate fi utilizată aceeași arhitectură și caracteristici pentru seturi de date cu valori apropiate, pentru aceeași mișcare de rotație și greutateți diferite ale mesei rotative.

Eroarea obținută în acest studiu este de aproximativ 10% și un coeficient de regresie în majoritatea cazurilor de peste 0,92.

Există cazuri când utilizarea unui sigur parametru de ieșire extras dintr-un set de parametri, aflați într-o interdependență foarte puternică, să conducă la erori grosolane așa cum a fost prezentat în exemplul de mai sus.

Se evindețiază faptul că, în primul caz studiat, utilizarea a doi parametri de ieșire a reușit să obțină o predicția relativ bună.

Se va încerca, în continuare, îmbunătățirea predicției și considerarea unor date de intrare certe, determinate experimental.

BIBLIOGRAFIE

- [1] <https://cs.stanford.edu/people/eroberts/courses/soco/projects/neural-networks/History/history1.html>
- [2] D. Michie, D.J. Spiegelhalter, C.C. Taylor, *Machine Learning, Neural and Statistical Classification*, Ellis Horwood, New York, 1994, ISBN 013106360X, 9780131063600, <https://www1.maths.leeds.ac.uk/~charles/statlog/whole.pdf>
- [3] Swati Aggarwal, Ranjit Biswas, A.Q.Ansari, *Neutrosophic Modeling and Control*, International Conference on Computer and Communication Technology, 2010, DOI: 10.1109/ICCCT.2010.5640435, https://www.researchgate.net/publication/231521008_Neutrosophic_Modeling_and_Control
- [4] Ioan Dzițac, *Inteligență Artificială*, Editura Universității "Aurel Vlaicu", Arad, 2008, ISBN 978-973-752-292-4 004.42, http://www.uav.ro/files/exacte/cursuri/Inteligenta_artificiala_Dzitac.pdf
- [5] Bălan C. George, http://www.mrm.ugal.ro/balan_site/e-books/miassm-pdf/cap.1.pdf
- [6] Ramin Shamshiri, Wan Ishak Wan Ismail, *Design and Simulation of Control Systems for a Field Survey Mobile Robot Platform*, Research Journal of Applied Sciences, Engineering and Technology 6(13): 2307-2315, 2013, ISSN: 2040-7459; e-ISSN: 2040-7467, https://www.researchgate.net/publication/259932485_Design_and_Simulation_of_Control_Systems_for_a_Field_Survey_Mobile_Robot_Platform
- [7] Thiang St, Handry Khoswanto, Rendy Pangaldus, *Artificial Neural Network with Steepest Descent Backpropagation Training Algorithm for Modeling Inverse Kinematics of Manipulator*, World Academy of Science, Engineering and Technology Vol. 60, 2009, https://www.researchgate.net/publication/43649867_Artificial_Neural_Network_with_Steepest

Descent Backpropagation Training Algorithm for Modeling Inverse Kinematics of Manipulator

[8] Dosoftci Constantin-Cătălin, *Utilizarea inteligenței computaționale în conducerea proceselor*, Teză de doctorat, Universitatea tehnică Gh.Asachi, Iași, 2009, <http://www.ace.tuiasi.ro/users/103/2009-Dosoftci%20Catalin%20PhD%202009.pdf>

[9] Uve Windhort, Hakan Johansson, *Modern techniques in neuroscience research*, Springer-Verlag Berlin Heidelberg 1999, ISBN 978-3-642-63643-1, ISBN 978-3-642-58552-4 (eBook), DOI 10.1007/978-3-642-58552-4, <https://books.google.ro/books?id=xfXsCAAQBAJ&pg=PA592&lpg=PA592&dq=Static+neuron+is+the+simplest+model+of+artificial+neuron&source=bl&ots=luOYwdAvl-&sig=jq20kt30bmtV-UUKBPz4gyg8hqw&hl=ro&sa=X&ved=0ahUKEwjOwsSc5MrVAhUCshQKHf5LAgIQ6AEIWDAH#v=onepage&q&f=false>

[10] Daniela Danciu, *Probleme calitative în dinamica rețelelor neuronale*, Teză de doctorat, Universitatea din Craiova, 2003, <http://www.automation.ucv.ro/Romana/membri/Daniela%20Danciu/DDRezumato.pdf>

[11] Ciocoiu Iulian-Aurelian, *Curs, Cap.2 Caracteristici fundamentale ale rețelelor neurale artificiale*, http://scs.etc.tuiasi.ro/iciocoiu/courses/DSP/course5/capitol2_NN.pdf

[12] Klaus Debes, Alexander Koenig, Horst-Michael Gross, *Transfer Functions in Artificial Neural Networks. A Simulation-Based Tutorial*. Supplementary Material for urn:nbn:de:0009-3-1515, <http://www.brains-minds-media.org/archive/151/supplement/bmm-debes-suppl-050704.pdf>

[13] Laura Dioșan, *Inteligență artificială. Curs 9*, Universitatea Babeș-Bolyai, 2013, http://www.cs.ubbcluj.ro/~lauras/test/docs/school/IA/lectures2013/lectures/09_10_ML_ANN.pdf

[14] Masahiko Morita, Shuji Yoshizawa, Kaoru Nakano, *Memory of Correlated Patterns by Associative Neural Networks with Improved Dynamics*, The International Neural Network Society (INNS), the IEEE Neural Network Council Cooperating Societies ISBN: 978-0-7923-0831-7 (Print) 978-94-009-0643-3 (Online), https://link.springer.com/chapter/10.1007/978-94-009-0643-3_115