

MOGUĆNOST PRIMENE VEŠTAČKIH NEURONSKIH MREŽA SA MALIM SETOM PODATAKA PRI MODELOVANJU RAVNOMERNOSTI KRETANJA KLIZAČA MAŠINA ALATKI**THE POSSIBILITY OF APPLYING AND USING SMALL DATASET IN MODELING THE UNIFORMITY MOVEMENT OF THE MACHINE TOOLS SLIDERS**Dejan Marinković, Aleksandar Živković, *Fakultet tehničkih nauka, Novi Sad***Oblast – MAŠINSTVO**

Kratak sadržaj – U ovom radu prikazana je analiza eksperimentalnih rezultata primenom veštačkih neuronskih mreža. Na osnovu dobijenog plana eksperimenta po Tagučiji planu izvršena su eksperimentalna ispitivanja na opitnom uređaju. Nakon toga izvedena je obrada rezultata pomoću sistema veštačkih neuronskih mreža sa variranim brojem ulaza i jednim izlazom.

Ključne reči: Veštačka inteligencija, Veštačke neuronske mreže, NU mašine alatke

Abstract – This paper presents the analysis of experimental results using artificial intelligence. Based on the obtained experimental plan according to Taguchi, the experiment was performed on a test device. After that, the results were processed using a system of artificial neural networks with a varied number of inputs and one output.

Keywords: Artificial intelligence, Artificial neural networks, NU machine tools

1. UVOD

Oblast veštačke inteligencije prvi put se javlja nekoliko godina nakon istraživanja Alana Tjuringa i njegovog testa za mašine („*Turing Test for machines*“). Zvanično je ovaj termin pomenut na naučnoj konferenciji 1956. godine na Darmut koledžu, a sve to od strane naučnika Džona Makartija koji se smatra začetnikom ove discipline. Tada je termin veštačka inteligencija („*Artificial Intelligence*“) definisana kao oblast računarske nauke koja za cilj ima razvijanje kompjuterskih programa i aplikacija koje bi imale sposobnosti nalik ljudskim kognitivnim sposobnostima [1]. Istaživanje veštačkih neuronskih mreža („*Artificial neural networks*“) kao jedne od disciplina veštačke inteligencije počelo je pedesetih godina prošlog veka. Osnovna ideja bila je kreiranje sistema koji funkcioniše na principu ljudskog nervnog sistema. Kao što nam je poznato, ljudske nervne ćelije imaju sposobnost pamćenja, pa se razvoj sistema veštačkih neuronskih mreža temeljio na istom. Veštačke neuronske mreže nisu razvijane za primenu u jednoj oblasti, već imaju više različitih namena, funkcija i mogućnosti [2].

NAPOMENA:

Ovaj rad proistekao je iz master rada čiji mentor je bio dr Aleksandar Živković, vanr. prof.


2. DEFINISANJE PARAMETARA KOJI UTIČU NA RAVNOMERNOST KRETANJA KLIZAČA MAŠINA ALATKI

Pri eksperimentalnom ispitivanju ravnornosti kretanja klizača mašina alatki varirani su sledeći uticajni parametri:

- materijal klizača,
- vrsta ulja za podmazivanje,
- pogonska brzina (v),
- površinski pritisak (p),
- krutost pogona (C).

Pri izvođenju eksperimenta u obzir su uzeti prethodno navedeni faktori, što ne znači isključivo da oni vrše uticaj na pojavu stick-slip-a. Faktori poput hrapavosti kliznih površina, mase klizača mogu biti od velikog uticaja na rezultate eksperimenta, dok kao materijal klizača u eksploataciji često koristi sivi liv, koji pri izvođenju ovog eksperimenta nije bio pristupačan.

Kada se govori o mašinskom inženjerstvu neravnomerno kretanje javlja se kod kretanja klizača mašina alatki. U mnogim radovima je objašnjeno da se stvaranje neravnomernog kretanja najčešće vezuje za pojavu samooscilacija mašine, kada krutost mehanizma nije dovoljna i razlike koeficijena trenja mirovanja i kretanja, što se javlja pri mešovitom trenju. Da bi sistem bio pouzdan i pri velikim ubrzanjima klizača moraju postojati odgovarajuće karakteristike pogonskog motora, dok tačnost pozicioniranja pri određenim spoljnim faktorima zavisi od osobina sistema za prenošenje kretanja od pogonskog motora na klizač, kao i od karakteristika vodećih elemenata mašine. Prema tome konstrukciono rešenje treba da obezbedi najmanje opterećenje sistema unutrašnjim silama koje nastaju zbog pojave trenja na površinama sa relativnim kretanjem [3].



Slika 1. Dijagram pojave neravnomernog kretanja (stick-slip-a) prilikom klizanja [4]

3. PLAN EKSPERIMENTA TAGUČI METODOM I OPIS OPITNOG UREĐAJA


Nakon definisanja parametara eksperimenta i njihovih nivoa, određen je i plan eksperimenta po metodi Tagučić. Pri izvođenju eksperimenta postoje upravljani i neupravljani parametri. Upravljani parametri su oni koje se mogu kontrolisati, a neupravljani parametri tzv. parametari šuma predstavljaju parametare koji su teški za identifikaciju i kontrolu. U tabeli 1 prikazani su ulazni upravljani parametri i njihovi nivoi na osnovu kojih je definisan plan eksperimenta, ortogonalni niz po Tagučiću, $L_{36} (2^2 \text{ i } 3^3)$. Plan eksperimenta dobijen je korišćenjem odgovarajućeg softvera [8].

Tabela 1. *Ulazni parametri i njihovi nivoi*

Parametri	Nivoi		
	1	2	3
Brzina klizača v [mm/min]	2	10	18
Površinski pritisak p [N/mm ²]	0,0266	0.1133	0.2
Krutost pogona C [N/mm]	200	300	400
	1	2	
Materijal klizača	Tarcit	Č.1530	
Vrsta ulja za podmazivanje	Fampol KS 68	Famcirkol 3	

Za merenje i detektovanje neravnomernog kretanja klizača mašine alatke korišćena je sledeća instrumentacija, prikazana na slici 2:

- pojačivač mernih signala Hottinger Baldwin Messtechnik KWS/6A-5
- PC računar za obradu podataka
- induktivni senzor (davač) položaja Hottinger Baldwin Messtechnik W1T/2
- dinamometar Hottinger Baldwin Messtechnik Q3
- frekventni regulator za promenu opsega brzina kretanja klizača – Danfoss FC302
- kartica za konverziju analognog signala u digitalni - National Instruments NI USB-6281



Slika 2. *Merna instrumentacija*

Kada se eksperiment planira prema Tagučić planu izvodi se manipulacija faktora šuma da bi se izazvala promena i pomoću dobijenog rezultata prepoznala optimalna podešavanja upravljanih faktora koji čine proces ili sam proizvod robustnim ili otpornim na promene izazvane faktorima šuma. Upravljani faktori su oni kojima je

moguće upravljati ili ih kontrolisati, a neupravljani faktori tzv. faktori šuma predstavljaju one faktore koji su teški za identifikaciju i kontrolu. Prema Tabeli 1 na osnovu faktora i njihovih nivoa koji su prikazani izabran je Tagučić $L_{36} (2^2 \text{ i } 3^3)$ ortogonalni niz. Plan eksperimenta dobijen je korišćenjem softvera Minitab i prikazan je u Tabeli 2. Kolone u Tabeli 2 označavaju ulazne parametre i njihove nivoe, sa druge strane redovi prikazuju broj eksperimenata [8].

Tabela 2. *Tagučić ortogonalni niz $L_{36} (2^2 \text{ i } 3^3)$*

R. br	Kod faktora				
	Materijal (M)	Ulje (U)	Brzina (B)	Pritisak (P)	Krutost (K)
1	1	1	1	1	1
2	1	1	2	2	2
3	1	1	3	3	3
4	1	1	1	1	1
5	1	1	2	2	2
6	1	1	3	3	3
7	1	1	1	1	2
8	1	1	2	2	3
9	1	1	3	3	1
10	1	2	1	1	2
11	1	2	2	2	1
12	1	2	3	3	3
13	1	2	1	2	3
14	1	2	2	3	1
15	1	2	3	1	2
16	1	2	1	2	3
17	1	2	2	3	1
18	1	2	3	1	2
19	2	1	1	2	1
20	2	1	2	3	2
21	2	1	3	1	3
22	2	1	1	2	2
23	2	1	2	3	3
24	2	1	3	1	1
25	2	1	1	3	2
26	2	1	2	1	3
27	2	1	3	2	1
28	2	2	1	3	2
29	2	2	2	1	3
30	2	2	3	2	1
31	2	2	1	3	3
32	2	2	2	1	1
33	2	2	3	2	2
34	2	2	1	3	1
35	2	2	2	1	2
36	2	2	3	2	3

Nakon analize rezultata eksperimentalnog ispitivanja po metodi Tagučić određen je procentualni uticaj materijala klizača, površinskog pritiska, brzine klizača, krutosti pogonsko-prenosnog sistema i vrste ulja za podmazivanje.

Navedeni uticaj pojedinačno iznosi respektivno 46,42%; 18,59%; 5,76%; 4,23%, 0,09%; dok greška eksperimenta iznosi 24,91%. Relativno velika greška eksperimenta ukazuje na moguću potrebu usavršavanja opitnog uređaja. Jedna od mogućnosti su zavojna vretena koja sa navrtkom imaju klizni spoj, da se ugrade zavojnih vretena i navrtke sa recirkulacijom kuglica.

Na ovaj način će se smanjiti pojava šuma eksperimenta koji nastaje zbog sprege između navrtke i zavojnog vretena [5].

4. DEFINISANJE MODELA PRIMENOM VEŠTAČKE NEURONSKE MREŽE

4.1. Definisane ulaznih parametara

U ovom radu je primenjena višeslojna neuronska mreža (MLP) sa prostiranjem signala unapred (*feedforward*) i prostiranjem greške unazad (*backpropagation*). Obučeni su veliki broj neuronskih mreža, nakon čega su izabrane one sa najboljom performansom. Analizirani su modeli koji imaju različite strukture ulaznih parametara. Pored različitih struktura ulaznih parametara analizirane su različite arhitekture neuronskih mreža, od onih sa jednim skrivenim slojem sa nekoliko neurona do mreža sa više skrivenih slojeva. Obuka je sprovedena za različite algoritme obuke, a to su *Levenberg – Marquardt (LM)*, *Bayesian Regularization (BR)*, *Scaled Conjugate Gradient (SCG)*. Struktura ulaznih parametara je definisana problemom koji se želi istražiti. Ulazni parametri su definisani u Tabeli 1, a izlazni parametar je maksimalna amplituda pomeranja (Y). Pri formiranju neuronske mreže, jedan od koraka zahteva izbor načina raspodele podataka na skupove. Podatke je potrebno podeliti na skup za obuku (*training set*), skup za validaciju (*validation set*) i skup za testiranje tokom obuke (*test set*). U ovom radu formirani su skupovi prema planu eksperimenta (Tabela 1 i Tabela 2). Ukupan broj eksperimenata je iznosio 36, pri čemu su 4 izdvojena za testiranje nakon obuke i ocenu performansi mreže. Preostala 32 eksperimenta se deli na 22 za obuku, 5 za validaciju i 5 za testiranje.

Podela podataka na skupove za obuku, validaciju i testiranje se često izvodi na slučajni način (*random*), pri čemu mreža tokom obuke proizvoljno bira obučavajuće parove za obuku, validaciju i testiranje. Izborom podataka na slučajni način ulazni parametri budu dodeljeni svakom skupu (obuka, validacija, test) i mreža veoma brzo određuje skup odgovarajućih težinskih koeficijenata i završava obuku. Ovo dovodi do tzv. podtreniranosti mreže, odnosno, obuka je završena suviše rano. Iz tog razloga u ovom radu primenjena je raspodela podataka kod koje je moguće proizvoljno definisati skupove za obuku, validaciju i testiranje. Iz tabele 1 su izdvojeni eksperimenti pod red. br. 2, 14, 21 i 34, kako ih mreža ne bi videla i koji su kasnije iskorišćeni za verifikaciju modela.

U tabeli 3 prikazana je definisana struktura i skupovi za obuku neuronske mreže. Ukupan raspoloživ broj obučavajućih parova je 165. Usvojeno je da se obuka izvodi sa prvih 110 obučavajućih parova (22 eksperimenta), sledećih 25 obučavajućih parova (5 eksperimenata) je namenjeno za validaciju, preostalih 25 (5 eksperimenata) je namenjeno za testiranje tokom obuke. Skup za testiranje (verifikaciju) nakon obuke sadrži 20 obučavajućih parova (4 eksperimenta).

4.2 Arhitektura neuronskih mreža

Veštačke neuronske mreže (VNM) se grade po slojevima, pri čemu su ulazni i izlazni sloj neophodni, a broj neurona u ulaznom i izlaznom sloju zavisi od broja parametara na ulazu i izlazu iz mreže. Skriveni slojevi se dodaju između ulaznog i izlaznog. Najčešće se za početni broj slojeva usvaja jedan i ako se utvrdi da nije dovoljan za rešavanje problema dodaju se novi slojevi.

Tabela 3 Struktura ulaznih podataka i skupovi za obuku neuronske mreže

R. br	Kod faktora					
	M	U	B	P	K	
1	1	1	1	1	1	OBUKA
2	1	1	3	3	3	
3	1	1	1	1	1	
21	2	1	3	1	1	VALIDACIJA
22	2	1	1	3	2	
23	2	1	2	1	3	
24	2	1	3	2	1	
25	2	2	1	3	2	
26	2	2	2	1	3	
27	2	2	3	2	1	TESTIRANJE
28	2	2	1	3	3	
29	2	2	2	1	1	
30	2	2	3	2	2	
31	2	2	2	1	2	
32	2	2	3	2	3	

Ne postoje preporuke za izbor arhitekture neuronske mreže za rešavanje konkretnog problema. Najčešće se kreće od najjednostavnije arhitekture koja se usložnjava do trenutka kada su rezultati zadovoljavajući. Pored broja skrivenih slojeva osnovni problem je definisati broj neurona u svakom sloju. Nedovoljan broj neurona u skrivenim slojevima dovodi do nemogućnosti neuronske mreže da reši određen problem. Ukoliko je broj neurona preveliki, mreža ima loše performanse generalizacije, odnosno dolazi do pojave pretreniranosti mreže (*overfitting*).

Broj skrivenih neurona zavisan je od više različitih faktora, od broja ulaza i izlaza, broja parova koji se obučavaju, veličine šuma i greške eksperimenta kod obučavajućih parova, složenosti funkcije greške, grade i algoritma kojim se veštačka neuronska mreža obučava. Broj neurona (n) u skrivenim slojevima može se odrediti na više različitih načina od kojih su neki [6]:

$$n \in [1, N_y]$$

$$n = \frac{2(N_x + N_y)}{3}, \quad (1)$$

$$n < 2N_x, \quad (2)$$

$$n = \sqrt{N_x N_y}, \quad (3)$$

gde je N_x broj ulaznih parametara, a N_y broj izlaznih parametara. Kod mreža sa većim brojem skrivenih slojeva, često se primenjuju arhitekture u obliku „levka“, gde se broj neurona u skrivenim slojevima smanjuje od ulaza ka izlazu iz mreže.

Prema prethodnim preporukama za konkretni slučaj izvršenog eksperimenta preporučeni broj neurona (n) u skrivenim slojevima iznosi od 1 do 10.

5. ANALIZA REZULTATA

U prethodnom delu je navedeno da u literaturi nema preporuke za izbor arhitekture veštačke neuronske mreže za konkretan problem. Poznato je da stepen nelinearnosti problema određuje složenost arhitekture, odnosno problem sa velikim stepenom nelinearnosti zahteva složene arhitekture sa većim brojem neurona u skrivenim slojevima čime se povećava broj težinskih koeficijenata koji se mogu podešavati. U ovom slučaju rešavanju problema se pristupa primenom metode pokušaja i pogrešaka. Kreće se od najjednostavnije arhitekture sa jednim neuronom i nakon obuke ocenjuje se njen kvalitet primenom na podatke koji nisu bili uključeni u proces obuke. Zbog velikog broja analiziranih podataka ovde će biti prikazani pojedini rezultati sa analize za *Scaled Conjugate Gradient (SCG)* algoritam obuke za različite brojeve neurona u jednom skrivenom sloju.

Tabela 4. Zavisnost kumulativne vrednosti Pearson-ovog koeficijenta korelacije (R), koeficijenta determinacije (R^2) i prosečne greške predviđanja (ϵ_{sr}) od broja neurona

Broj neurona	R	R^2	ϵ_{sr} %
1	2.335	2.015	16.8
2	2.615	2.435	11.1
6	2.636	2.484	12.2
10	2.624	2.452	12.6

Minimalna prosečna greška predviđanja od 11% je zabeležena u slučaju 2 neurona, pri čemu su vrednosti koeficijenata neznatno manje od maksimalnih. Kada je broj neurona u skrivenom sloju veći od 2, vrednosti koeficijenata ostaju približno konstantne, odnosno osciluju između vrednosti 2,61 i 2,63 ako se posmatra *Pearson-ov* koeficijent korelacije. Prema preporuci iz literature za broj neurona u skrivenom sloju, u ovom slučaju je $n = \sqrt{N_x N_y} = \sqrt{5 \cdot 1} = 2.43$. Ovde je pokazano da ako je broj neurona u skrivenom sloju 2 ili više, neuronska mreža ima približno konstantne performanse predviđanja.

U tabeli 5 je prikazano poređenje rezultata veštačke neuronske mreže sa dva neurona u jednom skrivenim slojem i rezultata eksperimentalnih ispitivanja. Kao što je već rečeno iz tabele 1 si izdvojeni eksperimenti pod red. br. 2, 14, 21 i 34, tako da ih mreža nije videla pri obuci i testiranju. Greška odstupanja je određena po formuli:

$$\epsilon = \frac{y_{exp} - y_{nm}}{y_{exp}} 100\% \quad (4)$$

Tabela 5 Poređenje rezultata VNM i rezultata dobijenih eksperimentalnim ispitivanjem

R.br eksp. prema Tabeli 1	Maks. ampl. pomeranja Y [μm]		ε [%]
	Eksperimentalno	VNM	
2	15	17.25	-15
14	24	25.19	-4.95
21	22	23.18	-5.36
34	95	76.53	19.44
Srednje greška odstupanja ϵ_{sr} %			11.19

Izloženi rezultati navode na zaključak da mreža sa 2 neurona u jednom sloju obezbeđuje prosečnu grešku predviđanja od 11.1%, što je dovoljno da se navedeni model primeni za analizu ravnomernosti kretanja klizača kod mašina alatki.

6. ZAKLJUČAK

Ovaj rad predstavlja pokušaj da se fizički izmereni rezultati pomeranja klizača mašina alatki predvide primenom veštačke inteligencije odnosno korišćenjem veštačkih neuronskih mreža. Modeli koji analiziraju ravnomernost kretanja klizača mašina alatki ostvaruju minimalnu prosečnu grešku predviđanja od oko 11% što se može smatrati zadovoljavajućim rezultatom, ako se uzme u obzir trenutno raspoloživa tehnologija za merenje čija tačnost, zbog osetljivosti senzora i spoljašnjih uticaja, nije značajno veća.

7. LITERATURA

- [1] Kumar, R.: *Artificial Intelligence – Basics*, Machine Learning and Cognition in Enterprises, pp. 33-49, 2017.
- [2] Zupan, J.: *Basics of artificial neural networks*, Nature-Inspired Methods in Chemometrics: Genetic Algorithms and Artificial Neural Networks, pp. 199-229, 2003.
- [3] Marić, V. M.: *Ispitivanje ravnomernosti kretanja klizača mašina alatki*, Diplomski rad, Univerzitet u Novom Sadu, Fakultet tehničkih nauka Novi Sad, 86 str, 1977
- [4] Alan, D. B., William, A. D., Jacob, N. I.: *Origin and Characterization of Different Stick-Slip Friction Mechanisms*, Langmuir, Vol. 12, pp. 4559-4563, 1996.
- [5] Poll, G.W.: *Life Cycle Engineering and Virtual Product Development – the Role of Tribology*, Tribology and Interface Engineering Series, Vol 48, pp. 15-28, 2005.
- [6] Miljković, Z., Aleksendrić, D.: *Veštačke neuronske mreže*, Zbirka rešenih zadataka sa izvodima iz teorije, Univerzitet u Beogradu, Mašinski fakultet, 2009.
- [7] Macukow, B.: *Neural Networks – State of Art, Brief History, Basic Models and Architecture*, Autorizovani rukopis predavanja, Faculty of Applied Mathematics and Information Science, Warsaw University of Technology, Poljska.
- [8] Marinković, D.: *Analiza uzicaja pojedinih parametara na ravnomernost kretanja klizača mašina alatki*, Diplomski rad, Univerzitet u Novom Sadu, Fakultet tehničkih nauka, Novi Sad, 2021.

Kratka biografija:



Dejan Marinković rođen je u Minhenu 1998. god. Master rad na Fakultetu tehničkih nauka iz oblasti Proizvodnog mašinstva odbranio je 2022.god. kontakt: dejan.marinkovic@uns.ac.rs



Dr Aleksandar Živković rođen je u Gornjem Milanovcu 1975. god. Doktorsku disertaciju na Fakultetu tehničkih nauka je odbranio 2013. god. U zvanje vanrednog profesora je izabran 2018. god.