

# Veštačka neuronska mreža kao alat za procenu hidrauličkog otpora

ŽARKO ĆOJBAŠIĆ, Univerzitet u Nišu, Mašinski fakultet u Nišu, Niš, Srbija, Aleksandra Medvedeva  
14, 18000 Niš, Srbija, +381638351936, [zcojba@ni.ac.rs](mailto:zcojba@ni.ac.rs)  
DEJAN BRKIĆ, Strumička 88, Beograd, Srbija, +381642543668, [dejanrgf@tesla.rcub.bg.ac.rs](mailto:dejanrgf@tesla.rcub.bg.ac.rs)

**Rezime -** *Empirijska Kolbrukova jednačina na osnovu koje je nacrtan u hidraulici dobro poznati Mudijev dijagram se danas opšteprihvaćeno koristi za proračun hidrauličkih otpora pri turbulentnom protoku. Glavni nedostatak Kolbrukove jednačine je u tome što je traženi koeficijent hidrauličkog otpora implicitno zadat te se stoga ista rešava približno iterativnim metodama ili se zamenjuje eksplisitno zadatim aproksimativnim jednačinama koje su razvili brojni autori. Takođe, Kolbrukova jednačina može veoma tačno da se aproksimira primenom metoda i tehnika veštačke inteligencije. Naime, pošto se relativna hrapavost unutrašnjeg zida cevi ( $\epsilon/D_u$ ) i Rejnoldsov broj ( $Re$ ) koriste kao ulazni podaci za iterativno rešenje Kolbrukove jednačine, moguće je generisati dovoljan broj tripteta podataka ( $\epsilon/D_u$ ,  $Re$ ,  $\lambda$ ) za obučavanje veštačke neuronske mreže koja se nadalje može koristiti za određivanje hidrauličkih otpora. Veštačka neuronska mreža je implementirana, obučena i valorizovana u programskom paketu MATLAB kompanije MathWorks.*

**Ključne reči:** *Kolbrukova jednačina, Koeficijent trenja, Hidraulički otpor, Turbulentni protok, Eksplisitne aproksimacije, Veštačka neuronska mreža*

## 1. UVOD

Eksperiment [1] koji su sproveli Kolbruk i Vajt 1937. godine pokazuje da pri protoku fluida kroz hrapave cevi ne postoji skokovit prelaz između režima u kojem se cev ponaša kao hidraulički glatka i režima u kojem se ponaša kao hidraulički hrapava. Ovaj prelaz je postepen, ali je manje izražen kod cevi koje su ravnomerno hrapave nego kod cevi koje postaju hrapave tokom vremena provedenog u eksploataciji. Kolbruk 1939. godine objavljuje relaciju koja važi za prethodno opisane uslove [2]. Poznata je i kao Kolbruk-Vajtova (CW) relacija (1):

$$\frac{1}{\sqrt{\lambda}} = -2 \cdot \log \left( \frac{2,51}{Re \cdot \sqrt{\lambda}} + \frac{\epsilon}{3,7 \cdot D_u} \right) \quad (1)$$

Kod Kolbrukove jednačine (1) koeficijent hidrauličkog otpora ( $\lambda$ ) je dat implicitno. Kolbrukova jednačina je transcendentna funkcija odnosno ne može se u konačnom obliku izraziti preko elementarnih funkcija te se mora rešavati iterativnim putem. Uz primenu računarske tehnologije ovaj postupak deluje trivijalno. Međutim kada treba rešiti problem protoka kroz prstenasti cevovod što takođe zahteva iterativni postupak, ovaj dvostruki iterativan postupak bi bilo bolje izbeći. Postoji veliki broj relacija koje su eksplisitne i koje vrlo dobro aproksimiraju Kolbrukovu relaciju [3]. Kolbrukova relacija se koristi za vrednosti Rejnoldsovog broja ( $Re$ ) od

oko 2320 do  $10^8$  i za praktično sve vrednosti relativnih hrapavosti ( $\epsilon/D_u$ ) koje su zastupljene kako u novim nekorišćenim cevima tako i na onima koji su duži niz godina u eksploataciji.

Razlog promene uobičajene vrednosti koeficijenata 2,51 i 3,7 u pojedinim aproksimacijama je nepoznat (npr. 3,7065 ili 3,71 umesto 3,7). Mala odstupanja u vrednosti ovih koeficijenata mogu promeniti vrednost izračunatog koeficijenta hidrauličkog otpora i za nekoliko procenata (pri tome se ponekad ometa upoređenje rezultata i izaziva konfuziju u pogledu tačnosti aproksimacija). Zamena koeficijenta 2,51 koeficijentom 2,825 prema preporuci američkog instituta za gas (eng. AGA; American Gas Institute) dovodi do promene vrednosti koeficijenta hidrauličkog otpora do 3,2%. Jednačina sa tako promenjenim koeficijentom se naziva modifikovana Kolbrukova jednačina i ona se koristi pri proračunu hidrauličkih otpora u slučaju protoka gasovitog fluida. Treba napomenuti da je prikazana neuronska mreža obučena za vrednosti koeficijenata 3,7 i 2,51 kakvi se uobičajeno koriste u Kolbrukovoj jednačini i na osnovu kojih je konstruisan dobro poznati Mudijev dijagram [4]. Naravno, mreža se može istrenirati koristeći i druge koeficijente kao što su npr. 2,825 i 3,71 koji su se pokazali pogodnijim za simuliranje protoka prirodnog gasa.

Od svih do sada raspoloživih eksplisitnih aproksimacija Kolbrukove jednačine devet ih je objavljeno časopisima iz oblasti hemijskog inženjerstva, sedam u časopisima iz oblasti građevinarstva, četiri iz oblasti mašinstva, tri iz oblasti nuklearne energije, te jedna u naftaškom časopisu. Ova raznornodnost tema koje obrađuju pomenuti časopisi samo potvrđuje činjenicu da Kolbrukova jednačina ima zaista široku primenu. Sama Kolbrukova jednačina je objavljena u časopisu iz oblasti građevinarstva [2]. Neuronska mreža prikazana u ovoj radu daje tačnije rezultatate u odnosu na sve dosad iz literature poznate aproksimacije.

U ovom radu je razmotrena mogućnost korišćenja veštačke neuronske mreže u svrhu rešavanja problema određivanja hidrauličkih otpora u cevima. Sva poređenja u tekstu se vrše u odnosu na iterativno rešenje Kolbrukove jednačine koje se posle dovoljnog broja iteracija može smatrati skoro tačnim. Međutim isto tako treba shvatiti da se ovde ipak ne govori o apsolutnoj tačnosti u matematičkom smislu.

## 2. KORIŠĆENA VEŠTAČKA NEURONSKA MREŽA

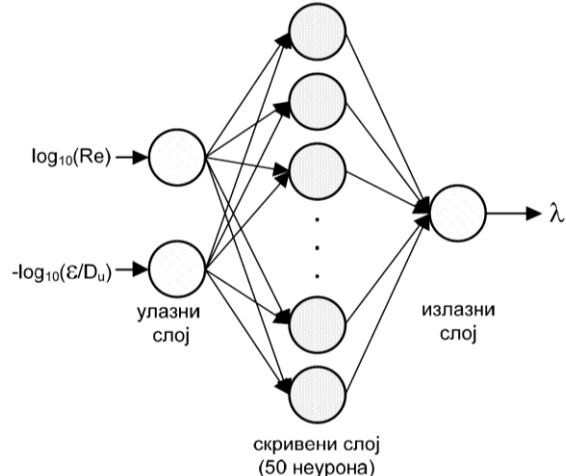
Kao jedna od dobro poznatih tehnika iz domena veštačke inteligencije, u ovom radu razmatrane su veštačke neuronske mreže i njihova primena za nalaženje približnog rešenja Kolbrukove jednačine.

Veštačke neuronske mreže (eng. ANN) su računarski modeli koji su nastali kao pokušaj matematičke formalizacije strukture ljudskog mozga. To su modeli koji omogućavaju sprovođenje zadataka kao što su prepoznavanje oblika, klasifikacija, predikcija, aproksimacija funkcija i sl. Takođe, neuro mreže se karakterišu masivnim paralelizmom operacija što ih čini veoma efikasnim. Neuro mreže predstavljaju jedinstvenu metodologiju kojom se znanje prikuplja iz skupova podataka za obučavanje i smešta u distribuiranom obliku u strukturi mreže. Veštačke neuronske mreže se formiraju od elementarnih procesnih jedinica koje međusobno komuniciraju razmenom signala kroz težinske veze. Model je nastao na osnovu labave analogije sa načinom vezivanja neurona u mozgu i prenosa informacija između njih.

Iako je primena neuronskih mreža za nalaženje približnog rešenja Kolbrukove jednačine već predložena od strane drugih autora [5-7], u ovom radu je taj koncept unapreden time što je pokazano da se izborom dovoljno složene strukture mreže i generisanjem dovoljnog broja podataka za obučavanje može dobiti izuzetno pogodan alat koji vrhunskom tačnošću koji može konkursati najtačnijim aproksimacijama Kolbrukove jednačine.

### 2.1. STRUKTURA NEURONSKE MREŽE

Konkretna veštačka neuronska mreža je generisana u programskom paketu MATLAB firme MathWorks, odnosno u njegovom dodatku neural networks toolbox. Izabrana je mreža sa prostiranjem signala unapred (feed-forward), sa jednim skrivenim slojem neurona. Željena visoka tačnost aproksimacije postignuta je strukturu sa 50 neurona u skrivenom sloju, a struktura mreže prikazana je na slici 1.

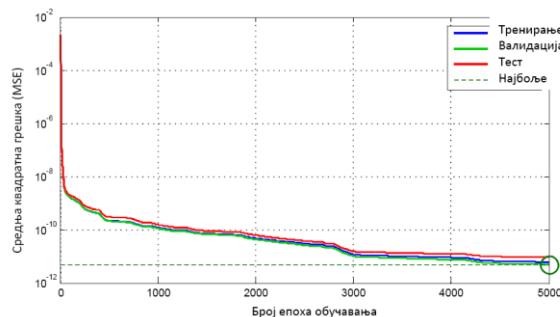


Slika 1 - Struktura veštačke neuronske mreže obučene da simulira Kolbrukovu jednačinu

### 2.2. OBUČAVANJE NEURONSKE MREŽE

Kao metod za obučavanje mreže, korišćen je Levenberg-Markeov algoritam čija je implementacija u paketu MATLAB posebno efikasna zbog načina tretiranja matričnih operacija. Kao mera tačnosti u toku obučavanja korišćena je srednje kvadratna greška, a zbog visokih zahteva u pogledu tačnosti, značajnog broja neurona i velikog broja tripteta podataka korišćenih za obučavanje tipično je bilo potrebno oko 5000 epoha obučavanja. Takav scenario obučavanja zahteva na prosečnom računaru

višečasovni postupak, ali je rezultat obučena veštačka neuronska mreža koja praktično trenutno sa visokom tačnošću prognozira koeficijenat trenja za zadate ulazne podatke. Tokom samog trajanja obučavanja računar radi samostalno tako da nikakve intervencije korisnika, tj. programera nisu potrebne. Takođe, zbog izuzetnih performansi u pogledu brzine računanja takav je veoma pogodan i za brzu izračunavanja hidrauličkih otpora u svakoj pojedinoj cevi koja je sastavni deo prstenaste mreže cevovoda koja se proračunava u iterativnoj proceduri čime se izbegava dvostruki iterativni proračun. Jedan tipičan scenario obučavanja prikazan je na slici 2.



Slika 2 - Procenjena srednja kvadratna greška veštačke neuronske mreže za simuliraciju Kolbrukove jednačine tokom 5000 epoha treninga

Kao što je poznato, kao ulazni parametri u Kolbrukovoj jednačini se javljaju relativna hrapavost ( $\epsilon/D_u$ ) i Rejnoldsov broj (Re), dok se kao izlazni parametar pojavljuje Darsijev koeficijent hidrauličkog otpora ( $\lambda$ ). Problem je u tome što se koeficijent hidrauličkog otpora ( $\lambda$ ) javlja kako sa leve tako i sa desne strane znaka jednakosti i to tako da se ne može eksplisitno izraziti na egzaktan matematički način.

Sve do sada poznate aproksimacije Kolbrukove jednačine su razvijene pomoću raznih matematičkih metoda za aproksimaciju čime se tražena veličina, u ovom slučaju koeficijent hidrauličkog otpora ( $\lambda$ ), izražava eksplisitno ali se isto tako i unosi određena greška u proračun. Ova greška se procenjuje poređenjem sa iterativnim rešenjem Kolbrukove jednačine koje se uzima kao dovoljno tačno. Iterativni proračun se može vršiti koristeći različite metode numeričke analize kao što je npr. Njutnova metoda. Ovaj proračun se može obaviti i u MS Excel-u (treba izvršiti podešavanja za MS Office

2007: pritisnuti Office Button u gornjem levom uglu ekrana a zatim u Excel Options izabrati Formulas gde treba čekirati opciju Enable iterative calculation pri čemu treba podešiti parametre Maximal iterations čime se određuje najveći broj iterativnih ciklusa koji se koristi za proračun, odnosno Maximum change čime se određuje najveća dozvoljena razlika u vrednosti tražene veličine između dve iteracije). Pošto je za iterativni proračun Kolbrukove jednačine dovoljno 7-10 iteracija, MS Excel-a sa 32767 iterativnih ciklusa sigurno zadovoljava traženu tačnost. Dakle, ako se u MS Excel-u vrednost relativne hrapavosti ( $\epsilon/D_u$ ) nalazi u polju B1 a Rejnoldsovog broja (Re) u A1, u polje C1 u koje treba smestiti vrednost leve strane Kolbrukove jednačine treba kucati:

$$=-2*\text{LOG10}(((1/3.7)*B1)+((2.51/A1)*C1))$$

U prethodnom redu figuriše i samo polje C1 čime se MS Excel poziva da izvrši iterativni proračun. Vrednost koeficijenta hidrauličkog otpora ( $\lambda$ ), se dobija npr. u polju D1 tako što se ukuca red:  
=1/POWER(C1,2)

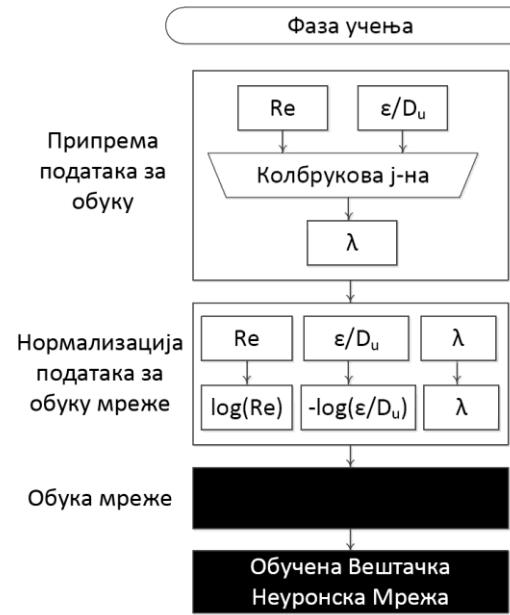
Na ovaj način se može generisati odgovarajući broj triplata parametara potrebnih za obuku veštačke neuronske mreže. Tripleti za obuku se dobijaju tako što se određenoj vrednosti Rejnoldsovog broja (Re) i relativne hrapavosti ( $\epsilon/D_u$ ) pridružuje odgovarajuća vrednost koeficijenta hidrauličkog otpora ( $\lambda$ ) pročunata iterativno koristeći Kolbrukovu jednačinu. Vrednost relativne hrapavosti ( $\epsilon/D_u$ ) unutrašnjeg zida cevi se u praksi kreće od 0 do 0,05, dok se Rejnoldsov broj (Re) nalazi u opsegu od 2320 do  $10^8$  (što se može videti sa Mudijevog dijagrama koji grafički predstavlja rezultate dobijene upotrebom Kolbrukove jednačine). Veštačka neuronska mreža na osnovu dovoljnog broja tripleta dovedenih na ulaz prilikom obuke nalazi zakonitost po kojoj se u našem slučaju za dva ulaza dobija izlaz. Ova zakonitost je u stvari Kolbrukova funkcija koju veštačka mreža ne poznaje kao takvu. Ona samo podešava parametre svojih neurona koji su kasnije u stanju da rade isti proračun za koji nam je prethodno bila potrebna Kolbrukova jednačina. Neuronska mreža praktično numerički aproksimira Kolbrukovu funkciju. Kao što je već rečeno, veštačka neuronska mreža uči slično poput ljudskog mozga. Ovde je najbolje zamisliti kao proces učenja stranog jezika, tj. na osnovu dovoljnog broja reči povezanih u rečenice ljudski

mozak nastoji da shvati gramatička pravila i da ih zatim uspešno primeni za sporazumevanje na jeziku koji uči. Uspešnost neuronske mreže da pravilno nauči da reši problem zavisi kako od matematičke složenosti relacije, tj. funkcije kojom je opisan problem (u našem slučaju to je Kolbrukova jednačina) tako i od veličine skupa podataka koji je predložen mreži u procesu obuke (u našem slučaju to je 90 hiljada triplata podataka;  $Re$ ,  $\epsilon/D_u$ ,  $\lambda$ ) tj. učenja kao i od složenosti same mreže koja je odabrana, tj. od broja neurona u unutrašnjem, skrivenom sloju mreže (u našem slučaju to je 50 neurona u skrivenom sloju). Veštačka mreža u našem slučaju ima dva ulazna neurona koji odgovaraju Rejnoldsovom broju ( $Re$ ) i relativnoj hrapavosti ( $\epsilon/D_u$ ) i izlazni neuron koji odgovara koeficijentu hidrauličkog otpora ( $\lambda$ ). Između ova dva sloja se nalazi unutrašnji skriveni sloj mreže (ovde 50 neurona). Što je više neurona u skrivenom sloju, to je mreža „pametnija“ tj. brže će shvatiti zakonist koju treba da primeni prilikom određivanja izlazne veličine na osnovu ulaznih veličina. U našem slučaju javlja se problem prilikom treniranja veštačke neuronske mreže pošto se ulazni parametri razlikuju u redu veličine. Tako dok je relativna hrapavost ( $\epsilon/D_u$ ) predstavljena vrlo malim brojevima od 0 do 0,05, Rejnoldsov broj ( $Re$ ) se kreće od par hiljada do  $10^8$ . Ovo predstavlja znatan problem za obuku neuronske mreže tako da ona ne može da se obuči da reši problem sa dovoljnom tačnošću bez normalizacije ulaznih parametara. Ova normalizacija je izvršena logaritmovanjem dva ulazna parametra naše mreže tako da njihove vrednosti u apsolutnom brojčanom iznosu budu približne (Slika 3).

Na slici 3 se veštačka neuronska mreža prikazuje kao crni kvadrat. Ovo odgovara shvatanju da je neuronska mreža u stvari neka vrsta „crne kutije“ tj. ona tako podešava svoje neurone i veze da se samo njihovim daljim proučavanjem ne može lako utvrditi za šta je ona obučena. Odnosno, ukoliko postoji neuronska mreža za koju se unapred ne zna za koje poslove je obučena, teško je samo na osnovu proučavanja njenih unutrašnjih parametara to i ustanoviti.

Normalizovanje se može izvršiti pored načina prikazanog na slici 3 i na druge načine npr.  $Re \rightarrow \log(Re)/100$ , dok drugi ulazni kao i sam izlazni parametar ostaju nepromenjeni. Da bi se

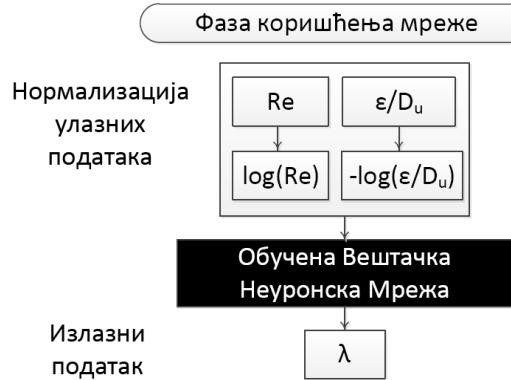
mreža dobro obučila potrebno je da podaci ravnomerno pokrivaju ceo praktičan opseg realnih parametara (ceo Mudijev dijagram).



Slika 3 - Proces obučavanja neuronske mreže za simuliraciju Kolbrukove jednačine

### 2.3. UPOTREBA NEURONSKE MREŽE

Neuronska mreža je obučena tako da služi kao zamena za Mudijev dijagram [4] i može se vrlo prosto koristiti tako što joj se na ulaz dovedu nepoznate a neuronska mreža trenutno proceni i prikaže vrednost izlaznog parametra (Slika 4).



Slika 4 - Faza korišćenja neuronske mreže za simuliraciju Kolbrukove jednačine

Generisana neuronska mreža u MATLAB-u može sačuvati i pozivati naknadno iz radnog foldera komandom Load. Komanda Sim služi nadalje za rad sa veštačkom neuronskom mrežom pod uslovom da je ista generisana u neural networks toolbox-u.

Tabela 1 – Eksplisitne aproksimacije koje po tačnosti mogu konkurisati neuronskoj mreži

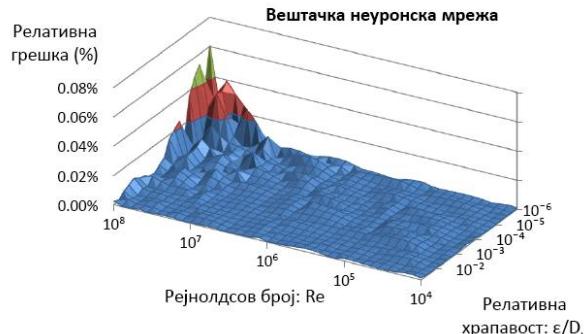
$$\frac{1}{\sqrt{\lambda}} \approx -2 \cdot \log \left\{ \begin{aligned} & \left( \frac{1}{3,7065} \cdot (\varepsilon/D) - \right. \\ & \left. - \left( 5,0272 / \text{Re} \right) \cdot \log \left[ \left( \frac{1}{3,827} \cdot (\varepsilon/D) - \left( 4,567 / \text{Re} \right) \cdot \log \left( \frac{\left( \frac{1}{7,7918} \cdot (\varepsilon/D) \right)^{0,9924} + }{\left( 5,3326 / (208,815 + \text{Re}) \right)^{0,9345}} \right) \right] \right) \end{aligned} \right\} \quad [8]$$

$$\begin{aligned} \lambda &\approx \left[ A - (B - A)^2 / (C - 2 \cdot B + A) \right]^2 \\ A &= -2 \cdot \log \left[ (1/3,7) \cdot (\varepsilon/D) + 12 / \text{Re} \right] \\ B &= -2 \cdot \log \left[ (1/3,7) \cdot (\varepsilon/D) + (2,51 \cdot A) / \text{Re} \right] \\ C &= -2 \cdot \log \left[ (1/3,7) \cdot (\varepsilon/D) + (2,51 \cdot B) / \text{Re} \right] \end{aligned} \quad [9]$$

$$\begin{aligned} \frac{1}{\sqrt{\lambda}} &= \alpha - \left[ (\alpha + 2 \cdot \log(\beta / \text{Re})) / (1 + 2,18 / \beta) \right] \\ \alpha &= [(0,774 \cdot \ln(\text{Re}) - 1,41) / (1 + 1,32 \cdot \sqrt{\varepsilon/D})] \\ \beta &= (1/3,7) \cdot (\varepsilon/D) \cdot \text{Re} + 2,51 \cdot \alpha \end{aligned} \quad [10]$$

$$\begin{aligned} \frac{1}{\sqrt{\lambda}} &\approx 0,8686 \cdot \ln \left[ (0,4587 \cdot \text{Re}) / (S - 0,31) \right]^{S/(S+0,9633)} \\ S &= 0,124 \cdot \text{Re} \cdot (\varepsilon/D) + \ln(0,4587 \cdot \text{Re}) \end{aligned} \quad [11]$$

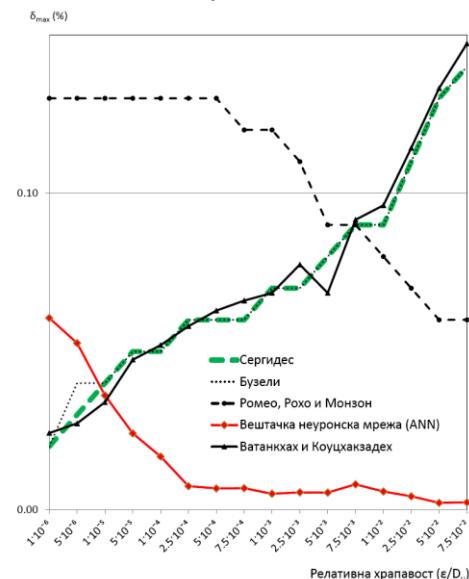
Ovako formirana i utrenirana neuronska mreža daje rešenje sa tačnošću koja vrlo malo odstupa od iterativnog rešenja Kolbrukove jednačine (Slika 5).



Slika 5 - Distribucija greške veštačke neuronske mreže u odnosu na iterativno rešenje

Dodatnim treniranjem veštačke neuronske mreže u oblasti vrlo malih vrednosti relativne hrapavosti a vrlo velike vrednosti Rejnoldsovog broja može se smanjiti greška koja je skoncentrisana u ovoj oblasti (Slika 5). Najveća procenjena relativna greška koju se javlja korišćenjem aproksimacija Romeo, Roha i Monzona [8] je procenjena na 0,1345%. Veštačka neuronska mreža iz prikazanog primera daje tačnije rezultate sa procenjenom relativnom greškom do 0,0606%. Pošto je greška neuronske mreže koncentrisana u zoni visokih vrednosti Rejnoldsovog broja i niske relativne hrapavosti (Slika 5), u ovoj uskoj zoni joj mogu po tačnosti parirati samo aproksimacije Sergidesa [9], Buzelija [10] kao i Vatankhaha i Kouchakzadeha [11] kao što se vidi sa slike 6 (pominjane aproksimacije se daju u tabeli 1).

Pošto je samo turbulentni deo Mudijevog dijagrama pokriven Kolbrukovom jednačinom mreža je za  $\text{Re} > 2320$  trenirana da daje rezultate kao Kolbrukova jednačina. Međutim, laminaran deo Mudijevog dijagrama ne pokriva Kolbrukova jednačina tako da bi za ovaj režim, tj. za  $\text{Re} < 2320$  mreža morala da se trenira da daje izlaze na osnovu relacije  $\lambda = 64/\text{Re}$ .



Slika 6 – Poređenje tačnosti neuronske mreže sa najtačnijim aproksimacijama

### 3. ZAKLJUČAK

Većina aproksimacija Kolbrukove jednačine ima tačnost veću od 3% [3]. Kako je i sama Kolbrukova jednačina (1) empirijskog tipa njena apsolutna tačnost može da se dovede u pitanje. Korišćenjem veštačke neuronske mreže obučene

na način prikazan u ovom radu postiže se velika tačnost sa odstupanjem do najviše 0,06% u odnosu na iterativno rešenje Kolbrukove jednačine (dodatnim treningom se i ova tačnost može poboljšati). Na osnovu, iznetog veštačka neuronska mreža neuronska mreža se može preporučiti za korišćenje u svakodnevnoj inženjerskoj praksi.

#### 4. KORIŠĆENE OZNAKE

$\lambda$ -Darsijev, tj Darsi-Vajsbahov, odnosno Mudijev koeficijent hidrauličkog otpora (-)  
 Re-Rejnoldsov broj (-)  
 $D_u$ -unutrašnji prečnik cevi (m)  
 $\epsilon$ -hrapavost (m)  
 $\epsilon/D_u$ -relativna hrapavost unutrašnjeg zida cevi (-)  
 log-Brigsov dekadni logaritam, tj.  $\log_{10}$   
 ln-Neperov prirodni logaritam, tj.  $\log_e$   
 -ostale oznake su pomoćne i definisane u tabeli 1

#### ZAHVALNICA

Rad je nastao zahvaljujući projektu 145009-Tempus-2008-RS-JPHES "Conversion Courses for Unemployed University Graduates in Serbia (CONCUR)" iz čijih sredstava se finansira školovanje drugog autora ovog rada dr Dejana Brkića, dipl. inž. naftnog ruderstva na master studijama na Mašinskom fakultetu Univerziteta u Nišu.

#### LITERATURA

[1]. C.F. Colebrook, C.M. White: Experiments with fluid friction in roughened pipes. Proc. Roy. Soc. Ser. A Math. Phys. Sci. 161 (1937) 367-381.

- [2]. C.F. Colebrook: Turbulent flow in pipes with particular reference to the transition region between the smooth and rough pipe laws. J. Inst. Civil. Eng. (London) 11 (1939) 133-156.
- [3]. D. Brkić: Review of explicit approximations to the Colebrook relation for flow friction. J. Pet. Sci. Eng. 77 (2011) 34-48.
- [4]. L.F. Moody: An approximate formula for pipe friction factors. Trans. ASME 69 (1947) 1005-1011.
- [5]. W.H. Shayya, S.S. Sablani: An artificial neural network for non-iterative calculation of the friction factor in pipeline flow. Comput. Electron. Agr. 21 (1998) 219-228.
- [6]. D.A. Fadare, U.I. Ofidhe: Artificial neural network model for prediction of friction factor in pipe flow. J Appl. Sci. Res. 5 (2009) 662-670.
- [7]. M. Özger, G. Yıldırım: Determining turbulent flow friction coefficient using adaptive neuro-fuzzy computing technique. Adv. Eng. Softw. 40 (2009) 281-287.
- [8]. E. Romeo, C. Royo, A. Monzon: Improved explicit equation for estimation of the friction factor in rough and smooth pipes. Chem. Eng. J. 86 (2002) 369-374.
- [9]. T.K. Serghides: Estimate friction factor accurately. Chem. Eng. 91 (1984) 63-64.
- [10]. D. Buzzelli: Calculating friction in one step. Mach. Des. 80 (2008) 54-55.
- [11]. A.R. Vatankhah, S. Kouchakzadeh: Discussion of "Turbulent flow friction factor calculation using a mathematically exact alternative to the Colebrook-White equation" by Jagadeesh R. Sonnad and Chetan T. Goudar, J. Hydraul. Eng. ASCE 134 (2008) 1187.

#### SUMMARY

#### ARTIFICIAL NEURAL NETWORK AS A TOOL FOR ESTIMATION OF HYDRAULIC RESISTANCE

*Empirical Colebrook equation also used as the base for in hydraulics wide-known Moody diagram today is used as an accepted standard for calculation of hydraulic friction valid for entire turbulent regime. Main shortcoming of the Colebrook equation is in its implicitly given friction factor which means that it can be solved only using iterative procedure or it can be replaced using approximate relations developed by many authors. Furthermore, Colebrook's equation can be simulated very accurately using of artificial neural network. As relative roughness of inner pipe surface ( $\epsilon/D_u$ ) and the Reynolds (Re) number are used for iterative solution of the Colebrook equation, it is possible to generate enough number of input data ( $\epsilon/D_u$ , Re,  $\lambda$ ) for training of neural network that will use for estimation of hydraulic resistances. Shown artificial neural network was trained and simulated in the software package MATLAB by MathWorks.*

**Key words:** Colebrook equation, Friction factor, Hydraulic resistance, Turbulent flow, Explicit approximations, Artificial Neural Networks (ANN)