

Modeliranje strukture i svojstava nodularnog lijeva neuronskim mrežama

Žmak, Irena

Doctoral thesis / Disertacija

2009

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Zagreb, Faculty of Mechanical Engineering and Naval Architecture / Sveučilište u Zagrebu, Fakultet strojarstva i brodogradnje**

Permanent link / Trajna poveznica: <https://urn.nsk.hr/urn:nbn:hr:235:864362>

Rights / Prava: [In copyright](#) / [Zaštićeno autorskim pravom.](#)

Download date / Datum preuzimanja: **2024-11-29**

Repository / Repozitorij:

[Repository of Faculty of Mechanical Engineering and Naval Architecture University of Zagreb](#)



SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

MODELIRANJE STRUKTURE I SVOJSTAVA NODULARNOG
LIJEVA NEURONSKIM MREŽAMA

DOKTORSKI RAD

Prof. dr. sc. TOMISLAV FILETIN

Mr. sc. IRENA ŽMAK

ZAGREB, 2009.

PODACI ZA BIBLIOGRAFSKU KARTICU

UDK:	669.131.7:004.032.26
Ključne riječi:	nodularni lijev, toplinska analiza, mikrostruktura, mehanička svojstva, umjetne neuronske mreže, predviđanje
Znanstveno područje:	TEHNIČKE ZNANOSTI
Znanstveno polje:	strojarstvo
Institucija u kojoj je rad izrađen:	Fakultet strojarstva i brodogradnje Sveučilišta u Zagrebu, Zagreb
Mentor rada:	Prof. dr. sc. Tomislav Filetin
Broj stranica:	140
Broj slika:	84
Broj korištenih bibliografskih jedinica:	68
Datum obrane:	8. siječnja 2009.
Povjerenstvo:	Prof. dr. sc. Dubravko Majetić, izvanredni profesor, Fakultet strojarstva i brodogradnje, Zagreb – predsjednik Prof. dr. sc. Tomislav Filetin, redoviti profesor, Fakultet strojarstva i brodogradnje, Zagreb – mentor Prof. dr. sc. Faruk Unkić, redoviti profesor, Metalurški fakultet, Sisak – član
Institucija u kojoj je rad pohranjen:	Fakultet strojarstva i brodogradnje, Zagreb Nacionalna i sveučilišna knjižnica, Zagreb

ZAHVALA

Zahvaljujem mentoru ovog rada i svom višegodišnjem znanstvenom mentoru, prof. dr. sc. Tomislavu Filetinu, na strpljenju i podršci tijekom istraživanja uključenim u ovaj rad. Osim toga, ovom prigodom zahvaljujem mu se na svim pruženim mogućnostima tijekom mog znanstvenog usavršavanja kao znanstvene novakinje.

Prof. dr. sc. Dubravku Majetiću zahvaljujem na poticajnim razgovorima i konstruktivnim savjetima, te na trudu uloženom u što skladnije i kvalitetnije oblikovanje ovog rada.

Zahvaljujem prof. dr. sc. Faruku Unkiću s Metalurškog fakulteta u Sisku na brojnim korisnim dopunama i pojašnjenjima metalurških procesa opisanih u radu. Također, kvalitetna toplinska analiza taljevina nodularnog lijeva u ljevaonici "Metalske industrije Varaždin" d.d. ne bi bila moguća bez uređaja kojeg nam je prof. Unkić posudio.

Doc. dr. sc. Zoranu Glavašu, također s Metalurškog fakulteta u Sisku, želim zahvaliti na velikoj pomoći u prikupljanju literature vezane za izradu ove disertacije, na konzultacijama, te korekcijama i nadopunama teorijskog dijela rada. Mr. sc. Katarina Terzić s Metalurškog fakulteta u Sisku, je stručno, brižljivo i sustavno analizirala mikrostrukturu ljevova, na čemu sam joj vrlo zahvalna.

Posebnu zahvalnost dugujem sljedećim zaposlenicima "Metalske industrije Varaždin" d.d.: Marini Špirelji, dipl. ing. metalurgije i Stjepanu Miklošiću, koji su marljivo, savjesno i pedantno snimali krivulje hlađenja i prikupljali podatke o kemijskom sastavu i mehaničkim svojstvima. Također, zahvaljujem Smiljanu Hrenu, dipl. ing. strojarstva koji je pomogao u prikupljanju podataka, dao niz korisnih savjeta, bio uvijek na raspolaganju za tumačenje rezultata, te Miloradu Vasiliću, dipl. ing. metalurgije i Velimiru Šijaku, dipl. ing. strojarstva, koji su mi nesebično prenijeli svoja znanja i literaturu o tehnološkim postupcima i metodama značajnim za ovaj rad.

Da bi ovaj rad poprimio konačan oblik u propisanom roku iznimno su zaslužni članovi moje obitelji, moj suprug, moja svekrva i moja mama, koji su se svi nesebično i rado posvetili mom djetetu u danima kad me ovaj rad potpuno okupirao. Za uspjeh ovog rada značajan je i moj brat, koji mi je bio uvijek dostupna i kvalitetna tehnička podrška.

Zahvaljujem se i svim dragim ljudima, koje ovdje nisam imenovala, a koji su svojom pažnjom, savjetima, podrškom i dobrom voljom bili uz mene.

SADRŽAJ:

PREDGOVOR.....	vii
SAŽETAK RADA.....	ix
SUMMARY	xi
KLJUČNE RIJEČI	xii
KEY WORDS	xii
POPIS OZNAKA	xiii
POPIS SLIKA	xviii
POPIS TABLICA.....	xxiii
POPIS PRILOGA.....	xxv
1. UVOD.....	1
1.1. Definiranje problema.....	1
1.2. Hipoteza rada.....	2
2. TEORIJSKI DIO	5
2.1. Nodularni lijev.....	5
2.1.1. Općenito o nodularnom lijevu	5
2.1.2. Klasifikacija nodularnog lijeva.....	10
2.1.3. Kemijski sastav nodularnog lijeva.....	11
2.1.3.1. Ugljik i silicij.....	12
2.1.3.2. Mangan.....	15
2.1.3.3. Sumpor	17
2.1.3.4. Fosfor.....	18
2.1.3.5. Magnezij.....	18
2.1.3.6. Cerij i rijetke zemlje	19
2.1.3.7. Bakar.....	19
2.1.3.8. Kositar	20
2.1.3.9. Molibden.....	21
2.1.3.10. Nikal	21
2.1.3.11. Ostali elementi u tragovima.....	22
2.1.4. Mikrostruktura nodularnog lijeva i utjecajni čimbenici	23

2.2.	Toplinska analiza.....	29
2.2.1.	Toplinska analiza nodularnog lijeva.....	31
2.2.1.1.	Primjena toplinske analize u određivanju kemijskog sastava nodularnog lijeva.....	33
2.2.1.2.	Primjena toplinske analize u određivanju mikrostrukture nodularnog lijeva i djelotvornosti cjepiva.....	35
2.2.1.3.	Primjena toplinske analize u određivanju mehaničkih svojstava nodularnog lijeva.....	39
2.3.	Umjetne neuronske mreže.....	41
2.3.1.	Model statičkog neurona.....	42
2.3.2.	Građa umjetnih neuronskih mreža.....	44
2.3.3.	Učenje umjetne neuronske mreže.....	47
2.3.4.	Algoritam povratnog rasprostiranja pogreške.....	49
2.3.5.	Levenberg – Marquardtova metoda.....	55
2.3.6.	Testiranje i validacija umjetne neuronske mreže.....	56
2.3.7.	Procjena točnosti preslikavanja umjetnom neuronskom mrežom.....	60
3.	EKSPERIMENTALNI DIO.....	63
3.1.	Priprema taljevina nodularnog lijeva.....	63
3.2.	Ispitivanje kemijskog sastava ljevova.....	70
3.3.	Lijevanje ispitnih uzoraka za ispitivanje mehaničkih svojstava.....	71
3.4.	Statičko vlačno ispitivanje uzoraka.....	73
3.5.	Toplinska analiza taljevina nodularnog lijeva.....	75
3.6.	Ispitivanje tvrdoće.....	82
3.7.	Ispitivanje mikrostrukture.....	82
3.8.	Modeliranje neuronskih mreža.....	84
4.	REZULTATI MODELIRANJA UMJETNIM NEURONSKIM MREŽAMA.....	89
4.1.	Predviđanje mikrostrukture nodularnog lijeva na temelju toplinske analize.....	89
4.1.1.	Predviđanje nodularnosti.....	89
4.1.2.	Predviđanje broja nodula po jedinici površine.....	96

4.1.3.	Predviđanje volumnog udjela ferita u metalnoj osnovi.....	101
4.2.	Predviđanje mehaničkih svojstava na temelju toplinske analize.....	107
4.2.1.	Predviđanje vlačne čvrstoće na temelju toplinske analize.....	107
4.2.2.	Predviđanje konvencionalne granice razvlačenja na temelju toplinske analize	112
4.2.3.	Predviđanje istežljivosti na temelju toplinske analize.....	117
4.2.4.	Predviđanje tvrdoće na temelju toplinske analize	122
4.2.5.	Predviđanje vlačne čvrstoće na temelju mikrostrukture.....	127
5.	RASPRAVA.....	133
6.	ZAKLJUČAK.....	139
	PRILOZI.....	I
	ŽIVOTOPIS	XXXII
	BIOGRAPHY	XXXIII
	LITERATURA.....	XXXV

PREDGOVOR

Nodularni (ili žilavi) lijev vrsta je lijeva na bazi željeza, čiji sastav karakterizira povišeni udio ugljika, silicija i magnezija, koji omogućavaju izlučivanje grafita u obliku kuglica (nodula). Nodularni je lijev materijal koji je sve zastupljeniji na tržištu odljevaka od ljevova na bazi željeza. U odnosu na sivi lijev, ovaj lijev ima znatno višu čvrstoću, slabije je obradiv i ima nešto slabiju sposobnost prigušenja vibracija. S druge strane, svojstvo prigušenja vibracija i rezljivost su kod nodularnog lijeva puno povoljniji nego kod čeličnog lijeva. Granica razvlačenja je viša nego kod sivog lijeva i nelegiranog čeličnog lijeva.

Metalna osnova u lijevanom stanju može biti feritna, feritno – perlitna ili perlitna. Legiranjem ili toplinskom obradom moguće je postići i druge metalne osnove. U primjeni je često najpovoljnija perlitna metalna osnova. Ukoliko su odljevci izloženi udarnom opterećenju, povoljnija je feritna metalna osnova. Pretežno perlitna metalna osnova optimalna je obzirom na postizanje visoke čvrstoće i dobre otpornosti na trošenje.

Svojstva odljevaka od nodularnog lijeva ovise, osim o kemijskom sastavu i eventualnoj naknadnoj toplinskoj obradi odljevka, o postupku obrade taljevine prije ulijevanja, kao i o uvjetima pri skrućivanju u kalupu. Jedan od načina praćenja svojstava taljevine, a time i praćenje svojstava budućeg odljevka je snimanje krivulje hlađenja toplinskom analizom taljevine.

Posljednjih godina u ljevačkoj se industriji sve češće susreće primjena računala u cilju optimiranja tehnološkog procesa lijevanja, povećanja produktivnosti i poboljšanja svojstava odljevaka, kao i nadzora nad tim svojstvima. Stoga se sve više primjenjuju i koriste različiti računalni programi za konstruiranje odljevaka, za pripremu tehnoloških nacrti odljevaka, za simulaciju ulijevanja rastaljenog metala u kalupe, za simulaciju hlađenja i skrućivanja, predviđanje svojstava odljevaka metodom konačnih elemenata i linearnom regresijom itd. Metoda umjetnih neuronskih mreža može se uspješno primijeniti u rješavanju izrazito nelinearnih problema, u kojima postoji velik broj varijabli koje utječu na jedno ili više promatranih svojstava. Primjena neuronskih mreža u znanosti i inženjerstvu materijala u zadnjem je desetljeću dala vrlo

dobre rezultate pri rješavanju različitih problema predviđanja svojstava materijala i parametara procesa. Stoga bi ovaj rad, uz pomoć umjetnih neuronskih mreža, trebao pridonijeti metodologiji modeliranja, predviđanja i optimiranja mikrostrukture i mehaničkih svojstava nodularnog lijeva.

SAŽETAK RADA

Dosadašnja su istraživanja pokazala da se umjetne neuronske mreže mogu uspješno primijeniti u predviđanju različitih svojstava materijala. Cilj ovog doktorskog rada je istraživanje mogućnosti primjene neuronskih mreža u predviđanju mehaničkih svojstava i mikrostrukture nodularnog lijeva.

Prikupljeni su eksperimentalni podaci o 147 taljevina nodularnog lijeva. Svaka je taljevina ispitana toplinskom analizom, a spektralnom je analizom utvrđen kemijski sastav. Ispitana su mehanička svojstva: vlačna čvrstoća, konvencionalna granica razvlačenja, istezljivost i tvrdoća. Analizom mikrostrukture utvrđena je nodularnost grafitu i broj grafitnih nodula po jedinici površine, te udio ferita i perlita u metalnoj osnovi. Neuronske su mreže oblikovane, primijenjene i simulirane programskim paketom Neural Network Toolbox od Matlaba 7.0. Korištene su neuronske mreže s povratnim rasprostiranjem pogreške. U cilju sprečavanja pretreniranosti mreže, odnosno unaprijeđenja generalizacije, korištena je metoda ranog zaustavljanja. Kako bi konvergencija k minimalnoj pogrešci bila brža, upotrijebljen je Levenberg – Marquardtov algoritam. Pogreška neuronske mreže praćena je preko normaliziranog korijena srednje kvadratne pogreške, koeficijenta korelacije i determinacije, te srednje vrijednosti relativne pogreške.

Mehanička svojstva i mikrostruktura nodularnog lijeva predviđani su na temelju relevantnih toplinskih parametara s krivulje hlađenja taljevine. Za model neuronske mreže utvrđen je najpovoljniji način normiranja ulaznih i izlaznih podataka, te najpovoljniji nagib aktivacijske funkcije skrivenih neurona. Određena je najpovoljnija kombinacija ulaznih toplinskih parametara. Najsličnije taljevine prema izmjerenim toplinskim parametrima izabrane su za testiranje mreže. Svaki mikrostrukturni parametar i mehaničko svojstvo predviđani su posebnim neuronskim mrežama i za svaku je mrežu određen najpovoljniji broj skrivenih neurona. Obzirom na ukupan broj uzoraka i rasipanja vrijednosti svojstava, neuronskim su mrežama postignuti relativno zadovoljavajući rezultati predviđanja svojstva i mikrostrukture. Pogreške generalizacije neuronske mreže bile su manje kod predviđanja mikrostrukture, posebno mikrostrukture

metalne osnove. Veće pogreške zabilježene su pri predviđanju mehaničkih svojstava, naročito istezljivosti.

SUMMARY

The present research has shown that artificial neural networks can be successfully applied in predicting different material properties. The scope of this dissertation is to investigate the possibilities of applying neural networks in predicting mechanical properties and microstructure of ductile cast iron.

Experimental data were collected for 147 ductile cast iron melts. Melts were analysed by thermal analysis, whereas spectral analysis was used to determine the chemical composition. Following mechanical properties were determined: tensile strength, yield strength, elongation, and hardness. Percent nodularity, nodule count per unit area, ferrite and pearlite content were determined by microstructural analysis. The Matlab's Neural Network Toolbox was used as a tool for the design, implementation, and simulation of neural networks. Backpropagation method of teaching artificial neural networks was used. In order to prevent overfitting, or for improving generalisation, early stopping technique was applied. Levenberg – Marquardt algorithm was used to train the networks faster. Network performance functions were: normalised root mean square error, correlation coefficient and coefficient of determination, and mean relative absolute error.

Mechanical properties and microstructure were predicted based on relevant thermal parameters from the cooling curve. The best way to normalise input and output data was determined, as well as the best slope of hidden neurone activation function. The set of thermal parameters for the input data set was analysed. The most similar melts considering thermal analysis were chosen for neural network testing. Each neural network was to predict one property, and for each network the most adequate number of hidden neurones was determined. Considering the total number of collected ductile cast iron data, as well as their distributions, the results of applying neural networks in predicting properties and microstructure were relatively satisfactory. Generalisation errors were lower when predicting microstructure, especially ferrite content. Higher generalisation errors were recorded in predicting mechanical properties, especially elongation.

KLJUČNE RIJEČI

nodularni lijev, taljevine, toplinska analiza, mikrostruktura, mehanička svojstva, umjetne neuronske mreže, algoritam povratnog rasprostiranja pogreške, predviđanje, modeliranje

KEY WORDS

nodular cast iron, melt, thermal analysis, microstructure, mechanical properties, artificial neural networks, error back – propagation algorithm, prediction, modeling

POPIS OZNAKA

Oznake prema latinskoj abecedi:

A	istezljivost, %
a, b, c, d, e, f, g, h, j	regresijski koeficijenti
ATAS	adaptabilni sustav za toplinsku analizu
Bias	zasebni neuron
CA – CCA	računalom potpomognuta analiza krivulje hlađenja
CE	ekvivalent ugljika, %
CEL	uglični ekvivalent likvidusa, %
d	matrica izmjerenih izlaznih podataka neuronske mreže
D	Euklidova udaljenost
DTA	diferencijalna toplinska analiza
d_0	početni promjer epruvete za statičko vlačno ispitivanje, mm
d_1	promjer glave epruvete za statičko vlačno ispitivanje, mm
$\frac{d\vartheta_{ES}}{dt}$	brzina hlađenja na temperaturi početka eutektičke reakcije, °C/s
$\frac{d\vartheta_S}{dt}$	brzina hlađenja na temperaturi solidus, °C/s
E	funkcija cilja
e	dozvoljena razina pogreške neuronske mreže
EBP	algoritam povratnog rasprostiranja pogreške
EN	europska norma
F	volumni udio ferita, %
$F(\mathbf{w})$	funkcija cilja pri učenju neuronske mreže
$F(\mathbf{w})_{\min}$	minimalna vrijednost funkcije cilja pri učenju neuronske mreže
F_{oks}	oksidacijski faktor
f_{S1}	udio površine ispod krivulje hlađenja između ϑ_L i ϑ_{EP} u ukupnoj površini (od ϑ_L do ϑ_S), %
f_{S2}	udio površine ispod krivulje hlađenja između ϑ_{EP} i ϑ_{ER} u

	ukupnoj površini (od \mathcal{A}_L do \mathcal{A}_S), %
f_{S3}	udio površine ispod krivulje hlađenja između \mathcal{A}_{ER} i \mathcal{A}_S u ukupnoj površini (od \mathcal{A}_L do \mathcal{A}_S), %
GRF1	grafitni faktor 1
GRF2	grafitni faktor 2
GRF3	grafitni faktor 3
H	redni broj skrivenog sloja neurona
h	duljina glave epruvete za statičko vlačno ispitivanje, mm
HB	tvrdoća po Brinellu
HRN	hrvatska norma
I	broj neurona u ulaznom sloju +1
\mathbf{I}	jedinična matrica
j	redni broj neurona u H -tom skrivenom sloju
J	broj neurona u skrivenom sloju +1
\mathbf{J}	Jakobijeva matrica funkcije cilja
K	broj neurona u izlaznom sloju
K_p	konstanta proporcionalnosti
KV	udarni rad loma, J
L_c	duljina tijela epruvete za statičko vlačno ispitivanje, mm
LT	ispitivanje se provodi na niskim temperaturama
L_t	duljina epruvete za statičko vlačno ispitivanje, mm
L_0	početna mjerna duljina epruvete za statičko vlačno ispitivanje, mm
MnE	mangan ekvivalent, %
MS	srednja kvadratna pogreška
n	iteracijski broj koraka učenja
N	broj ulazno – izlaznih parova podataka za neuronsku mrežu
net	zbroj produkata ulaza i težinskih koeficijenata
net_H	suma otežanih ulaza neurona H -tog skrivenog sloja
N_{min}	dovoljan broj parova podataka u učenje

N_{nod}	broja nodula po jedinci površine, mm^{-1}
$NRMS$	normalizirani korijen srednje kvadratne pogreške
N_1	broj neurona u skrivenom sloju
O	matrica izračunatih izlaznih podataka neuronske mreže
O	izlazni sloj neurona
P	volumni udio perlita, %
p	nenormirane vrijednosti varijable
\overline{p}	srednja vrijednost nenormiranih vrijednosti varijable
PCA	analiza glavnih komponenti
p_{min}	najniži iznos nenormiranih vrijednosti varijable
p_{maks}	najviši iznos nenormiranih vrijednosti varijable
p_n	normirane vrijednosti varijable
PRESS	predviđeni ostaci greške sume kvadrata
R	koeficijent korelacije
R^2	koeficijent determinacije
R_m	vlačna čvrstoća, N/mm^2
RMS	korijen srednje kvadratne pogreške
R^n	n -dimenzionalni prostor
$R_{p0,2}$	konvencionalna granica razvlačenja, N/mm^2
RT	ispitivanje se provodi na sobnoj temperaturi
S_z	stupanj zasićenja nodularnog lijeva
t	vrijeme, s
$t_{900-650}$	vrijeme hlađenja s 900 na 650 °C, s
t_d	dendritno vrijeme, s
t_{ES}	vrijeme početka eutektičke reakcije, s
t_S	vrijeme skrućivanja, s
u_j	J -i izlaz neurona
$\overline{u_{\text{rel}}}$	srednja vrijednost relativne pogreške, %
v	matrica težinskih koeficijenata skrivenog sloja neurona

\bar{v}_R	prosječna brzina rekalescencije, °C/s
$v_{R,max}$	najveća brzina rekalescencije, °C/s
v_{650}	brzina hlađenja taljevine pri temperaturi 650 °C, °C/s
v_{900}	brzina hlađenja taljevine pri temperaturi 900 °C, °C/s
\mathbf{w}	matrica težinskih koeficijenata izlaznog sloja neurona
W	ukupan broj težina neuronske mreže
w_J	J -i težinski koeficijent neuronske mreže
\mathbf{x}	vektor u n -dimenzionalnom prostoru
x_1, y_1, z_1	koordinate točke 1 u prostoru
x_2, y_2, z_2	koordinate točke 2 u prostoru
y	izlaz neurona
\mathbf{y}	vektor u n -dimenzionalnom prostoru
y_j	j -i izlaz iz skrivenog sloja neurona
\mathbf{Z}	matrica ulaznih podataka za neuronsku mrežu
%C	maseni udio ugljika, %
%Cr	maseni udio kroma, %
%Cu	maseni udio bakra, %
%Mn	maseni udio mangana, %
%Ni	maseni udio nikla, %
%P	maseni udio fosfora, %
%Si	maseni udio silicija, %
%V	maseni udio vanadija, %

Oznake prema grčkoj abecedi:

α	koeficijent zamaha
γ	aktivacijska funkcija
$\Delta \vartheta$	razlika temperature, °C
$\Delta \vartheta(n)$	promjena težinskih koeficijenata u n -tom koraku učenja
$\Delta \vartheta_{maks}$	maksimalno pothlađenje, °C

δ	karakteristična vrijednost algoritma povratnog rasprostiranja pogreške
δ_{Ok}	karakteristična vrijednost algoritma povratnog rasprostiranja pogreške za k -ti neuron izlaznog sloja, O
η	koeficijent brzine učenja
g	temperatura, °C
g_{EID}	temperatura eutektoidne pretvorbe, °C
g_{EP}	temperatura eutektičkog pothlađenja, °C
$g_{EP,t}$	teoretsko eutektičko pothlađenje, °C
g_{ER}	temperatura eutektičke rekalescencije, °C
g_{ES}	temperatura početka eutektičke reakcije, °C
$g_{E,metastabil}$	temperatura eutektičke reakcije za metastabilnu kristalizaciju, °C
$g_{E,stabil}$	temperatura eutektičke reakcije za stabilnu kristalizaciju, °C
g_L	temperatura likvidus, °C
g_{LA}	temperatura austenitnog zastoja, °C
g_R	rekalescencija, °C
g_r	temperatura referentnog materijala, °C
g_s	temperatura solidus, °C
g_{uz}	temperatura ispitivanog uzorka, °C
$g(n)$	težinski koeficijenti nakon n -tog koraka učenja
μ	Marquardtov parametar
σ	nagib sigmoidalne funkcije
σ_{d_n}	standardna devijacija ciljanih izlaza
σ_p	standardna devijacija nenormiranih vrijednosti

POPIS SLIKA

Slika 2.1. Svjetska proizvodnja nodularnog lijeva u zadnjih 60 godina [18].....	6
Slika 2.2. Godišnja proizvodnja nodularnog lijeva 10 zemalja najvećih proizvođača u 2006. godini [20]	7
Slika 2.3. Produktivnost po ljevaonici za pojedine zemlje u 2006. godini [20].....	7
Slika 2.4. Proizvodnja ljevova na bazi željeza u kg po stanovniku za 2001. godinu [21]	8
Slika 2.5. Usporedba svojstava različitih željeznih ljevova	9
Slika 2.6. Utjecaj udjela silicija i ugljika u nodularnom lijevu na strukturu i svojstva [18]	13
Slika 2.7. Utjecaj silicija na (a) granicu razvlačenja i istežljivost, te (b) žilavost i prijelaznu temperaturu nodularnog lijeva [18]	14
Slika 2.8. Utjecaj udjela Mn, Cu i Sn na udio perlita u metalnoj osnovi nodularnog lijeva [27].....	16
Slika 2.9. (a) Preporučeni udio mangana u nodularnom lijevu obzirom na udio silicija i debljinu stjenke; (b) Karbidi po granicama zrna uslijed visokog udjela mangana [18] .	16
Slika 2.10. Utjecaj mangana na mehanička svojstva nodularnog lijeva [27].....	17
Slika 2.11. Utjecaj fosfora na (a) žilavost i (b) prijelaznu temperaturu nodularnog lijeva [18]	18
Slika 2.12. Klasifikacija grafita u željeznim ljevovima prema HRN EN ISO 945:2002 [29]	23
Slika 2.13. Normirane veličine grafitnih nodula (grafit oblika VI.) u nodularnom lijevu [29]	24
Slika 2.14. Mikrostruktura nodularnog lijeva različitih nodularnosti: (a) 99 %; (b) 80 %; (c) 50 % [30].....	24
Slika 2.15. (a) Utjecaj nodularnosti na mehanička svojstva nodularnog lijeva; (b) Utjecaj udjela silicija iz cjepiva na broj nodula/mm ² za tri debljine stjenke [30].....	26
Slika 2.16. Mikrostruktura feritnog (a) i perlitnog (b) nodularnog lijeva, povećanje 100 puta, nagriženo 4 % nitalom [33]	27
Slika 2.17. Konvencionalna granica razvlačenja i vlačna čvrstoća nodularnog lijeva pri različitim udjelima perlita i nodularnostima [30].....	27

Slika 2.18. Udarni rad loma na različitim temperaturama za različite vrste nodularnog lijeva [30].....	27
Slika 2.19. Utjecaj debljine stjenke na mehanička svojstva nodularnog lijeva [30]	28
Slika 2.20. Krivulja zagrijavanja uzorka i DTA za egzotermni i endotermni proces [34]	30
Slika 2.21. Krivulje hlađenja taljevine nodularnog lijeva: bazna taljevina, taljevina nakon obrade magnezijem i cijepljena taljevina [18].....	32
Slika 2.22. Krivulja hlađenja nodularnog lijeva s označenim parametrima toplinske analize [18].....	33
Slika 2.23. Određivanje temperatura početka eutektičke reakcije, \mathcal{G}_{ES} i kraja skrućivanja, \mathcal{G}_s [39]	33
Slika 2.24. Krivulje hlađenja sivog, vermikularnog, nodularnog i bijelog tvrdog lijeva [44]	36
Slika 2.25. Nodularnost i broj nodula grafita u ovisnosti o eutektičkoj rekalescenciji i eutektičkom pothlađenju [36].....	36
Slika 2.26. Krivulja hlađenja nodularnog lijeva bez karbida u strukturi [18].....	37
Slika 2.27. Krivulja hlađenja nodularnog lijeva s primarnim karbidima u strukturi [18]	38
Slika 2.28. Krivulja hlađenja nodularnog lijeva s interkristalnim karbidima u strukturi [18]	38
Slika 2.29. Model statičkog neurona [53].....	43
Slika 2.30. (a) Unipolarna i (b) bipolarna sigmoidalna aktivacijska funkcija.....	43
Slika 2.31. Geometrijsko tumačenje glavnih komponenti [58].....	45
Slika 2.32. Statička unaprijedna višeslojna neuronska mreža.....	46
Slika 2.33. Tipičan izgled presjeka plohe pogreške učenja neuronske mreže [61].....	48
Slika 2.34. Opći oblik statičke unaprijedne višeslojne neuronske mreže [53].....	49
Slika 2.35. Pogreška u skupovima za učenje i testiranje prema koracima učenja [61]..	58
Slika 3.1. Komora i princip Flotret postupka obrade taljevine njenim prelijevanjem preko predlegure FeSiMg.....	68
Slika 3.2. Postupak obrade taljevine magnezijem Osmoza.....	69

Slika 3.3. Polovina bakrene kokile u koju su lijevani uzorci za ispitivanje kemijskog sastava taljevina.....	70
Slika 3.4. Postrojenje za izradu jezgri i kalupa postupkom Beta – set.....	72
Slika 3.5. Oblik i dimenzije Y2 – probe prema HRN EN 1563	72
Slika 3.6. Hlađenje dviju odljevenih Y – proba u kalupu.....	73
Slika 3.7. Epruveta za statičko vlačno ispitivanje B 14 x 70 prema HRN EN 1563 [22]	73
Slika 3.8. Sustav za toplinsku analizu taljevine ATAS	76
Slika 3.9. Čašica Quik – cup®	77
Slika 3.10. Krivulja hlađenja u eutektičkom području za taljevinu br. 2 s izmjerenim toplinskim parametrima.....	79
Slika 3.11. Prva derivacija krivulje hlađenja u eutektičkom području za taljevinu br. 2 s izmjerenim toplinskim parametrima.....	80
Slika 3.12. Krivulja hlađenja u eutektoidnom području za taljevinu br. 2 s izmjerenim toplinskim parametrima.....	81
Slika 3.13. Uzorci nodularnog lijeva pripremljeni za metalografsku analizu	82
Slika 3.14. Fotografija mikrostrukture feritnog nodularnog lijeva (lijev br. 29) u: (a) nenagriženom i (b) nagriženom stanju	83
Slika 3.15. Fotografija mikrostrukture perlitnog nodularnog lijeva (lijev br. 105) u nagriženom stanju.....	84
Slika 4.1. Utjecaj nagiba aktivacijske funkcije skrivenih neurona na pogrešku predviđanja nodularnosti	90
Slika 4.2. Utjecaj broja skrivenih neurona na pogrešku predviđanja nodularnosti	93
Slika 4.3. Korelacija između predviđenih i izmjerenih nodularnosti u skupu za testiranje	93
Slika 4.4. Izmjerene i predviđene nodularnosti iz skupa za učenje.....	95
Slika 4.5. Izmjerene i predviđene nodularnosti iz skupova za validaciju i testiranje.....	96
Slika 4.6. Utjecaj broja skrivenih neurona na pogrešku predviđanja broja nodula po jedinici površine	98
Slika 4.7. Korelacija između predviđenog i izmjerenog broja nodula po jedinici površine u skupu za testiranje	98

Slika 4.8. Izmjereni i predviđeni broj nodula/ mm ² iz skupa za učenje	100
Slika 4.9. Izmjereni i predviđeni broj nodula/ mm ² iz skupova za validaciju i testiranje	101
Slika 4.10. Utjecaj broja skrivenih neurona na pogrešku predviđanja udjela ferita	102
Slika 4.11. Korelacija između predviđenog i izmjerenog udjela ferita skupu za testiranje	104
Slika 4.12. Izmjereni i predviđeni udjeli ferita iz skupa za učenje.....	105
Slika 4.13. Izmjereni i predviđeni udjeli ferita iz skupova za validaciju i testiranje....	106
Slika 4.14. Utjecaj broja skrivenih neurona na pogrešku predviđanja vlačne čvrstoće	108
Slika 4.15. Korelacija između predviđenih i izmjerenih vlačnih čvrstoća u skupu za testiranje	110
Slika 4.16. Izmjerene i predviđene vlačne čvrstoće iz skupa za učenje	111
Slika 4.17. Izmjerene i predviđene vlačne čvrstoće iz skupova za validaciju i testiranje	112
Slika 4.18. Utjecaj broja skrivenih neurona na pogrešku predviđanja konvencionalne granice razvlačenja	114
Slika 4.19. Korelacija između predviđenih i izmjerenih konvencionalnih granica razvlačenja u skupu za testiranje	114
Slika 4.20. Izmjerene i predviđene konvencionalne granice razvlačenja iz skupa za učenje.....	116
Slika 4.21. Izmjerene i predviđene konvencionalne granice razvlačenja iz skupova za validaciju i testiranje.....	117
Slika 4.22. Utjecaj broja skrivenih neurona na pogrešku predviđanja istežljivosti.....	119
Slika 4.23. Korelacija između predviđenih i izmjerenih istežljivosti u skupu za testiranje	119
Slika 4.24. Izmjerene i predviđene istežljivosti iz skupa za učenje	121
Slika 4.25. Izmjerene i predviđene istežljivosti iz skupova za validaciju i testiranje ..	122
Slika 4.26. Utjecaj broja skrivenih neurona na pogrešku predviđanja tvrdoće	124
Slika 4.27. Korelacija između predviđenih i izmjerenih tvrdoća u skupu za testiranje	124
Slika 4.28. Izmjerene i predviđene tvrdoće iz skupa za učenje.....	126
Slika 4.29. Izmjerene i predviđene tvrdoće iz skupova za validaciju i testiranje.....	127

Slika 4.30. Utjecaj broja skrivenih neurona na pogrešku predviđanja vlačne čvrstoće na temelju mikrostrukture	128
Slika 4.31. Korelacija između izmjerenih vlačnih čvrstoća i čvrstoća predviđenih na temelju mikrostrukture u skupu za testiranje.....	130
Slika 4.32. Izmjerene vlačne čvrstoće i predviđene na temelju mikrostrukture iz skupa za učenje	131
Slika 4.33. Izmjerene vlačne čvrstoće i predviđene na temelju mikrostrukture iz skupova za validaciju i testiranje	132
Slika 5.1. Korelacija između izmjerenih vlačnih čvrstoća i (a) istežljivosti, odnosno (b) tvrdoća nodularnih ljevova	137

POPIS TABLICA

Tablica 2.1. Normom propisani udarni rad loma nodularnog lijeva (HRN EN 1563:1997).....	10
Tablica 2.2. Normom propisana mehanička svojstva nodularnog lijeva (HRN EN 1563:1997).....	11
Tablica 3.1. Udjeli pojedinih komponenti za izradu 1 t rastaljenog metala za proizvodnju nodularnog lijeva.....	64
Tablica 3.2. Kemijski sastav specijalnog sivog sirovog željeza za proizvodnju nodularnog lijeva	64
Tablica 3.3. Kemijski sastav čelika koji se koristi za proizvodnju nodularnog lijeva ...	65
Tablica 3.4. Kemijski sastav povratnog materijala	65
Tablica 3.5. Kemijski sastav ferosilicija u briketima	65
Tablica 3.6. Kemijski sastav ljevačkog koksa.....	66
Tablica 3.7. Kemijski sastav vapnenca CaCO_3	66
Tablica 3.8. Sastav i svojstva kalciniranog petrol – koksa.....	67
Tablica 3.9. Sastav tehničkog kalcij – karbida	67
Tablica 4.1. Parametri pogreške pri predviđanju nodularnosti različitim ulaznim skupovima toplinskih parametara.....	91
Tablica 4.2. Pogreške za pojedine ljevove u skupu za testiranje pri predviđanju nodularnosti	94
Tablica 4.3. Pogreške za pojedine ljevove u skupu za testiranje pri predviđanju broja nodula po jedinici površine	99
Tablica 4.4. Pogreške za pojedine ljevove u skupu za testiranje pri predviđanju udjela ferita.....	103
Tablica 4.5. Pogreške za pojedine ljevove u skupu za testiranje pri predviđanju vlačne čvrstoće.....	109
Tablica 4.6. Pogreške za pojedine ljevove u skupu za testiranje pri predviđanju konvencionalne granice razvlačenja.....	115
Tablica 4.7. Pogreške za pojedine ljevove u skupu za testiranje pri predviđanju istežljivosti.....	120

Tablica 4.8. Pogreške za pojedine ljevove u skupu za testiranje pri predviđanju tvrdoće	125
Tablica 4.9. Pogreške za pojedine ljevove u skupu za testiranje pri predviđanju vlačne čvrstoće na temelju mikrostrukture	129
Tablica 5.1. Pregled parametara pogreške iz skupova za učenje, validaciju i testiranje pri predviđanju različitih mikrostrukturnih parametara i svojstava nodularnih ljevova....	136

POPIS PRILOGA

Prilog 1. Svjetska proizvodnja odljevaka u 2006. [20]	I
Prilog 2. Proizvodnja iz 2001. g. željeznih i neželjeznih legura po glavi stanovnika za pojedine zemlje, rangirano [21].....	II
Prilog 3. Kemijski sastav ispitivanih taljevina (taljevine br. 1 – 50).....	III
Prilog 4. Kemijski sastav ispitivanih taljevina (taljevine br. 51 – 100).....	IV
Prilog 5. Kemijski sastav ispitivanih taljevina (taljevine br. 101 – 147).....	V
Prilog 6. Razdioba pojedinih legirnih elemenata u pripremljenim nodularnim ljevovima (1. dio)	VI
Prilog 7. Razdioba pojedinih legirnih elemenata u pripremljenim nodularnim ljevovima (2. dio)	VII
Prilog 8. Razdioba pojedinih legirnih elemenata u pripremljenim nodularnim ljevovima (3. dio)	VIII
Prilog 9. Mehanička svojstva svih ispitivanih taljevina	IX
Prilog 10. Razdioba mehaničkih svojstava pripremljenih nodularnih ljevova.....	X
Prilog 11. Toplinski parametri s krivulje hlađenja za ispitivane taljevine br. 1 – 30.....	XI
Prilog 12. Toplinski parametri s krivulje hlađenja za ispitivane taljevine br. 31 – 60 ..	XII
Prilog 13. Toplinski parametri s krivulje hlađenja za ispitivane taljevine br. 61 – 90 ..	XIII
Prilog 14. Toplinski parametri s krivulje hlađenja za ispitivane taljevine br. 91 – 120	XIV
Prilog 15. Toplinski parametri s krivulje hlađenja za ispitivane taljevine br. 121 – 147	XV
Prilog 16. Razdioba važnijih toplinskih parametara s krivulja hlađenja pripremljenih nodularnih ljevova (1. dio)	XVI
Prilog 17. Razdioba važnijih toplinskih parametara s krivulja hlađenja pripremljenih nodularnih ljevova (2. dio)	XVII
Prilog 18. Mikrostrukturni parametri za taljevine br. 1 – 50.....	XVIII
Prilog 19. Mikrostrukturni parametri za taljevine br. 51 – 100.....	XIX
Prilog 20. Mikrostrukturni parametri za taljevine br. 101 – 147.....	XX
Prilog 21. Razdioba mikrostrukturnih parametara pripremljenih nodularnih ljevova.	XXI

Prilog 22. Matrice početnih vrijednosti težinskih koeficijenata skrivenog sloja neuronske mreže	XXII
Prilog 23. Matrice početnih vrijednosti težinskih koeficijenata izlaznog sloja neuronske mreže	XXIII
Prilog 24. Matrice konačnih vrijednosti težinskih koeficijenata skrivenog sloja (\mathbf{W}_1 , \mathbf{b}_1) i izlaznog sloja (\mathbf{W}_2 , \mathbf{b}_2) neuronske mreže za predviđanje nodularnosti na temelju odabranih parametara toplinske analize	XXIV
Prilog 25. Matrice konačnih vrijednosti težinskih koeficijenata skrivenog sloja (\mathbf{W}_1 , \mathbf{b}_1) i izlaznog sloja (\mathbf{W}_2 , \mathbf{b}_2) neuronske mreže za predviđanje broja nodula po jedinici površine na temelju odabranih parametara toplinske analize.....	XXV
Prilog 26. Matrice konačnih vrijednosti težinskih koeficijenata skrivenog sloja (\mathbf{W}_1 , \mathbf{b}_1) i izlaznog sloja (\mathbf{W}_2 , \mathbf{b}_2) neuronske mreže za predviđanje udjela feritana temelju odabranih parametara toplinske analize	XXVI
Prilog 27. Matrice konačnih vrijednosti težinskih koeficijenata skrivenog sloja (\mathbf{W}_1 , \mathbf{b}_1) i izlaznog sloja (\mathbf{W}_2 , \mathbf{b}_2) neuronske mreže za predviđanje vlačne čvrstoće na temelju odabranih parametara toplinske analize	XXVII
Prilog 28. Matrice konačnih vrijednosti težinskih koeficijenata skrivenog sloja (\mathbf{W}_1 , \mathbf{b}_1) i izlaznog sloja (\mathbf{W}_2 , \mathbf{b}_2) neuronske mreže za predviđanje konvencionalne granice razvlačenja na temelju odabranih parametara toplinske analize	XXVIII
Prilog 29. Matrice konačnih vrijednosti težinskih koeficijenata skrivenog sloja (\mathbf{W}_1 , \mathbf{b}_1) i izlaznog sloja (\mathbf{W}_2 , \mathbf{b}_2) neuronske mreže za predviđanje istezljivosti na temelju odabranih parametara toplinske analize	XXIX
Prilog 30. Matrice konačnih vrijednosti težinskih koeficijenata skrivenog sloja (\mathbf{W}_1 , \mathbf{b}_1) i izlaznog sloja (\mathbf{W}_2 , \mathbf{b}_2) neuronske mreže za predviđanje tvrdoće na temelju odabranih parametara toplinske analize	XXX
Prilog 31. Matrice konačnih vrijednosti težinskih koeficijenata skrivenog sloja (\mathbf{W}_1 , \mathbf{b}_1) i izlaznog sloja (\mathbf{W}_2 , \mathbf{b}_2) neuronske mreže za predviđanje vlačne čvrstoće na temelju mikrostrukture	XXXI

1. UVOD

1.1. Definiranje problema

Lijevanjem se mogu postići složeni oblici proizvoda, koje bi bilo vrlo skupo ili tehnološki vrlo teško proizvesti na drugi način. Tehnološki postupak lijevanja poznat je oko 6000 godina.

Nodularni lijev je željezni lijev koji objedinjuje dobru livljivost sivog lijeva i visoku vlačnu čvrstoću čeličnog lijeva. Svoju povoljnu mikrostrukturu postiže već u lijevanom stanju pa odljevke najčešće nije potrebno naknadno toplinski obrađivati, kao što je to slučaj s tempernim lijevom, čime su troškovi proizvodnje značajno smanjeni. Kod nodularnog se lijeva povoljna mikrostruktura s kuglicama grafita postiže obradom taljevine prije ulijevanja. Proizvodnja nodularnog lijeva od njegovog otkrića prije 60-ak godina kontinuirano raste, a s vremenom se nastoje poboljšati proizvodni postupci i primijeniti nove metode i modeli računalnih simulacija, kako bi se smanjili troškovi i smanjio udio škartnih odljevaka.

Struktura, a time i svojstva nodularnog lijeva nisu izravno ovisna o kemijskom sastavu lijeva, već su znatno ovisna o primijenjenim metalurškim postupcima na taljevini. Krivulja hlađenja snima se tijekom skrućivanja taljevine i daljeg hlađenja odljevka i različita je za željezne ljeveve različitog kemijskog sastava i/ili različite metalurške povijesti. Na temelju podataka dobivenih snimanjem krivulje hlađenja mogu se okarakterizirati svojstva i struktura određenog lijeva.

Dosadašnja istraživanja na području primjene umjetnih neuronskih mreža u znanosti i inženjerstvu materijala pokazala su da se one mogu uspješno primijeniti u rješavanju niza različitih problema predviđanja svojstava čelika i ljevova na bazi željeza i drugih skupina materijala. Tako su uspješno riješeni problemi predviđanja mikrostrukture čelika na temelju veličine austenitnog zrna i brzine hlađenja u temperaturnom intervalu u kojem dolazi do faznih pretvorbi [1], problem predviđanja tvrdoće i dubine boridnog sloja na čelicima [2], predviđanja lomne žilavosti mikrolegiranih čelika [3], parametara nitriranja [4], predviđanje prokaljivosti čelika [5, 6], koeficijenta toplinske vodljivosti [7] i količine zaostalog austenita u izotermički

poboljšanom nodularnom lijevu [8]. Obradeno je i određivanje mehaničkih svojstava nodularnog lijeva na temelju kemijskog sastava [9], kao i mehaničkih svojstava na temelju kemijskog sastava, temperatura taljenja i temperature ulijevanja [10], uz upotrebu linearne regresije i umjetnih neuronskih mreža.

Toplinska analiza taljevine je široko korištena u proizvodnji metala jer je dokazano da se gotovo cijela povijest taljevine manifestira kroz karakteristike skrućivanja [11]. Fizikalno značenje pojedinih temperatura, prve i druge derivacije krivulje hlađenja ljevova na bazi željeza obrađeno je u literaturi [12, 13]. U početnim su istraživanjima krivulje hlađenja dobivene toplinskom analizom raščlanjivane na bitne segmente, pojavni tipovi tih segmenta klasificirani u skupine, da bi se kasnijom usporedbom sa stvarnim krivuljama hlađenja, predviđala mikrostruktura nodularnog lijeva [14]. Razvijeni su modeli za određivanje kvantitativne veze između mehaničkih svojstava, kao što su tvrdoća, vlačna čvrstoća i istezljivost, s mikrostrukturnim parametrima nodularnog lijeva [15]. Optimiranje svojstava željeznih ljevova na temelju podataka dobivenih toplinskom analizom moguće je upotrebom sustava za odlučivanje temeljenih na bazama znanja [16]. Za određivanje žilavosti nodularnog lijeva na temelju parametara diferencijalne toplinske analize taljevine mogu se koristiti i umjetne neuronske mreže [17].

U ovom će se radu umjetne neuronske mreže primijeniti u predviđanju mikrostrukture i mehaničkih svojstava nodularnog lijeva. Od mikrostrukturnih parametara predviđet će se nodularnost grafita i broj nodula po jedinici površine, te udio ferita, a od mehaničkih svojstava vlačna čvrstoća, konvencionalna granica razvlačenja, istezljivost i tvrdoća. Ulazni podaci bit će podaci dobiveni snimanjem krivulje hlađenja toplinskom analizom.

1.2. Hipoteza rada

Pretpostavlja se da metoda umjetnih neuronskih mreža može biti uspješno primijenjena za točnije predviđanje mikrostrukture i mehaničkih svojstava, a na temelju podataka dobivenih toplinskom analizom taljevine nodularnog lijeva.

Korištenjem rezultata dobivenih toplinskom analizom taljevine prije njenog ulijevanja u kalup primjenom naučene neuronske mreže mogu se unaprijediti procesi

taljenja i obrade taljevine u ljevaonici, a u cilju postizanja boljih ili optimalne kombinacije mehaničkih svojstava kao i odgovarajuće mikrostrukture.


2. TEORIJSKI DIO

2.1. Nodularni lijev

2.1.1. Općenito o nodularnom lijevu


Kombinacija dobre livljivosti sivog lijeva i čvrstoće čeličnog lijeva je u prvoj polovini 20. stoljeća bila djelomično zadovoljena upotrebom tempernog lijeva. Temperni se lijev dobiva postupkom dugotrajnog decementacijskog žarenja bijelog tvrdog lijeva, tijekom kojeg se razlaže cementit, Fe_3C . Time ugljik u elementarnom stanju stvara nakupine grafita, koje su uložene u feritnu ili perlitnu metalnu osnovu, ovisno o brzini hlađenja s temperature žarenja. Troškovi proizvodnje ovog materijala su zbog žarenja visoki pa, uz teškoće lijevanja većih odljevaka od bijelog lijeva, je primjena tempernog lijeva ostala ograničena.

U radu Hentona Morrogha objavljenom 1948. prvi je put prikazano dodavanje cerija u željeznu taljevinu, čime se izravno, bez toplinske obrade, postizao grafit izlučen u obliku kuglica u mikrostrukturi odljevaka. Povoljna mehanička svojstva, kao što su posebno visoka vlačna čvrstoća i duktilnost, tj. istezljivost ovog novog materijala nagovijestila su njegovu buduću uspješnu primjenu. Nakon objave ovog istraživanja, objavljen je i rad Keitha Millsa i suradnika koji su i ranije, 1943. godine, postigli istu mikrostrukturu dodavanjem magnezija u željeznu taljevinu, no to istraživanje nisu bili objavili iz strateških razloga. Radovi Morrogha i Millsa postali su temelj razvoja novog lijeva na bazi željeza kojeg zovemo nodularni ili žilavi lijev [18]. Od tada, proizvodnja nodularnog lijeva u svijetu raste kontinuirano kroz godine. U zadnjih pedesetak godina u Njemačkoj je nodularni lijev zamijenio 73 % tempernog lijeva i 38 % čeličnog lijeva [19]. Slika 2.1. prikazuje porast svjetske proizvodnje nodularnog lijeva od njegova otkrića.




Slika 2.1. Svjetska proizvodnja nodularnog lijeva u zadnjih 60 godina [18]

Ukupna svjetska proizvodnja nodularnog lijeva u 2003. godini bila je veća od 16 milijuna tona. Prilog 1. tablično prikazuje popis odljevenih količina pojedinih ljevova na bazi željeza (sivi, nodularni, temporni i čelični lijev), kao i ukupnu količinu svih metalnih odljevaka (uključujući lake i obojene metale) po pojedinim zemljama svijeta za 2006. godinu [20]. Iz tablice se također može očitati da je ukupna svjetska godišnja proizvodnja nodularnog lijeva bila veća od 21 milijun tona. Nadalje, tablica prikazuje broj ljevaonica koje lijevaju ljevove na bazi željeza, čelični lijev i neželjezne legure po pojedinim zemljama. Slika 2.2. prikazuje godišnju proizvodnju za 10 zemalja koje su proizvele najveće količine nodularnog lijeva u 2006. godini. Sa 6.843.019 t Kina je najveći svjetski proizvođač nodularnog lijeva, dok je u Hrvatskoj u 2006. godini proizvedeno 18.243 t nodularnog lijeva. Slika 2.3. prikazuje količinu proizvedenih svih metalnih odljevaka po ljevaonici za istih 10 zemalja, prema kojoj se vidi da je Njemačka najproduktivniji svjetski proizvođač ljevova, dok je u Kini produktivnost 8 puta manja. Masa izlivenih odljevaka po ljevaonici u Hrvatskoj je u 2006. godini bila 1622 t.




Slika 2.2. Godišnja proizvodnja nodularnog lijeva 10 zemalja najvećih proizvođača u 2006. godini [20]



Slika 2.3. Produktivnost po ljevaonici za pojedine zemlje u 2006. godini [20]


Prilog 2. tablicom prikazuje količine proizvedenih željeznih i neželjeznih odljevaka u 2001. godini po glavi stanovnika za pojedine zemlje, posloženo u padajućem nizu [21]. Vodeće zemlje u proizvodnji ljevova na bazi željeza, s količinama od 40 do 50 kg lijeva po stanovniku, su Slovenija, Njemačka, Tajvan i Češka. Za njima su Rusija, Francuska, Koreja, Japan i SAD, s 36–38 kg/stanovniku/godini. Prosječna je proizvodnja željeznih ljevova 16,3 kg/stanovniku. Hrvatska je daleko ispod prosjeka s

godišnjom proizvodnjom od 8,7 kg/stanovniku. Slika 2.4. prikazuje proizvodnju po stanovniku za izabrane države.



Slika 2.4. Proizvodnja ljevova na bazi željeza u kg po stanovniku za 2001. godinu [21]

Razlog brzog rasta proizvedenih količina nodularnog lijeva su povoljna svojstva, kao što su dobra livljivost, mogućnost površinskog kaljenja, visok modul elastičnosti, povoljna čvrstoća, otpornost koroziji, relativno dobra obradivost itd. Slika 2.5. prikazuje usporedbu svojstava nodularnog, tempernog, sivog, čeličnog i bijelog tvrdog lijeva.



Slika 2.5. Usporedba svojstava različitih željeznih ljevova

Ipak, najvažniji je razlog sve veće proizvodnje nodularnog ljeva vrlo povoljan omjer cijene i čvrstoće. Omjeri cijene (prema procjenama iz 2001. godine) i vlačne čvrstoće različitih ljevova su sljedeći [18]:

$$\text{Sivi ljev: } \frac{1500 \text{ USD / t}}{250 \text{ MPa}} = 6 \text{ USD / MPa}$$

$$\text{Čelični ljev: } \frac{3000 \text{ USD / t}}{500 \text{ MPa}} = 6 \text{ USD / MPa}$$

$$\text{Temperni ljev: } \frac{2000 \text{ USD / t}}{400 \text{ MPa}} = 5 \text{ USD / MPa}$$

$$\text{Nodularni ljev: } \frac{1700 \text{ USD / t}}{500 \text{ MPa}} = 3,4 \text{ USD / MPa}$$

Izotermički poboljšani
nodularni ljevi: $\frac{2500 \text{ USD} / \text{t}}{1000 \text{ MPa}} = 2,5 \text{ USD} / \text{MPa}$

Aluminijske legure: $\frac{8000 \text{ USD} / \text{t}}{200 \text{ MPa}} = 40 \text{ USD} / \text{MPa}$

2.1.2. Klasifikacija nodularnog lijeva

Hrvatska norma HRN EN 1563:1997 propisuje klasifikaciju nodularnog lijeva. Prema normi, ljevovi se klasificiraju na temelju minimalnih vrijednosti vlačne čvrstoće, konvencionalne granice razvlačenja, istežljivosti i žilavosti. Također, norma dozvoljava i propisuje klasifikaciju prema tvrdoći, ali samo za slučaj internog dogovora između proizvođača i kupca nodularnog lijeva. Tablica 2.1. prikazuje normom propisane vrijednosti udarnog rada loma nodularnog lijeva ispitanog na uzorcima s V – utorom izgledanih iz posebno odljevnih ispitnih uzoraka. Tablica 2.2. prikazuje normom propisana mehanička svojstva nodularnog lijeva ispitana na posebno odljevnim ispitnim uzorcima [22]. Oznake željeznih ljevova propisuje norma HRN EN 1560:2004, pa npr. oznaka EN-GJS-350-22 govori da je riječ o nodularnom lijevu koji zadovoljava europsku normu, koji ima garantiranu vrijednost vlačne čvrstoće 350 N/mm² i istežljivost minimalno 22 % [23].

Tablica 2.1. Normom propisani udarni rad loma nodularnog lijeva (HRN EN 1563:1997)

Označivanje materijala:		Minimalna vrijednost udarnog rada loma, <i>KV</i> , J					
Oznaka:	Broj:	Pri sobnoj temp. 23±5 °C		Pri -20±2 °C		Pri -40±2 °C	
		Sr. vr. 3 mj. ¹⁾	Pojed. vr. ²⁾	Sr. vr. 3 mj.	Pojed. vr.	Sr. vr. 3 mj.	Pojed. vr.
EN-GJS-350-22-LT	EN-JS1015	–	–	–	–	12	9
EN-GJS-350-22-RT	EN-JS1014	17	14	–	–	–	–
EN-GJS-400-18-LT	EN-JS1025	–	–	12	9	–	–
EN-GJS-400-18-RT	EN-JS1024	14	11	–	–	–	–

¹⁾ srednja vrijednost triju mjerenja

²⁾ pojedinačna vrijednost

Tablica 2.2. Normom propisana mehanička svojstva nodularnog lijeva (HRN EN 1563:1997)

Označivanje materijala:		Vlačna čvrstoća, R_m , N/mm^2 , min.	Konv. granica razvlačenja, $R_{p0,2}$, N/mm^2 , min.	Istezljivost, A , %, min.
Oznaka:	Broj:			
EN-GJS-350-22-LT ¹⁾	EN-JS1015	350	220	22
EN-GJS-350-22-RT ²⁾	EN-JS1014	350	220	22
EN-GJS-350-22	EN-JS1010	350	220	22
EN-GJS-400-18-LT ¹⁾	EN-JS1025	400	240	18
EN-GJS-400-18-RT ²⁾	EN-JS1024	400	250	18
EN-GJS-400-18	EN-JS1020	400	250	18
EN-GJS-400-15	EN-JS1030	400	250	15
EN-GJS-450-10	EN-JS1040	450	310	10
EN-GJS-500-7	EN-JS1050	500	320	7
EN-GJS-600-3	EN-JS1060	600	370	3
EN-GJS-700-2	EN-JS1070	700	420	2
EN-GJS-800-2	EN-JS1080	800	480	2
EN-GJS-900-2	EN-JS1090	900	600	2

¹⁾ LT (engl. *low temperature*) – žilavost se ispituje na niskim temperaturama

²⁾ RT (engl. *room temperature*) – žilavost se ispituje na sobnoj temperaturi

2.1.3. Kemijski sastav nodularnog lijeva

Prema kemijskom sastavu, nodularni lijev je visokouglični lijev na bazi željeza, kod kojega se ugljik izlučuje u obliku kuglica grafita. Približni sastav nodularnog lijeva je [24]:

3,2 do 3,8 %C,

2,4 do 2,8 %Si,

< 0,5 %Mn,

< 0,04 5%P,

< 0,01 %S,

0,03 do 0,04 %Mg.

Izlučivanje ugljika u obliku kuglica grafita postiže se dodavanjem malih količina magnezija, cerija ili itrija u taljevinu neposredno prije ulijevanja taljevine u kalup. Ukoliko rastaljeni metal sadrži prevelike količine sumpora ili ukoliko sadrži male

količine inhibitora nodulacije, kao što su titan, bizmut ili olovo, ugljik se neće izlučiti u obliku kuglica, već u obliku listića, i tako neće nastati nodularni, već sivi lijev [25].

Struktura i svojstva nodularnog lijeva posljedica su brojnih čimbenika, a moguće ih je podijeliti u sljedeće tri skupine:

- a) metalurški procesi nad taljevinom,
- b) kemijski sastav,
- c) brzina hlađenja pri skrućivanju i hlađenju u čvrstom stanju.

Na oblik grafita i strukturu metalne osnove znatno utječe kemijski sastav. Prema utjecaju na mikrostrukturu, kemijski elementi koji se pojavljuju u nodularnom lijevu mogu se podijeliti u sljedeće skupine:

- primarni elementi: C, Si, Mn, S, P,
- nodulatori: Mg, rijetke zemlje (Ce, La i sl.),
- elementi koji utječu na metalnu matricu: Cu, Sn,
- legirajući elementi: Ni, Mo,
- karbidotvorci: Cr, V, B, Mo, Te,
- nepoželjni elementi (sprječavaju stvaranje kuglastog grafita) [25].

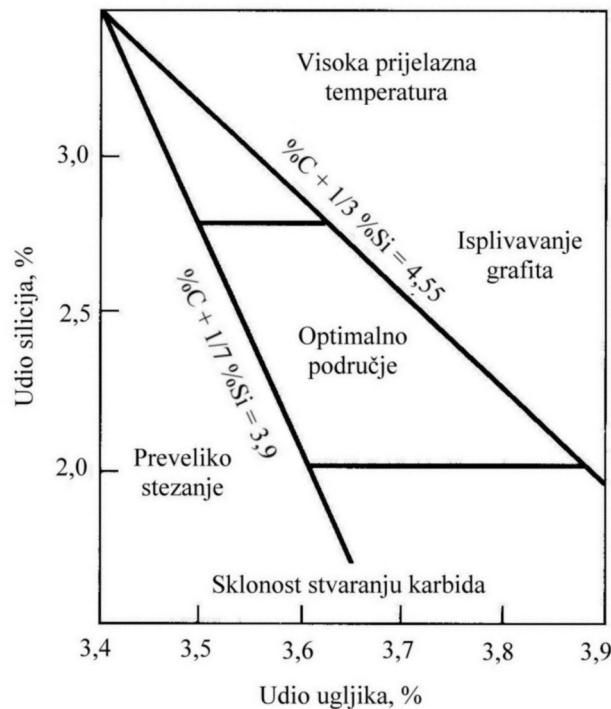
2.1.3.1. Ugljik i silicij

Od svih elemenata prisutnih u nodularnom lijevu, uz ugljik, naj snažniji utjecaj na eutektički udio ima silicij. Silicij pomiče eutektički udio prema vrijednostima nižim od 4,3 %C, koliko iznosi eutektički maseni udio ugljika za ravnotežni dijagram stanja sustava željezo – ugljik. Kemijski se sastav može izraziti preko stupnja zasićenja ili preko ekvivalenta ugljika. Jednadžba (2.1) predstavlja izraz za izračunavanje stupnja zasićenja, S_z . Eutektički sastav nodularnog lijeva ima $S_z = 1$, podeutektički $S_z < 1$, a nadeutektički $S_z > 1$. Češće se pri iskazivanju sastava nodularnog lijeva koristi vrijednost ekvivalenta ugljika, CE, prema izrazu (2.2). Prema tom empirijskom izrazu, 1 % silicija snižava eutektički udio za približno 0,33 %C. Ukoliko je izračunati ekvivalent ugljika veći od 4,3 %, legura se smatra nadeutektičkom, a ukoliko je manji od 4,3 %, legura je podeutektička.

$$S_z = \frac{\%C}{4,26 - \frac{1}{3}(\%Si + \%P)} \quad (2.1)$$

$$CE = \%C + \frac{\%Si}{3} + \frac{\%P}{3} \quad (2.2)$$

Sadržaj ugljika neznatno utječe na mehanička svojstva nodularnog lijeva. Obično se teži što većem udjelu ugljika, pri kojem je sastav legure blizu eutektičkom, jer se time poboljšava livljivost taljevine. Slika 2.6. prikazuje Handersonov dijagram, kojim su prikazana područja udjela silicija i ugljika u nodularnom lijevu i utjecaj njihovog različitog udjela na sastav i svojstva. Dovoljan udio silicija važan je za postizanje strukture bez karbida.




Slika 2.6. Utjecaj udjela silicija i ugljika u nodularnom lijevu na strukturu i svojstva [18]

Udio ugljika u nodularnom lijevu je najčešće između 3,4 i 3,9 %, a ovisi o debljini stjenke odljevka. Veće se vrijednosti javljaju kod tanjih stjenki (< 5 mm), a niže kod debljih stjenki (> 50 mm). Visoke vrijednosti ekvivalenta ugljika i sporo hlađenje debelostjenih odljevaka mogu uzrokovati flotaciju ili isplivavanje kuglica grafita i njihovu degeneraciju. Kod tankostjenih odljevaka ne postoji opasnost od flotacije, već

se javlja povećana mogućnost stvaranja karbida, pa se u tom slučaju koriste ljevovi s višim vrijednostima ekvivalenta ugljika.

Osim što potiče stvaranje grafita, tj. sprečava nastajanje karbida, silicij značajno povisuje vlačnu čvrstoću, granicu razvlačenja i istezljivost feritnih vrsta nodularnog lijeva. Slika 2.7. (a) prikazuje utjecaj silicija na konvencionalnu granicu razvlačenja, $R_{p0,2}$, i na istezljivost, A , za nodularni lijev u lijevanom stanju s feritno – perlitnom metalnom osnovom i za nodularni lijev u žarenom stanju s feritnom osnovom. Također, silicij povećava tvrdoću feritnog nodularnog lijeva. Kako silicij povećava vlačnu čvrstoću i tvrdoću nodularnog lijeva, tako istovremeno smanjuje žilavost lijeva. Slika 2.7. (b) prikazuje utjecaj silicija na žilavost nodularnog lijeva pri različitim temperaturama. Silicij snižava vrijednosti udarnog rada loma i linearno povećava prijelaznu temperaturu krhkog loma. Udio silicija obično se postavlja u granicama 1,5 do 3 %. Ovaj utjecaj na žilavost nodularnog lijeva je naročito važan kod feritnih vrsta nodularnog lijeva, dok je kod feritno – perlitnih ljevova manje izražena obzirom da je kod tih ljevova žilavost ionako smanjena uslijed pojave perlita u mikrostrukturi osnove. Ako za upotrebu žilavost nije posebno važna, može se povećati udio silicija da se ostvari jednofazna feritna metalna osnova. Takva mikrostruktura daje jednoličnu tvrdoću i bolju obradivost obradom odvajanjem čestica.




Slika 2.7. Utjecaj silicija na (a) granicu razvlačenja i istezljivost, te (b) žilavost i prijelaznu temperaturu nodularnog lijeva [18]

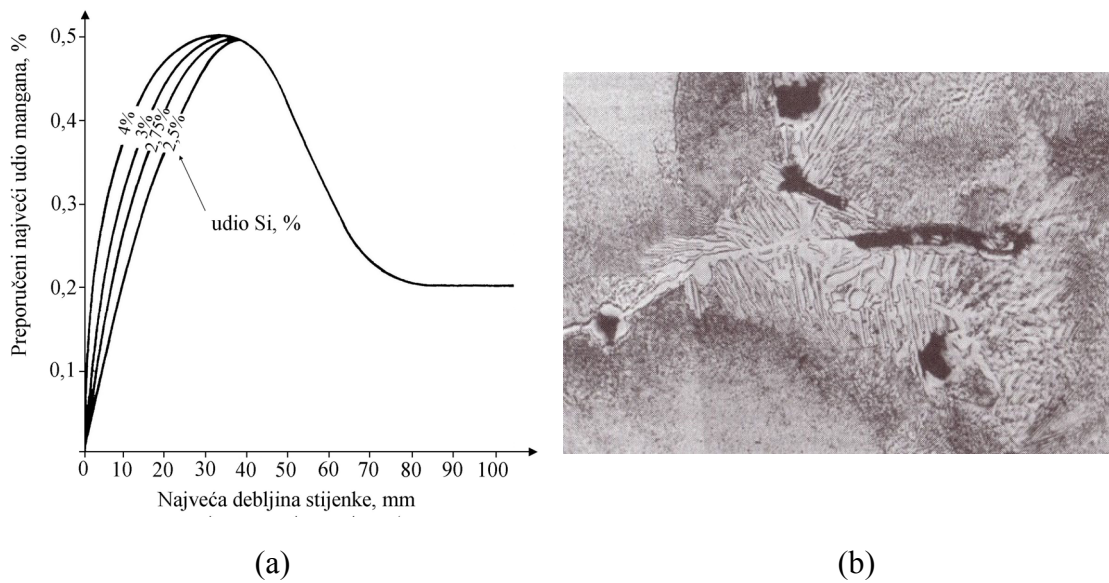
Varijacije udjela silicija utječu sasvim suprotno na vlačnu čvrstoću i tvrdoću nodularnog lijeva u toplinski obrađenom stanju, što se može pripisati djelovanju silicija na očvršćivanje feritne osnove. Vjerojatnost dobivanja normom propisanih vrijednosti udarnog rada loma na niskim temperaturama ($-20\text{ }^{\circ}\text{C}$) povećava se s feritizirajućim žarenjem odljevaka i ograničavanjem konačnog udjela silicija u nodularnom lijevu ispod 2,5 % [26].

2.1.3.2. Mangan

Mangan je karbidotvorac i pospješuje stvaranje perlita. Slika 2.8. prikazuje utjecaj udjela Mn, Cu i Sn na udio perlita u metalnoj osnovi [27]. Udio mangana u nodularnom lijevu mora se kontrolirati u cilju izbjegavanja pojave karbida u lijevanom stanju. Dozvoljeni udio mangana ovisi o udjelu silicija u lijevu i najvećoj debljini stjenke koja se pojavljuje na odljevku. Slika 2.9. (a) prikazuje dijagram za određivanje preporučene količine mangana na temelju udjela silicija i debljine stjenke. Kako se iz dijagrama može zaključiti, kod tanjih stjenki (do 30mm) sklonost mangana k stvaranju karbida može se uspješno nadomjestiti povišenjem udjela silicija. Ova je pojava posebno izražena pri smanjenju debljina stjenke. Npr. kod odljevaka koji imaju stjenke debljine 12 mm, dozvoljeni udio mangana povećava se s 0,2 na 0,25 % ako se udio silicija poveća s 2,5 na 3 %. Kod odljevaka srednjih i velikih debljina stjenki, dakle, kod sporijih ohlađivanja, silicij nema opisani utjecaj jer dolazi do segregacije. Kako se silicij izdvaja u krutinu koja se prva skrućuje, u taljevini koja se zadnja skrućuje može doći do izrazitog porasta udjela mangana, npr. s prosječnih 0,35 % u lijevu na više od 2,5 % u zadnjoj taljevini. Slika 2.9. (b) prikazuje mikrostrukturu gdje je uslijed visokog udjela mangana došlo do stvaranja karbida po granicama zrna.




Slika 2.8. Utjecaj udjela Mn, Cu i Sn na udio perlita u metalnoj osnovi nodularnog lijeva [27]



Slika 2.9. (a) Preporučeni udio mangana u nodularnom lijevu obzirom na udio silicija i debljinu stijenke; (b) Karbidi po granicama zrna uslijed visokog udjela mangana [18]

Ukoliko se traži visoka žilavosti i istezljivost nodularnog lijeva, potrebno je udio mangana održavati što nižim jer mangan pospješuje stvaranje perlita. Ukoliko se traži visoka tvrdoća i otpornost na trošenje, udio mangana u nodularnom lijevu raste do 1 %. Npr. nodularni lijev s 0,35 %Mn nakon žarenja ima istezljivost 20 %, dok lijev s 0,78 %Mn ima istezljivost svega 4 % [25]. Slika 2.10. prikazuje promjenu tvrdoće, vlačne čvrstoće i konvencionalne granice razvlačenja s povećanjem udjela mangana [27]. U istim je dijagramima prikazan utjecaj bakra i kositra.




Slika 2.10. Utjecaj mangana na mehanička svojstva nodularnog lijeva [27]

2.1.3.3. Sumpor

Obzirom da magnezij ima snažan afinitet prema sumporu, pri obradi bazne taljevine magnezijem nastaje magnezij – sulfid, MnS. Kako se ne bi trebalo dodavati previše magnezija, nastoji se udio sumpora u baznoj taljevini održati unutar granica od 0,01 do 0,06 %. Osim toga, visok udio sumpora izaziva uključke u odljevcima, koji smanjuju čvrstoću i žilavost lijeva. S druge strane, ni prenizak udio (<0,005 %) sumpora u baznoj taljevini nije poželjan jer tada taljevina loše reagira na obradu magnezijem. Posljedica toga je nizak broj nodula po jedinici površine i sklonosti nastajanju karbida.

2.1.3.4. Fosfor

Fosfor ne utječe na oblik izlučenog grafita, ali jako nepovoljno utječe na mehanička svojstva. Taj je kemijski element nepoželjan sastojak nodularnog lijeva i njegov udio treba biti što niži, po mogućnosti ispod 0,03 %. Fosfor stvara eutektik Fe_3P niskog tališta, koji se izlučuje po granicama zrna u obliku krhke i tvrde faze, uslijed čega se značajno smanjuju istezljivost i žilavost nodularnog lijeva. Fosfor stabilizira perlit, čime se povećava tvrdoća i čvrstoća, a smanjuje istezljivost. Međutim, najnepovoljniji učinak fosfora je na povišenje prijelazne temperature u području žilavog/ krhkog loma. Slika 2.11. prikazuje promjenu (a) žilavosti i (b) prijelazne temperature nodularnog lijeva za različite udjele fosfora.



Slika 2.11. Utjecaj fosfora na (a) žilavost i (b) prijelaznu temperaturu nodularnog lijeva [18]

2.1.3.5. Magnezij

Kada se magnezij dodaje u baznu taljevinu, on je najprije dezoksidira, zatim odsumpori i tek tada se njegovo djelovanje usmjerava na oblikovanje kuglica grafita. Ovisno o udjelu sumpora u baznoj taljevini, potrebna količina magnezija za stvaranje potpuno nodularne strukture grafita je od 0,02 do 0,06 %. Magnezij ima vrelište na 1090

°C, pa se pri njegovom dodavanju u taljevinu željeznog lijeva, koja je obično zagrijana na približno 1500 °C, događa vrlo burna reakcija. Obrada taljevine provodi se čistim magnezijem ili predlegurama FeSiMg, odnosno NiMg. Najčešće se koristi predlegura FeSiMg.

Produkt dezoksidacije taljevine magnezijem, MgO, je kemijski vrlo stabilan spoj, visokog tališta, niske gustoće i niske topivosti u željezu. Stoga se MgO skuplja na površini taljevine. Ukoliko MgO ostane zarobljen pri ulijevanju, mogu nastati štetni tvrdi uključci u odljevku. Magnezij sa sumporom tvori magnezij – sulfid, MgS, koji također, zbog male gustoće, teži isplivati na površinu taljevine. Ako je magnezija prisutno u suvišku, on potiče stvaranje eutektičkih karbida, pojavu poroznosti i uključaka troske.

2.1.3.6. Cerij i rijetke zemlje

Poput magnezija, cerij (Ce) snažno dezoksidira i odsumporava taljevinu, ali, kako mu je vrelište iznad 3000 °C, pri njegovom dodavanju u taljevinu željeznog lijeva ne događa se burna reakcija kao pri dodavanju magnezija. Također, cerij tvori stabilnije okside i sulfide, pa se manje cerija gubi, a manja je i vjerojatnost nastajanja uključaka. Ako se cerij koristi kao primarni nodulator, dovoljno je 0,035 %Ce za postizanje potpuno nodularne strukture u nadeutektičkom nodularnom lijevu. Međutim, kako je cerij i jak karbidotvorac, nodularni lijev proizveden cerijem kao nodulatorom je znatno osjetljiviji na pojavu karbida u lijevanom stanju.

Cerij se najčešće koristi kao komponenta rijetkih zemlji u leguri FeSiMg. Ta predlegura služi za obradu taljevine magnezijem, a sadrži obično 0,5 do 1 % cerija. Cerij i ostale rijetke zemlje korištene na ovaj način značajno doprinose povećanju broja nodula. Druge rijetke zemlje uključuju lantan (La), neodimij (Nd) i praseodimij (Pr). Lantan ima prednost pred cerijem jer je slabiji karbidotvorac, daje veći broj nodula i smanjuje opasnost od pojave pukotina uslijed stezanja.

2.1.3.7. Bakar

Bakar potiče stvaranje perlita, ne potiče nastajanje karbida i spada u skupinu elemenata grafitizatora. Bakar se dodaje kad je potrebo postići potpuno perlitnu

strukturu metalne osnove u nodularnom lijevu. Iako je topivost bakra u željezu oko 2,5 %, u nodularni se lijev dodaje najviše 1,5 % bakra kako bi se izbjegao svaki utjecaj bakra na oblikovanje kuglica grafita.

Legiranjem nodularnog lijeva bakrom, povećavaju se troškovi proizvodnje u odnosu na postizanje iste strukture manganom, ali je opasnost od nastajanja karbida znatno manja. Istraživanja [18] su pokazala da je dovoljno 0,82 % bakra ili 1,74 % mangana za postizanje potpuno perlitne mikrostrukture, ali se kod potonjeg slučaja javljaju i karbidi na granicama zrna.

Bakar smanjuje žilavost nodularnog lijeva i povisuje prijelaznu temperaturu žilavo/ krhko. Značajno povisuje vlačnu čvrstoću i tvrdoću u lijevanom stanju tako što povećava udio perlita i smanjuje njegovu zrnatost. S druge strane, kada se želi postići potpuno feritna mikrostruktura, potrebno je udio bakra održavati što nižim, obično do 0,03 %.

Pri legiranju nodularnog lijeva bakrom važno je koristiti bakar visoke čistoće, kako se ne bi onečišćenim povratnim materijalom unijeli štetni elementi, kao što su arsen, olovo, telur itd.

2.1.3.8. Kositar

Kositar snažno potiče stvaranje perlita te, kao i bakar, ne potiče stvaranje karbida sve do 0,15 % udjela kositra. Kositar se, poput bakra, tijekom skrućivanja nakuplja na površini grafitnih kuglica i tako sprječava difuziju ugljika. Na taj način ugljik iz austenita ostaje zarobljen i ne može difundirati u grafitne nakupine, zbog čega se austenit pretvara u perlit.

Kositar je približno 10 puta djelotvorniji u stvaranju perlitne metalne osnove u odnosu na bakar i za postizanje potpuno perlitne strukture potrebno ga je, ovisno o debljini stjenke odljevka, dodati tek 0,03 do 0,08 %.

Ukoliko se doda previše kositra (0,1 % u suvišku), nastaje relativno debela i tvrda ovojnica kositra oko grafitnih kuglica. Posljedica toga je značajno smanjenje istezljivosti i žilavosti odljevka. Maksimalno dozvoljeni udio kositra u nodularnom lijevu je 0,1 %. Za dobivanje feritnog nodularnog lijeva dozvoljen je udio kositra 0,01 %.

Često se u proizvodnji perlitnog nodularnog lijeva koriste zajedno kositar i bakar jer se njihovo djelovanje u povećanju tvrdoće odljevaka nadopunjava. Obje najviše dozvoljene količine (1,5 %Cu i 0,1 %Sn) ne smiju biti prekoračene.

2.1.3.9. Molibden

Molibden se dodaje nodularnom lijevu u cilju povećanja prokaljivosti. Dodavanjem do 0,1 %Mo postiže se martenzitna struktura bez perlita, bilo u lijevanom stanju ili nakon toplinske obrade. Osim toga, molibden se dodaje i radi povećanja vlačne čvrstoće na povišenim temperaturama. Dodatak do 2 % molibdena značajno povećava vlačnu čvrstoću na povišenim temperaturama i otpornost puzanju.

Molibden se smatra blagim karbidotvorcem, međutim pri suvišku većem od 0,3 %, mogu se pojaviti karbidi po granicama zrna. Ova je pojava izraženija kod odljevaka debljih stjenki, gdje sporo hlađenje pogoduje segregaciji molibdena, te kod ljevova legiranih s drugim karbidotvorcima, kao što su Cr, Mn i V.

Molibden povećava tvrdoću i granicu razvlačenja feritnog nodularnog lijeva. Za svako povećanje udjela od 1 %, vlačna se čvrstoća povećava za 42 MPa, a tvrdoća za oko 15 HRB, dok se istezljivost smanjuje za oko 8 % [18]. Molibden povećava vlačnu čvrstoću na povišenim temperaturama i kod feritnog i kod austenitnog nodularnog lijeva.

2.1.3.10. Nikal

Nikal se dodaje u nodularni lijev u cilju:

- povišenja prokaljivosti dodavanjem 0,5 do 4 % Ni,
- postizanja austenitne strukture metalne osnove dodavanjem 18 do 36 % Ni,
- poboljšanja mehaničkih svojstava feritnih vrsta lijeva pri sniženim temperaturama,
- povećanja granice razvlačenja i vlačne čvrstoće ljevova s niskim udjelom silicija.

Nikal je grafitizator, približno tri puta slabiji od silicija. On povećava temperaturu stabilne eutektičke pretvorbe i snižava temperaturu metastabilne eutektičke pretvorbe, te time smanjuje opasnost od nastanka karbida.

2.1.3.11. Ostali elementi u tragovima


Neki kemijski elementi, iako mogu biti prisutni tek u tragovima u nodularnom lijevu, ipak sprječavaju izlučivanje kuglica grafitu. Ako npr. taljevina sadrži iznad 0,13 %Al, 0,04 %Ti, 0,009 %Pb, 0,026 %Sb ili 0,003 %Bi, grafit će se izlučiti u obliku listića. Povećanje količine dodanog magnezija ne može ukloniti štetno djelovanje ovih elemenata. Spomenuti elementi dolaze u taljevinu kroz sirovine, npr. od boja ili emajla s otpadnog čelika, zalemljenih spojeva, ostataka maziva ili goriva u dijelovima otpadnih blokova motora itd. [28] Za proizvodnju nodularnog lijeva je, stoga, potrebno koristiti minimalno propisani udio posebno kvalitetnog sirovog željeza, za koje se garantira da je udio štetnih elemenata ispod dozvoljene granice.

2.1.4. Mikrostruktura nodularnog lijeva i utjecajni čimbenici


Nodularni je lijev legura približno eutektičkog sastava. Eutektik koji nastaje prilikom skrućivanja taljevine može biti stabilan ili metastabilan. Kod stabilne kristalizacije nastaju grafit i austenit, a kod metastabilne cementit (Fe_3C) i austenit. Postoji, također, treća mogućnost nastajanja miješane strukture austenita, grafita i cementita.

Brušenjem, poliranjem i nagrivanjem površine uzoraka nodularnog lijeva, te promatranjem takvog uzorka pod mikroskopom utvrđujemo njegovu mikrostrukturu.

Nakon brušenja i poliranja, pod mikroskopom su vidljive izlučevine grafita. Oblik grafita određuje se tijekom skrućivanja i na njega se ne može utjecati naknadnom toplinskom obradom. Sva specifična mehanička svojstva nodularnog lijeva posljedica su pojave grafita u obliku kuglica, koje su više ili manje pravilnog oblika. Slika 2.12. prikazuje normom HRN EN ISO 945:2002 propisanu klasifikaciju oblika grafita [29]. Prema toj normi, nodularni lijev ima oblik grafita VI. Ista norma propisuje normirane veličine grafitnih nodula (oblika VI.) u nodularnom lijevu uz povećanje od 100 puta, pri čemu se promatraju najveće nodule u slici. Slika 2.13. prikazuje pojedine veličine grafitnih nodula.




Slika 2.12. Klasifikacija grafita u željeznim ljevovima prema HRN EN ISO 945:2002 [29]



Slika 2.13. Normirane veličine grafitnih nodula (grafit oblika VI.) u nodularnom lijevu [29]


Nodularnost je volumni udio kuglastih nakupina grafita prema ukupnom broju grafitnih izlučevina. Cilj je proizvesti nodularni lijev sa što većom nodularnošću, obično iznad 90 %, jer mehanička svojstva izravno ovise o pravilnosti kuglica grafita [30]. Slika 2.14. prikazuje fotografije mikrostrukture triju nodularnih ljevova kod kojih se pojavljuje različita nodularnost.



Slika 2.14. Mikrostruktura nodularnog lijeva različitih nodularnosti: (a) 99 %; (b) 80 %; (c) 50 % [30]


Vlačna čvrstoća i dinamička izdržljivost izrazito opadaju s porastom udjela nekuglastih oblika grafita, dok se granica razvlačenja ne mijenja tako drastično. Slika 2.15. (a) prikazuje dijagramom ove pojave. Oblik nekuglastog grafita je važan jer tanki listići grafita s oštrim rubovima uzrokuju značajan pad vlačne čvrstoće. Smanjena nodularnost utječe i na modul elastičnosti, snižava žilavost, povećava sposobnost prigušenja vibracija, povećava toplinsku vodljivost i smanjuje električni otpor.

Prilikom proizvodnje odljevaka od nodularnog lijeva taljevina se, osim obrade nodulatorima, cijepi. Kod većine vrsta nodularnog lijeva pojava metastabilnih eutektičkih karbida u mikrostrukturi je nepoželjna, osim u slučaju da se zahtijeva povećana otpornost na abrazijsko trošenje. Cijepljenjem se potiče stabilno skrućivanje, povećava se broj nodula i poboljšava nodularnost [31]. Osim toga, povećanje broja nodula u lijevu otežava nastajanje karbida i potiče stvaranje ferita. Na taj se način smanjuje opasnost od nastanka tvrdih i krhkih mjesta u odljevku. Nadalje, takvi odljevci imaju ujednačenu vlačnu čvrstoću, istežljivost, tvrdoću i obradivost odvajanjem čestica, kao i ujednačena svojstva po različitim presjecima istog odljevka. Učinak cijepljenja je daleko veći nego što bi se moglo pripisati promijenjenom kemijskom sastavu taljevine nakon cijepljenja. Cijepljenjem se aktiviraju dodatni centri za nukleaciju i rast grafita. Učinak cijepljenja je najveći neposredno nakon dodavanja cjepiva i opada s vremenom. Brzina opadanja učinka cijepljenja ovisi o brojnim čimbenicima. Najvažniji su: kemijski sastav cjepiva, sastav taljevine u koju se dodaje cjepivo, temperatura taljevine i brzina hlađenja između likvidusa i solidusa [18]. Slika 2.15. (b) prikazuje utjecaj udjela silicija, koji je dodan u taljevinu iz cjepiva, na broj nodula po jedinici površine za tri odljevka različite debljine stjenke. Pri porastu udjela grafita u mikrostrukturi dolazi do blagog pada vlačne čvrstoće, istežljivosti i gustoće nodularnog lijeva.

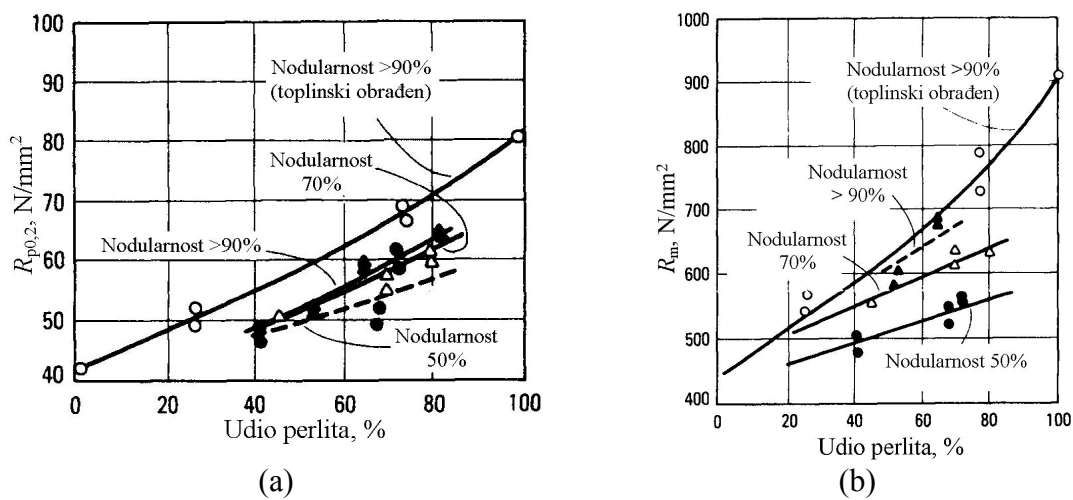


Slika 2.15. (a) Utjecaj nodularnosti na mehanička svojstva nodularnog lijeva; (b) Utjecaj udjela silicija iz cjeviva na broj nodula/ mm^2 za tri debljine stjenke [30]

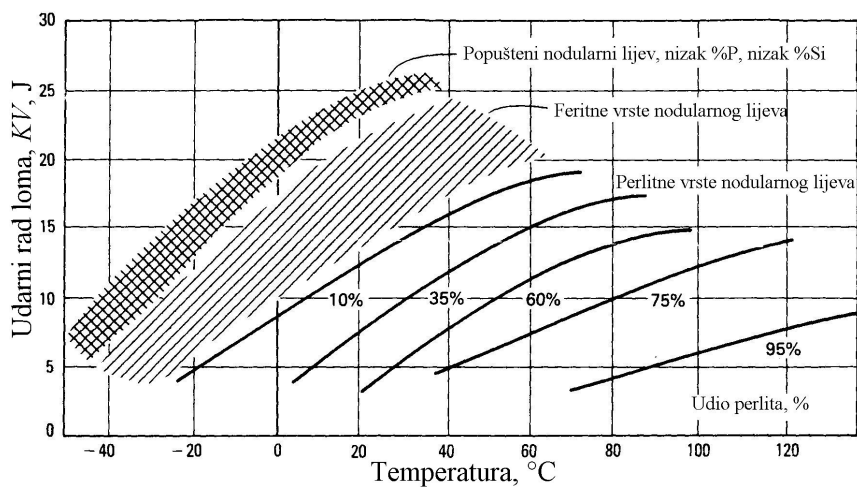
Metalna osnova nodularnog lijeva postaje vidljiva nakon što se izbrušeni i polirani uzorak nagriže nitalom. Nital je otopina dušične kiseline u etilnom alkoholu. Metalna osnova može biti feritna, perlitna, feritno – perlitna ili austenitna. Austenitni nodularni lijev koristi se prije svega u uvjetima tražene otpornosti na visoke temperature, otpornosti na koroziju i trošenje [32]. Slika 2.16. prikazuje mikrostrukture (a) feritnog i (b) perlitnog nodularnog lijeva, pri povećanju 100 puta, obje nagrižene 4 % nitalom [33]. U lijevanom stanju nodularni ljevovi imaju najčešće feritno – perlitnu metalnu osnovu. Pri povećanju udjela ferita u metalnoj osnovi, lijev ima nižu vlačnu čvrstoću lijevu, višu istezljivost, višu žilavost i nižu prijelaznu temperaturu žilavo/krhko. Slika 2.17. prikazuje promjenu (a) konvencionalne granice razvlačenja i (b) vlačne čvrstoće s promjenom udjela perlita za različite nodularnosti nodularnog lijeva. Slika 2.18. predstavlja promjenu vrijednosti udarnog rada loma pri promjeni temperature ispitivanja za različite metalne osnove nodularnog lijeva.



Slika 2.16. Mikrostruktura feritnog (a) i perlitnog (b) nodularnog lijeva, povećanje 100 puta, nagriženo 4 % nitalom [33]



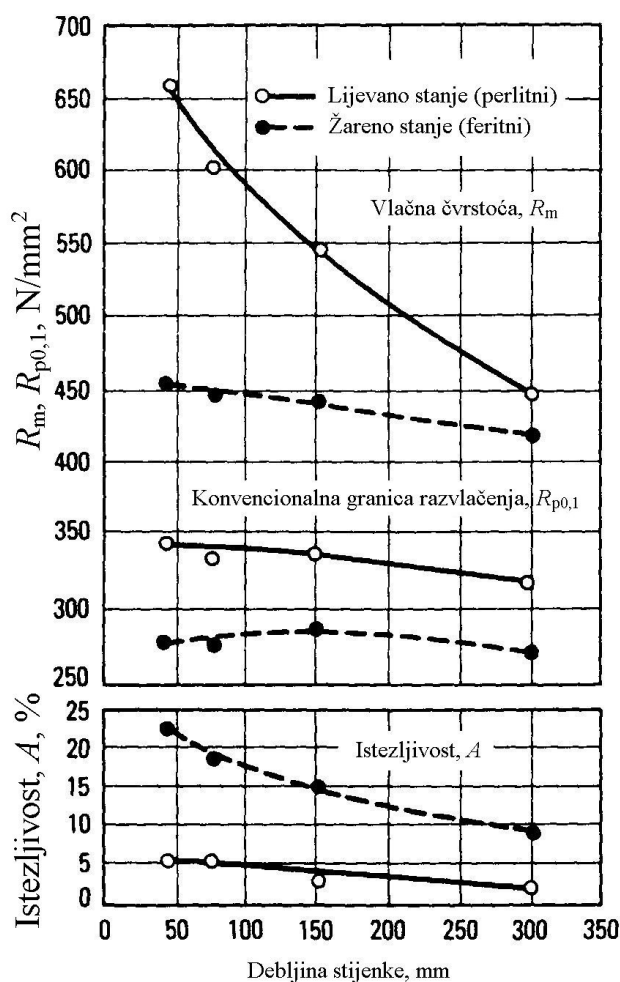
Slika 2.17. Konvencionalna granica razvlačenja i vlačna čvrstoća nodularnog lijeva pri različitim udjelima perlita i nodularnostima [30]



Slika 2.18. Udarni rad loma na različitim temperaturama za različite vrste nodularnog lijeva [30]

Na strukturu i svojstva nodularnog lijeva utječe i debljina stjenke odljevka. Kako se stjenka stanjuje, povećavaju se brzina kristalizacije i brzina hlađenja. Time se dobiva sitnozrnata mikrostruktura, ali se mogu pojaviti i karbidi koji povećavaju tvrdoću, smanjuju obradivost odvajanjem čestica i smanjuju žilavost odljevka. Stoga je kod tankostjenih odljevaka taljevinu potrebno pojačano cijepiti, i to što kasnije, kako bi se stvorio što veći broj nodula.

S povećanjem debljine stjenke smanjuje se broj nodula, nastaju velike nodule i sve je izraženija mikrosegregacija. Kod posebno debelih stjenki dolazi do segregacije karbidotvoraca, kao što su krom, titan i vanadij, što uzrokuje smanjenje istezljivosti, žilavosti i čvrstoće i tek blago smanjenje granice razvlačenja. Slika 2.19. prikazuje utjecaj debljine stjenke i metalne osnove na mehanička svojstva nodularnog lijeva.



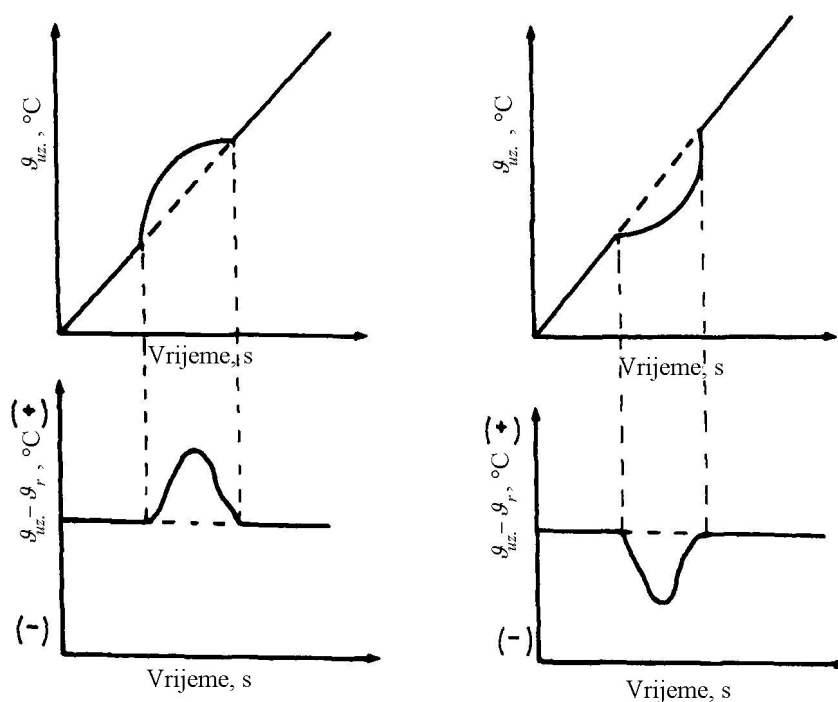
Slika 2.19. Utjecaj debljine stjenke na mehanička svojstva nodularnog lijeva [30]

2.2. Toplinska analiza

Pod pojmom toplinska analiza podrazumijevaju se metode kojima se ispituje bilo koji fizikalni parametar sustava u ovisnosti o temperaturi, pri čemu se određeni fizikalni parametar registrira kao dinamička funkcija temperature. Osnovne metode toplinske analize koje se najčešće koriste su termogravimetrija i diferencijalna toplinska analiza [34].

Diferencijalna toplinska analiza ili skraćeno DTA, prema engl. *Differential Thermal Analysis*, temelji se na uspoređivanju toplinskih svojstava ispitivanog uzorka i toplinski inertnog materijala. Parametar koji se kod ove metode registrira je razlika temperature, $\Delta\vartheta$, između ispitivanog uzorka, ϑ_{uz} i referentnog, inertnog materijala, ϑ_r , pri čemu se oba zagrijevaju ili hlade u istim uvjetima i s konstantnom brzinom zagrijavanja, odnosno ohlađivanja.

Različita promjena temperature ispitivanog uzorka pri zagrijavanju ili hlađenju u odnosu na temperaturu referentnog uzorka uvjetovana je promjenom entalpije uslijed odvijanja nekog procesa u ispitivanom uzorku. Ti procesi mogu biti: fazne transformacije, taljenje, prekrystalizacija, vrenje, isparavanje, reakcije dehidracije, disocijacije, oksidacije, redukcije itd. Neki su od pobrojanih procesa endotermni, npr. fazne transformacije, a neki su egzotermni, npr. kristalizacija. Slika 2.20. shematski prikazuje krivulje zagrijavanja uzorka u funkciji vremena i njihove pripadajuće DTA krivulje za slučaj egzotermnog i endotermnog procesa. U slučaju egzotermnog procesa, uslijed oslobađanja topline, ϑ_{uz} raste brže, a na krivulji DTA razlika temperature, $\Delta\vartheta$, se kreće prema višim vrijednostima. U slučaju endotermnog procesa, uslijed uzimanja topline iz okoline za odvijanje samog procesa, temperatura uzorka raste sporije, a na krivulji DTA se javlja otklon u negativnom smjeru. Nakon završetka egzotermnog ili endotermnog procesa, temperatura zagrijavanog uzorka raste istim tijekom koji je imala prije procesa.




Slika 2.20. Krivulja zagrijavanja uzorka i DTA za egzotermni i endotermni proces [34]

Obzirom da se razlika u temperaturi između ispitivanog i referentnog uzorka može registrirati s daleko većom osjetljivošću nego sama temperatura uzorka, otkloni na krivuljama DTA su znatno izraženiji nego na krivuljama zagrijavanja uzorka. Veličina, tj. površina nastalog pika na krivulji DTA i površina otklona od prvobitne krivulje zagrijavanja ili hlađenja ne ovise o toplinskom kapacitetu uzorka, već o vrijednosti entalpije procesa koji se odvija u ispitivanom uzorku tijekom zagrijavanja ili hlađenja. Ova je činjenica doprinijela razvoju diferencijalne toplinske analize i za kvantitativna određivanja toplina transformacija koje se događaju tijekom ispitivanja. Površina pika kada su termoparovi u toplinskom, ali ne i fizičkom kontaktu s ispitivanim i referentnim materijalom proporcionalna je masi uzorka i promjeni specifične entalpije, obrnuto proporcionalna koeficijentu toplinske vodljivosti uzorka, a ovisi i o obliku uzorka [35].

2.2.1. Toplinska analiza nodularnog lijeva


Proizvodnja odljevaka od nodularnog lijeva koja se temelji na empirijskim pravilima je skupa i spora, pa je racionalizacija proizvodnje i kontrola troškova uvjet konkurentnosti proizvodnje lijevaonice. Kontrola kvalitete se u suvremenim lijevaonicama temelji na kontroli parametara procesa, a manje na kontroli već odljevenih proizvoda [36]. Kako bi se poboljšala kvaliteta odljevaka i smanjio udio škarta, potrebno je optimirati uvjete proizvodnje. Jedan od tih uvjeta je i kontrola taljevine i njena pravodobna korekcija prije ulijevanja u kalupe [11]. Kemijskom analizom pomoću spektrometra može se odrediti približan udio pojedinog kemijskog elementa u taljevini nodularnog lijeva. Međutim kemijska analiza taljevine ne daje nikakvu informaciju o udjelu spojeva kao što su SiO_2 ili FeO , silikata ili u taljevini otopljenog kisika. Ovi spojevi u velikoj mjeri određuju nukleacijsko stanje taljevine, odnosno određuju način na koji će grafit precipitirati tijekom skrućivanja. Zbog toga dvije taljevine s identičnim kemijskim sastavom mogu imati različita mehanička svojstva i mikrostrukturu nakon ulijevanja. Kemijska analiza je, stoga, nedovoljna za učinkovito praćenje stanja taljevine [37].

Toplinska analiza omogućuje mjerenje promjena tijekom skrućivanja. Parametri koji su identificirani i izmjereni toplinskom analizom mogu se upotrijebiti za procjenu utjecaja proizvodnih varijabli na skrućivanje, odnosno ocjenu metalurške kvalitete taljevine, zbog čega se toplinska analiza smatra otiskom prsta ili DNK-om taljevine [38]. Slika 2.21. prikazuje krivulje hlađenja taljevine nodularnog lijeva u različitom metalurškom stanju: bazna taljevina, taljevina nakon obrade magnezijem i cijepljena taljevina [18]. Toplinska se analiza koristi u lijevaonicama već mnogo godina.

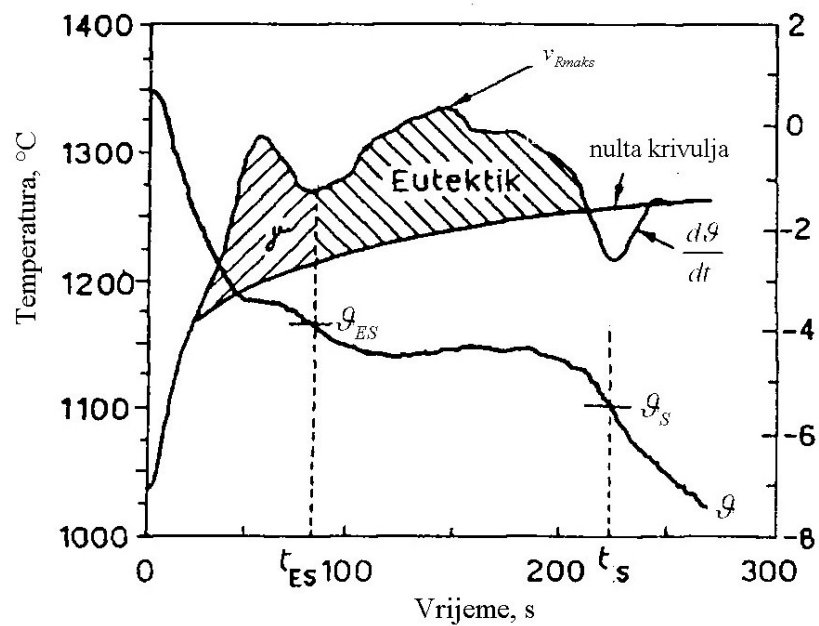


Slika 2.21. Krivulje hlađenja taljevine nodularnog lijeva: bazna taljevina, taljevina nakon obrade magnezijem i cijepljena taljevina [18]

Računalom potpomognuta analiza krivulje hlađenja (engl. *Computer aided cooling curve analysis*, CA – CCA) temelji se na upotrebi konvencionalne toplinske analize i diferencijalne toplinske analize. Kako bi se prevladala ograničenja konvencionalne diferencijalne toplinske analize, podaci se prikupljaju s krivulje hlađenja dobivene pri ulijevanju taljevine u lončić s ugrađenim termoparom i spremaju se u računalo. Zatim se izračunavaju prva i druga derivacija krivulje hlađenja, te se i one koriste u potpunijem tumačenju faznih promjena. Slika 2.22. prikazuje krivulju hlađenja nodularnog lijeva s označenim različitim parametrima toplinske analize [18]. Najčešće se koriste sljedeći parametri za određivanje pojedinih karakteristika taljevine: likvidus temperatura, \mathcal{G}_L , temperatura eutektičkog pothlađenja, \mathcal{G}_{EP} , temperatura eutektičke rekalescencije, \mathcal{G}_{ER} , rekalescencija, \mathcal{G}_R ($\mathcal{G}_R = \mathcal{G}_{ER} - \mathcal{G}_{EP}$), maksimalno pothlađenje, $\Delta\mathcal{G}_{maks}$, solidus temperatura, \mathcal{G}_S , temperatura eutektičke reakcije za stabilnu kristalizaciju, $\mathcal{G}_{E, stabil}$ i temperatura eutektičke reakcije za metastabilnu kristalizaciju, $\mathcal{G}_{E, metastabil}$. Slika 2.23. prikazuje kako se mogu odrediti temperatura početka eutektičke reakcije, \mathcal{G}_{ES} , i temperatura kraja skrućivanja, \mathcal{G}_S [39].



Slika 2.22. Krivulja hlađenja nodularnog lijeva s označenim parametrima toplinske analize [18]



Slika 2.23. Određivanje temperatura početka eutektikacije, ϑ_{ES} i kraja skrućivanja, ϑ_s [39]

2.2.1.1. Primjena toplinske analize u određivanju kemijskog sastava nodularnog lijeva

Već se duže vrijeme u ljevaonicama toplinska analiza koristi za kontrolu sastava taljevine tijekom proizvodnje. Opsežno istraživanje pokazalo je čvrstu povezanost

likvidus temperature, \mathcal{G}_L , i ugljičnog ekvivalenta likvidusa, CEL, što prikazuje empirijska jednadžba (2.3) [40].

$$\mathcal{G}_L [^{\circ}\text{C}] = 1664 - 124 \text{ CEL} \quad (2.3)$$

Ugljični ekvivalent likvidusa, CEL, predstavlja relativan utjecaj ugljika, silicija i fosfora na temperaturu likvidusa [41]. Jednadžbom (2.4) određuje se ugljični ekvivalent likvidusa, CEL, gdje su %C, %Si i %P maseni udjeli ugljika, silicija i fosfora.

$$\text{CEL} = \%C + \frac{\%Si}{4} + \frac{\%P}{2} \quad (2.4)$$

Udio ugljika u nelegiranim kvalitetama željeznog lijeva s $\text{CEL} < 4,3$ moguće je odrediti unutar intervala od $\pm 0,1$ % pomoću metastabilne kristalizacije uzorka taljevine u lončiću premazanim telurom. Temperatura likvidusa, \mathcal{G}_L i temperatura eutektičkog zastoja pri metastabilnoj kristalizaciji, $\mathcal{G}_{E,\text{metastabil}}$ ovise o sastavu na način:

$$\mathcal{G}_L [^{\circ}\text{C}] = 1650 - 124,5 \%C - 26,7 (\%Si + 2,45 \%P) \quad (2.5)$$

$$\mathcal{G}_{E,\text{metastabil}} [^{\circ}\text{C}] = 1140 - 9,8 \%C - 12,1 (\%Si + 2,45 \%P) \quad (2.6)$$

odakle slijedi:

$$\%C = 0,01693 \mathcal{G}_{E,\text{metastabil}} - 0,00796 \mathcal{G}_L - 6,05 \quad (2.7)$$

Na sličan je način određen izraz za izračunavanje udjela silicija [42], pomoću kojega se može procijeniti udio silicija na $\pm 0,14$ % kod željeznih ljevova s malim udjelom fosfora (0,05 %P):

$$\%Si = 86,79 - 0,00566 \mathcal{G}_L - 0,07016 \mathcal{G}_{E,\text{metastabil}} - 2,45 \%P \quad (2.8)$$

Točnost određivanja udjela ugljika i silicija uvjetovana je točnošću mjerenja temperature. Pogreška od ± 1 °C pri mjerenju \mathcal{G}_L i $\mathcal{G}_{E,\text{metastabil}}$ uzrokuje pogrešku od $\pm 0,02$ %C, dok je pogreška pri određivanju silicija znatno veća: $\pm 0,08$ %Si [43].

Za određivanje udjela ugljika i ekvivalenta ugljika potrebno je koristiti čašice premazane telurom kako bi se postigla metastabilna kristalizacija. Za određivanje temperatura $\Delta \mathcal{G}_{\text{maks}}$ i \mathcal{G}_R kristalizacija mora biti stabilna, stoga u čašicama za ispitivanje taljevine ne smije biti telura. Za analizu taljevine obrađene magnezijem potrebno je koristiti čašice s premazom telura koji je bogat i sumporom, čime se uklanja utjecaj magnezija i omogućuje mjerenje temperatura $\Delta \mathcal{G}_{\text{maks}}$ i \mathcal{G}_R [18]. Općenito, u proizvodnji kvalitetnog nodularnog lijeva vrijede sljedeće smjernice:


- pothlađenje, $\Delta\mathcal{G}_{\text{maks}}$, mora biti smanjeno da se minimizira opasnost od nastanka eutektičkih karbida (odbjela),
- rekalescencija, \mathcal{G}_R , mora biti smanjena kako bi se minimizirala vjerojatnost nastanka mikroporoznosti,
- temperatura eutektičkog pothlađenja, \mathcal{G}_{EP} , mora biti viša od temperature eutektičke reakcije za metastabilnu kristalizaciju, $\mathcal{G}_{E,\text{metastabil}}$, kako bi se uklonila opasnost od nastanka karbida,
- temperatura kraja skrućivanja, \mathcal{G}_S , mora biti viša od temperature eutektičke reakcije za metastabilnu kristalizaciju, $\mathcal{G}_{E,\text{metastabil}}$, kako bi se izbjeglo nastajanje karbida.

2.2.1.2. *Primjena toplinske analize u određivanju mikrostrukture nodularnog lijeva i djelotvornosti cjepiva*


Slika 2.24. prikazuje kvalitativnu razliku između krivulja hlađenja sivog, vermikularnog, nodularnog i bijelog tvrdog lijeva [44]. Istraživana je upotreba toplinske analize u određivanju topline koja se oslobađa pri skrućivanju sustava željezo – grafit i željezo – cementit kod željeznih ljevova, na temelju koje se može odrediti udio ukupnog austenita koji nastaje pri tom skrućivanju, zatim udio primarnog i eutektičkog austenita, te eventualni udio karbida [13]. Mogućnosti određivanja stupnja nodularnosti i broja nodula grafita na temelju podataka dobivenih snimanjem i analizom krivulje hlađenja istraživali su brojni autori [45, 46]. Jedan od empirijskih izraza za određivanje broja nodula po jedinci površine, N [cm^{-2}] na temelju pothlađenja, $\Delta\mathcal{G}_{\text{max}}$, [$^{\circ}\text{C}$] je sljedeći [47]:

$$N = 8171 + 20,82 \Delta\mathcal{G}_{\text{max}} + 13,96 \Delta\mathcal{G}_{\text{max}}^2 - 0,21 \Delta\mathcal{G}_{\text{max}}^3 \quad (2.9)$$

Slika 2.25. prikazuje kako se mijenja oblik izlučenog grafita, broj grafitnih nodula i nodularnost grafita za različite vrijednosti eutektičke rekalescencije i eutektičkog pothlađenja. Uz iste vrijednosti eutektičke rekalescencije, nodularni će lijev biti veće nodularnosti ako je veće eutektičko pothlađenje, dok broj nodula značajno ovisi o eutektičkoj rekalescenciji. Međutim, pri visokim vrijednostima eutektičkog pothlađenja javlja se i veća opasnost od nastajanja karbida u strukturi.



Slika 2.24. Krivulje hlađenja sivog, vermikularnog, nodularnog i bijelog tvrdog lijeva [44]

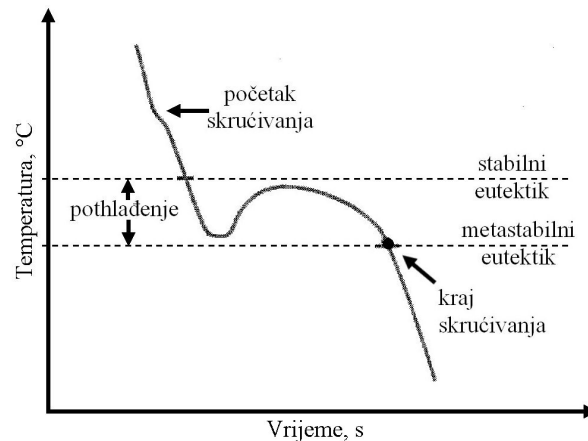


Slika 2.25. Nodularnost i broj nodula grafita u ovisnosti o eutektičkoj rekalescenciji i eutektičkom pothlađenju [36]

Toplinska analiza je također vrlo korisna u određivanju optimalne količine cjepljiva koje se dodaje u taljevinu. Ukoliko je taljevina nedovoljno cijepljena, mogu nastati karbidi, jer se taljevina skrućuje ispod temperature metastabilne kristalizacije. Prekomjerno cijepljenje nepotrebno povisuje troškove proizvodnje, a može također uzrokovati nastajanje grešaka u odljevku. Pri prekomjernom cijepljenju može doći do


ranog prekomjernog rasta grafitnih kuglica, zbog čega može nedostajati ugljika za rast nodula pri kraju skrućivanja, čime se povećava opasnost od nastajanja mikroporoznosti. Izborom najpovoljnije količine cjepiva pomoću toplinske analize taljevine nodularnog lijeva može se značajno smanjiti potrošnja cjepiva i udio škarta [48].

Najvažniji razlog cijepljenja taljevine nodularnog lijeva je nastojanje da se osigura stabilna kristalizacija tijekom cijelog temperaturnog intervala skrućivanja taljevine. Iz taljevine se eutektičkom reakcijom trebaju stvarati kristali eutektičkog austenita i eutektičkog grafita, a bez pojave cementita, Fe_3C . Prilikom kristalizacije neminovno dolazi do pothlađenja ispod temperature stabilne eutektičke reakcije. Slika 2.26. prikazuje krivulju hlađenja nodularnog lijeva za slučaj u kojemu je pothlađenje ograničeno unutar temperaturnog intervala između izoterme stabilne i metastabilne kristalizacije, pri čemu će nastati poželjna struktura bez karbida [18].



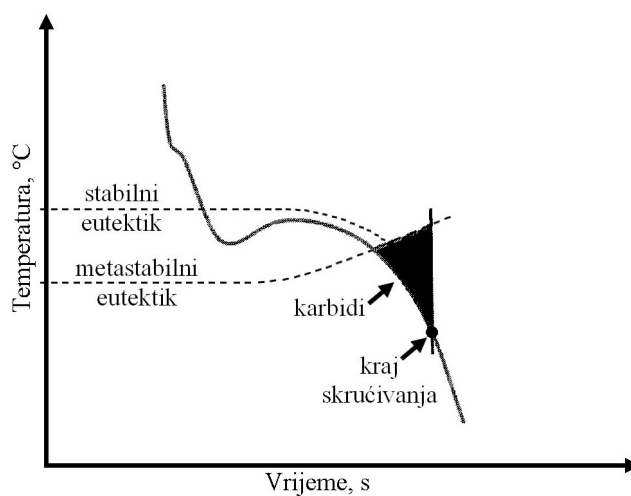
Slika 2.26. Krivulja hlađenja nodularnog lijeva bez karbida u strukturi [18]

Slika 2.27. prikazuje slučaj u kojemu je temperatura eutektičkog pothlađenja niža od temperature metastabilne kristalizacije. U ovom će se slučaju u strukturi pojaviti karbidi. Najčešće se nakon pothlađenja, a uslijed rekalescencije, temperatura taljevine ipak povisi iznad temperature metastabilne kristalizacije, no time u strukturi zaostaju primarni karbidi, tj. cementit Fe_3C . Pravilnim se cijepljenjem mogu izbjeći ovakve pojave.



Slika 2.27. Krivulja hlađenja nodularnog lijeva s primarnim karbidima u strukturi [18]

Sljedeća pojava koja se može pratiti na krivulji hlađenja je stvaranje interkristalnih karbida. Slika 2.28. prikazuje taj slučaj. Segregacija karbidotvoraca, kao što su mangan, krom, vanadij i dr. po granicama zrna uzrokuje porast temperature metastabilne kristalizacije i, posljedično, pojavu karbida u mikrostrukturi. Opasnost od pojave interkristalnih karbida izražena je kod nodularnih ljevova legiranih manganom u cilju postizanja perlitne metalne osnove, a naročito pri lijevanju odljevaka srednjih i debljih stjenki, kod kojih je hlađenje sporije, te je opasnost od segregacije karbidotvoraca veća. Kod pojave interkristalnih karbida niti obilno cijepljenje nije dovoljno da se oni izbjegnu, već je potrebno korigirati sastav taljevine.



Slika 2.28. Krivulja hlađenja nodularnog lijeva s interkristalnim karbidima u strukturi [18]

Praćenjem temperature eutektičkog pothlađenja taljevine u različitim vremenskim intervalima nakon dodavanja različitih količina cjepiva može se odrediti koja će količina cjepiva najviše smanjiti rizik od nastanka odbjela (karbida). Nadalje, povoljnije su niže vrijednosti rekalescencije, više vrijednosti grafitnog faktora 1, GRF1, i niže vrijednosti grafitnog faktora 2, GRF2 [48]. GRF2 opisuje izgled krivulje hlađenja pri kraju skrućivanja. Kada se izlučivanje grafita događa kontinuirano kroz cijeli temperaturni interval skrućivanja, toplina se također oslobađa kontinuirano. Zbog toga krivulja hlađenja ima konstantni nagib sve do završetka skrućivanja, nakon kojega se pojavljuje nagli pad. Time se naglo mijenja prva derivacija krivulje hlađenja, zbog čega je GRF2 nizak [49].

U cilju određivanja udjela ferita u metalnoj osnovi nodularnog lijeva, statističkom obradom podataka dobivenih snimanjem krivulje hlađenja utvrđeni su parametri koji značajno utječu na taj udio. Ti su parametri temperatura početka izdvajanja eutektika, ϑ_{ES} , i brzina hlađenja pri toj temperaturi, $\frac{d\vartheta_{ES}}{dt}$. Izraz za određivanje volumnog udjela ferita, F , dobiven regresijskom analizom je [36]:

$$F [\%] = -2166,3162 + 1,9554 \vartheta_{ES} + 16,5389 \frac{d\vartheta_{ES}}{dt} \quad (2.10)$$

gdje su ϑ_{ES} [°C] i $\frac{d\vartheta_{ES}}{dt}$ [°C/s], dok je pripadajući koeficijent korelacije $R = 0,6582$.

2.2.1.3. Primjena toplinske analize u određivanju mehaničkih svojstava nodularnog lijeva

Razlike u krivuljama hlađenja različitih vrsta željeznih ljevova potaknule su istraživanje mogućnosti određivanja veze između parametara očitanih na krivulji hlađenja lijeva i svojstva koje će odljevak od određene taljevine imati nakon skrućivanja. Međutim, ovaj je problem prilično složen ako se uzmu u obzir vrlo različiti željezni ljevovi, utjecaj različitih toplinskih svojstava kalupa za lijevanje, tj. različitih uvjeta hlađenja taljevine, različiti rubni uvjeti za pojedine odljevke itd. Jedan od modela izračuna tvrdoće po Brinellu, HB , za jednostavan odljevak na temelju kemijskog sastava i toplinskih parametara s krivulje hlađenja je [12]:

$$HB = a + b v_{900} + c v_{650} + d t_{900-650} + e t_s + f MnE + g CE + h \%Mg + j \%Si \quad (2.11)$$

gdje su:

v_{900} – brzina hlađenja taljevine pri temperaturi 900 °C, °C/s,

v_{650} – brzina hlađenja taljevine pri temperaturi 650 °C, °C/s,

$t_{900-650}$ – vrijeme hlađenja s 900 na 650 °C, s,

t_s – vrijeme skrućivanja, s,

MnE – mangan ekvivalent,

a, b, c, d, e, f, g, h, j – regresijski koeficijenti.

Vrijedi:

$$MnE = \%Mn + 1,5 \%Ni + 0,5 \%Cu + 4 \%Cr + 10 \%V \quad (2.12)$$

Koeficijent korelacije za gornji model iznosi 0,95. Ovaj je model točan na tankostjenim odljevcima (3 mm), dok se već kod stjenki srednjih debljina (10 mm) pojavljuju neprihvatljive pogreške predviđanja. Kako tvrdoća najznačajnije ovisi o mikrostrukturi odljevka, kao što su udio perlita i broj nodula, trebala bi postojati izravna povezanost između tih varijabli. Međutim, određivanje vrijednosti mehaničkih svojstava je znatno složeniji i širi problem nego što je npr. određivanje udjela ugljika, silicija ili ekvivalenta ugljika, jer uključuje odabrane eksperimentalne postupke i odabrane metode za simulaciju. Također, izvedeni model za izračun svojstava značajno ovisi o brojim lokalnim uvjetima koji vladaju u pojedinoj ljevaonici i često se razvijeni modeli ne mogu jednako dobro primijeniti u nekoj drugoj ljevaonici.

Višestrukom linearnom regresijskom analizom toplinskih parametara s krivulje hlađenja razvijeni su izrazi za izračun vlačne čvrstoće, istežljivosti i tvrdoće, ali koeficijenti korelacije za ove izraze nisu zadovoljavajuće visoki [50]. Izraz za izračun vlačne čvrstoće vermikularnog lijeva pomoću toplinskih parametara zadovoljavajuće korelacije dobiven je višestrukom linearnom regresijskom analizom [38].

2.3. Umjetne neuronske mreže

Umjetne neuronske mreže razvijene su prema modelu bioloških mreža neurona, iako se od njih znatno razlikuju. Ljudski se mozak sastoji od vrlo velikog broja međusobno povezanih živčanih stanica ili neurona. Međusobni odnos neurona i jačina njihovih međusobnih veza oblikuju djelovanje biološke neuronske mreže. Djelovanje biološke neuronske mreže vremenom se mijenja zbog jačanja ili slabljenja jačine veza između neurona u tzv. sinapsama. Mijenjanjem jačine veza između bioloških neurona živa bića uče. Umjetne neuronske mreže nisu ni približno toliko složene kao mozak, iako između prirodnih i umjetnih neuronskih mreža postoje bitne sličnosti: elementi od kojih su obje vrste mreža građene međusobno su povezani jednostavni računarski elementi, dok veze između elemenata njih određuju ponašanje mreže [51, 52].

Umjetna neuronska mreža je složen sustav, sastavljen od elemenata (neurona) koji stoje u određenoj interakciji, međusobno i s okolinom sustava, tako da grade funkcionalnu cjelinu [53]. Umjetna neuronska mreža predstavlja sustav za obradu informacija, koji ima određene karakteristike slične biološkim neuronskim mrežama [54].

Obrada informacija se događa u mnogo malih jednostavnih elemenata koji se nazivaju neuroni. Signali se prenose preko veza između neurona. Svakoj je vezi pridružena određena težina, koja se u neuronskoj mreži množi signalom koji se njome prenosi. Svaki neuron ima u sebi aktivacijsku funkciju, obično nelinearnu, koja na temelju otežanih ulaza (zbroja umnožaka ulaza i težina) određuje izlazni signal neurona.

Neuronska je mreža okarakterizirana građom, tj. načinom povezivanja pojedinih neurona, algoritmom učenja, odnosno metodom određivanja težina pojedinih veza, aktivacijskim funkcijama, te strukturom neurona, odnosno elemenata procesiranja.


Svaka se umjetna neuronska mreža sastoji od velikog broja elemenata za obradu signala, koji se nazivaju neuroni. Svaki je neuron povezan s drugim neuronima preko otežanih veza. Podešavanje težina je učenje neuronske mreže. Učenje neuronskih mreža na osnovi ulazno – izlaznih podataka nelinearnog procesa može se promatrati kao problem preslikavanja nelinearnih funkcija. Algoritmi učenja iterativno određuju

optimalne vrijednosti parametara mreže s ciljem minimiziranja funkcije cilja preslikavanja [55].

Ovisno o postavljenom kriteriju mogu se dobiti različite kategorizacije umjetnih neuronskih mreža [53]. Paralelno složeni skup neurona gradi jedan sloj neuronske mreže. Mreže mogu biti jednoslojne ili višeslojne. Uobičajeno je da višeslojne mreže imaju ulazni i izlazni sloj, a između njih su tzv. skriveni slojevi. Ako se slojevi mreže povežu tako da signali putuju samo u jednom smjeru, od ulaza prema izlazima mreže, onda su to unaprijedne umjetne neuronske mreže. Ukoliko postoji barem jedna povratna veza, riječ je o povratnim umjetnim neuronskim mrežama. U odnosu na vrijeme, razlikuju se vremenski kontinuirane i vremenski diskretne neuronske mreže. Ovisno o glavnom području primjene, razlikuju se perceptronske, asocijativne, dvostruko asocijativne, adaptivne, kognitorske i neokognitorske umjetne neuronske mreže. Neke se umjetne neuronske mreže nazivaju prema metodama koje se koriste za njihovo učenje. Tako razlikujemo povratno propagirane, suprotno propagirane i statističke neuronske mreže. Neki se modeli umjetnih neuronskih mreža nazivaju prema njihovim autorima, npr. Kohonenove i Hopfieldove neuronske mreže. Prema kriteriju načina realizacije umjetne neuronske mreže, postoje softverske, hardverske i optičke mreže.

2.3.1. Model statičkog neurona

Slika 2.29. prikazuje standardni model statičkog neurona. Izlazi iz drugih neurona i/ili okruženja promatranog neurona u_1, u_2, \dots, u_{J-1} (ako ukupno ima $J-1$ izlaza) upućuju se neuronu, gdje se množe s težinskim koeficijentima w_1, w_2, \dots, w_{J-1} , te se dovode do sumatora. U sumatoru se tako dobiveni produkti zbrajaju, a dobivena se suma, *net*, dovodi na ulaz aktivacijske funkcije, γ , koja na svom izlazu daje izlaz neurona, y . Slika 2.29. također prikazuje i osnovnu značajku svakog neurona, a to je posjedovanje više ulaza i samo jednog izlaza. Da bi se učenje neuronske mreže uopće moglo odvijati, svaki neuron koji sudjeluje u procesu učenja ima poseban ulaz jedinične vrijednosti, a on se u strukturi mreže ostvaruje vezom sa zasebnim neuronom oznake Bias, konstantnog izlaza jednakog jedinici [53].




Slika 2.29. Model statičkog neurona [53]

Za aktivacijsku funkciju uglavnom se odabire neka monotonno rastuća funkcija sa zasićenjem. Izraz (2.13) opisuje unipolarnu sigmoidalnu aktivacijsku funkciju. Jednadžba (2.14) opisuje bipolarnu sigmoidalnu aktivacijsku funkciju. Slika 2.30. prikazuje dvije najčešće korištene aktivacijske funkcije: unipolarnu (a) i bipolarnu (b) sigmoidalnu funkciju.

$$y = \frac{1}{1 + e^{-net}} \quad (2.13)$$

$$y_j = \frac{2}{1 + e^{-2*net}} - 1 \quad (2.14)$$



Slika 2.30. (a) Unipolarna i (b) bipolarna sigmoidalna aktivacijska funkcija

2.3.2. Građa umjetnih neuronskih mreža


U neuronskoj su mreži neuroni najčešće organizirani u pojedine slojeve. Obično su svi neuroni jednog sloja iste strukture. Ključni faktori za određivanje ponašanja neurona su aktivacijske funkcije neurona i način povezivanja neurona s ostalim neuronima. Ulazni i izlazni slojevi mreže su u izravnoj interakciji s okolinom, dok se sloj koji ove interakcije nema naziva skrivenim slojem.

Najčešće korišten model umjetne neuronske mreže je statička unaprijedna višeslojna neuronska mreža. Ulazni je sloj, preko skrivenih slojeva, povezan s izlaznim slojem vezama, koje su opterećene određenim težinama. Svi su slojevi neuronske mreže potpuno povezani, tj. svaki neuron promatranog sloja povezan je sa svakim neuronom prethodnoga sloja, pri čemu su izuzetak tzv. neuroni Bias, čije su vrijednosti izlaza uvijek jedinične. Izlazni sloj neurona određuje izlaze neuronske mreže, a povezan je sa skrivenim slojem neurona preko težinskih koeficijenata.

Broj ulaznih i izlaznih neurona definiran je problemom koji je potrebno riješiti. Broj izlaznih neurona jednak je broju zavisnih varijabli, dok je broj ulaznih neurona jednak broju nezavisnih varijabli problema. U slučaju da se raspolaze s vrlo velikim brojem ulaznih varijabli (deset, dvadeset i više), valja razmotriti mogućnost najpovoljnije kompozicije modela s odgovarajućim brojem varijabli, obzirom da se time olakšava primjena potrebnog modela i njegova analiza [56]. Osim toga, povećanjem broja ulaznih varijabli može se smanjiti pogreška preslikavanja neuronskom mrežom do određene granice, nakon koje se uspješnost mreže smanjuje. Optimalan broj ulaznih parametara ovisi i o veličini skupa za učenje – što je veći skup za učenje, možemo imati više ulaznih varijabli. Procjena konačne forme modela mora se donositi prema području primjene. Model koji je optimiran npr. nekom statističkom metodom može biti neupotrebljiv jer za njega nema teorijskog tumačenja.

Postoji više postupaka izbora utjecajnih varijabli za model. Svaki od postupaka temelji se na određenim kriterijima, odnosno na poželjnim vrijednostima analitičkih pokazatelja kvalitete modela. Neki od statističkih kriterija koji se koriste za izbor ulaznih varijabli su: kriterij najvećeg koeficijenta determinacije, kriterij najmanje rezidualne sredine kvadrata (najmanje procjene varijance) ili najvećeg korigiranog koeficijenta determinacije, zatim kriterij Mallowsa, te PRESS kriterij, tj. kriterij predviđenih ostataka greške sume kvadrata (engl. *Prediction sum of square statistics*)

[56]. Analiza glavnih komponenti ili PCA (engl. *Principal component analysis*) je klasična metoda multivarijatne analize kojom se nastoji smanjiti dimenzionalnost ulaznih varijabli. Ta analiza oblikuje nove, međusobno nekorelirane varijable, a odbacuju se one varijable koje ne pridonose značajno ukupnoj varijanci u skupu. Ovom se metodom transformira skup vektora u novi skup vektora tako da nove komponente vektora imaju posebna statistička svojstva: prva komponenta ima najveću varijancu, druga manju, treća još manju itd. Zadnje komponente imaju malu varijancu, tj. sadrže statistički manje važne informacije [57]. Prva glavna komponenta je smjer uzduž kojeg je varijanca podataka najveća. Druga glavna komponenta je smjer maksimalne varijance podataka u prostoru okomitom na prvu glavnu komponentu itd. Slika 2.31. prikazuje geometrijsku interpretaciju glavnih komponenta. Novi koordinatni sustav razapinju pripadni svojstveni vektori najvećih svojstvenih vrijednosti kovarijacijske matrice skupa podataka [58]. Prije analize glavnih komponenta, poželjno je poznate ulazne podatke normirati, tako da sve ulazne varijable imaju istu standardna devijaciju, obično jednaku jedinici, dok se srednja vrijednost postavlja u ničticu [52]. Postoje različiti kriteriji za zadržavanje, odnosno odbacivanje glavnih komponenta, npr. Kaiserov kriterij, Bartlettov kriterij, kriterij postotka ekstrahirane varijance i dr. [59]




Slika 2.31. Geometrijsko tumačenje glavnih komponenti [58]

Također, moguće je i samim modelom neuronske mreže ispitati koje se ulazne varijable mogu isključiti iz skupa. U tom se slučaju neuronska mreža u prvom koraku oblikuje s brojem ulaza jednakim ukupnom broju ulaznih varijabli, te se takva mreža nauči. Nakon učenja, pojedini ulazi mreže postavljaju u nulu i prati se promjena pogreške preslikavanja mreže. Ukoliko se pogreška pri isključivanju nekog ulaza ne

mijenja, smatra se da taj ulaz ne utječe značajno na odziv mreže i ta se ulazna varijabla može ispustiti u sljedećem modelu neuronske mreže.

Broj neurona u skrivenom sloju, kao i broj skrivenih slojeva nije definiran zadatkom ili problemom, već ga definira korisnik koji modelira umjetnu neuronsku mrežu. Ipak, potvrđeno je da se svaka kontinuirana funkcija može dobro aproksimirati već pomoću jednog skrivenog sloja, dok broj neurona u skrivenom sloju treba biti dovoljno velik. Kao teoretsku osnovu pri dokazivanju sposobnosti preslikavanja višeslojnih statičkih neuronskih mreža neki autori uzimaju npr. Kolmogorovljev teorem [55, 61]. Kolmogorovljev teorem dokazuje da se proizvoljna kontinuirana funkcija može aproksimirati superpozicijom konačnog broja kontinuiranih funkcija jedne varijable.

Potreban broj neurona ovisi o složenosti preslikavanja ulaznih na željene izlazne podatke i potrebno ga je odrediti za zadani slučaj. Ne postoji egzaktna veza između točnosti mreže i broja skrivenih slojeva i/ ili broja neurona. Ipak, istraživanja preslikavanja izrazito nelinearnih funkcija pokazuju da se veća točnost i bolja generalizacija postiže oblikovanjem neuronske mreže s dva skrivena sloja, nego s jednim skrivenim slojem u kojem je smješten povećani broj neurona [55, 61]. Slika 2.32. prikazuje pojednostavnjeni oblik statičke unaprijedne višeslojne neuronske mreže, za slučaj da mreža ima četiri nezavisne varijable i tri zavisne varijable. Prikazani primjer neuronske mreže ima jedan skriveni sloj s pet neurona u sloju.




Slika 2.32. Statička unaprijedna višeslojna neuronska mreža

2.3.3. Učenje umjetne neuronske mreže

Prije učenja neuronske mreže, potrebno je poznate podatke o ispitivanom problemu podijeliti u dva ili tri odvojena skupa: skup za učenje, skup za testiranje i skup za validaciju. U unaprijednoj se fazi učenja neuronske mreže iz skupa za učenje uzimaju vrijednosti ulaznih varijabli i pomoću njih se izračunavaju početne vrijednosti izlaza mreže. Za ovaj proračun potrebno je prethodno postaviti početne vrijednosti težina. Za skriveni se sloj ove vrijednosti određuju npr. generatorom slučajnih brojeva, dok određivanje težina izlaznog sloja na spomenuti način ne osigurava najbrži početak učenja mreže. Početne vrijednosti težina moguće je odrediti i posebnim algoritmima koji uzimaju u obzir postavljeni broj neurona u sloju, broj ulaznih varijabli, te najveće i najmanje vrijednosti koju poprima svaka ulazna varijabla. Jedna od takvih metoda je metoda po Nguyenu i Widrowu. Njenom se primjenom skraćuje proces učenja neuronske mreže u odnosu na učenje sa slučajno postavljenim početnim vrijednostima težina [60].

Izlazi iz neurona skrivenog sloja su preko težinskih koeficijenata izlaznog sloja spojeni na ulaze neurona izlaznog sloja. U povratnoj se fazi učenja umjetne neuronske mreže na osnovi izračunatih i željenih izlaza mreže izračunavaju pogreške učenja. Na temelju ovih pogrešaka potom se korigiraju vrijednosti težinskih koeficijenata veza između slojeva neurona. Slika 2.33. prikazuje tipičan izgled presjeka plohe pogreške učenja umjetne neuronske mreže. Cilj učenja neuronske mreže je odrediti vrijednosti težinskih koeficijenata \mathbf{w}^* koji minimiziraju funkciju cilja $F(\mathbf{w})$ [61].




Slika 2.33. Tipičan izgled presjeka plohe pogreške učenja neuronske mreže [61]

Postupak se ponavlja za svaki ulazno – izlazni par podataka iz skupa za učenje, dok se ne postigne tražena točnost učenja. Na osnovi odabrane funkcije cilja korigiraju se težinski koeficijenti pomoću nekog od algoritama nelinearnog optimiranja. Nakon pojedinog koraka učenja, nove će se vrijednosti težinskih koeficijenata izračunavati iz prethodnih vrijednosti težinskih koeficijenata i veličine njihove promjene u tom koraku učenja. Kako bi se pogreška najbrže smanjivala, potrebno je odrediti promjenu težinskih koeficijenata za koju je promjena pogreške maksimalno negativna. Koeficijent brzine učenja je pokazatelj za mjeru promjene pogreške, a njegova je vrijednost obično u intervalu od 10^{-3} do 10, te se određuje u skladu s rješavanim problemom. Učenje s preniskim koeficijentom brzine učenja rezultira sporim učenjem, dok prevelike vrijednosti mogu uzrokovati nestabilnost učenja, odnosno neuronska mreža ne može konvergirati k rješenju s najmanjom pogreškom. Stoga se često koristi promjenjivi koeficijent brzine učenja: ako je omjer nove i stare pogreške veći od neke prethodno zadane vrijednosti, nove se vrijednosti težina odbacuju, a koeficijent brzine učenja se smanjuje za prethodno zadani omjer. S druge strane, ako je nova pogreška manja od stare, nove se vrijednosti težina prihvaćaju, a koeficijent brzine učenja se povećava za unaprijed zadani omjer. Algoritam koji se u nelinearnom optimiranju naziva algoritmom najstrmijeg pada, kod umjetnih se neuronskih mreža naziva algoritam povratnog rasprostiranja pogreške. Radi bržeg učenja algoritmom povratnog rasprostiranja pogreške, tj. radi smanjenja broja potrebnih koraka iteracije za zadanu točnost, razvijeno je nekoliko modifikacija ovog algoritma. Jedna je upotreba zamaha, koji pri proračunu pogreške prati promjenu težinskih koeficijenata u prethodnom koraku učenja. Vrijednost koeficijenta zamaha određuje se unutar intervala (0, 1) proizvoljno prema zadanome problemu. Upotrebom zamaha u algoritmu povratnog rasprostiranja pogreške brzina učenja se povećava i do deset puta.

U povratnoj fazi učenja neuronske mreže s povratnim rasprostiranjem pogreške promjena težinskih koeficijenata odvija se od izlaznog prema ulaznom sloju. Nakon što se izračunaju promjene svih težinskih koeficijenata izlaznog sloja, potrebno je izračunati promjene težinskih koeficijenata skrivenog sloja. Ukoliko se u neuronsku mrežu postavi još koji skriveni sloj neurona, numerički je postupak za proračun težinskih koeficijenata tog sloja istovjetan postupku za slučaj jednog skrivenog sloja.

Svaki novi skriveni sloj neurona teoretski omogućava točnije učenje i veću sposobnost generalizacije mreže, ali pritom se produljuje i trajanje proračuna. Osim toga, odziv neuronske mreže s nekoliko skrivenih slojeva neurona je sporiji u odnosu na mrežu s jednim skrivenim slojem neurona. Teorijska istraživanja umjetnih neuronskih mreža pokazala su da je jedan skriveni sloj neurona dovoljan za dobro preslikavanje bilo koje kontinuirane funkcije, ukoliko se skriveni sloj sastoji od dovoljnog broja neurona. Ako se pri rješavanju određenih problema preslikavanja ukaže potreba za iznimno velikim brojem neurona u skrivenom sloju, preporučuje se ipak povećanje broja skrivenih slojeva neurona [61].

2.3.4. Algoritam povratnog rasprostiranja pogreške



Slika 2.34. Opći oblik statičke unaprijedne višeslojne neuronske mreže [53]

Slika 2.34. prikazuje opći oblik statičke unaprijedne višeslojne neuronske mreže. U unaprijednoj fazi učenja se iz skupa za učenje neuronske mreže uzimaju vrijednosti ulaza, upisane u matricu \mathbf{Z} , te se pomoću matrice \mathbf{Z} izračunavaju izlazi iz neuronske mreže, matrica \mathbf{O} . Početne vrijednosti izlaza mreže se izračunavaju i uz pomoć početnih vrijednosti težinskih koeficijenata, upisanih u težinskim matricama \mathbf{v} i \mathbf{w} . Težinske se matrice izračunavaju pomoću generatora slučajnih brojeva ili nekom drugom odgovarajućom funkcijom. Jedna metoda je npr. metoda po Nguyenu i Widrowu, kod koje se uzimaju u obzir broj neurona u sloju, broj ulaza i minimalne i maksimalne

vrijednosti svake od ulaznih varijabli. Njena primjena skraćuje učenje neuronske mreže u odnosu na učenje sa slučajno postavljenim težinskim koeficijentima [60].

Prema oznakama na gornjoj slici, funkciji sume neurona H -tog skrivenog sloja net dodjeljuje se prvi indeks prema oznaci sloja (net_H), a svaki j -i neuron u tom sloju određuje drugi indeks. Jednadžbom (2.15) izračunavaju se izlazi iz j -og neurona H -tog sloja [53]:

$$net_{Hj} = \sum_{i=1}^I v_{ji} Z_i \quad j = 1, 2, \dots, J-1, \quad i = 1, 2, \dots, I \quad (2.15)$$

gdje je I broj neurona u ulaznom sloju +1, a J je broj neurona u skrivenom sloju +1. Jedinica se dodaje zbog neurona Biasa. Ukoliko se u skrivenom sloju postavi bipolarna sigmoidalna aktivacijska funkcija, tada se izlazi iz skrivenog sloja neurona, y_j , mogu računati prema [53]:

$$y_j = \frac{2}{1 + e^{-\sigma net_{Hj}}} - 1, \quad j = 1, 2, \dots, J-1 \quad (2.16)$$

$$y_J = 1 \quad (2.17)$$

gdje je σ nagib sigmoidalne funkcije. U daljem će se izvodu uzeti $\sigma = 1$.

Izlazi iz neurona skrivenog sloja se preko težinskih koeficijenata izlaznog sloja, w_{kj} , prosljeđuju na ulaze svih K neurona izlaznog sloja O . Za izlazni sloj funkcija sume net zapisana je izrazom:

$$net_{Ok} = \sum_{j=1}^J w_{kj} y_j, \quad k = 1, 2, \dots, K \quad (2.18)$$

gdje je K je broj neurona izlaznog sloja, tj. broj izlaza mreže.

Ako se u izlaznom sloju neurona postavi linearna aktivacijska funkcija, na izlazu neuronske mreže dobiva se:

$$O_k = K_p net_{Ok}, \quad k = 1, 2, \dots, K \quad (2.19)$$

gdje je K_p konstanta proporcionalnosti, tj. nagib linearne aktivacijske funkcije. Za dalji izvod uzima se da je $K_p = 1$.

U povratnoj fazi učenja neuronska mreža na osnovi izračunatih izlaza mreže (matrica **O**) i željenih izlaza (matrica **d**) računa pogrešku učenja. Na temelju te pogreške korigiraju se težinski koeficijenti po slojevima neurona. Postupak se ponavlja za svaki

ulazno – izlazni par podataka za učenje, dok se dostigne zadana točnost. Odabrana funkcija cilja dana je izrazom (2.20):

$$E = \frac{1}{2} \sum_{n=1}^N (d_n - O_n)^2 \quad (2.20)$$

Podešavanjem težinskih koeficijenata potrebno je minimizirati funkciju cilja. Na osnovi funkcije cilja mijenjaju se težinski koeficijenti pomoću odabranog algoritama nelinearnog programiranja. Nove vrijednosti težinskih koeficijenata u $n+1$ koraku učenja, $\mathcal{G}(n+1)$, izračunavaju se iz težinskih koeficijenata u n -tom koraku, $\mathcal{G}(n)$, i vrijednosti promjene težinskih koeficijenata $\Delta\mathcal{G}(n)$:

$$\mathcal{G}(n+1) = \mathcal{G}(n) + \Delta\mathcal{G}(n) \quad (2.21)$$

Prema Slika 2.34., $\mathcal{G}=\mathbf{v}$ za skriveni sloj te $\mathcal{G}=\mathbf{w}$ za izlazni sloj neurona. Pogrešku $E(\mathcal{G})$ u blizini točke \mathcal{G} može se aproksimirati pomoću prva dva člana Taylorovog reda:

$$E(\mathcal{G} + \Delta\mathcal{G}) \approx E(\mathcal{G}) + \Delta E(\mathcal{G}) \quad (2.22)$$

$$\Delta E(\mathcal{G}) = \Delta\mathcal{G}^T \nabla E(\mathcal{G}) \quad (2.23)$$

$$\nabla E(\mathcal{G}) = \frac{\partial E(\mathcal{G})}{\partial \mathcal{G}} \quad (2.24)$$

Jednadžba (2.24) se naziva gradijent pogreške. Da bi se pogreška najbrže smanjivala, treba odrediti $\Delta\mathcal{G}$ za koji je promjena pogreške $\Delta E(\mathcal{G})$ maksimalno negativna:

$$\Delta\mathcal{G} = -\eta \nabla E(\mathcal{G}) \quad (2.25)$$

Mjera promjene pogreške, η se naziva koeficijent brzine učenja. Njegova vrijednost je obično u intervalu od 10^{-3} do 10 i određuje se iskustveno. Optimalna vrijednost koeficijenta brzine učenja može se odrediti pokušajima. Ako je koeficijent brzine učenja prenizak, učenje je sporo, ali previsoke vrijednosti koeficijenta mogu uzrokovati nestabilnost učenja. Ovaj se problem može riješiti upotrebom algoritma promjenjivog koeficijenta brzine učenja. Ako je omjer nove i stare pogreške veći od zadanog omjera, nove se vrijednosti težina odbacuju, a koeficijent brzine učenja se smanjuje za zadani omjer. S druge strane, ako je nova pogreška manja od stare, nove se vrijednosti težina prihvaćaju, a koeficijent brzine učenja poveća za zadani omjer.

Uvrštavanjem izraza (2.25) u izraz za nove vrijednosti težina, slijedi:

$$\mathcal{G}(n+1) = \mathcal{G}(n) - \eta \nabla E[\mathcal{G}(n)] \quad (2.26)$$

Ovaj se izraz u nelinearnom optimiranju naziva algoritmom najstrmijeg pada. U umjetnim neuronskim mrežama uobičajen je naziv algoritam povratnog rasprostiranja pogreške ili skraćeno EBP (engl. *error back – propagation algorithm*).

Da bi se ubrzalo učenje pomoću algoritma povratnog rasprostiranja pogreške, tj. smanjio broj potrebnih iteracija, razvijene su modifikacije ovog algoritma. Jedna je upotreba zamaha, čime se u izraz za proračun pogreške dodaje promjena težina iz prethodnog koraka, $\Delta \mathcal{G}(n-1)$:

$$\Delta \mathcal{G}(n) = -\eta \nabla E[\mathcal{G}(n)] + \alpha \Delta \mathcal{G}(n-1) \quad (2.27)$$

Upotreba metode zamaha pomaže neuronskoj mreži da ne zapne u nekom od lokalnih minimuma, na način da ne uzima u obzir samo promjenu u zadnjem koraku učenja, već prati i trendove u zadnjih nekoliko koraka na plohi pogreške. Time djeluje kao niskopropusni filter, kojim mreža zanemaruje male promjene u pogreški. Uz upotrebu zamaha, neuronska mreža prolazi dalje kroz lokalne minimume. Koeficijent zamaha α , bira se u intervalu od 0,1 do 0,9. Što je vrijednost ovog koeficijenta manja, to se manje uzima u obzir veličina promjene pogreške u prethodnom koraku učenja, a na promjenu težinskih koeficijenata više utječe gradijent pogreške.

Promjena težina se, uz upotrebu zamaha, izračunava pomoću:

$$\mathcal{G}(n+1) = \mathcal{G}(n) - \eta \nabla E[\mathcal{G}(n)] + \alpha \Delta \mathcal{G}(n-1) \quad (2.28)$$

U povratnoj fazi učenja neuronske mreže s povratnim rasprostiranjem pogreške promjena težina odvija se od izlaznog prema ulaznom sloju mreže. Promjena težina izlaznog sloja računa se pomoću izraza:

$$w_{kj}(n+1) = w_{kj}(n) - \eta \nabla E[w_{kj}(n)] + \alpha \Delta w_{kj}(n-1) \quad (2.29)$$

Gradijent pogreške za težine w_{kj} računa se prema:

$$\nabla E(n) = \frac{\partial E(n)}{\partial w_{kj}} \quad (2.30)$$

Ova se jednadžba rješava primjenom uzastopnih parcijalnih derivacija:

$$\frac{\partial E(n)}{\partial w_{kj}} = \frac{\partial E(n)}{\partial O_k} \frac{\partial O_k}{\partial net_{Ok}} \frac{\partial net_{Ok}}{\partial w_{kj}} \quad (2.31)$$

Prvi član iz jednadžbe (2.31) može se izračunati pomoću jednadžbe (2.20):

$$\frac{\partial E(n)}{\partial O_k} = -(d_k - O_k) \quad (2.32)$$

a drugi član jednadžbe (2.31) pomoću jednadžbe (2.19), uz $K_p = 1$:

$$\frac{\partial O_k}{\partial net_{O_k}} = 1 \quad (2.33)$$

Karakteristična vrijednost algoritma povratnog rasprostiranja pogreške, δ , računa se prvo za izlazni sloj i po definiciji je:

$$\delta = -\frac{\partial E(n)}{\partial net} \quad (2.34)$$

Njenu je vrijednost moguće izračunati množenjem prvih dvaju parcijalnih derivacija iz izraza (2.31), a izračunatih prema (2.32) i (2.33). Za k -ti neuron izlaznog sloja, O , u slučaju odabrane linearne aktivacijske funkcije koeficijent δ_{O_k} iznosi:

$$\delta_{O_k} = d_k - O_k \quad (2.35)$$

Treća parcijalna derivacija iz izraza (2.31) može se izračunati pomoću izraza (2.18):

$$\frac{\partial net_{O_k}}{\partial w_{kj}} = y_j \quad (2.36)$$

Uvrštenjem izraza (2.32), (2.33) i (2.36) u izraz (2.31) slijedi:

$$\nabla E(n) = \frac{\partial E(n)}{\partial w_{kj}} = -(d_k - O_k)y_j = -\delta_{O_k}y_j \quad (2.37)$$

Uvrštenjem izraza (2.37) u (2.29) slijedi algoritam promjene težina izlaznog sloja:

$$w_{kj}(n+1) = w_{kj}(n) + \eta \delta_{O_k} y_j + \alpha \Delta w_{kj}(n-1) \quad (2.38)$$

Nakon što se pomoću jednadžbe (2.38) izračunaju nove vrijednosti svih težina w izlaznog sloja, izračunavaju se novi težinski koeficijenti v skrivenog sloja. Osnovna jednadžba za izračun novih vrijednosti težina skrivenog sloja istovjetna je izrazu (2.29):

$$v_{ji}(n+1) = v_{ji}(n) - \eta \nabla E(n) + \alpha \Delta v_{ji}(n-1) \quad (2.39)$$

U ovom je izrazu nepoznanica gradijent pogreške, $\nabla E(n)$, koji se može izračunati na isti način kao kod težina izlaznog sloja, tj. uzastopnim parcijalnim deriviranjem. Prema oznakama na slici sa str. 49., slijedi:

$$\frac{\partial E(n)}{\partial v_{ji}} = \frac{\partial E}{\partial y_j} \frac{\partial y_j}{\partial net_{Hj}} \frac{\partial net_{Hj}}{\partial v_{ji}} \quad (2.40)$$

Kako na promjenu svake težine skrivenog sloja utječu svi neuroni izlaznog sloja, prvi član izraza (2.40) će biti:

$$\begin{aligned} \frac{\partial E(n)}{\partial y_j} &= \frac{\partial E(n)}{\partial O_1} \frac{\partial O_1}{\partial net_{O1}} \frac{\partial net_{O1}}{\partial y_j} + \frac{\partial E(n)}{\partial O_2} \frac{\partial O_2}{\partial net_{O2}} \frac{\partial net_{O2}}{\partial y_j} + \dots \\ &\dots + \frac{\partial E(n)}{\partial O_3} \frac{\partial O_3}{\partial net_{O3}} \frac{\partial net_{O3}}{\partial y_j} + \dots + \frac{\partial E(n)}{\partial O_K} \frac{\partial O_K}{\partial net_{OK}} \frac{\partial net_{OK}}{\partial y_j} \end{aligned} \quad (2.41)$$

Vrijedi:

$$\frac{\partial E(n)}{\partial O_K} = -(d_k - O_k), \quad k = 1, 2, \dots, K \quad (2.42)$$

$$\frac{\partial O_k}{\partial net_{Ok}} = 1 \quad k = 1, 2, \dots, K \quad (2.43)$$

$$\frac{\partial net_{Ok}}{\partial y_j} = w_{kj}, \quad k = 1, 2, \dots, K, \quad j = 1, 2, \dots, J - 1 \quad (2.44)$$

Uvrštavanjem izraza (2.42) do (2.44) u (2.41) slijedi:

$$\frac{\partial E(n)}{\partial y_j} = - \sum_{k=1}^K (d_k - O_k) w_{kj} \quad (2.45)$$

odnosno uz izraz (2.35) za koeficijent δ_{Ok} , slijedi prvi član parcijalnih derivacija za izraz (2.40):

$$\frac{\partial E(n)}{\partial y_j} = - \sum_{k=1}^K \delta_{Ok} w_{kj} \quad (2.46)$$

Drugi i treći član u izrazu (2.40) mogu se izračunati prema izrazima (2.16) i (2.15):

$$\frac{\partial y_j}{\partial net_{Hj}} = \frac{1}{2} (1 - y_j)^2 \quad (2.47)$$

$$\frac{\partial net_{Hj}}{\partial v_{ji}} = Z_i \quad (2.48)$$

Uvrštavanjem izraza (2.46) do (2.48) u izraz (2.40), a nakon toga u početni izraz (2.39), dobiva se konačan oblik algoritma promjene težinskih koeficijenata skrivenog sloja neurona:

$$v_{ji}(n+1) = v_{ji}(n) + \frac{1}{2} \eta (1 - y_j)^2 Z_i \left(\sum_{k=1}^K \delta_{Ok} w_{kj} \right) + \alpha \Delta v_{ji}(n-1) \quad (2.49)$$

Slika 2.34. prikazuje model neuronske mreže za koji izvedene jednadžbe isključivo vrijede. Jednadžbe definiraju promjene težinskih koeficijenata u izlaznom i

skrivenom sloju za odabrane aktivacijske funkcije neurona u izlaznom i u skrivenom sloju [53].

Ukoliko se u neuronsku mrežu postavi još jedan skriveni sloj neurona, numerički postupak za proračun promjena težinskih koeficijenata neurona tog sloja je analogan prikazanom postupku za jedan skriveni sloj. Svaki novi skriveni sloj neurona teorijski omogućava uspješnije učenje i sposobnost generalizacije, ali zahtijeva i dulje vrijeme proračuna. Također, odziv neuronske mreže s više skrivenih slojeva neurona je sporiji od mreže s jednim skrivenim slojem. Kako je već spomenuto, teorijska su istraživanja umjetnih neuronskih mreža pokazala da je jedan skriveni sloj neurona dostatan za dobro preslikavanje bilo koje kontinuirane funkcije, uz uvjet da se u skrivenom sloju nalazi dovoljan broj neurona. Međutim, na ovaj način broj neurona u skrivenom sloju može poprimiti iznimno velike vrijednosti pri rješavanju određenih problema preslikavanja, te se u takvim slučajevima ipak preporučuje povećanje broja skrivenih slojeva neurona.

2.3.5. Levenberg – Marquardtova metoda

Levenberg – Marquardtova metoda je popularna alternativa za Gauss – Newtonovu metodu za traženje minimuma funkcije cilja, koja je u slučaju umjetnih neuronskih mreža najčešće bazirana na sumi kvadrata odstupanja. Izračun vrijednosti težinskih koeficijenata u sljedećem koraku učenja, $\mathcal{G}(n+1)$, na temelju vrijednosti iz prethodnog koraka učenja, $\mathcal{G}(n)$, i vektora pogreške, \mathbf{E} , provodi se prema sljedećem izrazu [62]:

$$\mathcal{G}(n+1) = \mathcal{G}(n) - [\mathbf{J}^T - \mathbf{J} + \mu \mathbf{I}]^{-1} \mathbf{J}^T \mathbf{E} \quad (2.50)$$

gdje je \mathbf{J} Jakobijeva matrica funkcije cilja, koja sadrži vrijednosti prve derivacije vektora pogrešaka po pojedinim težinskim koeficijentima. Marquardtov parametar, μ , je nenegativan skalar, a \mathbf{I} je jedinična matrica. Levenberg – Marquardtova metoda kombinira najbolje karakteristike Gauss – Newtonove metode i metode najstrmijeg pada, te izbjegava ograničenja svake od te dvije metode [63, 64]. Glavna karakteristika Levenberg – Marquardtove metode je njena brza konvergencija [65]. Metodu je 1944.

predložio Levenberg, a Marquardt je doradio 1963., te je ova metoda je postala jedna od standardnih nelinearnih metoda najmanjih kvadrata [66].

2.3.6. Testiranje i validacija umjetne neuronske mreže

Da bi se provjerila točnost neuronske mreže u određivanju izlaznih varijabli na temelju ulaznih, potrebno je osigurati dodatni skup slučajno odabranih uzoraka, a koji nisu prethodno bili korišteni za učenje mreže. Ovaj se skup podataka naziva skup za testiranje. Podaci iz tog skupa moraju biti novi, neuronskoj mreži neviđeni, jer ako bi se koristili isti podaci koji su korišteni za učenje, zapravo bi se provjeravala opet točnost mreže u povezivanju ulazno – izlaznih parova podataka. Potrebno je odrediti koliko je dobro neuronska mreža naučila preslikavati funkciju za svaku vrijednost ulaznih varijabli. Jedan od problema u preslikavanju funkcija je nedostupnost beskonačnih količina podataka za učenje i testiranje. Ukoliko jesu dostupne, mreža se uči s najvećim mogućim skupom za učenje i testira s najvećim mogućim skupom za testiranje. Jedan od načina provjere jesu li ovi skupovi dovoljno veliki je postupno povećanje njihove veličine. Ako s povećanjem veličine skupova ne dolazi do povećanja točnosti učenja, skupovi su dovoljno veliki. S druge strane, ukoliko nije dostupna dovoljna količina podataka, metodom umjetnih neuronskih mreža nije moguće naučiti dobro aproksimirati funkcijsku ovisnost ulaznih i izlaznih varijabli.

Pri razvoju neke neuronske mreže dostupni se podaci često podjeljuju u tri podskupa: skup za učenje, skup za validaciju i skup za testiranje [61]. Skupovi za učenje i za validaciju se koriste u razvoju mreže, dok je skup za testiranje nezavisan skup, koji se koristi za konačnu provjeru valjanosti modela prije nego se ona dostavi korisniku u upotrebu. Bitno je da se skup za testiranje ne koristi prethodno tijekom razvoja neuronske mreže jer neke mreže, posebno one s povratnim rasprostiranjem pogreške, imaju osobinu da se mogu znatno bolje prilagoditi poznatim, definiranim podacima, nego što mogu generalizirati.

Nadalje, dostupni poznati podaci se često dijele i na četvrti skup, tzv. skup za prijam, koji ostaje kod naručitelja razvoja neuronske mreže. Na taj način naručitelj može samostalno provjeriti sposobnosti generalizacije naučene neuronske mreže.

Kod podjele dostupnih podataka u podskupove važno ih je podijeliti tako da se u skupu za učenje nalaze podaci koji su što je moguće više raznovrsni, odnosno koji pokrivaju cijelo područje očekivanih vrijednosti ulazno – izlaznih parova i u ostalim trima skupovima. Pojam generalizacije neuronske mreže znači da neuronska mreža može dati smislen odgovor na novi nepoznati ulazni vektor samo ukoliko se taj novi vektor nalazi blizu vektora na kojima je učila ili ako se nalazi između njih. Ukoliko je novi ulaz izrazito različit od svih podataka iz skupa za učenje, ne može se očekivati da će neuronska mreža na takav ulaz dati smislen odziv.

Jedna od metoda odabira uzoraka za skupove za učenje, validaciju i testiranje je određivanje sličnosti između uzoraka. Sličnost uzoraka može se odrediti preko udaljenost između uzoraka, npr. Euklidove udaljenosti. Euklidova udaljenost, D , između dvaju točaka čije su koordinate (x_1, y_1, z_1) i (x_2, y_2, z_2) u trodimenzionalnom prostoru računa se pomoću:

$$D = \sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2 + (z_2 - z_1)^2} \quad (2.51)$$

Općenito, udaljenost između dvaju vektora, \mathbf{x} i \mathbf{y} , u slučaju n -dimenzionalnog prostora, \mathbf{R}^n je:


$$D = |\mathbf{x} - \mathbf{y}| = \sqrt{\sum_{i=1}^n |x_i - y_i|^2} \quad (2.52)$$

Nakon izračuna udaljenosti između uzoraka, potrebno je odrediti kriterij grupiranja uzoraka. Jedan kriterij može biti potrebni broj uzoraka u pojedinom skupu. Drugi način je postavljanje minimalne sličnosti uzoraka. Iznad zadane razine sličnosti uzorci se dodjeljuju skupu za učenje, a ispod postavljene sličnosti uzorci se mogu koristiti u skupu za testiranje.

Kod neuronskih se mreža, a posebno kod mreža s povratnim rasprostiranjem pogreške često javlja problem pretreniranosti mreže (engl. *overfitting*). Kod pretreniranosti se često pri modeliranju pridaje prevelika težina slučajnim varijacijama vrijednosti podataka. Takvi modeli tipično imaju veliku prediktivnu točnost na skupu primjera za učenje, a značajno nižu na novim, nepoznatim primjerima podataka, ili testnom skupu podataka [67].

Kako učenje neuronske mreže kroz iteracijske korake napreduje, tako se ploha višedimenzionalne aktivacijske funkcije između ulaznih i izlaznih varijabli sve više deformira i prilagođava poznatim podacima. Međutim, ako se neuronskoj mreži isti

skup podataka izrazito mnogo puta daje na učenje, ona se tim podacima može i predobro prilagoditi. Tako se može postići izrazito dobar odgovor mreže na poznate podatke, ali se istovremeno značajno može smanjiti sposobnost interpolacije između poznatih podataka. Da bi se izbjegla pojava pretreniranosti, tijekom učenja neuronske mreže se, nakon određenog broja koraka učenja, učenje privremeno zaustavlja i pomoću trenutnih vrijednosti težinskih koeficijenata izračunaju se pogreške u skupu za validaciju. Slika 2.35. prikazuje primjer toka promjene pogreške predviđanja, F , u skupovima za učenje i testiranje s porastom broja koraka učenja.



Slika 2.35. Pogreška u skupovima za učenje i testiranje prema koracima učenja [61]

Pogreška u skupu za učenje konstantno opada, što je tipično za neuronske mreže s povratnim rasprostiranjem pogreške. Pogreška se u skupu za testiranje najčešće smanjuje u početku, zatim počinje rasti te može, ali ne mora, dostići zasićenje. Za prikazani je slučaj potrebno zaustaviti učenje neuronske mreže kada se pogreška u skupu za validaciju počinje povećavati. Ovaj se način učenja neuronske mreže naziva i rano zaustavljanje, a jedna je od metoda za unaprjeđenje generalizacije, odnosno sprječavanja pretreniranosti.

Dostupni se podaci za učenje neuronske mreže ponekad dijele na dva podskupa približno jednake veličine – jedan za učenje, drugi za testiranje, iako veličina ovih podskupova nije striktno određena. Ukoliko su dostupni podaci oskudni, mogu se svi

podaci koristiti za učenje neuronske mreže, s tim da postupak učenja treba zaustaviti kada su zadovoljena dva uvjeta: postignuta je tražena razina točnosti i krivulja pogreške dolazi do zasićenja, tj. počinje asimptotski približavati nekoj vrijednosti.

Vrlo je često pri učenju neuronskih mreža dostupan skup podataka dovoljno širok da se omogući dobro učenje mreže, ali nema dovoljno podataka koji bi se ostavili za testiranje, eventualnu validaciju ili prijam. U takvom se slučaju može primijeniti sljedeći postupak učenja. Za slučaj da je dostupno N parova podataka (ili uzoraka), neuronsku mrežu valja učiti N puta koristeći $N-1$ par podataka. U svakom se učenju izostavi po jedan uzorak, koji se nakon tog učenja koristi za testiranje mreže. Pogreška učenja neuronske mreže procjenjuje se pomoću skupa za učenje i postupak se zaustavlja kada krivulja pogreške počinje dolaziti blizu zasićenja. Nakon toga se izračuna pogreška odziva mreže na izostavljenom uzorku. Nakon N učenja, izračunava se srednja vrijednost pogrešaka dobivenih na izostavljenim uzorcima i taj se podatak može upotrijebiti za procjenu pogreške koju bi neuronska mreža pokazala da je bilo dostupno više podataka za njeno testiranje.

Drugi pristup problemu nedovoljne količine podataka za učenje neuronske mreže je dodavanje "lažnih" podataka u skupove za učenje i testiranje. Ako se uspiju prepoznati razlike koje se pojavljuju između uzoraka, dodatni se podaci mogu oblikovati kombiniranjem ili iskrivljenjem postojećih podataka. Nadalje, postojećim se podacima može dodati šum, te tako proširiti skupove za učenje i testiranje.

Također, kada se želi odabrati najefikasnija građa neuronske mreže za neki zadani problem, potrebno je usporediti mreže s različitim brojem neurona u sloju, različitim brojem slojeva neurona ili mreže s različitim algoritmima učenja. Za takvu se usporedbu promatra samo pogreška u skupu za učenje i testiranje, a ne i skupu za validaciju i/ ili prijam, jer se na taj način osigurava nezavisnost procjene konačnog rada mreže testom za validaciju.

Trenutno nije poznata metoda određivanja potrebnog broja parova podataka za učenje neuronske mreže nekom određenom problemu. Za problem klasifikacije orijentacijski vrijedi sljedeće pravilo [54]:

$$N_{\min} = \frac{W}{e} \tag{2.53}$$

gdje je N_{\min} dovoljan broj parova podataka u učenje, W je ukupan broj težina neuronske mreže i e je dozvoljena razina pogreške. Ovo približno određivanje potrebnog broja uzoraka se, međutim, ne može primijeniti na problem preslikavanja. Za taj se problem prikuplja određeni skup podataka, te ukoliko se pomoću njih ne može neuronska mreža dovoljno dobro naučiti preslikavati problem, nastoji se povećati broj podataka za učenje.

2.3.7. Procjena točnosti preslikavanja umjetnom neuronskom mrežom

Pomoću parametara koji procjenjuju sposobnost preslikavanja nekog nelinearnog problema neuronskom mrežom mogu se uspoređivati pojedine građe neuronske mreže, pojedini primijenjeni algoritmi ili odabrani skupovi za učenje i testiranje. Parametri koji se mogu koristiti su koeficijent korelacije između predviđenih i ciljanih vrijednosti na izlazu iz neuronske mreže, R , ili normalizirani korijen srednje kvadratne pogreške, $NRMS$ (engl. *normalised root mean square error*). Ostali parametri za procjenu su npr.: MS – srednja kvadratna pogreška (engl. *mean square error*) ili RMS – korijen srednje kvadratne pogreške (engl. *root mean square error*). Spomenuti se parametri računaju prema:

$$MS = \frac{\sum_{n=1}^N (d_n - O_n)^2}{N} \quad (2.54)$$

$$RMS = \sqrt{MS} = \sqrt{\frac{\sum_{n=1}^N (d_n - O_n)^2}{N}} \quad (2.55)$$

$$NRMS = \frac{RMS}{\sigma_{d_n}} = \frac{\sqrt{\frac{\sum_{n=1}^N (d_n - O_n)^2}{N}}}{\sigma_{d_n}} \quad (2.56)$$

gdje su: N – ukupan broj parova podataka, d_n – ciljani izlazi, O_n – izračunati izlazi, σ_{d_n} – standardna devijacija ciljanih izlaza. MS -om i RMS -om se dobiva procjena pogreške u istim jedinicama kao što je ciljani izlaz, dok $NRMS$ skalira pogrešku u bezdimenzionalan broj. Model koji potpuno točno predviđa svaku izlaznu vrijednost ima $NRMS$ pogrešku jednaku ničtici, a koeficijent korelacije jednak jedinici, a ako je

NRMS jednak jedinici, onda je koeficijent korelacije jednak ničtici. Međutim, ne postoji jedinstvena veza između ova dva parametra. Npr. ukoliko je svaka predviđena izlazna vrijednost upravo dvostruko veća od ciljane vrijednosti izlaza, tada je koeficijent korelacije jednak jedinici, ali je *NRMS* veći od ničtice. Stoga je *NRMS* bolji pokazatelj uspješnosti pojedinog modela neuronske mreže. Koeficijent korelacije je i dalje koristan podatak za procjenu uspješnosti predviđanja utoliko što je on, nakon kvadriranja, kvantitativno jednak koeficijentu determinacije, R^2 . Koeficijent determinacije je omjer protumačenog i ukupnog zbroja kvadrata odstupanja, te pokazuje koliki se dio odstupanja može protumačiti nekim primijenjenim modelom [68].

3. EKSPERIMENTALNI DIO

U tvrtki "Metalska industrija Varaždin" d.d. u Varaždinu, za potrebe ovog istraživanja pripremljeno je 147 različitih taljevina nodularnog lijeva. Ispitani su i kemijski sastavi taljevina, te je provedena toplinska analiza. Izmjerena je vlačna čvrstoća, konvencionalna granica razvlačenja, istezljivost i tvrdoća. Na Metalurškom fakultetu u Sisku ispitana je mikrostruktura ljevova.

3.1. Priprema taljevina nodularnog lijeva

Pripremljeno je ukupno 147 taljevina nodularnog lijeva u organizacijskoj jedinici Talionica ljevaonice "Metalske industrije Varaždin" d.d. u Varaždinu. U tehnološkom procesu proizvodnje nodularnog lijeva koriste se sljedeće peći:

1. Dvije kupolne peći promjera 700 mm, kapaciteta proizvodnje rastaljenog metala od 4 t/ sat, uz dodatak tehničkog kisika,
2. Kanalna indukcijska peć PIKS20/ 800Fe, snage 800 kW, kapaciteta 20 t, za pohranjivanje bazne taljevine za proizvodnju nodularnog lijeva,
3. Mrežno – frekvencijska peć R. Končar MTS 4/1100, snage 1100 kW, kapaciteta 4 t, za dogrijavanje taljevine iz kupolne peći i korekciju kemijskog sastava.

Kupolna peć šaržirana je metalnim i nemetalnim komponentama zasipa. Metalni dio zasipa čine:

- specijalno sivo sirovo željezo za proizvodnju nodularnog lijeva,
- čelik (otpadni, balirani lim, strugotina),
- povratni materijal (uljevni sustavi, škartni odljevci, strugotina) i
- FeSi.

Tablica 3.1. prikazuje masene udijeje pojedinih komponenti za izradu jedne tone rastaljenog metala. Nemetalni dio zasipa čine ljevački koks i vapnenac.

3. EKSPERIMENTALNI DIO

Tablica 3.1. Udjeli pojedinih komponenti za izradu 1 t rastaljenog metala za proizvodnju nodularnog lijeva

Komponenta	Udio, kg
Metalni dio zasipa:	
specijalno sivo sirovo željezo za proizvodnju nodularnog lijeva	350 kg
čelik	200 kg
povratni materijal	450 kg
FeSi briketi	20 kg
UKUPNO	1020 kg
Nemetalni dio zasipa:	
ljevački koks	140 kg
vapnenac	40 kg
UKUPNO	180 kg

Tablica 3.2. opisuje kemijski sastav specijalnog sivog sirovog željeza za proizvodnju nodularnog lijeva. Tablica 3.3. prikazuje kemijski sastav čelika koji se koristi za proizvodnju nodularnog lijeva. Tablica 3.4. daje kemijski sastav povratnog materijala. Tablica 3.5. predstavlja kemijski sastav ferosilicija u briketima. Ferosilicij (FeSi) se dodaje u kupolnu peć u briketima kako bi se postigao potreban udio silicija u rastaljenom metalu.

Tablica 3.2. Kemijski sastav specijalnog sivog sirovog željeza za proizvodnju nodularnog lijeva

	Sastav	%
Specijalno sivo sirovo željezo za proizvodnju nodularnog ljeva	C	3,50 – 4,30
	Si	0,15 – 2,50
	Mn	0,05 – 0,10
	P maks.	0,03
	S maks.	0,02
	ostali elementi u tragovima	

Tablica 3.3. Kemijski sastav čelika koji se koristi za proizvodnju nodularnog lijeva

	Sastav	%
Čelik (otpadni, balirani lim, strugotina)	C	0,10 – 0,30
	Si	0,20 – 0,50
	Mn	0,30 – 0,60
	P maks.	0,025
	S maks.	0,01
	ostali elementi u tragovima	

Tablica 3.4. Kemijski sastav povratnog materijala

	Sastav	%
Povratni materijal (uljevni sustavi, škartni odljevci, strugotina)	C	3,40 – 3,80
	Si	2,00 – 3,50
	Mn	0,10 – 0,25
	P maks.	0,05
	S maks.	0,02
	ostali elementi u tragovima	

Tablica 3.5. Kemijski sastav ferosilicija u briketima


	Sastav	%
FeSi briketi	Si	45 – 80
	Mn	0,30 – 1,0
	Al maks.	2,00
	C	0,10 – 0,20
	ostali elementi u tragovima	

Kemijski sastav i svojstva komponenti nemetalnog dijela zasipa prikazan je sljedećim tablicama: Tablica 3.6. prikazuje kemijski sastav ljevačkog koksa. Tablica 3.7. daje kemijski sastav vapnenca. Ljevački se koks koristi u zasipu kupolne peći i

3. EKSPERIMENTALNI DIO

osigurava izgaranjem potrebnu toplinu za taljenje metala, te utječe na naugljičenje rastaljenog metala. Vapnenac je komponenta nemetalnog zasipa koja služi kao taljivo za izvođenje procesa u kupolnoj peći, a rezultat njegovog korištenja je nastajanje troske.

Disocijacijom vapnenca nastaje:



Tablica 3.6. Kemijski sastav ljevačkog koksa

	Sastav, svojstvo	%
Ljevački koks	C	82 – 90
	S maks.	0,90
	P maks.	0,03
	pepeo maks.	10
	vlaga maks.	4,5
	hlapljive tvari maks.	1
	poroznost	40 – 45

Tablica 3.7. Kemijski sastav vapnenca CaCO_3

	Sastav	%
Vapnenac, CaCO_3	CaCO_3	85 – 95
	MgO	0,50 – 1,0
	FeO + SiO_2	3,0 – 4,0
	Al_2O_3 + Fe_2O_3	2,0 – 3,0
	SiO_2	3,0 – 5,0
	prašina	3,0 – 5,0

Sve se navedene metalne i nemetalne komponente zasipa šaržiraju po propisanom redoslijedu. Proces taljenja u kupolnoj peći traje 40 do 50 minuta. Rastaljeni metal iz izlaznog kanala kupolne peći istječe u ljevački lonac kapaciteta 3 t, a kao sporedni produkt taljenja metala nastaje troska. Nakon što se ljevački lonac napuni, taljevina se prelijeva u mrežno – frekvencijsku peć R. Končar MTS 4/1100, gdje se vrši dogrijavanje i korekcija kemijskog sastava, odnosno korekcija udjela ugljika i silicija.

Korekcija udjela ugljika vrši se sredstvom za naugličenje, npr. kalciniranim petrol – koksom. Tablica 3.8. prikazuje sastav i svojstva kalciniranog petrol – koksa.

Tablica 3.8. Sastav i svojstva kalciniranog petrol – koksa







	Sastav, svojstvo	%
Kalcinirani petrol – koks	C	98
	S	< 1
	vlaga maks.	0,20
	hlapivo	0,20 – 0,30
	pepeo	0,2 – 0,3

Nakon korekcije kemijskog sastava i dogrijavanja na potrebnu temperaturu (1500 – 1550 °C), taljevina se prelijeva u lonac od 3 t, te započinje faza odsumporavanja. U ljevaonici "Metalske industrije Varaždin" d.d. usvojen je postupak odsumporavanja pomoću kalcij – karbida (CaC_2). Pri odsumporavanju se na površinu taljevine dodaje oko 2 % kalcij – karbida u odnosu na masu taljevine koja se obrađuje. Na dnu lonca se pričvrste tri dovoda plinovitog dušika, koji služi za miješanje taljevine. Miješanje omogućava da što veća površina taljevine dođe u dodir sa CaC_2 , čime se ubrzava reakcija odsumporavanja. Tablica 3.9. prikazuje sastav tehničkog kalcij – karbida.

Tablica 3.9. Sastav tehničkog kalcij – karbida

	Sastav	%
Tehnički kalcij – karbid	CaC_2	70 – 80
	CaO	15 – 20
	$\text{Al}_2\text{O}_3 + \text{SiO}_2 + \text{Fe}_2\text{O}_3$	3,0 – 6,0
	slobodni C	1,0 – 4,0


Kemijske reakcije taljevine željeznog lijeva s kalcij – karbidom su sljedeće:



Temperaturne promjene taljevine uslijed obrade kalcij – karbidom su male jer su reakcije kalcij – karbida sa sumporom egzotermne.

Nakon odsumporavanja u ljevačkom loncu nastaje tzv. bazna taljevina za proizvodnju nodularnog lijeva, koja se iz lonca prelijeva u kanalnu indukcijsku peć za zadržavanje topline (receptor). Na pripremljenim taljevinama za ovo istraživanje provedeni su sljedeći postupci obrade taljevine magnezijem: Flotret[®] i Osmoza[®].


Postupak Flotret koristi se za izradu nodularnog lijeva za lijevanje na strojnom kalupljenju. Postupak se provodi s loncima kapaciteta 200 ili 400 kg, na način da se taljevina prelijeva preko komore s nodulatorom u lonce. Slika 3.1. shematski prikazuje komoru i princip postupka Flotret. U ovom je istraživanju dobivena taljevina iz kupolne peći ulivena u mrežno – frekvencijsku peć R. Končar MTS 4/1100, ispitan joj je sadržaj ugljika i silicija diferencijalnom toplinskom analizom, te je prema rezultatima analize korigiran sastav taljevine. Nakon toga je taljevini povišena temperatura radi odsumporavanja. Odsumporena taljevina korigiranog sastava akumulirana je u kanalnoj indukcijskoj peći, odakle je ulijevana u lonac kapaciteta 200 kg ili 400 kg, te je prelijevana preko nodulatora (predlegure FeSiMg5), smještenog u reakcijskoj komori Flotret posude.



Slika 3.1. Komora i princip Flotret postupka obrade taljevine njenim prelijevanjem preko predlegure FeSiMg

Postupak Osmoza koristi se ukoliko je taljevina nodularnog lijeva namijenjena ulijevanju pri ručnom kalupljenju. Taljevine pripremane u ovom istraživanju su nakon

dobivanja u kupolnoj peći, uljevane u mrežno – frekvencijsku peć R. Končar MTS 4/1100. Svakoj je taljevini ispitan sadržaj ugljika i silicija diferencijalnom toplinskom analizom. Prema rezultatima analize, korigiran je sastav taljevine. Nakon toga je taljevina dodatno zagrijana zbog odsumporavanja. Odsumporena taljevina korigiranog sastava akumulirana je u kanalnoj indukcijskoj peći. Iz peći je ulijevana u ljevački lonac od 1 t ili 3 t. U lonac je zatim na površinu taljevine u tankom mlazu istjecala proračunom određena količina nodulatora (predlegure FeSiMg5) iz dozatora, te je taljevina propuhana dušikom radi postizanja turbulencije i intenzifikacije reakcija. Slika 3.2. shematski prikazuje postupak Osmoza.




Slika 3.2. Postupak obrade taljevine magnezijem Osmoza

Ovisno o primijenjenom postupku obrade taljevine magnezijem, koristi se odgovarajuća vrsta i količina nodulatora. Reakcija nodulatora FeSiMg kod svih je postupaka burna, uz pojavu velikog bljeska i velike količine dima.

3.2. Ispitivanje kemijskog sastava ljevova

Svakoj od 147 pripremljenih taljevina nodularnog lijeva određen je kemijski sastav spektralnom analizom. Korišten je spektrometar GDS 400A proizvođača Leco, koji se nalazi u Laboratoriju "Metalske industrije Varaždin" d.d. Uzorci taljevine su uzimani ulijevanjem rastaljenog metala u bakrenu kokilu, te je nakon skrućivanja taljevine određen maseni udio sljedećih kemijskih elemenata: Mg, C, Si, Mn, S, P, Ni, Cr, Cu, Mo, Ti, Al, Sn, Pb i Zn. Slika 3.3. prikazuje polovinu bakrene kokile, u koju su lijevani uzorci za ispitivanje kemijskog sastava taljevina nodularnog lijeva.



Slika 3.3. Polovina bakrene kokile u koju su lijevani uzorci za ispitivanje kemijskog sastava taljevina

Prilog 3. prikazuje rezultate kemijske analize sastava taljevina br. 1 – 50. Prilog 4. daje rezultate kemijske analize taljevina br. 51 – 100. Prilog 5. navodi rezultate kemijske analize taljevina br. 101 – 147. Također, analizirana je razdioba frekvencija

udjela pojedinih legirnih elemenata da bi se vidjelo koliko su dostupni podaci za učenje neuronske mreže raznovrsni. Prilog 6., Prilog 7. i Prilog 8. prikazuju te distribucije.

3.3. Lijevanje ispitnih uzoraka za ispitivanje mehaničkih svojstava


Pripremljeni uzorci taljevine, nakon obrade taljevine magnezijem, ulijevani su u normirane kalupe za izradu tzv. Y – proba. Od Y – proba izrađeni su ispitni uzorci za statičko vlačno ispitivanje nodularnog lijeva. Jednokratni pješčani kalupi za lijevanje Y – proba izrađivani su postupkom Beta – set[®]. Beta – set je hladni postupak izrade pješčanih kalupa i jezgri za izradu odljevaka kojim mješavina brzo očvrstne, te je stoga pogodan za korištenje na automatskim linijama kalupljenja. Mješavina se pripremala u omjeru: 75 kg suhog kvarcnog pijeska veličine zrna 0,18 – 0,20 mm, 1,4 l fenol – formaldehidne smole kao veziva i para metil – formiata kao plina za učvršćivanje. Tijekom dvije minute mješavina je strojno miješana, nakon čega je unesena u drveni kalup, gdje je propuhana metil – formiatom. Slika 3.4. prikazuje postrojenje za izradu jezgri i kalupa postupkom Beta – set.

U jednom su kalupu izliveno dvije Y – probe od iste taljevine. Oblik, dimenzije, vrsta kalupa, način ulijevanja i hlađenja Y – probe propisani su normom HRN EN 1563. Norma propisuje četiri veličine Y – probe, a u ovom je istraživanju korištena veličina probe Y2. Slika 3.5. prikazuje normom propisani oblik i dimenzije Y2 – probe. Slika 3.6. prikazuje hlađenje dviju odljevenih Y – proba u kalupu.

3. EKSPERIMENTALNI DIO



Slika 3.4. Postrojenje za izradu jezgri i kalupa postupkom Beta – set




Slika 3.5. Oblik i dimenzije Y2 – probe prema HRN EN 1563



Slika 3.6. Hlađenje dviju odljevenih Y – proba u kalupu

3.4. Statičko vlačno ispitivanje uzoraka

Norma HRN EN 1563 propisuje i način izuzimanja uzoraka za statičko vlačno ispitivanje iz odljevene Y – probe. Slika 3.5. također prikazuje mjesto izuzimanja epruveta crtkanom crtom, a za potrebe ovog istraživanja korištena je slikom prikazana donja epruveta. Epruvete su kružnog poprečnog presjeka, oblika i dimenzija B 14 x 70, prema HRN EN 1563. Slika 3.7. prikazuje epruvetu za statičko vlačno ispitivanje B 14 x 70. Prema normi, početni je promjer epruvete $d_0 = 14$ mm, a početna mjerna duljina $L_0 = 70$ mm. Ostale dimenzije prema normi su: promjer glave epruvete, d_1 je M20, duljina glave epruvete, h je minimalno 17 mm, duljina tijela epruvete, L_c iznosi najmanje 84 mm, te ukupna duljina epruvete L_t je minimalno 125 mm.



Slika 3.7. Epruveta za statičko vlačno ispitivanje B 14 x 70 prema HRN EN 1563 [22]

Prema normi HRN EN 1563, za svaku je taljevinu pripremljena po jedna epruveta za statičko vlačno ispitivanje. Na univerzalnoj kidalici u laboratoriju "Metalske industrije Varaždin" d.d. provedeno je statičko vlačno ispitivanje i određena su sljedeća mehanička svojstva: vlačna čvrstoća, R_m , konvencionalna granica razvlačenja, $R_{p0,2}$ i istežljivost, A . Ispitivanje je provedeno na kidalici vrste ZD–20, njemačkog proizvođača "Fritz Heckert", klase točnosti 1, sukladno normi EN ISO 7500-1. Prilog 9. tablično prikazuje rezultate ispitivanja mehaničkih svojstava (R_m , $R_{p0,2}$, A , HB) svih pripremljenih taljevina. Prilog 10. predstavlja razdiobe pojedinih ispitivanih mehaničkih svojstava. Uvid u te razdiobe važan je pri modeliranju neuronskih mreža koje na temelju tih podataka trebaju naučiti predviđati određeno mehaničko svojstvo.

3.5. Toplinska analiza taljevina nodularnog lijeva

Toplinska analiza, tj. snimanje krivulja hlađenja pripremljenih taljevina nodularnog lijeva provedena je adaptabilnim sustavom za toplinsku analizu ATAS®. Sustav je razvila tvrtka "NovaCast" u suradnji sa švedskim ljevačkim udruženjem SFA ("Svenska Gjuterifoereningenens Service" AB). ATAS je skraćena od engl. *adaptive thermal analysis system*. Riječ je o sustavu za kontrolu metalurških procesa u proizvodnji sivog i nodularnog lijeva. Sustav je prilagodljiv različitim ljevaonicama i različitim legurama željeznog lijeva, obzirom da uvjeti lijevanja znatno variraju između ljevaonica. ATAS je namijenjen za kontrolu stanja taljevine i za nadzor nad procesima pripreme i obrade taljevine uz pomoć toplinske analize. Sustav ATAS moguće je koristiti za detaljnu metaluršku analizu taljevine uz pomoć sustava za analizu i obradu podataka dobivenih toplinskom analizom, temeljenog na metodama umjetne inteligencije.

ATAS Verifier je temeljni modul, koji se prema potrebi može nadograditi dodatnim modulima s naprednim funkcijama. Rad sustava zasniva se na analizi krivulje hlađenja normiranih uzoraka taljevine. Krivulja hlađenja taljevine smatra se njenim "otiskom prsta". Ukoliko neka taljevina ima istu krivulju hlađenja kao neka prethodno analizirana taljevina, nova će taljevina imati ista svojstva. S druge strane, dvije taljevine istog kemijskog sastava mogu dati različita mehanička svojstva odljevka. Upotrebom toplinske analize može se kontrolirati taljevina i unaprijed predvidjeti moguće pogreške prilikom lijevanja.


ATAS White je modul razvijen za analiziranje uzoraka koji skrućuju "bijelo", tj. metastabilno. Uzorci taljevine ulijevaju se u telurom obložene čašice, čime se postiže izlučivanje ugljika u obliku cementita, te se može odrediti ekvivalent ugljika, udio ugljika i udio silicija. Modul ATAS Pearlite koristi se za praćenje eutektoidne pretvorbe. Njime se može predvidjeti količina perlita koja će se stvoriti i svojstva koja će dobiveni odljevak imati.

Sustav ATAS može se koristiti za kontrolu kvalitete tijekom taljenja i postupaka metalurških obrada taljevine. Nadalje, ATAS se može koristiti i za optimiranje različitih faza u procesu pripreme taljevine. Moguće je pratiti utjecaj malih promjena u procesu,

3. EKSPERIMENTALNI DIO


kao što su promjena vremena, temperatura, redoslijeda zasipavanja, postupaka obrade taljevine itd., te na taj način odrediti optimalni tehnološki postupak pripreme taljevine.

Za snimanje krivulja hlađenja taljevina u "Metalskoj industriji Varaždin" d.d. za potrebe ovog istraživanja korišten je sustav ATAS Verifier 4.2.1. i ATAS Pearlite 4.2.1., koji je u vlasništvu Metalurškog fakulteta u Sisku. Slika 3.8. prikazuje u radu korišteni ATAS.



Slika 3.8. Sustav za toplinsku analizu taljevine ATAS

Sustav za toplinsku analizu temelji se na mjerenju temperature pomoću normiranih čašica Quik – cup[®], u kojima se nalaze termoelementi. Za potrebe ovog istraživanja korištene su čašice QC 4010. Programski paket omogućuje istovremeno praćenje metastabilnog (tzv. bijelog) i stabilnog (tzv. sivog) skrućivanja pomoću lončića Quik – cup sa i bez telura, a u cilju određivanja %C, %Si i CE, te za praćenje kritičnih točaka na krivulji hlađenja od temperature ulijevanja do završetka eutektoidne pretvorbe. Slika 3.9. prikazuje jednu još neupotrijebljenu Quik – cup čašicu. Čašice su namijenjene za jednokratnu upotrebu. Kompenzacijski kablovi su povezivali termoelement u čašici s A/D pretvornikom signala Datascan 7220 / 7221. Digitalni je signal prenošen na obradu u osobno računalo s instaliranim odgovarajućim programskim paketom.

Slika 3.9. Čašica Quik – cup[®]

Za svaku je taljevinu snimljena krivulja hlađenja i njena prva derivacija u eutektičkom području, te krivulja hlađenja u eutektoidnom području. Sustav ATAS je za svaku taljevinu pohranio 21 različiti toplinski parametar:

1. ϑ_L likvidus, °C
2. ϑ_{ES} temperatura početka eutektičke reakcije, °C
3. $\frac{d\vartheta_{ES}}{dt}$ brzina hlađenja u trenutku početka eutektičke reakcije, °C/s
4. ϑ_{EP} temperatura eutektičkog pothlađenja, °C
5. ϑ_{ER} temperatura eutektičke rekalescencije, °C
6. ϑ_R rekalescencija ($\vartheta_R = \vartheta_{ER} - \vartheta_{EP}$), °C
7. $\overline{v_R}$ prosječna brzina rekalescencije, °C/s
8. $v_{R,maks}$ maksimalna brzina rekalescencije, °C/s
9. ϑ_S solidus, °C
10. GRF1 grafitni faktor 1
11. GRF2 grafitni faktor 2
12. GRF3 grafitni faktor 3
13. F_{oks} oksidacijski faktor ($\frac{f_{S2}}{f_{S2} + f_{S3}}$)


3. EKSPERIMENTALNI DIO

14. f_{S1} udio površine ispod krivulje hlađenja između \mathcal{G}_L i \mathcal{G}_{EP} u ukupnoj površini (od \mathcal{G}_L do \mathcal{G}_S), %
15. f_{S2} udio površine ispod krivulje hlađenja između \mathcal{G}_{EP} i \mathcal{G}_{ER} u ukupnoj površini (od \mathcal{G}_L do \mathcal{G}_S), %
16. f_{S3} udio površine ispod krivulje hlađenja između \mathcal{G}_{ER} i \mathcal{G}_S u ukupnoj površini (od \mathcal{G}_L do \mathcal{G}_S), %
17. t_d dendritno vrijeme, s
18. $t_{L,zastoj}$ vrijeme zastoja na likvidusu, s
19. $\mathcal{G}_{EP,t}$ teoretsko eutektičko pothlađenje
20. $\frac{d\mathcal{G}_S}{dt}$ nagib krivulje hlađenja na \mathcal{G}_S , tj. dubina negativnog pika na \mathcal{G}_S , °C/s
21. \mathcal{G}_{EID} temperatura eutektoidne pretvorbe, °C

Temperatura eutektičkog pothlađenja \mathcal{G}_{EP} je najniža temperatura tijekom eutektičke reakcije, nakon koje počinje temperatura rasti, osim ako nije riječ o metastabilnoj reakciji. Maksimalna brzina rekalescencije određuje se kao najveći iznos prve derivacije krivulje hlađenja između temperatura eutektičkog pothlađenja, \mathcal{G}_{EP} , i temperature eutektičke rekalescencije, \mathcal{G}_{ER} .


Grafitni faktor 1, GRF1, je definiran kao relativno vrijeme potrebno da se temperatura snizi za 15 °C u odnosu na temperaturu eutektičke rekalescencije, \mathcal{G}_{ER} . GRF1 predstavlja količinu eutektika, tj. eutektičkog grafita koji nastaje tijekom druge faze eutektičke reakcije. Povoljan je što viši iznos ovog faktora jer uvjetuje veći udio eutektičkog grafita u strukturi. Grafitni faktor 2, GRF2, izračunava se na temelju brzine hlađenja taljevine prije i nakon solidusa. GRF2 predstavlja kut prve derivacije krivulje hlađenja na solidus temperaturi i prikazuje brzinu kojom željezni lijev prolazi zonu ukupnog skrućivanja. Ovaj je faktor indirektna mjera toplinske vodljivosti lijeva. Povoljniji je što niži GRF2 jer ukazuje na veću količinu izlučenog grafita. Grafitni faktor 3, GRF3, definiran je kao kut prve derivacije krivulje hlađenja neposredno prije solidusa. Dendritno vrijeme, t_d , definirano je kao omjer vremenskog intervala od likvidusa do temperature eutektičkog pothlađenja i vremenskog intervala od likidusa do solidusa. Slika 3.10. prikazuje primjer ATAS-om snimljene krivulje hlađenja taljevine

br. 2 u eutektičkom temperaturnom području, uz izmjerene toplinske parametre. Za teorijsku temperaturu stabilne kristalizacije vrijedi: $T_{E, stabil} = 1153 + 6,7 \%Si$ [°C]. Za teorijsku temperaturu metastabilne kristalizacije vrijedi $T_{E, metastabil} = 1147 - 12 \%Si$ [°C]. Dvije horizontalne crte na slici predstavljaju teorijsku temperaturu stabilne kristalizacije (1165 °C), odnosno metastabilne kristalizacije (1131 °C) taljevine br. 2. Slika 3.11. prikazuje prvu derivaciju krivulje hlađenja taljevine br. 2 u eutektičkom temperaturnom području i izmjerene toplinske parametre. Slika 3.12. prikazuje krivulju hlađenja taljevine br. 2 u eutektoidnom temperaturnom području, s pripadajućim toplinskim parametrima.

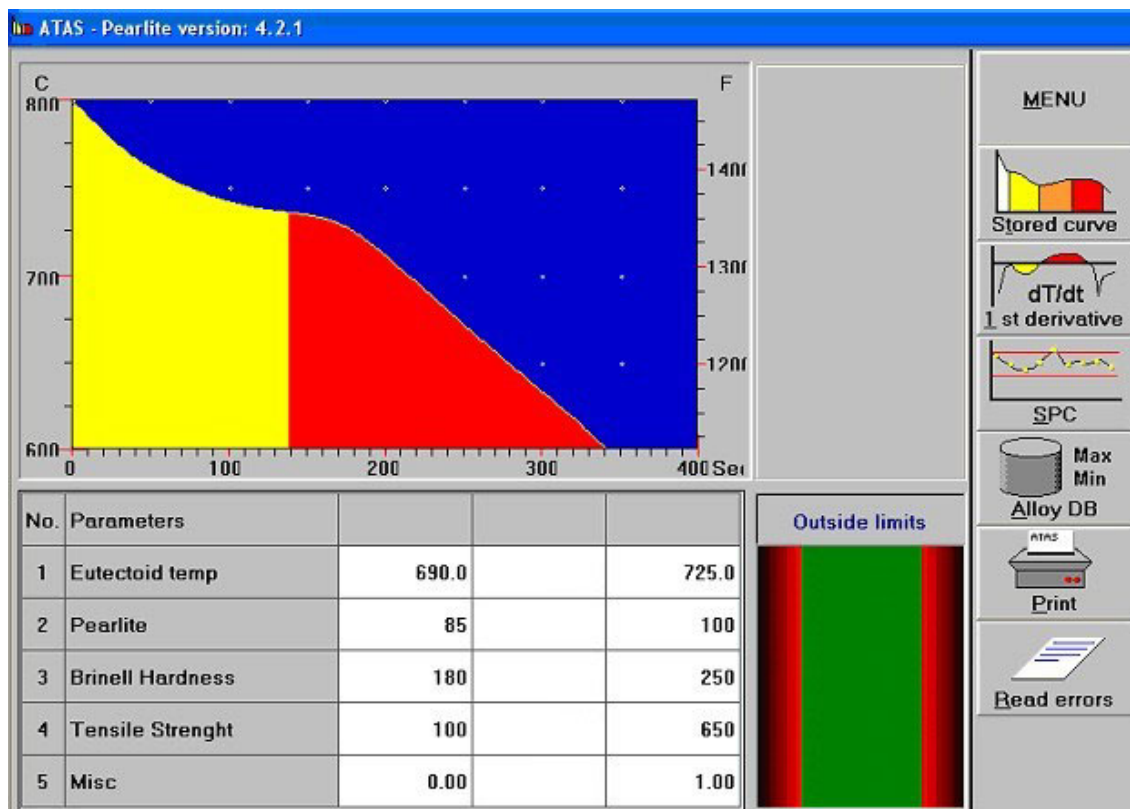


Slika 3.10. Krivulja hlađenja u eutektičkom području za taljevinu br. 2 s izmjerenim toplinskim parametrima

3. EKSPERIMENTALNI DIO



Slika 3.11. Prva derivacija krivulje hlađenja u eutekličkom području za taljevinu br. 2 s izmjerenim toplinskim parametrima



Slika 3.12. Krivulja hlađenja u eutektoidnom području za taljevinu br. 2 s izmjerenim toplinskim parametrima

Prilog 11. prikazuje izmjerene toplinske parametre s krivulje hlađenja za taljevine br. 1 – 30. Prilog 12. daje toplinske parametre izmjerene na krivuljama hlađenja taljevina označene brojevima 31 – 60. Prilog 13. predstavlja izmjerene toplinske parametre s krivulje hlađenja taljevina od br. 61 do br. 90. Prilog 14. prikazuje toplinske parametre izmjerene na krivuljama hlađenja taljevina br. 91 – 120. Prilog 15. donosi izmjerene toplinske parametre s krivulja hlađenja taljevina označene brojevima 121 do 147. Kako bi se dobio uvid u raznovrsnost prikupljenih uzoraka za učenje neuronske mreže, načinjena je analiza distribucije frekvencija pojedinih toplinskih parametara. Prilog 16. i Prilog 17. prikazuju te distribucije.

3.6. Ispitivanje tvrdoće

Nakon provedenog statičkog vlačnog ispitivanja, poprečno su odrezane glave epruveta, kako bi se dobili valjčići, na kojima je ispitana tvrdoća po Brinellu, prema normi HRN EN 6505-1. U svaki je uzorak utisnut redni broj njegove taljevine. Tvrdoća je ispitana u mehaničkom laboratoriju "Metalske industrije Varaždin" d.d. Tvrdomjer vrste HPO 250, njemačkog proizvođača "Fritz Heckert", korišten je za ispitivanje tvrdoće. Na svakom je uzorku tvrdoća izmjerena tri puta, te je određena srednja vrijednost. Prilog 9. prikazuje tvrdoće za pojedine taljevine. Prilog 10. daje prikaz razdiobe učestalosti pojedinih razreda vrijednosti tvrdoća za cijeli skup podataka.

3.7. Ispitivanje mikrostrukture

Nakon ispitivanja tvrdoće, na Metalurškom fakultetu u Sisku pripremljeni su uzorci za metalografsko ispitivanje, te je na njima analizirana mikrostruktura za svaku od pripremljenih taljevina. Valjčići, na kojima je prethodno ispitana tvrdoća, prerezani su poprečno sredinom promjera, uz hlađenje vodenom emulzijom. Korištena je rezalica Abrasimet 2 proizvođača "Buehler".

Po jedna polovica od svakog prerezanog uzorka taljevine zalivena je polimernom masom Buehler Varidur 20. U svaki kalup za zalijevanje smještno je po 2 uzorka. Slika 3.13. prikazuje dva uzorka pripremljena za metalografsku analizu: jedan je uzorak prikazan sa strane gdje su utisnute oznake taljevina, a drugi s izbrušene strane.




Slika 3.13. Uzorci nodularnog lijeva pripremljeni za metalografsku analizu


Nakon zalijevanja, uzorci su brušeni i polirani na uređaju za pripremu uzoraka Buehler Phoenix Beta. Uzorci su brušeni brusnim papirima granulacija 120, 240, 400 i

600 s abrazivnim sredstvom SiC, pri čemu su hlađeni vodom. Sa svakom je granulacijom papira brušeno tijekom tri minute pri brzini vrtnje 150 min^{-1} i pritisnoj sili 30 N. Nakon brušenja svi su uzorci polirani na podlozi od filca s vodenom otopinom Al_2O_3 . Uzorci su polirani tijekom 5 minuta pri brzini vrtnje 150 min^{-1} i pritisnoj sili 10 N.

Za metalografsku analizu korišten je svjetlosni metalografski mikroskop s digitalnom kamerom Olympus GX 51 i sustav za automatsku obradu slike AnalySIS[®] Materials Research Lab od proizvođača "Soft Imaging System". Na svakom su uzorku načinjena tri snimka mikrostrukture i tri mjerenja. U nenagriženom stanju, prema normi EN ISO 945, izmjereni su stupanj nodularnosti i broj nodula grafita po jedinici površine. Nakon nagrizanja uzoraka s 5 % nitalom tijekom 10 s, određeni su i udjeli ferita i perlita u metalnoj osnovi. Slika 3.14. prikazuje fotografije mikrostrukture nodularnog lijeva br. 29 u nenagriženom stanju (a) i u nagriženom stanju (b). Riječ je je feritnom nodularnom lijevu s 96,1 % ferita, odnosno 3,9 % perlita u metalnoj osnovi. Slika 3.15. prikazuje fotografiju mikrostrukture perlitnog nodularnog lijeva u nagriženom stanju. Riječ je o lijevu br. 105, koji ima 67,7 % perlita, tj. 32,3 % ferita u metalnoj osnovi.



Slika 3.14. Fotografija mikrostrukture feritnog nodularnog lijeva (lijev br. 29) u: (a) nenagriženom i (b) nagriženom stanju



Slika 3.15. Fotografija mikrostrukture perlitnog nodularnog lijeva (lijev br. 105) u nagriženom stanju

Prilog 18. prikazuje vrijednosti ispitanih mikrostrukturnih parametra (nodularnost, udio ferita, udio perlita i broj nodula/mm²) za taljevine br. 1 – 50. Prilog 19. predstavlja mikrostrukturne parametre za taljevine br. 51 – 100.

Prilog 20. donosi mikrostrukturne parametre za taljevine označene brojevima od 101 do 147. Za sve su taljevine prikazane vrijednosti za sva tri mjerenja svakog mikrostrukturnog parametra. Prilog 21. prikazuje razdiobe učestalosti pojavljivanja pojedinih razreda vrijednosti ispitanih mikrostrukturnih parametara. Što je razdioba više jednolika, to je problem koji neuronska mreža treba riješiti bolje opisan i veća je vjerojatnost da će modelirana mreža moći dobro naučiti preslikavati ulazne parametre na tražene izlaze.

3.8. Modeliranje neuronskih mreža

Modeliranje neuronskih mreža provedeno je uz pomoć programskog paketa Matlab 7.0 i njegovog programskog podskupa za neuronske mreže. Primijenjeni su modeli dvoslojnih unaprijednih neuronskih mreža koje uče pomoću algoritma povratnog rasprostiranja pogreške. Aktivacijska funkcija u skrivenom sloju bila je bipolarna sigmoidalna funkcija, a u izlaznom sloju je bila linearna aktivacijska funkcija.

Korišten je Levenberg – Marquardtov algoritam. Početna vrijednost Marquardtovog parametra, μ , postavljena je na 0,001. Faktor smanjenja Marquardtovog parametra bio je 0,1, a povećanja 10. Marquardtov parametar se množi faktorom

smanjenja pri svakom koraku u kojem dolazi do smanjenja funkcije cilja. Faktorom povećanja Marquardtovog parametra množi se taj parametar ukoliko pri nekom koraku učenja dođe do povećanja funkcije cilja. Ukoliko vrijednost Marquardtovog parametra naraste iznad granične vrijednosti 10^{10} , učenje se zaustavlja.

Maksimalni broj koraka učenja bio je 1000. Granična razina točnosti učenja postavljena je pomoću normaliziranog korijena srednje kvadratne pogreške $NRMS = 0,05$, pri čemu je odgovarajuća približna srednja vrijednost relativne pogreške $\overline{u_{rel}} \approx 0,25\%$, a odgovarajući koeficijenti korelacije i determinacije približno su $R \approx 0,999$, $R^2 \approx 0,998$.

Podaci o različitim svojstvima pojedinih taljevina podijeljeni su u tri skupa: skup za učenje, za validaciju i za testiranje. Podjela je vršena na temelju minimalnih vrijednosti Euklidovih udaljenosti između pojedinih taljevina. Euklidove su udaljenosti između taljevina određivane na skupu podataka o 21 toplinskom parametru za svih dostupnih 147 ispravno snimljenih krivulja hlađenja taljevina. Euklidove su udaljenosti između taljevina posložene zatim u rastućem nizu. Unutar tog skupa, prvih 17 najbližih taljevina dodijeljeno je u skup za testiranje, a sljedećih 16 taljevina u skup za validaciju. Na taj je način oblikovan skup za testiranje sa sljedećim taljevinama: 4, 14, 30, 38, 42, 43, 66, 71, 73, 89, 102, 110, 118, 124, 127, 141 i 142. U skup za validaciju uključene su sljedeće taljevine: 2, 19, 26, 33, 54, 56, 64, 94, 100, 103, 104, 106, 126, 134, 138 i 145. Preostalih 114 taljevina sačinjavalo je skup za učenje. Ovako oblikovani skupovi korišteni su u svim predviđanima problemima kod kojih su ulazni podaci bili toplinski parametri taljevina.

Maksimalni broj koraka pri kojima dolazi do porasta pogreške u skupu za validaciju je postavljen na 5. Dakle, ako je nakon 5 koraka učenja došlo do porasta pogreške u skupu za validaciju, dalje učenje neuronske mreže je zaustavljeno.

Na ulaz neuronske mreže postavljeni su poznati podaci o taljevinama dobiveni toplinskom analizom, a na izlaz podaci o pripadajućem jednom od mehaničkih svojstava ili mikrostrukturi. Bilo je potrebno reducirati broj ulaznih parametara dobivenih toplinskom analizom, te odabrati samo one relevantne, koji bitno utječu na mehanička svojstva i mikrostrukturu nodularnog lijeva. Analizom glavnih komponenata određeni su parametri toplinske analize koji značajno utječu na varijacije unutar skupa sastavljenog od 21 toplinskog parametara svih taljevina. Korišten je programski paket

Statistica 8.0. Određeno je 9 glavnih komponenata, kojima je objašnjivo 97,4377 % sume kvadrata odstupanja. Te su komponente: likvidus, \mathcal{G}_L , temperatura početka eutektičke reakcije, \mathcal{G}_{ES} , grafitni faktor 2, GRF2, oksidacijski faktor, F_{oks} , udio površine ispod krivulje hlađenja između \mathcal{G}_L i \mathcal{G}_{EP} u ukupnoj površini (od \mathcal{G}_L do \mathcal{G}_S), f_{S1} , udio površine ispod krivulje hlađenja između \mathcal{G}_{EP} i \mathcal{G}_{ER} u ukupnoj površini (od \mathcal{G}_L do \mathcal{G}_S), f_{S2} , udio površine ispod krivulje hlađenja između \mathcal{G}_{ER} i \mathcal{G}_S u ukupnoj površini (od \mathcal{G}_L do \mathcal{G}_S), f_{S3} , dendritno vrijeme, t_d , i temperatura eutektoidne pretvorbe, \mathcal{G}_{EID} .

Također, u programskom paketu Matlab postoji funkcija za transformaciju matrice analizom glavnih komponenata, čijom se primjenom može reducirati broj ulaznih parametara za neuronsku mrežu. Nakon transformacije matrice nije definirano koje su to odabrane komponente preostale. Pri izračunu koje će se komponente isključiti iz matrice, potrebno je zadati kriterij isključivanja. Zadano je da se isključe one komponente koje doprinose s manje od 2 % u ukupnoj varijaciji.

Nadalje, prema teorijskim razmatranjima, na ulaz neuronske mreže postavljeno je 7 toplinskih parametara. Tumačenje njihovog utjecaja slijedi iz poznavanja fizikalnih zakonitosti procesa skrućivanja taljevine nodularnih ljevova. To su sljedeći parametri: likvidus, \mathcal{G}_L , temperatura eutektičkog pothlađenja, \mathcal{G}_{EP} , rekalescencija, \mathcal{G}_R , solidus, \mathcal{G}_S , grafitni faktor 1, GRF1, grafitni faktor 2, GRF2, te brzina hlađenja na solidusu, $\frac{d\mathcal{G}_S}{dt}$.

Uz ove toplinske parametre, prema teorijskim razmatranjima, je pri modeliranju nodularnosti uključen i osmi toplinski parametar: temperatura eutektoidne pretvorbe, \mathcal{G}_{EID} , °C.

Za pobrojana četiri načina određivanja skupa ulaznih varijabli ispitana je sposobnost generalizacije neuronske mreže praćenjem promjene pogreške pojedinih parametra pogreške u skupovima za učenje, validaciju i testiranje pri predviđanju nodularnosti.

U trima skupovima, za učenje, za validaciju i za testiranje, analizirana je pogreška, te je načinjena i statistička obrada pogrešaka. Korišteni su sljedeći parametri: koeficijent korelacije, R , normalizirani korijen srednjeg kvadratnog odstupanja, $NRMS$ i relativna pogreška, $\overline{u_{rel}}$. Analiza pogreške učenja, validacije i testiranja pokazuje koliko se dobro neuronska mreža prilagodila ulazno – izlaznim parovima podataka, odnosno

koliko dobro mreža na temelju zadanih ulaznih vrijednosti predviđa izlazne parametre nodularnog lijeva.

Broj neurona u izlaznom sloju određen je brojem izlaznih varijabli i ne može se varirati. Broj neurona u skrivenom sloju može se optimirati. Najpovoljniji broj neurona u skrivenom sloju određen je praćenjem promjene parametara pogreške u skupu za testiranje.

U izlaznom je sloju neurona postavljena linearna aktivacijska funkcija, opisana jednadžbom (2.19). Nagib linearne aktivacijske funkcije je $K_p = 1$. U skrivenom sloju postavljena je bipolarna sigmoidalna aktivacijska funkcija, određena jednadžbom (2.16). Također je određen najpovoljniji početni nagib sigmoidalne funkcije, σ , pri kojem je pogreška u skupu za testiranje najmanja.

Pri svakoj promjeni broja neurona u skrivenom sloju i pri promjeni nagiba aktivacijske funkcije u skrivenom sloju neuronske mreže, postavljane su iste početne vrijednosti težinskih koeficijenata. Prije svakog učenja te su početne vrijednosti ponovno učitavane. Početne su vrijednosti težinskih koeficijenata određene algoritmom Nguyen – Widrow.

Prije učenja neuronske mreže, svi su ulazni i izlazni podaci normirani. Normiranje je provedeno na dva načina. Prvim načinom normiranja je srednja vrijednost normiranih podataka svih slučajeva neke ulazne ili neke izlazne varijable iz skupa jednaka ničtici, a standardna devijacija normiranih vrijednosti jednaka je jedinici. Izraz (3.1) korišten je za normiranje svake pojedine ulazne ili izlazne varijable:

$$p_n = \frac{p - \bar{p}}{\sigma_p} \quad (3.1)$$

gdje su p_n normirane vrijednosti, p nenormirane, izvorne vrijednosti, \bar{p} srednja vrijednost nenormiranih vrijednosti i σ_p standardna devijacija nenormiranih vrijednosti.

Drugi je način normiranja bio linearno preslikavanje svih vrijednosti neke ulazne ili neke izlazne varijable u interval vrijednosti $[-1, 1]$. Izrazom (3.2) normirani su podaci u interval $[-1, 1]$:

$$p_n = 2 \frac{p - p_{\min}}{p_{\max} - p_{\min}} - 1 \quad (3.2)$$

gdje su p_{\min} najniži iznos nenormiranih vrijednosti neke varijable, a p_{\max} najviši iznos.

Konačno je odabran onaj način normiranja koji je davao manju pogrešku u skupu za testiranje.

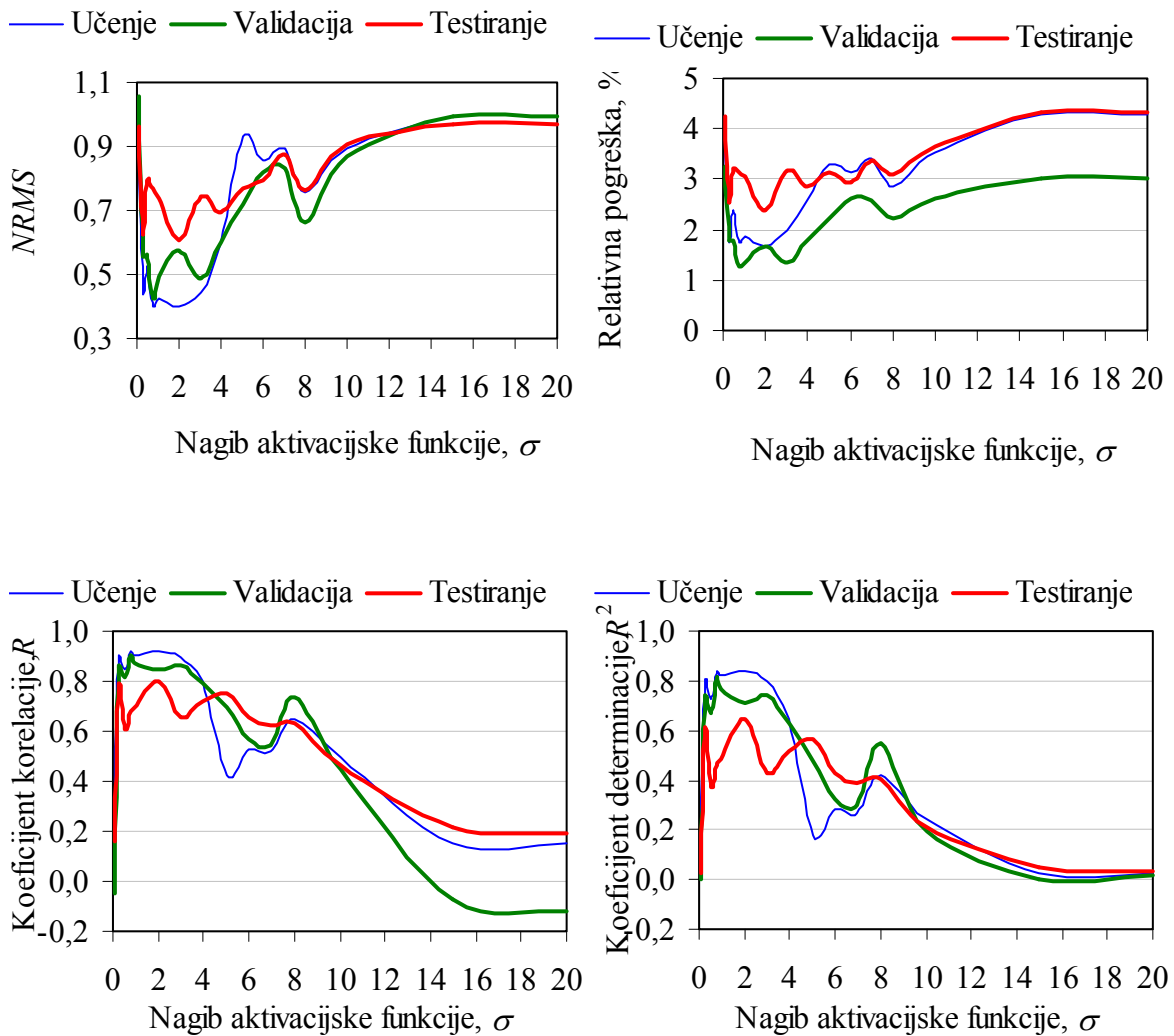
4. REZULTATI MODELIRANJA UMJETNIM NEURONSKIM MREŽAMA

4.1. Predviđanje mikrostrukture nodularnog lijeva na temelju toplinske analize

4.1.1. Predviđanje nodularnosti

Umjetna neuronska mreža modelirana je s dva sloja, jednim izlaznim i jednim skrivenim slojem. U izlazni je sloj neurona smještena linearna aktivacijska funkcija. Aktivacijska funkcija neurona u skrivenom sloju je bila sigmoidalna bipolarna, a njen najpovoljniji nagib, σ , određen je praćenjem promjene pogreške u skupu za testiranje. Praćeni parametri koji ukazuju na veličinu pogreške predviđanja nodularnosti lijeva iz skupova za učenje, validaciju i testiranje bili su srednja vrijednost apsolutnih vrijednosti relativne pogreške, $\overline{u_{rel}}$, normalizirani korijen srednjeg kvadratnog odstupanja, $NRMS$, te koeficijenti korelacije i determinacije između predviđenih i izmjerenih vrijednosti nodularnosti, R i R^2 . Slika 4.1. prikazuje promjenu pogreške u skupu za učenje, validaciju i testiranje s promjenom nagiba aktivacijske sigmoidalne bipolarne funkcije skrivenih neurona, σ . Od spomenuta tri skupa, najvažnije je pratiti pogrešku u skupu za testiranje, jer njena veličina govori koliko je dobro neki model neuronske mreže naučio preslikavati željenu funkciju. Najviša vrijednost koeficijenta korelacije u skupu za testiranje, $R = 0,8027$, uz $R^2 = 0,6443$, postignuta je uz vrijednost nagiba $\sigma = 2$. Također, najniže vrijednosti normaliziranog korijena srednjeg kvadratnog odstupanja, $NRMS = 0,6034$, i relativne pogreške, $\overline{u_{rel}} = 2,40\%$, u skupu za testiranje javile su se pri nagibu aktivacijske funkcije $\sigma = 2$.

Ove su vrijednosti parametara pogreške dobivene pri normiranju ulaznih i izlaznih podataka na način opisan izrazom (3.2), str. 88. Kada su podaci normirani izrazom (3.1), str. 87., uz $\sigma = 2$, parametri pogreške u skupu za testiranje bili su: $R = 0,8378$, $R^2 = 0,7019$, $NRMS = 0,6370$, te $\overline{u_{rel}} = 2,62$ %. Iako je koeficijent korelacije u ovom slučaju bio nešto viši, dakle povoljniji nego u slučaju normiranja u skup $[-1,1]$, zbog viših je vrijednosti parametra $NRMS$ ovaj način normiranja podataka napušten. U daljem modeliranju ostalih neuronskih mreža unutar ovog rada zadržano je normiranje ulaznih i izlaznih podataka u skup $[-1,1]$, tj. prema (3.2), a nagib sigmoidalne aktivacijske funkcije postavljen je za sve mreže na $\sigma = 2$.



Slika 4.1. Utjecaj nagiba aktivacijske funkcije skrivenih neurona na pogrešku predviđanja nodularnosti

U skrivenom sloju variran je broj neurona te je praćena promjena pogreške u skupu za testiranje. Prilog 22. prikazuje početne vrijednosti težinskih koeficijenata skrivenog sloja (\mathbf{W}_1 i \mathbf{b}_1) i izlaznog sloja (\mathbf{W}_2 i \mathbf{b}_2) koje su ućitavane prije ućenja pojedinih neuronskih mreža s razlićitim brojem skrivenih neurona. Poćetne su vrijednosti odrećdene algoritmom Nguyen – Widrow, a na temelju normiranih vrijednosti odabranih toplinskih parametara dobivenih snimanjem krivulje hlaćdenja taljevina. Prema zadanom broju neurona u skrivenom sloju, ućitavan je potreban broj redaka iz matrice poćetnih vrijednosti težinskih koeficijenta, do maksimalno 30 skrivenih neurona.

Kako je opisano u poglavlju 3.8., str. 86., praćena je pogreška neuronske mreže pri predvićdanju nodularnosti primjenom ćetiri razlićita seta ulaznih podataka. Tablica 4.1. prikazuje parametre pogreške u skupovima za ućenje, validaciju i testiranje za ćetiri slućajaja oblikovanja ulaznog skupa podataka. Prema parametru pogreške u skupu za testiranje, $NRMS$, zakljućeno je da je najpovoljnije kao ulazne parametre upotrijebiti sljedećih 8 velićina: likvidus, \mathcal{G}_L , temperatura eutektićkog pothlaćdenja, \mathcal{G}_{EP} , rekalescencija, \mathcal{G}_R , solidus, \mathcal{G}_S , grafitni faktor 1, GRF1, grafitni faktor 2, GRF2, brzina hlaćdenja na solidusu, $\frac{d\mathcal{G}_S}{dt}$, te temperatura eutektoidne pretvorbe, \mathcal{G}_{EID} , °C.

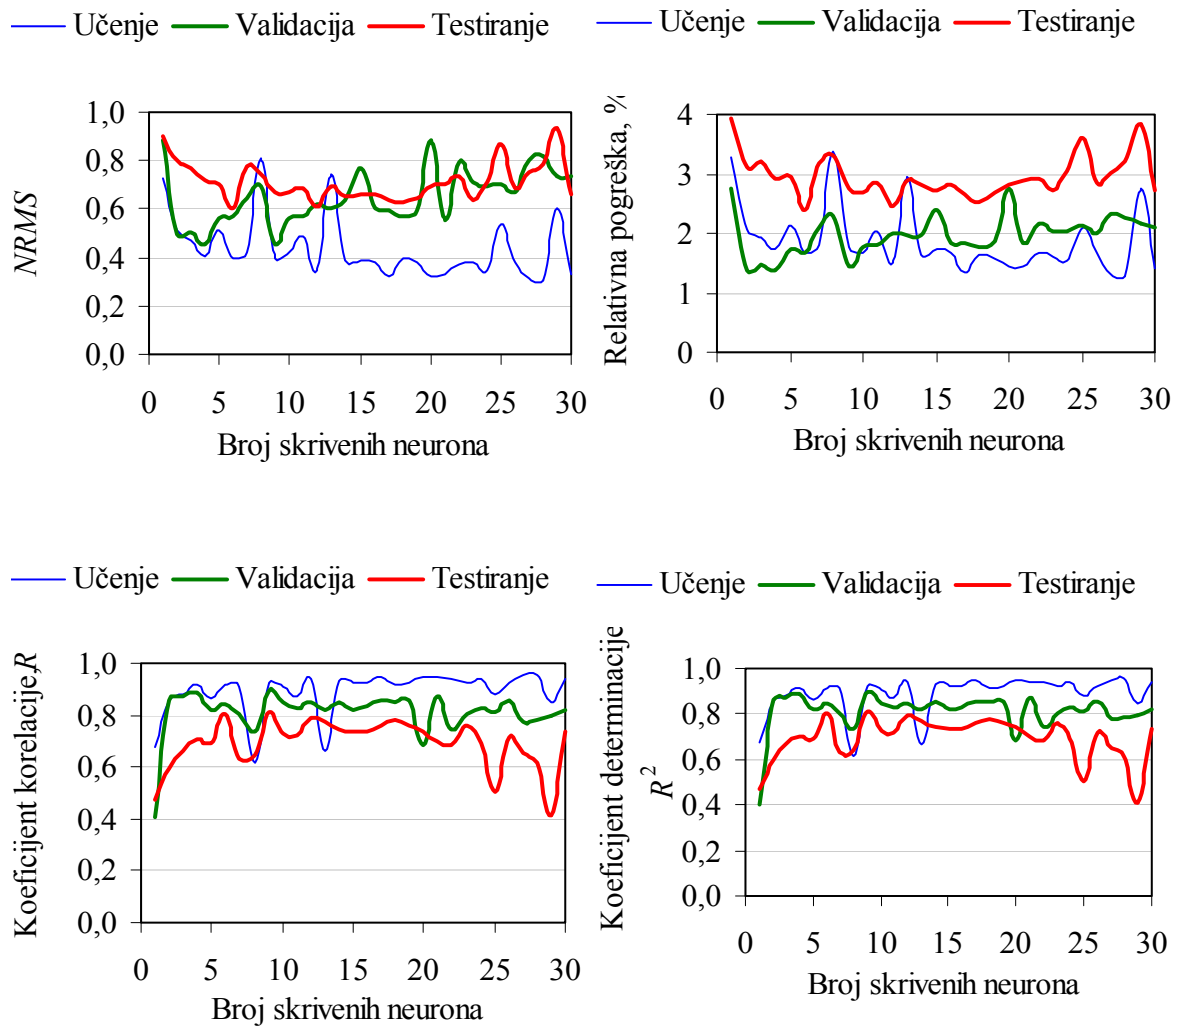
Tablica 4.1. Parametri pogreške pri predvićdanju nodularnosti razlićitim ulaznim skupovima toplinskih parametara

Ulazi odabrani:	R			R^2			$NRMS$			$\overline{u_{rel}}$, %		
	Uć.	Valid.	Test.	Uć.	Valid.	Test.	Uć.	Valid.	Test.	Uć.	Valid.	Test.
7 ulaza – teorija	0,695	0,801	0,706	0,48	0,64	0,50	0,731	0,588	0,706	2,79	1,94	2,88
8 ulaza – teorija	0,917	0,844	0,803	0,84	0,71	0,64	0,398	0,573	0,603	1,66	1,68	2,40
9 ulaza – Matlab	0,830	0,802	0,806	0,69	0,64	0,65	0,571	0,624	0,656	2,37	2,03	2,87
9 ulaza – Statistica	0,888	0,796	0,662	0,79	0,63	0,44	0,461	0,611	0,775	1,95	1,87	3,21


Slika 4.2. prikazuje utjecaj broja skrivenih neurona na pogrešku predvićdanja nodularnosti, preko praćenja promjene srednje vrijednosti relativne pogreške, $\overline{u_{rel}}$,

normaliziranog korijena srednjeg kvadratnog odstupanja, $NRMS$, te koeficijenta korelacije i determinacije između predviđenih i izmjerenih vrijednosti nodularnosti, R i R^2 , za skupove za učenje, validaciju i za testiranje. Najviša vrijednost koeficijenta korelacije u skupu za testiranje, $R = 0,8145$, odnosno pripadajućeg koeficijenta determinacije $R^2 = 0,6635$, određena je za 9 skrivenih neurona. S druge strane, najniže vrijednosti normaliziranog korijena srednje kvadratne pogreške, $NRMS = 0,6034$, i srednje vrijednosti relativne pogreške, $\overline{u_{rel}} = 2,40 \%$, u skupu za testiranje očitane su kod neuronske mreže sa 6 skrivenih neurona. Stoga je taj model neuronske mreže odabran kao konačan model za predviđanje nodularnosti. Kod te je mreže vrijednost koeficijenta korelacije u skupu za testiranje bila $R = 0,8027$, uz $R^2 = 0,6443$. Tablica 4.2 prikazuje pojedine predviđene i izmjerene vrijednosti nodularnosti i analizu relativne pogreške za pojedine ljevove u skupu za testiranje. Slika 4.3. daje korelaciju između predviđenih i izmjerenih nodularnosti u skupu za testiranje, s pripadajućim regresijskim pravcem i koeficijentom linearne korelacije, te s ucrtanim pravcem potpune korelacije, $R = 1$. Kako je koeficijent korelacije u skupu za testiranje neuronske mreže $R > 0,8$, može se reći da je odabranim modelom mreže postignuta čvrsta korelacija između izmjerenih i predviđenih nodularnosti. Prilog 24. prikazuje matrice konačnih vrijednosti težinskih koeficijenata skrivenog sloja (\mathbf{W}_1 , \mathbf{b}_1) i izlaznog sloja (\mathbf{W}_2 , \mathbf{b}_2) neuronske mreže za predviđanje nodularnosti na temelju odabranih parametara toplinske analize.

Slika 4.4. usporedno prikazuje izmjerene nodularnosti iz skupa za učenje i nodularnosti predviđene na dva načina: za ulaz je uzeto 8 toplinskih parametara, prema teorijskim razmatranjima, odnosno za slučaj 9 glavnih komponenata, prema Matlabu. Slika 4.5. na isti način uspoređuje izmjerene i predviđene nodularnosti iz skupova za validaciju i testiranje.






Slika 4.2. Utjecaj broja skrivenih neurona na pogrešku predviđanja nodularnosti



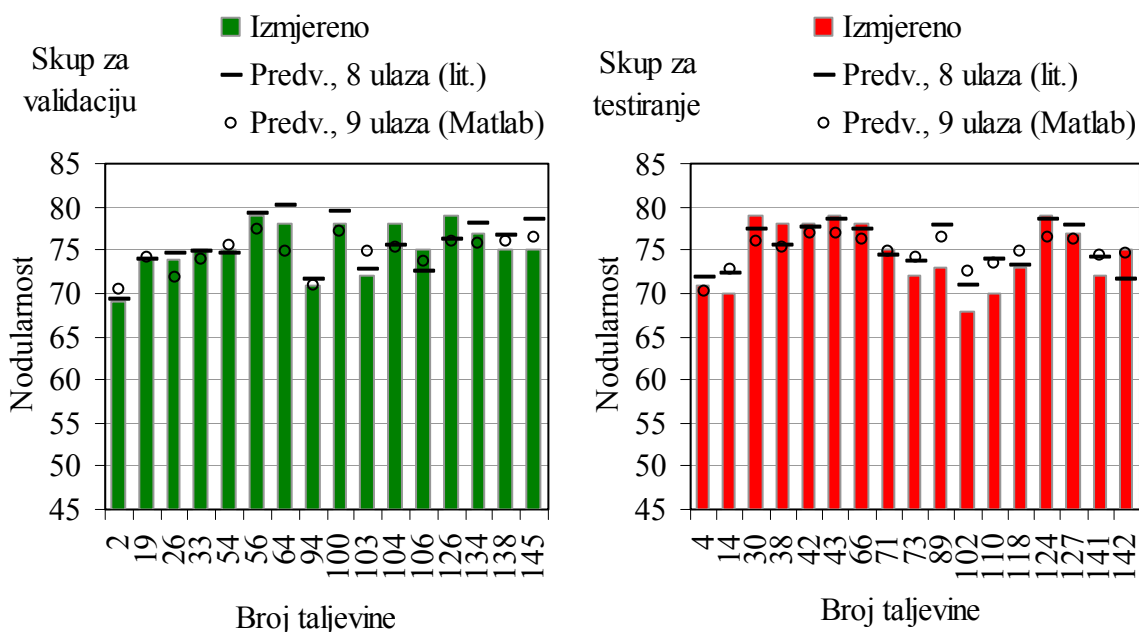
Slika 4.3. Korelacija između predviđenih i izmjerenih nodularnosti u skupu za testiranje

Tablica 4.2. Pogreške za pojedine ljevoe u skupu za testiranje pri predviđanju nodularnosti

Skup za testiranje; Predviđanje nodularnosti				
Taljevina br.	Izmjereno, d_i	Predviđeno, O_i	$ d_i - O_i $	$ d_i - O_i /$ $d_i, \%$
4	71	71,75	0,75	1,05%
14	70	72,32	2,32	3,32%
30	79	77,28	1,72	2,18%
38	78	75,58	2,42	3,11%
42	78	77,60	0,40	0,51%
43	79	78,58	0,42	0,53%
66	78	77,38	0,62	0,80%
71	75	74,38	0,62	0,83%
73	72	73,75	1,75	2,43%
89	73	77,92	4,92	6,75%
102	68	70,90	2,90	4,26%
110	70	73,84	3,84	5,48%
118	73	73,22	0,22	0,29%
124	79	78,49	0,51	0,65%
127	77	77,79	0,79	1,02%
141	72	74,17	2,17	3,02%
142	75	71,58	3,42	4,56%
		Min.	0,22	0,29%
		Maks.	4,92	6,75%
		Sr. vr.	1,75	2,40%
		St. dev.	1,40	1,96%



Slika 4.4. Izmjerene i predviđene nodularnosti iz skupa za učenje




Slika 4.5. Izmjerene i predviđene nodularnosti iz skupova za validaciju i testiranje


4.1.2. Predviđanje broja nodula po jedinici površine

Sljedeći mikrostrukturni parametar koji je predviđan pomoću umjetne neuronske mreže je broj nodula po mm^2 . Ulazne varijable za neuronsku mrežu bile su sljedeći toplinski parametri: likvidus, \mathcal{G}_L , temperatura eutektičkog pothlađenja, \mathcal{G}_{EP} , rekalescencija, \mathcal{G}_R , solidus, \mathcal{G}_S , grafitni faktor 1, GRF1, grafitni faktor 2, GRF2, brzina hlađenja na solidusu, $\frac{d\mathcal{G}_S}{dt}$ i temperatura eutektoidne pretvorbe, \mathcal{G}_{EID} , prema teorijskim razmatranjima. U izlaznom je sloju neurona bila linearna aktivacijska funkcija, a u skrivenom sloju bipolarna sigmoidalna funkcija nagiba $\sigma = 2$. U prvoj fazi učenja optimirana je veličina skrivenog sloja neurona. Praćene su promjene nekoliko parametra pogreške: koeficijenta korelacije i determinacije, R i R^2 , normaliziranog korijena srednje kvadratne pogreške, $NRMS$, i srednje relativne pogreške, $\overline{u_{rel}}$, u skupovima za učenje, validaciju i testiranje. Slika 4.6. prikazuje promjene pogrešaka predviđanja nodularnosti pri različitom broju skrivenih neurona. Pri odabiru najpovoljnije strukture neuronske mreže, pogreška u skupu za testiranje je minimizirana. Najniža vrijednost

normaliziranog korijena srednje kvadratne pogreške, $NRMS = 0,5570$, u skupu za testiranje postignuta je kod neuronske mreže s 18 skrivenih neurona, pri čemu su koeficijenti korelacije i determinacije iznosili $R = 0,8247$ i $R^2 = 0,6802$, a pripadajuća srednja relativna pogreška, $\overline{u_{rel}} = 4,22$ %. U slučaju modela neuronske mreže s 18 skrivenih neurona bilo bi riječ o izrazito složenoj strukturi s vrlo velikim brojem težinskih koeficijenata, njih 181, koje mreža treba tijekom učenja podesiti. Taj broj težinskih koeficijenata znatno je veći od dostupnog broja parova podataka dobivenih u ljevaonici. Ovako složena neuronska mreža nema dovoljno poznatih podataka na kojima bi dobro naučila preslikavati poznate na nepoznate varijable. Stoga je promotrena najpovoljnija građa mreže prema sljedećem kriteriju, kriteriju srednje relativne pogreške. Ona je minimalno iznosila $\overline{u_{rel}} = 4,22$ %, pri čemu su ostali parametri pogreške iznosili: $R = 0,7984$, $R^2 = 0,6375$ i $NRMS = 0,5889$. Te su pogreške postignute pri znatno jednostavnijoj građi neuronske mreže s 5 skrivenih neurona, te je taj model odabran kao optimalan. Prilog 25. prikazuje konačne vrijednosti težinskih koeficijenata skrivenog sloja (\mathbf{W}_1 , \mathbf{b}_1) i izlaznog sloja (\mathbf{W}_2 , \mathbf{b}_2) neuronske mreže za predviđanje broja nodula po jedinici površine na temelju odabranih parametara toplinske analize. Slika 4.7. prikazuje korelaciju između predviđenog i izmjenog broja nodula po jedinici površine u skupu za testiranje, uz pripadajući pravac potpune korelacije, $R = 1$. Tablica 4.3. navodi pojedine predviđene i izmjerene vrijednosti broja nodula po mm^2 i analizu relativne pogreške za pojedine ljevove u skupu za testiranje. Slika 4.8 uspoređuje izmjerene i predviđene brojeve nodula/ mm^2 iz skupa za učenje. Slika 4.9. prikazuje istu usporedbu, ali za ljevove iz skupova za validaciju i za testiranje.



Slika 4.6. Utjecaj broja skrivenih neurona na pogrešku predviđanja broja nodula po jedinici površine



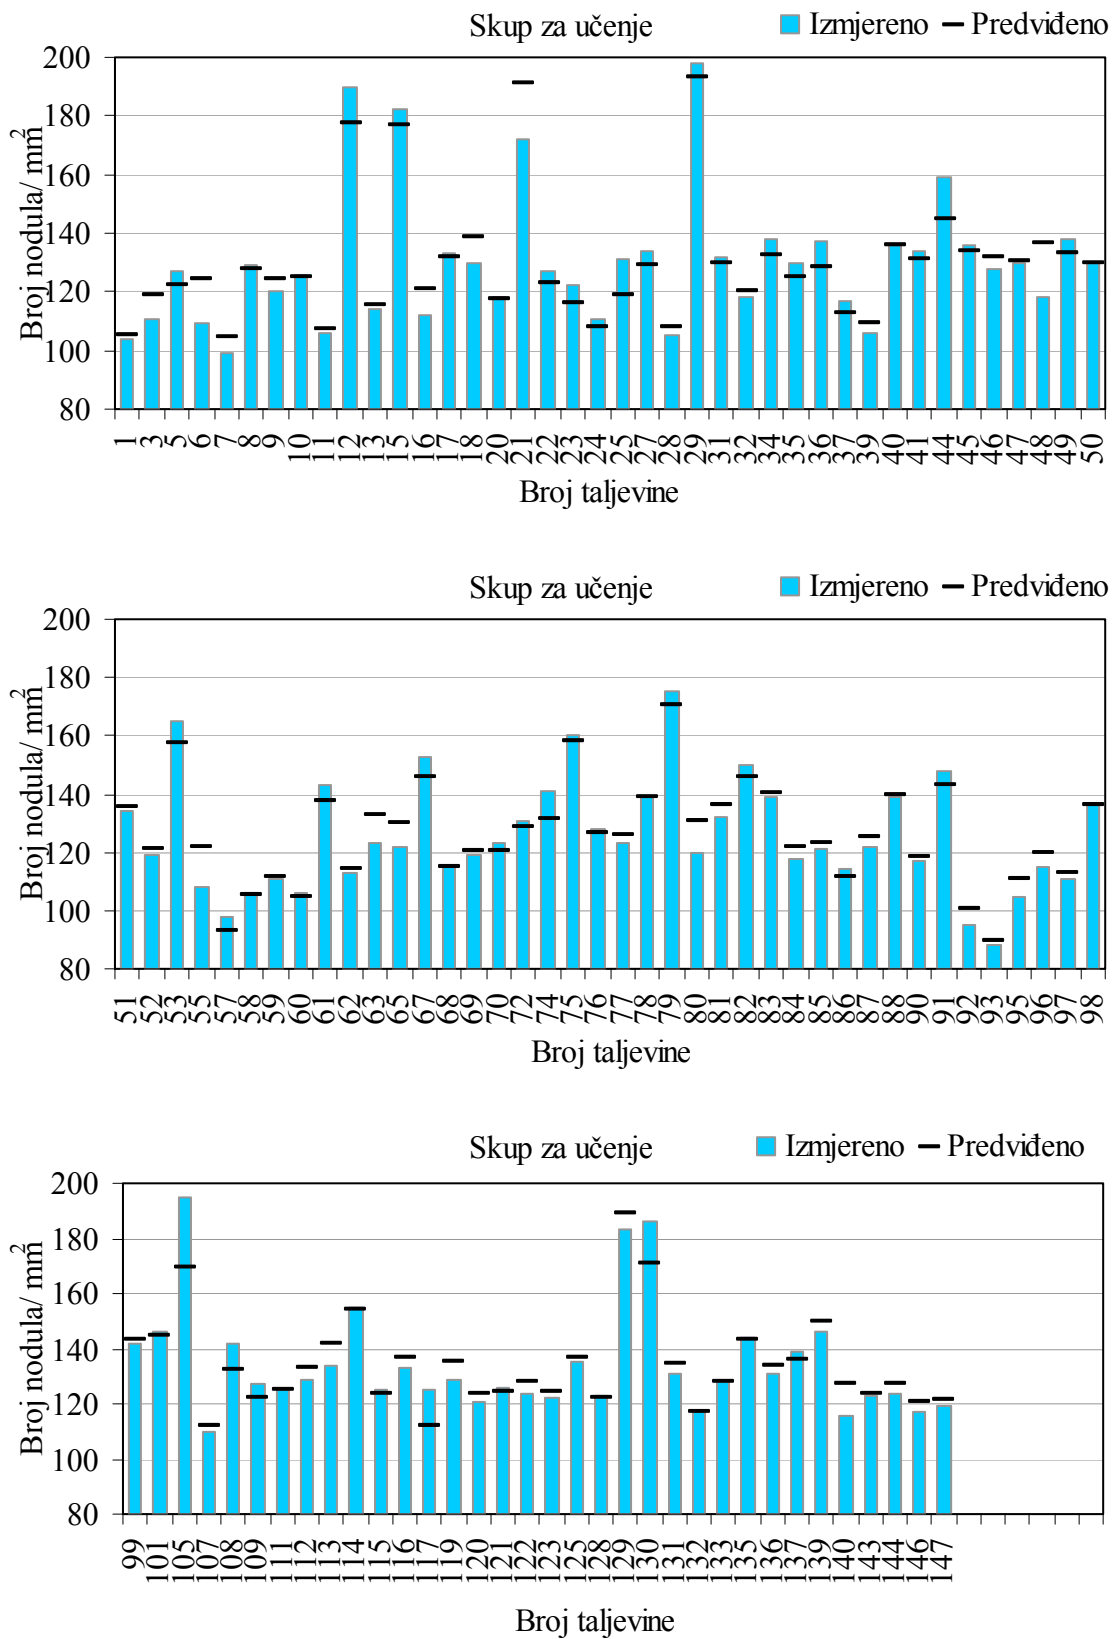
Slika 4.7. Korelacija između predviđenog i izmjereneog broja nodula po jedinici površine u skupu za testiranje

Tablica 4.3. Pogreške za pojedine ljevove u skupu za testiranje pri predviđanju broja nodula po jedinici površine


Skup za testiranje; Predviđanje broja nodula/mm ²				
Taljevina br.	Izmjereno, d_i	Predviđeno ¹⁾ , O_i	$ d_i - O_i $	$ d_i - O_i /$ $d_i, \%$
4	107	106,94	0,06	0,06%
14	108	122,49	14,49	13,42%
30	131	132,57	1,57	1,20%
38	138	132,75	5,25	3,80%
42	143	137,82	5,18	3,62%
43	151	142,81	8,19	5,42%
66	145	139,41	5,59	3,86%
71	127	126,99	0,01	0,01%
73	110	121,41	11,41	10,37%
89	138	140,72	2,72	1,97%
102	110	113,59	3,59	3,26%
110	119	120,85	1,85	1,55%
118	127	127,32	0,32	0,25%
124	143	141,99	1,01	0,71%
127	138	137,17	0,83	0,60%
141	121	123,79	2,79	2,31%
142	142	115,33	26,67	18,78%
		Min.	0,01	0,01%
		Maks.	26,67	18,78%
		Sr. vr.	5,38	4,19%
		St. dev.	6,83	5,24%

¹⁾ Neuronskom mrežom predviđeni broj nodula/ mm² nije zaokružen na cijeli broj kako bi se točnije prikazale pogreške predviđanja

4. REZULTATI MODELIRANJA UMJETNIM NEURONSKIM MREŽAMA



Slika 4.8. Izmjereni i predviđeni broj nodula/ mm² iz skupa za učenje

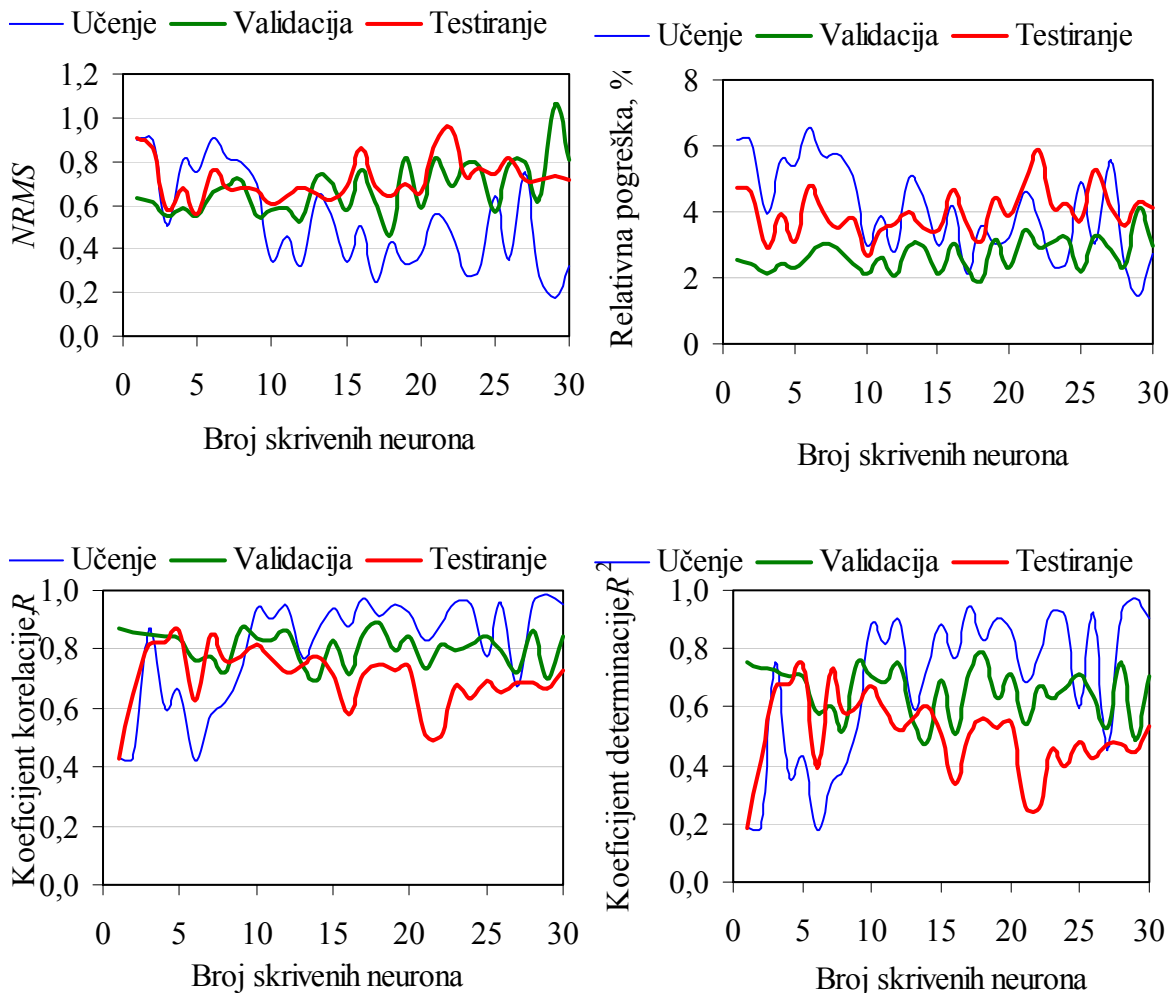
Slika 4.9. Izmjereni i predviđeni broj nodula/ mm² iz skupova za validaciju i testiranje

4.1.3. Predviđanje volumnog udjela ferita u metalnoj osnovi

Obzirom da volumni udjeli ferita i perlita zajedno čine 100 % volumena u mikrostrukturi metalne osnove nodularnog lijeva, udio perlita nije predviđan umjetnom neuronskom mrežom. Toplinski parametri: likvidus, \mathcal{G}_L , temperatura eutektičkog pothlađenja, \mathcal{G}_{EP} , rekalescencija, \mathcal{G}_R , solidus, \mathcal{G}_S , grafitni faktor 1, GRF1, grafitni faktor 2, GRF2, brzina hlađenja na solidusu, $\frac{d\mathcal{G}_S}{dt}$ i temperatura eutektoidne pretvorbe, \mathcal{G}_{EID} , bili su ulazne varijable za neuronsku mrežu, prema teorijskim razmatranjima. Najpovoljniji broj skrivenih neurona u neuronskoj mreži određen je praćenjem pogreške predviđanja udjela ferita u nodularnim ljevovima iz skupa za testiranje. Najniža vrijednost normaliziranog korijena srednje kvadratne pogreške, $NRMS = 0,5564$ očitana je za građu mreže s 5 skrivenih neurona. Pri tom su $NRMS$ -u bili koeficijenti korelacije i determinacije $R = 0,8625$ i $R^2 = 0,74390$, dok je srednja relativna pogreška iznosila $\overline{u_{rel}} = 3,08$ %. Najniža srednja relativna pogreška, $\overline{u_{rel}} = 2,69$ %, postignuta je primjenom neuronske mreže s 10 skrivenih neurona. Kod takve strukture mreže ostali parametri pogreške bili su: $R = 0,8192$, $R^2 = 0,6711$, $NRMS = 0,6014$, no kako se tim modelom

4. REZULTATI MODELIRANJA UMJETNIM NEURONSKIM MREŽAMA

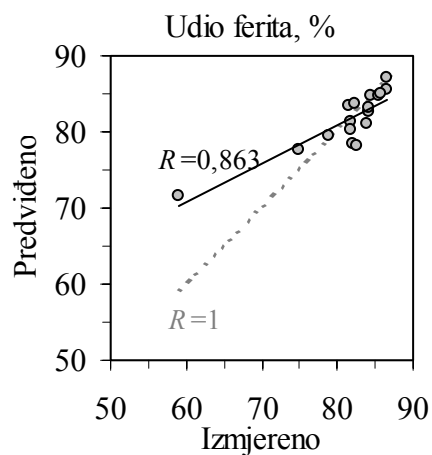
značajno povećava broj težinskih koeficijenata koje mreža treba naučiti, za predviđanje udjela ferita u metalnoj osnovi nodularnog lijeva usvojen je model s 5 skrivenih neurona. Slika 4.10. prikazuje promjene pojedinih parametra pogreške u skupovima za učenje, validaciju i testiranje s promjenom broja skrivenih neurona. Prilog 26. donosi konačne vrijednosti težinskih koeficijenata u skrivenom (\mathbf{W}_1 , \mathbf{b}_1) i u izlaznom sloju (\mathbf{W}_2 , \mathbf{b}_2) neuronske mreže. Tablica 4.4. daje pojedine predviđene i izmjerene vrijednosti volumnog udjela ferita u metalnoj osnovi nodularnog lijeva i analizu relativne pogreške za pojedine ljevove u skupu za testiranje. Slika 4.11. prati korelaciju između predviđenog i izmjerenog volumnog udjela ferita u metalnoj osnovi u skupu za testiranje, uz prikaz pripadajućeg pravca potpune korelacije, $R = 1$.



Slika 4.10. Utjecaj broja skrivenih neurona na pogrešku predviđanja udjela ferita


Tablica 4.4. Pogreške za pojedine ljevove u skupu za testiranje pri predviđanju udjela ferita

Skup za testiranje; Predviđanje udjela ferita, %				
Taljevina br.	Izmjereno, d_i	Predviđeno, O_i	$ d_i - O_i $	$ d_i - O_i /$ $d_i, \%$
4	82,01	78,44	3,57	4,36%
14	74,78	77,73	2,95	3,95%
30	84,22	82,68	1,54	1,83%
38	82,71	78,03	4,68	5,66%
42	84,41	84,86	0,45	0,53%
43	86,62	85,55	1,07	1,24%
66	85,42	84,85	0,57	0,66%
71	83,95	81,10	2,85	3,40%
73	81,85	81,25	0,60	0,73%
89	81,72	80,29	1,43	1,75%
102	79,00	79,56	0,56	0,71%
110	81,57	83,44	1,87	2,29%
118	82,23	83,67	1,44	1,75%
124	86,54	87,07	0,53	0,61%
127	85,64	85,06	0,58	0,67%
141	84,11	83,13	0,98	1,17%
142	59,13	71,54	12,41	20,98%
		Min.	0,45	0,53%
		Maks.	12,41	20,98%
		Sr. vr.	2,24	3,08%
		St. dev.	2,90	4,86%




Slika 4.11. Korelacija između predviđenog i izmjenenog udjela ferita skupu za testiranje

Slika 4.12. usporedno prikazuje izmjerene i neuronskom mrežom previđene volumne udjele ferita za pojedine taljevine iz skupa za učenje. Slika 4.13. prikazuje istovrsnu usporedbu, sada za nodularne ljevove iz skupova za validaciju i testiranje.



Slika 4.12. Izmjereni i predviđeni udjeli ferita iz skupa za učenje



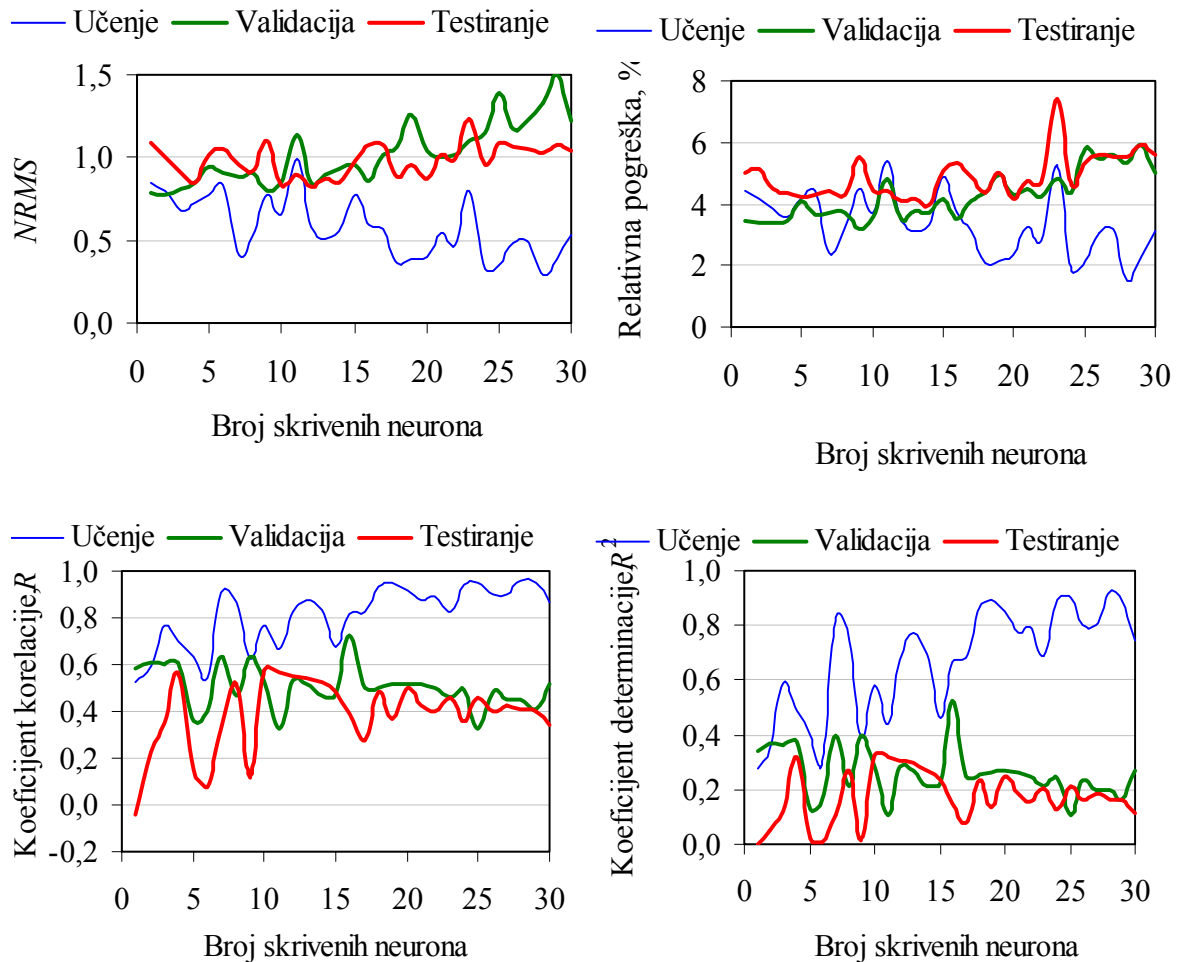
Slika 4.13. Izmjereni i predviđeni udjeli ferita iz skupova za validaciju i testiranje

4.2. Predviđanje mehaničkih svojstava na temelju toplinske analize

4.2.1. Predviđanje vlačne čvrstoće na temelju toplinske analize

Ulazne varijable za predviđanje vlačne čvrstoće umjetnom neuronskom mrežom bili su parametri dobiveni snimanjem krivulje hlađenja: likvidus, ϑ_L , temperatura eutektičkog pothlađenja, ϑ_{EP} , rekalescencija, ϑ_R , solidus, ϑ_S , grafitni faktor 1, GRF1, grafitni faktor 2, GRF2, brzina hlađenja na solidusu, $\frac{d\vartheta_S}{dt}$ i temperatura eutektoidne pretvorbe, ϑ_{EID} , prema teorijskim razmatranjima. Izlazna varijabla neuronske mreže bila je vlačna čvrstoća nodularnog lijeva, R_m . Ulazni i izlazni podaci normirani su u skup $[-1, 1]$, prema izrazu (3.2), sa str. 88. Određena je najpovoljnija struktura mreže praćenjem pogreške u skupu za testiranje pri različitim veličinama skrivenog sloja neurona. Skriveni su neuroni imali bipolarnu sigmoidalnu aktivacijsku funkciju, nagiba $\sigma = 2$, a izlazni neuroni linearnu funkciju. Korišten je algoritam povratnog rasprostiranja pogreške. U cilju bržeg učenja, uz algoritam povratnog rasprostiranja pogreške korištena je i Levenberg – Marquardtova metoda. Slika 4.14. prikazuje promjene parametra pogreške u skupovima za učenje, validaciju i testiranje s promjenom broja neurona u skrivenom sloju. Prema najnižoj vrijednosti normaliziranog korijena srednjeg kvadratnog odstupanja, $NRMS = 0,8207$, postignutoj korištenjem modela mreže s 12 skrivenih neurona, odabrana je konačna, najpovoljnija struktura neuronske mreže. Prilog 27. daje konačne vrijednosti težinskih koeficijenata u skrivenom (\mathbf{W}_1 , \mathbf{b}_1) i u izlaznom sloju (\mathbf{W}_2 , \mathbf{b}_2) neuronske mreže. Pri toj strukturi, srednja relativna pogreška u skupu za testiranje iznosila je $\overline{u_{rel}} = 4,10$ %. Koeficijenti korelacije i determinacije između izmjerenih i predviđenih vrijednosti iznosili su $R = 0,5518$, odnosno $R^2 = 0,3045$. Obzirom da je koeficijent korelacije $R > 0,5$, korelacija između izmjerenih i predviđenih vlačnih čvrstoća nodularnog lijeva je srednje jakosti. Slika 4.15. prikazuje korelaciju između predviđenih i izmjerenih vlačnih čvrstoća u skupu za testiranje. Na slici su također ucrtani pravci korelacije za predviđene i izmjerene podatke o čvrstoći, te

za slučaj potpune korelacije, $R = 1$. Tablica 4.5. predstavlja analizu vrijednosti pogrešaka pri predviđanju vlačne čvrstoće kod pojedinih ljevova iz skupa za testiranje neuronske mreže. Slika 4.16. usporedno prikazuje sve izmjerene i predviđene vlačne čvrstoće iz skupa za učenje. Slika 4.17. predstavlja istu usporedbu, ali za podatke iz skupa za validaciju i za testiranje.




Slika 4.14. Utjecaj broja skrivenih neurona na pogrešku predviđanja vlačne čvrstoće


Tablica 4.5. Pogreške za pojedine ljevove u skupu za testiranje pri predviđanju vlačne čvrstoće

Skup za testiranje; Predviđanje vlačne čvrstoće, R_m , N/mm^2				
Taljevina br.	Izmjereno, d_i	Predviđeno ¹⁾ , O_i	$ d_i - O_i $	$ d_i - O_i /$ $d_i, \%$
4	512	524,21	12,21	2,38%
14	549	554,29	5,29	0,96%
30	517	501,30	15,70	3,04%
38	493	527,52	34,52	7,00%
42	488	509,91	21,91	4,49%
43	490	495,85	5,85	1,19%
66	507	481,94	25,06	4,94%
71	499	492,48	6,52	1,31%
73	517	503,40	13,60	2,63%
89	496	508,28	12,28	2,48%
102	518	520,78	2,78	0,54%
110	436	511,41	75,41	17,30%
118	488	503,44	15,44	3,16%
124	461	469,30	8,30	1,80%
127	503	494,54	8,46	1,68%
141	478	496,75	18,75	3,92%
142	596	531,68	64,32	10,79%
		Min.	2,78	0,54%
		Maks.	75,41	17,30%
		Sr. vr.	20,38	4,10%
		St. dev.	20,37	4,24%


¹⁾ Neuronskom mrežom predviđena vlačna čvrstoća nije zaokružena na cijeli broj kako bi se točnije odredila pogreška predviđanja



Slika 4.15. Korelacija između predviđenih i izmjerenih vlačnih čvrstoća u skupu za testiranje



Slika 4.16. Izmjerene i predviđene vlačne čvrstoće iz skupa za učenje

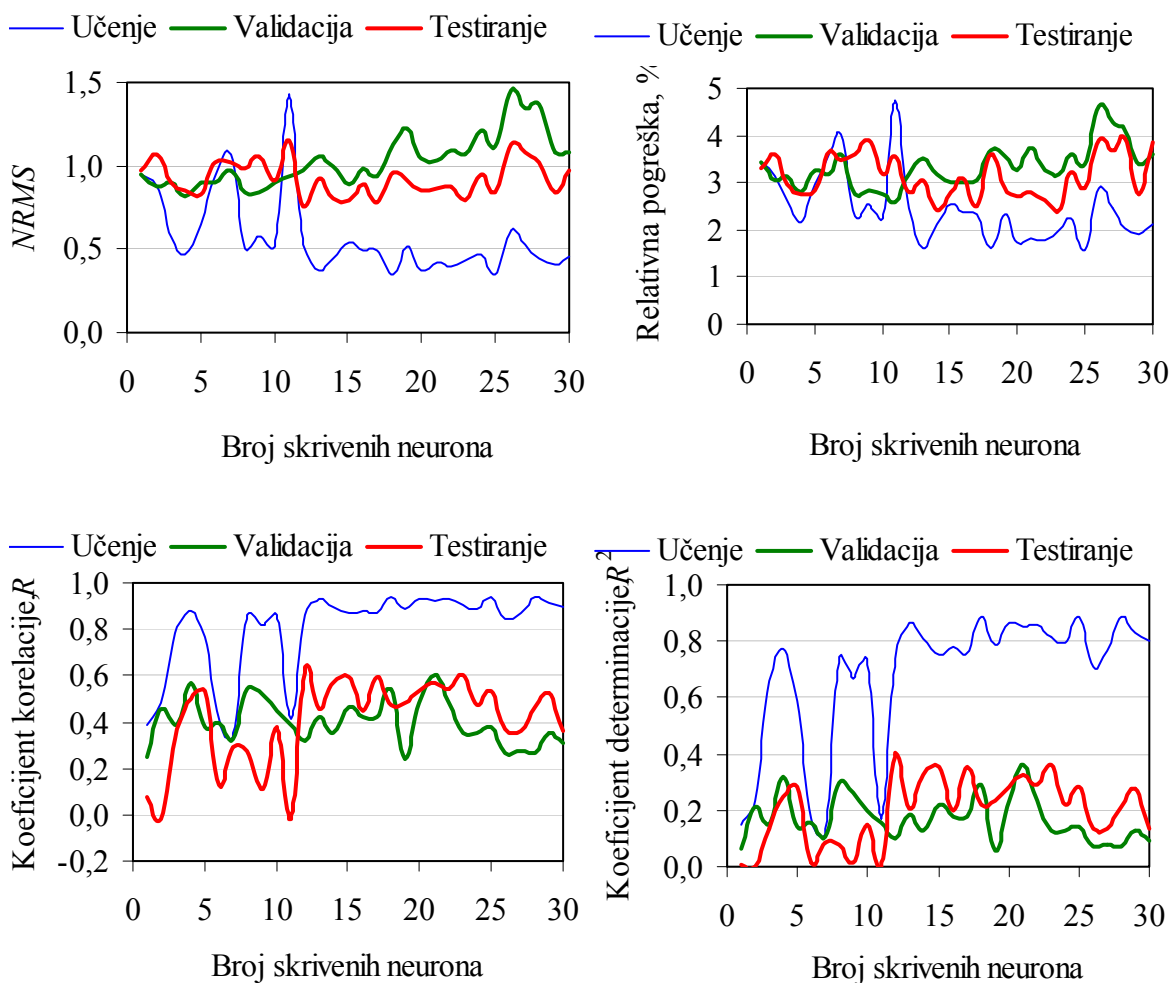


Slika 4.17. Izmjerene i predviđene vlačne čvrstoće iz skupova za validaciju i testiranje


4.2.2. Predviđanje konvencionalne granice razvlačenja na temelju toplinske analize

U ovom slučaju predviđanja svojstava nodularnog lijeva, izlazna varijabla neuronske mreže bila je konvencionalna granica razvlačenja, $R_{p0.2}$. Ulazne su varijable bili sljedeći parametri s krivulje hlađenja taljevina nodularnog lijeva: likvidus, ϑ_L , temperatura eutektičkog pothlađenja, ϑ_{EP} , rekalescencija, ϑ_R , solidus, ϑ_S , grafitni faktor 1, GRF1, grafitni faktor 2, GRF2, brzina hlađenja na solidusu, $\frac{d\vartheta_S}{dt}$ i temperatura eutektoidne pretvorbe, ϑ_{EID} , kako je opisano u teorijskim razmatranjima. Pomoću izraza (3.2) normirani su svi ulazni i izlazni podaci u skup [-1, 1]. Najpovoljnija struktura mreže definirana je analizom parametara pogreške u skupu za testiranje pri različitom broju skrivenih neurona. Skriveni su neuroni aktivirani bipolarnim sigmoidalnim aktivacijskim funkcijama, nagiba $\sigma = 2$, dok su izlazni neuroni aktivirani linearnim funkcijama. Neuronska mreža učila je algoritmom povratnog rasprostiranja pogreške, uz upotrebu Levenberg – Marquardtove metode. Slika 4.18. prikazuje kako se mijenjaju pojedini parametri pogreške u skupovima za učenje, validaciju i testiranje s promjenom broja neurona u skrivenom sloju. Kako je pogreška u skupu za testiranje najznačajnija

pri procjeni uspješnosti generalizacije neuronske mreže, prema parametrima pogreške u tom skupu odabrana je najpovoljnija građa mreže. Najniža je vrijednost normaliziranog korijena srednje kvadratne pogreške $NRMS = 0,7615$ postignuta modelom mreže s 12 skrivenih neurona, te je taj model mreže konačno usvojen za predviđanje konvencionalne granice razvlačenja. Prilog 28. donosi konačne vrijednosti težinskih koeficijenata u skrivenom ($\mathbf{W}_1, \mathbf{b}_1$) i u izlaznom sloju ($\mathbf{W}_2, \mathbf{b}_2$) neuronske mreže. Pri odabranom broju skrivenih neurona postignute su i najviše vrijednosti koeficijenata korelacije i determinacije, $R = 0,6314$ i $R^2 = 0,3986$. Kako je koeficijent korelacije između izmjerenih i predviđenih konvencionalnih granica razvlačenja $R > 0,5$, njihova je korelacija srednje jakosti. Pritom je srednja relativna pogreška u skupu za testiranje iznosila $\overline{u_{rel}} = 2,81$ %. Najniža srednja relativna pogreška u skupu za testiranje, $\overline{u_{rel}} = 2,41$ %, pojavila se kod mreže s 14 skrivenih neurona. Slika 4.19. daje korelaciju između predviđenih i izmjerenih konvencionalnih granica razvlačenja u skupu za testiranje. Na slici su ucrtani i pravci korelacije za predviđene i izmjerene podatke o granici razvlačenja, te za potpunu korelaciju, $R = 1$. Tablica 4.6. analizira vrijednosti pogrešaka pri predviđanju konvencionalne granice razvlačenja kod pojedinih ljevova iz skupa za testiranje neuronske mreže. Slika 4.20. uspoređuje sve izmjerene i predviđene konvencionalne granice razvlačenja iz skupa za učenje. Slika 4.21. uspoređuje iste podatke, ali sada iz skupova za validaciju i za testiranje.



Slika 4.18. Utjecaj broja skrivenih neurona na pogrešku predviđanja konvencionalne granice razvlačenja




Slika 4.19. Korelacija između predviđenih i izmjerenih konvencionalnih granica razvlačenja u skupu za testiranje

Tablica 4.6. Pogreške za pojedine ljevoe u skupu za testiranje pri predviđanju konvencionalne granice razvlačenja


Skup za testiranje; Predviđanje konvencionalne granice razvlačenja, $R_{p0,2}$, N/mm ²				
Taljevina br.	Izmjereno, d_i	Predviđeno ¹⁾ , O_i	$ d_i - O_i $	$ d_i - O_i /$ d_i , %
4	369	373,76	4,76	1,29%
14	382	372,17	9,83	2,57%
30	357	361,87	4,87	1,36%
38	350	361,75	11,75	3,36%
42	357	360,97	3,97	1,11%
43	350	358,54	8,54	2,44%
66	369	346,03	22,97	6,22%
71	369	358,38	10,62	2,88%
73	369	362,79	6,21	1,68%
89	357	363,10	6,10	1,71%
102	369	375,71	6,71	1,82%
110	357	363,86	6,86	1,92%
118	350	362,84	12,84	3,67%
124	338	348,88	10,88	3,22%
127	350	358,09	8,09	2,31%
141	350	359,54	9,54	2,73%
142	408	377,29	30,71	7,53%
		Min.	3,97	1,11%
		Maks.	30,71	7,53%
		Sr. vr.	10,31	2,81%
		St. dev.	6,87	1,72%

¹⁾ Neuronskom mrežom predviđena konvencionalna granica razvlačenja nije zaokružena na cijeli broj kako bi se točnije odredila pogreška predviđanja

4. REZULTATI MODELIRANJA UMJETNIM NEURONSKIM MREŽAMA



Slika 4.20. Izmjerene i predviđene konvencionalne granice razvlačenja iz skupa za učenje




Slika 4.21. Izmjerene i predviđene konvencionalne granice razvlačenja iz skupova za validaciju i testiranje

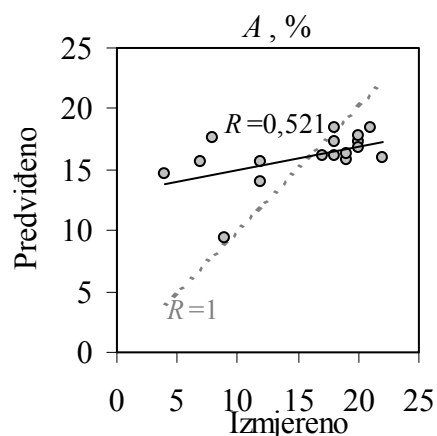
4.2.3. Predviđanje istezljivosti na temelju toplinske analize

Dio toplinskih parametara očitanih snimanjem krivulja hlađenja taljevina nodularnog lijeva činio je ulazne varijable za umjetnu neuronsku mrežu. Odabrani su sljedeći parametri: likvidus, ϑ_L , temperatura eutektičkog pothlađenja, ϑ_{EP} , rekalescencija, ϑ_R , solidus, ϑ_S , grafitni faktor 1, GRF1, grafitni faktor 2, GRF2, brzina hlađenja na solidusu, $\frac{d\vartheta_S}{dt}$ i temperatura eutektoidne pretvorbe, ϑ_{EID} , prema teorijskim razmatranjima. Izlazna varijabla neuronske mreže bila je istezljivost na kratkoj epruveti, A . Izrazom (3.2) svi su ulazni i izlazni podaci normirani u skup $[-1, 1]$. Optimalna struktura mreže odabrana je pregledom parametara pogreške u skupu za testiranje pri različitoj veličini skrivenog sloja neurona. Neuroni u skrivenom sloju aktivirani su bipolarnim sigmoidalnim aktivacijskim funkcijama, nagiba $\sigma = 2$. Linearnim funkcijama aktivirani su izlazni neuroni. Neuronska mreža je učila pomoću algoritma povratnog rasprostiranja pogreške, pri čemu je korištena i Levenberg – Marquardtova metoda brze konvergencije. Slika 4.22. prati promjene pojedinih parametara pogreške u skupovima za učenje, validaciju i testiranje s promjenom broja neurona u skrivenom

sloju. Kod ovog je problema predviđanja mehaničkih svojstava utvrđeno da je najpovoljniji broj neurona u skrivenome sloju 6. Najniža se vrijednost normaliziranog korijena srednjeg kvadratnog odstupanja, $NRMS = 0,8298$, pojavila kod građe mreže s 20 skrivenih neurona, no takav model ima vrlo veliki broj težinskih parametara koje bi mreža trebala naučiti. Slično je s neuronskom mrežom koja bi imala 17 skrivenih neurona, a nešto veću pogrešku, $NRMS = 0,8385$. Sljedeći je najmanji $NRMS = 0,8458$, a postiže se neuronskom mrežom koja ima 6 skrivenih neurona. Izborom takve građe sniženi su koeficijenti korelacije i determinacije s $R = 0,6271$ i $R^2 = 0,3932$ za slučaj 20 skrivenih neurona na $R = 0,5211$ i $R^2 = 0,2715$, za slučaj 6 skrivenih neurona. Srednja relativna pogreška porasla je s $\overline{u_{rel}} = 40,47\%$ na $\overline{u_{rel}} = 40,80\%$. Prilog 29. prikazuje konačne vrijednosti težinskih koeficijenata u skrivenom ($\mathbf{W}_1, \mathbf{b}_1$) i u izlaznom sloju ($\mathbf{W}_2, \mathbf{b}_2$) neuronske mreže. Slika 4.23. predstavlja korelaciju između predviđenih i izmjerenih istezljivosti u skupu za testiranje. Na slici su također ucrtani pravac korelacije za predviđene i izmjerene istezljivosti, te za slučaj njihove potpune korelacije, gdje je $R = 1$. Tablica 4.7. donosi vrijednosti pogrešaka pri predviđanju istezljivosti kod pojedinih ljevova iz skupa za testiranje neuronske mreže. Slika 4.24. usporedno prikazuje izmjerene i predviđene istezljivosti za svaku taljevinu iz skupa za učenje. Slika 4.25. uspoređuje izmjerene istezljivosti i one dobivene predviđanjem neuronskom mrežom za taljevine iz skupova za validaciju i testiranje.



Slika 4.22. Utjecaj broja skrivenih neurona na pogrešku predviđanja istezljivosti




Slika 4.23. Korelacija između predviđenih i izmjerenih istezljivosti u skupu za testiranje

4. REZULTATI MODELIRANJA UMJETNIM NEURONSKIM MREŽAMA

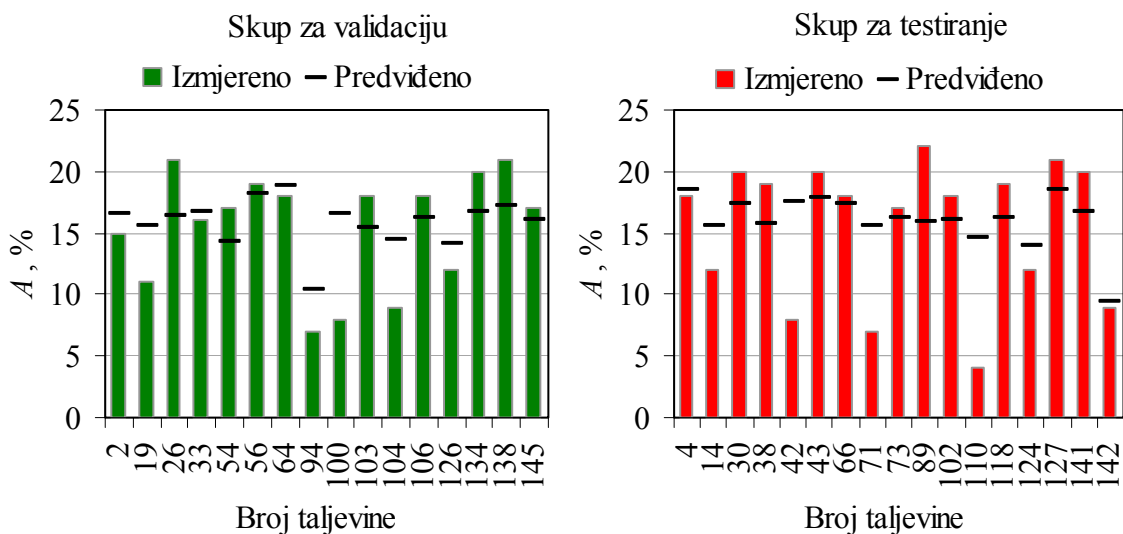
Tablica 4.7. Pogreške za pojedine ljevoe u skupu za testiranje pri predviđanju istezljivosti

Skup za testiranje; Predviđanje istezljivosti, A , %				
Taljevina br.	Izmjereno, d_i	Predviđeno ¹⁾ , O_i	$ d_i - O_i $	$ d_i - O_i /$ d_i , %
4	18	18,45	0,45	2,51%
14	12	15,65	3,65	30,43%
30	20	17,35	2,65	13,27%
38	19	15,80	3,20	16,86%
42	8	17,60	9,60	119,95%
43	20	17,81	2,19	10,95%
66	18	17,34	0,66	3,65%
71	7	15,61	8,61	123,04%
73	17	16,18	0,82	4,80%
89	22	15,96	6,05	27,48%
102	18	16,10	1,90	10,56%
110	4	14,60	10,60	264,90%
118	19	16,25	2,75	14,47%
124	12	14,04	2,04	16,96%
127	21	18,45	2,56	12,17%
141	20	16,70	3,31	16,53%
142	9	9,45	0,45	5,01%
		Min.	0,45	2,51%
		Maks.	10,60	264,90%
		Sr. vr.	3,62	40,80%
		St. dev.	3,19	68,36%

¹⁾ Neuronskom mrežom predviđena istezljivost nije zaokružena na cijeli broj kako bi se točnije odredila pogreška predviđanja



Slika 4.24. Izmjerene i predviđene istezljivosti iz skupa za učenje

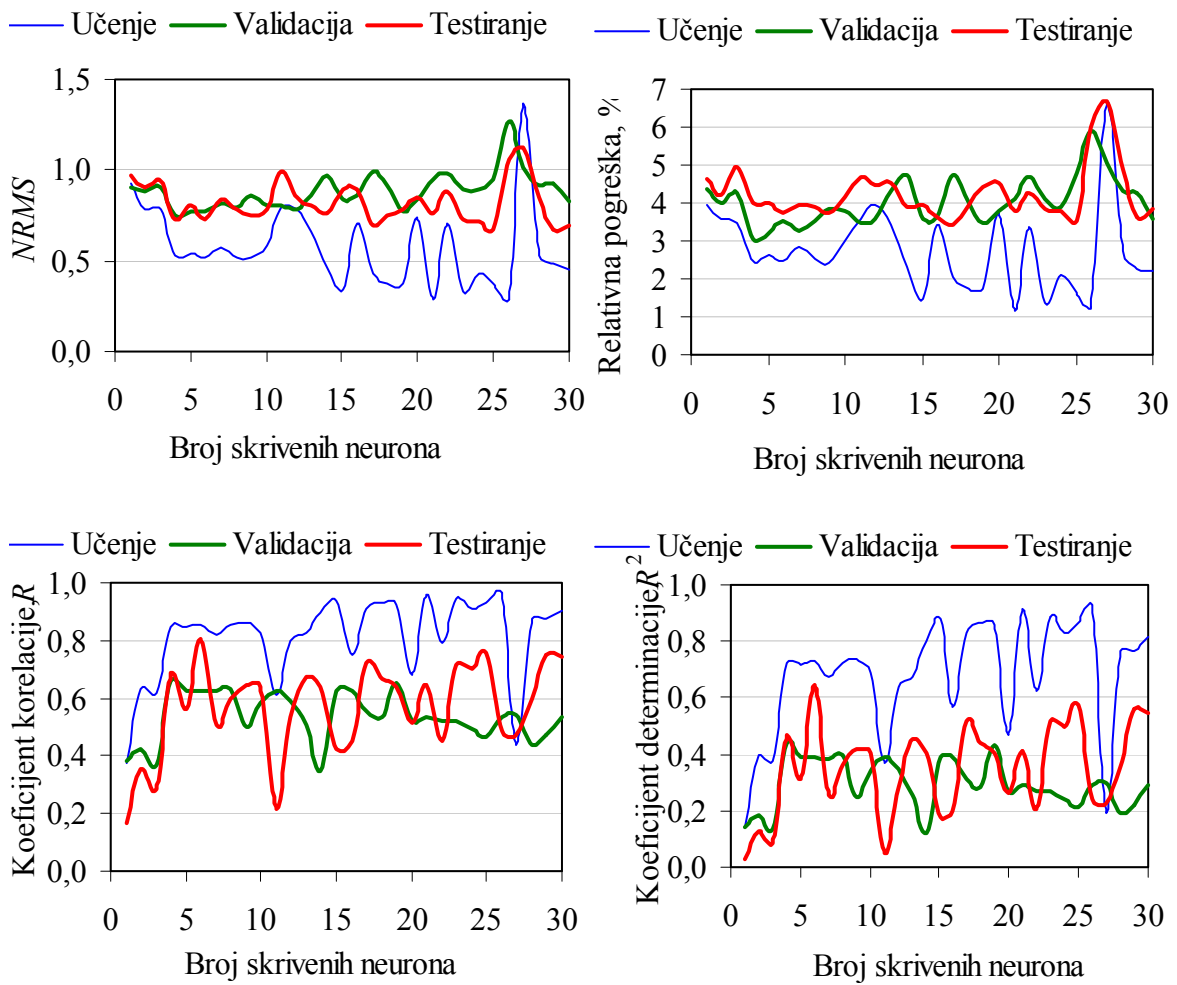


Slika 4.25. Izmjerene i predviđene istezljivosti iz skupova za validaciju i testiranje


4.2.4. Predviđanje tvrdoće na temelju toplinske analize

Tvrdoća po Brinellu je bila posljednje mehaničko svojstvo predviđano umjetnom neuronskom mrežom na temelju podataka dobivenih toplinskom analizom. Dakle, izlazna je varijabla neuronske mreže bila tvrdoća, HB , dok su za ulazne varijable odabrani sljedeći parametri dobiveni snimanjem krivulja hlađenja pojedinih taljevina nodularnog lijeva: likvidus, \mathcal{G}_L , temperatura eutektičkog pothlađenja, \mathcal{G}_{EP} , rekalescencija, \mathcal{G}_R , solidus, \mathcal{G}_S , grafitni faktor 1, GRF1, grafitni faktor 2, GRF2, brzina hlađenja na solidusu, $\frac{d\mathcal{G}_S}{dt}$ i temperatura eutektoidne pretvorbe, \mathcal{G}_{EID} , prema teorijskim razmatranjima. U skup $[-1, 1]$ normirani su svi ulazni i izlazni podaci, prema izrazu (3.2). Optimalna građa neuronske mreže definirana je analizom pojedinih parametara pogreške u skupu za testiranje, pri promjeni broja neurona u skrivenom sloju mreže. Bipolarne sigmoidalne aktivacijske funkcije aktivirale su skrivene neurone, uz nagib tih funkcija postavljen na $\sigma = 2$. Izlazni su neuroni aktivirani linearnim funkcijama. Algoritam povratnog rasprostiranja pogreške korišten je pri učenju neuronske mreže. U cilju brže konvergencije, upotrijebljena je Levenberg – Marquardtova metoda. Slika 4.26. predstavlja promjene pojedinih parametara pogreške po skupovima za učenje,

validaciju i testiranje uz promjenu broja neurona u skrivenom sloju. Obzirom da je pri procjeni uspješnosti generalizacije neuronske mreže najznačajnija pogreška u skupu za testiranje, prema parametrima pogreške u tom skupu odabrana je najpovoljnija građa mreže. Najniža vrijednost normaliziranog korijena srednje kvadratne pogreške, $NRMS = 0,6693$, izračunata je iz odziva neuronske mreže koja je imala 25 skrivenih neurona. Pri tom su koeficijenti korelacije i determinacije iznosili $R = 0,7584$ i $R^2 = 0,5751$, dok je srednja relativna pogreška bila $\overline{u_{rel}} = 3,53 \%$. Najmanju srednju relativnu pogrešku, $\overline{u_{rel}} = 3,44 \%$, imala je neuronska mreža s 17 skrivenih neurona. S druge strane, po kriteriju najviših vrijednosti koeficijenata korelacije i determinacije, za zadani je problem optimalna građa mreže sa samo 6 skrivenih neurona. Kod te su građe koeficijenti korelacije i determinacije iznosili $R = 0,8049$, odnosno $R^2 = 0,6479$. Srednja relativna pogreška u skupu za testiranje kod takve je mreže iznosila $\overline{u_{rel}} = 3,72 \%$. Prilog 30. prikazuje težinske koeficijente usvojenog modela neuronske mreže sa 6 skrivenih neurona. Slika 4.27. predložuje korelaciju između predviđenih i izmjerenih tvrdoća u skupu za testiranje. Na slici su prikazani i pravac korelacije između predviđenih i izmjerenih podataka, te pravac potpune korelacije, $R = 1$. Tablica 4.8. donosi pojedine vrijednosti pogrešaka pri predviđanju tvrdoće pojedinih ljevova iz skupa za testiranje neuronske mreže. Slika 4.28. usporedno daje izmjerene i predviđene tvrdoće za svaki nodularni lijev iz skupa za učenje. Slika 4.29. na isti način predstavlja razlike u izmjerenim i predviđenim tvrdoćama pojedinog nodularnog lijeva iz skupova za validaciju i testiranje.



Slika 4.26. Utjecaj broja skrivenih neurona na pogrešku predviđanja tvrdoće




Slika 4.27. Korelacija između predviđenih i izmjerenih tvrdoća u skupu za testiranje

Tablica 4.8. Pogreške za pojedine ljevove u skupu za testiranje pri predviđanju tvrdoće


Skup za testiranje; Predviđanje tvrdoće, <i>HB</i>				
Taljevina br.	Izmjereno, d_i	Predviđeno ¹⁾ , O_i	$ d_i - O_i $	$ d_i - O_i /$ $d_i, \%$
4	165	165,79	0,79	0,48%
14	174	168,60	5,40	3,10%
30	163	162,74	0,26	0,16%
38	159	166,31	7,31	4,60%
42	159	162,78	3,78	2,38%
43	152	158,94	6,94	4,57%
66	165	158,80	6,20	3,76%
71	170	161,80	8,20	4,82%
73	159	161,55	2,55	1,60%
89	156	162,86	6,86	4,40%
102	170	168,54	1,46	0,86%
110	167	163,83	3,17	1,90%
118	152	161,74	9,74	6,41%
124	149	158,57	9,57	6,42%
127	159	159,60	0,60	0,38%
141	154	160,50	6,50	4,22%
142	199	172,83	26,17	13,15%
		Min.	0,26	0,16%
		Maks.	26,17	13,15%
		Sr. vr.	6,21	3,72%
		St. dev.	6,00	3,16%

¹⁾ Neuronskom mrežom predviđena tvrdoća po Brinellu nije zaokružena na cijeli broj kako bi se točnije odredila pogreška predviđanja

4. REZULTATI MODELIRANJA UMJETNIM NEURONSKIM MREŽAMA



Slika 4.28. Izmjerene i predviđene tvrdoće iz skupa za učenje



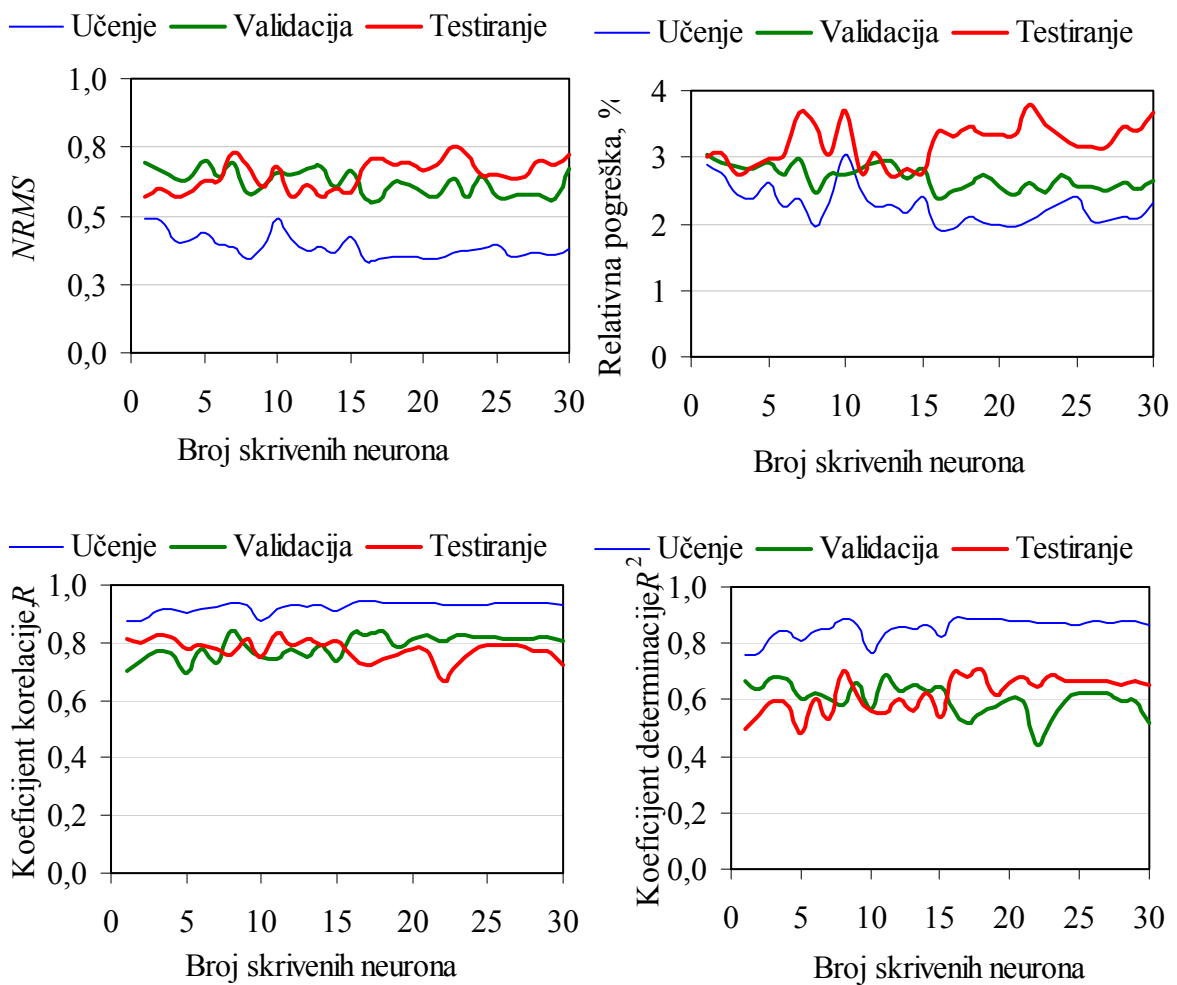
Slika 4.29. Izmjerene i predviđene tvrdoće iz skupova za validaciju i testiranje

4.2.5. Predviđanje vlačne čvrstoće na temelju mikrostrukture

Kako je vlačna čvrstoća nodularnog lijeva povezana s njegovom mikrostrukturom, ispitana je mogućnost predviđanja tog svojstva na temelju izmjerenih parametara mikrostrukture. Izlazna je varijabla neuronske mreže bila vlačna čvrstoća, R_m , dok su ulazne varijable bili nodularnost, broj nodula/mm² i udio ferita. Prema jednadžbi (3.2) normirani su ulazni i izlazni podaci u skup [-1, 1]. Optimalna veličina skrivenog sloja neuronske mreže definirana je analizom parametara pogreške u skupu za testiranje. Skriveni neuroni imali su bipolarne sigmoidalne aktivacijske funkcije nagiba $\sigma = 2$. Izlazni su neuroni aktivirani linearnim funkcijama. Pri učenju neuronske mreže korišten je algoritam povratnog rasprostiranja pogreške. U cilju brže konvergencije, upotrijebljena je Levenberg – Marquardtova metoda. Slika 4.30. prikazuje vrijednosti parametara pogreške u skupovima za učenje, validaciju i testiranje pri promjeni broja skrivenih neurona. Najniži $NRMS = 0,5659$ u skupu za testiranje pojavljuje se kod građe mreže sa samo tri skrivena neurona, pri čemu su $R = 0,8271$ i $R^2 = 0,6841$, te $\overline{u_{rel}} = 2,75\%$. Prilog 31. prikazuje težinske koeficijente modela neuronske mreže s tri skrivena neurona za predviđanje vlačne čvrstoće na temelju tri mikrostrukturna parametra. Slika 4.31. prikazuje korelaciju između predviđenih i izmjerenih vlačnih čvrstoća u skupu za

testiranje. Osim toga, na slici su prikazani i pravac korelacije između predviđenih i izmjerenih podataka, te pravac potpune korelacije, $R = 1$.

Tablica 4.9. prikazuje pojedine vrijednosti pogrešaka pri predviđanju vlačne čvrstoće na temelju mikrostrukture ljevova iz skupa za testiranje neuronske mreže. Slika 4.32. usporedno daje izmjerene vlačne čvrstoće i čvrstoće predviđene na temelju mikrostrukture za svaki nodularni lijev iz skupa za učenje. Slika 4.33. prikazuje razlike između izmjerenih i predviđenim vlačnih čvrstoća pojedinih taljevina nodularnog lijeva iz skupova za validaciju i testiranje.




Slika 4.30. Utjecaj broja skrivenih neurona na pogrešku predviđanja vlačne čvrstoće na temelju mikrostrukture


Tablica 4.9. Pogreške za pojedine ljevoe u skupu za testiranje pri predviđanju vlačne čvrstoće na temelju mikrostrukture

Skup za testiranje; Predviđanje vlačne čvrstoće, R_m , N/mm^2 , na temelju mikrostrukture				
Taljevina br.	Izmjereno, d_i	Predviđeno ¹⁾ , O_i	$ d_i - O_i $	$ d_i - O_i /$ $d_i, \%$
4	512	518,23	6,23	1,22%
14	549	549,61	0,61	0,11%
30	517	502,27	14,73	2,85%
38	493	503,87	10,87	2,20%
42	488	491,65	3,65	0,75%
43	490	486,70	3,30	0,67%
66	507	485,33	21,67	4,27%
71	499	490,99	8,01	1,61%
73	517	518,12	1,12	0,22%
89	496	485,04	10,96	2,21%
102	518	521,60	3,60	0,69%
110	436	499,15	63,15	14,48%
118	488	494,37	6,37	1,31%
124	461	482,71	21,71	4,71%
127	503	477,88	25,12	4,99%
141	478	486,89	8,89	1,86%
142	596	611,37	15,37	2,58%
		Min.	0,61	0,11%
		Maks.	63,15	14,48%
		Sr. vr.	13,26	2,75%
		St. dev.	14,84	3,37%


¹⁾ Neuronskom mrežom predviđena vlačna čvrstoća nije zaokružena na cijeli broj kako bi se točnije odredila pogreška predviđanja



Slika 4.31. Korelacija između izmjerenih vlačnih čvrstoća i čvrstoća predviđenih na temelju mikrostrukture u skupu za testiranje



Slika 4.32. Izmjerene vlačne čvrstoće i predviđene na temelju mikrostrukture iz skupa za učenje



Slika 4.33. Izmjerene vlačne čvrstoće i predviđene na temelju mikrostrukture iz skupova za validaciju i testiranje

5. RASPRAVA

Kako bi se modelirala struktura i svojstva nodularnog lijeva neuronskim mrežama, što je bio cilj rada, ispitana su različita svojstva 147 taljevina nodularnog lijeva. Tijekom skrućivanja snimane su krivulje hlađenja, te je registriran 21 karakterističan toplinski parametar. Tri su krivulje snimljene netočno te taljevine nisu dalje razmatrane. Spektralnom analizom određen je kemijski sastav taljevina. Od svake je taljevine odljevena Y–proba, iz koje su izuzeti uzorci na kojima je ispitana vlačna čvrstoća, konvencionalna granica razvlačenja, istežljivost i tvrdoća. Konačno, na tim je uzorcima ispitana i mikrostruktura, te je određena nodularnost i broj nodula po jedinici površine, te volumni udio ferita i perlita u metalnoj osnovi.

Na temelju podataka dobivenih toplinskom analizom trebalo je predvidjeti četiri mehanička svojstva nodularnog lijeva: vlačnu čvrstoću, konvencionalnu granicu razvlačenja, istežljivost i tvrdoću, te tri mikrostrukturna parametra: nodularnost, broj nodula po mm^2 i udio ferita. Broj dostupnih uzoraka taljevina premalen je za predviđanje svih navedenih svojstva i parametara sa samo jednom neuronskom mrežom. Nadalje, rasipanje svojstava nodularnih ljevova je bilo izrazito nejednoliko, što je sa stajališta uspješnog učenja neuronske mreže nepovoljno. Iz tih je razloga za svako svojstvo, odnosno parametar nodularnog lijeva oblikovana posebna neuronska mreža. Dakle, svaka neuronska mreža imala je po jedan izlaz.

Zatim je bilo potrebno odrediti najpovoljniju kombinaciju ulaznih varijabli za neuronsku mrežu. Jedan je model postavljen prema saznanjima iz literature, gdje se na temelju fizikalne pozadine procesa skrućivanja utvrđuje da je za definiranje broja nodula i njihovog oblika relevantno sljedećih 7 parametara dobivenih toplinskom analizom taljevina nodularnog lijeva: likvidus, \mathcal{G}_L , temperatura eutektičkog pothlađenja, \mathcal{G}_{EP} , rekalescencija, \mathcal{G}_R , solidus, \mathcal{G}_S , grafitni faktor 1, GRF1, grafitni faktor 2, GRF2, i brzina hlađenja na solidusu, $\frac{d\mathcal{G}_S}{dt}$. Nadalje, kao relevantan parametar za predviđanje mikrostrukture uključen je i osmi toplinski parametar: temperatura eutektoidne pretvorbe, \mathcal{G}_{EID} . Na strukturu metalne osnove, tj. na udio ferita i perlita

utječe temperatura eutektoidne pretvorbe, \mathcal{G}_{EID} , °C. Stoga su ovakvi skupovi sa 7, odnosno s 8 ulaznih varijabli upotrijebljeni za modeliranje neuronskom mrežom. Osim opisana dva načina određivanja ulaznih varijabli za neuronsku mrežu, načinjena je i analiza glavnih komponenata toplinske analize na dva načina. Prvim načinom zadana je ukupna količina objašnjive varijance odabranih glavnih komponenata. Drugim je načinom odabira glavnih komponenata bila zadana minimalna razina objašnjive varijance za pojedinu komponentu. Ukupno je promotreno četiri različita načina odabira ulaznih varijabli. Rezultati pogrešaka predviđanja svojstva nodularnosti u skupovima za učenje, validaciju i testiranje pokazali su da je najpovoljnije kao ulazne parametre za neuronsku mrežu upotrijebiti 8 gore pobrojanih toplinskih parametara, dok ostale metode daju veće pogreške, tj. lošiju generalizaciju mreže.

Mogućnost daljeg istraživanja optimalne kombinacije ulaznih varijabli za neuronsku mrežu bila bi pomoću neuronske mreže oblikovane pomoću svih dostupnih ulaznih podataka o npr. toplinskoj analizi. Naučenoj mreži se u tom slučaju pojedini ulazi gase, tj. na njihove se vrijednosti upisuju ničice. Ukoliko pritom ne dođe do smanjenja pogreške, određena se ulazna varijabla može isključiti u sljedećem koraku modeliranja neuronske mreže.

Podjela dostupnih podataka u tri skupa, u skup za učenje, za validaciju i za testiranje, može se izvršiti nasumičnim odabirom, no tim se načinom postavlja vrlo strogi test neuronskoj mreži nakon učenja. Stoga, uzevši u obzir relativno malen dostupan broj različitih taljevina, te njihovo rasipanje po pojedinom svojstvu, odnosno parametru, nužno je bilo odabrati skupove za validaciju i testiranje na način da su u njima taljevine što sličnije onima iz skupa za učenje neuronske mreže. Time je omogućeno da taljevine iz skupa za učenje budu što raznovrsnije, čime se postiže bolje učenje neuronske mreže. Osim toga, na taj se način poboljšava i generalizacija mreže na novim taljevinama, što je glavni kriterij za ocjenu uspješnosti predviđanja neuronskom mrežom. U cilju određivanja sličnosti taljevina računata je Euklidova udaljenost između toplinskih parametara. Sljedeća mogućnost, koja u radu nije ispitana, je određivanje sličnosti između taljevina istodobnim promatranjem sličnosti između parametara toplinske analize i određenih mehaničkih svojstava ili mikrostrukturnih parametara, jednog ili više njih, koja se neuronskom mrežom trebaju predvidjeti.

Najznačajniji parametar pogreške koji opisuje sposobnost generalizacije neke neuronske mreže je normalizirani korijen srednje kvadratne pogreške, *NRMS*. Osim njega, pri različitim modelima istraživanih neuronskih mreža, praćene su i vrijednosti koeficijenta korelacije i determinacije između izmjerenih i neuronskim mrežama predviđenih vrijednosti svojstva, R i R^2 , te srednja vrijednost relativne pogreške, $\overline{u_{rel}}$, %, kako bi se dobio jasniji uvid u razmjer pogreške.

U radu je ispitan najpovoljniji nagib sigmoidalne aktivacijske funkcije, koja je aktivirala neurone skrivenog sloja. Praćenjem parametra pogreške zaključeno je da najpovoljniji nagib $\sigma = 2$.

Ulazni i izlazni podaci normirani su na dva načina: u interval $[-1, 1]$ i na način da je srednja vrijednost normiranih ulaznih ili izlaznih parametra jednaka ničici, a standardna devijacija jednaka jedinici. Utvrđeno je da se nešto manje pogreške postižu normiranjem u skup $[-1, 1]$, te je taj način normiranja podataka korišten pri svim modeliranjima svojstava, odnosno parametara nodularnog lijeva neuronskim mrežama u ovom radu.

Optimalna građa neuronske mreže nije definirana problemom koji se rješava. Najpovoljniji broj neurona u jednom ili više skrivenih slojeva mreže potrebno je bilo ispitati za svako svojstvo, odnosno mikrostrukturni parametar nodularnih ljevova kojeg je neuronska mreža trebala predvidjeti. Praćena je promjena parametara pogreške pri promjenama veličine skrivenog sloja. Tablica 5.1. donosi pregled pojedinih analiziranih parametara pogreške za nodularne ljevove iz skupa za testiranje pri različitim predviđanjima svojstava, odnosno parametara neuronskim mrežama koja su u radu izvedena, te je navedena i odabrana optimalna veličina skrivenog sloja neurona, N_1 .

Prema broju skrivenih neurona može se zaključiti i o složenosti problema koji je predviđan. Što je problem bio složeniji, to je postizana manja točnost predviđanja neuronskom mrežom, a ujedno se povećavala i optimalna veličina skrivenog sloja neurona. Praćenjem podataka u donjoj tablici, zapaža se mali broj neurona kod predviđanja istežljivosti uz istovremenu visoku pogrešku u skupu za testiranje. Valja podsjetiti da je kod modeliranja istežljivosti u radu utvrđeno da najmanju pogrešku daje građa mreže s 20 skrivenih neurona, no ta građa nije usvojena jer je broj težinskih parametara mreže koje učenjem treba oblikovati prevelik u odnosu na broj dostupnih uzoraka taljevina nodularnog lijeva.

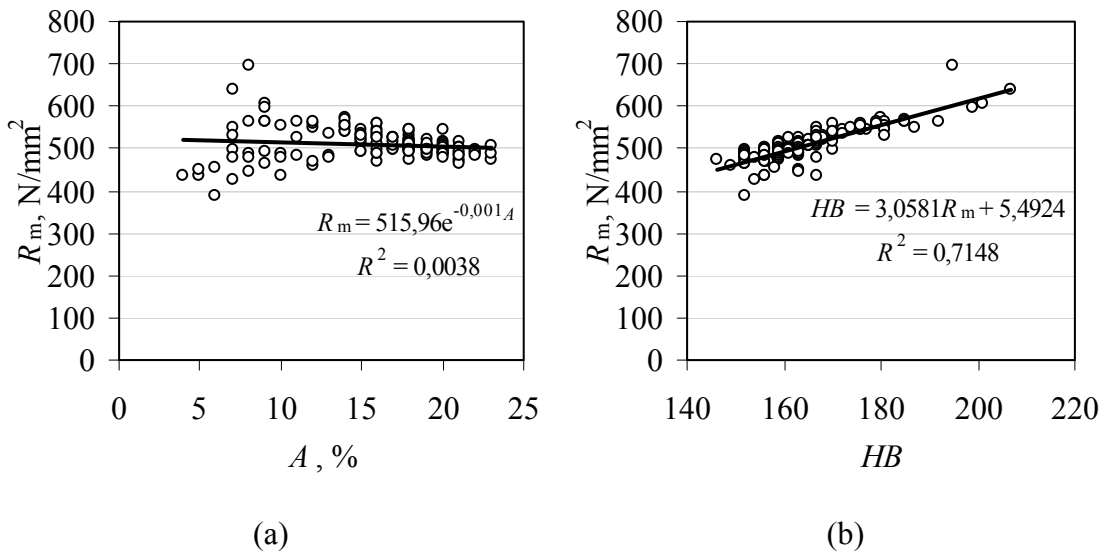
Tablica 5.1. Pregled parametara pogreške iz skupova za učenje, validaciju i testiranje pri predviđanju različitih mikrostrukturnih parametara i svojstava nodularnih ljevova

Parametar/ Svojstvo:	N_1	R			R^2			$NRMS$			$\overline{u_{rel}}, \%$		
		Uč.	Valid.	Test.	Uč.	Valid.	Test.	Uč.	Valid.	Test.	Uč.	Valid.	Test.
Nodularnost	6	0,917	0,844	0,803	0,841	0,712	0,644	0,398	0,573	0,603	1,66	1,68	2,40
N, mm^{-2}	5	0,952	0,940	0,798	0,906	0,883	0,637	0,309	0,332	0,589	3,44	2,24	4,19
$F, \%$	5	0,659	0,839	0,862	0,434	0,703	0,744	0,750	0,551	0,556	5,40	2,32	3,08
$R_m, \text{N/mm}^2$	12	0,822	0,533	0,552	0,676	0,284	0,305	0,576	0,849	0,821	3,46	3,48	4,10
$R_{p0,2}, \text{N/mm}^2$	12	0,861	0,317	0,631	0,741	0,100	0,399	0,524	0,970	0,762	2,46	3,18	2,81
$A, \%$	6	0,740	0,631	0,521	0,548	0,399	0,272	0,691	0,782	0,846	18,20	24,99	40,80
HB	6	0,857	0,625	0,805	0,734	0,391	0,648	0,515	0,772	0,731	2,45	3,52	3,72
R_m -mikrostr.	3	0,913	0,773	0,827	0,833	0,597	0,684	0,407	0,636	0,566	2,42	2,85	2,75

Iz pregleda parametara pogreške u gornjoj tablici može se zaključiti da su, u slučaju predviđanja na temelju toplinske analize, neuronske mreže znatno uspješnije učile predviđati mikrostrukturne parametre, nego mehanička svojstva. Razlog tome može se pripisati brojnim uzrocima. Prije ispitivanja valjalo bi provjeriti kvalitetu izrade svake epruvete za statički vlačni pokus. Osim toga, bilo bi dobro izraditi više epruveta od svake taljevine kako bi se dobio veći broj epruveta za ispitivanje. Nadalje, statički vlačni pokusi provedeni su na kidalici iz industrijskog laboratorija za ispitivanje metala, čija je mjerna preciznost ograničena. Također, može se zaključiti i da određeni toplinski parametri, koji nisu bili uključeni u model, utječu značajnije na predviđana mehanička svojstva, nego na mikrostrukturu. Od svih predviđanih mehaničkih svojstva najveća je točnost predviđanja postignuta pri predviđanju tvrdoće, koja je na svakom uzorku i mjerena tri puta i time je smanjena pogreška mjerenja u odnosu na ispitivanja epruveta statičkim vlačnim pokusom.

Najlošiji rezultati predviđanja postignuti su pri predviđanju istezljivosti nodularnog lijeva. Slika 5.1. (a) prikazuje izmjerene vrijednosti vlačne čvrstoće i istezljivosti za sve pripremljene taljevine nodularnog lijeva. Teoretski ta bi veza trebala izgledati kao eksponencijalna funkcija, no u prikazanom dijagramu se vidi da je ta veza izrazito narušena. Ako se promotri povezanost vlačne čvrstoće i tvrdoće, ta je veza sasvim u skladu s teorijom, tj. jaka je linearna povezanost. Slika 5.1. (b) prikazuje izmjerene vlačne čvrstoće i tvrdoće. Stoga se može zaključiti da se, vjerojatno zbog

ručnog mjerenja produljenja epruvete nakon kidanja, pojavila značajna pogreška mjerenja istezljivosti. Zbog ove činjenice su i rezultati modeliranja istezljivosti neuronskom mrežom bili nezadovoljavajući.



Slika 5.1. Korelacija između izmjerenih vlačnih čvrstoća i (a) istezljivosti, odnosno (b) tvrdoća nodularnih ljevova

Ako se usporede pogreške u skupu za testiranje pri predviđanju vlačne čvrstoće na temelju mikrostrukturnih parametara (Tablica 5.1), vidi se da je točnost predviđanja znatno veća nego pri predviđanju vlačne čvrstoće na temelju toplinske analize. Uz pretpostavku da je točnost mjerenja toplinskih parametara približno jednaka točnosti određivanja mikrostrukturnih parametara, može se zaključiti da je vlačna čvrstoća nodularnog lijeva značajnije određena mikrostrukturnim parametrima, nego što je određena odabranim toplinskim parametrima s krivulje hlađenja taljevine nodularnog lijeva.

Jedno od rješenja za poboljšanje točnosti predviđanja nekog od svojstava ili parametara mikrostrukture nodularnog lijeva neuronskim mrežama bio bi i izbacivanje tzv. *outliera*, tj. točaka koje izrazito, po bilo kojem izmjerenom parametru ili svojstvu odstupaju od ostalih podataka.

U ovome radu to se nije učinilo jer je dostupan skup podataka o 147 taljevina ionako bio prilično skroman, te se on stoga nije dalje reducira. Osim toga, cilj rada je bio definiranje neuronske mreže koja bi predviđala svojstva nodularnih ljevova

proizvedenih u određenoj ljevaonici. Konačni model neuronske mreže značajno ovisi o lokalnim uvjetima koji vladaju u pojedinoj ljevaonici, te se razvijeni modeli ne mogu jednako uspješno primijeniti u nekoj drugoj ljevaonici. Kako bi se poboljšao model neuronske mreže, valjalo bi prikupiti značajno veći broj uzoraka i ispitati sva njihova svojstva, počevši od toplinske analize i analize kemijskog sastava taljevine, pažljivog ispitivanja mehaničkih svojstava, do pripreme uzoraka i metalografskog ispitivanja. Kod proširivanja ispitivanja, posebno bi trebalo povećati količinu uzoraka taljevina koje su slične sadašnjim *outlierima*. To su npr. taljevine br. 48, 74 i 105, koje imaju značajno povišeni udio bakra, visoku vlačnu čvrstoću, te visoki udio perlita.

U daljem istraživanju kao ulazna varijabla za neuronsku mrežu može se uzeti i način obrade taljevine nodularnog lijeva. U konkretnoj ljevaonici gdje su snimane taljevine ljevova za ovaj rad, taljevina se obrađuje magnezijem postupcima Flotret i Osmoza.

6. ZAKLJUČAK

U radu je toplinskom analizom ispitano 147 taljevina nodularnog lijeva, određen im je kemijski sastav, ispitana vlačna čvrstoća, konvencionalna granica razvlačenja, istezljivost, tvrdoća i kvantitativnom analizom utvrđeni mikrostrukturni parametri. Statički vlačni pokus izvršen je u uvjetima industrijskog laboratorija, kod kojeg je pri određivanju istezljivosti bilo uključeno ručno mjerenje, zbog čega je bila niska točnost rezultata mjerenja istezljivosti. Mikrostrukturni parametri (nodularnost, broj nodula po jedinici površina, udio ferita i perlita) ispitani su u kontroliranim laboratorijskim uvjetima. Također, analiza kemijskog sastava i toplinska analiza taljevine su dale točne rezultate mjerenja. Na relativno nisku točnost dobivenih vrijednosti mehaničkih svojstava utječe i kvaliteta strojne obrade epruveta, mjerenja na samo jednom ispitnom uzorku te na kidalici s većom dozvoljenom pogreškom mjerenja.

Neuronskim mrežama predviđena su mehanička svojstva i mikrostrukturni parametri nodularnih ljevova. Ulazni su parametri bili podaci dobiveni toplinskom analizom taljevine. Broj značajnih parametara dobivenih toplinskom analizom reduciran je analizom glavnih komponenata, no pokazalo se da parametri toplinske analize odabrani prema fizikalnim zakonitostima procesa skrućivanja taljevine daju bolje rezultate pri predviđanju nodularnosti. Optimalna veličina sloja skrivenih neurona, optimalni nagib njihove aktivacijske funkcije, te povoljniji način normiranja ulaznih i izlaznih podataka određen je praćenjem normaliziranog korijena srednje kvadratne pogreške, koeficijenata korelacije i determinacije, te srednje vrijednost relativne pogreške. Pogreške su praćene u skupovima za učenje, za validaciju i testiranje, u koje su svi dostupni podaci bili podijeljeni. U skupove za validaciju i testiranje uključeni su nodularni ljevovi koji imaju krivulje hlađenja slične jednoj ili više drugih krivulja iz skupa za učenje.

Rezultati modeliranja mikrostrukture nodularnog lijeva neuronskim mrežama na izmjerenim podacima o taljevinama pokazali su da se mikrostrukturni parametri, posebno nodularnost, mogu uspješno i pouzdano predvidjeti na temelju rezultata toplinske analize. Ti su parametri točnije modeliranjem predviđeni jer su i njihova ispitivanja provedena u kontroliranim laboratorijskim uvjetima, s ponavljanjem

mjerenja. Modeliranja svojstava određenih statičkim vlačnim pokusom dala su relativno niske koeficijente korelacije, visoka srednja kvadratna odstupanja, visoke srednje vrijednost relativne pogreške pri čemu su te vrijednosti bile najlošije kod modeliranja istežljivosti.

Utvrđeni problemi pri predviđanju svojstava i mikrostrukture nodularnog lijeva neuronskim mrežama prouzročeni su ponajviše ograničenim brojem dostupnih uzoraka taljevina. Rasipanja izmjerenih mehaničkih svojstava taljevina su, osim toga, bila vrlo izražena. Nadalje, pri modeliranju nisu izuzeti outlieri jer se nastojao kreirati model neuronske mreže koji bi predviđao svojstva i mikrostrukturu za sve ljevove koji se proizvode u dotičnoj ljevaonici.

U daljem istraživanju, potrebno je prije svega ispitati taljevine slične sadašnjim outlierima. Riječ je o taljevinama s povišenim udjelom bakra, visokom vlačnom čvrstoću i s pretežno perlitnom strukturom metalne osnove. Također, pri sljedećim se modeliranjima mogu uzeti u obzir i duge kombinacije ulaznih parametara, npr. primijenjena tehnologija obrade taljevine magnezijem.

PRILOZI

Prilog 1. Svjetska proizvodnja odljevaka u 2006. [20]

zemlja	br. ljevaonica				41. popis svjetske proizvodnje Fe odljevaka u 2006., [tona]				ukupno svih ljevova, t	produktiv- nost po ljevaonici, 10 ³ t	
	Fe-lijev	čelič-ni l.	ne Fe	ukupno	sivi lijev	nodularni lijev	temperni lijev	čelični lijev			
Austrija	12	4	35	74	49.080	138.383	n/a	19.671	340.657	4,603	
Belgija	17	9	10	36	81.200	10.700	n/a	46.800	165.034	4,584	
Brazil	609	186	577	1.372	1.760.376	750.432	21.014	325.113	3.087.045	2,250	
Češka	89	28	59	176	293.026	51.006	3.900	113.878	556.391	3,161	
Danska	8	n/a	10	18	36.500	42.100	n/a	n/a	85.014	4,723	
Finska	15	6	15	36	46.780	67.250	n/a	19.816	150.412	4,178	
Francuska	110	37	322	469	874.022	1.071.145	1.358	116.583	2.408.241	5,135	
Hrvatska	15	3	25	43	30.971	18.243	50	2.000	69.753	1,622	
Indija	n/a	n/a	n/a	4.750	4.870.000	762.000	62.300	914.000	7.179.300	1,511	
Italija	170	27	974	1.171	931.400	549.300	n/a	83.000	2.637.400	2,252	
Japan	454	78	1.169	1.701	2.834.185	2.035.845	56.401	281.190	7.927.626	4,661	
Južnoafr. R.	87	51	117	255	14.700	86.000	n/a	184.000	368.700	1,446	
Kanada	55	28	83	166	483.000	n/a	n/a	117.600	901.385	5,430	
Kina	17.000	4.700	4.300	26.000	13.928.086	6.843.019	517.214	3.811.210	28.094.168	1,081	
Koreja	501	140	210	851	987.600	576.500	46.600	150.400	1.968.300	2,313	
Litva	8	3	5	16	12.500	200	n/a	90	12.852	0,803	
Madarska	42	27	143	212	48.950	20.112	31	6.033	175.106	0,826	
Meksiko	n/a	n/a	n/a	1.500	899.712	n/a	n/a	79.200	1.675.212	1,117	
Nizozemska	16	0	5	21	63.100	78.241	6.209	438	147.988	7,047	
Norveška	7	3	11	21	17.971	53.199	n/a	3.346	100.950	4,807	
Njemačka	212	53	354	619	2.582.539	1.661.189	56.103	215.303	5.480.900	8,854	
Poljska	185	n/a	245	430	431.000	129.400	24.400	60.400	849.020	1,974	
Portugal	49	10	40	99	28.025	80.694	n/a	14.171	156.010	1,576	
Rumunjska	72	54	84	210	61.540	14.753	898	35.616	150.488	0,717	
Rusija	n/a	n/a	n/a	1.900	3.480.000	720.000	280.000	1.200.000	6.900.000	3,632	
SAD	564	239	1.367	2.170	4.255.604	4.128.598	n/a	1.366.220	12.454.738	5,740	
Slovenija	16	4	33	53	79.000	28.800	n/a	30.000	177.823	3,355	
Slovačka	12	7	32	51	41.520	8.760	n/a	4.300	84.805	1,663	
Španjolska	65	34	57	156	440.600	623.000	17.300	87.700	1.330.001	8,526	
Švedska	36	15	85	136	193.600	67.800	n/a	24.100	354.000	2,603	
Švicarska	17	3	38	58	38.886	28.225	n/a	n/a	92.936	1,602	
Tajland	230	26	220	476	170.000	70.000	30.000	30.000	445.500	0,936	
Tajvan	520	45	350	915	840.203	227.527	n/a	86.568	1.556.726	1,701	
Turska	890	66	306	1.262	586.000	368.000	6.500	132.000	1.209.500	0,958	
Ukrajina	400	233	437	960	626.610	40.000	10.000	266.060	974.140	1,015	
V. Britanija	203	46	210	459	421.000	335.000	10.000	112.000	1.100.000	2,397	
					ukupno:						
					42.539.286	21.685.421	1.150.278	9.938.806	91.368.121		

n/a - podatak nije dostupan






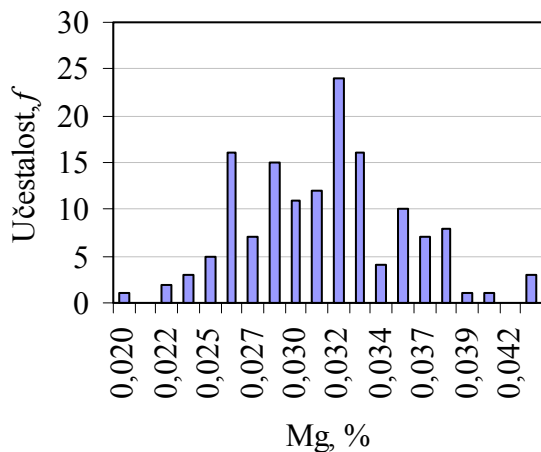
Prilog 2. Proizvodnja iz 2001. g. željeznih i neželjeznih legura po glavi stanovnika za pojedine zemlje, rangirano [21]

red. br.	zemlja	Fe-leg., kg/stan.	red. br.	zemlja	neFe-leg., kg/stan.	red. br.	zemlja	ukupno, kg/stan.
1	Slovenija	50,7	1	Tajland	220,0	1	Tajland	476,0
2	Njemačka	46,8	2	Italija	16,8	2	Slovenija	65,2
3	Tajvan	43,6	3	Slovenija	14,5	3	Tajvan	57,9
4	Češka	40,2	4	Austrija	14,3	4	Njemačka	57,1
5	Rusija	37,7	5	Tajvan	14,3	5	Japan	46,9
6	Francuska	37,3	6	Japan	10,4	6	SAD	46,1
7	Koreja	36,6	7	Njemačka	10,4	7	Češka	45,8
8	Japan	36,5	8	SAD	9,8	8	Francuska	44,0
9	SAD	36,3	9	Meksiko	9,2	9	Italija	41,9
10	Španjolska	32,8	10	Norveška	7,2	10	Rusija	41,7
11	Kanada	30,1	11	Španjolska	7,0	11	Španjolska	39,8
12	Švedska	28,1	12	Francuska	6,6	12	Austrija	39,7
13	Tajland	26,0	13	Švedska	6,1	13	Koreja	38,2
14	Italija	25,1	14	Mađarska	5,7	14	Švedska	34,3
15	Ukrajina	25,1	15	Češka	5,6	15	Kanada	32,8
16	Austrija	24,4	16	Litva	5,0	16	Ukrajina	26,5
17	Finska	23,4	17	Rusija	4,0	17	Finska	25,4
18	Poljska	17,6	18	Švicarska	3,4	18	Norveška	24,2
19	Norveška	17,1	19	Belgija	3,2	19	Meksiko	20,9
20	Velika Britanija	16,7	20	Kanada	2,7	20	Poljska	19,5
21	Danska	16,5	21	Portugal	2,6	21	Švicarska	18,5
22	Švicarska	15,1	22	Hrvatska	2,4	22	Belgija	18,2
23	Belgija	14,9	23	Finska	2,0	23	Danska	17,5
24	Rumunjska	14,7	24	Poljska	1,9	24	Velika Britanija	16,7
25	Turska	14,5	25	Koreja	1,6	25	Litva	16,0
26	Kina	11,7	26	Južnoafrička R	1,4	26	Rumunjska	16,0
27	Meksiko	11,7	27	Ukrajina	1,4	27	Turska	15,2
28	Južnoafrička R	11,5	28	Rumunjska	1,3	28	Južnoafrička R	12,9
29	Brazil	10,3	29	Brazil	1,0	29	Portugal	12,8
30	Portugal	10,2	30	Danska	1,0	30	Kina	12,6
31	Hrvatska	8,7	31	Kina	1,0	31	Mađarska	11,9
32	Nizozemska	8,6	32	Turska	0,7	32	Brazil	11,3
33	Mađarska	6,2	33	Indija	0,3	33	Hrvatska	11,0
34	Indija	3,3				34	Nizozemska	8,6
35	Litva	3,0				35	Indija	3,5







Prilog 5. Kemijski sastav ispitivanih taljevina (taljevine br. 101 – 147)

broj lijeva	Mg	C leco	Si	Mn	S	P	Ni	Cr	Cu	Mo	Ti	Al	Sn	Pb	Zn
101	0,028	3,660	2,724	0,124	0,005	0,048	0,040	0,060	0,079	0,005	0,022	0,011	0,009	0,001	0,010
102	0,033	3,690	2,866	0,122	0,010	0,046	0,033	0,052	0,066	0,002	0,018	0,013	0,008	0,000	0,003
103	0,028	3,645	2,800	0,129	0,012	0,045	0,036	0,057	0,068	0,003	0,018	0,012	0,014	0,000	0,002
104	0,025	3,640	2,728	0,139	0,007	0,044	0,041	0,056	0,075	0,003	0,020	0,012	0,009	0,000	0,002
105	0,027	3,680	2,720	0,144	0,007	0,043	0,041	0,054	0,479	0,011	0,020	0,010	0,015	0,001	0,001
106	0,033	3,680	2,862	0,153	0,006	0,059	0,043	0,061	0,078	0,010	0,019	0,010	0,009	0,001	0,001
107	0,027	3,650	2,783	0,184	0,009	0,070	0,038	0,071	0,091	0,010	0,019	0,009	0,011	0,000	0,003
108	0,029	3,690	2,876	0,182	0,015	0,056	0,043	0,061	0,087	0,005	0,020	0,009	0,012	0,000	0,008
109	0,028	3,700	2,913	0,193	0,012	0,057	0,040	0,062	0,089	0,005	0,018	0,011	0,016	0,000	0,008
110	0,026	3,670	2,810	0,187	0,013	0,057	0,041	0,061	0,087	0,004	0,018	0,010	0,014	0,000	0,007
111	0,029	3,630	2,901	0,182	0,011	0,059	0,043	0,061	0,088	0,004	0,019	0,010	0,014	0,000	0,008
112	0,024	3,690	2,572	0,156	0,007	0,049	0,033	0,058	0,074	0,001	0,016	0,013	0,002	0,001	0,006
113	0,023	3,700	2,631	0,158	0,005	0,053	0,036	0,057	0,075	0,003	0,018	0,012	0,013	0,000	0,007
114	0,020	3,740	2,719	0,147	0,004	0,054	0,043	0,056	0,088	0,005	0,020	0,008	0,000	0,000	0,007
115	0,031	3,740	2,923	0,150	0,004	0,053	0,043	0,055	0,088	0,005	0,020	0,011	0,013	0,001	0,008
116	0,023	3,740	2,773	0,141	0,004	0,054	0,039	0,052	0,083	0,005	0,021	0,010	0,006	0,000	0,008
117	0,030	3,760	2,753	0,134	0,004	0,059	0,032	0,048	0,079	0,004	0,021	0,010	0,009	0,000	0,007
118	0,026	3,770	2,708	0,131	0,004	0,051	0,032	0,045	0,072	0,003	0,020	0,010	0,010	0,000	0,005
119	0,033	3,650	2,782	0,120	0,009	0,036	0,043	0,086	0,069	0,003	0,017	0,013	0,016	0,001	0,004
120	0,044	3,670	3,031	0,146	0,007	0,058	0,050	0,089	0,087	0,010	0,022	0,014	0,021	0,001	0,025
121	0,028	3,710	2,788	0,158	0,006	0,048	0,057	0,079	0,092	0,007	0,021	0,018	0,019	0,002	0,022
122	0,027	3,740	2,871	0,145	0,007	0,045	0,050	0,075	0,078	0,005	0,016	0,018	0,010	0,000	0,019
123	0,031	3,710	2,879	0,150	0,006	0,051	0,048	0,076	0,083	0,007	0,020	0,018	0,001	0,000	0,020
124	0,022	3,690	2,678	0,135	0,007	0,051	0,048	0,070	0,092	0,007	0,018	0,008	0,008	0,000	0,024
125	0,032	3,700	2,876	0,140	0,005	0,053	0,050	0,074	0,090	0,008	0,022	0,010	0,010	0,000	0,020
126	0,023	3,700	2,574	0,132	0,004	0,041	0,047	0,068	0,078	0,006	0,015	0,014	0,014	0,001	0,020
127	0,037	3,730	2,878	0,152	0,003	0,036	0,046	0,068	0,096	0,007	0,017	0,019	0,008	0,001	0,021
128	0,028	3,700	2,809	0,152	0,002	0,038	0,047	0,070	0,099	0,007	0,018	0,016	0,004	0,000	0,022
129	0,030	3,660	2,837	0,162	0,006	0,041	0,056	0,070	0,089	0,009	0,021	0,009	0,011	0,000	0,024
130	0,032	3,640	2,814	0,161	0,004	0,042	0,057	0,070	0,089	0,009	0,023	0,009	0,009	0,000	0,022
131	0,025	3,690	2,782	0,151	0,006	0,032	0,048	0,062	0,079	0,004	0,017	0,009	0,012	0,001	0,018
132	0,027	3,730	2,852	0,152	0,005	0,045	0,044	0,064	0,073	0,006	0,021	0,014	0,002	0,000	0,021
133	0,031	3,710	2,860	0,147	0,005	0,041	0,042	0,062	0,070	0,005	0,018	0,017	0,009	0,000	0,021
134	0,030	3,730	2,851	0,141	0,009	0,044	0,042	0,067	0,076	0,005	0,024	0,010	0,011	0,001	0,009
135	0,031	3,720	2,883	0,154	0,005	0,046	0,042	0,072	0,078	0,007	0,023	0,014	0,013	0,001	0,005
136	0,028	3,700	2,833	0,122	0,004	0,044	0,039	0,064	0,072	0,006	0,019	0,013	0,005	0,000	0,006
137	0,033	3,680	2,905	0,195	0,005	0,046	0,042	0,069	0,080	0,008	0,028	0,012	0,019	0,002	0,006
138	0,035	3,720	3,046	0,197	0,005	0,037	0,052	0,066	0,080	0,008	0,025	0,010	0,021	0,001	0,006
139	0,024	3,750	3,103	0,198	0,005	0,035	0,063	0,071	0,079	0,008	0,026	0,013	0,019	0,000	0,004
140	0,032	3,700	3,257	0,207	0,005	0,039	0,074	0,080	0,085	0,011	0,030	0,015	0,026	0,002	0,008
141	0,028	3,740	2,957	0,200	0,003	0,036	0,072	0,081	0,082	0,011	0,024	0,009	0,010	0,001	0,007
142	0,026	3,710	2,705	0,165	0,002	0,031	0,081	0,296	0,079	0,010	0,026	0,008	0,045	0,001	0,007
143	0,033	3,720	2,759	0,148	0,003	0,030	0,070	0,259	0,069	0,008	0,027	0,009	0,037	0,000	0,007
144	0,022	3,650	2,775	0,141	0,007	0,032	0,054	0,148	0,063	0,006	0,023	0,012	0,022	0,001	0,006
145	0,030	3,640	2,826	0,233	0,008	0,034	0,059	0,125	0,076	0,007	0,025	0,009	0,019	0,002	0,007
146	0,036	3,640	2,939	0,145	0,001	0,051	0,077	0,102	0,092	0,006	0,022	0,014	0,019	0,001	0,000
147	0,033	3,650	2,849	0,151	0,000	0,058	0,074	0,103	0,089	0,007	0,025	0,010	0,012	0,001	0,000




Prilog 6. Razdioba pojedinih legirnih elemenata u pripremljenim nodularnim ljevovima
(1. dio)



Prilog 7. Razdioba pojedinih legirnih elemenata u pripremljenim nodularnim ljevovima
(2. dio)



Prilog 8. Razdioba pojedinih legirnih elemenata u pripremljenim nodularnim ljevovima
(3. dio)







Prilog 9. Mehanička svojstva svih ispitivanih taljevina

Broj taljevine	R_m , N/mm ²	$R_{p0,2}$, N/mm ²	A , %	HB
1	550	382	14	167
2	543	376	15	177
3	530	382	16	167
4	512	369	18	165
5	538	369	14	172
6	574	389	14	180
7	538	376	14	172
8	524	369	15	163
9	558	389	14	179
10	538	369	18	167
11	543	369	20	172
12	526	363	17	167
13	530	363	18	168
14	549	382	12	174
15	543	369	18	176
16	557	389	16	170
17	506	357	19	159
18	535	376	15	170
19	527	389	11	170
20	530	376	15	170
21	517	363	21	167
22	522	369	18	167
23	498	363	18	152
24	521	369	19	165
25	515	369	18	167
26	501	350	21	159
27	502	357	20	156
28	525	369	16	161
29	499	350	19	159
30	517	357	20	163
31	485	350	21	159
32	504	357	20	161
33	513	357	16	167
34	522	363	15	170
35	501	357	17	161
36	497	357	18	163
37	507	363	18	165
38	493	350	19	159
39	498	357	17	159
40	507	363	19	167
41	497	369	16	159
42	488	357	8	159
43	490	350	20	152
44	488	350	22	156
45	475	344	21	152
46	507	363	19	159
47	483	350	19	152
48	639	433	7	207
49	468	350	16	157
50	427	331	7	154

Broj taljevine	R_m , N/mm ²	$R_{p0,2}$, N/mm ²	A , %	HB
51	498	369	17	161
52	497	357	19	156
53	474	357	23	146
54	507	357	17	159
55	513	357	20	163
56	502	350	19	156
57	558	382	12	176
58	563	388	12	181
59	564	388	11	179
60	552	376	10	181
61	475	344	18	159
62	546	382	16	176
63	525	369	17	168
64	543	376	18	181
65	557	382	16	179
66	507	369	18	165
67	501	363	20	159
68	503	357	21	163
69	484	357	13	159
70	482	363	11	163
71	499	369	7	170
72	437	369	5	156
73	517	369	17	159
74	604	420	9	201
75	488	350	21	156
76	499	357	20	159
77	512	363	15	167
78	487	357	10	163
79	469	344	21	156
80	494	357	20	161
81	507	363	18	159
82	488	350	23	159
83	490	357	15	159
84	518	369	15	167
85	506	369	18	165
86	521	369	18	170
87	501	357	19	163
88	506	363	20	163
89	496	357	22	156
90	522	369	15	168
91	499	363	20	161
92	566	389	14	185
93	564	395	9	192
94	548	389	7	187
95	564	401	9	185
96	561	395	8	185
97	531	382	7	181
98	455	369	6	158
99	480	357	7	167
100	478	369	8	159

Broj taljevine	R_m , N/mm ²	$R_{p0,2}$, N/mm ²	A , %	HB
101	490	376	9	159
102	518	369	18	170
103	510	369	18	159
104	464	357	9	152
105	697	497	8	195
106	511	357	18	163
107	535	363	16	172
108	502	357	20	163
109	530	363	15	167
110	436	357	4	167
111	534	369	13	170
112	489	350	16	152
113	488	338	20	159
114	434	331	10	156
115	490	357	22	156
116	494	350	18	156
117	497	363	18	156
118	488	350	19	152
119	452	344	5	163
120	512	363	19	159
121	479	357	10	159
122	479	350	13	152
123	484	350	20	159
124	461	338	12	149
125	498	357	19	163
126	470	338	12	156
127	503	350	21	159
128	490	350	21	159
129	462	344	21	152
130	386	293	6	152
131	489	350	20	163
132	498	344	18	159
133	499	363	19	156
134	488	350	20	159
135	494	357	15	163
136	493	344	18	159
137	482	344	22	152
138	483	350	21	156
139	487	357	16	161
140	506	363	23	165
141	478	350	20	154
142	596	408	9	199
143	552	389	14	176
144	446	338	8	163
145	526	369	17	168
146	539	395	16	170
147	526	369	16	167

Prilog 10. Razdioba mehaničkih svojstava pripremljenih nodularnih ljevova



Prilog 11. Toplinski parametri s krivulje hlađenja za ispitivane tajjevine br. 1 – 30

Broj tajjevine	ϑ_{L_s} , °C	ϑ_{ES} , °C	$\frac{d\vartheta_{ES}}{dt}$, °C/s	ϑ_{EP} , °C	ϑ_{ER} , °C	ϑ_{R} , °C	\overline{V}_R , °C/s	v_r , maks, °C/s	ϑ_s , °C	GRF1	GRF2	GRF3	F_{obs} , %	f_{SI} , %	f_{S2} , %	f_{S3} , %	t_{ds} , s	$t_{L,zastoj}$, s	$\vartheta_{EP,1}$, °C	$\frac{d\vartheta_s}{dt}$, °C/s	ϑ_{EID} , °C
1	1149,3	1149,1	0,00	1149,1	1152,1	3,0	0,10	0,26	1100,2	89	101	39	19	1	19	80	0,6	0	16,0	-2,29	734,3
2	1140,0	1140,0	0,00	1140,0	1145,0	5,0	0,17	0,30	1091,0	84	90	44	20	1	20	79	0,6	0	25,2	-2,38	734,2
3	1139,1	1139,2	0,00	1139,2	1144,1	4,9	0,16	0,29	1096,8	90	65	40	20	1	20	79	0,6	0	25,1	-2,71	734,9
4	1140,8	1140,8	0,00	1140,8	1147,2	6,4	0,21	0,33	1093,2	83	93	42	21	1	20	78	0,0	0	23,5	-2,43	735,1
5	1139,5	1139,5	0,00	1139,5	1147,3	7,9	0,21	0,32	1095,3	79	66	35	25	1	25	74	0,6	0	24,8	-2,80	734,5
6	1136,3	1136,3	0,00	1136,3	1142,5	6,2	0,19	0,30	1093,8	86	61	38	22	1	22	77	0,7	0	28,0	-2,83	733,1
7	1139,7	1139,7	0,00	1139,7	1142,7	3,0	0,15	0,22	1090,4	96	98	43	14	1	14	85	0,7	0	24,6	-2,37	732,0
8	1139,5	1139,5	0,00	1139,5	1148,0	8,5	0,19	0,35	1095,9	70	61	41	34	1	33	65	0,7	0	24,8	-2,91	733,9
9	1137,0	1137,0	0,00	1137,0	1143,5	6,5	0,17	0,29	1093,5	81	61	36	26	1	26	73	0,7	0	27,3	-2,84	733,0
10	1138,6	1138,6	0,00	1138,6	1144,4	5,8	0,17	0,27	1096,5	86	64	39	24	1	23	75	0,7	0	26,6	-2,82	733,5
11	1149,7	1149,7	0,00	1149,7	1152,3	2,5	0,13	0,21	1094,4	95	80	38	14	1	14	85	0,7	0	14,6	-2,50	732,2
12	1156,4	1153,6	-0,49	1151,5	1153,5	2,0	0,14	0,19	1104,0	100	58	35	11	11	10	78	11,0	12	12,8	-2,95	731,6
13	1145,9	1146,0	0,00	1146,0	1148,8	2,8	0,11	0,24	1104,9	95	74	36	19	1	18	80	0,7	0	18,3	-2,59	733,4
14	1144,3	1144,4	0,00	1144,4	1148,5	4,0	0,12	0,22	1103,8	92	64	36	22	1	21	77	0,6	0	19,9	-2,78	732,5
15	1150,0	1138,5	-0,54	1131,7	1137,2	5,5	0,13	0,17	1081,3	57	117	42	35	28	25	47	27,2	10	32,6	-2,11	730,8
16	1143,3	1143,3	0,00	1143,3	1149,2	5,9	0,17	0,25	1100,6	88	70	37	22	1	22	77	0,6	0	21,0	-2,73	733,7
17	1139,9	1139,9	0,00	1139,9	1147,9	8,0	0,21	0,33	1096,2	78	55	44	27	1	27	72	0,7	0	24,4	-3,00	733,0
18	1140,1	1140,1	0,00	1140,1	1147,4	7,3	0,21	0,32	1098,2	82	55	37	26	1	25	73	0,7	0	24,2	-3,11	734,2
19	1140,0	1140,0	0,00	1140,0	1146,5	6,4	0,21	0,30	1097,5	88	63	38	21	1	20	78	0,7	0	24,3	-2,81	733,6
20	1201,6	1178,0	-4,84	1147,6	1150,1	2,5	0,18	0,23	1095,3	93	69	37	10	15	9	76	14,2	8	16,7	-2,72	735,2
21	1149,2	1149,2	0,00	1149,2	1151,9	2,8	0,16	0,25	1103,7	95	35	41	13	1	13	86	0,7	0	15,1	-3,50	735,9
22	1140,5	1140,5	0,00	1140,5	1144,0	3,5	0,12	0,22	1095,5	93	69	34	19	1	19	80	0,6	0	23,8	-2,78	735,5
23	1142,0	1142,0	0,00	1142,0	1145,7	3,7	0,15	0,24	1096,0	96	75	34	16	1	16	83	0,6	0	22,3	-2,64	735,4
24	1144,6	1144,6	0,00	1144,6	1147,8	3,2	0,19	0,28	1094,2	91	93	40	13	1	13	85	0,7	0	19,7	-2,44	738,9
25	1147,1	1147,1	0,00	1147,1	1149,6	2,5	0,12	0,18	1100,3	97	72	39	15	1	14	84	0,7	0	17,2	-2,68	739,6
26	1147,2	1147,3	0,00	1147,3	1150,7	3,4	0,13	0,23	1103,4	91	69	37	19	1	19	80	0,7	0	17,0	-2,73	734,2
27	1143,0	1143,1	0,00	1143,1	1149,6	6,5	0,23	0,32	1100,4	88	59	38	21	1	21	78	0,7	0	21,2	-2,92	739,9
28	1137,8	1137,8	0,00	1137,8	1144,6	6,9	0,18	0,29	1088,5	77	87	40	25	1	25	74	0,6	0	26,6	-2,51	732,6
29	1148,8	1148,8	0,00	1148,8	1152,7	4,0	0,14	0,24	1106,6	91	29	35	20	1	20	78	0,7	0	15,5	-3,62	737,9
30	1139,7	1139,8	0,00	1139,8	1146,5	6,7	0,20	0,29	1097,4	88	54	38	22	1	22	77	0,6	0	24,5	-3,02	736,2

Prilog 12. Toplinski parametri s krivulje hlađenja za ispitivane taljevine br. 31 – 60

Broj taljevine	$\vartheta_L, ^\circ\text{C}$	$\vartheta_{ES}, ^\circ\text{C}$	$\frac{d\vartheta_{ES}}{dt}, \frac{^\circ\text{C}}{\text{s}}$	$\vartheta_{EP}, ^\circ\text{C}$	$\vartheta_{ER}, ^\circ\text{C}$	$\vartheta_{R}, ^\circ\text{C}$	$\overline{V}_R, \frac{^\circ\text{C}}{\text{s}}$	$V_{r, maks}, \frac{^\circ\text{C}}{\text{s}}$	$\vartheta_S, ^\circ\text{C}$	GRF1	GRF2	GRF3	F _{oksr} , %	f _{S1} , %	f _{S2} , %	f _{S3} , %	t _{ds} , s	t _{L, zastoj} , s	$\vartheta_{EP, b}, ^\circ\text{C}$	$\frac{d\vartheta_S}{dt}, \frac{^\circ\text{C}}{\text{s}}$	$\vartheta_{EID}, ^\circ\text{C}$
31	1141,2	1141,4	0,00	1141,4	1148,6	7,2	0,22	0,25	1098,1	86	56	38	22	1	22	77	0,7	0	22,9	-2,99	736,3
32	1139,6	1139,6	0,00	1139,6	1148,7	9,1	0,24	0,36	1098,3	80	68	42	26	1	26	73	0,7	0	24,7	-2,73	735,6
33	1140,0	1140,0	0,00	1140,0	1147,9	7,9	0,22	0,30	1097,6	83	67	42	24	1	24	75	0,7	0	24,3	-2,81	734,6
34	1147,5	1146,6	-0,15	1145,1	1145,3	0,2	0,01	0,01	1098,9	77	88	42	26	37	17	47	36,6	0	19,2	-2,43	739,3
35	1141,3	1141,3	0,00	1141,3	1146,5	5,2	0,22	0,30	1096,9	96	58	38	15	1	15	84	0,6	0	23,0	-2,84	736,7
36	1138,3	1138,3	0,00	1138,3	1145,6	7,4	0,21	0,31	1099,0	86	59	38	24	1	24	75	0,7	0	26,0	-2,88	734,8
37	1137,7	1137,7	0,00	1137,7	1142,8	5,1	0,17	0,26	1090,6	89	79	38	19	1	19	80	0,6	0	26,6	-2,59	733,5
38	1139,5	1139,5	0,00	1139,5	1144,5	5,0	0,12	0,21	1094,7	80	56	38	28	1	27	72	0,7	0	24,8	-3,00	732,7
39	1139,4	1139,4	0,00	1139,4	1146,2	6,8	0,16	0,23	1091,2	73	87	43	28	1	28	71	0,7	0	24,9	-2,51	734,0
40	1136,7	1136,6	0,00	1136,6	1141,6	4,9	0,11	0,20	1094,9	80	53	35	30	1	29	70	0,7	0	27,7	-3,02	733,5
41	1141,5	1141,5	0,00	1141,5	1146,2	4,7	0,09	0,18	1096,7	70	59	40	36	1	35	63	0,7	0	22,8	-2,94	737,7
42	1141,8	1141,8	0,00	1141,8	1143,4	1,6	0,07	0,09	1096,2	98	47	34	16	1	15	83	0,7	0	22,5	-3,10	735,0
43	1139,7	1139,7	0,00	1139,7	1144,0	4,3	0,11	0,18	1095,4	82	46	36	27	1	27	72	0,7	0	24,6	-3,18	737,2
44	1136,7	1136,7	0,00	1136,7	1142,4	5,7	0,15	0,25	1093,8	81	45	37	28	1	27	71	0,7	0	27,6	-3,23	736,0
45	1144,1	1144,1	0,00	1144,1	1150,7	6,6	0,20	0,32	1093,4	87	52	35	24	1	24	75	0,7	0	29,2	-3,06	733,5
46	1143,3	1143,3	0,00	1143,3	1149,1	5,8	0,13	0,20	1095,6	80	56	36	30	1	29	69	0,6	0	29,0	-3,00	735,2
47	1137,5	1137,4	0,00	1137,4	1144,6	7,2	0,16	0,25	1095,5	78	60	38	30	1	29	69	0,7	0	26,9	-2,91	737,3
48	1141,0	1141,0	0,00	1141,0	1147,2	6,1	0,13	0,21	1097,8	75	50	37	32	1	32	67	0,7	0	23,3	-3,08	729,2
49	1137,8	1137,8	0,00	1137,8	1141,4	3,6	0,09	0,15	1092,5	79	50	38	29	1	28	70	0,7	0	26,5	-3,00	738,9
50	1140,2	1140,2	0,00	1140,2	1146,5	6,3	0,14	0,23	1096,8	74	52	42	31	1	31	68	0,7	0	24,1	-2,93	738,0
51	1138,7	1138,7	0,00	1138,7	1141,6	2,9	0,08	0,12	1094,6	86	53	36	26	1	26	73	0,7	0	25,6	-3,03	738,6
52	1139,1	1139,1	0,00	1139,1	1143,8	4,8	0,11	0,18	1092,3	79	69	37	28	1	28	71	0,6	0	25,2	-2,77	736,9
53	1142,1	1142,1	0,00	1142,1	1143,0	1,0	0,03	0,04	1095,8	93	41	38	20	1	20	78	0,7	0	22,2	-3,38	737,8
54	1141,7	1141,7	0,00	1141,7	1147,4	5,7	0,12	0,20	1098,0	75	55	38	31	1	31	68	0,6	0	22,6	-2,91	737,1
55	1140,9	1140,8	0,00	1140,8	1148,1	7,2	0,18	0,29	1095,6	75	71	40	29	1	29	70	0,7	0	23,5	-2,75	738,2
56	1139,5	1139,5	0,00	1139,5	1142,0	2,5	0,06	0,08	1093,8	79	45	33	30	1	30	69	0,7	0	24,8	-3,27	737,1
57	1139,1	1139,5	0,00	1139,5	1145,7	6,2	0,26	0,33	1093,8	87	46	34	20	2	20	78	0,8	0	24,8	-3,30	746,0
58	1144,2	1144,3	0,00	1144,3	1148,0	3,7	0,14	0,24	1099,9	91	84	39	18	1	17	81	0,7	0	20,1	-2,42	745,9
59	1139,1	1139,1	0,00	1139,1	1144,9	5,8	0,16	0,27	1097,5	84	71	43	25	1	25	74	0,7	0	25,2	-2,64	746,3
60	1143,2	1143,2	0,00	1143,2	1147,0	3,9	0,18	0,26	1099,7	97	80	35	14	1	14	85	0,7	0	21,1	-2,45	745,3

Prilog 13. Toplinski parametri s krivulje hlađenja za ispitivane taljevine br. 61 – 90

Broj taljevine	$\vartheta_L, ^\circ\text{C}$	$\vartheta_{ES}, ^\circ\text{C}$	$\frac{d\vartheta_{ES}}{dt}, ^\circ\text{C/s}$	$\vartheta_{EP}, ^\circ\text{C}$	$\vartheta_{ER}, ^\circ\text{C}$	$\vartheta_{R}, ^\circ\text{C}$	$\overline{V_R}, ^\circ\text{C/s}$	$V_{r, maks}, ^\circ\text{C/s}$	$\vartheta_S, ^\circ\text{C}$	GRF1	GRF2	GRF3	$F_{okst}, \%$	$f_{S1}, \%$	$f_{S2}, \%$	$f_{S3}, \%$	t_{ds}, s	$t_{L, zastoj}, \text{s}$	$\vartheta_{EP, 1}, ^\circ\text{C}$	$\frac{d\vartheta_S}{dt}, ^\circ\text{C/s}$	$\vartheta_{EID}, ^\circ\text{C}$
61	1140,4	1140,4	0,00	1140,4	1144,4	4,0	0,11	0,17	1092,2	73	51	37	31	2	30	68	0,8	0	23,9	-3,10	739,5
62	1140,8	1140,8	0,00	1140,8	1147,9	7,1	0,24	0,34	1096,7	87	77	39	20	1	20	79	0,7	0	23,5	-2,60	741,5
63	1139,7	1139,7	0,00	1139,7	1146,8	7,2	0,22	0,31	1098,5	87	55	38	23	1	22	76	0,7	0	24,6	-2,99	740,2
64	1137,3	1137,5	0,00	1137,5	1145,6	8,2	0,22	0,35	1092,6	73	53	41	31	2	30	68	0,8	0	26,8	-3,15	739,7
65	1138,6	1138,6	0,00	1138,6	1145,6	7,0	0,16	0,28	1095,4	76	56	37	30	1	29	69	0,7	0	25,7	-2,93	738,6
66	1140,1	1140,1	0,00	1140,1	1147,9	7,9	0,20	0,31	1095,7	76	50	40	28	1	28	71	0,7	0	24,2	-3,11	739,0
67	1141,3	1141,3	0,00	1141,3	1149,7	8,4	0,26	0,40	1098,0	79	52	42	25	2	25	74	0,8	0	23,0	-3,11	739,6
68	1146,3	1146,3	0,00	1146,3	1152,6	6,2	0,19	0,26	1105,3	86	77	39	23	1	23	76	0,7	0	18,0	-2,56	739,2
69	1140,9	1140,9	0,00	1140,9	1151,0	10,1	0,21	0,37	1100,7	73	67	40	32	1	32	67	0,7	0	23,4	-2,72	736,8
70	1142,2	1142,2	0,00	1142,2	1153,1	10,9	0,24	0,40	1099,3	68	65	45	32	1	32	67	0,7	0	22,1	-2,76	736,8
71	1139,6	1139,6	0,00	1139,6	1147,5	7,9	0,21	0,33	1097,1	82	58	35	26	1	25	73	0,7	0	24,7	-2,88	736,6
72	1140,5	1140,5	0,00	1140,5	1149,0	8,5	0,16	0,26	1096,0	63	55	43	37	1	37	62	0,7	0	23,8	-2,93	735,8
73	1139,6	1139,6	0,00	1139,6	1146,6	7,0	0,18	0,27	1095,9	78	66	40	27	1	27	72	0,7	0	24,7	-2,76	737,3
74	1143,6	1143,6	0,00	1143,6	1146,0	2,4	0,06	0,11	1094,3	69	53	42	32	1	32	67	0,8	0	20,7	-2,99	730,5
75	1143,9	1143,9	0,00	1143,9	1144,9	1,0	0,02	0,05	1092,4	67	39	35	35	2	35	64	0,8	0	20,4	-3,50	736,0
76	1139,9	1139,9	0,00	1139,9	1147,7	7,8	0,16	0,26	1097,8	72	61	41	34	1	33	65	0,7	0	24,4	-2,85	737,0
77	1139,7	1139,7	0,00	1139,7	1148,4	8,7	0,19	0,29	1101,4	74	63	41	33	1	33	66	0,7	0	24,6	-2,82	735,3
78	1139,9	1139,9	0,00	1139,9	1142,1	2,3	0,04	0,06	1094,5	70	48	37	36	1	36	63	0,7	0	24,4	-3,10	733,8
79	1142,6	1142,6	0,00	1142,6	1143,2	0,7	0,05	0,06	1095,4	105	37	34	18	2	10	89	0,8	0	21,7	-3,53	737,3
80	1140,8	1140,8	0,00	1140,8	1147,0	6,2	0,14	0,22	1098,0	79	58	45	29	1	29	70	0,7	0	23,5	-2,94	735,7
81	1141,2	1141,2	0,00	1141,2	1145,5	4,2	0,10	0,20	1096,0	77	52	37	30	1	30	69	0,7	0	23,1	-3,05	734,4
82	1142,4	1142,4	0,00	1142,4	1144,2	1,8	0,05	0,10	1095,8	89	46	32	23	1	23	76	0,6	0	21,9	-3,23	736,0
83	1142,5	1142,5	0,00	1142,5	1144,2	1,7	0,05	0,09	1094,3	88	48	37	22	1	22	77	0,7	0	21,8	-3,14	736,3
84	1141,9	1141,9	0,00	1141,9	1147,1	5,2	0,15	0,26	1097,8	84	66	40	24	1	23	75	0,7	0	22,4	-2,75	736,2
85	1139,6	1139,6	0,00	1139,6	1144,9	5,3	0,12	0,19	1096,1	76	65	37	31	1	30	68	0,7	0	24,7	-2,79	734,6
86	1139,5	1139,5	0,00	1139,5	1146,0	6,5	0,20	0,28	1095,8	86	84	39	22	1	22	77	0,7	0	24,8	-2,53	736,4
87	1140,6	1140,5	0,00	1140,5	1147,6	7,1	0,16	0,29	1099,8	78	64	38	29	1	29	70	0,6	0	23,8	-2,80	734,4
88	1140,8	1140,8	0,00	1140,8	1142,2	1,3	0,05	0,07	1095,8	96	48	33	18	1	18	81	0,6	0	23,5	-3,12	734,5
89	1139,9	1139,9	0,00	1139,9	1145,6	5,7	0,14	0,23	1097,4	75	48	42	31	1	30	68	0,8	0	24,4	-3,13	734,7
90	1141,0	1141,0	0,00	1141,0	1145,5	4,4	0,11	0,18	1091,8	73	71	41	30	1	30	69	0,7	0	23,3	-2,72	738,6



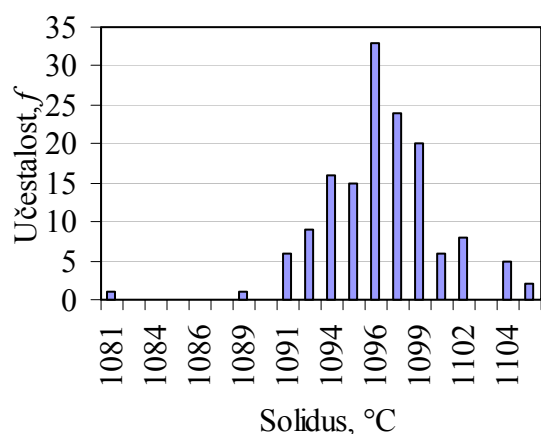



Prilog 14. Toplinski parametri s krivulje hlađenja za ispitivane tajjevine br. 91 – 120

Broj tajjevine	ϑ_L , °C	ϑ_{ES} , °C	$\frac{d\vartheta_{ES}}{dt}$, °C/s	ϑ_{EP} , °C	ϑ_{ER} , °C	ϑ_{R_0} , °C	$\overline{V_R}$, °C/s	$V_{r, maks}$, °C/s	ϑ_S , °C	GRF1	GRF2	GRF3	F_{okst} , %	f_{SI} , %	f_{S2} , %	f_{S3} , %	$t_{d, s}$	$t_{L, zastoip}$, s	$\vartheta_{EP, b}$, °C	$\frac{d\vartheta_S}{dt}$, °C/s	ϑ_{EID} , °C
91	1144,2	1144,2	0,00	1144,2	1144,5	0,3	0,01	0,04	1096,8	82	44	35	28	1	28	71	0,7	0	20,1	-3,17	734,7
92	1137,3	1137,3	0,00	1137,5	1145,7	8,1	0,19	0,33	1092,2	65	117	45	32	1	32	67	0,8	0	26,8	-2,18	746,7
93	1137,2	1137,2	0,00	1137,4	1145,3	7,9	0,27	0,41	1093,5	79	88	45	24	2	24	75	0,8	0	26,9	-2,49	750,2
94	1139,8	1139,8	0,00	1139,8	1146,5	6,7	0,14	0,23	1095,9	71	81	40	34	1	33	65	0,7	0	24,5	-2,48	746,2
95	1139,2	1139,2	0,00	1139,2	1146,0	6,8	0,15	0,23	1095,9	72	79	40	32	1	31	67	0,7	0	25,1	-2,51	747,1
96	1138,8	1138,8	0,00	1138,8	1144,5	5,7	0,13	0,19	1096,7	73	64	43	32	1	32	67	0,7	0	25,5	-2,69	744,2
97	1140,2	1140,2	0,00	1140,2	1140,9	0,7	0,02	0,03	1091,5	80	73	39	26	1	26	73	0,7	0	24,1	-2,56	744,1
98	1142,9	1142,9	0,00	1142,9	1143,8	0,9	0,02	0,06	1094,9	69	47	38	36	1	36	63	0,7	0	21,4	-3,04	740,7
99	1144,9	1144,1	-0,11	1142,6	1142,8	0,2	0,01	0,02	1096,1	102	50	36	11	24	8	68	23,7	0	21,7	-3,04	741,7
100	1141,3	1141,3	0,00	1141,3	1142,7	1,3	0,03	0,05	1097,0	79	47	36	31	1	31	68	0,7	0	23,0	-3,15	737,0
101	1143,0	1143,0	0,00	1143,0	1143,7	0,7	0,02	0,04	1095,8	76	44	36	32	1	31	67	0,7	0	21,3	-3,22	741,3
102	1141,7	1141,7	0,00	1141,7	1148,7	7,0	0,23	0,35	1098,6	87	77	41	21	1	20	78	0,6	0	22,6	-2,57	743,1
103	1138,2	1138,2	0,00	1138,2	1146,8	8,5	0,20	0,31	1098,4	75	57	40	30	1	29	69	0,7	0	26,1	-2,83	741,5
104	1138,5	1138,5	0,00	1138,5	1144,0	5,5	0,12	0,18	1093,5	73	53	40	32	1	32	67	0,7	0	25,8	-2,95	739,1
105	1142,2	1142,2	0,00	1142,2	1151,6	9,4	0,21	0,33	1103,6	77	47	37	31	1	31	68	0,7	0	22,1	-3,14	733,5
106	1139,4	1139,4	0,00	1139,4	1148,0	8,6	0,23	0,32	1096,7	79	63	42	26	1	26	73	0,7	0	24,9	-2,82	743,4
107	1137,9	1137,9	0,00	1137,9	1143,3	5,4	0,12	0,19	1090,4	73	80	42	30	1	30	69	0,7	0	26,4	-2,55	743,9
108	1136,5	1136,5	0,00	1136,5	1144,6	8,1	0,28	0,38	1094,7	81	52	38	25	2	24	74	0,8	0	27,8	-3,11	743,5
109	1137,5	1137,5	0,00	1137,5	1144,9	7,4	0,31	0,44	1090,6	85	62	37	20	2	19	79	0,8	0	26,8	-2,87	743,3
110	1139,4	1139,4	0,00	1139,4	1146,5	7,0	0,14	0,24	1093,8	71	67	37	32	1	32	67	0,6	0	24,9	-2,75	742,2
111	1138,6	1138,6	0,00	1138,6	1145,2	6,6	0,15	0,24	1094,1	76	61	39	30	1	30	69	0,7	0	25,8	-2,84	741,7
112	1139,2	1139,2	0,00	1139,2	1147,8	8,5	0,20	0,32	1098,4	75	53	40	30	1	30	69	0,7	0	25,1	-2,97	742,2
113	1140,0	1140,0	0,00	1140,0	1146,8	6,8	0,16	0,25	1096,8	74	49	39	32	1	31	67	0,7	0	24,4	-3,15	742,5
114	1138,1	1138,1	0,00	1138,1	1146,3	8,3	0,18	0,29	1094,5	68	41	40	35	1	35	64	0,7	0	26,2	-3,31	740,1
115	1142,3	1142,5	0,00	1142,5	1148,6	6,1	0,21	0,26	1101,2	89	58	38	21	1	21	77	0,7	0	21,8	-2,91	743,8
116	1140,0	1140,0	0,00	1140,0	1146,2	6,3	0,13	0,23	1094,3	69	51	42	35	1	34	64	0,7	0	24,3	-3,07	741,9
117	1144,0	1144,0	0,00	1144,0	1149,3	5,3	0,19	0,29	1098,2	89	78	40	18	1	18	81	0,6	0	20,3	-2,54	741,6
118	1141,5	1141,5	0,00	1141,5	1148,6	7,1	0,19	0,27	1096,7	79	61	38	26	1	26	73	0,7	0	22,8	-2,89	743,5
119	1144,4	1144,4	0,00	1144,4	1146,8	2,3	0,06	0,09	1092,1	69	51	43	32	2	31	67	0,8	0	19,9	-3,08	734,4
120	1142,1	1142,1	0,00	1142,1	1146,2	4,1	0,13	0,18	1097,6	86	65	37	23	1	23	76	0,7	0	22,2	-2,80	742,6


Prilog 15. Toplinski parametri s krivulje hlađenja za ispitivane tajjevine br. 121 – 147

Broj tajjevine	ϑ_{L_s} , °C	ϑ_{ES} , °C	$\frac{d\vartheta_{ES}}{dt}$, °C/s	ϑ_{EP} , °C	ϑ_{ER} , °C	ϑ_{R} , °C	$\overline{V_R}$, °C/s	$V_{r, maks}$, °C/s	ϑ_{S} , °C	GRF1	GRF2	GRF3	F_{okss} , %	f_{S1} , %	f_{S2} , %	f_{S3} , %	t_{db} , s	$t_{L, zastoj}$, s	$\vartheta_{EP, b}$, °C	$\frac{d\vartheta_{S}}{dt}$, °C/s	ϑ_{EID} , °C
121	1141,7	1141,7	0,00	1141,7	1145,6	3,8	0,07	0,12	1095,9	66	61	38	37	1	36	62	0,7	0	22,6	-2,79	740,8
122	1143,5	1143,5	0,00	1143,5	1150,3	6,9	0,20	0,28	1100,9	84	59	41	24	1	24	75	0,7	0	20,8	-2,87	743,1
123	1142,0	1142,0	0,00	1142,0	1150,2	8,2	0,23	0,36	1101,5	85	60	40	24	1	24	75	0,6	0	22,3	-2,83	743,3
124	1140,1	1140,1	0,00	1140,1	1143,7	3,6	0,08	0,12	1093,4	67	46	37	36	2	36	63	0,8	0	24,2	-3,17	739,0
125	1137,3	1137,3	0,00	1137,3	1142,7	5,4	0,14	0,21	1093,0	81	44	37	27	1	27	72	0,7	0	27,0	-3,26	743,1
126	1140,8	1140,8	0,00	1140,8	1147,3	6,5	0,12	0,18	1097,0	68	52	42	36	1	35	63	0,7	0	23,5	-2,98	739,1
127	1139,5	1139,6	0,00	1139,6	1146,7	7,1	0,23	0,33	1096,5	84	53	39	23	1	23	75	0,7	0	24,7	-3,09	738,5
128	1139,2	1139,2	0,00	1139,2	1146,5	7,3	0,16	0,30	1096,1	73	65	41	31	1	30	69	0,7	0	25,1	-2,76	738,9
129	1141,3	1141,3	0,00	1141,3	1145,8	4,5	0,10	0,20	1098,3	90	34	33	35	1	34	64	0,7	0	23,0	-3,60	738,0
130	1147,3	1145,9	-0,18	1144,2	1147,8	3,6	0,08	0,15	1095,8	61	33	45	37	18	31	51	17,7	15	20,1	-3,59	752,0
131	1141,2	1141,2	0,00	1141,2	1147,3	6,1	0,12	0,22	1098,1	73	55	36	34	1	33	65	0,7	0	23,1	-3,00	738,9
132	1140,1	1140,1	0,00	1140,1	1146,1	6,1	0,11	0,31	1095,9	65	70	38	37	1	37	62	0,7	0	24,2	-2,64	741,6
133	1139,6	1139,7	0,00	1139,7	1146,4	6,7	0,18	0,28	1095,5	79	58	39	26	1	26	73	0,7	0	24,6	-2,93	742,9
134	1137,0	1137,0	0,00	1137,0	1142,1	5,1	0,13	0,21	1093,7	84	49	38	27	1	26	72	0,7	0	27,3	-3,08	740,2
135	1138,5	1138,5	0,00	1138,5	1144,5	6,0	0,15	0,20	1097,6	84	45	36	27	1	26	72	0,6	0	25,8	-3,20	739,9
136	1138,4	1138,4	0,00	1138,4	1143,8	5,4	0,12	0,19	1097,8	82	54	35	28	1	28	71	0,6	0	25,9	-2,97	739,7
137	1138,1	1138,1	0,00	1138,1	1145,9	7,8	0,17	0,27	1093,3	69	52	44	33	1	33	66	0,7	0	26,3	-3,08	737,4
138	1137,5	1137,5	0,00	1137,5	1145,6	8,1	0,22	0,29	1097,9	84	53	36	26	1	25	73	0,7	0	26,8	-3,02	737,8
139	1144,9	1145,0	0,00	1145,0	1147,5	2,5	0,10	0,19	1097,7	94	44	37	17	1	16	82	0,6	0	19,3	-3,19	740,9
140	1150,0	1149,1	-0,18	1148,1	1149,0	1,0	0,09	0,10	1096,7	97	82	34	8	10	7	83	9,4	0	16,3	-2,49	738,7
141	1139,5	1139,6	0,00	1139,6	1146,9	7,3	0,21	0,34	1094,3	81	61	40	25	1	24	74	0,7	0	24,7	-2,85	738,4
142	1138,2	1138,2	0,00	1138,2	1142,5	4,3	0,12	0,17	1093,8	84	50	37	25	1	25	74	0,7	0	26,1	-3,04	745,6
143	1139,4	1139,4	0,00	1139,4	1142,9	3,6	0,10	0,16	1095,4	83	49	37	26	1	26	73	0,7	0	24,9	-3,08	745,0
144	1136,8	1136,8	0,00	1136,8	1146,2	9,4	0,17	0,31	1095,5	84	55	43	38	1	37	62	0,7	0	27,5	-2,90	741,0
145	1139,5	1139,5	0,00	1139,5	1144,4	4,9	0,11	0,18	1093,5	73	48	36	32	1	32	67	0,7	0	24,8	-3,15	735,5
146	1139,9	1139,9	0,00	1139,9	1147,0	7,0	0,17	0,27	1099,4	80	67	36	27	1	27	72	0,7	0	24,4	-2,72	744,5
147	1139,1	1139,1	0,00	1139,1	1142,9	3,8	0,10	0,16	1094,9	83	54	34	27	1	26	72	0,7	0	25,2	-3,01	745,2

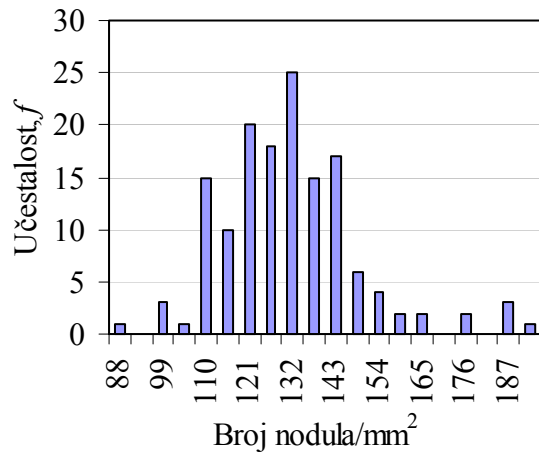


Prilog 16. Razdioba važnijih toplinskih parametara s krivulja hlađenja pripremljenih nodularnih ljevova (1. dio)



Prilog 17. Razdioba važnijih toplinskih parametara s krivulja hlađenja pripremljenih nodularnih ljevova (2. dio)



Prilog 21. Razdioba mikrostrukturnih parametara pripremljenih nodularnih ljevova



Prilog 22. Matrice početnih vrijednosti težinskih koeficijenata skrivenog sloja neuronske mreže

0,27704	0,15400	0,27658	0,24532	0,09926	0,11261	0,12195	0,15664	-0,06972	0,07352	0,20289	-0,25395	0,16128
-0,14290	0,05226	0,11458	-0,19803	0,28456	0,15923	-0,21640	0,01987	0,19217	-0,01851	-0,24937	-0,13111	-0,29114
-0,19392	0,03186	0,24564	0,14872	-0,17931	0,30080	0,20837	0,17924	-0,02327	-0,22587	0,09816	0,11037	-0,08874
-0,07069	0,07325	-0,07225	-0,10174	0,07629	-0,08378	-0,03030	0,09493	-0,26194	-0,02672	-0,34225	0,07248	0,37361
0,24014	-0,17282	0,35573	-0,02458	0,24550	-0,20993	0,13260	-0,08513	-0,07340	0,13472	-0,01571	-0,24329	0,24480
-0,22234	-0,14944	-0,30015	-0,24906	-0,13095	0,12856	0,29661	0,10257	0,06800	-0,09502	0,10874	0,21308	0,21998
0,00869	-0,05692	0,03077	0,05079	0,01208	0,34446	-0,12421	0,21682	-0,00382	0,13270	-0,32808	-0,01024	-0,26401
-0,04233	0,03323	0,04264	-0,08667	0,09365	-0,23689	0,17398	-0,15455	-0,18564	-0,13661	-0,02682	0,27662	0,34440
-0,15395	-0,12672	-0,20066	0,19793	-0,06776	-0,32742	0,11236	0,07748	-0,13504	0,12052	-0,31878	0,18460	0,08983
-0,11868	0,17459	-0,13478	0,22378	-0,01027	-0,01674	0,15264	-0,09427	0,23770	0,13966	0,06771	0,12255	-0,34850
0,28608	-0,05151	-0,33967	-0,06638	0,14371	-0,24399	-0,31000	0,05120	-0,04981	0,11058	0,04114	0,27828	-0,24506
0,21815	-0,24305	0,03944	-0,15810	-0,24194	0,10170	0,10948	-0,01422	-0,15141	0,06541	-0,17214	-0,21895	0,31272
0,22710	0,03140	0,20983	-0,07119	-0,20960	0,21726	0,22409	0,11754	-0,14441	0,18560	-0,13035	-0,17177	0,27682
-0,03750	0,03200	-0,32917	0,31544	-0,08808	-0,03022	0,08482	-0,10683	0,06227	-0,19598	-0,35897	0,17916	0,08719
0,31118	-0,19319	-0,36012	-0,01608	0,15583	0,03114	0,25027	0,07826	0,12434	-0,19759	-0,10097	-0,15489	-0,14048
-0,23940	-0,16752	-0,29790	-0,06598	0,22102	-0,23022	-0,27647	-0,05155	-0,15571	0,13378	0,14180	-0,01917	-0,17176
-0,35770	0,22125	0,28106	0,16674	-0,01430	-0,00409	0,20784	-0,00899	-0,16465	-0,23268	0,05210	-0,10535	-0,04043
-0,11549	-0,13814	-0,35692	-0,08704	-0,26595	-0,06192	0,11158	-0,01357	0,18298	0,02281	-0,07162	-0,36169	0,12939
-0,10817	-0,15702	0,34691	0,26221	-0,01072	-0,14422	-0,23388	0,08274	0,11350	-0,16969	-0,21922	-0,11334	-0,21299
-0,01597	-0,27957	0,01552	-0,24228	0,34515	-0,17062	0,02499	-0,12209	0,04154	0,06366	0,01025	-0,20173	-0,03124
0,38422	0,05392	0,40000	-0,08254	-0,08390	0,16864	-0,19578	0,08352	0,07632	-0,10888	0,14708	0,32242	-0,00205
-0,10625	0,01935	-0,26912	0,21508	-0,08943	-0,22017	0,02749	0,11542	0,15804	-0,17606	0,20818	0,21754	-0,27947
-0,20234	-0,20522	-0,38958	0,00997	0,17305	-0,28098	-0,30741	-0,03421	0,02072	0,00355	0,16665	-0,09801	0,21320
0,06957	0,06968	-0,10354	-0,25715	-0,12878	0,14696	0,06105	-0,02896	0,11425	0,20159	0,34159	-0,14499	-0,36418
0,02094	-0,03128	-0,08121	0,15921	-0,22060	0,18997	-0,06304	0,18855	0,04903	0,06538	0,27291	-0,28674	-0,28917
-0,23319	-0,18645	-0,07202	-0,26282	0,10247	0,08883	-0,18477	0,12415	0,17024	-0,20125	-0,00828	-0,14334	0,18772
-0,01023	-0,05865	-0,06261	0,05938	-0,13755	0,18942	-0,27883	0,07014	-0,17079	0,21756	0,25539	0,24075	-0,21431
-0,00301	-0,11906	-0,09918	0,26754	-0,02505	-0,07805	-0,27652	-0,06990	0,18664	-0,16205	-0,30895	-0,10715	-0,18551
0,28584	0,21962	0,35764	-0,06543	0,22189	-0,13101	-0,13457	0,12887	-0,12368	0,17423	0,09597	0,04828	-0,08424
0,22821	0,05990	0,13369	0,13217	0,22040	-0,07823	0,28150	0,16478	0,15460	0,05516	0,27878	-0,18716	-0,01407

$W_1 =$

$b_1 =$

-2,73700	0,97883	1,32530	1,92160	-1,77740	0,70324	-2,01160	1,94280	0,67680	0,111741	-0,62654	0,14428	-0,46951	0,59481	-0,78136	0,47423	0,83091	-0,36631	-0,96643	-0,90284	0,22274	-1,27710	-1,08560	1,17560	0,77149	-2,14580	-1,14680	-1,59750	1,20760	-0,01381
----------	---------	---------	---------	----------	---------	----------	---------	---------	----------	----------	---------	----------	---------	----------	---------	---------	----------	----------	----------	---------	----------	----------	---------	---------	----------	----------	----------	---------	----------

Prilog 23. Matrice početnih vrijednosti težinskih koeficijenata izlaznog sloja neuronske mreže

$$\mathbf{W}_2 = \begin{bmatrix} 0,01858 & -0,28156 & -0,44628 & -0,11137 & 0,88813 & -0,38269 & -0,89194 & -0,92603 & 0,17488 & -0,27103 & 0,56513 & 0,57758 & 0,83843 \\ 0,24959 & -0,44802 & 0,15768 & -0,15354 & 0,82416 & 0,11639 & -0,77034 & -0,37489 & 0,84837 & 0,95143 & -0,06704 & 0,26889 & 0,56101 & \dots \\ 0,25109 & 0,35623 & 0,64567 & 0,99240 & 0,62995 & 0,27352 & 0,69198 & 0,63456 & -0,33990 & 0,43379 & -0,53545 & 0,31957 & -0,34658 \\ 0,98233 & 0,01753 & 0,88291 & 0,22824 & 0,37927 & 0,53816 & -0,65523 & -0,53073 & -0,58892 & 0,28662 & -0,36424 & 0,07517 & 0,47750 \\ \dots & -0,12453 & 0,24371 & -0,77870 & 0,35742 & -0,73676 & -0,33710 & -0,34147 & 0,96601 & -0,33661 & 0,28680 & 0,48777 & 0,73468 & -0,39608 \\ 0,18359 & 0,78911 & -0,19396 & 0,95958 & 0,68978 & 0,15047 & -0,02400 & 0,93140 & -0,98448 & -0,35545 & -0,40267 & 0,24988 & -0,69536 & \dots \\ -0,77098 & 0,92717 & -0,80561 & -0,20113 & -0,53455 & -0,72636 & -0,13693 & 0,89703 & -0,66832 & -0,94726 & -0,63755 & -0,88960 & -0,38166 \\ -0,36167 & -0,95987 & -0,41390 & 0,64177 & -0,86569 & 0,73560 & -0,47892 & -0,09656 & 0,65633 & -0,28911 & -0,16962 & -0,19181 & -0,99348 \\ \dots & -0,12518 & -0,67472 & -0,11619 & 0,10405 & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots \\ 0,35282 & 0,10409 & -0,91040 & 0,86860 & \mathbf{b}_2 = & \begin{bmatrix} 0,39985 \\ 0,87819 \\ -0,09583 \\ -0,64666 \end{bmatrix} \\ 0,64583 & 0,05019 & 0,92917 & 0,79722 & & & & & & & & & & & \\ 0,51169 & 0,83871 & -0,97308 & 0,23598 & & & & & & & & & & & \end{bmatrix}$$

Prilog 24. Matrice konačnih vrijednosti težinskih koeficijenata skrivenog sloja (\mathbf{W}_1 , \mathbf{b}_1) i izlaznog sloja (\mathbf{W}_2 , \mathbf{b}_2) neuronske mreže za predviđanje nodularnosti na temelju odabranih parametara toplinske analize

$$\mathbf{W}_1 = \begin{bmatrix} -1,07430 & 4,81770 & -1,57080 & 6,20810 & -1,70620 & -0,92040 & -1,85860 & 3,86720 \\ 3,38380 & -4,04010 & 0,35007 & 2,54660 & 0,45103 & -1,06730 & 1,49720 & -3,20080 \\ 0,99480 & 3,14510 & 0,78520 & -0,90117 & -0,49055 & -4,45580 & 5,64840 & 2,54310 \\ 0,78043 & -2,72010 & 1,75850 & 3,57290 & 0,69249 & 0,16038 & 2,03900 & 4,71340 \\ 0,93187 & -2,63200 & -1,28250 & -1,91930 & 5,64260 & -0,90373 & 3,18560 & -3,63020 \\ -5,33000 & 1,15420 & -0,09037 & 0,28158 & 0,00327 & -0,17628 & 0,89570 & -1,61260 \end{bmatrix} \quad \mathbf{b}_1 = \begin{bmatrix} -3,97810 \\ 4,48330 \\ 1,15070 \\ -0,99643 \\ 1,70760 \\ -6,77100 \end{bmatrix}$$

$$\mathbf{W}_2 = \begin{bmatrix} 0,10670 & 0,88321 & -0,17128 & -0,08984 & -0,05695 & -1,42800 \end{bmatrix} \quad \mathbf{b}_2 = \begin{bmatrix} -1,57430 \end{bmatrix}$$

Prilog 25. Matrice konačnih vrijednosti težinskih koeficijenata skrivenog sloja (\mathbf{W}_1 , \mathbf{b}_1) i izlaznog sloja (\mathbf{W}_2 , \mathbf{b}_2) neuronske mreže za predviđanje broja nodula po jedinici površine na temelju odabranih parametara toplinske analize

$$\mathbf{W}_1 = \begin{bmatrix} 0,46780 & -0,45738 & 0,32286 & -0,17020 & 0,16917 & 0,47283 & 0,20209 & 0,14160 \\ 1,55580 & 0,34142 & 0,21229 & -0,33153 & -1,48090 & -0,49318 & 1,91980 & -3,30050 \\ 8,07120 & -0,05561 & 3,28340 & 4,04750 & 3,52170 & -4,97950 & -4,14190 & -1,02280 \\ -7,41510 & 2,33070 & 0,05476 & -0,15204 & 0,01278 & -0,08382 & 0,91283 & -0,04601 \\ 1,00430 & 2,90610 & 2,50020 & 2,36650 & 1,61210 & -2,69910 & -5,55860 & 0,07033 \end{bmatrix} \quad \mathbf{b}_1 = \begin{bmatrix} -3,67390 \\ 4,27720 \\ -0,81497 \\ -6,09360 \\ -5,00460 \end{bmatrix}$$

$$\mathbf{W}_2 = \begin{bmatrix} 0,69103 & 1,22830 & -0,53976 & -0,81200 & 0,85334 \end{bmatrix} \quad \mathbf{b}_2 = \begin{bmatrix} -0,42135 \end{bmatrix}$$

Prilog 26. Matrice konačnih vrijednosti težinskih koeficijenata skrivenog sloja (\mathbf{W}_1 , \mathbf{b}_1) i izlaznog sloja (\mathbf{W}_2 , \mathbf{b}_2) neuronske mreže za predviđanje udjela feritana temelju odabranih parametara toplinske analize

$$\mathbf{W}_1 = \begin{bmatrix} 0,19828 & -0,34471 & 0,00246 & -0,22748 & -0,03297 & 0,00893 & -0,27802 & 0,40142 \\ 0,76783 & 0,75037 & 0,33337 & -0,27552 & -0,48077 & -0,18075 & 0,13183 & -2,27630 \\ -0,10343 & 0,05337 & 0,05896 & -0,20248 & 0,33567 & -0,24628 & 0,36076 & 0,58040 \\ 0,48838 & 0,23137 & 0,24913 & -0,21585 & -0,15186 & -0,29885 & 0,43797 & -0,88535 \\ -0,14400 & 0,11720 & 0,00664 & -0,28643 & -0,11936 & -0,34413 & -0,26156 & 0,76714 \end{bmatrix} \quad \mathbf{b}_1 = \begin{bmatrix} -3,22340 \\ 1,71820 \\ -1,02270 \\ 0,73306 \\ -1,53340 \end{bmatrix}$$

$$\mathbf{W}_2 = \begin{bmatrix} -0,51855 & 0,99670 & 0,62615 & -0,76870 & 0,80990 \end{bmatrix} \quad \mathbf{b}_2 = \begin{bmatrix} 0,78232 \end{bmatrix}$$

Prilog 27. Matrice konačnih vrijednosti težinskih koeficijenata skrivenog sloja (\mathbf{W}_1 , \mathbf{b}_1) i izlaznog sloja (\mathbf{W}_2 , \mathbf{b}_2) neuronske mreže za predviđanje vlačne čvrstoće na temelju odabranih parametara toplinske analize

$$\mathbf{W}_1 = \begin{bmatrix} 0,14646 & -0,29094 & -0,02692 & -0,21660 & -0,24606 & -0,17359 & -0,46555 & 0,47699 \\ -0,35891 & 1,06970 & 1,59420 & -0,19283 & -1,00620 & -0,37081 & -0,15479 & -0,06995 \\ 0,54709 & -0,65718 & 0,71856 & -0,24851 & -0,87119 & -0,21228 & -0,33855 & -1,59510 \\ -0,74841 & 0,10175 & 0,42054 & 0,11763 & -0,17802 & 0,60959 & 1,10460 & 0,60426 \\ 0,02545 & -0,17422 & 0,44992 & 0,82779 & -0,02458 & 0,44749 & -1,19470 & -1,83840 \\ 0,43284 & 0,07649 & 1,24720 & 0,27900 & 1,25240 & -1,17200 & 0,58368 & 0,19225 \\ -0,14648 & -0,08637 & 0,63196 & 0,00847 & 0,28881 & -1,36790 & 0,08516 & 1,02650 \\ -0,43868 & 0,01993 & -0,13711 & 0,03387 & 0,23288 & -0,08627 & -0,04529 & 0,63982 \\ 0,24286 & -0,09543 & -0,84185 & -0,45078 & 0,14126 & -0,58524 & 0,10336 & -0,27447 \\ 0,58090 & 0,74921 & 0,13128 & 0,00522 & -0,70121 & -0,95216 & -0,20962 & -1,44000 \\ 1,08210 & 0,19277 & -1,17290 & 0,20221 & -1,16480 & 0,92312 & -0,76735 & -2,15870 \\ 1,33540 & 0,23517 & -0,25942 & -0,00712 & -0,87729 & -1,51160 & -0,31553 & -0,81586 \end{bmatrix}$$

$$\mathbf{b}_1 =$$

$$\begin{bmatrix} -3,11000 \\ 2,82250 \\ -2,26470 \\ 2,22960 \\ -2,63890 \\ -1,86420 \\ 2,62920 \\ 2,59470 \\ -1,62830 \\ 1,01360 \\ -2,48850 \\ -0,56161 \end{bmatrix}$$

$$\mathbf{W}_2 = \begin{bmatrix} -0,59370 & 1,05970 & -0,51973 & -0,02005 & 2,33860 & -1,07310 & -0,16975 & -0,01296 & 0,53577 & -0,26581 & 1,22390 & -0,31421 \end{bmatrix}$$

$$\mathbf{b}_2 = \begin{bmatrix} 0,72003 \end{bmatrix}$$

Prilog 28. Matrice konačnih vrijednosti težinskih koeficijenata skrivenog sloja (\mathbf{W}_1 , \mathbf{b}_1) i izlaznog sloja (\mathbf{W}_2 , \mathbf{b}_2) neuronske mreže za predviđanje konvencionalne granice razvlačenja na temelju odabranih parametara toplinske analize

$$\mathbf{W}_1 = \begin{bmatrix} 0,13999 & -0,14934 & -0,14531 & -0,21950 & -0,49258 & -0,34259 & -0,69857 & 0,60716 \\ -0,40070 & 0,81604 & 1,98060 & -0,68412 & -0,60080 & -0,39951 & -0,32104 & 0,34167 \\ 0,65166 & -0,58636 & 1,39560 & 0,12359 & -0,23037 & -0,67172 & -0,92219 & -1,36930 \\ -0,09354 & 0,30028 & -0,00045 & 0,40321 & -0,25031 & -0,18121 & 0,44556 & 0,88467 \\ 0,15490 & 0,48342 & 0,67464 & 0,50090 & 0,25272 & 0,34117 & -0,91085 & -0,75143 \\ 0,36071 & 0,66300 & 0,51334 & 1,00610 & 1,13380 & -0,60521 & 0,05757 & 0,10480 \\ -0,66471 & -0,20283 & 0,67107 & -0,54361 & 0,28322 & -0,39968 & -0,09491 & 0,73738 \\ -0,33929 & 0,01061 & -0,18341 & -0,03215 & 0,30102 & -0,14794 & -0,13943 & 0,58431 \\ 0,52918 & -0,06933 & -0,26131 & -0,53606 & -0,20220 & -0,16528 & 0,30432 & 0,20885 \\ 0,37945 & 0,57350 & -0,35614 & 0,80730 & -1,14500 & -1,52520 & -1,37940 & 0,75236 \\ 1,03730 & 1,05770 & 0,40544 & 1,00130 & -1,40830 & -0,02097 & -0,99205 & -1,87220 \\ 0,49676 & 0,31630 & 0,54255 & -0,17687 & -0,46162 & -0,51148 & -0,34377 & -0,47996 \end{bmatrix}$$

 $\mathbf{b}_1 =$

$$\begin{bmatrix} -3,01330 \\ 3,00550 \\ -2,39100 \\ 1,57560 \\ -2,05210 \\ -2,26420 \\ 2,72540 \\ 2,46850 \\ -1,93810 \\ 1,26580 \\ -2,19140 \\ -0,37293 \end{bmatrix}$$

$$\mathbf{W}_2 = \begin{bmatrix} -0,59970 & 1,18520 & 0,72989 & 0,04489 & 0,76769 & -1,02540 & -1,11250 & 0,34946 & 0,59034 & 0,03285 & 1,36820 & -0,71790 \end{bmatrix}$$

$$\mathbf{b}_2 = \begin{bmatrix} 0,62208 \end{bmatrix}$$

Prilog 29. Matrice konačnih vrijednosti težinskih koeficijenata skrivenog sloja (\mathbf{W}_1 , \mathbf{b}_1) i izlaznog sloja (\mathbf{W}_2 , \mathbf{b}_2) neuronske mreže za predviđanje istezljivosti na temelju odabranih parametara toplinske analize

$$\mathbf{W}_1 = \begin{bmatrix} 0,14088 & -0,30852 & -0,05329 & -0,20713 & -0,11146 & -0,09654 & -0,34526 & 0,47157 \\ 0,44162 & -0,15723 & 0,81407 & 0,41476 & 0,41765 & 0,74369 & -0,90699 & -1,64580 \\ 0,20388 & 1,21710 & 0,80469 & -1,31050 & 0,83184 & -1,14070 & 0,62377 & 0,08834 \\ 0,23893 & 0,44630 & 0,29642 & -0,36109 & -0,11898 & -1,36280 & 1,15360 & -0,58719 \\ 0,29174 & 0,50549 & 0,15199 & -0,74203 & 0,30264 & -0,21477 & -0,62206 & -0,41372 \\ 0,37020 & -0,25813 & 0,80649 & -0,16099 & 2,00390 & -0,80467 & 0,15115 & 1,16720 \end{bmatrix} \quad \mathbf{b}_1 = \begin{bmatrix} -3,13890 \\ 1,43050 \\ -1,35720 \\ -1,07490 \\ -2,07320 \\ -1,69880 \end{bmatrix}$$

$$\mathbf{W}_2 = \begin{bmatrix} 0,38116 & 1,08940 & 1,58690 & -2,39630 & 1,45360 & -1,29130 \end{bmatrix} \quad \mathbf{b}_2 = \begin{bmatrix} -0,26899 \end{bmatrix}$$

Prilog 30. Matrice konačnih vrijednosti težinskih koeficijenata skrivenog sloja (\mathbf{W}_1 , \mathbf{b}_1) i izlaznog sloja (\mathbf{W}_2 , \mathbf{b}_2) neuronske mreže za predviđanje tvrdoće na temelju odabranih parametara toplinske analize

$$\mathbf{W}_1 = \begin{bmatrix} 0,66137 & -0,12092 & -0,12493 & -0,17173 & -0,01964 & -0,08876 & -0,47431 & -0,22492 \\ -1,48990 & -1,75200 & 1,06310 & -1,43210 & 0,35321 & 2,45160 & 4,57220 & 1,64050 \\ 1,69450 & -2,66390 & -1,10810 & 3,41950 & -0,62476 & -0,13362 & -0,31743 & -6,20350 \\ 0,49115 & -1,89790 & -0,58168 & 0,26857 & 0,39707 & 0,00336 & 1,28460 & 1,45470 \\ 0,53961 & -0,52642 & -0,15501 & 2,19970 & 2,01240 & 0,53565 & 1,49060 & -5,95580 \\ 2,18590 & 1,37090 & 0,39075 & 2,02860 & -3,08790 & -0,27742 & -1,46240 & -4,79370 \end{bmatrix} \quad \mathbf{b}_1 = \begin{bmatrix} -3,77860 \\ 3,78670 \\ -3,54370 \\ -0,85565 \\ -2,10160 \\ -4,36040 \end{bmatrix}$$

$$\mathbf{W}_2 = \begin{bmatrix} -0,97515 & 0,12266 & 0,08112 & 0,56561 & 0,07930 & 0,90385 \end{bmatrix} \quad \mathbf{b}_2 = \begin{bmatrix} -0,07152 \end{bmatrix}$$

Prilog 31. Matrice konačnih vrijednosti težinskih koeficijenata skrivenog sloja (\mathbf{W}_1 , \mathbf{b}_1) i izlaznog sloja (\mathbf{W}_2 , \mathbf{b}_2) neuronske mreže za predviđanje vlačne čvrstoće na temelju mikrostrukture

$$\mathbf{W}_1 = \begin{bmatrix} -0,65435 & 2,20300 & 0,96073 \\ 2,11830 & -11,32900 & -16,87900 \\ 1,29310 & -0,83389 & 2,96410 \end{bmatrix} \quad \mathbf{b}_1 = \begin{bmatrix} -0,73841 \\ 9,81250 \\ -1,10400 \end{bmatrix}$$

$$\mathbf{W}_2 = \begin{bmatrix} -0,60862 & 0,10043 & 0,36977 \end{bmatrix} \quad \mathbf{b}_2 = \begin{bmatrix} -0,07523 \end{bmatrix}$$

ŽIVOTOPIS

Irena Žmak rođena je 1974. godine u Puli, gdje je završila osnovnu školu i prirodoslovno – matematičku gimnaziju.

Studij strojarstva na Fakultetu strojarstva i brodogradnje u Zagrebu upisala je akademske godine 1992./93. Od druge godine studija bila je demonstrator na Zavodu za materijale. Za studentske je radove nagrađena dvjema Rektorovim nagradama. Nagradu "Davorin Bazjanac" za uzoran uspjeh u 4. godini studija strojarstva primila je od Fakulteta. Iste joj je godine dodijeljena Dekanska nagrada, kao najboljem studentu Fakulteta u toj akademskoj godini. Diplomirala je na smjeru Proizvodno strojarstvo, usmjerenje Automatizacija i robotika 1998. godine s izvrsnim uspjehom i s najvišim prosjekom ocjena na smjeru Proizvodno strojarstvo za tu godinu. Prigodom promocije dodijeljena joj je Medalja Fakulteta strojarstva i brodogradnje za izvanredan uspjeh u studiju.

Od 1999. godine zaposlena je kao znanstvena novakinja – mlađa asistentica u Zavodu za materijale Fakulteta strojarstva i brodogradnje. Završila je poslijediplomski studij "Materijali u strojarstvu" obranivši 2003. godine magistarski rad "Predviđanje svojstava materijala neuronskim mrežama".

Radila je na znanstveno – istraživačkim projektima Ministarstva znanosti, obrazovanja i športa Republike Hrvatske "Računalne simulacije i razvoj materijala", "Razvoj materijala i procesa računalnim modeliranjem" i na tehnologijskim projektima "SUMAT – Razvoj i primjena suvremenih materijala" i "Identifikacija čelika prema kemijskom sastavu i standardnim oznakama". Trenutno radi na projektu Ministarstva "Modeliranje svojstava materijala i parametara procesa". Objavila je dva poglavlja u knjizi, jedan izvorni znanstveni rad u CC časopisu, jedan u drugim časopisima, 8 na znanstvenim skupovima s međunarodnom recenzijom i dva na ostalim skupovima.

Govori engleski, talijanski i njemački. 2001. godine Deutscher Akademischer Austauschdienst (DAAD) dodijelio joj je stipendiju za usavršavanje znanja njemačkog jezika, uz pomoć koje je završila stupanj "Mittelstufe 2" u Düsseldorfu.

Članica je Hrvatskog društva za materijale i tribologiju. Udana je i majka jedne kćeri.

BIOGRAPHY

Irena Žmak was born in 1974 in Pula, where she completed primary school and grammar school of natural sciences and mathematics.

She enrolled in mechanical engineering study at the Faculty of Mechanical Engineering and Naval Architecture, University of Zagreb in the academic year 1992/93. During the studies she worked as student tutor at the Department for Materials. She received two Rector's prizes for the best student's paper. She was awarded the "Davorin Bazjanac" award for being the best student of the 4th year of study of mechanical engineering in the academic year. She was also awarded the Dean's prize for being the best student of the Faculty that year. She graduated Production Engineering in 1998, at the course Automation and Robotics with excellent degree. Her final average note was the best average note among graduated students of Production Engineering in 1998. At the graduation ceremony she received the Medal of the Faculty of Mechanical Engineering and Naval Architecture for achieving remarkable success in studies.

Since 1999 she works as junior research assistant at the Department for Materials at the Faculty of Mechanical Engineering and Naval Architecture. In 2003 she completed the postgraduate study "Materials in Engineering" at the Faculty of Mechanical Engineering and Naval Architecture. Her master's thesis was entitled "Predicting material properties by neural networks".

She worked on the scientific projects "Computer Simulation and Development of Materials", and "Development of Materials and Processes with Computer Modeling", financed by the Croatian Ministry of Science, Education and Sports. She also took part on two technological projects "SUMAT – Development and Application of Modern Materials", and "Steel identification according to chemical composition and standard designations". At the present time she works on the project "Modeling of material properties and process parameters", financed by the Ministry. She published two book chapters, one journal article in CC journals, one scientific paper in other journals, 8 scientific conference papers with international peer-review, and two refereed conference papers.

She speaks good English, Italian and German. In 2001 the DAAD foundation (Deutscher Akademischer Austauschdienst) awarded her a scholarship for improving

German language skills, by which she completed the level "Mittelstufe 2" in Düsseldorf, Germany.

She is a member of the Croatian society for materials and tribology. She is married and mother to one daughter.

LITERATURA

- [1] J. Kusiak, R. Kuziak, Modelling of microstructure and mechanical properties of steel using the artificial neural network, *Journal of Materials Processing and Technology*, **127**(2002), str. 115-121.
- [2] K. Genel, I. Obzek, A. Kurt, C. Bindal, Boriding response of AISI W1 steel and use of artificial neural network for prediction of borided layer properties, *Surface and coatings technology*, **160**(2002), str. 38-43.
- [3] M. E. Haque, K. V. Sudhakar, ANN back-propagation model for fracture toughness in microalloy steel, *Inter. Journal of Fatigue*, **24**(2002), str. 1003-1010.
- [4] T. Filetin, I. Žmak, D. Novak, Nitriding parameters analyzed by neural network and genetic algorithm, *Journal de Physique IV.*, **120**(2004), str. 355-362.
- [5] L. A. Dobrzański, W. Sitek, J. Załona, The modelling of hardenability using neural networks, *Journal of Materials Processing Technology*, **92-93**(1999), str. 8-14.
- [6] T. Filetin, D. Majetić, I. Žmak, Predicting the hardenability of steels using neural network, *Proceedings of the 7th International Scientific Conference: Achievements in Mechanical & Materials Engineering - AMME '98*, str. 151-154, Gliwice - Zakopane, Poljska, studeni 1998.
- [7] T. Filetin, I. Žmak, D. Markučič, D. Novak, Determination of the physical properties of heat treatable steels, *Proceedings of the 8th Seminar of the International Federation for Heat Treatment and Surface Engineering*, str. 399-406, Dubrovnik, rujan 2001.
- [8] M. A. Yescas, H. K. D. H. Bhadeshia, D. J. MacKay, Estimation of the amount of retained austenite in austempered ductile irons using neural networks, *Materials Science and Engineering*, **A311**(2001), str. 162-173.
- [9] M. Perzyk, A. W. Kochanski, Prediction of ductile cast iron quality by artificial neural networks, *Journal of Materials Processing Technology*, **109**(2001), str. 305-307.
- [10] R. B. Yao, C. X. Tang, G. X. Sun, Predicting gray cast iron properties with artificial neural network, *AFS Trans.*, **104**(1996), str. 635-642.

- [11] B. Koroušić, Upotreba termičke analize u proučavanju fizikalnih svojstava metala, *Ljevarstvo* **34**(1992) 1, str. 3-6.
- [12] C. Labrecque, M. Gagné, Interpretation of cooling curves of cast irons: A literature review, *AFS Trans.*, **106**(1998), str. 83-90.
- [13] U. Ekpoom, R. W. Heine, Thermal analysis by differential heat analysis (DHA) of cast iron, *AFS Trans.*, **85**(1981), str. 27-38.
- [14] E. F. Ryntz, J. F. Janowak, A. W. Hochstein, C. A. Wargek, Prediction of nodular iron microstructure using thermal analysis, *AFS Trans.*, **79**(1971), str. 141-144.
- [15] X. Guo, D. M. Stefanescu, A mechanical properties model for ductile iron, *AFS Trans.*, **99**(1997), str. 47-53.
- [16] R. V. Sillén, Optimizing iron quality through artificial intelligence, *Modern Casting*, **11**(1996), str. 43-45.
- [17] Z. Glavaš, D. Lisjak, F. Unkić, The application of artificial neural network in the prediction of the as-cast impact toughness of spheroidal graphite cast iron, *Kovove Materialy - Metallic Materials* **45**(2007) 1, str. 41-49.
- [18] M. Gagné, *The Sorelmetal Book of Ductile Iron*, Rio Tinto Iron & Titanium, Montreal, Kanada, 2004.
- [19] G. Engels, Half a century of foundry technical progress in the mirror of GIFA, *Proceedings of the 43rd Foundry Conference*, CD-ROM izdanje, rad br. 2, Portorož, Slovenija, rujan 2003.
- [20] 41st Census of World Casting Production--2006: Global casting production surpasses 90 million tons, *Modern Casting*, prosinac 2007, str. 22-25.
- [21] F. Unkić, Metal casting production in Croatia, *Proceedings of the 43rd Foundry Conference*, CD-ROM izdanje, rad br. 6, Portorož, Slovenija, rujan 2003.
- [22] nHRN EN 1563 - Hrvatski normativni dokument: Ljevarstvo -- Nodularni ljevovi (EN 1563:1997+A1:2002)
- [23] HRN EN 1560:2004 - Hrvatski normativni dokument: Ljevarstvo -- Sustav označivanja željeznih ljevova -- Simboli i brojevi materijala (EN 1560:1997)
- [24] T. Filetin, F. Kovačiček, J. Indof, *Svojstva i primjena materijala*, Fakultet strojarstva i brodogradnje, Zagreb, 2002.

- [25] I. Kerekeš, Osnovi livarstva, Viša tehnička škola u Novom Sadu, Novi Sad, Srbija, 1997.
- [26] F. Unkić, N. Gavranović, M. Vasilić, Influence of Silicon content on the Mechanical Properties of As-cast and Heat Treated Samples of Nodular iron Grade EN-1563-GJS-400-18-LT, *Strojarstvo* **47**(2005) 1-2, str. 33-38.
- [27] L. Guerin, M. Gagne, Effects of Mn, Cu and Sn on the microstructure and properties of ductile iron castings, *The foundryman*, **80**(1987) 8/9, str. 336-344.
- [28] Effects of Minor and Trace Elements in Cast Iron, Technical information 12, Elkem ASA, Foundry Products Division, Oslo, Norveška, 2004.
- [29] HRN EN ISO 945:2002 - Hrvatski normativni dokument: Željezni lijev -- Označivanje mikrostrukture grafita (ISO 945:1975; EN ISO 945:1994).
- [30] Metals handbook, Ninth edition, Vol. 15, Casting, ASM International, Metals Park, Ohio, SAD, 1988.
- [31] L. Karbić, Metode proizvodnje žilavog lijeva, Ljevaonica i tvornica armatura Varaždin, Varaždin, 1973.
- [32] ASTM A439 - **83**(2004) Standard Specification for Austenitic Ductile Iron Castings.
- [33] Nodular Iron, <http://www.metallography.com/technotes/iron/nodular.htm>
- [34] Ž. Živković, B. Dobovišek, Diferencijalno termijska analiza – Teorija i primjena, Tehnički fakultet u Boru, Sveučilište u Beogradu, Bor, Srbija, 1984.
- [35] H. K. D. H. Bhadeshia, Thermal analysis techniques - Differential thermal analysis, Material Science and Metallurgy, University of Cambridge, Cambridge, Velika Britanija, www.msm.cam.ac.uk/phase-trans/2002/Thermal1.pdf
- [36] F. Unkić, Z. Glavaš, T. Vusić, M. Vasilić, Procjena kvalitete taljevine nodularnog lijeva pomoću toplinske analize, *Ljevarstvo*, **41**(1999) 1, str. 3-16.
- [37] Introduction to ATAS Verifier 4.0, NovaCast AB, Soft Center, Ronneby, Švedska, http://castiron.m78.com/NovaCast/Brochures/ATAS_Verifier_40_Eng.ppt
- [38] Z. Glavaš, F. Unkić, Š. Majstorović, Predviđanje vlačne čvrstoće vermikularnog lijeva toplinskom analizom, *Strojarstvo*, **47**(2005) 3-4, str. 77–85.

- [39] J. M. Frost, D. M. Stefanescu, Melt Quality Assessment of SG Iron Through Computer – Aided Cooling Curve Analysis, AFS Trans., **100**(1992), str. 189-200.
- [40] A. Moore, Rapid carbon determination using BCIRA carbon calculator, BCIRA Report **1126**(1973).
- [41] J. G. Humphreys, BCIRA Report **605**(1961).
- [42] W. Donald, A. Moore, Significance of carbon equivalent formulae and their applications in the foundry, BCIRA Report **1128**(1973).
- [43] M. Booth, Thermal analysis for composition determination of grey cast iron, British Foundryman, **76**(1982) 5, str. 35-45.
- [44] D. M. Stefanescu, Solidification of flake, compacted/vermicular and spheroidal graphite cast irons as revealed by thermal analysis and directional solidification, MRS symposium proceeding, Vol. 34, Elsevier Science Publishing Co., Stockholm, Švedska, 1985.
- [45] R. Monroe, C. E. Bates, Thermische Analyse zur Kontrolle der Graphitform bei Gußeisen mit Kugelgraphit, Giesserei-Praxis, **4**(1983), str. 53-58.
- [46] M. D. Chaudhari, R. W. Heine, C. R. Loper, Principles involved in the use of cooling curves in ductile iron process control, AFS Trans., **82**(1974), str. 431-440.
- [47] D. K. Banerjee, D. M. Stefanescu, Structural transitions and solidification kinetics of SG cast iron during directional solidification experiments, AFS Trans., **99**(1991), str. 747 - 759.
- [48] V. Popovski, Determining the Optimum Level of Inoculant Addition by Thermal Analysis - A Case Study, Ductile Iron News, prosinac 2004.
- [49] T. Skaland, Ductile iron shrinkage control through graphite nucleation and growth, <http://www.concrete.elkem.com/dav/d23d99065b.pdf>
- [50] M. Bartošová, Z. Gedeónová, A. Pribulová, P. Bartoš, Using thermal analysis to predict nodular graphite cast iron properties in the operating conditions, Proceedings of the 6th International Foundrymen Conference, Innovative foundry materials and technologies, CD-ROM izdanje, rad br. 5, Opatija, svibanj 2005.
- [51] M. T. Hagan, H. B. Demuth, H. Beale, Neural network design, PWS Publishing, Boston, MA, SAD, 1996.

- [52] H. Demuth, M. Beale, Neural Network Toolbox User's Guide, The MathWorks Inc., Natick, MA, SAD, 1992.
- [53] B. Novaković, D. Majetić, M. Široki: Umjetne neuronske mreže, Fakultet strojarstva i brodogradnje, Zagreb, 1998.
- [54] L. Fausett: Fundamentals of neural networks: architecture, algorithms, and applications, Prentice-Hall, Englewood cliffs, NJ, SAD, 1994.
- [55] I. Petrović, N. Perić, Inteligentno upravljanje sustavima, Fakultet elektrotehnike i računarstva, skripta, Zagreb, 2007.
- [56] I. Šošić, Vježbe iz statistike, Ekonomski fakultet, Zagreb, 1995.
- [57] S. Lončarić, Analiza i razumijevanje slike – Raspoznavanje uzoraka, ars.zesoi.fer.hr/predavanja/pdf/05RaspoznavanjeUzoraka.pdf
- [58] N. Bogunović, B. Dalbelo Bašić, Otkrivanje znanja u skupovima podataka - Metoda glavnih komponeneta, <http://www.zemris.fer.hr/predmeti/kdisc/bojana/biljeske-OZSP-pogl-1-2-3.pdf>
- [59] A. Fulgosi, Faktorska analiza, Školska knjiga, Zagreb, 1984.
- [60] D. Nguyen, B. Widrow, Improving the Learning Speed of Two-Layer Networks by Choosing Initial Values of the Adaptive Weights, International Joint Conference on Neural Networks, III:21-26., San Diego, CA, SAD, 1990.
- [61] R. Hecht-Nielsen, Neurocomputing, Addison-Wesley Publishing Company Inc., Reading, MA, SAD, 1990.
- [62] P. S. Agachi, Z. K. Nagy, M. V. Cristea, A. Imre–Lucaci, Model Based Control: Case Studies in Process Engineering, Wiley-VCH, Weinheim, Njemačka, 2006.
- [63] S. Hadživoković, R. Zegnal, K. Čobanović, Regresiona analiza, Privredni pregled, Beograd, Srbija, 1982.
- [64] E. W. Weisstein, Levenberg-Marquardt Method, MathWorld, A Wolfram Web Resource, <http://mathworld.wolfram.com/Levenberg-MarquardtMethod.html>
- [65] S. Haykin, Neural networks – A Comprehensive Foundation, Prentice Hall, SAD, 1999.

- [66] W. H. Press, B. P. Flannery, S. A. Teukolsky, W. T. Vetterling, Numerical Recipes In C: The Art Of Scientific Computing, Cambridge University Press, UK, 1988.-1992.
- [67] D. Gamberger, T. Šmuc, Pregled područja: popis pojmova, Data Mining Server, Institut Ruđer Bošković, Laboratorij za informacijske sustave, Zagreb, 2001., http://dms.irb.hr/tutorial/hr_tut_glosary.php
- [68] I. Šošić, V. Serdar, Uvod u statistiku, Školska knjiga, Zagreb, 2000.