

Procjena cikličkih i zamornih parametara čelika na osnovi njihovih monotonih značajki primjenom umjetnih neuronskih mreža

Marohnić, Tea

Doctoral thesis / Disertacija

2017

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Rijeka, Faculty of Engineering / Sveučilište u Rijeci, Tehnički fakultet**

Permanent link / Trajna poveznica: <https://um.nsk.hr/um:nbn:hr:190:774192>

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

Download date / Datum preuzimanja: **2025-01-24**



Repository / Repozitorij:

[Repository of the University of Rijeka, Faculty of Engineering](#)



SVEUČILIŠTE U RIJECI
TEHNIČKI FAKULTET

Tea Marohnić

**PROCJENA CIKLIČKIH I ZAMORNIH
PARAMETARA ČELIKA NA OSNOVI
NJIHOVIH MONOTONIH ZNAČAJKI
PRIMJENOM UMJETNIH
NEURONSKIH MREŽA**

DOKTORSKA DISERTACIJA

Rijeka, 2017.

SVEUČILIŠTE U RIJECI
TEHNIČKI FAKULTET

Tea Marohnić

**PROCJENA CIKLIČKIH I ZAMORNIH
PARAMETARA ČELIKA NA OSNOVI
NJIHOVIH MONOTONIH ZNAČAJKI
PRIMJENOM UMJETNIH
NEURONSKIH MREŽA**

DOKTORSKA DISERTACIJA

Mentor: izv. prof. dr. sc. Robert Basan

Rijeka, 2017.

UNIVERSITY OF RIJEKA
FACULTY OF ENGINEERING

Tea Marohnić

**ESTIMATION OF CYCLIC AND
FATIGUE PARAMETERS OF STEELS
BASED ON THEIR MONOTONIC
PROPERTIES USING ARTIFICIAL
NEURAL NETWORKS**

DOCTORAL THESIS

Rijeka, 2017.

Sveučilište u Rijeci
TEHNIČKI FAKULTET
Fakultetsko vijeće

KLASA: 030-09/12-01/12
URBROJ: 2170-57-01-12-11
Rijeka, 30. studenog 2012.

Fakultetsko vijeće Tehničkog fakulteta Sveučilišta u Rijeci, na svojoj 2. sjednici u ak. god. 2012./13., održanoj 30. studenog 2012., donijelo je sljedeću

ODLUKU

Sukladno izvješću Stručnog povjerenstva u sastavu: doc. dr. sc. Robert Basan (predsjednik), prof. dr. sc. Domagoj Rubeša (član) i doc. dr. sc. Marina Franulović (članica) utvrđuje se da pristupnica **Tea Marohnić, dipl. ing.** ispunjava Zakonom propisane uvjete za izradu teme doktorskog rada pod naslovom

Karakterizacija i procjena cikličkog i zamornog ponašanja materijala na osnovi njegovih monotonih značajki primjenom neuronskih mreža.

Mentorom se imenuje doc. dr. sc. Roberta Basana.


Dekan
Prof. dr. sc. Goran Turkalj

Dostaviti:

- 1.) Tea Marohnić, dipl. ing.
- 2.) Mentor, doc. dr. sc. Robert Basan
- 3.) Služba studentske evidencije
- 4.) Pismohrana Fv

Sveučilište u Rijeci
TEHNIČKI FAKULTET
Fakultetsko vijeće

KLASA: 030-09/16-01/12
URBROJ: 2170-57-01-16-12
Rijeka, 22. prosinca 2016.

Fakultetsko vijeće Tehničkog fakulteta Sveučilišta u Rijeci, na svojoj 3. sjednici u ak. god. 2016./17., održanoj 22. prosinca 2016., donijelo je sljedeću

ODLUKU

Temeljem prijedloga mentora doktorske disertacije izv. prof. dr. sc. Roberta Basana vrši se **promjena naslova doktorske disertacije Tee Marohnić, dipl. ing. stroj.:** *Karakterizacija i procjena cikličkog i zamornog ponašanja materijala na osnovi njegovih monotonih značajki primjenom neuronskih mreža u naslov: Procjena cikličkih i zamornih parametara čelika na osnovi njihovih monotonih značajki primjenom umjetnih neuronskih mreža.*



Dekanica

Prof. dr. sc. Jasna Prpić-Oršić

Dostaviti:

- 1.) Tea Marohnić, dipl. ing. stroj.
- 2.) Mentor izv. prof. dr. sc. Robert Basan
- 3.) Služba studentske evidencije
- 4.) Pismohrana FV

Mentor rada: izv. prof. dr. sc. Robert Basan, dipl. ing. stroj.

Doktorska disertacija obranjena je dana _____ na Tehničkom fakultetu Sveučilišta u Rijeci, pred povjerenstvom u sastavu:

1. prof. dr. sc. Domagoj Rubeša, dipl. ing. brod., predsjednik
(FH Joanneum Gesellschaft mbH, Graz, Austrija)
2. izv. prof. dr. sc. Robert Basan, dipl. ing. stroj., mentor, član
(Tehnički fakultet, Sveučilište u Rijeci)
3. prof. dr. sc. Nelida Črnjarić-Žic, dipl. ing. mat., članica
(Tehnički fakultet, Sveučilište u Rijeci)

In God we trust. All others must bring data.

W. Edwards Deming (1900–1993), američki
statističar, pedagog i konzultant

Zahvale

Doktorska disertacija "Procjena cikličkih i zamornih parametara čelika na osnovi njihovih monotonih značajki primjenom umjetnih neuronskih mreža" djelomično je izrađena u okviru bilateralnog hrvatsko-njemačkog znanstveno-istraživačkog projekta "Karakterizacija i modeliranje ponašanja materijala za lake i inovativne konstrukcije", potpora Sveučilišta u Rijeci "Karakterizacija i modeliranje ponašanja materijala i konstrukcija za inovativne primjene" [13.09.1.2.09] i "Razvoj evolucijskih metoda za identifikaciju parametara materijala" [13.09.2.2.18] te istraživačkog projekta Hrvatske zaklade za znanost "Razvoj evolucijskih postupaka za karakterizaciju ponašanja bioloških tkiva (BIOMAT)" [IP-2014-09-4982].

Mentoru, izv. prof. dr. sc. Robertu Basanu zahvaljujem na ukazanom povjerenju, potpori, sugestijama, strpljenju i poticaju tijekom cijelog doktorskog studija. Hvala što si bio i mentor i prijatelj kad je trebalo.

Članovima Povjerenstava za ocjenu i obranu prof. dr. sc. Domagoju Rubeši i prof. dr. sc. Nelidi Črnjarić-Žic zahvaljujem na uloženom trudu pri čitanju doktorske disertacije i svim primjedbama i sugestijama koje su neizmjerljivo doprinijele njevoj kvaliteti.

Hvala kolegicama i kolegama sa Zavoda, posebno "užoj radnoj skupini", na podršci, savjetima i suradnji. Marina, hvala na ukazanom povjerenju i uključivanju u BIOMAT.

Prijateljima zahvaljujem na potpori i razumijevanju svih "ne mogu" i "ne stignem" u zadnjih godinu dana. Nadoknadit ćemo.

Noni Elviri, mami, Borisu dugujem veliku zahvalu – i za potporu i za svako "kad ćeš to finit". *Mašinka* će konačno postati doktor. Nona Vitora, Jasna i Vlade – uz vas saki izazov va životu dobije smisla. Hvala van ča ste vavik tu.

Tatko, neću nikad biti vrstan inženjer ko ča si ti, ali uspjela sam i ja napraviti neki mali doprinos našoj struci. Onaj kompas me ipak dopeljavao na pravo mjesto.

I na kraju, hani, tebi beskrajno hvala što si me trpio u najgorim izdanjima i bodrio kad više nisam vjerovala u sebe. Konačno dolazimo na svoje.

Autorica

Sažetak

U doktorskoj disertaciji obrađen je problem procjene cikličkih Ramberg–Osgoodovih i zamornih Basquin–Coffin–Mansonovih parametara čelika na osnovi monotonih značajki primjenom umjetnih neuronskih mreža.

Za potrebe istraživanja iz relevantne je literature i putem on-line baze podataka o materijalima MATDAT prikupljen velik broj eksperimentalnih podataka za čelike. Pregledom postojećih istraživanja utvrđeno je da se podjelom čelika u skupine prema kriteriju udjela legirajućih elemenata može poboljšati točnost procjene cikličkih i zamornih parametara na osnovi monotonih značajki. U skladu s tim, čelici su grupirani u nelegirane, niskolegirane i visokolegirane čelike. Različitost vrijednosti cikličkih i zamornih parametara spomenutih grupa čelika i formalno je potvrđena provođenjem jednofaktorske analize varijance i Welchovog testa. Dodatno provedenim post-hoc analizama utvrđena je različitost na razini parova nelegiranih, niskolegiranih i visokolegiranih čelika. Provođenjem unaprijedne selekcije određene su monotone značajke relevantne za procjenu svakog od cikličkih i zamornih parametara različitih skupina čelika. Na osnovi rezultata statističkih analiza, predložena je procjena cikličkih i zamornih parametara primjenom neuronskih mreža, zasebno za svaku skupinu čelika i uz korištenje samo onih monotonih značajki koje su se pokazale statistički relevantnim za procjenu pojedinog parametra. Za učinkovitije korištenje prikupljenih podataka u razvoju neuronskih mreža primijenjena je metoda k -struke unakrsne validacije. Rezultati dobiveni razvijenim umjetnim neuronskim mrežama vrednovani su usporedbom s eksperimentalnim vrijednostima cikličkih i zamornih parametara, ali i onima dobivenim postojećim empirijskim metodama procjene. Za odabrani skup podataka umjetne neuronske mreže pokazale su se uspješnijim od empirijskih metoda procjene većine cikličkih i zamornih parametara i ponašanja različitih skupina čelika.

Razvijeni pristup procjeni cikličkih i zamornih parametara na osnovi lako dostupnih monotonih značajki primjenom neuronskih mreža može poslužiti jednostavnijem, točnijem i bržem određivanju opteretivosti i trajnosti čeličnih dijelova i konstrukcija u raznim industrijskim djelatnostima (automobilskoj, zrakoplovnoj i dr.). Razvojem pouzdanog sustava za procjenu cikličkih i zamornih parametara smanjuje se potreba za eksperimentalnom karakterizacijom cikličkog i zamornog ponašanja materijala u ranim fazama razvoja proizvoda u kojima se vrednuju različiti materijali i konstrukcijska rješenja, što za posljedicu ima i smanjenje troškova i vremena potrebnih za razvoj proizvoda.

Abstract

Research presented in this doctoral thesis deals with estimation of cyclic Ramberg–Osgood and fatigue Basquin–Coffin–Manson parameters i.e. stress–strain and strain–life behaviour of steels on the basis of their monotonic properties using artificial neural networks.

For the purpose of this study, a large number of experimental data for steels were collected from relevant literature and online Materials Properties Database MATDAT. The overview of existing methods showed that separate consideration of steels divided according to the content of alloying elements can improve the accuracy of estimations of cyclic and fatigue parameters on the basis of their monotonic properties. Thus, steels were divided into unalloyed, low-alloy and high-alloy steels. Differences among cyclic and fatigue parameters of steels divided in such a way were formally confirmed by performing one-way analysis of variance and Welch’s test. Additionally, pairwise differences between groups were found to exist by performing post-hoc analyses. Further detailed statistical analysis was performed by means of forward selection, and monotonic properties relevant for estimation of each cyclic and fatigue parameter of each group of steels were determined. Based on results of performed statistical analyses, estimation of cyclic and fatigue parameters using artificial neural networks was proposed, separately for each parameter and each steel subgroup, using only monotonic properties that proved to be relevant for estimation of particular parameter. Data collected were efficiently used in artificial neural network development by implementing k -fold cross-validation technique. Results obtained by artificial neural networks have been evaluated by comparison with experimental values and values obtained using existing empirical estimation methods. For used test data, artificial neural networks proved to be more successful than empirical methods for estimation of most of the cyclic and fatigue properties and behaviour of different steel subgroups.

Proposed and developed estimation of cyclic and fatigue parameters from readily available monotonic properties using artificial neural networks can facilitate faster and more accurate load capacity and durability analyses of steel components and structures during early stages of product design in various industrial applications (automotive, aeronautical etc.). Furthermore, it can contribute to the reduction of the need for experimental characterisation of material behavior and help decrease time and costs of product development.

Ključne riječi

- Zamor materijala
- Čelici
- Ciklički parametri
- Zamorni parametri
- Predviđanje vijeka trajanja
- Statistička analiza
- Umjetne neuronske mreže

Keywords

- Fatigue of materials
- Steels
- Cyclic stress–strain parameters
- Fatigue strain–life parameters
- Lifetime prediction
- Statistical analysis
- Artificial neural networks

Sadržaj

Zahvale	II
Sažetak	III
Abstract	IV
Ključne riječi	V
Keywords	V
Sadržaj	VI
1 Uvod	1
1.1 Predmet, svrha i ciljevi istraživanja	1
1.2 Znanstvena hipoteza i metodologija rješenja	4
1.3 Očekivani znanstveni doprinos i primjena rezultata istraživanja	5
1.4 Struktura doktorske disertacije	6
2 Pregled stanja znanja i postojećih istraživanja	9
2.1 Karakterizacija ponašanja materijala	9
2.1.1 Ponašanje materijala izloženog monotonom opterećenju	9
2.1.2 Ponašanje materijala izloženog cikličkom opterećenju	12
2.1.3 Karakterizacija zamaranja materijala	16
2.1.3.1 Općenito o zamoru materijala	16
2.1.3.2 Pristup karakterizaciji procesa zamaranja materijala temeljen na deformaciji ..	18
2.2 Pregled postojećih metoda procjene cikličkih i zamornih parametara materijala na osnovi njihovih monotonih značajki	21
2.2.1 Uvod	21
2.2.2 Empirijske metode procjene cikličkih i zamornih parametara i ponašanja materijala ...	21
2.2.2.1 Metode kvalitativne procjene ponašanja materijala izloženog cikličkom opterećenju	21
2.2.2.2 Metode procjene cikličkih parametara materijala	23
2.2.2.3 Metode procjene zamornih parametara materijala	25
2.2.2.4 Evaluacija empirijskih metoda procjene cikličkih i zamornih parametara na osnovi monotonih značajki	28

2.2.3	Procjena cikličkih i zamornih parametara materijala primjenom umjetnih neuronskih mreža	31
2.3	Zaključak	34
3	Prikupljanje i obrada podataka	37
3.1	Uvod	37
3.2	Prikupljanje podataka o materijalima	38
3.3	Metodologija za utvrđivanje razlika između skupina čelika	38
3.3.1	Jednofaktorska analiza varijance i Welchov test.....	38
3.3.2	Post-hoc analize	42
3.4	Zaključak	43
4	Identifikacija monotonih značajki relevantnih za procjenu cikličkih i zamornih parametara čelika.....	45
4.1	Uvod	45
4.2	Metodologija za identifikaciju monotonih značajki relevantnih za procjenu cikličkih i zamornih parametara čelika.....	46
4.2.1	Odabir metode za identifikaciju relevantnih monotonih značajki.....	46
4.2.2	Izgradnja modela višestruke linearne regresije unaprijednom selekcijom.....	47
4.2.2.1	Model višestruke linearne regresije.....	47
4.2.2.2	Test o značajnosti regresije (skupni test).....	48
4.2.2.3	Test o značajnosti jednog prediktora ili podskupa prediktorskih varijabli.....	50
4.2.3	Dodatna razmatranja u vezi s metodom unaprijedne selekcije	53
4.3	Postupak identifikacije monotonih značajki relevantnih za procjenu cikličkih i zamornih parametara čelika.....	55
4.4	Unaprijedna selekcija monotonih značajki relevantnih za procjenu cikličkih i zamornih parametara materijala	61
4.4.1	Rezultati unaprijedne selekcije za procjenu cikličkih parametara	61
4.4.1.1	Određivanje redoslijeda ulaska prediktora u modele za procjenu cikličkih parametara čelika.....	61
4.4.1.2	Monotone značajke relevantne za procjenu cikličke granice tečenja R_e'	62
4.4.1.3	Monotone značajke relevantne za procjenu koeficijenta cikličkog deformacijskog očvršćivanja K'	63
4.4.1.4	Monotone značajke relevantne za procjenu eksponenta cikličkog deformacijskog očvršćivanja n'	63
4.4.1.5	Diskusija rezultata unaprijedne selekcije za cikličke parametre	64
4.4.2	Rezultati unaprijedne selekcije za procjenu zamornih parametara	65
4.4.2.1	Određivanje redoslijeda ulaska prediktora u modele za procjenu zamornih parametara čelika.....	65

4.4.2.2	Monotone značajke relevantne za procjenu koeficijenta dinamičke čvrstoće σ_f'	67
4.4.2.3	Monotone značajke relevantne za procjenu eksponenta dinamičke čvrstoće b .	68
4.4.2.4	Monotone značajke relevantne za procjenu koeficijenta cikličkih deformacija ε_f'	68
4.4.2.5	Monotone značajke relevantne za procjenu eksponenta cikličkih deformacija c	69
4.4.2.6	Diskusija rezultata unaprijedne selekcije za zamorne parametre	69
4.5	Monotone značajke relevantne za modeliranje umjetnih neuronskih mreža za procjenu cikličkih i zamornih parametara čelika	71
5	Razvoj umjetnih neuronskih mreža za procjenu cikličkih i zamornih parametara materijala	73
5.1	Općenito o umjetnim neuronskim mrežama	73
5.1.1	Uvod	73
5.1.2	Temeljni pojmovi i odabir umjetne neuronske mreže za predmetnu zadaću	74
5.1.2.1	Kratak povijesni pregled	74
5.1.2.2	Biološki neuron	75
5.1.2.3	Umjetni neuron	76
5.1.2.4	Mrežna arhitektura	78
5.1.2.5	Učenje	80
5.2	Višeslojni perceptron sa širenjem unatrag	81
5.2.1	Osnovne karakteristike višeslojnog perceptrona	81
5.2.2	Učenje korekcijom pogreške	82
5.2.3	Širenje unatrag	84
5.2.4	Generalizacija	85
5.2.4.1	Dimenzioniranje mreže i generalizacija	85
5.2.4.2	Metode poboljšanja generalizacije	87
5.3	Modeliranje umjetnih neuronskih mreža za procjenu cikličkih i zamornih parametara materijala na osnovi monotonih značajki	90
5.3.1	Uvod	90
5.3.2	Odabir ulaznih varijabli i priprema podataka	91
5.3.3	Odabir mrežne arhitekture	93
5.3.4	Odabir algoritma za učenje	95
5.3.5	Inicijalizacija težina i treniranje mreže	96
5.3.6	Analiza mrežnih performansi	98
5.4	Odabrane umjetne neuronske mreže za procjenu cikličkih i zamornih parametara čelika	103

6	Vrednovanje primjenjivosti umjetnih neuronskih mreža za procjenu cikličkih i zamornih parametara materijala	107
6.1	Uvod	107
6.2	Metodologija vrednovanja.....	107
6.3	Odabir empirijskih metoda procjene cikličkih i zamornih parametara i ponašanja čelika za usporedno vrednovanje.....	110
6.4	Vrednovanje umjetnih neuronskih mreža za procjenu cikličkih i zamornih parametara čelika	112
6.4.1	Vrednovanje procijenjenih cikličkih parametara	112
6.4.1.1	Vrednovanje procijenjenih vrijednosti cikličke granice tečenja R_e'	112
6.4.1.2	Vrednovanje procijenjenih vrijednosti koeficijenta cikličkog deformacijskog očvršćivanja K'	114
6.4.1.3	Vrednovanje procijenjenih vrijednosti eksponenta cikličkog deformacijskog očvršćivanja n'	115
6.4.2	Vrednovanje procijenjenih zamornih parametara	117
6.4.2.1	Vrednovanje procijenjenih vrijednosti koeficijenta dinamičke čvrstoće σ_f'	117
6.4.2.2	Vrednovanje procijenjenih vrijednosti eksponenta dinamičke čvrstoće b	118
6.4.2.3	Vrednovanje procijenjenih vrijednosti koeficijenta cikličkih deformacija ε_f' .	120
6.4.2.4	Vrednovanje procijenjenih vrijednosti eksponenta cikličkih deformacija c	121
6.5	Vrednovanje umjetnih neuronskih mreža za procjenu cikličkog i zamornog ponašanja čelika	123
6.5.1	Vrednovanje amplituda deformacije $\Delta\sigma/2$ proračunatih na osnovi procijenjenih cikličkih parametara.....	123
6.5.2	Vrednovanje broja izmjena opterećenja do otkazivanja $2N_f$ proračunatih na osnovi procijenjenih zamornih parametara.....	125
6.6	Zaključak	126
7	Zaključak i smjernice za daljnji rad.....	129
	Popis literature.....	133
	Popis znakova i kratica.....	141
	Popis slika i tablica.....	147
	Prilog A Empirijske metode procjene cikličkih i zamornih parametara metalnih materijala	155
	A.1 Metode procjene cikličkih parametara.....	155
	A.2 Metode procjene zamornih parametara	157
	Prilog B Podaci za provedbu statističke analize, razvoj umjetnih neuronskih mreža i vrednovanje procjene cikličkih i zamornih parametara čelika	161
	B.1 Prikaz podataka za nelegirane, niskolegirane i visokolegirane čelike korištenih u istraživanju.....	161

B.2	Podaci za nelegirane, niskolegirane i visokolegirane čelike korišteni za provedbu unaprijedne selekcije i razvoj umjetnih neuronskih mreža za procjenu cikličkih i zamornih parametara čelika.....	163
B.3	Dodatni podaci za nelegirane i niskolegirane čelike korišteni za razvoj umjetnih neuronskih mreža za procjenu cikličkih i zamornih parametara čelika.....	169
B.3.1	Podaci za razvoj umjetnih neuronskih mreža za procjenu cikličkih parametara čelika	169
B.3.2	Podaci za razvoj umjetnih neuronskih mreža za procjenu zamornih parametara čelika	172
B.4	Podaci za nelegirane i niskolegirane čelike korišteni za vrednovanje empirijskih metoda i umjetnih neuronskih mreža za procjenu cikličkih i zamornih parametara čelika....	175
B.4.1	Podaci za vrednovanje empirijskih metoda i umjetnih neuronskih mreža za procjenu cikličkih parametara čelika.....	175
B.4.2	Podaci za vrednovanje empirijskih metoda i umjetnih neuronskih mreža za procjenu zamornih parametara čelika.....	177
B.5	Podaci za visokolegirane čelike korišteni za vrednovanje empirijskih metoda i umjetnih neuronskih mreža za procjenu cikličkih i zamornih parametara čelika.....	180
Prilog C	Rezultati postupne regresijske analize (unaprijedne selekcije)	181
C.1	Rezultati unaprijedne selekcije (postupne regresijske analize) monotonih značajki za procjenu cikličkih parametara nelegiranih, niskolegiranih i visokolegiranih čelika .	181
C.2	Rezultati unaprijedne selekcije (postupne regresijske analize) monotonih značajki za procjenu zamornih parametara nelegiranih, niskolegiranih i visokolegiranih čelika	187
Prilog D	Primjeri MATLAB koda za učenje umjetnih neuronskih mreža.....	193
D.1	Primjeri koda za učenje umjetnih neuronskih mreža za procjenu cikličkih i zamornih parametara čelika.....	193
D.2	Kod za učenje umjetne neuronske mreže za procjenu cikličke granice tečenja R_c' nelegiranih čelika pomoću 10-struke unakrsne validacije i Levenberg–Marquadtovog algoritma za učenje pogreške s ranim zaustavljanjem.....	194
D.3	Kod za učenje umjetne neuronske mreže za procjenu eksponenta cikličkog deformacijskog očvršćivanja n' niskolegiranih čelika pomoću 10-struke unakrsne validacije i Bayesove regularizacije	202
	Životopis.....	209
	Popis objavljenih radova	211

1 Uvod

1.1 Predmet, svrha i ciljevi istraživanja

Većina mehaničkih komponenata (dijelovi strojeva, vozila, zrakoplova) i konstrukcija u radu je izložena djelovanju ponavljajućeg, cikličkog opterećenja, što rezultira pojavom cikličkih naprezanja i deformacija u materijalu te njegovim zamaranjem. Pojam *zamora materijala* uveo je Poncelet još u prvoj polovici 19. stoljeća na osnovi promatranja materijala izloženog djelovanju ponavljajućeg opterećenja i njime uzrokovanih lomova. Svijest o mehaničkom otkazivanju materijala izazvanog zamorom porasla je u doba Industrijske revolucije, s problemom lomova željezničkih osovina na mjestima promjene poprečnog presjeka – koncentrata naprezanja [49, 78].

Procjenjuje se, ovisno o izvoru, da u današnje vrijeme zamor materijala uzrokuje 50 % pa do čak 90 % otkazivanja mehaničkih dijelova i konstrukcija [78] te je stoga predmet intenzivnih istraživanja. Osim opasnosti po ljudske živote i okolinu, zamaranje materijala, odnosno zamorni lomovi, mogu izravno ili neizravno uzrokovati i značajnu ekonomsku štetu. Prema [49] američko gospodarstvo je 1982. pretrpjelo trošak od 119 milijardi dolara (4 % bruto nacionalnog dohotka), većim dijelom zbog otkazivanja dijelova i konstrukcija uslijed djelovanja zamora materijala.


Gubici uzrokovani zamornim lomovima mogu se smanjiti ili spriječiti ispravnim konstruiranjem proizvoda s obzirom na zahtijevani vijek trajanja dijela ili konstrukcije, za što je razvijeno i nekoliko kriterija [78]:

- *kriterij neograničenog vijeka trajanja* (engl. *infinite life design*), prema kojem nikad ne smije doći do otkazivanja dijela ili konstrukcije,
- *kriterij sigurnog postojanja* (engl. *safe life design*), kod kojeg dio ili konstrukcija moraju izdržati predviđeni vijek trajanja bez otkazivanja,
- *kriterij ograničenog otkazivanja* (engl. *fail safe design*), koji osigurava da cjelokupna konstrukcija neće otkazati ukoliko jedan njen dio otkáže, i

- *kriterij dopuštenog oštećenja* (engl. *damage tolerant design*), kojim se pretpostavlja da će zamorne pukotine nastati u dijelu ili konstrukciji, ali će se pravovremenom periodičkom inspekcijom spriječiti njihov rast do kritične veličine.

Za uspješno konstruiranje s obzirom na vijek trajanja, kao i za odluku o primjenjivom kriteriju trajnosti potrebno je poznavati mnoge faktore – ulogu dijela ili konstrukcije u sigurnosti proizvoda, posljedice neželjenog otkazivanja dijela ili konstrukcije i sl.

Konstruiranje s obzirom na vijek trajanja je *iterativan proces* čiji su tipični koraci prikazani na slici 1.1.



Slika 1.1 Dijagram toka konstruiranja s obzirom na vijek trajanja, prema [78]

Razvoj računalne tehnologije i CAE računalnih rješenja omogućili su složene simulacije ponašanja dijelova i konstrukcija izloženih cikličkom opterećenju, kao i određivanje opteretivosti i trajnosti tijekom ranih faza razvoja proizvoda. Primjer takvih simulacija su

analize vijeka trajanja temeljene na deformaciji, koje su široko rasprostranjene u automobilskoj, zrakoplovnoj i energetske industriji za procjenu trajnosti visokopterećenih metalnih dijelova i konstrukcija [15, 52, 88]. Za provođenje ovih analiza potrebno je, između ostalog, poznavati cikličko i zamorno ponašanje, odnosno cikličke i zamorne parametre materijala.

Karakterizacija cikličkog i zamornog ponašanja materijala i određivanje pripadajućih parametara eksperimentalnim putem najtočnija je, no ujedno i skupa, dugotrajna i vrlo često nedostupna u ranim fazama razvoja proizvoda, kad se još uvijek vrednuje više materijala i konstrukcijskih rješenja. Iz tog su razloga od sredine 20. stoljeća razvijene brojne empirijske metode procjene cikličkih [11, 39, 42–44, 75, 89–91] i zamornih [14, 48, 57, 64, 67, 73, 76] parametara i ponašanja materijala na osnovi lako dostupnih monotonih značajki.

Za razliku od eksperimenata, empirijske metode procjene cikličkih i zamornih parametara na osnovi monotonih značajki materijala praktične su, jednostavne i brze, pa su stoga i danas u širokoj upotrebi. Međutim, za procjenu parametara najčešće uzimaju u obzir tek mali broj najlakše dostupnih monotonih značajki što ukazuje na mogućnost da bi se povećanjem broja i korištenjem relevantnih monotonih značajki koje se uzimaju u obzir moglo poboljšati točnost i pouzdanost procjene cikličkih i zamornih parametara materijala. Osim toga, empirijske metode procjene temelje se na regresijskim modelima koji često ne pružaju mogućnost dovoljno točne identifikacije složenih veza između monotonih značajki i cikličkih odnosno zamornih parametara materijala. Iz navedenih je razloga posljednjih godina sve raširenija karakterizacija cikličkog i zamornog ponašanja materijala primjenom umjetnih neuronskih mreža [3, 21, 25, 26, 31, 35, 53, 71, 82, 84, 85].

Pregledom postojećih metoda procjene cikličkih i zamornih parametara materijala, bile one empirijske ili utemeljene na primjeni umjetnih neuronskih mreža, utvrđeno je nekoliko ključnih nedostataka. Metode procjene pretežno su razvijane na skromnom broju materijala i predložene za procjenu parametara svih čelika ili čak svih metalnih materijala zajedno čime se zanemaruju specifičnosti pojedinih skupina čelika odnosno materijala [12, 51, 52]. Monotone značajke na osnovi kojih se procjenjuju ciklički i zamorni parametri, tj. ponašanje čelika, odabrane su bez prethodno provedene statističke analize kojom bi se utvrdila relevantnost pojedine monotone značajke i doprinos procjeni pojedinog cikličkog ili zamornog parametra čelika [51]. Tako dok neke metode koriste ograničen broj, uglavnom najdostupnijih, monotonih značajki, druge neselektivno koriste sve dostupne značajke. Odabir relevantnih varijabli iznimno je bitan za procjenu cikličkih i zamornih parametara primjenom umjetnih neuronskih mreža. U idealnoj

situaciji, uz neograničen broj primjera za učenje, moguće je modelirati mreže koje će iz svih dostupnih značajki uspješno izuzeti samo informacije relevantne za dani problem. Međutim, broj primjera za učenje dostupnih pri rješavanju stvarnih problema često je nedostatan u odnosu na broj mogućih ulaznih varijabli i složenost funkcijske veze koju se želi modelirati.

Slijedom utvrđenih nedostataka postojećih metoda procjene, definirani su ciljevi istraživanja:

- prikupljanje velikog broja podataka i rezultata monotonih i cikličkih/zamornih eksperimenata za čelike iz relevantnih izvora,
- odabir odgovarajućeg kriterija grupiranja čelika i provođenje statističke analize s ciljem utvrđivanja postojanja statistički značajnih razlika tako grupiranih čelika s obzirom na njihove cikličke i zamorne parametre,
- provođenje detaljne statističke analize s ciljem identifikacije monotonih značajki relevantnih za procjenu cikličkih i zamornih parametara pojedine skupine čelika te naposljetku
- razvoj modela umjetnih neuronskih mreža za procjenu cikličkih i zamornih parametara čelika podijeljenih u skupine prema odabranom kriteriju, uzimajući u obzir relevantne monotone značajke utvrđene prethodnom statističkom analizom.

1.2 Znanstvena hipoteza i metodologija rješenja

Iz postavljenih ciljeva istraživanja proizašlih iz utvrđenih nedostataka postojećih pristupa problematici procjene cikličkih i zamornih parametara čelika na osnovi njihovih monotonih značajki slijedi znanstvena hipoteza istraživanja. Hipotezom se pretpostavlja da se umjetnim neuronskim mrežama razvijenim posebno za svaku skupinu čelika, i to samo na osnovi relevantnih monotonih značajki, može točnije procijeniti cikličke i zamorne parametre odnosno cikličko i zamorno ponašanje čelika.

Istraživanje opravdanosti postavljene hipoteze izvršeno je uporabom niza znanstvenih metoda, kako slijedi.

Iz relevantne literature prikupljen je velik broj eksperimentalnih podataka za čelike.

Sukladno hipotezi odabran je kriterij za grupiranje čelika. Na tako grupiranim čelicima statističkim testovima utvrđeno je da se pojedine skupine čelika statistički značajno razlikuju s obzirom na pojedine cikličke i zamorne parametre.

S obzirom na utvrđene različitosti među cikličkim i zamornim parametrima različitih skupina čelika, daljnjom detaljnom statističkom analizom za svaku skupinu čelika zasebno određene su monotone značajke koje statistički značajno doprinose točnijoj procjeni tih parametara. Monotone značajke za koje je statističkom analizom utvrđeno da su relevantne, uspoređene su s monotonim značajkama korištenim u postojećim metodama procjene.

Na osnovi rezultata statističkih analiza, koristeći monotone značajke relevantne za procjenu pojedinog parametra, razvijene su umjetne neuronske mreže za procjenu svakog cikličkog i zamornog parametra svake skupine čelika zasebno. S ciljem utvrđivanja svrsishodnosti podjele čelika u skupine i korištenja samo relevantnih monotonih značajki za procjenu cikličkih i zamornih parametara čelika razvijene su i mreže za procjenu parametara na skupini koju čine svi čelici zajedno, i to koristeći sve dostupne značajke.

Kako bi se na nepristran način utvrdila valjanost predloženog rješenja, mreže su testirane na neovisnom uzorku podataka, a rezultati su uspoređeni s eksperimentalnim vrijednostima i vrijednostima dobivenim primjenom postojećih empirijskih metoda procjene cikličkih i zamornih parametara čelika.

1.3 Očekivani znanstveni doprinos i primjena rezultata istraživanja

Očekivani znanstveni doprinos istraživanja očituje se u razvoju nove metodologije za razvoj rješenja za procjenu cikličkih i zamornih parametara čelika temeljenom na umjetnim neuronskim mrežama te unaprijeđivanju metoda procjene tih parametara na osnovi monotonih značajki. Nadalje, doprinos se očituje u uključivanju detaljnih statističkih analiza u proces razvoja spomenutih umjetnih neuronskih mreža. Statističkim analizama utvrđene su statistički značajne razlike između skupina čelika grupiranih prema udjelu legirajućih elemenata na nelegirane, niskolegirane i visokolegirane čelike s obzirom na njihove cikličke i zamorne parametre. Predložena je statistička metodologija za određivanje monotonih značajki relevantnih za procjenu cikličkih i zamornih parametara. Primjenom predložene metodologije utvrđeno je da su različite monotone značajke relevantne za procjenu pojedinih cikličkih i zamornih parametara različitih skupina čelika, što dodatno ukazuje na to da čelike grupirane prema udjelu legirajućih elemenata treba zasebno razmatrati pri procjeni cikličkih i zamornih parametara na osnovi monotonih značajki. Ova saznanja uspješno su primijenjena na razvoj modela umjetnih neuronskih mreža za promatrani problem.

Implementacija razvijenih modela umjetnih neuronskih mreža u softversko rješenje olakšala bi određivanje opteretivosti i trajnosti u ranim fazama razvoja proizvoda. Jednostavnijom evaluacijom velikog broja materijala moglo bi se na lakši i brži način smanjiti izbor na nekoliko najprikladnijih. Troškovi razvoja proizvoda smanjili bi se uslijed smanjivanja potrebnog broja eksperimentalnih ispitivanja, a smanjenjem broja dugotrajnih i složenih eksperimenata skratilo bi se i vrijeme potrebno za razvoj proizvoda. Korištenje ovakvog alata omogućilo bi točniju procjenu vijeka trajanja prije eksperimentalne verifikacije.

1.4 Struktura doktorske disertacije

Doktorsku disertaciju čini sedam međusobno povezanih poglavlja.

U prvom poglavlju predstavljen je predmet istraživanja, postavljeni su ciljevi istraživanja i znanstvena hipoteza, navedena metodologija rješenja te očekivani znanstveni doprinos.

U drugom poglavlju prikazano je stanje znanja i dan je pregled postojećih istraživanja, s detaljnim osvrtom na značajke te posebno na nedostatke postojećih istraživanja.

U trećem poglavlju opisana je procedura prikupljanja podataka na kojima je provedeno istraživanje. Čelici su prema kriteriju udjela legirajućih elemenata podijeljeni u nelegirane, niskolegirane i visokolegirane čelike, a potom je provedena statistička analiza s ciljem utvrđivanja različitosti cikličkog i zamornog ponašanja pojedinih skupina čelika.

U četvrtom poglavlju provedena je detaljna statistička analiza s ciljem utvrđivanja monotonih značajki relevantnih za procjenu cikličkih i zamornih parametara svake skupine čelika. Relevantne monotone značajke uspoređene su s onima korištenim u postojećim metodama.

U petom poglavlju opisan je razvoj umjetnih neuronskih mreža za procjenu cikličkih i zamornih parametara nelegiranih, niskolegiranih i visokolegiranih čelika na osnovi relevantnih monotonih značajki definiranih u četvrtom poglavlju. Osim toga modelirane su i mreže za procjenu cikličkih i zamornih parametara svih čelika, bez obzira na pripadnost prethodno definiranim skupinama.

U šestom poglavlju provedeno je vrednovanje rezultata dobivenih umjetnim neuronskim mrežama usporedbom rezultata s eksperimentalnim vrijednostima te rezultatima dobivenim odabranim empirijskim metodama procjene.

U sedmom, zaključnom, poglavlju dana je ocjena postignutosti cilja, predstavljene su mogućnosti primjene razvijenog pristupa procjeni cikličkih i zamornih parametara čelika te mogućnosti nastavka i produblivanja istraživanja.

Osim navedenih poglavlja doktorska disertacija sadrži popis literature, popise znakova i kratica kao i popis slika i tablica.

Na kraju doktorske disertacije nalaze se četiri priloga, koji čine njen bitan dio, a koji su zbog svog opsega izdvojeni iz glavnog dijela rada.

Prilog A obuhvaća pregled empirijskih metoda procjene cikličkih i zamornih parametara (i pripadne izraze) te čini sastavni dio pregleda dosadašnjih istraživanja iz drugog poglavlja.

Prilog B obuhvaća eksperimentalne podatke čelika korištene za provedbu statističkih analiza iz četvrtog poglavlja, razvoj umjetnih neuronskih mreža iz petog poglavlja te vrednovanje dobivenih rezultata provedeno u šestom poglavlju. Na ovaj način omogućena je potpuna ponovljivost istraživanja.

U Prilogu C nalaze se tablice s rezultatima statističkih analiza provedenih u poglavlju 4.

U Prilogu D dani su primjeri MATLAB koda za učenje umjetnih neuronskih mreža za opisani problem.

2 Pregled stanja znanja i postojećih istraživanja

2.1 Karakterizacija ponašanja materijala

2.1.1 Ponašanje materijala izloženog monotonom opterećenju

Rezultati ispitivanja materijala koriste se za najrazličitije svrhe, od kojih je jedna od važnijih određivanje ponašanja materijala u uvjetima monotonog opterećenja i monotonih značajki koje su potrebne za izvođenje različitih proračuna opteretivosti dijelova i konstrukcija [18, 78]. Monotono ponašanje materijala i pripadajuće značajke određuju se opterećivanjem standardiziranog ispitnog uzorka kružnog ili pravokutnog poprečnog presjeka monotono rastućim produljenjem, sve do konačnog loma ispitnog uzorka na dva dijela. Procedura karakterizacije monotonog ponašanja materijala propisana je normom ASTM E8 ili E8M [78].

Pritom se definiraju i bilježe ovisnosti dviju osnovnih veličina, *naprezanje* S i *deformacija* e

$$S = F/A_0, \quad (1)$$


$$e = (l - l_0)/l_0 = \Delta l/l_0, \quad (2)$$

gdje je F je vlačna sila, A_0 početna površina poprečnog presjeka ispitnog uzorka, l trenutna duljina ispitnog uzorka, l_0 početna duljina ispitnog uzorka, a Δl produljenje ispitnog uzorka. Veličine S i e iz izraza (1) i (2) poznate su kao *inženjersko naprezanje* i *inženjerska deformacija*, i ne uzimaju u obzir smanjenje poprečnog presjeka odnosno povećanje duljine ispitnog uzorka uslijed djelovanja vlačne sile. U stvarnosti se duljina ispitnog uzorka neprestano povećava, a poprečni presjek smanjuje pa su *stvarno naprezanje* σ i *stvarna deformacija* ε definirani kao

$$\sigma = F/A \quad (3)$$

$$\varepsilon = \ln(l/l_0). \quad (4)$$

U izrazu (3) A je stvarna površina poprečnog presjeka ispitnog uzorka. Prikaz inženjerskih i stvarnih krivulja ovisnosti naprezanja i deformacije (S - e i σ - ε) dan je na slici 2.1.



Slika 2.1 Dijagram ovisnosti napreznja i deformacije σ - ϵ dobivenih monotonim vlačnim eksperimentom, prema [5]

Vrijednosti stvarnog napreznja σ i stvarne deformacije ϵ moguće je izračunati iz inženjerskog napreznja S i inženjerske deformacije e [5, 18, 78] pomoću izraza

$$\sigma = S(1 + e), \quad (5)$$

$$\epsilon = \ln(1 + e). \quad (6)$$

koji vrijede sve do pojave izraženog smanjenja poprečnog presjeka, tzv. *neckinga*, odnosno trenutka kad inženjersko napreznje dostigne vrijednost vlačne čvrstoće R_m .

Ukupnu deformaciju ϵ čine dvije komponente, reverzibilna *elastična deformacija* ϵ_e i ireverzibilna *plastična deformacija* ϵ_p (slika 2.1). Međusobna ovisnost stvarnih napreznja σ i stvarnih elastičnih deformacija ϵ_e je linearna $\epsilon_e = \sigma/E$, a međusobna ovisnost stvarnih napreznja σ i stvarnih plastičnih deformacija ϵ_p se za većinu metalnih materijala može opisati eksponencijalnom funkcijom. Ovisnost napreznja σ i ukupne deformacije ϵ dana je Ramberg–Osgoodovim izrazom za slučaj monotonog opterećenja [6, 72]

$$\epsilon = \epsilon_e + \epsilon_p = \frac{\sigma}{E} + \left(\frac{\sigma}{K} \right)^{\frac{1}{n}}. \quad (7)$$

Prikaže li se veza σ - ϵ_p u dvostrukom logaritamskom dijagramu (slika 2.2), parametrima Ramberg–Osgoodovog izraza može se dodijeliti sljedeće značenje: eksponent deformacijskog očvršćivanja n je koeficijent smjera dobivenog pravca, dok bi koeficijent deformacijskog

U nedostatku eksperimentalnih vrijednosti, stvarno naprezanje pri lomu σ_f može se prema [48] izračunati iz vlačne čvrstoće R_m i stvarnog istezanja pri lomu ε_f

$$\sigma_f = R_m(1 + \varepsilon_f). \quad (10)$$


2.1.2 Ponašanje materijala izloženog cikličkom opterećenju

Ponašanje metala i slitina pod djelovanjem cikličkog opterećenja može se značajno razlikovati od njihovog ponašanja u uvjetima monotonog jednoosnog opterećenja [41, 78]. Ovisno o materijalu, temperaturi i stanju ispitivanog materijala mogu nastupiti

- *cikličko očvršćivanje* (engl. *cyclic hardening*), tj. povećanje raspona vrijednosti naprezanja $\Delta\sigma$ pri eksperimentima s konstantnom amplitudom deformacije $\Delta\varepsilon/2 = \text{const.}$ (slika 2.3 a)), i
- *cikličko oslabljivanje* (engl. *cyclic softening*), tj. smanjenje raspona vrijednosti naprezanja $\Delta\sigma$ pri eksperimentima s konstantnom amplitudom deformacije $\Delta\varepsilon/2 = \text{const.}$ (slika 2.3 b)).


Postupak karakterizacije cikličkog odziva materijala propisan je u normi ASTM E606 [6] i podrazumijeva opterećivanje standardiziranih, glatkih ispitnih uzoraka (najčešće kružnog poprečnog presjeka) cikličkim vlačnim–tlačnim, potpuno simetričnim opterećenjem (faktor asimetrije opterećenja $R_\varepsilon = -1$) konstantne vrijednosti amplitude deformacije $\Delta\varepsilon/2$ [18, 78].

Za vrijeme trajanja eksperimenta sa svakim ciklusom kontinuirano se bilježe vrijednosti amplituda naprezanja $\Delta\sigma/2$ i amplituda ukupnih $\Delta\varepsilon/2$ i plastičnih deformacija $\Delta\varepsilon_p/2$, sve do otkazivanja ispitnog uzorka. Prema [6] *otkazivanje* (engl. *failure*) može biti definirano na više načina: kao potpuni lom, smanjenje omjera tangentnog modula u opterećenju i rasterećenju za 50 % u odnosu na prvi ciklus, pojava mikroskopske pukotine definirane veličine ili kao smanjenje raspona opterećenja $\Delta\sigma$ u odnosu na vrijednost u stabiliziranom području za definirani postotak (u normi ASTM E606 to je 50 %).




Slika 2.3 Ponašanje materijala pod djelovanjem cikličkog opterećenja u eksperimentima s konstantnom amplitudom deformacije $\Delta\varepsilon/2$: a) cikličko očvršćivanje, b) cikličko oslabljivanje, prema [41]

Za karakterizaciju cikličkog odziva materijala uobičajeno se odabire histerezna petlja naprezanja i deformacije dobivena na otprilike polovici ukupnog broja ciklusa opterećenja do otkazivanja ispitnog uzorka. Histerezna petlja naprezanje–deformacija s naznačenim osnovnim veličinama prikazana je na slici 2.4.



Slika 2.4 Histerezna petlja naprezanje–deformacija

Ciklička krivulja naprezanje–deformacija (engl. *cyclic stress–strain curve*) dobiva se spajanjem vrhova preklopljenih stabiliziranih histereznih petlji iz eksperimenata provedenih s nekoliko različitih konstantnih amplituda deformacije $\Delta\varepsilon/2$ (slika 2.5). Ukoliko materijal ciklički očvršćuje, ciklička krivulja naprezanje–deformacija bit će iznad monotone, a u suprotnom, ukoliko materijal ciklički oslabljuje, ciklička će krivulja biti ispod one dobivene monotonim opterećivanjem materijala.




Slika 2.5 Ciklička krivulja naprezanje–deformacija dobivena spajanjem vrhova stabiliziranih histereznih petlji, prema [8]

Cikličke krivulje naprezanje–deformacija većine metalnih materijala dovoljno se dobro mogu opisati Ramberg–Osgoodovim (RO) izrazom [6, 72], koji za slučaj cikličkog opterećenja ima oblik

$$\frac{\Delta\varepsilon}{2} = \frac{\Delta\varepsilon_e}{2} + \frac{\Delta\varepsilon_p}{2} = \frac{\Delta\sigma}{2E} + \left(\frac{\Delta\sigma}{2K'}\right)^{\frac{1}{n'}}. \quad (11)$$

U izrazu (11) K' je koeficijent cikličkog deformacijskog očvršćivanja, a n' eksponent cikličkog deformacijskog očvršćivanja. Ovisnost amplituda naprezanja $\Delta\sigma/2$ o amplitudama plastičnih deformacija $\Delta\varepsilon_p/2$ iz izraza (11) u dvostrukom logaritamskom mjerilu je pravac pa se RO parametrima može dodijeliti slično značenje kao i parametrima Ramberg–Osgoodovog izraza za slučaj monotonog opterećenja (7): eksponent cikličkog deformacijskog očvršćivanja n' je koeficijent smjera tog pravca, a K' vrijednost amplitude naprezanja pri amplitudi plastične deformacije $\Delta\varepsilon_p/2 = 1$ (slika 2.6).



Slika 2.6 Ovisnost amplituda naprezanja o amplitudama plastičnih deformacija $\Delta\sigma/2$ – $\Delta\varepsilon_p/2$, prema [5]

Kod cikličke krivulje naprezanje–deformacija granica tečenja nije izražena pa je ciklička granica tečenja R'_e definirana kao naprezanje koje se javlja pri vrijednosti amplitude plastične deformacije $\Delta\varepsilon_p/2 = 0,2\%$, iz čega slijedi

$$R'_e = K' \cdot 0,002^{n'}. \quad (12)$$

Utvrđivanje međusobne ovisnosti naprezanja i deformacija pri djelovanju cikličkog opterećenja, a posebice relativnih udjela amplituda elastične i plastične deformacije ($\Delta\epsilon_e/2$ i $\Delta\epsilon_p/2$) u amplitudi ukupne deformacije $\Delta\epsilon/2$, neizostavan je dio karakterizacije zamornog ponašanja materijala pomoću pristupa temeljenog na deformaciji, o kojem će biti riječ u narednom odjeljku.

2.1.3 Karakterizacija zamaranja materijala

2.1.3.1 Općenito o zamoru materijala

Zamor materijala (engl. *fatigue*) je progresivno, lokalizirano i trajno strukturno oštećenje materijala izloženog djelovanju cikličkih opterećenja, koja u materijalu uzrokuju pojavu cikličkih naprezanja i plastičnih deformacija. Plastične deformacije nužan su uvjet za pokretanje procesa zamaranja materijala i njime uzrokovanog otkazivanja dijela ili konstrukcije, a mogu se javiti i pri nazivnim naprezanjima manjim od granice tečenja R_e odnosno R_e' [5]. U tom slučaju u materijalu se pri normalnoj temperaturi plastične deformacije javljaju u lokaliziranim područjima koncentracije naprezanja – uzrokovane promjenom geometrije, zaostalim naprezanjima, mikrostrukturnim nesavršenostima i dr. – te postupno iniciraju zamorne pukotine¹. Proces zamaranja materijala može se podijeliti u četiri faze: *inicijacija pukotine* (engl. *crack initiation*), *rast kratkih pukotina*, *rast dugih pukotina* (engl. *crack propagation*) i *lom*.

Tri su glavna pristupa karakterizaciji procesa zamaranja i predviđanja vijeka trajanja dijelova i konstrukcija:

- *pristup temeljen na naprezanju* (engl. *stress-based approach*),
- *pristup temeljen na deformaciji* (engl. *strain-based approach*) i
- *pristup temeljenim na načelima mehanike loma* (engl. *fracture mechanics crack growth*).

Pristup temeljen na naprezanju najstariji je pristup karakterizaciji procesa zamaranja i predviđanja vijeka trajanja dijelova i konstrukcija², koji povezuje broj izmjena opterećenja do

¹ Pri visokim temperaturama javlja se i vremenski ovisna trajna deformacija uzrokovana *puzanjem*.

² Začetnikom najstarijeg pristupa karakterizaciji procesa zamaranja i predviđanja vijeka trajanja dijelova i konstrukcija možemo smatrati njemačkog inženjera Augusta Wöhlera (1819–1914). Wöhler je na željezničkim

otkazivanja $2N_f$ s amplitudom nominalnog naprezanja $\Delta\sigma/2$. Basquin je 1910. pokazao da se njihova međusobna ovisnost može aproksimirati eksponencijalnom funkcijom

$$\Delta\sigma/2 = \sigma'_f (2N_f)^b, \quad (13)$$

koja se u dvostrukom logaritamskom mjerilu može prikazati pravcem. U izrazu (13) σ'_f je koeficijent dinamičke čvrstoće, a b eksponent dinamičke čvrstoće.

Pristup temeljen na naprezanju primjenjiv je samo u slučaju *visokocikličkog zamora*, kad su vrijednosti nazivnih naprezanja dovoljno male da u ukupnoj deformaciji prevladavaju elastične deformacije.

Uz pristup temeljen na naprezanju često se veže pojam *trajne dinamičke čvrstoće* (engl. *fatigue limit, endurance limit*), koji implicira da pri dovoljno maloj vrijednosti nazivnog naprezanja vijek trajanja postaje neograničen. Međutim, trajna dinamička čvrstoća postoji samo kod metala s prostorno centriranom kubičnom rešetkom (poput α -željeza), dok je metali s plošno centriranom kubičnom rešetkom (poput γ -željeza ili aluminija) zapravo i nemaju. U potonjem se slučaju uvodi *uvjetna* trajna dinamička čvrstoća uz definiran broj ciklusa opterećenja N_f (uobičajeno $N_f = 10^7$) kod kojeg još neće doći do loma ispitnog uzorka.

Pristup temeljen na deformaciji povezuje broj izmjena opterećenja do otkazivanja $2N_f$ s amplitudom ukupne deformacije $\Delta\varepsilon/2$ koju čine dvije komponente: amplituda elastične deformacije $\Delta\varepsilon_e/2$ i amplituda plastične deformacije $\Delta\varepsilon_p/2$. Ovim pristupom moguća je detaljna analiza zamora materijala u područjima gdje naprezanja prelaze granicu tečenja R_e materijala te je on prikladniji za procjenu vijeka trajanja u slučaju niskocikličkog zamora, kad u ukupnoj deformaciji prevladavaju plastične deformacije [18]. Osim toga, pristupom temeljenim na deformaciji uspješno se karakterizira i visokociklički zamor, pa se on primjenjuje za karakterizaciju zamaranja većine metalnih materijala. Iz tog je razloga daljnje istraživanje u ovom radu temeljeno na pristupu temeljenom na deformaciji.

Pristup temeljen na načelima mehanike loma (engl. *fracture mechanics crack growth*) analizira rast već postojećih makroskopskih pukotina (engl. *long cracks*), što se u ovom istraživanju neće razmatrati.

osovinama proveo prvo sustavno ispitivanje zamora materijala te je ustanovio da vijek trajanja osovina ovisi o amplitudi naprezanja $\Delta\sigma/2$ kojem su izložene, ali i o vrijednosti srednjeg naprezanja σ_m [18].

2.1.3.2 Pristup karakterizaciji procesa zamaranja materijala temeljen na deformaciji

Pristup karakterizaciji procesa zamaranja materijala temeljen na deformaciji (engl. *strain-based approach*) predložili su Coffin i Manson 50-ih godina 20. st. U međusobno neovisnim istraživanjima problematike niskocikličkog zamora broj izmjena opterećenja do nastanka pukotine (ili loma) $2N_f$ povezali su s amplitudom plastične deformacije $\Delta\varepsilon_p/2$ [5, 18, 49]

$$\Delta\varepsilon_p/2 = \varepsilon'_f(2N_f)^c. \quad (14)$$

Danas se za procjenu broja izmjena opterećenja do otkazivanja $2N_f$, za veliku većinu metalnih materijala, uspješno primjenjuje integralni pristup opisan *Basquin–Coffin–Mansonovim (BCM) izrazom*, koji povezuje amplitudu ukupne deformacije $\Delta\varepsilon/2$ s brojem izmjena opterećenja do otkazivanja $2N_f$

$$\frac{\Delta\varepsilon}{2} = \frac{\Delta\varepsilon_e}{2} + \frac{\Delta\varepsilon_p}{2} = \frac{\sigma'_f}{E}(2N_f)^b + \varepsilon'_f(2N_f)^c. \quad (15)$$

Procjena vijeka trajanja pomoću izraza (15) praktičnija je za inženjersku primjenu od izraza (14), s obzirom na to da je mjerenje ukupne deformacije lakše od mjerenja plastične deformacije. Procedura karakterizacije zamaranja materijala na osnovi deformacije propisana je normom ASTM E606 [6], kao i postupak karakterizacije cikličkog odziva materijala.


Ovisnosti vrijednosti amplituda ukupne, elastične i plastične deformacije ($\Delta\varepsilon/2$, $\Delta\varepsilon_e/2$ i $\Delta\varepsilon_p/2$) i broja izmjena opterećenja do otkazivanja $2N_f$ uobičajeno se prikazuju u dvostrukom logaritamskom dijagramu, slijedom čega su ovisnosti $\Delta\varepsilon_e/2-2N_f$ i $\Delta\varepsilon_p/2-2N_f$ pravci³ [18, 49, 78]. Omjer koeficijenta dinamičke čvrstoće i modula elastičnosti σ'_f/E odgovara vrijednosti amplitude elastične deformacije $\Delta\varepsilon_e/2$ pri kojoj bi (teoretski) do otkazivanja došlo nakon jedne izmjene opterećenja, tj. pri $2N_f = 1$ (odnosno 1/2 ciklusa opterećenja), a eksponent dinamičke čvrstoće b koeficijent je smjera dotičnog pravca i on je negativan (slika 2.7).

³ Ovisnost broja izmjena opterećenja do otkazivanja $2N_f$ o amplitudi elastične $\Delta\varepsilon_e/2$ i/ili amplitudi plastične deformacije $\Delta\varepsilon_p/2$ za neke slitine, uključujući neke dvofazne čelike, aluminijske i titanijske slitine, odstupa od pravca. Također, u slučajevima kad unutarnje greške značajno utječu na vijek trajanja materijala (kod lijevanih metala, materijala zavara, kompozita itd.) potrebno je modificirati dani izraz tako da uračunava utjecaj grešaka u mikrostrukturi [5].




Slika 2.7 Ovisnost broja izmjena opterećenja do otkazivanja o amplitudi elastične deformacije $\Delta\epsilon_e/2-2N_f$, prema [76]

Ovisnost broja izmjena opterećenja do otkazivanja $2N_f$ o amplitudi plastičnih deformacija $\Delta\epsilon_p/2$ određena je koeficijentom cikličkih deformacija ϵ_f' , koji predstavlja vrijednost amplitude plastične deformacije $\Delta\epsilon_p/2$ pri kojoj do otkazivanja dolazi već nakon jedne izmjene opterećenja, tj. pri $2N_f = 1$, i negativnim eksponentom cikličkih deformacija c kao koeficijentom smjera odgovarajućeg pravca u dvostrukom logaritamskom mjerilu (slika 2.8).



Slika 2.8 Ovisnost broja izmjena opterećenja do otkazivanja o amplitudi plastične deformacije $\Delta\epsilon_p/2-2N_f$, prema [76]

Parametri pravaca σ'_f , b , ε'_f i c još se nazivaju i *zamornim parametrima* i u potpunosti određuju međusobnu ovisnost ukupne amplitude deformacije $\Delta\varepsilon/2$ i broja izmjena opterećenja do otkazivanja $2N_f$ (slika 2.9).



Slika 2.9 Ovisnosti broja izmjena opterećenja do otkazivanja $2N_f$ o amplitudi elastične $\Delta\varepsilon_c/2$, plastične $\Delta\varepsilon_p/2$ i ukupne $\Delta\varepsilon/2$ deformacije, prema [5]

Sjecište pravaca $\Delta\varepsilon_c/2-2N_f$ i $\Delta\varepsilon_p/2-2N_f$ je *točka tranzicije* (engl. *transition point*), kojoj odgovara amplituda deformacije $\Delta\varepsilon_T/2$, odnosno broj izmjena opterećenja $2N_T$. Broj izmjena opterećenja N_T koji odgovara točki tranzicije ovisi o materijalu, a uobičajeno iznosi $2 \cdot 10^2 \dots 2 \cdot 10^4$ [18, 49].

Iako točka tranzicije intuitivno daje naslutiti vrijednost amplitude ukupne deformacije $\Delta\varepsilon/2$ pri kojoj se ponašanje mijenja iz dominantno plastičnog u dominantno elastično, područje visokocikličkog zamora prema [49] može se definirati kao ono područje gdje je vrijednost amplitude ukupnih deformacija $\Delta\varepsilon/2$ jednaka ili manja od 75 % amplitude deformacije koja odgovara točki tranzicije, $\Delta\varepsilon_T/2$. Uz ovaj kriterij amplituda plastičnih deformacija $\Delta\varepsilon_p/2$ iznosi manje od 10 % amplitude elastičnih deformacija $\Delta\varepsilon_c/2$ te je u tom slučaju za karakterizaciju procesa zamaranja i predviđanja vijeka trajanja dijelova i konstrukcija razumno primijeniti pristup temeljen na naprezanju.

2.2 Pregled postojećih metoda procjene cikličkih i zamornih parametara materijala na osnovi njihovih monotonih značajki

2.2.1 Uvod

Određivanje cikličkog i zamornog ponašanja materijala i pripadajućih RO i BCM parametara u izrazima (11) i (15) najtočnije je eksperimentalnim putem, no eksperimentalna karakterizacija je zbog svoje složenosti, dugotrajnosti i visokih troškova teško primjenjiva u ranim fazama razvoja proizvoda, u kojima se tek preliminarno vrednuju različita konstrukcijska rješenja i materijali. Stoga su u postojećim istraživanjima dostupne brojne metode procjene, koje pokušavaju povezati cikličke i zamorne parametre s lako odredivim monotonim značajkama. Uz pretpostavku da se na taj način može postići razumna razina točnosti, procjena cikličkog i zamornog ponašanja i parametara materijala na osnovi njihovih monotonih značajki može značajno smanjiti potrebu za eksperimentalnom karakterizacijom velikog broja materijala i unaprijediti proces razvoja proizvoda već u samom začetku.

2.2.2 Empirijske metode procjene cikličkih i zamornih parametara i ponašanja materijala

2.2.2.1 Metode kvalitativne procjene ponašanja materijala izloženog cikličkom opterećenju

Za praktičnu je primjenu, osim poznavanja vrijednosti cikličkih i zamornih parametara, korisno i poznavanje ponašanja ciklički opterećenog materijala u odnosu na ponašanje monotono opterećenog materijala. Prve metode procjene cikličkog ponašanja razvijene su za kvalitativnu procjenu tipa cikličkog ponašanja, odnosno predviđanja da li će materijal izložen cikličkom opterećenju ciklički očvršćivati, oslabljivati ili pokazati mješovito ponašanje.

Smith et al. [75] proveli su monotone i cikličke eksperimente na heterogenoj skupini metalnih materijala (čelika, aluminijskih i titanijevih slitina, niklovijskih slitina, čistom beriliju) i utvrdili razumnu razinu povezanosti tipa cikličkog ponašanja s omjerom vlačne čvrstoće i granice tečenja R_m/R_e . Usporedbom monotonih i cikličkih krivulja naprežanje–deformacija utvrđuju da materijali kod kojih je omjer $R_m/R_e \geq 1,4$ ciklički očvršćuju, oni s $R_m/R_e \leq 1,2$ ciklički oslabljuju, dok se kod materijala s vrijednostima $1,2 < R_m/R_e < 1,4$ može javiti i cikličko očvršćivanje i cikličko oslabljivanje. Dodatno je utvrđeno da cikličkom očvršćivanju odnosno

oslabljivanju čeličnih i aluminijskih slitina odgovaraju vrijednosti eksponenta deformacijskog očvršćivanja $n > 0,11$ odnosno $n < 0,07$ [49].

Landgraf et al. [39] uspoređivali su krivulje naprezanje–deformacija iz monotonih i cikličkih eksperimenata provedenih za 18 različito toplinski obrađenih metalnih materijala (bakra, aluminijskih, titanijskih i nikloviskih slitina te čelika s rasponom tvrdoće od 350 do 670 HB). Usporedbom granice tečenja i eksponenta deformacijskog očvršćivanja iz monotonih (R_e , n) i cikličkih eksperimenata (R_e' , n') utvrđeno je da materijali s niskim vrijednostima eksponenta deformacijskog očvršćivanja n ciklički oslabljuju, dok oni s visokim vrijednostima n ciklički očvršćuju. Različito ponašanje utvrđeno je za čelike SAE 1045 i SAE 4142 različitih tvrdoća. Čelik veće tvrdoće (670 HB) ciklički je očvrstnuo, čelici tvrdoće manje od 500 HB ciklički su oslabljivali, dok su čelici s tvrdoćom između navedenih vrijednosti pokazali približno stabilno ponašanje u odnosu na monotone krivulje naprezanje–deformacija.

Zhang et al. [90] za procjenu cikličkog ponašanja materijala predlažu tzv. "novi parametar loma α ", koji definiraju kao umnožak smanjenja poprečnog presjeka pri lomu Z i stvarnog istezanja pri lomu ε_f . Istraživanje provedeno na skupini od 40 različitih metalnih materijala (čelika, aluminijskih i titanijskih slitina te čistom cirkoniju) u [90] pokazalo je da za vrijednosti $\alpha < 2\%$ i $20\% < \alpha < 65,4\%$ materijali ciklički oslabljuju, dok za vrijednosti $2\% < \alpha < 20\%$ i $\alpha > 65,4\%$ ciklički očvršćuju. U prethodnom istraživanju [89] granica između cikličkog oslabljivanja i očvršćivanja je postavljena na $\alpha = 20\%$, što daje naslutiti da kvalitativna procjena cikličkog ponašanja materijala na temelju novog parametra loma α značajno ovisi o podacima na kojima se istraživanje temeljilo.

Lopez i Fatemi [44] evaluirali su kriterije kvalitativne procjene cikličkog ponašanja na uzorku od 114 čelika (većinom nelegiranih i niskolegiranih). Utvrđeno je da kriteriji procjene na osnovi omjera R_m/R_e [75], eksponenta deformacijskog očvršćivanja n [39] i novog parametra loma α [89, 90] nisu pouzdani za kvalitativnu procjenu cikličkog ponašanja materijala s obzirom na to da je kriterij na osnovi eksponenta deformacijskog očvršćivanja n , kao najuspješniji kriterij, točno predviđao ponašanje tek za 63 % materijala. Ispitivanjem mogućnosti procjene cikličkog ponašanja na osnovi Brinellove tvrdoće HB i vlačne čvrstoće R_m utvrdili su da čelici vlačne čvrstoće R_m manje od 920 MPa i Brinellove tvrdoće HB manje od 250 HB pokazuju mješovito ponašanje (u početku će ciklički očvršćivati, potom ciklički oslabljivati), dok čelici vlačne čvrstoće R_m veće od 920 MPa i Brinellove tvrdoće HB veće od 250 HB ciklički oslabljuju. Nije, međutim, dan kriterij za procjenu cikličkog očvršćivanja.

2.2.2.2 Metode procjene cikličkih parametara materijala

Novije metode procjene cikličkog ponašanja izravno procjenjuju koeficijent cikličkog deformacijskog očvršćivanja K' i eksponent cikličkog deformacijskog očvršćivanja n' na osnovi monotonih značajki materijala, kao i cikličku granicu tečenja R_e' .

Zhang et al. [91] predlažu nekoliko izraza za procjenu K' i n' razvijenih na eksperimentalnim podacima za 22 materijala, i to čelika, aluminijskih i titanijskih slitina. Kako bi povećali točnost procjena, materijale grupiraju ovisno o vrijednosti ranije predloženog novog parametra loma α i predlažu različite izraze za procjenu K' i n' svake skupine. Najuspješnijim je ocijenjen izraz za procjenu K' na osnovi monotonog koeficijenta deformacijskog očvršćivanja K . Eksponent cikličkog deformacijskog očvršćivanja n' povezuju s vlačnom čvrstoćom R_m , granicom tečenja R_e , stvarnim naprežanjem pri lomu σ_f i eksponentom deformacijskog očvršćivanja n . Za čelike, procijenjene vrijednosti K' i n' prema danim izrazima odstupaju do 27 % i 34 % od odgovarajućih eksperimentalnih vrijednosti. Za aluminijske i titanijske slitine maksimalna odstupanja procijenjenog n' iznose čak do 65 %. Za slučaj kad K i n nisu poznati predlažu dodatne izraze temeljene na izrazima za procjenu monotonih K i n na osnovi vlačne čvrstoće R_m , granice tečenja R_e , stvarnog naprežanja pri lomu σ_f i stvarnog istezanja pri lomu ε_f . Osim izračuna odstupanja pojedinačnih vrijednosti procijenjenih parametara vrednovanje pristupa provedeno je usporedbom cikličkih krivulja naprežanje–deformacija dobivenih na osnovi procijenjenih i eksperimentalnih vrijednosti cikličkih parametara te je utvrđeno da za točnu procjenu cikličkih krivulja, osim brojčane vrijednosti, veliku važnost ima i predznak odstupanja. Ukoliko procijenjene vrijednosti oba parametra K' i n' odstupaju s istim predznakom, procijenjene krivulje dobro odgovaraju eksperimentalnim krivuljama. Međutim, ako predznak odstupanja parametara K' i n' nije isti, procijenjene krivulje značajno odstupaju od eksperimentalnih.

Li et al. [42] predložili su izraz za procjenu cikličke granice tečenja R_e' na osnovi vlačne čvrstoće R_m i smanjenja poprečnog presjeka pri lomu Z korištenjem rezultata monotonih i cikličkih ispitivanja 27 čelika (većinom nelegiranih i niskolegiranih). Evaluacijom predloženog izraza na istim podacima koji su korišteni za razvoj metode utvrđeno je da procijenjene vrijednosti odstupaju do najviše 14 % od eksperimentalnih vrijednosti R_e' .

Basan et al. [11] predlažu preliminarnu metodu procjene cikličkih parametara na temelju Brinellove tvrdoće HB . Metoda je razvijena na podacima za 40 različito toplinski obrađenih

niskolegiranih čelika 42CrMo4 s rasponom tvrdoće od 186 do 670 HB. Ustanovljena je dobra korelacija koeficijenta cikličkog deformacijskog očvršćivanja K' s tvrdoćom izražena u obliku polinoma drugog stupnja. Veza između tvrdoće i eksponenta cikličkog deformacijskog očvršćivanja n' nije utvrđena, pa mu je pripisana srednja vrijednost eksponenta n' svih razmatranih materijala. Evaluacijom vrijednosti amplituda naprezanja $\Delta\sigma/2$ proračunatih na osnovi procijenjenih i eksperimentalnih vrijednosti K' i n' za niz amplituda plastičnih deformacija $\Delta\varepsilon_p/2$ utvrđeno je da otprilike 80 % procijenjenih amplituda naprezanja $\Delta\sigma/2$ odstupa do najviše 20 % od eksperimentalnih vrijednosti.

Lopez i Fatemi [44] predlažu više izraza za procjenu cikličke granice tečenja R_e' te cikličkih parametara K' i n' , za sve čelike ili zasebno za njihove grupe formirane prema omjeru vlačne čvrstoće i granice tečenja R_m/R_e ($R_m/R_e > 1,2$ i $R_m/R_e \leq 1,2$). Metode su razvijane i evaluirane na velikom uzorku od 123 čelika (većinom nelegiranih i niskolegiranih) velikog raspona vlačne čvrstoće R_m (279 MPa do 2450 MPa) i Brinellove tvrdoće (80 HB do 595 HB). Predlažu tri izraza za procjenu koeficijenta cikličkog deformacijskog očvršćivanja K' , i to na osnovi Brinellove tvrdoće HB , vlačne čvrstoće R_m i koeficijenta deformacijskog očvršćivanja K . Svi izrazi dani su za čelike grupirane prema omjeru R_m/R_e , a evaluacijom je utvrđeno da oko 70 % vrijednosti K' procijenjenih na osnovi HB i R_m odstupa do 20 % od eksperimentalnih vrijednosti, dok je za procjenu K' na osnovi K taj postotak oko 60 %. Za procjenu eksponenta cikličkog deformacijskog očvršćivanja n' daju tri izraza – jedan na temelju eksponenta deformacijskog očvršćivanja n , drugi na temelju omjera granice tečenja i vlačne čvrstoće R_e/R_m i treći na temelju vlačne čvrstoće R_m i granice tečenja R_e (za čelike grupirane prema R_m/R_e). Najuspješnijom je ocijenjena procjena n' na osnovi omjera granice tečenja i vlačne čvrstoće R_e/R_m (nešto manje od 70 % tako procijenjenih vrijednosti n' odstupa 20 % ili manje od eksperimentalnih vrijednosti). Za procjenu cikličke granice tečenja R_e' predlažu također tri izraza – za sve čelike predlažu izraze na temelju Brinellove tvrdoće HB i vlačne čvrstoće R_m , a za čelike grupirane prema omjeru R_m/R_e predlažu izraze na osnovi granice tečenja R_e . Evaluacijom je utvrđena dobra podudarnost procijenjenih i eksperimentalnih vrijednosti R_e' , ali i da je izraz koji su predložili Li et al. u [42] prikladniji za procjenu R_e' .

Kako je u [44] utvrđeno da izraz za procjenu R_e' iz [42] rezultira podcijenjenim vrijednostima u slučaju da je $R_e' < 900$ MPa, Li et al. u [43] predlažu njegovu modifikaciju. Koriste većinom iste podatke kao i autori u [44]. Novopredloženi izraz (A.5) treba, međutim, koristiti oprezno, s obzirom na to da autori konstatiraju da se vrijednost stvarnog naprezanja pri lomu σ_f može procijeniti koristeći relaciju $\sigma_f = R_m(1+Z)$ (prvi dio izraza (A.5)). Međutim, poznati izraz za

procjenu stvarnog naprezanja pri lomu σ_f (10) uključuje vlačnu čvrstoću R_m i stvarno istežanje pri lomu ε_f . Osim izraza za procjenu cikličke granice tečenja Li et al. u [43] predlažu i izraze za procjenu cikličkih parametara K' i n' . Ukoliko je poznat jedan od tih parametara, predlažu da se drugi parametar procijeni iz procijenjene cikličke granice tečenja R_e' i plastičnog dijela izraza (11) za amplitudu plastične deformacije $\Delta\varepsilon_p/2 = 0,2\%$, kojoj odgovara amplituda naprezanja jednaka cikličkoj granici tečenja R_e' . U slučaju da niti K' niti n' nisu poznati, predlažu procjenu koeficijenta cikličkog deformacijskog očvršćivanja K' na osnovi vlačne čvrstoće R_m . Kao i u [75], različiti izrazi za procjenu K' dani su za čelike grupirane prema omjeru R_m/R_e .

Pod pretpostavkom da su rasponi elastičnih $\Delta\varepsilon_e$ i plastičnih deformacija $\Delta\varepsilon_p$ iz izraza (11) i (15) identični, ciklički RO parametri K' i n' mogu se procijeniti na osnovi zamornih BCM parametara materijala u skladu s tzv. *uvjetom kompatibilnosti* (engl. *compatibility condition*)

$$K' = \sigma_f' / \varepsilon_f'^{n'} , \quad (16)$$

$$n' = b/c . \quad (17)$$

Međutim, prema [57], [66] i [78] primjenjivost uvjeta kompatibilnosti uvelike ovisi o načinu dobivanja parametara u izrazima (11) i (15) pa vrijednosti cikličkih parametara izračunatih prema (16) i (17) mogu značajno odstupati od eksperimentalnih vrijednosti. Stoga, iako se izrazi (16) i (17) mogu koristiti za grubu procjenu cikličkih parametara K' i n' [78], kad je moguće, njihove vrijednosti treba odrediti neovisno o zamornim parametrima materijala.

2.2.2.3 Metode procjene zamornih parametara materijala

Prve metode procjene zamornih parametara na osnovi monotonih značajki materijala, metodu univerzalnih nagiba pravaca i korelacijsku metodu četiriju točaka, predložio je Manson 1965. godine [48]. U metodi univerzalnih nagiba pravaca koeficijent dinamičke čvrstoće σ_f' povezuje se s vlačnom čvrstoćom R_m , a ε_f' sa stvarnim istežanjem pri lomu ε_f (ili smanjenjem poprečnog presjeka pri lomu Z). Eksponentima b i c , tj. nagibima elastičnih i plastičnih pravaca u $\Delta\varepsilon/2-2N_f$ dijagramu, pripisane su konstantne vrijednosti po čemu je ta metoda i nazvana. U korelacijskoj metodi četiriju točaka određivanje zamornih parametara temelji se na koreliranju amplituda elastične $\Delta\varepsilon_e/2$ i plastične deformacije $\Delta\varepsilon_p/2$ za četiri vrijednosti ciklusa opterećenja ($N_f = 1/4$ i $N_f = 10^5$ za pravac $\Delta\varepsilon_e/2-2N_f$, $N_f = 10$ i $N_f = 10^4$ za pravac $\Delta\varepsilon_p/2-2N_f$). Procjena zamornih parametara temelji se na vlačnoj čvrstoći R_m , stvarnom naprežanju σ_f i stvarnom istežanju pri lomu ε_f . U nedostatku eksperimentalnih vrijednosti ε_f se može izračunati iz smanjenja poprečnog presjeka pri lomu Z (8), a σ_f iz vlačne čvrstoće R_m i stvarnog istežanja pri

lomu ε_f (10). Obje metode razvijene su na eksperimentalnim podacima za 29 raznovrsnih metala.

Mitchell [76] predlaže metodu za procjenu zamornih parametara čelika Brinellove tvrdoće $HB \leq 500$ HB prema kojoj se σ_f' i b mogu procijeniti iz vlačne čvrstoće R_m . Koeficijentu cikličkih deformacija ε_f' pripisuje vrijednost stvarnog istezanja pri lomu ε_f iz monotonih eksperimenata, a eksponentu c konstantnu vrijednost, ali različitu za duktilne i za krhke materijale.

Muralidharan i Manson u [64] predlažu modificiranu metodu univerzalnih nagiba pravaca. Procjenu koeficijenta dinamičke čvrstoće σ_f' temelje na osnovi novouvedenog parametra, omjera vlačne čvrstoće i modula elastičnosti R_m/E , a iz R_m/E i ε_f procjenjuju koeficijent cikličkih deformacija ε_f' . Ujedno korigiraju konstantne vrijednosti eksponenata b i c na po njima prikladnije vrijednosti za sve materijale. Metoda je razvijena na podacima za 47 čelika, aluminijevih i titanijevih slitina.

Bäumel i Seeger [14] prvi su prepoznali potrebu odvojenog razmatranja različitih skupina materijala. U okviru svog uniformnog materijalnog zakona predložili su različite izraze za procjenu zamornih parametara za čelike (nelegirane i niskolegirane) te za titanijeve i aluminijeve slitine. Statističkom analizom 125 skupova podataka ustanovili su da su vrijednosti eksponenta dinamičke čvrstoće b i eksponenta cikličkih deformacija c za aluminijeve i titanijeve slitine načelno niže nego za čelike. Ovo objašnjava i relativno niske vrijednosti eksponenta b koje je predložio Manson u metodi univerzalnih nagiba pravaca razvijenoj na skupini materijala koja je osim čelika obuhvaćala i druge vrste metalnih materijala, uključujući aluminijeve i titanijeve slitine. Bäumel i Seeger povezuju koeficijent dinamičke čvrstoće σ_f' s vlačnom čvrstoćom R_m , a koeficijent cikličkih deformacija ε_f' s omjerom vlačne čvrstoće i modula elastičnosti R_m/E za čelike, dok koeficijentu ε_f' aluminijevih i titanijevih slitina pripisuju konstantnu vrijednost. Konstantne vrijednosti u oba slučaja pripisuju i eksponentima b i c . Kako je za primjenu uniformnog materijalnog zakona potrebno poznavati samo vlačnu čvrstoću R_m i modul elastičnosti E , ova je metoda i danas u širokoj upotrebi u praksi.

Ong [67] predlaže modifikaciju Mansonove korelacijske metode četiriju točaka. Kao i Manson [48], određuje b i c kao funkcije vlačne čvrstoće R_m i vrijednosti stvarnog istezanja pri lomu ε_f . Koeficijentu cikličkih deformacija ε_f' , kao i Mitchell [76], pripisuje vrijednost stvarnog istezanja pri lomu ε_f . Metoda je razvijena na podacima za 49 čelika različite duktilnosti ($Z = 10 \dots 80$ %) i velikog raspona vrijednosti vlačne čvrstoće ($R_m = 300 \dots 2500$ MPa).

Roessle i Fatemi [73] predlažu metodu tvrdoće u kojoj zamornim eksponentima b i c pripisuju konstantne vrijednosti koje su im dodijeljene u modificiranoj metodi univerzalnih nagiba pravaca [64]. Zamorne koeficijente σ_f' i ε_f' pak procjenjuju na temelju Brinellove tvrdoće HB i modula elastičnosti E . Metoda je razvijena i evaluirana na podacima za 69 čelika. Kao i uniformni materijalni zakon, metoda tvrdoće praktična je za upotrebu s obzirom ne to da za njenu primjenu treba poznavati jedino široko dostupne i lako mjerljive monotone značajke.

Meggiolaro i Castro [57] razvijaju metodu medijana, u kojoj koeficijent dinamičke čvrstoće σ_f' povezuju s vlačnom čvrstoćom R_m , dok svim ostalim parametrima pripisuju konstantne vrijednosti. Odvojeno razmatraju različite skupine metala: čelike, aluminijske slitine, titanijske slitine, niklove slitine i lijevano željezo, uz napomenu da vrijednosti medijana zamornih parametara za posljednje tri skupine treba koristiti oprezno, s obzirom na vrlo mali uzorak na kojem su metode razvijene. Uzimanje u obzir specifičnosti pojedinih skupina metala opravdavaju vrlo različitim vrijednostima zamornih eksponenta b i c čelika te aluminijskih i titanijskih slitina. Valja napomenuti da je četvrtina podataka za čelike koje Meggiolaro i Castro koriste za razvoj metode dobivena ispitivanjem na povišenim temperaturama. Iako navode da temperatura ne utječe značajno na $\Delta\varepsilon/2-2N_f$ krivulje, ustanovili su da se vrijednosti zamornih koeficijenata σ_f' i ε_f' čelika ispitivanih na povišenim temperaturama razlikuju od onih dobivenih eksperimentima na sobnoj temperaturi.

Basan u [8] i [9] predlaže nov pristup procjeni zamornih parametara. Za razliku od prijašnjih pristupa, koji su direktno povezivali monotone značajke i zamorne parametre, povezuje Brinellovu tvrdoću HB s odnosom $\Delta\varepsilon/2-2N_f$. Iz dobivenih relacija računaju se novi zamorni parametri za svaku vrijednost tvrdoće, a potom utvrđuju funkcionalne zavisnosti između zamornih parametara i tvrdoće. Ključna prednost nove metode je zajednička, a ne individualna procjena zamornih parametara. Preliminarnom procjenom valjanosti pristupa pokazano je da vrijednosti broja izmjena opterećenja do otkazivanja dobivene na temelju tako izračunatih zamornih parametara vrlo dobro koreliraju s eksperimentalnim vrijednostima vijeka trajanja, osim u području visokocikličkog zamora. Kako je visokociklički zamor praćen velikim rasapom rezultata, ovakvi rezultati su očekivani. Metoda je razvijena i evaluirana na uzorku od 32 različito toplinski tretirana niskolegirana čelika AISI4140 i AISI4142.

2.2.2.4 Evaluacija empirijskih metoda procjene cikličkih i zamornih parametara na osnovi monotonih značajki

Od 1993. je u relevantnoj literaturi publicirano i nekoliko radova koji ocjenjuju uspješnost empirijskih metoda procjene cikličkih krivulja naprezanje–deformacija i broja izmjena opterećenja do otkazivanja $2N_f$, kao samostalno istraživanje ili u okviru novopredloženih pristupa. Evaluacije metoda procjene na neovisnom skupu podataka (koji nije korišten za njihov razvoj) vrlo su važne, budući da uspješnost i primjenjivost metode izravno ovisi o kvaliteti i sastavu uzorka podataka korištenog za njen razvoj.

Ong [67] je analizom dviju Mansonovih metoda i Mitchellove metode utvrdio da potonja daje nekonzervativne procjene broja izmjena opterećenja do otkazivanja $2N_f$, koje značajno odstupaju od eksperimentalnih vrijednosti (osobito u području visokocikličkog zamora). Obje Mansonove metode rezultiraju podjednako dobrim procjenama broja izmjena opterećenja do otkazivanja $2N_f$, no na razini pojedinačnih parametara samo vrijednosti procijenjenih koeficijenata dinamičke čvrstoće σ'_f zadovoljavajuće koreliraju s eksperimentalnim vrijednostima.

Park i Song [68] za vrednovanje uspješnosti najvažnijih dotad objavljenih metoda uvode novu metodologiju za vrednovanje metoda procjene koja pored dotad gotovo isključivo korištenog *konvencionalnog kriterija greške* (engl. *conventional error criterion*) koristi i dva dodatna pokazatelja: *srednju vrijednost kriterija dobrote prilagodbe* (engl. *goodness of fit criterion*) za pojedine materijale i *kriterij dobrote prilagodbe za sve materijale zajedno*. Uvode i sveobuhvatni pokazatelj valjanosti metode kao srednju vrijednost prethodno navedenih kriterija. Evaluacija metoda procjene izvršena je na uzorku od 315 eksperimentalnih $\Delta\epsilon/2-2N_f$ krivulja (138 različitih materijala). Konstatiraju da obje Mansonove izvorne metode daju vrlo konzervativne procjene za velik broj izmjena opterećenja, a nekonzervativne za mali broj izmjena opterećenja. Modificirana metoda univerzalnih nagiba pravaca najprikladnija je za procjenu broja izmjena opterećenja do otkazivanja $2N_f$ svih čelika, ali i aluminijevih i titanijevih slitina, dok uniformni materijalni zakon daje podjednako dobre procjene za nelegirane i visokolegirane čelike. Park i Song potvrdili su da Mitchellova metoda rezultira nekonzervativnim predviđanjima za sve vrijednosti broja izmjena opterećenja do otkazivanja, iako se pokazala prikladnom za primjenu na aluminijevim slitinama. Za procjenu broja izmjena opterećenja titanijevih slitina naprikladnijom se pokazala Ongova modificirana korelacijska metoda četiriju točaka, a izvorna Mansonova korelacijska metoda četiriju točaka pokazala se

najlošijom od svih metoda za sve skupine metala. Osobitost ovog istraživanja je zasebno tretiranje čelika s obzirom na udio legirajućih elemenata, kao i zasebno tretiranje aluminijskih i titanijskih slitina.

Roessle i Fatemi [73] dolaze do gotovo istih zaključaka kao i Park i Song u [68], uz naglasak da nema dovoljno snažne korelacije između koeficijenta dinamičke čvrstoće σ_f' i stvarne vrijednosti napreznja pri lomu σ_f . Utvrdili su i da procjena koeficijenta cikličkih deformacija ε_f' na temelju vrijednosti stvarnog istežanja pri lomu ε_f iz monotonih eksperimenata može dovesti do značajnih pogrešaka u procjeni vijeka trajanja.

Jeon i Song [33] provode evaluaciju na vrlo velikom uzorku, koristeći kriterije iz [68], i zasebno razmatraju nelegirane, niskolegirane i visokolegirane čelike, kao i aluminijske i titanijske slitine. Najboljim metodama za procjenu vijeka trajanja svih skupina čelika pokazale su se modificirana metoda univerzalnih nagiba pravaca, uniformni materijalni zakon i Ongova modificirana korelacijska metoda četiriju točaka.

Analizirajući najvažnije dotad objavljene metode procjene na eksperimentalnim podacima osam čelika Kim et al. [36] utvrđuju da uniformni materijalni zakon Bäumela i Seegera, metoda tvrdoće Roesslea i Fatemija te Muralidharanova i Mansonova modificirana metoda univerzalnih nagiba pravaca rezultiraju najtočnijim procjenama vijeka trajanja. Ongovu metodu ocjenjuju vrlo nekonzervativnom, osobito za broj izmjena opterećenja do otkazivanja $2N_f$ veći od 10^4 , dok Mitchellova metoda rezultira nekonzervativnim procjenama i u niskocikličkom i u visokocikličkom režimu.

Meggiolaro i Castro [57] su na uzorku podataka korištenom za razvoj i evaluaciju novopredložene metode medijana evaluirali i sve ostale postojeće metode procjene zamornih parametara. Utvrđeno je da Mitchellova metoda i metoda tvrdoće precjenjuju vrijednosti koeficijenta dinamičke čvrstoće σ_f' , kao i da se σ_f' ne bi trebalo aproksimirati stvarnim naprežanjem pri lomu σ_f . Pokazalo se da vrijednosti koeficijenta cikličkih deformacija ε_f' procijenjene na osnovi evaluiranih metoda značajno odstupaju od eksperimentalnih, posebice za vrijednosti ε_f' aproksimirane s ε_f , kako je predloženo Mitchellovom i Ongovom metodom. Potvrđena je loša povezanost zamornih eksponenata b i c s monotonim značajkama materijala, pa procijenjene vrijednosti tih parametara pokazuju značajna odstupanja od eksperimentalnih. Iako metoda tvrdoće, uniformni materijalni zakon i modificirana metoda univerzalnih nagiba pravaca daju loše procjene ε_f' , dobro procjenjuju vijek trajanja u usporedbi s eksperimentalnim vrijednostima. Ongova metoda rezultira prihvatljivim procjenama vijeka trajanja unatoč lošim

procjenama zamornih koeficijenata σ_f' i ε_f' . Obje Mansonove metode rezultirale su nekonzervativnim procjenama vijeka trajanja u niskocikličkom području te vrlo konzervativnim procjenama u području visokocikličkog zamora, što potvrđuje zaključke iz [68].

Basan et al. [12] detaljnom analizom većine dotad predloženih metoda procjene zamornih parametara utvrđuju nedostatke koji se u većoj ili manjoj mjeri odnose na sve metode, a te su: utvrđivanje međusobno neovisnih, izravnih veza između odabranih monotonih značajki i eksperimentalno dobivenih pojedinačnih zamornih parametara, dodjeljivanje konstantnih vrijednosti određenim zamornim parametrima zbog nezadovoljavajućih ili nepostojećih korelacija s monotonim značajkama (posebice zamornih eksponenata b i c) te zanemarivanje razlika u zamornom ponašanju pojedinih skupina materijala (izuzev kod uniformnog materijalnog zakona i metode medijana). Analizom 310 različitih materijala (128 nelegiranih, 64 niskolegirana i 75 visokolegiranih čelika te 30 aluminijevih i 13 titanijevih slitina), utvrđena je statistički značajna razlika u vrijednostima zamornih parametara i vijeka trajanja pojedinih skupina materijala (posebice između čelika i aluminijevih i titanijevih slitina). Ovo je ukazalo na to da bi se bolji rezultati mogli očekivati kad bi se metode procjene razvijale uzimajući u obzir specifičnosti pojedinih skupina materijala.

Troshchenko i Khamaza [83] evaluiraju dotad objavljene metode procjene zamornih parametara na podacima 200 čelika i potvrđuju nedostatke postojećih metoda utvrđene ranijim evaluacijama u [57], [67], [68] i [73]. Najprikladnijom metodom procjene vijeka trajanja ocijenjuju metodu medijana Meggiolara i Castra.

Marohnić et al. u [52] provode sustavnu evaluaciju metoda procjene cikličkih parametara iz [43], [44] i [90], kako bi utvrdili adekvatnost primjene postojećih metoda na čelike podijeljene prema udjelu legirajućih elemenata. Evaluacija je provedena na nezavisnim uzorcima podataka sačinjenim od 34 nelegirana, 47 niskolegiranih i 35 visokolegiranih čelika, kao i uzorku sačinjenim od svih čelika zajedno. Izravno uspoređuju procijenjene i eksperimentalne vrijednosti cikličke granice tečenja R_e' i vrijednosti amplituda naprezanja $\Delta\sigma/2$ (odnosno točaka na cikličkoj krivulji naprezanje–deformacija) dobivenih na osnovi procijenjenih i eksperimentalnih vrijednosti cikličkih parametara K' i n' , i to za četiri različite amplitude ukupne deformacije $\Delta\varepsilon/2$: 0,1, 0,2, 1 i 2 %. Za ocjenu uspješnosti pojedine metode računaju postotak procijenjenih vrijednosti koje odstupaju od eksperimentalnih vrijednosti za ± 10 , ± 20 i ± 30 %. Utvrđeno je da su za procjenu R_e' nelegiranih i niskolegiranih čelika prikladne Lijeve

metoda iz [43], kao i Lopez–Fatemijeva metoda [44] predložena za čelike podijeljene na osnovi omjera R_m/R_e . Za visokolegirane čelike dvije prethodno spomenute metode su manje uspješne, što je i razumljivo s obzirom na to da su razvijene na uzorku sačinjenom većinom od nelegiranih i niskolegiranih čelika. Utvrđeno je i da niti jedna Zhangova metoda [91] nije adekvatna za procjenu $\Delta\sigma/2$, dok Lijeva metoda [43] i Lopez–Fatemijeva metoda [44] (procjena K' i n' za čelike podijeljene na osnovi omjera R_m/R_e) daju dobre rezultate, osobito za niskolegirane čelike (oko 80 % procijenjenih vrijednosti odstupa do ± 20 % od experimentalnih vrijednosti). Sve analizirane metode daju značajno slabije rezultate za visokolegirane čelike. Evaluacijom koja je provedena na uzorku podataka sačinjenom od svih razmatranih čelika ne uzimajući u obzir podjelu u skupine utvrđeno je i da se tako gubi vrijedna informacija o adekvatnosti metoda procjene za čelike grupirane prema udjelu legirajućih elemenata.

2.2.3 Procjena cikličkih i zamornih parametara materijala primjenom umjetnih neuronskih mreža

Procjena cikličkih i zamornih parametara materijala na osnovi monotonih značajki je problem aproksimacije funkcije, tj. identifikacije odnosa (tzv. *mapiranja*) između nezavisnih, prediktorskih varijabli (monotonih značajki) i zavisnih varijabli (cikličkih i zamornih parametara). Empirijske metode procjene cikličkih i zamornih parametara materijala uglavnom se temelje na razvoju modela jednostavne ili višestruke, linearne ili nelinearne regresije. Pritom odabir monotonih značajki na temelju kojih se procjenjuju ciklički/zamorni parametri često ovisi o iskustvu i intuiciji istraživača, a radi lakše primjene metoda procjene broj monotonih značajki koje uključuju je skroman. Nemogućnost nalaženja veze pojedinih parametara s monotonim značajkama u nekim ranije spomenutim metodama procjene rezultira pripisivanjem prosječnih vrijednosti ili medijana tim parametrima.

Nasuprot empirijskim metodama procjene, novija istraživanja nastoje karakterizirati i procijeniti cikličko i zamorno ponašanje materijala primjenom umjetnih neuronskih mreža. Umjetne neuronske mreže fleksibilni su nelinearni statistički modeli koji "učenjem" na dostupnim podacima mogu modelirati složenije odnose između ulaza (prediktorskih varijabli) i izlaza (zavisnih varijabli) pa su kao takve primjenjive i za modeliranje odnosa između materijalnih značajki na jednoj i cikličkih odnosno zamornih parametara na drugoj strani. Umjetne neuronske mreže omogućavaju lakšu manipulaciju s većim brojem prediktorskih varijabli i većim brojem podataka, što bi trebalo doprinijeti točnijoj procjeni cikličkih i zamornih parametara i krivulja materijala. Prednosti i mogućnosti primjene umjetnih

neuronskih mreža za poboljšanu procjenu cikličkih i zamornih parametara na osnovi monotonih značajki materijala već su pokazane u određenom broju radova.

Genel [25] primjenjuje umjetne neuronske mreže za predviđanje zamornih parametara na temelju monotonih značajki 73 čelika, od kojih je većina nelegirana i niskolegirana. Dvije trećine podataka korištene su za učenje, a jedna trećina za testiranje mreže. Razvija četiri višeslojna perceptrona za procjenu svakog zamornog parametra σ_f' , b , ε_f' i c . Sve mreže imaju jedan skriveni sloj i logističku sigmoidu kao aktivacijsku funkciju neurona u skrivenom sloju. Odabrani algoritam učenja je gradijentni spust s momentumom. Vrijednosti momentuma i stope učenja birane su na način da osiguravaju najbržu konvergenciju mreže. Za procjenu svih zamornih parametara korišteni su modul elastičnosti E , granica tečenja R_e , vlačna čvrstoća R_m , smanjenje poprečnog presjeka pri lomu Z i Brinellova tvrdoća HB . Odabir ovih značajki dodatno je potkrijepljen prikazom rezultata više različitih neuronskih mreža za procjenu zamornih koeficijenata σ_f' i ε_f' koje koriste različit broj i različite kombinacije ulaznih parametara. Generalizacija je osigurana ograničenjem broja neurona u skrivenom sloju (5 ili 6), s obzirom na to da je prikladna veličina skrivenog sloja usko povezana s brojem primjera za učenje. Usporedba na taj način dobivenih vrijednosti i onih procijenjenih primjenom najvažnijih analitičkih metoda s eksperimentalnim rezultatima pokazala je da prve daju značajno točnija predviđanja.

Tomasella et al. u [82] predlažu primjenu neuronskih mreža za procjenu cikličkih i zamornih parametara i krivulja materijala na osnovi 12 ulaznih varijabli (modula elastičnosti E , granice tečenja R_e , vlačne čvrstoće R_m , istežanja pri lomu A_5 , istežanja pri lomu A_{80} , plastičnog istežanja A_g , smanjenja poprečnog presjeka pri lomu Z , ukupne ekvivalentne plastične deformacije φ_v , smjera valjanja, temperature T , koeficijenta deformacijskog očvršćivanja K i eksponenta deformacijskog očvršćivanja n) s ciljem simuliranja stvarnih eksperimenata. Predlažu da se vrijednosti amplituda naprezanja dobivene na temelju tako procijenjenih cikličkih parametara kombiniraju s rezultatima stvarnih eksperimenata i tako smanji broj potrebnih eksperimenata.

Troshchenko et al. [84] za procjenu zamornih parametara razvijaju četiri višeslojna perceptrona s jednim skrivenim slojem i tangensom hiperbolnim kao aktivacijskom funkcijom. Zamorni parametri nisu u potpunosti neovisno procjenjivani, već su mreže razvijene točno određenim redoslijedom: $\sigma_f' \rightarrow b \rightarrow \varepsilon_f' \rightarrow c$. Za procjenu koeficijenta dinamičke čvrstoće σ_f' koristili su iste monotone značajke kao i Genel u [25], a svaka sljedeća mreža je pored ulaznih varijabli iz prethodne mreže koristila i zamorne parametre procijenjene prethodnim mrežama. Mreže su

inicijalno trenirane na podacima za 190 čelika, iz kojih je potom izuzeto 50 materijala s najmanjim odstupanjem procijenjenih od eksperimentalnih vrijednosti te je nastavljeno daljnje treniranje. Autori su isprobali različite veličine skrivenog sloja za svaku mrežu i utvrdili da je optimalan broj neurona u skrivenom sloju 10 za procjenu σ_f' , a 11 za procjenu ostalih zamornih parametara. Evaluacijom na svim materijalima pokazano je da je 91,1 % vrijednosti ciklusa opterećenja N_f dobivenih pomoću procijenjenih vrijednosti zamornih parametara unutar pojasa odstupanja od tri puta.

Mathew et al. [53] primjenjuju umjetnu neuronsku mrežu za procjenu vijeka trajanja nehrđajućeg čelika 316L u području niskocikličkog zamora na osnovi ispitne temperature, raspona amplitude ukupne deformacije, brzine deformiranja i ekvivalentnih udjela kroma i nikla. Iako procijenjeni vijek trajanja čelika 316L odstupa 1,5 do 2 puta od eksperimentalnog, rezultate treba uzeti s oprezom, s obzirom na to da su mreže razvijene na malom broju primjera za učenje u odnosu na velik broj ulaznih varijabli i neurona u skrivenom sloju.

Ghajar et al. [26] za procjenu cikličkih parametara K' i n' čelika razvijaju dva višeslojna perceptrona s jednim skrivenim slojem, koristeći podatke većinom nelegiranih i niskolegiranih čelika iz [36], [73] i [81] (36 podataka za K' i 60 za n'). Za učenje mreža koriste Levenberg–Marquadtov algoritam. Optimalnu kombinaciju ulaznih značajki i veličinu skrivenog sloja određuju metodom pokušaja i pogreške. Monotone značajke korištene u istraživanju su modul elastičnosti E , granica tečenja R_e , vlačna čvrstoća R_m , smanjenje poprečnog presjeka pri lomu Z i Brinellova tvrdoća HB . Osim različitih kombinacija monotonih značajki isprobavaju i različite veličine skrivenog sloja, od 2 do 10 neurona. Mreže su testirane na nezavisnim podacima (12 za K' i 22 za n'). Za procjenu K' odabrana je mreža s 8 neurona u skrivenom sloju i ulazima R_e , R_m , Z i HB , dok se za procjenu n' najboljom mrežom pokazala ona s 9 neurona u skrivenom sloju i istom kombinacijom ulaznih podataka. U radu je pokazano da odabrane mreže zadovoljavajuće predviđaju cikličke parametre K' i n' . Treba napomenuti da su broj ulaznih varijabli korištenih za razvoj neuronskih mreža i veličina skrivenog sloja bili vrlo veliki u odnosu na broj primjera za učenje (posebice kod mreže za procjenu K'), a u razvoju mreža nisu primijenjene metode poboljšanja generalizacije, tako da rezultate treba oprezno koristiti.

Osim za izravnu procjenu cikličkih RO i zamornih BCM parametara na osnovi monotonih značajki materijala, neuronske mreže našle su široku primjenu u karakterizaciji cikličkog i zamornog ponašanja metalnih, ali i drugih materijala.

Artymiak et al. [3] predlažu procjenu Wöhlerovih krivulja čelika na osnovi vlačne čvrstoće R_m , granice tečenja R_e i teorijskog faktora koncentracije naprezanja K_t , kombinacijom četiriju neuronskih mreža. Pleune i Chopra [71] umjetnim neuronskim mrežama procjenjuju vijek trajanja nelegiranih i niskolegiranih čelika na osnovi uvjeta opterećenja i okolnih uvjeta u nuklearnim elektranama. Srinivasan et al. [77] umjetnim neuronskim mrežama procjenjuju ponašanje čelika 316L(N) u području i uvjetima niskocikličkog zamora, ali i sinergističko djelovanje puzanja i zamora na vijek trajanja materijala. Furukawa i Hoffmann [23] primjenjuju neuronske mreže za razvoj naprednog materijalnog modela koji opisuje monotono i cikličko ponašanje materijala. Kang et al. [35] primjenjuju umjetne neuronske mreže za analizu zamornog oštećivanja materijala uzrokovanog višeosnim stanjem opterećenja. Vassilopoulos et al. [85] primjenjuju umjetne neuronske mreže za procjenu krivulja konstantnog vijeka trajanja kompozitnih materijala. Janežič et al. [31] koriste neuronske mreže za smanjenje rasapa u rezultatima cikličkog ispitivanja ponašanja materijala uslijed varijacija u temperaturi okoline, postotku legirajućih elemenata, brzini promjene opterećenja pri izvođenju eksperimenta i dr. Figueira Pujol i Andrade Pinto [21] koriste neuronske mreže za predviđanje vjerojatnosti da će dio izložen izvjesnom cikličkom opterećenju otkazati nakon određenog broja ciklusa opterećenja.

2.3 Zaključak

Pregledom empirijskih metoda procjene cikličkih i zamornih parametara na osnovi monotonih značajki utvrđeno je da se uzorci podataka korištenih za razvoj metoda procjene značajno razlikuju po opsegu i skupinama metalnih materijala na kojima su razvijane [51]. Ranije metode procjene cikličkih i zamornih parametara razvijane su na uzorcima podataka koji su osim čelika sadržavali i druge metalne materijale [48, 64, 91], dok novije metode [14, 42–44, 57, 67, 73, 76] odvajaju čelike od ostalih materijala, posebno aluminijevih i titanijevih slitina. Podjelu čelika s obzirom na udio legirajućih elemenata prvi su primijenili Bäumel i Seeger s ciljem poboljšanja procjene zamornih parametara materijala, pa je njihov uniformni materijalni zakon [14] predložen zasebno za nelegirane i niskolegirane čelike te aluminijeve i titanijeve slitine, dok visokolegirani čelici nisu razmatrani [52]. Prednosti ovakve podjele materijala za procjenu zamornih parametara materijala spomenute su u Hatscher et al. [29], a za procjenu cikličkih parametara u [11], [13] i [50]. Zasebno razmatranje čelika te aluminijevih i titanijevih slitina za procjenu cikličkih i zamornih parametara pokazalo se opravdanim u nizu radova koji se bave evaluacijom metoda procjene [33, 57, 68]. U tim je radovima pokazano da nisu sve metode

jednako prikladne za procjenu cikličkih i zamornih parametara čelika i drugih metalnih materijala. Osim toga, u [33], [52] i [68] dodatno je utvrđeno i da se uspješnost metoda procjene cikličkih i zamornih parametara razlikuje za čelike podijeljene u skupine s obzirom na udio legirajućih elemenata, a u [12] da postoji statistički značajna razlika između zamornih parametara i ponašanja nelegiranih, niskolegiranih i visokolegiranih čelika te aluminijevih i titanijevih slitina.

Čelici su jedna od najkompleksnijih i najraznovrsnijih skupina slitina i mogu se grupirati prema raznim kriterijima – s obzirom na kemijski sastav, primjenu, postupak proizvodnje, toplinsku obradu, mikrostrukturu i dr. Osim legirajućih elemenata, toplinska obrada i rezultirajuća mikrostruktura utječu na karakteristike materijala i ukazuju na to da bi podjela čelika s obzirom na mikrostrukturu mogla doprinijeti poboljšanoj procjeni cikličkih i zamornih parametara, tj. ponašanja materijala. Međutim, podaci o mikrostrukturi često su nedostupni u ranim fazama razvoja proizvoda, pa bi korištenje odgovarajućih metoda za procjenu cikličkih i zamornih parametara materijala baziranih na mikrostrukturi imalo otežanu primjenu. Ranije spomenuta podjela s obzirom na udio legirajućih elemenata (tj. kemijski sastav) je najraširenija. Služi kao osnova za klasifikaciju čelika i dodjeljivanje oznaka [4] i lako je primjenjiva u inženjerskoj praksi. Iz tog je razloga ona odabrana kao kriterij podjele čelika za daljnje istraživanje, s ciljem poboljšane procjene cikličkih i zamornih parametara i ponašanja čelika.

Manjkavost empirijskih metoda procjene je i skroman broj monotonih značajki koje se koriste za procjenu cikličkih i zamornih parametara materijala te činjenica da njihov odabir najčešće nije utemeljen na prethodnoj statističkoj analizi kojom bi se utvrdila relevantnost pojedine značajke za procjenu pojedinih parametara.

Pregledom postojećih pristupa razvoju umjetnih neuronskih mreža utvrđene su prednosti, ali i nedostaci slični onima empirijskih metoda procjene cikličkih i zamornih parametara.

Ni u jednom radu koji se time bavi [25, 26, 82, 84] razvoju umjetnih neuronskih mreža nije prethodila statistička analiza monotonih značajki relevantnih za procjenu pojedinog cikličkog ili zamornog parametra čelika. Monotone značajke koriste se ili potpuno neselektivno, kao u [82], gdje je za razvoj neuronskih mreža korišteno čak 12 ulaznih varijabli, ili se koriste najdostupnije monotone značajke – modul elastičnosti E , vlačna čvrstoća R_m , granica tečenja R_e , smanjenje poprečnog presjeka pri lomu Z i Brinellova tvrdoća HB [25, 26, 84]. Ova kombinacija varijabli, međutim, uključuje dvije visokokorelirane ulazne značajke: vlačnu

čvrstoću R_m i Brinellovu tvrdoću HB , što može negativno utjecati na učenje mreže i uspješnost primjene na neovisnom uzorku podataka.

Za razvoj umjetnih neuronskih mreža u [25] i [26] koristi se relativno skroman broj podataka (u okvirima razvoja umjetnih neuronskih mreža), za koji je nerealno očekivati da je mogao dobro obuhvatiti varijabilnosti svih skupina čelika. Drukčije je kod Troschenka et al. [84], koji su za razvoj neuronskih mreža koristili podatke za 190 čelika, no pregledom izvora korištenih podataka nejasno je jesu li oni filtrirani po nekom od kriterija za osiguranje kvalitete i dosljednost podataka u uzorku.

Osim ranije navedenih nedostataka uočeni su i nedostaci u samom pristupu razvoju umjetnih neuronskih mreža. Broj podataka u uzorku za učenje mreže i broj ulaznih varijabli usko su vezani s odabirom mrežne arhitekture kako bi se osigurala uspješna primjena neuronskih mreža na neovisnom uzorku podataka. U većini radova nije poznato da li je korištena neka od metoda prevencije prenaučivosti (predefiniranosti) modela, osim u [25], gdje je veličina skrivenog sloja ograničena kako bi se spriječila prenaučivost modela.

Postojeće metode procjene cikličkih i zamornih parametara primjenom umjetnih neuronskih mreža razvijane su za sve čelike zajedno, s tim da su neke razvijane pretežno na podacima za nelegirane i niskolegirane čelike [25, 26], ne uzimajući u obzir različitosti pojedinih skupina čelika. Kao i skroman broj primjera za učenje, nedovoljno raznolik sastav uzoraka za učenje ukazuje na to da se ovako razvijene mreže teško mogu primijeniti za procjenu cikličkih i zamornih parametara svih čelika, zbog već ranije spomenute raznovrsnosti ove skupine slitina.

Temeljem utvrđenih nedostataka u ovom je radu provedeno sustavno istraživanje primjenjivosti umjetnih neuronskih mreža na procjenu cikličkih i zamornih parametara (odnosno ponašanja) čelika. Posebna važnost u razvoju neuronskih mreža za opisani problem pridana je različitostima čelika grupiranih prema udjelu legirajućih elemenata te utvrđivanju monotonih značajki relevantnih za procjenu pojedinog cikličkog RO (R_e' , K' i n') i zamornog BCM (σ_f' , b , ε_f' i c) parametra nelegiranih, niskolegiranih i visokolegiranih čelika.

3 Prikupljanje i obrada podataka

3.1 Uvod

Za provjeru hipoteze da se cikličko i zamorno ponašanje čelika grupiranih prema udjelu legirajućih elemenata u nelegirane, niskolegirane i visokolegirane čelike statistički značajno razlikuje provedena je statistička analiza s ciljem utvrđivanja različitosti cikličkih i zamornih parametara tako grupiranih čelika. Iako je u [12] već pokazano da se zamorni parametri nelegiranih, niskolegiranih i visokolegiranih čelika statistički značajno razlikuju, nije pokazano koje skupine se međusobno razlikuju s obzirom na pojedini zamorni parametar. Stoga su, nakon utvrđivanja različitosti među cikličkim odnosno zamornim parametrima ovako grupiranih čelika, provedene dodatne analize s ciljem detaljnijeg ustanovljavanja razlika između pojedinih skupina. Sve statističke analize u ovom istraživanju provedene su korištenjem programskog paketa MINITAB 17™ (akademska licenca) [60].

Za provedbu uspješnog i pouzdanog istraživanja cikličkih i monotonih parametara čelika potrebno je voditi računa o

- a) količini (broju) dostupnih podataka u uzorku⁴ i
- b) kvaliteti dostupnih podataka u uzorku.

Uzorak koji služi za provođenje istraživanja mora biti nasumično prikupljen i dovoljno velik da na adekvatan način predstavi cijelu populaciju⁵ [61]. O količini i distribuciji podataka ovisi koliko će rezultati i zaključci doneseni na temelju njihove analize biti relevantni za primjenu na cijeloj populaciji, tj. skupini materijala, te je stoga tome posvećena posebna pažnja.

⁴ *Uzorkom* nazivamo podskup predmeta, događaja ili u ovom slučaju skupina podataka o materijalima koji se prikupljaju iz populacije s ciljem analize i donošenja zaključaka [61].

⁵ *Populacija* je skup predmeta, događaja ili u ovom slučaju podataka o materijalima o kojima se na temelju analize donose zaključci [61].

3.2 Prikupljanje podataka o materijalima

Iz relevantne literature [14], [16] i putem MATDAT on-line baze podataka o materijalima [7] prikupljeno je 687 skupova eksperimentalnih podataka za čelike. Prikupljene su vrijednosti monotonih značajki iz vlačnih pokusa, te ciklički (RO) i zamorni (BCM) parametri dobiveni iz cikličkih vlačnih–tlačnih, potpuno simetričnih eksperimenata izvedenih uz kontrolu amplitude deformacije ($R_\epsilon = -1$).

U obzir su uzeti samo podaci dobiveni iz eksperimenata na zraku i pri sobnoj temperaturi, dok podaci dobiveni eksperimentima pri povišenim ili sniženim temperaturama ili u drugom mediju nisu uključeni u analizu. Podaci dobiveni iz ispitivanja provedenih na manje od četiri različite amplitude ukupne deformacije $\Delta\epsilon/2$ i oni čiji je raspon amplituda ukupne deformacije $\Delta\epsilon/2$ manji od 0,4 % nisu razmatrani zbog potencijalno neadekvatne karakterizacije cikličkog i zamornog ponašanja u uvjetima niskocikličkog i visokocikličkog zamora.

U prikupljenim podacima uočen je i manji broj skupova podataka kod kojih su vrijednosti pojedinih parametara značajno odstupale od ostatka uzorka (za jedan ili dva reda veličine). Takvi skupovi podataka izuzeti su iz uzorka za provođenje daljnjih analiza, jer mogu rezultirati donošenjem pristranih, pogrešnih zaključaka.

Nakon selekcije po navedenim kriterijima, za provedbu analiza s ciljem utvrđivanja različitosti cikličkih i zamornih parametara čelika grupiranih prema udjelu legirajućih elemenata korišteno je 205 skupova podataka i to: 57 za nelegirane, 106 za niskolegirane i 42 za visokolegirane čelike, što je značajno veći uzorak od onih korištenih u većini postojećih istraživanja.

3.3 Metodologija za utvrđivanje razlika između skupina čelika

3.3.1 Jednofaktorska analiza varijance i Welchov test

Za testiranje hipoteze da se eksperimentalne vrijednosti cikličkih i zamornih parametara nelegiranih, niskolegiranih i visokolegiranih čelika statistički značajno razlikuju provedena je jednofaktorska analiza varijance (engl. *analysis of variance*, ANOVA) za nezavisne uzorke⁶. Jednofaktorska ANOVA statistički je postupak temeljen na usporedbi aritmetičkih sredina $i = 1, 2, 3, \dots, a$ uzoraka (uobičajeno tri ili više), pri čemu svaki ima n_i elemenata (opažanja),

⁶ Nezavisni uzorci su oni kod kojih ne postoji nikakva veza između podataka.

kojim se utvrđuje da li se one statistički značajno razlikuju. Statistička hipoteza⁷ koja se testira, tzv. *nul-hipoteza* H_0 (engl. *null-hypothesis*) glasi da su aritmetičke sredine svih uzoraka jednake, dok se *alternativnom hipotezom* H_1 (engl. *alternative hypothesis*) pretpostavlja da se bar jedna aritmetička sredina razlikuje od ostalih:

$$\begin{aligned} H_0: & \mu_1 = \mu_2 = \dots = \mu_a \\ H_1: & \mu_j \neq \mu_k \text{ za neke } j, k. \end{aligned} \quad (18)$$

Za provođenje jednofaktorske ANOVA-e ukupna varijabilnost zavisne varijable y_i , tj. *ukupna suma kvadrata odstupanja* SS_T (engl. *total sum of squares*) dijeli se na *sumu kvadrata odstupanja između uzoraka* SS_{Treat} (engl. *treatment sum of squares*, udio varijabilnosti zbog razlike aritmetičkih sredina uzoraka i cjelokupne aritmetičke sredine) i *sumu kvadrata pogreške* SS_E (engl. *error sum of squares*, udio varijabilnosti unutar uzorka zbog razlike između vrijednosti opažanja unutar uzorka i aritmetičke sredine uzorka) [63]

$$SS_T = SS_{\text{Treat}} + SS_E, \quad (19)$$

gdje su

$$SS_T = \sum_{i=1}^a \sum_{j=1}^{n_i} y_{ij}^2 - \frac{y_{..}^2}{N}, \quad (20)$$

i

$$SS_{\text{Treat}} = \sum_{i=1}^a \frac{y_{i.}^2}{n_i} - \frac{y_{..}^2}{N}. \quad (21)$$

Iz izraza (19), (20) i (21) slijedi da je suma kvadrata pogreške SS_E razlika ukupne sume kvadrata odstupanja SS_T i sume kvadrata odstupanja između uzoraka SS_{Treat}

$$SS_E = \sum_{i=1}^a \sum_{j=1}^{n_i} y_{ij}^2 - \frac{y_{..}^2}{N} - \sum_{i=1}^a \frac{y_{i.}^2}{n_i} - \frac{y_{..}^2}{N}. \quad (22)$$

U izrazima (20), (21) i (22) y_{ij} je suma svih opažanja y_{ij} i -tog uzorka, a $y_{..}$ suma svih opažanja svih uzoraka. Točka u indeksnom zapisu znači zbrajanje po indeksu koji predstavlja [63].

Izrazi (20), (21) i (22) vrijede za slučaj kad su uzorci nejednake veličine (tzv. *nebalansirani eksperiment*).

⁷ Statistička hipoteza je tvrdnja koja predstavlja polaznu osnovu na kojoj se temelji izračun statističkog testa.

Broj opažanja u svakom pojedinom uzorku jednak je n_i , a ukupni broj opažanja jednak je:

$$N = \sum_{i=1}^a n_i . \quad (23)$$

U tom slučaju F -statistika jednaka je

$$F_0 = \frac{SS_{\text{Treat}}/(a-1)}{SS_E/[a(n-1)]} = \frac{MS_{\text{Treat}}}{MS_E}, \quad (24)$$

gdje su MS_{Treat} i MS_E prosječna suma kvadrata odstupanja između uzoraka (engl. *treatment mean square*) i prosječna suma kvadrata pogreške (engl. *error mean square*). Ukoliko je vrijednost F -statistike izračunate izrazom (24) veća od kritične vrijednosti $f_{\alpha, a-1, a(n-1)}$ koja se određuje na osnovu kumulativne f -distribucije i postavljene razine značajnosti α , i stupnjeva slobode brojnika $a - 1$ i nazivnika $a(n - 1)$ izraza (24)), tj. ako je P -vrijednost manja od razine značajnosti α , nul-hipoteza H_0 se odbacuje s vjerojatnošću $1 - \alpha$. P -vrijednost je vjerojatnost, izračunata pod pretpostavkom da je nul-hipoteza H_0 istinita, da će vrijednost test statistike poprimiti veću vrijednost od one izračunate pomoću uzorka. P -vrijednost nije vjerojatnost da je nul-hipoteza H_0 istinita [17]. Razina značajnosti α predstavlja vjerojatnost odbacivanja istinite nul-hipoteze H_0 , tj. vjerojatnost za pogrešku tipa I (α pogrešku)⁸, i za područje istraživanja koje je predmet ovog rada uobičajeno se postavlja na vrijednost 0,05.

Izrazi (20–24) vrijede pod sljedećim pretpostavkama:

- uzorci su normalno distribuirani i
- uzorci imaju *homogene (jednake)* varijance σ^2 , odnosno standardne devijacije σ .

Broj podataka u pojedinom uzorku (57, 106 i 42 za nelegirane, niskolegirane i visokolegirane čelike) dovoljan je da se pretpostavi normalna distribucija⁹, no ako nije ispunjen uvjet o homogenosti varijanci, povećava se mogućnost pogreške tipa I [59]. Iz tog razloga, za svaki od cikličkih i zamornih parametara materijala proveden je *test višestruke usporedbe homogenosti varijanci* (engl. *multiple comparison*). Test višestrukih usporedbi odabran je radi podjednako

⁸ Kod testiranja hipoteza, osim pogreške tipa I, postoji i pogreška tipa II (β pogreška) – prihvatanje neistinite nul-hipoteze H_0 .

⁹ Ovo je djelomično objašnjeno *centralnim graničnim teoremom* koji kaže da distribucija aritmetičke sredine bilo kojeg uzorka ima distribuciju približnu normalnoj i da ta aproksimacija postaje gotovo normalna s porastom veličine uzorka. Opširnijim istraživanjem u [59] utvrđeno je da je za pouzdano provođenje jednofaktorske ANOVA-e na dva do devet uzoraka dovoljno 15 opservacija po uzorku.

točnih rezultata bez obzira na distribuciju analiziranih podataka, a detalji testa dostupni su u [62]. Nul-hipotezom pretpostavlja se da su varijance svih uzoraka jednake, a alternativnom hipotezom da se varijance bar dva uzorka statistički značajno razlikuju

$$\begin{aligned} H_0 : \sigma_1^2 = \sigma_2^2 = \dots = \sigma_a^2 \\ H_1 : \sigma_j^2 \neq \sigma_k^2 \text{ za neke } j, k. \end{aligned} \quad (25)$$

Ukoliko je P -vrijednost manja od razine značajnosti α ($\alpha = 0,05$), nul-hipoteza iz izraza (25) se odbacuje. Rezultati testova višestrukih usporedbi homogenosti varijance za cikličke i zamorne parametre dani su u tablici 3.1.

Tablica 3.1 Rezultati testa višestrukih usporedbi za homogenost varijance

Parametar koji se testira	P -vrijednost	Uzorci imaju jednake varijance σ^2
R_c'	0,758	DA
K'	0,020	NE
n'	0,000	NE
σ_f'	0,459	DA
b	0,000	NE
ε_f'	0,016	NE
c	0,829	DA

Utvrđeno je da varijanca među uzorcima nije homogena za koeficijent cikličkog deformacijskog očvršćivanja K' , eksponent cikličkog deformacijskog očvršćivanja n' , eksponent dinamičke čvrstoće b i koeficijent cikličkih deformacija ε_f' pa je za utvrđivanje statistički značajnih razlika pojedinih skupina za navedene parametre provedena alternativa jednofaktorskoj ANOVA-i koja ne pretpostavlja jednake varijance, tzv. *Welchov test*. Procedura Welchovog testa vrlo je slična F -testu jednofaktorske analize varijance, a detalji su dostupni u [59]. Varijanca među uzorcima homogena je za R_c' , σ_f' i c pa je za utvrđivanje statistički značajnih razlika nelegiranih, niskolegiranih i visokolegiranih čelika s obzirom na te parametre provedena jednofaktorska analiza varijance (F -test). Rezultati jednofaktorske ANOVA-e i Welchovog testa dani su u tablici 3.2. Rezultati potvrđuju da postoji statistički značajna razlika između svih cikličkih i zamornih parametara različitih skupina čelika, no ne pokazuju i detalje o parovima uzoraka koji se međusobno razlikuju. Stoga će se u idućem poglavlju provesti tzv. *post-hoc analiza*, kojom će se utvrditi međusobne razlike između pojedinih skupina.

Tablica 3.2 Rezultati jednofaktorske analize varijance i Welchovog testa za cikličke i zamorne parametre

Parametar koji se testira	Jednofaktorska ANOVA		Welchov test		Uzorci se statistički značajno razlikuju
	<i>F</i> -statistika	<i>P</i> -vrijednost	<i>F</i> -statistika	<i>P</i> -vrijednost	
R_e'	23,21	0,000	-	-	DA
K'	-	-	13,83	0,000	DA
n'	-	-	71,27	0,000	DA
σ_f'	25,37	0,000	-	-	DA
b	-	-	40,43	0,000	DA
ε_f'	-	-	10,95	0,000	DA
c	32,99	0,000	-	-	DA

3.3.2 Post-hoc analize

Kako bi se utvrdile razlike između cikličkih i/ili zamornih parametara na razini parova uzoraka nelegiranih (NeČ), niskolegiranih (NČ) i visokolegiranih čelika (VČ), provedena je *post-hoc analiza*. Za post-hoc analizu rezultata jednofaktorske ANOVA-e korištena je *Tukeyeva metoda višestrukih kontrasta* [63], a za post-hoc analizu rezultata Welchovog testa *Games–Howellova metoda višestrukih kontrasta* [24]. Ukupna razina značajnosti postavljena je na 0,05 kako bi se kompenzirala povećana mogućnost pogreške tipa I zbog višestrukih usporedbi (razina značajnosti za pojedinačne usporedbe je 0,0192).

Rezultati post-hoc analize provedene korištenjem Tukeyeve i Games–Howellove metode višestrukih kontrasta dani su u tablici 3.3.

Post-hoc analizom utvrđene su statistički značajne razlike između cikličkih i zamornih parametara nelegiranih, niskolegiranih i visokolegiranih čelika u svim slučajevima osim za:

- cikličku granicu tečenja R_e' nelegiranih i visokolegiranih čelika,
- koeficijent cikličkog deformacijskog očvršćivanja K' nelegiranih i niskolegiranih čelika,
- koeficijent dinamičke čvrstoće σ_f' nelegiranih i niskolegiranih čelika,
- koeficijent cikličkih deformacija ε_f' nelegiranih i visokolegiranih čelika, te
- eksponent cikličkih deformacija c nelegiranih i visokolegiranih čelika.

Tablica 3.3 Rezultati post-hoc analize

Parametar koji se testira	Parovi uzoraka	Tukeyeva metoda višestrukih usporedbi		Games–Howellova metoda višestrukih usporedbi		Parovi uzoraka statistički se značajno razlikuju
		<i>t</i> -statistika	<i>P</i> -vrijednost	<i>t</i> -statistika	<i>P</i> -vrijednost	
R_e'	NeČ – NČ	5,32	0,000	-	-	DA
	NeČ – VČ	-0,82	0,689	-	-	NE
	NČ – VČ	-5,71	0,000	-	-	DA
K'	NeČ – NČ	-	-	-0,05	0,999	NE
	NeČ – VČ	-	-	5,08	0,000	DA
	NČ – VČ	-	-	5,27	0,000	DA
n'	NeČ – NČ	-	-	-7,68	0,000	DA
	NeČ – VČ	-	-	6,54	0,000	DA
	NČ – VČ	-	-	10,10	0,000	DA
σ_f'	NeČ – NČ	2,25	0,066	-	-	NE
	NeČ – VČ	6,93	0,000	-	-	DA
	NČ – VČ	5,70	0,000	-	-	DA
b	NeČ – NČ	-	-	3,62	0,001	DA
	NeČ – VČ	-	-	-6,22	0,000	DA
	NČ – VČ	-	-	-8,72	0,000	DA
ε_f'	NeČ – NČ	-	-	4,66	0,000	DA
	NeČ – VČ	-	-	0,74	0,739	NE
	NČ – VČ	-	-	-3,84	0,001	DA
c	NeČ – NČ	-6,89	0,000	-	-	DA
	NeČ – VČ	0,04	0,999	-	-	NE
	NČ – VČ	6,26	0,000	-	-	DA

3.4 Zaključak

Statističkim analizama provedenim na 205 skupova podataka, od čega 57 za nelegirane, 106 za niskolegirane i 42 za visokolegirane čelike, utvrđeno je da postoje statistički značajne razlike između cikličkih i zamornih parametara nelegiranih, niskolegiranih i visokolegiranih čelika. Utvrđene razlike označene su sa znakom plus "+" u tablici 3.4.

Tablica 3.4 Utvrđene razlike između cikličkih i zamornih parametara nelegiranih, niskolegiranih i visokolegiranih čelika

Parovi uzoraka	Ciklički parametar			Zamorni parametar			
	R_e'	K'	n'	σ_f'	b	ε_f'	c
NeČ – NČ	+		+		+	+	+
NeČ – VČ		+	+	+	+		
NČ – VČ	+	+	+	+	+	+	+

Iako za određene parametre nije utvrđena statistički značajna razlika među pojedinim skupinama čelika, može se utvrditi da se ciklički i zamorni parametri nelegiranih, niskolegiranih i visokolegiranih čelika statistički značajno razlikuju, što pokazuje da je odabrana podjela čelika prema udjelu legirajućih elemenata opravdana.

Iz tog su razloga daljnje statističke analize, kao i razvoj umjetnih neuronskih mreža, provedene zasebno za svaku od navedenih skupina čelika s ciljem poboljšanja procjene cikličkih i zamornih parametara materijala.

4 Identifikacija monotonih značajki relevantnih za procjenu cikličkih i zamornih parametara čelika

4.1 Uvod

Uobičajen pristup metoda procjene cikličkih i zamornih parametara materijala jest utvrđivanje veze između monotonih značajki materijala kao nezavisnih, prediktorskih varijabli i cikličkih odnosno zamornih parametara kao zavisnih varijabli uz pomoć jednostavne ili višestruke, linearne ili nelinearne regresijske analize [51], ili pak primjenom umjetnih neuronskih mreža. Takva regresijska analiza rezultira određenom funkcijskom vezom, tj. regresijskim modelom između prediktorske i zavisne varijable, koji se kasnije koristi za predviđanje budućih opservacija. Pregledom postojećih istraživanja utvrđeno je da razvoju metoda procjene cikličkih i zamornih parametara čelika ne prethodi sustavna analiza relevantnosti monotonih značajki za procjenu pojedinog parametra (ili takva analiza nije poznata), što je i glavna motivacija za provedbu statističkih analiza opisanih u nastavku ovog poglavlja. Pored toga, za usporedbu i ocjenu prikladnosti dobivenih regresijskih modela uobičajeno se koristi *koeficijent determinacije* R^2 (engl. *coefficient of determination*), koji je moguće definirati na dva načina: a) kao postotak varijabilnosti zavisne varijable koji se smanjuje uključivanjem određenog prediktora u model ili b) kao postotak varijabilnosti zavisne varijable koji je objašnjen varijabilnošću prediktora. Drugu definiciju (b) treba oprezno koristiti, jer implicira kauzalnost između prediktora i zavisne varijable¹⁰. Metodama procjene cikličkih odnosno zamornih parametara nastoji se "povezati" procese koji se odvijaju primarno na mikrostrukturnoj razini s empirijskim parametrima dobivenim promatranjem ponašanja materijala na makroskopskoj razini.

¹⁰ Podaci za regresijsku analizu mogu biti *opservacijski* (vrijednosti nezavisnih varijabli nisu kontrolirane) ili *eksperimentalni* (nezavisne varijable kontroliraju se statističkim planiranjem eksperimenta) [58]. *Statističko planiranje eksperimenta* jedini je način za određivanje kauzalnosti između prediktora i zavisne varijable [63].

Koeficijent determinacije R^2 može se koristiti za grubu, preliminarnu procjenu kvalitete regresijskog modela, no čak i tada s dozom opreza, budući da se njegova vrijednost povećava dodavanjem prediktora u model bez obzira na to jesu li oni utjecajni ili ne. Prikladnija statistika za procjenu modela višestruke regresije jest *prilagođeni koeficijent determinacije* (engl. *adjusted coefficient of determination*) R_{adj}^2 , čija se vrijednost povećava samo u slučaju da prediktor pridodan regresijskom modelu poboljšava taj model. Međutim, vrednovanje modela višestruke regresije bilo s R^2 ili R_{adj}^2 ne pruža uvid u individualni doprinos pojedine prediktorske varijable (tj. monotone značajke) na procjenu cikličkih/zamornih parametara i opravdanost povećanja složenosti regresijskog modela. Stoga su su zaključci doneseni na temelju R^2 ili R_{adj}^2 ograničene primjenjivosti.

Adekvatniji pokazatelj pojedinačnog doprinosa prediktorske varijable u modelu je parcijalni ili sekvencijalni koeficijent determinacije R_{seq}^2 , o kojem će se detaljnije govoriti u narednim potpoglavljima.

4.2 Metodologija za identifikaciju monotonih značajki relevantnih za procjenu cikličkih i zamornih parametara čelika

4.2.1 Odabir metode za identifikaciju relevantnih monotonih značajki

Procjena cikličkih i zamornih parametara iz monotonih značajki materijala svodi se na *problem aproksimacije funkcije*, odnosno *regresijski problem*. Identifikacija "odgovarajućeg" podskupa (ili više njih) potencijalno korisnih prediktorskih varijabli koje će biti uključene u finalni regresijski model, kao i određivanje prikladnih funkcionalnih i interakcijskih odnosa tih varijabli ključni je problem u regresijskoj analizi [38].

Jedna od najraširenijih metoda za odabir prediktora je *postupna regresijska analiza* (engl. *stepwise regression*), koja može biti *unaprijedna* (engl. *forward stepwise regression*) ili *povratna* (engl. *backward stepwise regression*). Postupnom regresijom iterativno se uključuju ili isključuju prediktori iz modela, a kriterij za uključivanje/isključivanje prediktorskih varijabli iz modela mogu biti smanjenje sume kvadrata pogreške SSE , koeficijent parcijalne korelacije, t -statistika ili F -statistika. Neovisno o kriteriju, u svakom se koraku testiraju svi mogući prediktori, uključuju u model ili iz njega isključuju prema odabranom kriteriju, sve dok ne preostane niti jedna varijabla za uključivanje ili isključivanje iz modela. Moguće je i da neki

prediktor u jednom koraku postupne regresije uđe u model, da bi u narednom ili nekom kasnijem koraku iz njega bio isključen.

Sve vrste postupne regresijske analize uobičajeno se provode pomoću računalnih programa i rezultiraju regresijskim modelom izgrađenom prema unaprijed definiranim kriterijima, no valja napomenuti da niti jedna procedura neće formirati univerzalno najbolji model [38]. Također, u izgradnji modela višestruke linearne regresije važno je i suštinsko poznavanje problema koji se istražuje, tj. veze koja se želi aproksimirati. Ponekad se zna da su neke prediktorske varijable "fundamentalnije" ili dostupnije od drugih i potrebno ih je zadržati u modelu usprkos formalnim pokazateljima koji ukazuju na suprotno.

Kako automatizirana, računalna postupna analiza ne pruža detaljni uvid u individualni doprinos pojedine prediktorske varijable poboljšanju modela, niti dozvoljava uvođenje dodatnih kriterija za izgradnju modela, u ovom je istraživanju provedeno "ručno" građenje modela višestruke regresije, s ciljem utvrđivanja pojedinačnog doprinosa monotonih značajki procjeni cikličkih i zamornih parametra, i to za svaku skupinu čelika zasebno. Za odabir relevantnih monotonih značajki za procjenu cikličkih i zamornih parametara materijala odabrana je podvarijanta postupne regresije, tzv. *unaprijedna selekcija* (engl. *forward selection*). Unaprijednom selekcijom dodaje se po jedna varijabla u svakom koraku, a jednom kad prediktor uđe u regresijski model, više ga se ne isključuje (ni po kojem kriteriju). Detalji metode opisani su u nastavku.

4.2.2 Izgradnja modela višestruke linearne regresije unaprijednom selekcijom

4.2.2.1 Model višestruke linearne regresije

Model višestruke linearne regresije povezuje zavisnu varijablu Y s k prediktorskih varijabli x_1, x_2, \dots, x_k i dan je izrazom

$$Y = \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k + \varepsilon \quad (26)$$

pri čemu je ε slučajna varijabla koja predstavlja pogrešku aproksimacije.

Za n opservacija ($i = 1, 2, \dots, n$; $n > k$) model *višestruke linearne regresije* s k prediktorskih varijabli daje vezu oblika:

$$y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \beta_k x_{ik} + e_i = \beta_0 + \sum_{j=1}^k \beta_j x_{ij} + e_i, \quad (27)$$

gdje su x_{ij} i y_i vrijednosti prediktora i zavisne varijable za i -tu opservaciju, β_j su *parametri (koeficijenti) regresije*, a e_i predstavlja pogrešku modela. Parametar β_j je očekivana promjena u zavisnoj varijabli Y po jedinici promjene prediktorske varijable x_j kad se sve ostale prediktorske varijable drže konstantnima. Pretpostavlja se da je pogreška modela ε normalno distribuirana slučajna varijabla s aritmetičkom sredinom jednakom nuli i konstantnom varijancom σ^2 .

Linearni regresijski model je svaki model koji je linearan u parametrima modela, bez obzira na oblik površine koju formira u k -dimenzijskom prostoru¹¹ [63], pa su tako npr. polinomni modeli i modeli koji uključuju interakcijske članove također linearni modeli.

Model višestruke linearne regresije koristi se kad je egzaktna povezanost između zavisne varijable i prediktora nepoznata, ali je njime moguće dovoljno točno opisati tu povezanost za određene raspone vrijednosti prediktorskih varijabli [63]. Korisna mjera adekvatnosti modela u rješavanju problema višestrukim linearnom regresijom je testiranje hipoteza o parametrima modela. Poznata procedura za testiranje značajnosti parametara modela je *F-test* iz *analize varijance (ANOVA)*¹², koji ima nekoliko varijanti:

1. *test o značajnosti regresije ili skupni test*, kojim se testira značajnost svih prediktora u modelu i
2. *test o značajnosti jednog prediktora ili podskupa prediktorskih varijabli*.

4.2.2.2 Test o značajnosti regresije (skupni test)

Za potrebe testiranja značajnosti regresijskog modela ukupna varijabilnost zavisne varijable Y , tj. *ukupna suma kvadrata odstupanja* SS_T dijeli se na *sumu kvadrata odstupanja modela* SS_R (engl. *regression sum of squares*, udio varijabilnosti objašnjen regresijskim modelom) i *sumu kvadrata pogreške* SS_E (neobjašnjeni dio):

$$SS_T = SS_R + SS_E, \quad (28)$$

$$\sum_{i=1}^n (y_i - \bar{y})^2 = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2 + \sum_{i=1}^n (y_i - \hat{y}_i)^2. \quad (29)$$

¹¹ Modeli višestruke linearne regresije ne formiraju nužno plohe koje su linearne.

¹² Pojam "analiza varijance" podrazumijeva niz statističkih procedura za različite namjene. ANOVA proceduru u ovom poglavlju ne treba miješati s jednosmjernom analizom varijance provedenom u poglavlju 3.

Nul-hipotezom H_0 pretpostavlja se da su svi koeficijenti regresije jednaki nuli i da niti jedan od k prediktora ne utječe na zavisnu varijablu, dok njeno odbacivanje (odnosno prihvaćanje alternativne hipoteze H_1) implicira da je barem jedan koeficijent regresije različit od nule, tj. da prediktorska varijabla značajno doprinosi poboljšanju modela

$$\begin{aligned} H_0: & \beta_1 = \beta_2 = \dots = \beta_k = 0 \\ H_1: & \beta_j \neq 0 \text{ za bar jedan } j. \end{aligned} \quad (30)$$

U tom slučaju F -statistika jednaka je

$$F_0 = \frac{SS_R/k}{SS_E/(n-p)} = \frac{MS_R}{MS_E}, \quad (31)$$

gdje su MS_R i MS_E prosječna suma kvadrata odstupanja modela (engl. *regression mean square*) i prosječna suma kvadrata pogreške. Ukoliko je vrijednost F -statistike izračunate izrazom (31) veća od $f_{\alpha, k, n-p}$ (gdje je α vrijednost kumulativne distribucije, uobičajeno 0,05, a k i $n-p$ su stupnjevi slobode (engl. *degrees of freedom, DF*) brojnika i nazivnika izraza (31)), nul-hipoteza H_0 se odbacuje¹³. Uobičajeni ispis ANOVA tablice za testiranje značajnosti višestruke regresije dan je u tablici 4.1.

Tablica 4.1 ANOVA za testiranje značajnosti regresije

Uzrok varijabilnosti	DF	SS	MS	F -vrijednost	P -vrijednost
Model	$p - 1$	SS_R	MS_R	MS_R / MS_E	
Pogreška	$n - p$	SS_E	MS_E		
Ukupno	$n - 1$	SS_T			

Adekvatnost regresijskog modela često se procjenjuje omjerom sume kvadrata odstupanja objašnjene regresijskim modelom SS_R i ukupne sume kvadrata odstupanja SS_T , tzv. *koeficijentom determinacije* R^2 ,¹⁴

$$R^2 = \frac{SS_R}{SS_T} = 1 - \frac{SS_E}{SS_T}. \quad (32)$$

¹³ $p = k + 1$, broj linearnih jednadžbi u sustavu, po jedna za svaki nepoznati parametar regresije.

¹⁴ Kod višestruke regresije R^2 se zove i *koeficijent višestruke determinacije*.

Vrijednosti R^2 kreću se u granicama $0 \leq R^2 \leq 1$, gdje nula znači da model uopće ne objašnjava varijabilnost zavisne varijable, dok jedinica znači da model u potpunosti objašnjava varijabilnost u podacima.

Bolji pokazatelj adekvatnosti modela je *prilagođeni koeficijent determinacije* R_{adj}^2

$$R_{\text{adj}}^2 = 1 - \frac{SS_E / (n - p)}{SS_T / (n - 1)}, \quad (33)$$

jer se, za razliku od R^2 , on ne povećava s uključivanjem svake varijable u model već samo onih koje doprinose smanjenju sume kvadrata pogreške SS_E .¹⁵ Prilagođeni koeficijent determinacije R_{adj}^2 korisna je mjera i za prevenciju predefiniranja, tj. prenaučivosti modela, o čemu će biti riječi na kraju ovog odjeljka.

Nedostatak skupnog ANOVA F -testa o značajnosti regresije jest da ne pruža informacije o doprinosu individualnog prediktora (ili više njih) povećanju sume kvadrata odstupanja modela SS_R (tj. smanjenju sume kvadrata pogreške SS_E) kad se dodaju u model u koji je već uključen određen skup prediktorskih varijabli. Stoga je za provedbu analize relevantnosti monotonih značajki za procjenu cikličkih i zamornih parametara čelika prikladniji test o značajnosti jednog prediktora ili podskupa prediktorskih varijabli, čija je procedura opisana u nastavku.

4.2.2.3 Test o značajnosti jednog prediktora ili podskupa prediktorskih varijabli

Procedura za testiranje hipoteza o doprinosu jednog ili više prediktora dodanih u model koji već sadrži određeni skup prediktorskih varijabli zove se *test o značajnosti jednog prediktora* odnosno *test o značajnosti podskupa prediktorskih varijabli* (engl. *general regression significance test*). Čest je i naziv *metoda sekvencijalne sume kvadrata odstupanja* (engl. *sequential sum of squares method* ili *extra sum of squares method*), koji će se koristiti u daljnjem tekstu.

S obzirom na to da će se za analizu koristiti test o značajnosti jednog prediktora, u nastavku je objašnjena pripadajuća procedura.

¹⁵ S povećanjem broja prediktora u modelu koeficijent determinacije R^2 teži prema vrijednosti 1 (za n opservacija, $R^2 = 1$ može se dobiti polinomom $n - 1$ reda).

Metoda sekvencijalne sume kvadrata odstupanja uključuje sljedeće korake:

1. definiranje većeg, *punog modela* (engl. *full model*) (F) koji uključuje sve prediktorske varijable:

$$y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \beta_j x_{ij} + \dots + \beta_k x_{ik} + e_i, \quad (34)$$

2. definiranje manjeg, *reduciranog modela* (engl. *reduced model*) (R) koji ne uključuje jednu ili više prediktorskih varijabli čiji doprinos modelu želi biti testiran i kvantificiran:

$$y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \beta_{j-1} x_{i(j-1)} + \beta_{j+1} x_{i(j+1)} + \dots + \beta_k x_{ik} + e_i, \quad (35)$$

3. primjenu *sekvencijalnog F-testa* za testiranje sljedećih hipoteza:

$$\begin{aligned} H_0 : \beta_j &= 0 \\ H_1 : \beta_j &\neq 0 \end{aligned} \quad (36)$$

gdje se nul-hipotezom H_0 pretpostavlja da je koeficijent regresije uz prediktor dodan reduciranom modelu jednak nuli, dok alternativna hipoteza H_1 pretpostavlja da je regresijski koeficijent različit od nule, tj. da prediktorska varijabla značajno doprinosi modelu. Važno je napomenuti da su ova dva modela tzv. *ugnježđeni modeli* (engl. *nested models*) [58], odnosno puni model sadrži sve varijable koje sadrži i reducirani model, uz dodatak prediktorske varijable čiji se doprinos provjerava.

Sekvencijalni F -test je funkcija razlike između sume kvadrata odstupanja punog modela $SS_R(F)$ i sume kvadrata odstupanja reduciranog modela $SS_R(R)$:

$$\begin{aligned} F_0 &= \frac{SS_R(\beta_1, \beta_2, \dots, \beta_j, \dots, \beta_k) - SS_R(\beta_1, \beta_2, \dots, \beta_{j-1}, \beta_{j+1}, \dots, \beta_k)}{\frac{df_R - df_F}{SS_E(\beta_1, \beta_2, \dots, \beta_j, \dots, \beta_k)}} = \\ &= \frac{SS_R(F) - SS_R(R)}{\frac{df_R - df_F}{SS_E(F)}} = \frac{SS_R(\beta_j | \beta_1, \beta_2, \dots, \beta_{j-1}, \beta_{j+1}, \dots, \beta_k)}{\frac{df_R - df_F}{MS_E(F)}}. \end{aligned} \quad (37)$$

Brojnik sekvencijalnog F -testa, $SS_R(F) - SS_R(R)$ je *sekvencijalna suma kvadrata odstupanja* (engl. *sequential sum of squares*) dobivena dodavanjem koeficijenta β_j u model koji već sadrži koeficijente $\beta_1, \beta_2, \dots, \beta_{j-1}, \beta_{j+1}, \dots, \beta_k$ i obično se piše kao

$$SS_R(F) - SS_R(R) = SS_R(\beta_j | \beta_1, \beta_2, \dots, \beta_{j-1}, \beta_{j+1}, \dots, \beta_k) = SS_R(B | B_{-j}). \quad (38)$$

Razlika stupnjeva slobode reduciranog i punog modela $r = df_R - df_F$ zove se *stupanj slobode sekvencijalne sume kvadrata odstupanja*. Sekvencijalna suma kvadrata odstupanja često se naziva i *Tip 1 sume kvadrata odstupanja* (engl. *sequential sum of squares*) i za razliku od *Tipa 3 (Prilagođena suma kvadrata odstupanja, engl. adjusted sum of squares)*, kod koje redosljed ulaska varijabli u model nije bitan. Tip 1 sume kvadrata odstupanja izravno ovisi o varijablama koje su prethodno već bile uključene u model [61].

Ukoliko je vrijednost F -statistike iz izraza (37) veća od $f_{\alpha, r, n-p}$ ($F_0 > f_{\alpha, r, n-p}$), nul-hipotezu H_0 treba odbaciti, što znači da koeficijent regresije čiji se doprinos regresijskom modelu istražuje nije jednak nuli, odnosno da je j -ti promatrani prediktor u punom modelu značajno doprinio regresijskom modelu. Uobičajeni ispis ANOVA tablice za sekvencijalni F -test dan je u tablici 4.2.

Tablica 4.2 ANOVA za sekvencijalni F -test

Izvor varijabilnosti	DF	Tip I SS	Sekv. MS	F -statistika	P -vrijednost
Regresija	$df_F = p - 1$	$SS_R(F)$	$MS_R(F)$	$MS_R(B B_{-j}) / MS_E(F)$	
B_{-j}	$df_R = p - 1 - r$	$SS_R(R)$	$MS_R(R)$		
B	$r = df_R - df_F$	$SS_R(B B_{-j})$	$MS_R(B B_{-j})$		
Pogreška	$n - p$	SS_E	$MS_E(F)$		
Ukupno	$n - 1$	SS_T			

Testovi koriste sekvencijalnu sumu kvadrata odstupanja.

Kako bi se kvantificirao razmjor varijabilnosti dodatno objašnjene prediktorima u punom modelu, a koji nisu uključeni u reducirani model, definiran je *koeficijent parcijalne determinacije* (engl. *coefficient of partial determination*)

$$R_{y, \beta_j | \beta_1, \beta_2, \dots, \beta_{j-1}, \beta_{j+1}, \dots, \beta_k}^2 = \frac{SS_R(\beta_j | \beta_1, \beta_2, \dots, \beta_{j-1}, \beta_{j+1}, \dots, \beta_k)}{SS_E(\beta_1, \beta_2, \dots, \beta_j, \dots, \beta_k)}. \quad (39)$$

Koeficijent parcijalne determinacije obično je izražen u postotku, a u daljnjem tekstu koristit će se kraća oznaka R_{seq}^2 .

Prema [63] i [38] sekvencijalna suma kvadrata odstupanja posebno je korisna za izgradnju modela višestruke regresije te je u ovom istraživanju primijenjena kao dio unaprijedne postupne regresijske analize (tj. unaprijedne selekcije) za identifikaciju monotonih parametara koji su statistički značajni za procjenu cikličkih i zamornih parametara materijala.

Kriterij za dodavanje (ili oduzimanje) prediktora u svakom koraku izražen je kao sekvencijalni F -test i kvantificiran koeficijentom parcijalne determinacije R_{seq}^2 iz izraza (39). Razina značajnosti α postavljena je na 0,10 (umjesto uobičajenih 0,05), kako bi se olakšalo ulaženje prediktorskih varijabli u model. Analize su provedene korištenjem programskog paketa MINITAB 17™ [60].

4.2.3 Dodatna razmatranja u vezi s metodom unaprijedne selekcije

Prilikom izgradnje polinomnog regresijskog modela javlja se nekoliko pitanja: 1) da li graditi hijerarhijske ili nehijerarhijske modele, 2) jesu li u model uključene visokokorelirane prediktorske varijable i 3) koliko je razvijeni regresijski model adekvatan za buduća predviđanja.

Prvo je pitanje uključivanja članova nižeg reda u model koji sadrži članove višeg reda, ukoliko članovi nižeg reda nisu statistički značajni [58]. Modeli u koje je uključen član nižeg reda koji nije statistički značajan zove se *hijerarhijski model*, naspram *nehijerarhijskog modela*, u koji se članovi nižeg reda koji nisu statistički značajni ne uključuju. Oprečna su mišljenja i preporuke o hijerarhiji gradnje modela, ukoliko članovi nižeg reda nisu značajni. Neki autori preferiraju nehijerarhijske modele kako se ne bi bespotrebno smanjivao broj stupnjeva slobode modela, međutim Peixoto [69, 70] smatra da polinomni regresijski modeli trebaju biti hijerarhijski, zato što izostavljanje članova nižeg reda povećava opasnost od umjetno povećanih ili smanjenih statističkih pokazatelja, poput koeficijenta determinacije R^2 , prosječne sume kvadrata pogreške MSE i drugih. I Kutner [38] navodi da članove nižeg reda treba zadržati u modelu bez obzira na značajnost, jer pružaju bazične informacije o obliku funkcionalne zavisnosti, dok članovi višeg reda preciziraju oblik te funkcije. U ovom su istraživanju građeni hijerarhijski modeli te je usprkos članu prvog reda koji nije statistički značajan istraživan i doprinos kvadratnog člana.

Multikolinearnost, kao drugo pitanje pri izgradnji regresijskog modela, pak može utjecati na rezultate regresijske analize tako da primjerice procijenjene vrijednosti parametara β_k budu nepouzdanе (imaju veliku standardnu devijaciju) ili pak pogrešnog predznaka. Multikolinearnost je česta pojava između prediktorskih varijabli opservacijskih podataka (poput duljine u centimetrima i inčima). U poglavlju 4.3 je, u određenoj mjeri, riješen problem multikolinearnosti izbacivanjem stvarnog istežanja pri lomu ϵ_f iz skupa potencijalnih prediktora zbog visoke koreliranosti te značajke sa smanjenjem poprečnog presjeka pri lomu Z . Daljnje

reduciranje prediktorskih varijabli nije provedeno radi mišljenja da, za razliku od prethodnog primjera, preostale varijable ne "opisuju" iste fenomene. Kao primjer može se navesti koreliranost granice tečenja R_e s vlačnom čvrstoćom R_m . Kod gradnje polinomnih modela pak, multikolinearnost se javlja između članova nižeg i višeg reda ukoliko je raspon vrijednosti prediktorske varijable malen [38, 58]. Smanjenje multikolinearnosti između članova nižeg i višeg reda može se postići *centriranjem nezavisnih varijabli*, tako da se od opservacija oduzme aritmetička sredina pojedine varijable¹⁶. Centriranje rezultira i realnijim vrijednostima pokazatelja multikolinearnosti među prediktorskim varijablama, tj. *faktora inflacije varijance VIF* (engl. *variance inflation factor*), koji će se kontrolirati za članove regresijskog modela koji se pokažu statistički značajnima pri provođenju sekvencijalnog F -testa. Prije je rečeno da multikolinearnost utječe na povećanje procjenitelja standardne devijacije (odnosno varijance) za individualne parametre regresije. Faktor inflacije varijance VIF je [63]

$$VIF(\beta_j) = \frac{1}{1 - R_j^2} \quad j = 1, 2, \dots, k, \quad (40)$$

gdje je R_j^2 koeficijent determinacije modela s prediktorom x_j u ulozi zavisne varijable, a svi ostali prediktori $x_1, x_2, \dots, x_{j-1}, x_{j+1}, \dots, x_k$ ostaju u ulozi nezavisnih varijabli. VIF raste s R_j^2 , tj. kad je varijabla x_j visokokorelirana s ostalim prediktorima. Razni autori navode da ozbiljan problem multikolinearnosti postoji ukoliko je VIF veći od 10 [58].

I kao treći problem javlja se pitanje primjenjivosti modela izgrađenog na dostupnom uzorku na podacima koji nisu korišteni za razvoj modela. Postoji više metoda za procjenu adekvatnosti modela za buduća predviđanja, koje je poželjno provoditi na novim podacima. Kad prikupljanje novih podataka nije moguće, može se koristiti *unakrsna validacija* (ili *kros-validacija*, engl. *cross-validation*). Za provođenje unakrsne validacije potrebno je uzorak podijeliti na dva dijela, na poduzorak za razvoj modela i poduzorak za validaciju, koji će biti korišten za računanje pokazatelja adekvatnosti modela poput *koeficijenta determinacije za buduća predviđanja* R_{pred}^2 (engl. *predicted coefficient of determination*) [58]. Međutim, ove su metode teško primjenjive u područjima poput istraživanja ponašanja materijala koja traže vremenski i financijski zahtjevne eksperimente, što čini eksperimentalne podatke malobrojnima. Iz tog se razloga u

¹⁶ Centriranje varijabli, za razliku od drugih načina standardizacije, ne mijenja način interpretacije regresijskih parametara (koeficijenata). Svaki parametar β_j i dalje predstavlja očekivanu promjenu vrijednosti zavisne varijable y_i po jedinici promjene prediktorske varijable x_{ij} kad se sve ostale prediktorske varijable drže konstantnima [22].

ovom istraživanju kao dodatni kriterij za gradnju i procjenu adekvatnosti modela koristila statistika $R_{\text{jack-knife}}^2$:

$$R_{\text{jack-knife}}^2 = 1 - \frac{\sum_{\substack{i=1 \\ i \neq j}}^n (y_i - \hat{y}_j)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}. \quad (41)$$

Za izračun $R_{\text{jack-knife}}^2$ izostavlja se jedna po jedna opservacija y_j iz postojećeg uzorka, procjenjuje regresijski model i određuje koliko dobro taj model predviđa izostavljenu opservaciju. $R_{\text{jack-knife}}^2$ korisna je mjera i za prevenciju predefiniranja, tj. prenaučivosti modela – situacije kad je model prikladan za uzorak na kojem je razvijan, ali ne i buduće opservacije. Ukoliko se vrijednost $R_{\text{jack-knife}}^2$ smanjuje dodavanjem novih prediktora u model čak i kad su oni statistički značajni, postoji opasnost od predefiniranja modela. Budući da MINITAB u slučaju kad ne postoji mogućnost unakrsne validacije statistiku R_{pred}^2 računa prema izrazu (41) za $R_{\text{jack-knife}}^2$, u narednim će poglavljima, radi pojednostavljenja, oznaka ove statistike biti R_{pred}^2 .

Predefiniranje (engl. *overfitting*) je jedan od mogućih problema i u razvoju umjetnih neuronskih mreža, o čemu će biti riječi u poglavlju 5. Stoga će se pri provođenju postupne regresijske analize (unaprijedne selekcije) na temelju dosad navedenih kriterija primijeniti princip *parsimonije*: ukoliko dva regresijska modela imaju istu "moć" predviđanja, treba odabrati model s manjim brojem parametara regresije, odnosno prediktorskih varijabli. Princip *parsimonije* temeljen je na općepoznatoj *Ockhamovoj britvi*¹⁷, prema kojoj od svih mogućih rješenja uvijek treba odabrati ono najjednostavnije.

4.3 Postupak identifikacije monotonih značajki relevantnih za procjenu cikličkih i zamornih parametara čelika

S obzirom na to da su rezultati jednofaktorske analize varijance u poglavlju 3 pokazali da postoje statistički značajne razlike između cikličkih i zamornih parametara nelegiranih, niskolegiranih i visokolegiranih čelika, provedena je unaprijedna selekcija za identifikaciju monotonih značajki relevantnih za procjenu cikličkih (R_e' , K' i n') i zamornih (σ_r' , b , ε_r' i c) parametara. Analiza je provedena zasebno za svaki parametar i za svaku skupinu čelika.

¹⁷ William of Ockham (1287–1347/1349): "*Pluralitas non est ponenda sine necessitate.*" [86]

Za provedbu analiza korišteni su podaci iz poglavlja 3 koji sadrže vrijednosti svih cikličkih i zamornih parametara te vrijednosti većine monotonih značajki. Selekcija materijala koji sadrže sve monotone značajke bila bi prestroga i znatno bi umanjila broj materijala valjanih za provođenje statističke analize, s posljedicom smanjenja pouzdanosti provedene analize [51]. Iz tog razloga, istežanje pri lomu A_5 i Poissonov koeficijent ν kao dvije rijetko dostupne monotone značajke nisu uvrštene u analizu.

Kao što je rečeno u odjeljku 4.2.3, multikolinearnost može značajno utjecati na statističku analizu i rezultirati pogrešnim zaključcima o značajnosti pojedinog prediktora. Primjer koreliranih prediktora su tvrdoća i vlačna čvrstoća R_m [73], kao i smanjenje poprečnog presjeka pri lomu Z i stvarno istežanje pri lomu ε_f , koji su i povezani izrazima (8), odnosno (9). Više materijala sadržavalo je podatke za vlačnu čvrstoću R_m i smanjenje poprečnog presjeka pri lomu Z , pa tvrdoća i stvarno istežanje pri lomu ε_f nisu uključene u analizu. Za manji broj materijala postojala je mogućnost preračunavanja smanjenja poprečnog presjeka pri lomu Z iz vrijednosti stvarnog istežanja pri lomu ε_f , no za provođenje relevantne statističke analize nastojalo se izbjeći intervencije u eksperimentalne podatke.

Zbog malog broja materijala za koje su oni poznati, koeficijent deformacijskog očvršćivanja K i eksponent deformacijskog očvršćivanja n visokolegiranih čelika nisu uključeni u analizu.

U postojećim metodama se za procjenu cikličkih i/ili zamornih parametara materijala koriste i dva omjera: omjer vlačne čvrstoće i granice tečenja R_m/R_e [43, 44] te omjer omjer vlačne čvrstoće i modula elastičnosti R_m/E [14, 64, 67]. Iz tog su razloga, pored monotonih značajki prikupljenih iz literature, u analizu uključeni i navedeni omjeri.

Nakon selekcije, za provođenje daljnjih istraživanja preostalo je 116 skupova podataka, i to 34 materijala iz skupine nelegiranih čelika, 47 iz skupine niskolegiranih čelika i 35 materijala iz skupine visokolegiranih čelika. Pregled monotonih značajki čiji se doprinos procjeni cikličkih i zamornih parametara analizirao dan je u tablici 4.3.

Tablica 4.3 Pregled monotonih značajki za koje se statističkom analizom utvrđivala značajnost za procjenu cikličkih i zamornih parametara

Skupina čelika	Broj materijala korištenih za provedbu statističke analize	Monotona značajka								
		E	R_e or $R_{p0.2}$	R_m	R_m/R_e	R_m/E	Z	K	n	σ_f
NeČ	34	+	+	+	+	+	+	+	+	+
NČ	47	+	+	+	+	+	+	+	+	+
VČ	35	+	+	+	+	+	+			

Nakon pripreme podataka generirane su matrice korelacije s ciljem provjere korelacije između monotonih značajki i pojedinog cikličkog/zamornog parametra materijala. Matrica korelacije daje pregled koeficijenata korelacije r (Pearsonov koeficijent korelacije), a na osnovi njihovih vrijednosti definira se redosljed ulaska varijabli u model. Što je apsolutna vrijednost koeficijenta korelacije r bliža ± 1 , očekuje se jača veza između promatranih varijabli i viši rang pripadajuće monotone značajke, te on ranije ulazi u model. Iznimno, ukoliko su vlačna čvrstoća R_m i neka druga monotona značajka imale sličnu vrijednost koeficijenta korelacije r , vlačna čvrstoća R_m je uvijek imala prednost pri ulasku u analizu.

Pri svakom koraku definirani su puni i reducirani model prema izrazima (34) i (35). U svakom koraku uključivana je po jedna varijabla (tj. jedan regresijski koeficijent), a provjeravao se doprinos članova prvog i drugog reda (kvadratni član). Članovi višeg reda i interakcijski članovi nisu razmatrani. S obzirom na to da je pristup gradnji modela hijerarhijski, čak i kad se članovi nižeg reda nisu pokazali statistički značajnima, zadržani su u modelu za potrebu provjere značajnosti članova višeg reda. Za posljednji dodani prediktor očitavali su se vrijednost sekvencijalne F -statistike prema izrazu (37), P -vrijednost te R_{pred}^2 . Ako je sekvencijalni F -test pokazao da je posljednja dodana varijabla u model statistički značajna, izračunat je parcijalni koeficijent determinacije R_{seq}^2 prema izrazu (39), provjeren je faktor inflacije varijance VIF radi utvrđivanja postojanja ili nepostojanja multikolinearnosti i u konačnici, vodeći se principom parsimonije, utvrdilo se je li opravdano uključiti tu varijablu u regresijski model. Sve nezavisne varijable su centrirane kako bi se izbjegla multikolinearnost između linearnih i kvadratnih članova iste monotone značajke.

Postupak gradnje modela ilustriran je na primjeru određivanja monotonih značajki relevantnih za procjenu cikličke granice tečenja R_e' nelegiranih čelika. Radi opsežnosti rezultata prikazana su prva tri od ukupno 18 koraka. Varijable koje s R_e' nelegiranih čelika imaju najviši koeficijent korelacije r su granica tečenja R_e ($r = 0,890$) i vlačna čvrstoća R_m ($r = 0,887$). Ukoliko vlačna čvrstoća ima sličnu vrijednost koeficijenta korelacije kao i neka druga varijabla, kao što je to u ovom slučaju, ona ima prednost ulaska u model.

U prvom koraku definiran je regresijski model s R_e' kao zavisnom i R_m kao nezavisnom varijablom:

$$R_e' = -19,6 + 0,6434R_m. \quad (42)$$

Iz ANOVA tablice u ispisu programskog paketa MINITAB očitane su vrijednosti sume kvadrata pogreške SS_E i prosječne sume kvadrata pogreške MS_E tog modela, sekvencijalne sume kvadrata odstupanja $SS_R(B|B_j)$ koja je u prvom koraku jednaka sumi kvadrata odstupanja modela SS_R . Nadalje, očitana je F -statistika prema (37), P -vrijednost za taj regresijski koeficijent (odnosno prediktor) i koeficijent determinacije za buduća predviđanja R_{pred}^2 . Pregled vrijednosti, skupa s onim očitanim ili izračunatim u drugom i trećem koraku, dan je u tablici 4.4. Iz tablice 4.4 vidljivo je da je $P < 0,10$, a $R_{pred}^2 = 76\%$.

Tablica 4.4 Prva tri koraka unaprijedne selekcije monotonih parametara za procjenu R_e' nelegiranih čelika

Varijable u reduciranom modelu	Varijable u punom modelu	$SS_E(F)$	$MS_E(F)$	$SS_R(B B_j)$	F -statistika	P -vrijednost	R_{pred}^2	R_{seq}^2
-	R_m	100998	3156	371219	117,62	0,000	75,75	-
R_m	R_m, R_m^2	87348	2818	13650	4,84	0,035	78,76	13,51
R_m, R_m^2	R_m, R_m^2, R_e	74950	2498	12397	4,96	0,034	80,41	14,19

U drugom koraku u model koji već sadrži linearni član R_m ulazi kvadratni član R_m^2 :

$$R_e' = 255 - 0,238R_m + 0,000665R_m^2. \quad (43)$$

Model (43) sad je *puni model*, jer sadrži sve prethodno uključene prediktore (R_m) i onaj prediktor (u ovom slučaju R_m^2) čiji se doprinos smanjenju sume kvadrata pogreške provjerava. U ovom koraku model iz (42) postaje *reducirani model*. Očitane su iste vrijednosti kao i u prethodnom koraku te je utvrđeno da je P -vrijednost manja od 0,10, odnosno da je koeficijent regresije uz prediktor R_m^2 u modelu statistički značajan. Nadalje, vrijednost R_{pred}^2 porasla je za oko 3%. Dodatno je prema izrazu (39) izračunata vrijednost koeficijenta parcijalne

determinacije R_{seq}^2 te je utvrđeno da uključivanje R_m^2 u model koji već sadrži linearni član R_m doprinosi smanjenju sume kvadrata pogreške SS_E za 14 %. Provjerene su i vrijednosti faktora inflacije varijance (VIF -a) te je utvrđeno da se nalaze unutar preporučenih granica. S obzirom na navedeno, kvadratni član R_m^2 uključen je u model.


U trećem koraku provjeravan je doprinos linearnog člana granice tečenja R_e modelu koji već sadrži linearni i kvadratni član vlačne čvrstoće (R_m i R_m^2):

$$R'_c = 295 - 0,599R_m + 0,000679R_m^2 + 0,408R_e. \quad (44)$$

Model iz (44) sad je puni model, a puni model iz drugog koraka (43) sad postaje reducirani model. P -vrijednost regresijskog koeficijenta uz R_e manja je od 0,10 što ga čini statistički značajnim u modelu. Nadalje, vrijednost R_{pred}^2 porasla je za oko 2,5 %. Dodatno je prema izrazu (39) izračunata vrijednost koeficijenta parcijalne determinacije R_{seq}^2 te je utvrđeno da uključivanje granice tečenja R_e u model koji već sadrži R_m i R_m^2 doprinosi smanjenju sume kvadrata pogreške SS_E za 14 %. Vrijednosti faktora inflacije varijance VIF porasle su u odnosu na prvi drugi korak, što je i očekivano zbog koreliranosti vlačne čvrstoće R_m i granice tečenja R_e , no utvrđeno je da se nalaze unutar preporučenih granica. Granica tečenja R_e je, s obzirom na pokazatelje, uključena u model.

U narednom, četvrtom koraku provjeravan je doprinos kvadratnog člana granice tečenja R_e^2 te on nije uključen u model za procjenu cikličke granice tečenja nelegiranih čelika s obzirom da je P -vrijednost regresijskog koeficijenta uz R_e^2 veća od prethodno definirane razine značajnosti od 0,10. Detaljniji rezultati ove analize, kao i rezultati svih preostalih koraka, dani su u tablici C.1 Priloga C.

Cjelokupna procedura za identifikaciju utjecajnih monotonih značajki dana je na dijagramu toka na slici 4.1. Rezultati provedenih analiza dani su u poglavljima 4.4.1 za cikličke, odnosno 4.4.2 za zamorne parametre nelegiranih, niskolegiranih i visokolegiranih čelika.



Slika 4.1 Dijagram toka za identifikaciju relevantnih monotonih značajki, prema [51]

4.4 Unaprijedna selekcija monotoni značajki relevantnih za procjenu cikličkih i zamornih parametara materijala

4.4.1 Rezultati unaprijedne selekcije za procjenu cikličkih parametara

4.4.1.1 Određivanje redoslijeda ulaska prediktora u modele za procjenu cikličkih parametara čelika

Prema veličini koeficijenta korelacije r određen je redoslijed kojim monotone značajke, tj. prediktorske varijable ulaze u model. Iznimka je vlačna čvrstoća R_m , koja ima prednost pred drugim varijablama ukoliko imaju sličnu vrijednost koeficijenta korelacije r . Koeficijenti korelacije r između cikličkih parametara R_e' , K' i n' i monotoni značajki čiji se doprinos procjeni cikličkih parametara želi provjeriti i odgovarajuće P -vrijednosti dani su u tablici 4.5 za nelegirane, niskolegirane i visokolegirane čelike.

Tablica 4.5 Koeficijenti korelacije između cikličkih i monotoni parametara nelegiranih, niskolegiranih i visokolegiranih čelika i odgovarajuće P -vrijednosti

Skupina čelika	Ciklički parametar	Monotoni parametar								
		E	R_e	R_m	R_m/R_e	R_m/E	Z	K	n	σ_f
NeČ	R_e'	-0,043 0,810	0,890 0,000	0,887 0,000	-0,536 0,001	0,883 0,000	-0,541 0,001	0,430 0,011	-0,520 0,002	0,490 0,003
	K'	-0,170 0,337	0,429 0,011	0,575 0,000	-0,011 0,950	0,594 0,000	-0,376 0,029	0,518 0,002	0,004 0,983	0,361 0,036
	n'	-0,135 0,446	-0,601 0,000	-0,474 0,005	0,590 0,000	-0,449 0,008	0,158 0,372	-0,060 0,736	0,559 0,001	-0,294 0,091
NČ	R_e'	-0,103 0,493	0,913 0,000	0,944 0,000	-0,421 0,003	0,930 0,000	-0,572 0,000	0,855 0,000	-0,363 0,012	0,643 0,000
	K'	-0,024 0,873	0,711 0,000	0,821 0,000	-0,031 0,834	0,797 0,000	-0,755 0,000	0,748 0,000	-0,142 0,340	0,369 0,011
	n'	0,086 0,566	-0,283 0,054	-0,152 0,309	0,625 0,000	-0,163 0,273	-0,319 0,029	-0,091 0,545	0,403 0,005	-0,387 0,007
VČ	R_e'	-0,324 0,058	0,827 0,000	0,873 0,000	-0,582 0,000	0,905 0,000	-0,613 0,000	N/A N/A	N/A N/A	N/A N/A
	K'	-0,067 0,702	-0,399 0,017	-0,191 0,273	0,599 0,000	-0,166 0,340	0,106 0,546	N/A N/A	N/A N/A	N/A N/A
	n'	0,079 0,652	-0,879 0,000	-0,744 0,000	0,858 0,000	-0,725 0,000	0,523 0,001	N/A N/A	N/A N/A	N/A N/A

Sadržaj ćelija: koeficijent korelacije r
 P -vrijednost

Na osnovi koeficijenta korelacije r utvrđen je redosljed ulaska monotonih značajki u model za predviđanje cikličkih parametara te je prikazan u tablici 4.6 za sve tri skupine čelika.

Tablica 4.6 Redosljed ulaska monotonih parametara u modele regresijske analize za procjenu cikličkih parametara nelegiranih, niskolegiranih i visokolegiranih čelika

Skupina čelika	Ciklički parametar	Redosljed ulaska monotonih varijabli u analizu								
		1.	2.	3.	4.	5.	6.	7.	8.	9.
NeČ	R_e'	R_m	R_e	R_m/E	Z	R_m/R_e	n	σ_f	K	E
	K'	R_m/E	R_m	K	R_e	Z	σ_f	E	R_m/R_e	n
	n'	R_e	R_m/R_e	n	R_m	R_m/E	σ_f	Z	E	K
NČ	R_e'	R_m	R_m/E	R_e	K	σ_f	Z	R_m/R_e	n	E
	K'	R_m	R_m/E	Z	K	R_e	σ_f	n	R_m/R_e	E
	n'	R_m/R_e	n	σ_f	Z	R_e	R_m/E	R_m	K	E
VČ	R_e'	R_m	R_m/E	R_e	Z	R_m/R_e	E			
	K'	R_m/R_e	R_e	R_m	R_m/E	Z	E			
	n'	R_e	R_m/R_e	R_m	R_m/E	Z	E			

U model uvijek ulazi član nižeg reda (linearni član), nakon čega se dodatno provjerava doprinos kvadratnog člana (član višeg reda), koji ulazi u model odmah nakon linearnog člana monotone značajke. Izgradnja modela višestruke regresije s članovima drugog reda zahtijeva dvostruki broj koraka u unaprijednoj selekciji od broja prediktorskih varijabli čiji se doprinos procjeni zavisnih varijabli istražuje, što rezultira velikim brojem podataka. Stoga su u nastavku komentirani samo najvažniji rezultati, a detaljni rezultati svakog koraka unaprijedne selekcije za pojedinačne analize nalaze se u Prilogu C.

4.4.1.2 Monotone značajke relevantne za procjenu cikličke granice tečenja R_e'

Rezultati unaprijedne selekcije pokazali su da su različite monotone značajke relevantne za procjenu cikličke granice tečenja R_e' nelegiranih, niskolegiranih i visokolegiranih čelika. Za sve skupine, prva monotona značajka koja se pokazala statistički značajnom i ušla u model je vlačna čvrstoća R_m .

Za procjenu R_e' nelegiranih čelika granica tečenja R_e doprinijela je smanjenju sume kvadrata pogreške za 14 %, smanjenje poprečnog presjeka pri lomu Z za daljnjih, značajnih 29 %, a eksponent cikličkog očvršćivanja n za dodatnih 12,66 %.

Za procjenu R_e' niskolegiranih čelika koeficijent deformacijskog očvršćivanja K doprinio je smanjenju sume kvadrata pogreške za 26 %, a omjer vlačne čvrstoće i granice tečenja R_m/R_e za daljnjih čak 53 %.

Za procjenu R_e' visokolegiranih čelika uključivanjem omjera vlačne čvrstoće i modula elastičnosti R_m/E , granice tečenja R_e i smanjenja poprečnog presjeka pri lomu Z u model koji polazi od vlačne čvrstoće R_m smanjila se suma kvadrata pogreške za, redom, 20 %, 21 % i 43 %.

4.4.1.3 Monotone značajke relevantne za procjenu koeficijenta cikličkog deformacijskog očvršćivanja K'

Monotone značajke koje su se pokazale relevantnima za procjenu koeficijenta cikličkog deformacijskog očvršćivanja K' nelegiranih čelika su, osim vlačne čvrstoće R_m , granica tečenja R_e i eksponent deformacijskog očvršćivanja n . Te dvije varijable doprinijele su smanjenju sume kvadrata pogreške za 19 % i daljnjih 11 %, kao i ukupnom povećanju koeficijenta determinacije za buduća predviđanja R_{pred}^2 od oko 15 %. Osim spomenutih varijabli, dvije varijable čiji se doprinos pokazao statistički značajnim (P -vrijednost $< \alpha = 0,10$) nisu uključene u model. Omjer vlačne čvrstoće i modula elastičnosti R_m/E radi povećanja VIF faktora i smanjenja R_{pred}^2 , a koeficijent deformacijskog očvršćivanja K radi značajnog smanjenja R_{pred}^2 do kojeg bi došlo uključivanjem statistički značajnog kvadratnog člana u model.

Kod niskolegiranih čelika, pored linearnog i kvadratnog člana vlačne čvrstoće R_m , smanjenje poprečnog presjeka pri lomu Z doprinijelo je objašnjenju varijacije zavisne varijable K' od 40 %.

Za procjenu K' visokolegiranih čelika značajnim se pokazao samo omjer R_m/R_e .

Valja reći da je R_{pred}^2 regresijskog modela za procjenu K' niskolegiranih čelika znatno viši od onih nelegiranih i visokolegiranih čelika – 83 % naspram ≈ 37 %.

4.4.1.4 Monotone značajke relevantne za procjenu eksponenta cikličkog deformacijskog očvršćivanja n'

Uključivanjem omjera R_m/R_e u model za procjenu eksponenta cikličkog deformacijskog očvršćivanja n' nelegiranih čelika koji već sadrži granicu tečenja R_e suma kvadrata pogreške smanjila se za 9 %. Uključivanjem eksponenta deformacijskog očvršćivanja n suma kvadrata pogreške smanjila se za daljnjih, značajnih 30 %.

Statistički značajni prediktori za procjenu n' niskolegiranih čelika su omjer vlačne čvrstoća i granice tečenja R_m/R_e i eksponent deformacijskog očvršćivanja n .

Kod visokolegiranih čelika, osim granice tečenja R_e statistički značajnim za procjenu n' pokazao se i omjer R_m/R_e , koji je doprinio objašnjenju varijacije zavisne varijable za 12 %. Iako su se statistički značajnim pokazali i kvadratni član R_e^2 i smanjenje poprečnog presjeka pri lomu Z , ove varijable nisu uključene u model. Doprinos kvadratnog člana R_e^2 pokazao se vrlo malim ($R_{seq}^2 = 3 \%$), pa je primijenjen princip parsimonije, a uključivanje Z rezultiralo bi smanjenjem koeficijenta determinacije za buduća predviđanja R_{pred}^2 .

Kao što je to bio slučaj s regresijskim modelima za procjenu K' , R_{pred}^2 regresijskog modela za procjenu n' jedne skupine čelika značajno odstupa od drugih. Tako je R_{pred}^2 visokolegiranih čelika $\approx 77 \%$ naspram 46% , tj. 32% za nelegirane i niskolegirane čelike.

4.4.1.5 Diskusija rezultata unaprijedne selekcije za cikličke parametre

Rezultati unaprijedne selekcije pokazali su da su različite monotone značajke relevantne za procjenu pojedinih cikličkih parametara i različitih skupina čelika.

Najviši koeficijent korelacije između cikličke granice tečenja R_e' i neke monotone značajke utvrđen je s vlačnom čvrstoćom R_m , i to za sve skupine čelika. Ovo je djelomično u skladu s [44], gdje su Lopez i Fatemi predložili procjenu R_e' na osnovi vlačne čvrstoće R_m , i metodom iz [43], gdje Li et al. predlažu izraz za procjenu R_e' na osnovi R_m i smanjenja poprečnog presjeka pri lomu Z . Budući da su izrazi za procjenu R_e' iz [43] i [44] razvijeni na uzorku sačinjenom većinom od nelegiranih i niskolegiranih čelika, treba napomenuti da u ovom istraživanju nije utvrđena statistička značajnost Z za procjenu R_e' niskolegiranih čelika.

Usporedbom monotonih značajki čija se relevantnost za procjenu koeficijenta i eksponenta cikličkog deformacijskog očvršćivanja K' i n' utvrdila provođenjem unaprijedne selekcije s monotonim značajkama u postojećim metodama procjene tih parametara, utvrđena su neka nepodudaranja. Basan et al. [11], Lopez i Fatemi [44] i Li et al. [43] za procjenu K' predlažu izraze na osnovi lako dostupne vlačne čvrstoće R_m ili Brinellove tvrdoće HB , a Zhang et al. u [91] predlažu niz izraza na osnovi K , R_m , R_e , E , σ_f , ϵ_f i n .

Rezultati unaprijedne selekcije pokazali su, međutim, sljedeće:

- K nije relevantan za procjenu K' ,

- R_m , R_e i/ili njihov omjer R_m/R_e relevantni su za procjenu K' svih skupina čelika,
- E i σ_f nisu statistički značajni za procjenu K' niti bilo kojeg drugog cikličkog parametra za nelegirane i niskolegirane čelike,
- E nije statistički značajan za procjenu cikličkih parametara visokolegiranih čelika, dok se zbog nedostupnosti podataka za σ_f značajnost nije mogla utvrditi,
- n je statistički značajan samo za procjenu K' niskolegiranih čelika,
- stvarno istezanje pri lomu ε_f nije uključeno u analizu zbog nedovoljnog broja podataka, ali se smanjenje poprečnog presjeka pri lomu Z , s kojim je ε_f povezana izrazom (8) pokazalo u velikoj mjeri značajnim za procjenu K' , doduše samo za niskolegirane čelike.

Utjecaj Brinellove tvrdoće HB na procjenu koeficijenta cikličkog deformacijskog očvršćivanja K' nije istražen radi koreliranosti HB i vlačne čvrstoće R_m i HB utvrđene u [73].

Za n' Lopez i Fatemi [44] predlažu procjenu na osnovi kombinacije vlačne čvrstoće R_m i granice tečenja R_e ili njihovog omjera R_m/R_e . Ovo je djelomično u skladu s rezultatima unaprijedne selekcije, gdje je pokazano da je R_e relevantna za procjenu eksponenta cikličkog deformacijskog očvršćivanja n' nelegiranih i visokolegiranih čelika, dok je omjer R_m/R_e relevantan za procjenu n' svih skupina čelika. Vlačna čvrstoća R_m nije se pokazala značajnom ni za jednu skupinu čelika.

Zhang et al. [91] predlažu procjenu n' na osnovi istih monotonih značajki kao i za K' . Unaprijednom selekcijom potvrđeno je da n jest, a Z nije relevantan za procjenu n' nelegiranih i niskolegiranih čelika. Doprinos Z procjeni n' visokolegiranih čelika ocijenjen je irelevantnim radi negativnog utjecaja koji bi uključenje Z u model imalo na koeficijent determinacije za buduća predviđanja R_{pred}^2 .

4.4.2 Rezultati unaprijedne selekcije za procjenu zamornih parametara

4.4.2.1 Određivanje redoslijeda ulaska prediktora u modele za procjenu zamornih parametara čelika

Kao i za unaprijednu selekciju prediktora za procjenu cikličkih parametara, prema apsolutnim vrijednostima koeficijenta korelacije r određen je redoslijed kojim monotone značajke ulaze u modele za procjenu zamornih parametara čelika. Iznimka je vlačna čvrstoća R_m , koja ima prednost pred drugim varijablama ukoliko imaju sličnu vrijednost koeficijenta korelacije r .

Koeficijenti korelacije r između zamornih parametara σ_f' , b , ε_f' , c i monotonih značajki čiji se doprinos procjeni zamornih parametara želi provjeriti i odgovarajuće P -vrijednosti dani su u tablici 4.7 za nelegirane, niskolegirane i visokolegirane čelike.

Tablica 4.7 Koeficijenti korelacije između zamornih i monotonih parametara nelegiranih, niskolegiranih i visokolegiranih čelika i odgovarajuće P -vrijednosti

Skupina čelika	Zamorni parametar	Monotoni parametar								
		E	R_e	R_m	R_m/R_e	R_m/E	Z	K	n	σ_f
NeČ	σ_f'	-0,199	0,413	0,574	-0,007	0,597	-0,215	0,567	-0,047	0,457
		0,259	0,015	0,000	0,970	0,000	0,223	0,000	0,792	0,007
	b	0,263	0,412	0,229	-0,538	0,191	-0,025	-0,062	-0,348	0,171
		0,132	0,016	0,193	0,001	0,278	0,887	0,729	0,044	0,333
ε_f'	0,146	0,059	0,030	-0,131	0,020	-0,224	-0,113	-0,142	-0,130	
	0,408	0,738	0,864	0,460	0,909	0,203	0,524	0,424	0,463	
c	-0,091	-0,190	-0,167	0,199	-0,162	0,200	0,029	0,212	-0,040	
	0,609	0,282	0,346	0,260	0,359	0,257	0,869	0,228	0,821	
NČ	σ_f'	-0,029	0,693	0,811	-0,086	0,792	-0,528	0,828	-0,086	0,513
		0,845	0,000	0,000	0,567	0,000	0,000	0,000	0,564	0,000
	b	-0,050	0,016	-0,158	-0,467	-0,146	0,268	-0,312	-0,381	0,039
		0,737	0,914	0,290	0,001	0,326	0,068	0,033	0,008	0,797
ε_f'	0,009	-0,087	-0,144	-0,170	-0,140	0,373	-0,161	-0,071	0,035	
	0,955	0,563	0,334	0,255	0,347	0,010	0,279	0,637	0,815	
c	-0,113	-0,094	-0,057	0,281	-0,043	-0,378	-0,028	0,219	-0,201	
	0,448	0,531	0,704	0,056	0,772	0,009	0,849	0,138	0,175	
VČ	σ_f'	-0,122	-0,332	-0,212	0,476	-0,163	0,102	N/A	N/A	N/A
		0,487	0,052	0,222	0,004	0,350	0,560	N/A	N/A	N/A
	b	-0,064	0,773	0,744	-0,687	0,713	-0,485	N/A	N/A	N/A
		0,716	0,000	0,000	0,000	0,000	0,003	N/A	N/A	N/A
ε_f'	0,299	0,128	0,012	-0,161	-0,048	-0,088	N/A	N/A	N/A	
	0,081	0,464	0,947	0,356	0,783	0,617	N/A	N/A	N/A	
c	-0,049	-0,578	-0,389	0,594	-0,368	0,384	N/A	N/A	N/A	
	0,780	0,000	0,021	0,000	0,029	0,023	N/A	N/A	N/A	

Sadržaj ćelija: koeficijent korelacije r
 P -vrijednost

Redosljed ulaska monotonih značajki u model za predviđanje zamornih parametara prikazan je u tablici 4.8 za sve tri skupine čelika.

Kao što je bio slučaj i s unaprijednom selekcijom za cikličke parametre, unaprijedna selekcija za zamorne parametre rezultirala je velikim brojem podataka. Iz tog su razloga u narednim potpoglavljima komentirani samo najznačajniji rezultati, a detaljni rezultati dostupni su u Prilogu C.

Tablica 4.8 Redosljed ulaska monotonih parametara u modele regresijske analize za procjenu zamornih parametara nelegiranih, niskolegiranih i visokolegiranih čelika

Skupina čelika	Zamorni parametar	Redosljed ulaska monotonih varijabli u analizu								
		1.	2.	3.	4.	5.	6.	7.	8.	9.
NeČ	σ_f'	R_m/E	R_m	K	σ_f	R_e	Z	E	n	R_m/R_e
	b	R_m/R_e	R_e	n	E	R_m	R_m/E	σ_f	K	Z
	ε_f'	Z	E	n	R_m/R_e	σ_f	K	R_e	R_m	R_m/E
	c	n	Z	R_m/R_e	R_e	R_m	R_m/E	E	σ_f	K
NČ	σ_f'	K	R_m	R_m/E	R_e	Z	σ_f	R_m/R_e	n	E
	b	R_m/R_e	n	K	Z	R_m	R_m/E	E	σ_f	R_e
	ε_f'	Z	R_m/R_e	K	R_m	R_m/E	R_e	n	σ_f	E
	c	Z	R_m/R_e	n	σ_f	E	R_e	R_m	R_m/E	K
VČ	σ_f'	R_m/R_e	R_e	R_m	R_m/E	E	Z			
	b	R_e	R_m	R_m/E	R_m/R_e	Z	E			
	ε_f'	E	R_m/R_e	R_e	Z	R_m/E	R_m			
	c	R_m/R_e	R_e	R_m	Z	R_m/E	E			

4.4.2.2 Monotone značajke relevantne za procjenu koeficijenta dinamičke čvrstoće σ_f'

Za procjenu koeficijenta dinamičke čvrstoće σ_f' nelegiranih čelika, statistički značajnim prediktorima pokazale su se vlačna čvrstoća R_m , koeficijent deformacijskog očvršćivanja K , stvarno naprezanje pri lomu σ_f i granica tečenja R_e . Iako je u model ušla kao posljednja od njih, granica tečenja R_e doprinijela je smanjenju sume kvadrata pogreške s 41 % (linearni i kvadratni član zajedno). Osim navedenih varijabli, omjer vlačne čvrstoće i granice tečenja R_m/E pokazao se statistički značajnim (P -vrijednost $< \alpha = 0,10$), no uključivanje R_m/E značajno bi povećao VIF i smanjio R_{pred}^2 , pa prediktor nije uključen u model.

Monotone značajke relevantne za procjenu σ_f' niskolegiranih čelika su, kao i kod nelegiranih čelika, vlačna čvrstoća R_m i koeficijent deformacijskog očvršćivanja K (linearni i kvadratni član doprinijeli su smanjenju sume kvadrata pogreške za otprilike 34 %). Poprečni presjek pri lomu Z doprinio je daljnjem smanjenju sume kvadrata pogreške za oko 14 %. Omjer R_m/E nije uključen usprkos statističkoj značajnosti, radi velikog povećanja VIF faktora, kao i kod nelegiranih čelika.

Za procjenu σ_f' visokolegiranih čelika statistički značajnim prediktorima pokazala su se dva omjera – R_m/R_e i R_m/E .

4.4.2.3 Monotone značajke relevantne za procjenu eksponenta dinamičke čvrstoće b

Za procjenu eksponenta dinamičke čvrstoće b nelegiranih i niskolegiranih čelika prva statistički značajna varijabla, ujedno i ona s najvišim koeficijentom korelacije s b , je omjer vlačne čvrstoće i granice tečenja R_m/R_e . Dodatno, za procjenu eksponenta b nelegiranih čelika statistički značajnim varijablama pokazale su se stvarno naprezanje pri lomu σ_f ($R_{seq}^2 = 22\%$) i smanjenje poprečnog presjeka pri lomu Z ($R_{seq}^2 = 11\%$). Kod niskolegiranih čelika, pored omjera R_m/R_e statistički su značajne varijable koeficijent deformacijskog očvršćivanja K , smanjenje poprečnog presjeka pri lomu Z i omjer vlačne čvrstoće i modula elastičnosti R_m/E . One smanjuju sumu kvadrata pogreške, redom, za 20 %, 9 % i 8 %.

Statistički značajni prediktori za procjenu eksponenta b visokolegiranih čelika su vlačna čvrstoća R_m (linearni i kvadratni član), granica tečenja R_e i omjer R_m/E . Koeficijent determinacije budućih predviđanja R_{pred}^2 regresijskog modela koji uključuje ove varijable je približno 67 %, što je znatno više od utvrđenih modela za nelegirane i niskolegirane čelike (26 %, odnosno 34 %).

4.4.2.4 Monotone značajke relevantne za procjenu koeficijenta cikličkih deformacija ϵ_f'

Za koeficijent cikličkih deformacija ϵ_f' nelegiranih i niskolegiranih čelika nije bilo moguće provesti unaprijednu selekciju i utvrditi relevantne prediktore za njegovu procjenu. Naime kod nelegiranih čelika korelacije monotonih značajki i koeficijenta ϵ_f' nisu se pokazale statistički značajnima, dok je kod niskolegiranih čelika statistička značajnost utvrđena samo za koeficijent korelacije između koeficijenta ϵ_f' i smanjenja poprečnog presjeka pri lomu Z . Svi koeficijenti determinacije modela koji sadrži Z bili su, međutim, izuzetno niski ($< 15\%$), a uključivanje preostalih prediktora u model koji sadrži Z nije rezultiralo statistički značajnim doprinosom smanjenju vrlo velike sume kvadrata pogreške.

Kod visokolegiranih čelika statistički značajnim pokazao se model s omjerom R_m/E kao prediktorskom varijablom (polinom 2. reda). Zanimljivo je da najviši koeficijent korelacije s ϵ_f' kod visokolegiranih čelika ima modul elastičnosti E , no ova varijabla radi svoje slabe varijabilnosti nije uzeta u obzir.

4.4.2.5 Monotone značajke relevantne za procjenu eksponenta cikličkih deformacija c

Kao i za procjenu koeficijenta cikličkih deformacija ε_f' , unaprijedna selekcija nije se mogla provesti za eksponent cikličkih deformacija c nelegiranih čelika.

Za procjenu eksponenta c niskolegiranih čelika statistička značajnost utvrđena je za smanjenje poprečnog presjeka pri lomu Z , omjer R_m/R_e i eksponent deformacijskog očvršćivanja n , dok vlačna čvrstoća R_m usprkos značajnosti nije uključena u model. Uključivanje R_m u model koji sadrži prethodno navedene varijable rezultiralo bi smanjenjem ionako vrlo niskog koeficijenta determinacije budućih predviđanja R_{pred}^2 .

Za procjenu c visokolegiranih čelika utvrđena je značajnost dvaju prediktora, i to granice tečenja R_e i vlačne čvrstoće R_m . Koeficijent determinacije budućih predviđanja R_{pred}^2 ovog modela je 51 %.

4.4.2.6 Diskusija rezultata unaprijedne selekcije za zamorne parametre

Rezultati unaprijedne selekcije pokazali su da su i za procjenu zamornih parametara različitih skupina čelika relevantne različite monotone značajke.

Najviši koeficijent korelacije između koeficijenta dinamičke čvrstoće σ_f' i neke monotone značajke utvrđen je između σ_f' i vlačne čvrstoće R_m za nelegirane i niskolegirane čelike, što je u skladu s većinom postojećih metoda procjene σ_f' , u kojima je predložena procjena samo na osnovi R_m (u [14], [48], [57] i [76]) ili na osnovi vlačne čvrstoće R_m i drugih značajki (u [64] i [67]). S obzirom na visoku koreliranost tvrdoće HB i vlačne čvrstoće R_m [73] ovo vrijedi i za procjenu koeficijenta σ_f' na osnovi tvrdoće prema [73]. Dodatne monotone značajke koje postojeće metode koriste za procjenu σ_f' su modul elastičnosti E i stvarno naprezanje pri lomu σ_f , a posredno, u skladu s izrazima (8), (9) i (10) i smanjenje poprečnog presjeka Z . Stvarno naprezanje pri lomu σ_f pokazalo se značajnim za procjenu σ_f' samo nelegiranih čelika, a Z za procjenu σ_f' niskolegiranih čelika.

Unaprijednom selekcijom utvrđeno je da su za procjenu σ_f' nelegiranih i niskolegiranih čelika relevantni još i koeficijent deformacijskog očvršćivanja K te, za nelegirane čelike, granica tečenja R_e . U postojećim metodama nije, međutim, primijenjen niti jedan od ova dva parametra.

Monotone značajke relevantne za procjenu procjenu σ_f' visokolegiranih čelika su dva omjera: R_m/R_e i R_m/E . Ovo je djelomično u skladu s [14] i [64], gdje je za procjenu zamornih koeficijenata σ_f' i ϵ_f' korišten omjer vlačne čvrstoće i modula elastičnosti R_m/E .

Za procjenu koeficijenta cikličkih deformacija ϵ_f' nelegiranih i niskolegiranih čelika nije utvrđena niti jedna relevantna monotona značajka, što je u skladu s metodom medijana [57], kojom se ϵ_f' pripisuje srednja vrijednost svih ϵ_f' u uzorku na kojem je metoda razvijana. Unaprijednom selekcijom za visokolegirane čelike utvrđena je povezanost ϵ_f' s omjerom R_m/E , što je u skladu s [64] i [73], gdje su omjeri R_m/E ili HB/E jedina ili jedna od monotonih značajki na temelju kojih se procjenjuje ϵ_f' .

Većina postojećih metoda procjene eksponentima b i c pripisuje konstantne vrijednosti [14, 48, 57, 73]. U slučaju eksponenta dinamičke čvrstoće b to nije opravdano, s obzirom na to da su rezultati unaprijedne selekcije za sve skupine čelika pokazali da postoje varijable koje značajno doprinose procjeni eksponenta b . Ovo je posebno izraženo za procjenu eksponenta dinamičke čvrstoće b visokolegiranih čelika, gdje se na osnovi granice tečenja R_e , vlačne čvrstoće R_m i omjera R_m/E regresijskim modelom dobiva zadovoljavajući koeficijent determinacije za buduća predviđanja R_{pred}^2 od 67 %. U originalnoj [48] i modificiranoj [67] korelacijskoj metodi četiriju točaka za procjenu eksponenta b dodatno se koriste stvarno naprezanje pri lomu σ_f , koje se u ovom istraživanju pokazalo značajnim za procjenu b nelegiranih čelika, i modul elastičnosti E , čija relevantnost nije utvrđena.

Što se tiče procjene eksponenta cikličkih deformacija c , rezultati za nelegirane i niskolegirane čelike su u skladu s postojećim metodama procjene i pripisivanjem konstantnih vrijednosti tom parametru. Za nelegirane čelike nije utvrđena niti jedna monotona značajka relevantna za procjenu eksponenta c , dok je za niskolegirane čelike utvrđena relativno niska značajnost R_m/R_e , Z i n . Za visokolegirane čelike situacija je potpuno drugačija – utvrđena je relevantnost granice tečenja R_e i vlačne čvrstoće R_m , što je djelomično u skladu s originalnom korelacijskom metodom četiriju točaka [48], gdje je R_m samo jedna od monotonih značajki za procjenu eksponenta c .

4.5 Monotone značajke relevantne za modeliranje umjetnih neuronskih mreža za procjenu cikličkih i zamornih parametara čelika

Na osnovi rezultata unaprijedne selekcije predstavljenih u 4.4, u nastavku je dan sumaran pregled monotonih značajki relevantnih za procjenu cikličkih (tablica 4.9) odnosno zamornih parametara (tablica 4.10) pojedinih skupina čelika. Dane su i vrijednosti prilagođenog koeficijenta determinacije R_{adj}^2 i koeficijenta determinacije za buduća predviđanja R_{pred}^2 za modele koji sadrže relevantne monotone značajke.

Tablica 4.9 Pregled monotonih značajki relevantnih za procjenu cikličkih parametara nelegiranih, niskolegiranih i visokolegiranih čelika

Skupina čelika	Zavisna varijabla (ciklički parametar)	Nezavisne varijable (monotoni parametri)									R_{adj}^2	R_{pred}^2
		E	R_e	R_m	R_m/R_e	R_m/E	Z	K	n	σ_f		
NeČ	R_e'		+	+			+		+		88,32	81,94
	K'		+	+					+		46,89	36,01
	n'		+		+				+		55,14	45,88
NČ	R_e'			+	+			+			95,22	93,90
	K'			+			+				85,05	83,15
	n'				+				+		42,46	31,78
VČ	R_e'		+	+		+	+	N/A	N/A	N/A	90,08	83,12
	K'				+			N/A	N/A	N/A	43,57	37,48
	n'		+		+			N/A	N/A	N/A	78,75	76,88

Uz pretpostavku da umjetne neuronske mreže mogu finije mapirati složene funkcijske veze između monotonih i cikličkih odnosno zamornih parametara, relevantne monotone značajke iz tablica 4.9 i 4.10 primijenjene su za razvoj umjetnih neuronskih mreža za procjenu pojedinog cikličkog ili zamornog parametra svake skupine čelika.

U tri slučaja nije se moglo utvrditi doprinos neke od monotonih značajki za procjenu pojedinog parametra. Stoga su za razvoj umjetnih neuronskih mreža za procjenu:

- koeficijenta cikličkih deformacija ϵ_f' nelegiranih i niskolegiranih čelika i
- eksponenta cikličkih deformacija c nelegiranih čelika

korištene tri najčešće dostupne monotone značajke: vlačna čvrstoća R_m , granica tečenja R_e i smanjenje poprečnog presjeka pri lomu Z .

Tablica 4.10 Pregled monotonih značajki relevantnih za procjenu zamornih parametara nelegiranih, niskolegiranih i visokolegiranih čelika

Skupina čelika	Zavisna varijabla (ciklički parametar)	Nezavisne varijable (monotoni parametri)									R_{adj}^2	R_{pred}^2
		E	R_e	R_m	R_m/R_e	R_m/E	Z	K	n	σ_f		
NeČ	σ_f'		+	+				+		+	70,51	55,82
	b				+		+			+	51,73	25,92
	ε_f'	analiza se ne može provesti										
	c	analiza se ne može provesti										
NČ	σ_f'			+			+	+			77,57	64,13
	b				+	+	+	+			40,24	33,61
	ε_f'	analiza se ne može provesti										
	c				+		+		+		31,8	13,14
VČ	σ_f'				+	+		N/A	N/A	N/A	33,66	25,42
	b		+	+		+		N/A	N/A	N/A	70,65	66,62
	ε_f'					+		N/A	N/A	N/A	31,41	17,79
	c		+	+				N/A	N/A	N/A	55,39	50,94

5 Razvoj umjetnih neuronskih mreža za procjenu cikličkih i zamornih parametara materijala

5.1 Općenito o umjetnim neuronskim mrežama

5.1.1 Uvod

Empirijske metode procjene cikličkih i zamornih parametara materijala najčešće koriste metode linearne ili nelinearne, jednostavne ili višestruke regresijske analize, čiji se razvoj otežava i usporava s porastom broja prediktorskih varijabli, ali i broja podataka na kojima se provodi analiza. Iako su regresijski modeli dovoljno točna aproksimacija većine regresijskih problema, njihova sposobnost detektiranja složenijih odnosa prediktorskih varijabli i zavisne varijable je ograničena [38].

Nasuprot regresijskim modelima, *umjetne neuronske mreže* (engl. *artificial neural networks*, *ANN*) su *fleksibilni nelinearni statistički modeli* (u užem smislu poopćenje višestruke regresije) koji se primjenjuju u raznim područjima ljudskog djelovanja za rješavanje različitih tipova problema – predviđanja vremenske prognoze, prepoznavanja uzoraka u medicinskim nalazima, obrade signala, procjene rizika itd. Jedna od njihovih mnogobrojnih primjena je i *aproksimacija funkcije* (engl. *function approximation*), tj. identifikacija nepoznate veze između ulaznih podataka (prediktorskih varijabli) i izlaznih podataka (jedne ili više zavisnih varijabli).

Umjetne neuronske mreže, koje "učenjem" iz dostupnih podataka mogu uspješno modelirati široki raspon oblika hiperploha u k -dimenzijskom prostoru, omogućavaju lakšu manipulaciju većim brojem prediktorskih varijabli i većim brojem podataka, što ukazuje na mogućnost da bi se njihovom primjenom moglo poboljšati točnost i pouzdanost procjene cikličkih i zamornih parametara na osnovi monotonih značajki materijala.

5.1.2 Temeljni pojmovi i odabir umjetne neuronske mreže za predmetnu zadaću

5.1.2.1 Kratak povijesni pregled

Ljudski mozak je iznimno složeno "računalo" koje karakteriziraju [19, 28, 30]

- *paralelno, distribuirano procesiranje velike količine informacija,*
- *sposobnost učenja iz iskustva i prilagodljivost¹⁸,*
- *sposobnost generaliziranja,*
- *tolerancija pogrešaka (funkcioniranje sustava i kad je dio sustava onesposobljen) i*
- *mala potrošnja energije.*

Sve navedeno poslužilo je kao inspiracija za stvaranje inteligentnih, fleksibilnih računalnih sustava koji nalikuju biološkim neuronskim mrežama – umjetnih neuronskih mreža.

Za stvaranje umjetnih neuronskih mreža kakve poznajemo danas bila su potrebna znanja iz najrazličitijih znanstvenih polja: matematike, neurobiologije, psihologije, računalstva i drugih.

McCulloch i Pitts 1943. godine postavljaju temelje za razvoj umjetnih neuronskih mreža publiciranjem pojednostavljenog modela neurona i principa njegovog djelovanja. McCulloch–Pittsov neuron može imati dva stanja, pobuđeno i nepobuđeno [1, 19, 30]. Hebb 1949. predlaže prvo pravilo "učenja", tzv. *Hebbovo pravilo*, prema kojem se veze među neuronima (*sinapse*) jačaju svaki put kad se dva neurona povezana tom sinapsom sinkronizirano koriste¹⁹ [2, 30, 74]. Rochester i suradnici su 1956. predstavili su prvu simulaciju umjetnih neuronskih mreža, a prva praktična primjena započela je 1958. Rosenblattovom mrežom nazvanom *perceptron*. Jednoslojni perceptron mogao je klasificirati podatke u dva razreda, ali samo one koji su linearno djeljivi [19, 30]. Ograničena uspješnost prvih neuronskih mreža i nedostatak dovoljno snažnih računala potrebnih za istraživanje uzrokovali su stagnaciju razvoja umjetnih neuronskih mreža od gotovo 20 godina, sve do 80-ih godina 20. stoljeća [27]. Napredak u razvoju potakli su novi koncepti, od kojih su dva značajno utjecala na velik porast interesa za neuronske mreže, koji traje do danas. Hopfield 1982. predlaže *energetski pristup*, prema kojem individualni neuroni poprimaju ono stanje koje rezultira manjom ukupnom energijom mreže,


¹⁸ Razvoj neurološkog sustava karakterizira tzv. *plastičnost*, koja dozvoljava kontinuirano učenje iz dostupnih podataka, prilagođavanje okolini, a potom i primjenu naučenih znanja na nove slučajeve [28].

¹⁹ Primjer: Pavlovljev uvjetovani refleks.

analogno fizikalnim sustavima [2]. Drugi ključan trenutak u razvoju neuronskih mreža bio je usavršavanje koncepta *višeslojnog unaprijednog perceptrona* (engl. *multilayer perceptron, multilayer feedforward network*) sa *širenjem unatrag* (engl. *back-propagation learning algorithm*), koji je predložio Werbos 1974., a popularizirali su ga Rumelhart i McClelland 1986. [27]. S vremenom su razvijeni brojni algoritmi za učenje neuronskih mreža, no višeslojna unaprijedna mreža sa širenjem unatrag, kao univerzalni aproksimator nepoznate funkcije $f(x)$ [28], ostala je do danas najprimjenjivija mreža [2, 19, 27].

5.1.2.2 Biološki neuron

Moždana kora²⁰ čovjeka izgrađena je od 10^{11} stanica visoke razine povezanosti, koje zovemo *neuroni* (engl. *neurons*). Jedan neuron može biti povezan i s $2 \cdot 10^5$ drugih neurona, iako je tipičan broj veza od 10^3 do 10^4 [27, 30]. Ono što ih razlikuje od ostalih stanica ljudskog tijela jest sposobnost procesiranja informacija putem složenih elektrokemijskih procesa. Biološki neuron čine *tijelo stanice (soma)*, *akson*, *dendriti* i *sinapse* (slika 5.1).



Slika 5.1 Prikaz biološkog neurona, prema [30]

U osnovi, biološki neuron preko dendrita prima impulse (signale) iz drugih neurona, koji se potom obrađuju u tijelu stanice i pretvaraju u izlazni signal. Izlazni signal se preko aksona prenosi na druge neurone. Mjesto na kojem se dodiruju akson jednog neurona i dendriti drugog zove se *sinapsa*. Po dolasku signala do sinapse u sinaptičku pukotinu oslobađaju se *neurotransmiteri* i ovisno o vrsti sinapse pobuđuju ili inhibiraju sposobnost neurona koji prima signal da pošalje električni signal. Sinapsa *uči* iz aktivnosti u kojoj sudjeluje [30].

²⁰ Vanjski sloj mozga, često nazivan *sivom tvari*.


5.1.2.3 Umjetni neuron

Umjetne neuronske mreže nisu ni približno složene kao ljudski mozak²¹, no dijele dvije ključne značajke [27]:

- izgrađene su od jednostavnih, visokopovezanih računalnih jedinica,
- veze između neurona određuju funkciju mreže.

Umjetni neuroni, kao osnovne gradbene jedinice umjetnih neuronskih mreža, oponašaju dijelove i procese biološkog neurona.

Nelinearni model umjetnog neurona prikazan je na slici 5.2.



Slika 5.2 Nelinearni model neurona k , prema [28]

Razlikujemo tri osnovna dijela umjetnog neurona [28]:

1. skup sinapsi, odnosno poveznica, koje su karakterizirane težinama w_{kj} ²², gdje se ulazni signal (ulaz) neurona x_j množi s težinom w_{kj} . Sinaptičke težine umjetnog neurona mogu imati pozitivne vrijednosti (analogno pobuđujućim sinapsama) i negativne vrijednosti (analogno inhibirajućim sinapsama)
2. sumator vaganih ulaznih signala $x_j \cdot w_{kj}$ i

²¹ Valja napomenuti da je biološki neuron vrlo spor u usporedbi s elektroničkim krugovima (10^{-3} s naspram 10^{-10} s), no upravo zbog simultanog rada mnoštva neurona ljudski mozak mnoge probleme rješava brže od konvencionalnih računala [27, 30].

²² Prvi indeks k označava neuron, a drugi indeks j označava ulazni signal koji sinapsa veže s neuronom k .

3. *aktivacijsku funkciju* (engl. *activation function, transfer function, squashing function*) koja formira izlaz iz neurona unutar željenih granica.

Prikazani model neurona uključuje dodatnu težinu, pristrani član b_k (engl. *bias, offset*) koji smanjuje ili povećava ulaz iz mreže u aktivacijsku funkciju²³.

Linearna kombinacija vaganih ulaznih signala, tj. suma umnožaka ulaznih signala s težinama je

$$u_k = \sum_{j=1}^m w_{kj} x_j, \quad (45)$$

gdje su x_1, x_2, \dots, x_m ulazi u neuron, a $w_{k1}, w_{k2}, \dots, w_{km}$ odgovarajuće sinaptičke težine. Kad se tome pridoda pristrani član b_k ²⁴

$$v_k = \sum_{j=1}^m w_{kj} x_j + b_k \quad (46)$$

i propusti kroz aktivacijsku funkciju neurona $\varphi(\cdot)$, dobijemo izlazni signal (odziv) iz neurona:

$$y_k = \varphi(v_k). \quad (47)$$

Vrste aktivacijskih funkcija

Odabir aktivacijske funkcije ovisi o vrsti problema koji se rješava neuronskom mrežom [27], a neke od njih navedene su u tablici 5.1.







Aktivacijska funkcija može biti diskontinuirana *funkcija skoka* (engl. *threshold function*) ili neka kontinuirana funkcija, najčešće *sigmoidna funkcija* (engl. *sigmoid function*) [19].

Funkcijom skoka uspoređuje se izlaz iz sumatora s nekom vrijednosti koja predstavlja *prag* – ukoliko je izlaz veći od praga neuron generira signal, ukoliko je manji od njega neuron ne generira signal [2].

²³ Bias b_k kod neuronskih mreža ima sličnu karakteristiku kao *odsječak* kod linearne regresije.

²⁴ U daljnjem tekstu pojmovi "težine" ili "slobodni parametri mreže" podrazumijevati će i težine w_{kj} i pristrani član b_k .

Tablica 5.1 Neke vrste aktivacijskih funkcija umjetnog neurona, prema [27] i [28]

Aktivacijska funkcija	Veza ulaza i izlaza	Oblik aktivacijske funkcije
Funkcija skoka	$y_k = \begin{cases} 0 & v_k < 0 \\ 1 & v_k \geq 0 \end{cases}$	
Simetrična funkcija skoka	$y_k = \begin{cases} -1 & v_k < 0 \\ +1 & v_k \geq 0 \end{cases}$	
Logistička sigmoidna funkcija	$y_k = \frac{1}{1 + e^{-v_k}}$	
Tangens hiperbolni	$y_k = \frac{e^{v_k} - e^{-v_k}}{e^{v_k} + e^{-v_k}}$	
Linearna funkcija	$y_k = v_k$	
Normalna distribucija	$y_k = e^{-v_k^2}$	


Sigmoidna funkcija je jedna od najčešće korištenih aktivacijskih funkcija [28], posebno kod višeslojnih neuronskih mreža sa širenjem unatrag, zbog svojstva *derivabilnosti* [27]. Sigmoidna funkcija je monotono rastuća funkcija, oblika slova "S". Logistička sigmoidna funkcija može poprimiti bilo koju vrijednost izlaza od 0 do 1, no u praktičnoj primjeni češći je tangens hiperbolni – neparna, monotono rastuća funkcija, s rasponom vrijednosti od -1 do +1.

5.1.2.4 Mrežna arhitektura

Jedna od prednosti neurološkog sustava je *paralelnost* procesiranja informacija i *visok stupanj povezanosti* između neurona pa je i za rješavanje problema pomoću umjetnih neuronskih mreža potrebno koristiti više od jednog neurona koji istovremeno "uče" – takva skupina neurona zove se *sloj* (engl. *layer*). Neuronska mreža može biti *jednoslojna* (engl. *single-layer network*) ili *višeslojna* (engl. *multilayer network*). Jednoslojna mreža je ona koja pored ulaznog sloja (engl. *input layer*) ima samo još jedan sloj neurona, i to onaj *izlazni* (engl. *output layer*). Veličina ulaznog sloja ovisi o broju ulaznih vektora (odnosno broj ulaznih varijabli, broj ulaza), a veličina izlaznog sloja o broju izlaznih vektora. Višeslojna mreža između ulaznog i izlaznog sloja može imati jedan ili više slojeva neurona koji se zovu *skriveni slojevi* (engl. *hidden layers*)²⁵. Uloga skrivenih slojeva je učenje složenijih međuzavisnosti između ulaznog i

²⁵ Način na koji se broje slojevi u mreži varira od autora do autora – ovdje je usvojen princip prema kojem se ulazni sloj ne broji kao zaseban sloj.

izlaznog sloja. Višeslojne mreže su moćnije od jednoslojnih, a u praktičnoj upotrebi najčešće su one s jednim ili dva skrivena sloja [27]²⁶. Na slici 5.3 prikazane su osnovne vrste mrežne arhitekture i tipične mreže za svaku od njih.



Slika 5.3 Vrste mrežne arhitekture, prema [30]

U odnosu na način na koji su slojevi mreže povezani razlikujemo dvije fundamentalno različite vrste umjetnih neuronskih mreža [28, 30]:

- *unaprijedne mreže* (engl. *feedforward networks*), kod kojih tok signala ide isključivo prema naprijed. Tako primjerice kod dvoslojne mreže signali putuju od ulaznog sloja prema prvom skrivenom sloju, a iz prvog skrivenog sloja prema izlaznom sloju;
- *mreže s povratnom vezom* (engl. *recurrent networks*), gdje postoji barem jedna petlja putem koje signal putuje unatrag.

Ove dvije vrste povezanosti diktiraju i ponašanje mreže. Općenito, unaprijedne mreže su *stacionarne* (*statičke, acikličke*), jer proizvode jedan skup izlaznih vrijednosti neovisno o prethodnom stanju mreže, a povratne mreže *dinamičke* (*cikličke*), s obzirom na to da se njihovo stanje mijenja unosom novih ulaznih vrijednosti u mrežu. Kako je procjena cikličkih i zamornih

²⁶ Neuronske mreže s više skrivenih slojeva koriste se rijetko, za vrlo složene probleme. Zahtijevaju ogromne količine podataka i mnogo vremena za uspješno treniranje. Nazivaju se i *dubokim neuronskim mrežama* (engl. *deep neural networks*).

parametara na osnovi monotonih značajki materijala u osnovi stacionaran problem, mreže s povratnom vezom neće se razmatrati.

Višeslojne unaprijedne mreže

Dvije su vrste višeslojnih unaprijednih mreža, i to *višeslojni perceptron* (engl. *multilayer perceptron*) i *mreža s radijalno zasnovanom funkcijom* (engl. *radial basis function network*). Za obje vrijedi sljedeće [27]: Dvoslojna mreža gdje neuroni u skrivenom sloju koriste sigmoidnu aktivacijsku funkciju, a u izlaznom sloju linearnu funkciju, može aproksimirati većinu funkcija proizvoljno točno.

Budući da su mreže s radijalno zasnovanom funkcijom mnogo osjetljivije na podatke koji u sebi sadrže pogrešku (šum) [28], za rješavanje problema procjene cikličkih i zamornih parametara pomoću umjetnih neuronskih mreža odabran je *višeslojni perceptron*.

5.1.2.5 Učenje

Glavno odličje inteligentnih sustava, bili oni biološki ili umjetni, je sposobnost *učenja*. Kod umjetnih neuronskih mreža učenje možemo promatrati kao *prilagođavanje mrežne arhitekture i težina unutar mreže s ciljem uspješnog rješavanja zadanog problema* [30].

Postoje tri paradigme učenja umjetnih neuronskih mreža, i to

- *učenje s učiteljem* (engl. *learning with a teacher*) ili *nadgledano učenje* (engl. *supervised learning*),
- *učenje bez učitelja* (engl. *learning without a teacher*) i
- *učenje s podrškom* (engl. *reinforcement learning*), koje je prema Haykinu [28] podvarijanta učenja bez učitelja.

Kod nadgledanog učenja mreži su, osim ulaznih vrijednosti (engl. *inputs*), predstavljene i *željene izlazne (ciljne) vrijednosti* (engl. *targets*), za razliku od učenja bez učitelja, gdje ciljana vrijednost nije predstavljena mreži. Nadgledanim učenjem prilagođavaju se težine u mreži kako bi izlazne vrijednosti mreže (engl. *outputs*) bile čim bliže ciljanim vrijednostima. Nadgledano učenje primijenjeno je i u procjeni cikličkih i zamornih parametara na osnovi monotonih značajki čelika, s obzirom na to da su željene izlazne vrijednosti mreže, tj. eksperimentalne vrijednosti cikličkih i zamornih parametara, poznate.

O mrežnoj arhitekturi i paradigmi učenja ovisi *pravilo učenja mreže* (engl. *learning rule*), a shodno tome i *algoritam učenja* (engl. *learning algorithm*), tj. procedura prema kojoj se pravilo učenja primjenjuje za prilagođavanje težina u mreži. Jedan od najpopularnijih algoritama za nadgledano učenje višeslojnog perceptrona, koji je primijenjen i u ovom istraživanju, je tzv. *širenje unatrag* (engl. *backpropagation*), temeljeno na *učenju korekcijom pogreške* (engl. *error-correction learning*). Stoga je u ovom istraživanju za problem procjene cikličkih i zamornih parametara čelika na osnovi monotonih značajki odabran višeslojni perceptron sa širenjem unatrag, čiji opis slijedi u poglavlju 5.2.


5.2 Višeslojni perceptron sa širenjem unatrag

5.2.1 Osnovne karakteristike višeslojnog perceptrona

Osnovne karakteristike višeslojnog perceptrona su sljedeće:

- svaki neuron u mreži ima nelinearnu aktivacijsku funkciju koja je *derivabilna*,
- mreža ima jedan ili više skrivenih slojeva i
- neuroni su međusobno visokopovezani.


Na slici 5.4 dan je prikaz *potpuno povezanog*²⁷ višeslojnog perceptrona s dva skrivena sloja.



Slika 5.4 Potpuno povezani višeslojni perceptron s dva skrivena sloja, prema [28]

²⁷ Mreža je potpuno povezana (engl. *fully connected*) kad je svaki element (ulaz ili neuron) u sloju u potpunosti povezan s neuronima u narednom sloju.

Na slici 5.5 prikazan je tok ulaznih signala i signala pogreške u višeslojnom perceptronu.



Slika 5.5 Tok ulaznih signala i signala pogreške u višeslojnom perceptronu, prema [28]

Algoritam učenja višeslojnog perceptrona sa *širenjem unatrag* unatrag sastoji se od dvije faze [28]:

1. *unaprijedna faza* (engl. *forward phase*), u kojoj se težine u mreži ne mijenjaju, a *ulazni signali* (engl. *input signals, function signals*) iz neurona šire se mrežom unaprijed, sloj po sloj, do izlaznog sloja; i
2. *povratna faza* (engl. *backward phase*), u kojoj se *signali pogreške* (engl. *error signals*), dobiveni usporedbom željenog i stvarnog izlaza, *šire unatrag*, sloj po sloj, od izlaznog sloja prema ulazu. U ovoj fazi podešavaju se težine u mreži.

5.2.2 Učenje korekcijom pogreške

Algoritam učenja sa širenjem unatrag temelji se na pravilu učenja s korekcijom pogreške. Neka je $d_j(n)$ željena izlazna vrijednost neurona j u izlaznom sloju u trenutku n (j -ti element vektora željenih izlaznih vrijednosti $\mathbf{d}(n)$), a $y_j(n)$ stvarna izlazna vrijednost tog neurona u trenutku n kao posljedica vektora $\mathbf{x}(n)$ u ulaznom sloju mreže. *Pogreška* (engl. *error signal*) je definirana kao razlika između željenog i dobivenog izlaza, tj. [28]

$$e_j(n) = d_j(n) - y_j(n). \quad (48)$$

Pod utjecajem ulaznih vektora i signala pogreške, slobodni parametri mreže (težine između neurona) prilagođavaju se s ciljem minimiziranja *funkcije pogreške* (engl. *error function, performance function, cost function*).

Trenutna vrijednost funkcije pogreške neurona j u koraku n je:

$$E_j(n) = e_j^2(n), \quad (49)$$

a suma trenutnih vrijednosti funkcije pogreške svih C neurona u izlaznom sloju je ukupna trenutna vrijednost funkcije pogreške

$$E(n) = \sum_{j \in C} E_j(n) = \sum_{j \in C} e_j^2(n). \quad (50)$$

Kako se treniranje mreže odvija na $n = 1, 2, \dots, N$ uređenih parova vrijednosti ulaznog vektora $\mathbf{x}(n)$ i vektora željenih izlaznih vrijednosti $\mathbf{d}(n)$, tako je funkcija pogreške na cijelom uzorku za treniranje zapravo *srednje kvadratno odstupanje* (engl. *mean squared error*) za sve neurone u izlaznom sloju i cijeli uzorak treniranja²⁸

$$E_{\text{red}}(N) = \frac{1}{N} \sum_{n=1}^N E(n) = \frac{1}{N} \sum_{n=1}^N \sum_{j \in C} e_j^2(n). \quad (51)$$

Funkcija pogreške je funkcija slobodnih parametara mreže (težina i pristranih članova), koja u višedimenzijском prostoru tvori *hiperplohu pogreške* (engl. *error-performance surface*). Cilj učenja je postepeno prilagođavati vrijednosti sinaptičkih veza sve do dostizanja *globalnog minimuma* ili (nepoželjno) *lokalnog minimuma*.

Ukoliko se težine podešavaju nakon što se mreži predstave svi primjeri u uzorku za treniranje, tj. nakon jedne *epohe* (engl. *epoch*) govorimo o *skupnom učenju* (engl. *batch learning*). Prema [28] skupno učenje nalikuje *statističkoj inferenciji* (engl. *statistical inference*) pa je pogodno za primjenu kod *nelinearnih regresijskih problema*. Osim toga, skupno učenje je i brže te često rezultira manjom vrijednosti funkcije pogreške od *inkrementalnog učenja* (engl. *on-line learning, incremental learning*) [55]. Kod inkrementalnog učenja težine u mreži podešavaju se nakon svake *iteracije*, tj. nakon što se mreži predstavi jedan primjer ili jedan podskup primjera uzorka za učenje²⁹.

²⁸ Umjesto srednjeg kvadratnog odstupanja koristi se i *suma kvadrata pogreške* (engl. *sum of squared errors*).

²⁹ Inkrementalno učenje popularno je kod neuronskih mreža za rješavanje klasifikacijskih problema [28].

5.2.3 Širenje unatrag

Širenje unatrag u užem smislu – algoritam temeljen na gradijentnom spustu

Širenje unatrag (engl. *backpropagation*) u užem smislu podrazumijeva algoritam učenja temeljen na *gradijentnom spustu* (engl. *gradient descent algorithm, steepest descent algorithm*). Učenje (prilagođavanje vrijednosti težina) je iterativan proces koji počinje u nasumičnoj točki na hiperplohi pogreške i kreće u negativnom smjeru *gradijenta* (engl. *gradient*) tj. u smjeru *najvećeg spusta* (engl. *steepest descent*) na hiperplohi pogreške [28]. Težine se prilagođavaju prema tzv. *delta pravilu* (engl. *delta rule*):

$$\mathbf{w}(n+1) = \mathbf{w}(n) + \Delta\mathbf{w}(n), \quad (52)$$

gdje je $\mathbf{w}(n+1)$ vektor težina u narednom koraku, $\mathbf{w}(n)$ trenutni vektor težina, a $\Delta\mathbf{w}(n)$ vektor promjena vektora težina $\mathbf{w}(n)$:

$$\Delta\mathbf{w}(n) = -\eta\mathbf{g}(n) = -\eta \frac{\partial E(\mathbf{w})}{\partial \mathbf{w}(n)}. \quad (53)$$

Promjena težina proporcionalna je *stopi učenja* η (engl. *learning rate*) i *trenutnom gradijentu funkcije pogreške* $\mathbf{g}(n)$ ³⁰.

Širenje unatrag u širem smislu

Algoritam temeljen na gradijentnom spustu karakterizira spora konvergencija pa su razvijeni brojni brži algoritmi za učenje višeslojnog perceptrona, koji se prema [27] mogu podijeliti u dvije kategorije:

- algoritmi bazirani na *heurističkim principima* (npr. algoritam s momentumom, algoritam s varijabilnom brzinom učenja i drugi) i
- algoritmi bazirani na *numeričkoj optimizaciji* (Levenberg–Marquadtov algoritam, metoda konjugiranog gradijenta, Bayesova regularizacija i drugi).

Obje skupine koriste metodu širenja unatrag u kojoj se parcijalne derivacije funkcije pogreške obrađuju od posljednjeg sloja prema prvom, i zato u širem smislu spadaju pod *algoritme sa širenjem unatrag*. Pojedini algoritmi se međusobno razlikuju prema načinu na koji se derivacije

³⁰ Algoritam temeljen na gradijentnom spustu podrazumijeva inkrementalno učenje.

koriste da bi se podesile težine u mreži [27]. Detalji najčešće primjenjivanih algoritama iz obje skupine sa širenjem unatrag dostupni su u [27], [28], [45], [46], [55] i [56], a u ovom će radu naglasak biti na praktičnoj primjeni odabranih algoritama.

5.2.4 Generalizacija

5.2.4.1 Dimenzioniranje mreže i generalizacija

Osnovni cilj razvoja umjetne neuronske mreže je da "znanje" naučeno iz *uzorka za učenje* (engl. *training data*) mreže uspješno primijeni na novi, neovisni *uzorak za testiranje* (engl. *testing data*). Svojstvo da mreža uspješno primjenjuje stečeno "znanje" na novim podacima zove se *generalizacija* (engl. *generalization*). Ključni korak prema generalizaciji je ispravno dimenzioniranje mreže – odabir broja *hiperparametara* (težina) odnosno *broja neurona u skrivenom sloju*. Dvije su negativne krajnosti u dimenzioniranju mreže:

- mreža je *poddimenzionirana* – broj neurona u skrivenom sloju je premali da bi mreža mogla ispravno naučiti vezu između ulaznih i izlaznih podataka i
- mreža je *predimenzionirana* – broj neurona u skrivenom sloju uzrokuje tzv. *pretreniranost* (*prenaučenost*) mreže (engl. *overfitting*, *overtraining*).

Dimenzioniranje mreže treba provoditi prema principu *Ockhamove britve*, tj. odabira najjednostavnijeg modela (tj. mreže s najmanjim brojem neurona u skrivenom sloju) koji daje dovoljno malu pogrešku.

Za višeslojni perceptron *I-H-O*, gdje je *I* broj ulaznih vektora, *H* broj neurona u skrivenom sloju, a *O* broj izlaznih vektora (neurona u izlaznom sloju), broj sinaptičkih veza u mreži je

$$N_w = (I + 1) \cdot H + (H + 1) \cdot O = O + H \cdot (I + O + 1), \quad (54)$$

a broj jednadžbi za treniranje

$$N_{\text{jedn}} = N_{\text{tren}} \cdot O, \quad (55)$$

gdje je N_{tren} broj primjera za treniranje. Broj jednadžbi za treniranje mreže trebao bi biti značajno veći od broja sinaptičkih veza u mreži N_w , od nekoliko puta do nekoliko desetaka puta


$$N_{\text{jedn}} \gg N_w. \quad (56)$$

Uvrste li se izrazi (54) i (55) u izraz (56), proizlazi da bi broj neurona u skrivenom sloju H trebao biti

$$H \leq \frac{O \cdot (N_{\text{tren}} - 1)}{I + O + 1}. \quad (57)$$

Ukoliko je taj broj veći od onog dobivenog izrazom (57), nužno je koristiti neku od metoda poboljšanja generalizacije, jer može doći do prenaučenosti mreže.

Na slici 5.6 a) ilustriran je primjer prenaučenog modela, koji loše *interpolira* i *ekstrapolira*, tj. loše aproksimira funkciju u rasponu vrijednosti uzorka za treniranje, ali i izvan njega. Slika 5.6 b) prikazuje model koji dobro interpolira, ali loše ekstrapolira. Pritom je loša *ekstrapolacija mreže* uvijek očekivana, s obzirom na to da mreža ne može naučiti funkcijsku vezu podataka u području izvan uzorka za treniranje [27].



- Stvarna funkcijska zavisnost
- Nelinearno mapiranje kroz podatke za učenje
- Željene izlazne vrijednosti
- Izlazne vrijednosti mreže

Slika 5.6 a) Prenaučen model, b) model koji dobro generalizira, prema [27]

Kako bi uzorak za testiranje dao adekvatnu i objektivnu procjenu generalizacije modela neuronske mreže, prema [27] i [28] važno je da

- uzorak za testiranje bude *neovisan* i *ne sudjeluje u učenju mreže*,
- uzorci za učenje i testiranje mreže pripadaju istoj distribuciji i da
- uzorak za testiranje pokriva raspon vrijednosti na kojima će se mreža koristiti.

5.2.4.2 Metode poboljšanja generalizacije

Postoji više metoda za stvaranje jednostavnih mreža koje dobro generaliziraju [27]:


- *metoda rasta* (engl. *growing method*) – broj neurona u skrivenom sloju povećava se sve do postizanja željene pogreške,
- *metoda odbacivanja* (engl. *pruning method*) – broj neurona u skrivenom sloju se smanjuje dok se pogreška ne smanji na željenu vrijednost,
- *metoda globalnog pretraživanja* (engl. *global searches*) – pretraživanje prostora svih mogućih rješenja (odnosno mrežnih arhitektura) pomoću genetskog algoritma,
- *metoda ranog zaustavljanja* (engl. *early stopping*) i
- *regularizacija* (engl. *regularization*).

Metoda ranog zaustavljanja i regularizacija funkcioniraju na principu ograničavanja *veličine*, a ne *broja* težina u mreži [27] te su kroz odgovarajuće algoritme, u kombinaciji s metodom rasta, primijenjene u ovom istraživanju.

Unakrsna validacija i metoda ranog zaustavljanja

Učenjem višeslojnog perceptrona pogreška mreže uobičajeno se smanjuje s povećanjem broja epoha učenja, no ako se to učenje nastavi do nekog zadanog broja epoha ili dostizanja željene pogreške, moguće je dobiti pretreniranu mrežu, koja loše generalizira. *Metoda ranog zaustavljanja*, temeljena na *unakrsnoj validaciji* (engl. *cross-validation*), korisna je za određivanje trenutka u kojem se učenje mreže treba zaustaviti. Na slici 5.7 ilustrirana je metoda ranog zaustavljanja.


Za primjenu unakrsne validacije, uzorak za učenje se dijeli u *uzorak za treniranje* i *uzorak za validaciju* (engl. *validation data*). Prilagođavanje težina vrši se "učenjem" iz podataka za treniranje, a istovremeno se pogreška mreže računa na uzorku za validaciju. Kad pogreška na uzorku za validaciju (crvena krivulja na slici 5.7) dostigne minimum, da bi zatim rasla u nekom najčešće predefiniranom broju uzastopnih epoha, učenje se zaustavlja. To zovemo *ranim zaustavljanjem*, jer mreža nije dostigla cilj učenja (željenu pogrešku). Daljnjim učenjem mreža bi postizala manju pogrešku, na temelju učenja šumova iz podataka za treniranje koji nisu dio funkcijske veze ulaza i izlaza. Validacijska krivulja u realnim situacijama, međutim, nije glatka krivulja s jednim minimumom, već krivulja s više lokalnih i jednim globalnim minimumom.



Slika 5.7 Metoda ranog zaustavljanja, prema [28]

Ukoliko se dio podataka izdvoji iz uzorka za učenje u uzorak validaciju i više ne mijenja, govorimo o *unakrsnoj validaciji s izuzimanjem* (engl. *holdout method*). Iako praktična, metoda je problematična za primjenu na malim uzorcima za učenje, jer se za samo treniranje mreže koristi mali broj podataka.

Podvarijanta unakrsne validacije pogodnija za korištenje na malim uzorcima, je *k-struka unakrsna validacija* (engl. *k-fold cross-validation*), gdje je k broj podskupova na koje se dijeli uzorak za učenje mreže. Pri učenju, model se trenira k puta, svaki put na $k - 1$ podskupova, dok k -ti služi kao validacijski podskup. U ovom slučaju svi podaci uzorka za učenje podjednako sudjeluju i u treniranju i u validaciji mreže. Na slici 5.8 prikazana je četverostruka unakrsna validacija.



Slika 5.8 k -struka unakrsna validacija, prema [28]

Uzorak je podijeljen u četiri jednaka dijela od kojih tri sudjeluju u treniranju, a četvrti u validaciji. Pritom validacijski uzorak pokriva svaki put neki drugi dio podataka u uzorku. Uspješnost modela je prosjek pogrešaka za svih k treniranja³¹.

Ekstreman slučaj k -struke unakrsne validacije je *pojedinačna unakrsna validacija* (engl. *leave-one-out cross-validation*), kod koje je broj podskupova jednak broju podataka u uzorku za učenje. Međutim, ova je metoda računalno izuzetno zahtjevna i ne rezultira uvijek jednostavnijom mrežom i boljom generalizacijom.

Regularizacija

Regularizacija je metoda kojom se funkcija pogreške modificira, odnosno *regularizira*, na način da se uvodi regularizacijski član koji penalizira velike težine u mreži:

$$R(\mathbf{w}) = \beta E_{\text{sred}}(\mathbf{w}) + \alpha E_{\mathbf{w}}(\mathbf{w}). \quad (58)$$

Prvi član izraza (58) je srednje kvadratno odstupanje iz izraza (51), a $E_{\mathbf{w}}(\mathbf{w})$ suma kvadrata svih težina u mreži. Omjer koeficijenata α i β je *regularizacijski koeficijent* λ , koji kontrolira složenost mreže. Veće težine u mreži uzrokuju strmiju aproksimacijsku funkciju i veću sklonost k pretreniranosti mreže. Ako se težine uz pomoć regularizacijskog koeficijenta ograniče, aproksimacijska funkcije postaje glađa, a interpolacija točnija.

Uspješna metoda za određivanje vrijednosti koeficijenata α i β odnosno λ , je tzv. *Bayesova regularizacija* koju je predložio MacKay 1992. [45, 45]. Ona se temelji na *Bayesovom teoremu*, odnosno *uvjetnoj vjerojatnosti*³². Detalji su dostupni u [27], [45], [46] i [47]. Prednosti Bayesove regularizacije je što ne zahtijeva izdvajanje zasebnog poduzorka za validaciju, pa je pogodna za učenje na manjim uzorcima.


³¹ Ukoliko neka od k mreža dobivenih k -strukom unakrsnom validacijom rezultira značajno većom pogreškom od ostalih, moguće ju je isključiti iz krajnjeg korištenja.

³² Bayesov teorem, $P(A|B)=P(B|A) \cdot P(A)/P(B)$, daje vjerojatnost događaja A ako je nastupio događaj B . $P(A|B)$ je vjerojatnost *a posteriori*.

5.3 Modeliranje umjetnih neuronskih mreža za procjenu cikličkih i zamornih parametara materijala na osnovi monotonih značajki

5.3.1 Uvod

Ranije je spomenuto da su regresijski modeli (posebice oni linearni), kao jedna od najčešćih metoda za procjenu cikličkih i zamornih parametara iz monotonih značajki materijala, ograničeni u otkrivanju složenijih odnosa između prediktorskih i zavisnih varijabli. Umjetne neuronske mreže su, za razliku od regresijskih modela, fleksibilni statistički modeli koji zbog svojstva "plastičnosti", tj. sposobnosti da uče iz dostupnih podataka, a potom i primijene naučeno znanje na nove slučajeve, mogu unaprijediti procjene spomenutih parametara u odnosu na konvencionalne metode procjene. U postojećoj literaturi [25, 26, 82, 84] pokazane su prednosti primjene neuronskih mreža nad klasičnim empirijskim metodama za opisanu problematiku. Pored nesumnjivih prednosti utvrđene su i neke manjkavosti, poput neselektivnog korištenja prediktora u razvoju neuronske mreže [82] ili uobičajenog korištenja samo najdostupnijih monotonih značajki R_m , R_e , Z i HB od čega su R_m i HB visokokorelirane [25, 26, 84], o čemu se posebno vodilo računa u ovom istraživanju. Osim toga, u [25] i [26] korišten je skroman broj podataka za modeliranje neuronskih mreža, a niti jedna od metoda ne uzima u obzir specifičnosti pojedinih skupina čelika. Kako su rezultati statističkih analiza iz poglavlja 4 pokazali da se ciklički i zamorni parametri nelegiranih, niskolegiranih i visokolegiranih čelika statistički značajno razlikuju, u ovom se istraživanju pristupilo modeliranju umjetnih neuronskih mreža za procjenu cikličkih i zamornih parametara zasebno za svaku skupinu čelika i svaki od sedam cikličkih i zamornih parametara pojedinačno, dakle ukupno 21 mreže. Dodatno je razvijeno i 7 mreža za procjenu cikličkih i zamornih parametara svih čelika zajedno, kako bi se usporedili dobiveni rezultati i potvrdila svrsishodnost podjele čelika u skupine. Umjetne neuronske mreže modelirane su pomoću programskog paketa MATLAB 2010b [54], a primjeri koda za učenje umjetnih neuronskih mreža korištenjem različitih algoritama za učenje pogreške dani su u Prilogu D. Prema [27] modeliranje umjetnih neuronskih mreža iterativan je proces, čiji su koraci prikazani na slici 5.9, a detalji objašnjeni u nastavku ovog potpoglavlja.



Slika 5.9 Dijagram toka modeliranja umjetnih neuronskih mreža

5.3.2 Odabir ulaznih varijabli i priprema podataka

Odabir podataka

Modeliranje umjetne neuronske mreže počinje prikupljanjem podataka, a uspješnost razvijene mreže uvelike ovisi o kvaliteti podataka na kojima je mreža učila. Za učenje mreža korišteni su uzorci na kojima su provedene statističke analize u poglavlju 4, a dani su u prilogu B.2. Iznimno, radi ograničenog broja podataka visokolegiranih čelika, pet materijala (označeni zvjezdicom "*" u tablicama B.5 i B.6) izostavljeno je iz uzorka za učenje, kako bi se na njima moglo testirati uspješnost razvijenih modela. Kvaliteta korištenih podataka osigurana je selekcijom prema kriterijima navedenim u poglavlju 3.

Broj podataka iz uzoraka na kojima se provodila statistička analiza u poglavlju 4 pokazao se premalim za uspješno učenje mreža, pa su postojeći uzorci dopunjeni dodatnim primjerima za učenje. Ciljano su iz [1], [7], [14], [16], [40], [73] i [81] prikupljene eksperimentalne vrijednosti

monotonih značajki iz vlačnih eksperimenata, te ciklički (RO) i zamorni (BCM) parametri nelegiranih, niskolegiranih i visokolegiranih čelika dobiveni iz cikličkih vlačnih–tlačnih, potpuno simetričnih eksperimenata ($R_e = -1$) izvedenih uz kontrolu amplitude deformacije na zraku i pri sobnoj temperaturi. Naknadno prikupljeni podaci moraju biti iz iste distribucije (raspona vrijednosti) kao i uzorci na kojima je provedena statistička analiza za utvrđivanje relevantnih monotonih značajki za procjenu pojedinih cikličkih/zamornih parametara, kako bi zaključci temeljeni na navedenoj analizi bili važeći i za novoprikupljene podatke, o čemu se posebno vodilo računa. Ti dodatni, naknadno prikupljeni podaci dani su u prilogu B.3.

Dio naknadno prikupljenih podataka korišten je za razvoj i/ili evaluaciju uspješnosti razvijenih neuronskih mreža za procjenu cikličkih i zamornih parametara te usporednu evaluaciju empirijskih metoda procjene.

Pretprocesiranje podataka za umjetnu neuronsku mrežu

Prema [27] pretprocesiranje podataka olakšava učenje relevantnih informacija o funkcijskoj vezi između ulaznih i izlaznih podataka. U modeliranju neuronskih mreža za procjenu cikličkih i zamornih parametara pretprocesiranje je provedeno *normalizacijom, uklanjanjem konstantnih vrijednosti i nadomještanjem nedostajućih podataka*.

Normalizacija sprečava prerano zasićenje neurona, koje može značajno usporiti učenje mreže. Aktivacijska funkcija u skrivenom sloju višeslojnog perceptrona najčešće je sigmoidna funkcija (logistička ili tangens hiperbolni), kod koje dolazi do zasićenja ako je ulaz u neuron veći od tri. Normaliziranjem podataka tako da padnu unutar područja vrijednosti aktivacijske funkcije osiguravaju se male vrijednosti ulaza u neuron. Ukoliko su ulazne vrijednosti normalizirane, veličine težina u mreži imaju dosljedno značenje, što je posebno važno kod korištenja regularizacijskih algoritama. Obično se normaliziraju i ulazni vektori, kao i vektori željenih izlaznih vrijednosti.

U skrivenom sloju korišten je tangens hiperbolni, koji ima područje vrijednosti od $i_{\min} = -1$ do $i_{\max} = +1$, pa su i podaci normalizirani unutar tog intervala na sljedeći način:

$$X' = \frac{(X - X_{\min})}{(X_{\max} - X_{\min})} (i_{\max} - i_{\min}) + i_{\min} . \quad (59)$$

U izrazu (59) X je vrijednost koja se normalizira, X_{\min} i X_{\max} su minimalna i maksimalna vrijednost elemenata vektora koji se normalizira, a X' normalizirana vrijednost elementa

ulaznog vektora. Kad mreža uči na normaliziranim podacima, u fazi primjene mreže ulazne vrijednosti treba normalizirati, a izlazne vrijednosti povratno procesirati u originalnu skalu.

Pored normalizacije, uklonjeni su istovjetni vektori čiji elementi imaju jednake vrijednosti, a ulazni podaci koji nedostaju nadomješteni su brojevnim vrijednostima koje algoritmi za učenje mogu obraditi. Podaci koji nedostaju moraju označavati se s NaN ³³. Tu informaciju mreža obrađuje tako da se NaN se zamijeni sa srednjom vrijednosti svih elemenata vektora, a dodatno se zapisuje da li je vrijednost tog elementa bila poznata ili nepoznata. Primjer nepotpunih podataka su vrijednosti K , n i σ_f visokolegiranih čelika korištene za modeliranje mreža za sve čelike na temelju svih dostupnih monotonih parametara.

5.3.3 Odabir mrežne arhitekture

Već je ranije spomenuto da je procjena cikličkih i zamornih parametara na osnovi monotonih značajki materijala problem aproksimacije funkcije, odnosno regresijski problem. Učinkovita mrežna arhitektura za rješavanje većine regresijskih problema (univezalni aproksimator) je *višeslojni perceptron s jednim skrivenim slojem*, kojem je aktivacijska funkcija u skrivenom sloju tangens hiperbolni, a u izlaznom linearna funkcija, pa je takva arhitektura korištena za modeliranje umjetnih neuronskih mreža za procjenu cikličkih i zamornih parametara materijala.

Odabir veličine skrivenog sloja

Odabir broja hiperparametara u mreži (broja neurona u skrivenom sloju) provedeno je metodom rasta. Maksimalni broj neurona u skrivenom sloju iz izraza (57) specifičan je za svaku mrežu, jer ovisi o broju podataka za treniranje N_{tren} i broju ulaznih vektora I . Veličina skrivenog sloja ovisi i o broju neurona u izlaznom sloju O , no kako sve mreže modelirane u okviru ovog istraživanja imaju po jedan neuron u izlaznom sloju, veličina izlaznog sloja ovdje ne igra nikakvu ulogu.

Metodom rasta povećavan je broj neurona u skrivenom sloju od 1 do maksimalnog broja neurona H iz izraza (57) za algoritme učenja koji se ne kombiniraju s metodama poboljšanja generalizacije (Levenberg–Marquadtov algoritam bez ranog zaustavljanja).

³³ NaN (engl. *Not-a-Number*).

Za algoritme koji imaju implementiranu neku od metoda poboljšanja generalizacije, metodu ranog zaustavljanja (Levenberg–Marquadtov algoritam s ranim zaustavljanjem) ili Bayesovu regularizaciju mrežna arhitektura je *svjesno* predimenzionirana tako da se maksimalni broj neurona u skrivenom sloju ograniči na 1,5 puta maksimalni broj neurona H iz izraza (57).

Odabir ulaznih vektora

Osim dobrog dimenzioniranja skrivenog sloja važno je i adekvatno odabrati ulazne vektore u mrežu (prediktorske varijable). Uz dovoljno velik³⁴ broj podataka za učenje i velik broj prediktorskih varijabli mogu se razviti mreže za procjenu cikličkih i zamornih parametara koje će učiti na podacima za *sve* čelike i dobro naučiti veze između ulaza i izlaza (neovisno o skupini čelika). Međutim, broj dostupnih podataka za učenje najčešće je ograničen, što limitira i gornju granicu broja ulaznih varijabli, kao i broj neurona u skrivenom sloju.

Iz izraza (57) vidljivo je da se uz fiksnu veličinu uzorka za učenje mreže i veličinu izlaznog sloja (uz $O = 1$ kod svih mreža u ovom istraživanju) pametnim odabirom broja ulaznih vektora može povećati broj neurona u skrivenom sloju, a time i vjerojatnost da će mreža dobro rješavati problem od interesa. Stoga su se za razvoj svake neuronske mreže koristile varijable za koje se unaprijednom selekcijom u poglavlju 4 pokazalo da su značajne za procjenu određenog parametra određene skupine čelika (pregled varijabli dan je u tablicama 4.9 i 4.10. Za one parametre za koje se nije utvrdila niti jedna relevantna varijabla koja bi doprinijela procjeni korištene su tri obično dostupne monotone značajke: vlačna čvrstoća R_m , granica tečenja R_e i smanjenje poprečnog presjeka pri lomu Z . Za sve čelike zajedno, korištene su sve dostupne monotone značajke.

Kako je u unaprijednoj selekciji primijenjen princip parsimonije, broj prediktorskih varijabli ostao je dovoljno malen u odnosu na veličinu uzoraka za učenje. Unaprijednom selekcijom eliminirani su i visokokorelirani prediktori. Uključivanje visokokoreliranih prediktora ne donosi novu informaciju o funkcijskoj vezi između ulaznih i izlaznih varijabli, a svako daljnje povećavanje ulaznog sloja, uz fiksnu veličinu uzorka za učenje, može dovesti do prenaučenosti mreže i loše generalizacije.

³⁴ Velik uzorak s aspekta umjetnih neuronskih mreža i problematike koja se obrađuje bio bi nekoliko tisuća podataka, iako se najčešće velikim uzorcima smatra nekoliko desetaka tisuća, pa čak i milijuna podataka.

5.3.4 Odabir algoritma za učenje

Odabir algoritma za učenje mreže ovisi o više faktora, uključujući složenost problema koji se rješava neuronskom mrežom, veličinu ulaznih vektora, broj hiperparametara u mreži, željenu vrijednosti funkcije pogreške, te vrstu problema koji se rješava [55].

Teško je unaprijed reći koji će algoritam biti najbolji za učenje mreže, pa su korištena dva algoritma za učenje³⁵, i to

1. *Levenberg–Marquadtov algoritam*, koji se preporuča za probleme aproksimacije funkcije i mreže koje imaju do nekoliko stotina hiperparametara, kao algoritam koji najbrže konvergira [27, 55]. Korištene su dvije podvarijante LM algoritma i to:
 - LM algoritam u kombinaciji s metodom ranog zaustavljanja (LM-rz), i
 - LM algoritam bez ranog zaustavljanja (LM), ali s ograničenjem maksimalnog broja neurona u skrivenom sloju prema izrazu (57).
2. *Algoritam s Bayesovom regularizacijom (BR)*, kod kojeg se težine mreže podešavaju prema LM algoritmu, a minimizira linearna kombinacija srednjeg kvadratnog odstupanja i sume kvadrata svih težina u mreži (58), kako je opisano u odjeljku 5.2.4, s ciljem poboljšanja generalizacije. Učenje traje dok se ne nađe optimalna kombinacija pogrešaka i težina [56]. Ovaj algoritam učenja ne zahtijeva izdvajanje uzorka za validaciju iz uzorka za učenje mreže pa je pogodan za korištenje kod manjih uzoraka.

Za sve algoritme odabrana funkcija pogreške je *srednje kvadratno odstupanje* iz izraza (51).

Podjela podataka na uzorke za učenje i testiranje

Prije početka učenja podatke je potrebno podijeliti na uzorke za učenje i za testiranje, ovisno o odabranom algoritmu za učenje mreže i metodi prevencije prenaučivosti mreže. Za podjelu i učenje mreža korištena je k -struka unakrsna validacija (broj podskupova $k = 10$), opisana u 5.2.4.2. U svakom prolazu podaci su nasumce raspoređivani u uzorke za treniranje i za testiranje (kod LM i BR algoritma) odnosno za treniranje, za validaciju i za testiranje (kod LM-rz), ali

³⁵ Tijekom istraživanja isproban je i algoritam *gradijentnog spusta s momentumom i prilagodljivom brzinom učenja (GDX)* uz metodu ranog zaustavljanja. Kako rezultati dobiveni korištenjem tog algoritma nisu bili zadovoljavajući, nisu ni uključeni u disertaciju.

tako da svi podaci na kojima mreža uči podjednak broj puta sudjeluju i u treniranju i u testiranju odnosno u treniranju, u validaciji i u testiranju mreže³⁶.

Prije k -struke unakrsne validacije isprobana je i unakrsna validacija s izuzimanjem, kod koje jednom formirani poduzorci za treniranje i testiranje (BR algoritam), odnosno treniranje, validaciju i testiranje (LM-rz algoritam) ostaju fiksni do kraja učenja mreže. Isprobani su razni omjeri podjele (80:20 odnosno 70:30 za BR i LM algoritam; 70:15:15 i 60:20:20 za LM-rz algoritam) i različiti načini raspodjele podataka po poduzorcima: potpuno nasumična podjela podataka i podjela podataka s obzirom na indeks ulazne matrice. Podjela podataka prema indeksu ulazne matrice pokazala se boljom, jer je za dobro učenje, a potom i testiranje mreže važno da svi uzorci pokrivaju cijeli raspon vrijednosti dostupnih podataka. Tako razvijene mreže djelovale su uspješnima sve do trenutka evaluacije rada mreže na neovisnim uzorcima. Neovisna evaluacija pokazala je, međutim, da izuzetno loše generaliziraju, zato što kod unakrsne validacije s izuzimanjem broj primjera za treniranje ostaje trajno smanjen, što izravno utječe na broj neurona u skrivenom sloju. Ukoliko se poštuje uvjet iz izraza (57), mreža nema dovoljno mogućnosti da nauči složene veze između ulaznih i izlaznih podataka, a u slučaju predimenzioniranja praktički "pamti" primjere na kojima je učila.

Kod malih uzoraka za učenje primjenom k -struke unakrsne validacije mnogo se bolje iskorištavaju podaci. Nedostatak u odnosu na unakrsnu validaciju s izuzimanjem je potreba treniranja k puta više mreža, što značajno produljuje vrijeme potrebno za dobivanje rezultata.

5.3.5 Inicijalizacija težina i treniranje mreže

Inicijalizacija težina i broj učenja

Prije učenja mreže treba postaviti početne vrijednosti težina u mreži. Početne vrijednosti težina izravno utječu na konvergenciju funkcije pogreške prema globalnom ili lokalnom minimumu. Težine u mreži inicijalizirane su *Nguyen–Widrowovom funkcijom inicijalizacije* [65], koja ubrzava konvergenciju višeslojnog perceptrona sa širenjem unatrag [27, 56]. Nguyen–Widrowova funkcija inicijalizacije postavlja početne težine u mreži w_{kj} tako da su aktivna

³⁶ U učenju mreže temeljenom na k -strukoj unakrsnoj validaciji uzorak za testiranje nije neovisan, odnosno dio podataka koji u jednom prolazu služi za testiranje mreže u idućem služi za treniranje ili validaciju. Stoga je za neovisnu analizu uspješnosti razvijenih modela neuronskih mreža potrebno imati dodatan, potpuno neovisan uzorak za testiranje, o čemu je riječ u 5.3.6.

područja svakog neurona podjednako raspodijeljena u rasponu vrijednosti ulaznih varijabli, a pristrani član b_k tako da nasumično centrira svaku sigmoidu unutar raspona vrijednosti ulaznih varijabli. Ulazne varijable moraju biti normalizirane prema izrazu (59).

Uobičajeno je trenirati mreže nekoliko puta s različitim vrijednostima početnih težina u mreži, kako bi se smanjila mogućnost da je funkcija pogreške odabrane mreže konvergirala u lokalni umjesto u globalni minimum. Prema [27] 5 do 10 treniranja s različitim početnim uvjetima gotovo uvijek rezultira mrežom koja je konvergirala u globalni minimum, pa je stoga svaka mreža za procjenu pojedinog parametra trenirana deset puta.

Zaustavljanje učenja mreže

Učenje mreže zaustavlja se kad je ispunjen neki od sljedećih uvjeta [56]:

- *Dostignut je maksimalni broj epoha učenja* – za sve algoritme broj epoha postavljen je na 1000. Veći broj epoha nije se isprobavao, s obzirom na to da su algoritmi s ranim zaustavljanjem uvijek završili učenje prije dostizanja maksimalnog broja epoha, dok bi veći broj epoha kod BR bio vremenski izuzetno zahtjevan.
- *Dostignuta je željena vrijednost funkcije pogreške* – željena vrijednost funkcije pogreške postavljena je u ovisnosti o korigiranoj varijanci izlazne varijable za koju se mreža trenira, tako da bude reda veličine 10^0 do 10^2 .³⁷
- *Vrijednost gradijenta pala je ispod zadane minimalne vrijednosti gradijenta* – u globalnom minimumu funkcije pogreške gradijent bi bio nula, pa zadanu minimalnu vrijednost gradijenta treba postaviti na vrlo malu vrijednost. U ovom slučaju postavljen je ovisno o željenoj funkciji pogreške, reda veličine 10^{-7} .
- *Parametar učenja μ postao je veći od zadane maksimalne vrijednosti* – samo kod LM i BR algoritama.
- *Srednje kvadratno odstupanje na uzorku za validaciju poraslo je u šest uzastopnih epoha* – samo za algoritam LM-rz koji je korišten u kombinaciji s unakrsnom validacijom.

³⁷ Zadana željena vrijednost funkcije pogreške u MATLAB-u je nula, što može dovesti do pretreniranosti mreže (ako se učenje ne zaustavi na osnovi nekog od preostalih kriterija).

5.3.6 Analiza mrežnih performansi

Za analizu uspješnosti mreža na neovisnom uzorku u prilogu B.4, u tablicama B.15 do B.20, dane su eksperimentalne vrijednosti monotonih značajki iz vlačnih eksperimenata, te ciklički (RO) i zamorni (BCM) parametri nelegiranih, niskolegiranih i visokolegiranih čelika dobiveni iz cikličkih vlačnih–tlačnih, potpuno simetričnih eksperimenata ($R_e = -1$) izvedenih uz kontrolu amplitude deformacije na zraku pri sobnoj temperaturi, na kojima je provedeno vrednovanje. Podaci su prikupljeni iz relevantne literature [1, 7, 14, 16, 20, 32, 34, 37, 40, 73, 75, 79, 80, 87].

Procjena uspješnosti nepristrana je i objektivna isključivo ako je provedena na podacima koji nisu korišteni za razvoj metode, čemu se u ovom istraživanju posvetila posebna pažnja. Tako je dio materijala korišten za razvoj neuronskih mreža za procjenu cikličkih parametara R_e' , K' i n' korišten za evaluaciju neuronskih mreža i metoda procjene zamornih parametara σ_f' , b , ϵ_f' i c , dok je dio korišten za razvoj neuronskih mreža za zamorne parametre korišten za evaluaciju neuronskih mreža i metoda procjene cikličkih parametara, kako bi se osigurala maksimalna iskoristivost prikupljenih podataka.


Važno je napomenuti da podaci za testiranje *moraju* pripadati istoj distribuciji kao i podaci koji su korišteni za razvoj neuronske mreže, s obzirom na to da je primjenjivost umjetnih neuronskih mreža ograničena *samo* na područje na kojem je mreža učila, odnosno da je ekstrapolacija gotovo nemoguća.

Procedura za odabir najuspješnije mreže bit će pojašnjena na jednom primjeru, i to na odabiru mreže za procjenu cikličke granice tečenja R_e' nelegiranih čelika pomoću 10-struke unakrsne validacije i Levenberg–Marquadtovog algoritma za učenje pogreške s ranim zaustavljanjem³⁸.

Za ovaj slučaj trenirale su se mreže sa od 1 do 11 neurona u skrivenom sloju. Za svaku mrežnu arhitekturu (broj neurona u skrivenom sloju) trenirano je po 10 mreža s različitim vrijednostima početnih težina u mreži, kako bi se smanjila mogućnost da funkcija pogreške odabrane mreže konvergira prema lokalnom umjesto u globalnom minimumu. Na svaki od tih slučajeva primijenjena je 10-struka unakrsna validacija, što čini ukupno 1100 treniranih mreža. Po završetku učenja mreže u poseban dokument zapisuju se podaci o treniranju svih mreža i


³⁸ Procedura koje će se opisati provedena je i za druge algoritme i arhitekture koji su procijenjeni uspješnima, no prezentacija svih rezultata bila bi preopširna.

generiraju dva dijagrama (slike 5.10 i 5.11), kako bi se vizualno utvrdio trend funkcije pogreške (srednjeg kvadratnog odstupanja) i koeficijenata determinacije R^2 i R_{adj}^2 u ovisnosti o broju neurona u skrivenom sloju. Na slici 5.10 prikazana je ovisnost funkcije pogreške o broju neurona u skrivenom sloju za poduzorke za treniranje, testiranje, validaciju i za cijeli uzorak. Vrijednosti prikazane na obje slike su najbolje prosječne vrijednosti funkcije pogreške i koeficijenata determinacije 10-struke unakrsne validacije, dobivene s 11 različitih arhitektura mreže i s po 10 treniranja s različitim početnim vrijednostima težina u mreži, čime je mogućnost izbora najbolje mreže smanjena na 110 mreža.



Slika 5.10 Ovisnost funkcije pogreške o broju neurona u skrivenom sloju mreža treniranih za procjenu cikličke granice tečenja nelegiranih čelika R_c' , ispis iz programskog paketa MATLAB

Na slici 5.11 prikazana je ovisnost maksimalnog koeficijenta determinacije R^2 i prilagođenog koeficijenta determinacije R_{adj}^2 o broju neurona u skrivenom sloju (napomena: programski paket koristi decimalnu točku umjesto decimalnog zareza). Dotični koeficijenti determinacije izračunati su za odstupanja između željenih d_j i dobivenih izlaza y_j mreže.



Slika 5.11 Ovisnost koeficijenta determinacije R^2 i prilagođenog koeficijenta determinacije R_{adj}^2 o broju neurona u skrivenom sloju mreža treniranih za procjenu cikličke granice tečenja nelegiranih čelika R_c' , ispis iz programskog paketa MATLAB

Iz oba dijagrama vidljivo je da su najmanje vrijednosti funkcije pogreške i najveće vrijednosti koeficijenata determinacije R^2 i R_{adj}^2 dobivene s 5 i 10 neurona u skrivenom sloju pa su u zapisu o učenju svih mreža nađene one koje odgovaraju tim slučajevima:

- 5 neurona u skrivenom sloju: prva trenirana mreža, vrijednost funkcije pogreške na cijelom uzorku $E_{sred,ans} = 1148$, koeficijent determinacije $R^2 = 0,919$, i
- 10 neurona u skrivenom sloju: druga trenirana mreža, vrijednost funkcije pogreške na cijelom uzorku $E_{sred,ans} = 1131$, koeficijent determinacije $R^2 = 0,920$.

Gornji rezultati su generirani kao prosjek svih 10 mreža iz 10-struke unakrsne validacije za pojedini slučaj. Uprosječe li se rezultati nekoliko mreža dobiva se tzv. *ansambl mreža* (engl. *ensemble of networks, committee of networks*). Generalizacija ansambla mreža često je bolja od najbolje pojedinačne mreže [27]. Iako je poželjno rezultate temeljiti na izlazima više mreža, kao što je sugerirano u [27] i [47], nema opravdanja da se u ansambl uključi i "loš" model. Stoga su za svaki od navedenih slučajeva osim srednje vrijednosti $E_{sred,ans}$ dodatno utvrđene vrijednosti medijana funkcije pogreške ansambla $E_{med,ans}$ i minimalne funkcije pogreške ansambla $E_{min,ans}$.

Mreže su potom testirane na nezavisnom uzorku podataka za

- svih 10 mreža iz 10-struke unakrsne validacije u ansamblu zajedno,
- sve mreže s funkcijom pogreške manjom od prosječne vrijednosti funkcije pogreške svih 10 mreža $E_{\text{sred}} < E_{\text{sred,ans}}$,
- mreže s funkcijom pogreške manjom od medijana funkcije pogreške svih 10 mreža $E_{\text{sred}} < E_{\text{med,ans}}$,
- najbolju mrežu $E_{\text{min,ans}}$ i
- nekoliko najboljih mreža zajedno.

Za ovako dobivene rezultate određen je koeficijent korelacije r_{test} među vrijednostima željenih i stvarnih izlaza mreže (tj. eksperimentalnih i procijenjenih podataka), napravljen je dijagram rasipanja parova tih vrijednosti i određeni su postoci podataka čija procijenjena vrijednost cikličke granice tečenja Re' odstupa $\pm 10\%$, $\pm 20\%$ i $\pm 30\%$ od vrijednosti utvrđenih eksperimentom. Za testne uzorke izračunat je i *korijen srednjeg kvadratnog odstupanja* (engl. *root mean square error*)

$$RMSE_{\text{sred,test}} = \sqrt{\frac{1}{N} \sum_{n=1}^N (d_j - y_j)^2}, \quad (60)$$

kao koristan pokazatelj standardne devijacije pogreške (u istim je mjernim jedinicama kao i zavisna varijabla). Primjer takve analize dan je u tablicama 5.2 i 5.3 te slici 5.12.


Tablica 5.2 Analiza ansambla mreža dobivenih 10-strukom unakrsnom validacijom i Levenberg–Marquadtovim algoritmom za učenje pogreške s ranim zaustavljanjem – mreža s 5 neurona u skrivenom sloju

Algoritam učenja: Levenberg–Marquadtovog algoritma za učenje pogreške s ranim zaustavljanjem						
Broj neurona u skrivenom sloju / redni broj mreže: 5 / 1						
$E_{\text{sred,ans}} = 1148, R_{\text{max}}^2 = 0,919$						
Testirane mreže	Srednje kvadratno odstupanje uzorka za testiranje, $E_{\text{ans,test}}$	Koeficijent korelacije eksperimentalnih i procijenjenih podataka, r_{test}	Postotak podataka koji odstupaju			
			0–10 %	10–20 %	20–30 %	> 30 %
sve mreže	1145	0,937	65	35	0	0
$E_{\text{sred}} < E_{\text{sred,ans}}$	1427	0,919	76	18	6	0
$E_{\text{sred}} \leq E_{\text{med,ans}}$	1753	0,913	76	17	0	6
$E_{\text{min,ans}}$	3700	0,848	70	18	6	6
nekoliko najboljih	3212	0,866	70	18	0	12

Tablica 5.3 Analiza ansambla mreža dobivenih 10-strukom unakrsnom validacijom i Levenberg–Marquadtovim algoritmom za učenje pogreške s ranim zaustavljanjem – mreža s 10 neurona u skrivenom sloju

Algoritam učenja: Levenberg–Marquadtovog algoritma za učenje pogreške s ranim zaustavljanjem Broj neurona u skrivenom sloju / redni broj mreže: 10 / 2 $E_{\text{sred,ans}} = 1131, R^2 = 0,920$						
Testirane mreže	Srednje kvadratno odstupanje uzorka za testiranje, $E_{\text{ans,test}}$	Koeficijent korelacije eksperimentalnih i procijenjenih podataka, r_{test}	Postotak podataka koji odstupaju			
			0–10 %	10–20 %	20–30 %	> 30 %
sve mreže	932	0,950	76	24	0	0
$E_{\text{sred}} < E_{\text{sred,ans}}$	1057	0,934	70	30	0	0
$E_{\text{sred}} \leq E_{\text{med,ans}}$	1315	0,926	65	35	0	0
$E_{\text{min,ans}}$	6781	0,788	59	24	0	17
nekoliko najboljih	1175	0,939	76	18	6	0

Iz tablica 5.2 i 5.3 jasno je da najbolje rezultate na neovisnom uzorku za testiranje daje arhitektura s 10 neurona u skrivenom sloju, i to za sve mreže u ansamblu dobivene 10-strukom unakrsnom validacijom i Levenberg–Marquadtovim algoritmom za učenje pogreške s ranim zaustavljanjem pa je taj ansambl i odabran za procjenu cikličke granice tečenja R_e' nelegiranih čelika. Sve vrijednosti procijenjenih R_e' odstupaju do maksimalno $\pm 20\%$. Vidljivo je i da ansambl mreža daje bolje rezultate od najboljeg modela. Primjer dijagrama rasipanja eksperimentalnih i procijenjenih vrijednosti cikličke granice tečenja R_e' dobivenih ansamblom koji daje najbolje rezultate (ansambl svih mreža) dan je na slici 5.12.



Slika 5.12 Dijagram rasipanja vrijednosti cikličke granice tečenja R_e' dobivenih mrežom s 10 neurona u skrivenom sloju, 10-strukom unakrsnom validacijom i Levenberg–Marquadtovim algoritmom za učenje pogreške s ranim zaustavljanjem (sve mreže, testni uzorak), ispis iz programskog paketa MATLAB

Opisana procedura provedena je za odabir najbolje umjetne neuronske mreže za procjenu svakog cikličkog i svakog zamornog parametra nelegiranih, niskolegiranih i visokolegiranih čelika (21 mreža), kao i mreža za procjenu pojedinih parametara svih čelika zajedno, kako bi se usporedili dobiveni rezultati (7 mreža).

Sinteza rezultata prezentirana je u narednom potpoglavlju.

5.4 Odabrane umjetne neuronske mreže za procjenu cikličkih i zamornih parametara čelika

U tablicama 5.4 i 5.5 dan je pregled razvijenih umjetnih neuronskih mreža za procjenu cikličkih (R_e' , K' i n') i zamornih parametara (σ_f' , b , ε_f' i c) odabranih na temelju kriterija opisanih u prethodnom poglavlju, za pojedine skupine i za sve čelike zajedno.

Kao što je već rečeno, nije moguće unaprijed odrediti koji algoritam učenja će biti najuspješniji za dani problem. Tako se svaki od tri korištena algoritma pokazao najboljim za učenje mreža za procjenu nekog od parametara određene skupine čelika. Međutim, može se zaključiti da su algoritmi koji koriste neku od metoda poboljšanja generalizacije, Levenberg–Marquadtov algoritam s ranim zaustavljanjem i algoritam s Bayesovom regularizacijom općenito uspješniji od Levenberg–Marquadtovog algoritma bez ranog zaustavljanja. Iako se mreža koja nije predimenzionirana ne bi trebala moći prenaučiti, testiranjem mreža na nezavisnom uzorku podataka pokazalo je da su LM algoritmom često dobivane vrijednosti pojedinih parametara s pogrešnim predznakom.

Vidljivo je i da su u većini slučajeva uspješniji rezultati dobivani kombinacijom više mreža dobivenih k -strukom validacijom (najčešće sve mreže), što govori u prilog korištenju ansambla mreža kao dodatnoj mjeri poboljšanja generalizacije.

Zaključno, promatranjem vrijednosti korijena srednjeg kvadratnog odstupanja dobivenih na uzorku za testiranje $RMSE_{ans,test}$, kao standardnoj devijaciji pogreške, vidljivo je da se najčešće veće vrijednosti tog pokazatelja dobivaju na podacima procijenjenim primjenom umjetnih neuronskih mreža razvijanih za sve čelike zajedno. Jedan od ekstremnijih primjera je procjena koeficijenta cikličkog deformacijskog očvršćivanja K' , gdje je vrijednost $RMSE_{ans,test}$ za sve čelike 597. Usporedba s rezultatima mreža za procjenu K' nelegiranih i niskolegiranih čelika, gdje su dobivene vrijednosti $RMSE_{ans,test}$ 341 i 303 govori u prilog razvoju umjetnih neuronskih mreža zasebno za svaku skupinu čelika podijeljenih prema udjelu legirajućih elemenata.

Tablica 5.4 Pregled umjetnih neuronskih mreža odabranih za procjenu cikličkih parametara čelika

Grupa čelika	Ciklički parametar	Algoritam	H	R. br. treniranja	$E_{\text{sred,ans}}$	R^2_{max}	Odabrane mreže (maks. $k = 10$)	$RMSE_{\text{sred,test}}$	r_{test}
Nlegirani	R_e'	LM-rz	10	2	1131	0,920	sve	31	0,950
	K'	BR	11	1	11020	0,892	$E_{\text{sred}} < E_{\text{sred,ans}}$	341	0,564
	n'	LM-rz	14	2	$2,67 \cdot 10^{-4}$	0,830	sve	0,044	0,294
Niskolegirani	R_e'	LM-rz	8	6	1504	0,961	nekoliko najboljih mreža	64	0,960
	K'	BR	4	5	60543	0,701	sve	303	0,692
	n'	BR	2	6	$6,15 \cdot 10^{-4}$	0,475	$E_{\text{sred}} < E_{\text{sred,ans}}$	0,036	0,473
Visokolegirani	R_e'	LM	3	1	1317	0,962	sve	52	0,976
	K'	LM	6	8	275930	0,879	sve	2357	0,150
	n'	LM-rz	3	2	0,0022	0,809	sve	0,077	0,720
Svi čelici	R_e'	LM-rz	8	1	2768	0,943	nekoliko najboljih mreža	62	0,952
	K'	LM-rz	7	2	73192	0,900	sve	597	0,472
	n'	LM-rz	4	1	$7,40 \cdot 10^{-4}$	0,902	sve	0,046	0,660

Tablica 5.5 Pregled umjetnih neuronskih mreža odabranih za procjenu zamornih parametara čelika

Grupa čelika	Zamorni parametar	Algoritam	H	R. br. treniranja	$E_{\text{stred,ans}}$	R^2_{max}	Odabrane mreže (maks. $k = 10$)	$RMSE_{\text{stred,test}}$	r_{test}
Neligirani	σ_f'	LM	6	3	18173	0,775	nekoliko najboljih mreža	178	0,670
	b	LM-rz	13	10	$1,87 \cdot 10^{-4}$	0,630	sve	0,016	0,451
	ε_f'	LM	5	2	0,045	0,637	nekoliko najboljih mreža	0,301	0,324
	c	LM	5	10	0,0033	0,635	sve	0,080	0,546
Niskolegirani	σ_f'	BR	4	6	35091	0,817	$E_{\text{stred}} < E_{\text{med,ans}}$	255	0,846
	b	BR	3	8	$2,08 \cdot 10^{-4}$	0,379	sve	0,015	0,715
	ε_f'	BR	4	2	0,455	0,109	sve	0,651	0,113
	c	BR	6	2	0,011	0,243	sve	0,085	0,526
Viskolegirani	σ_f'	LM	4	6	114890	0,542	sve	246	0,901
	b	BR	2	1	$5,03 \cdot 10^{-4}$	0,774	$E_{\text{stred}} < E_{\text{stred,ans}}$	0,038	0,425
	ε_f'	LM-rz	5	10	0,064	0,569	nekoliko najboljih mreža	0,411	-0,144
	c	LM-rz	3	5	0,003	0,718	sve	0,146	0,324
Svi čelici	σ_f'	LM-rz	10	6	40287	0,802	sve	321	0,698
	b	BR	4	7	$2,86 \cdot 10^{-4}$	0,789	sve	0,017	0,645
	ε_f'	BR	1	8	0,268	0,076	sve	0,523	0,379
	c	BR	4	1	0,008	0,496	sve	0,081	0,696

Pristup procjeni cikličkih i zamornih parametara čelika primjenom odabranih neuronskih mreža vrednovat će se u idućem poglavlju na neovisnom uzorku podataka za nelegirane, niskolegirane, visokolegirane i sve čelike zajedno i usporediti s eksperimentalnim podacima i vrijednostima dobivenim odabranim empirijskim metodama procjene cikličkih i zamornih parametara čelika.

6 Vrednovanje primjenjivosti umjetnih neuronskih mreža za procjenu cikličkih i zamornih parametara materijala

6.1 Uvod

Osnovni je cilj razvoja umjetnih neuronskih mreža sposobnost generalizacije – sposobnost mreže da znanje stečeno na primjerima za učenje uspješno primijeni na nov, neovisan uzorak koji sadrži podatke koji nisu korišteni za učenje mreže. Za vrednovanje predloženog i razvijenog pristupa procjeni cikličkih Ramberg–Osgoodovih (R_e' , K' i n') i zamornih Basquin–Coffin–Mansonovih parametara (σ_f' , b , ε_f' i c) čelika, vrijednosti parametara procijenjene odabranim umjetnim neuronskim mrežama (tablice 5.4 i 5.5) uspoređene su s odgovarajućim eksperimentalnim vrijednostima. Pored toga, kako bi se utvrdilo da li razvoj umjetnih neuronskih mreža temeljen na statistički relevantnim monotonim značajkama poboljšava procjenu cikličkih i zamornih parametara čelika na osnovi monotonih značajki, rezultati dobiveni neuronskim mrežama uspoređeni su i s vrijednostima dobivenim odabranim empirijskim metodama procjene. Dodatno su vrednovani i rezultati dobiveni umjetnim neuronskim mrežama razvijenim za procjenu cikličkih i zamornih parametara skupine sačinjene od svih čelika i na osnovi svih dostupnih monotonih značajki, kako bi se utvrdile prednosti podjele čelika prema udjelu legirajućih elemenata i korištenja samo relevantnih monotonih značajki za procjenu cikličkih i zamornih parametara i ponašanja čelika.

6.2 Metodologija vrednovanja

Vrednovanje je provedeno na neovisnom uzorku podataka, kako je opisano u 5.3.6, posebno za nelegirane, niskolegirane i visokolegirane čelike. Za vrednovanje neuronskih mreža za procjenu cikličkih parametara i ponašanja čelika korištena su 52 skupa podataka za čelike, i to 17 za nelegirane, 25 niskolegirane i 10 za visokolegirane. Vrednovanje neuronskih mreža za procjenu

zamornih parametara provedeno je na 49 čelika, od čega 16, 23 i 10 za nelegirane, niskolegirane i visokolegirane čelike.

Vrednovanje rezultata dobivenih umjetnim neuronskim mrežama na neovisnom uzorku podataka provedeno je u dvije faze:

1. *vrednovanje na razini parametara, i*
2. *vrednovanje na razini ponašanja čelika.*

Vrednovanje na razini parametara

Vrednovanje na razini parametara provedeno je izravnom usporedbom vrijednosti cikličkih RO i zamornih BCM parametara procijenjenih odabranim neuronskim mrežama s vrijednostima procijenjenim odabranim empirijskim metodama te odgovarajućim eksperimentalnim vrijednostima.

Za vrednovanje procijenjenih vrijednosti cikličke granice tečenja R_e' izračunat je postotak procijenjenih vrijednosti koje od eksperimentalnih vrijednosti odstupaju do $\pm 5\%$, $\pm 10\%$, $\pm 15\%$ i $\pm 20\%$, dok je za vrednovanje procijenjenih vrijednosti parametara K' , n' , σ_f' , b , ε_f' i c izračunat postotak procijenjenih vrijednosti koje od eksperimentalnih vrijednosti odstupaju do $\pm 10\%$, $\pm 20\%$ i $\pm 30\%$. Pojasevi odstupanja za vrednovanje procijenjenih vrijednosti R_e' uži su od onih za ostale parametre, s obzirom na to da ciklička granica tečenja R_e' predstavlja konkretnu vrijednost amplitude naprezanja $\Delta\sigma/2$ pri amplitudi plastične deformacije od $\Delta\varepsilon_p/2 = 0,2\%$, pa su ti pojasevi odstupanja usklađeni s onima definiranim za vrednovanje amplituda naprezanja $\Delta\sigma/2$ proračunatih na osnovi procijenjenih vrijednosti parametara K' i n' .

Rezultati evaluacije na razini parametara dani su u potpoglavlju 6.4.

Vrednovanje na razini ponašanja

Cilj metoda procjene cikličkih i zamornih parametara materijala na osnovi monotonih značajki je čim točnije predviđanje cikličkih krivulja ovisnosti amplitude naprezanja o amplitudi deformacije $\Delta\sigma/2 - \Delta\varepsilon/2$, odnosno zamornih krivulja ovisnosti broja izmjena opterećenja do otkazivanja o amplitudi ukupne deformacije $\Delta\varepsilon/2 - 2N_f$. Stoga je, osim izravnog vrednovanja procijenjenih vrijednosti pojedinih parametara, za svaku pojedinu skupinu čelika i skupinu

sačinjenu od svih čelika zajedno provedeno i vrednovanje cikličkih i zamornih krivulja $\Delta\sigma/2$ – $\Delta\varepsilon/2$ i $\Delta\varepsilon/2$ – $2N_f$ dobivenih na osnovi tako procijenjenih parametara.

Uvrštavanjem procijenjenih i eksperimentalnih vrijednosti cikličkih parametara K' i n' u Ramberg–Osgoodov izraz (11) proračunate su vrijednosti amplituda naprežanja $\Delta\sigma/2$ za osam različitih amplituda ukupne deformacije $\Delta\varepsilon/2$: 0,25 %, 0,3 %, 0,35 %, 0,4 %, 0,45 %, 0,5 %, 0,9 % i 1,5 %. Za tako procijenjene vrijednosti amplituda naprežanja $\Delta\sigma/2$ izračunati su postotci procijenjenih vrijednosti koje od eksperimentalnih vrijednosti odstupaju redom do ± 5 %, ± 10 %, ± 15 % i ± 20 %.

Na osnovi procijenjenih i eksperimentalnih vrijednosti zamornih parametara σ_f' , b , ε_f' i c i Basquin–Coffin–Mansonovog izraza (15) iterativnim postupkom temeljenim na Newton–Raphsonovoj metodi izračunate su vrijednosti broja izmjena opterećenja do otkazivanja $2N_f$ za istih osam amplituda ukupne deformacije $\Delta\varepsilon/2$ za koje su računati i vrijednosti amplituda naprežanja $\Delta\sigma/2$.

Za vrednovanje točnosti tako procijenjenih trajnosti korišten je često primjenjivan kriterij greške (engl. *conventional error criterion*) [8, 33, 48, 67, 68, 73, 84]

$$E_f(s) = \frac{\text{broj podataka unutar } \frac{1}{s} \leq \frac{2N_{f,\text{pror}}}{2N_{f,\text{eksp}}} \leq s}{\text{ukupan broj podataka}} \quad (61)$$

U izrazu (61) $2N_{f,\text{pror}}$ su proračunate vrijednosti izmjena opterećenja do otkazivanja dobivene na osnovi procijenjenih zamornih parametara, a $2N_{f,\text{eksp}}$ vrijednosti izmjena opterećenja do otkazivanja dobivene na osnovi zamornih parametara dobivenih eksperimentom. Kriterij greške $E_f(s)$ izračunat je zasebno za vrijednosti pojasa odstupanja $s = 1,5, 2, 3, 5, 10$.

Treba napomenuti da su vrijednosti broja izmjena opterećenja do otkazivanja izračunate na osnovi eksperimentalnih vrijednosti zamornih BCM parametara $2N_{f,\text{eksp}}$ za određen broj materijala kao i neke amplitude ukupne deformacije $\Delta\varepsilon/2$ rezultirale nerealno velikim trajnostima, čak većim od 10^8 za najmanje vrijednosti $\Delta\varepsilon/2$. Stoga su vrijednosti $2N_{f,\text{eksp}}$ veće od $5 \cdot 10^6$ i pripadajući parovi vrijednosti proračunati procijenjenim parametrima $2N_{f,\text{pror}}$ isključeni iz postupka vrednovanja [10].

Rezultati evaluacije na razini ponašanja dani su u potpoglavlju 6.5.

6.3 Odabir empirijskih metoda procjene cikličkih i zamornih parametara i ponašanja čelika za usporedno vrednovanje

Iako su evaluacije empirijskih metoda procjene dostupne u nizu postojećih publikacija [33, 36, 52, 57, 67, 68, 83], one su provedene na uzorcima podataka raznolikog sastava, a samo su u [33], [52] i [68] nelegirani, niskolegirani i visokolegirani čelici za potrebe evaluacije razmatrani kao zasebne skupine. Da bi rezultati bili izravno usporedivi, potrebno je na jednak način provesti vrednovanje kako rezultata dobivenih primjenom neuronskih mreža tako i rezultata dobivenih empirijskim metodama procjene. Stoga, osim razvijenog pristupa procjeni cikličkih i zamornih parametara i ponašanja čelika na istom su uzorku vrednovane i empirijske metode procjene.

U tablici 6.1 dan je pregled empirijskih metoda procjene cikličkih parametara R_e' , K' i n' i cikličkog ponašanja $\Delta\sigma/2 - \Delta\varepsilon/2$ odabranih za usporedno vrednovanje.

Tablica 6.1 Empirijske metode procjene cikličkih parametara i ponašanja čelika odabrane za usporedno vrednovanje

Empirijska metoda	Procijenjeni parametar	Procijenjena vrijednost	Metoda predložena za	Izrazi
Lopez 1 [44]	R_e'	–	čelike podijeljene prema R_m/R_e	(A.2), (A.3)
Lopez 2 [44]	R_e'	–	sve čelike	(A.4)
Li [43]	R_e'	–	sve čelike	(A.5)
Zhang 1 [91]	K'	$\Delta\sigma/2$	sve čelike	(A.6)
	n'		čelike podijeljene prema α	(A.7) – (A.9)
Zhang 2 [91]	K'	$\Delta\sigma/2$	čelike podijeljene prema α	(A.12), (A.13)
	n'		čelike podijeljene prema α	(A.14) – (A.16)
Lopez 1 [44]	K'	$\Delta\sigma/2$	čelike podijeljene prema R_m/R_e	(A.17), (A.18)
	n'		čelike podijeljene prema R_m/R_e	(A.19), (A.20)
Lopez 2 [44]	K'	$\Delta\sigma/2$	čelike podijeljene prema R_m/R_e	(A.17), (A.18)
	n'		sve čelike	(A.21)
Li [43]	K'	$\Delta\sigma/2$	čelike podijeljene prema R_m/R_e	(A.22) – (A.24)
	n'		sve čelike	(A.25)

Metode procjene dane u tablici 6.1 uključuju sve postojeće metode procjene osim one predložene u [11], s obzirom na to da je ta metoda razvijana na uzorku sačinjenom od samo jednog materijala, i to niskolegirano čelika 42CrMo4.

Pregled empirijskih metoda procjene odabranih za usporedno vrednovanje rezultata procijenjenih vrijednosti zamornih parametara čelika σ_f' , b , ε_f' i c i zamornog ponašanja $\Delta\varepsilon/2-2N_f$ dan je u tablici 6.2.

Tablica 6.2 Empirijske metode procjene zamornih parametara i ponašanja čelika odabrane za usporedno vrednovanje

Empirijska metoda	Procijenjeni parametar	Procijenjena vrijednost	Metoda predložena za	Izrazi
Modificirana metoda univerzalnih nagiba pravaca (Modif. UNP) [64]	σ_f'	$2N_f$	sve materijale	(A.30)
	b			
	ε_f'			
	c			
Uniformni materijalni zakon (UMZ) [14]	σ_f'	$2N_f$	nelegirane i niskolegirane čelike	(A.31), (A.32)
	b			
	ε_f'			
	c			
Metoda tvrdoće [73]	σ_f'	$2N_f$	čelike Brinellove tvrdoće 100 – 700 HB	(A.36)
	b			
	ε_f'			
	c			
Metoda medijana [57]	σ_f'	$2N_f$	sve čelike	(A.37)
	b			
	ε_f'			
	c			

Metode procjene dane u tablici 6.2 ocijenjene su najuspješnijima u nekoliko publikacija koje ocjenjuju uspješnost empirijskih metoda za procjenu broja izmjena opterećenja do otkazivanja $2N_f$ [33, 36, 57, 67, 68, 83], pa su stoga odabrane za usporedno vrednovanje u ovom istraživanju. Osim toga, ove su metode zbog relativno malog broja lako dostupnih monotonih značajki koje su potrebne za njihovu primjenu jednostavne za korištenje.

Za procjenu broja izmjena opterećenja do otkazivanja $2N_{f, \text{pro}}'$ primjenom metode tvrdoće potrebno je poznavanje vrijednosti Brinellove tvrdoće HB . Kako eksperimentalna vrijednost HB nije bila dostupna za sve čelike korištene u vrednovanju, ti podaci proračunati su iz vrijednosti vlačne čvrstoće R_m na osnovi izraza iz [76]


$$R_m \cong 3,45 \cdot HB. \quad (62)$$

6.4 Vrednovanje umjetnih neuronskih mreža za procjenu cikličkih i zamornih parametara čelika

6.4.1 Vrednovanje procijenjenih cikličkih parametara

6.4.1.1 Vrednovanje procijenjenih vrijednosti cikličke granice tečenja R_e'

Postotak vrijednosti cikličke granice tečenja R_e' za nelegirane, niskolegirane i visokolegirane čelike procijenjenih odabranim metodama (tablica 6.1) i umjetnim neuronskim mrežama (UNM) koje od eksperimentalnih vrijednosti odstupaju do $\pm 5\%$, $\pm 10\%$, $\pm 15\%$ i $\pm 20\%$ prikazan je na slici 6.1.



Slika 6.1 Postotak vrijednosti R_e' nelegiranih, niskolegiranih i visokolegiranih čelika procijenjenih empirijskim metodama procjene i umjetnim neuronskim mrežama koje odstupaju do 5, 10, 15 i 20 % od eksperimentalnih vrijednosti


Vrijednosti R_e' procijenjene primjenom UNM pokazale su se najuspješnijim za sve tri skupine čelika, a posebno nelegiranih i visokolegiranih. Sve procijenjene vrijednosti R_e' nelegiranih čelika odstupaju do najviše $\pm 20\%$ od eksperimentalnih vrijednosti. Iako najbolja empirijska metoda ima isti postotak podataka u tom pojasu odstupanja, postotak vrijednosti R_e' procijenjenih primjenom UNM koje odstupaju do $\pm 5\%$, $\pm 10\%$ i $\pm 15\%$ značajno je bolji od najbolje empirijske metode – 53 %, 76 % i 94 % naspram 29 %, 53 % i 71 % vrijednosti procijenjenih Lijevom metodom.

Za niskolegirane čelike postotak vrijednosti procijenjenih primjenom UNM u svim je pojasevima odstupanja tek malo bolji od empirijskih metoda procjene, koje sve daju podjednake i to općenito uzevši vrlo dobre rezultate. Najveća razlika u postotku procijenjenih vrijednosti

R_e' niskolegiranih čelika vidljiva je u pojasu odstupanja do $\pm 10\%$, gdje je postotak vrijednosti procijenjenih Lijevom metodom 72 %, a primjenom UNM 84 %. Razlog tome jest sastav uzorka podataka na kojima su sve tri razmatrane empirijske metode procjene razvijane – na podacima za pretežno nelegirane i niskolegirane čelike.

Najznačajnija razlika u rezultatima procijenjenih vrijednosti R_e' vidljiva je kod visokolegiranih čelika, najvjerojatnije zbog činjenice da su uzorci podataka na kojima su razvijane empirijske metode procjene bili sačinjeni većinom od nelegiranih i niskolegiranih čelika. Lopezova metoda za čelike podijeljene prema omjeru R_m/R_e (Lopez 1) rezultira najboljim postotkom vrijednosti unutar svih pojaseva odstupanja, ali s tek 50 % vrijednosti unutar pojasa $\pm 20\%$. Primjenom UNM taj postotak je visokih 90 % unutar pojasa $\pm 15\%$ i $\pm 20\%$ i čak 60 % unutar odstupanja $\pm 5\%$.

Na slici 6.2 prikazani su postotci odstupanja cikličke granice tečenja R_e' procijenjene odabranim empirijskim metodama i UNM razvijenom za sve čelike zajedno.




Slika 6.2 Postotak vrijednosti R_e' procijenjenih empirijskim metodama i umjetnim neuronskim mrežama primijenjenim na sve čelike zajedno koje odstupaju do 5, 10, 15 i 20 % od eksperimentalnih vrijednosti

Iako su UNM razvijene za procjenu R_e' svih čelika podjednako uspješne kao empirijske metode, a ponešto uspješnije u pojasevima odstupanja $\pm 10\%$ i $\pm 15\%$, usporedbom vrijednosti prikazanih na slici 6.2 s onima na slici 6.1 vidljivo je da ta mreža rezultira značajno lošijim rezultatima u odnosu na mreže razvijane zasebno za svaku skupinu, posebice u pojasu odstupanja do $\pm 5\%$. U tom je pojasu za nelegirane, niskolegirane i visokolegirane čelike postotak vrijednosti 50 – 60 %, a za sve čelike tek 36 %, što potvrđuje svrsishodnost podjele čelika u skupine. Ovakvi rezultati su potvrda da grupiranje čelika u skupine prema udjelu legirajućih elemenata poboljšava procjenu cikličkih i zamornih parametara čelika.

6.4.1.2 Vrednovanje procijenjenih vrijednosti koeficijenta cikličkog deformacijskog očvršćivanja K'

Postotak vrijednosti koeficijenta cikličkog deformacijskog očvršćivanja K' za nelegirane, niskolegirane i visokolegirane čelike procijenjenih odabranim metodama (tablica 6.1) i umjetnim neuronskim mrežama koje od eksperimentalnih vrijednosti odstupaju do $\pm 10\%$, $\pm 20\%$ i $\pm 30\%$ prikazan je na slici 6.3.




Slika 6.3 Postotak vrijednosti K' nelegiranih, niskolegiranih i visokolegiranih čelika procijenjenih empirijskim metodama procjene i umjetnim neuronskim mrežama koje odstupaju do 10, 20 i 30 % od eksperimentalnih vrijednosti

Primjenom UNM za procjenu K' podjednako dobri rezultati dobiveni su za nelegirane i niskolegirane čelike, za koje 88 % odnosno 92 % procijenjenih vrijednosti K' odstupaju do $\pm 30\%$ od eksperimentalnih vrijednosti. U usporedbi s empirijskim metodama primjena UNM uspješnija je unutar svih pojaseva odstupanja za nelegirane čelike. Nešto manje od 90 % vrijednosti odstupaju $\pm 20\%$ u usporedbi s najviših 65 % dobivenih Lijevom metodom. Međutim, za niskolegirane čelike rezultati su za UNM i najbolju, Lijevu empirijsku metodu podjednaki, s oko 55 % i 80 % procijenjenih vrijednosti koje odstupaju do $\pm 10\%$ i $\pm 20\%$.

Što se visokolegiranih čelika tiče, UNM je bolja od većine empirijskih metoda procjene, iako s tek 50 % vrijednosti koje odstupaju do $\pm 30\%$ od eksperimentalnih vrijednosti. Razlog relativno niskom postotku vrijednosti unutar pojasa $\pm 30\%$ je velik rasap rezultata za K' visokolegiranih čelika i mali broj podataka za učenje. Od UNM boljom se pokazala Zhangova metoda koja je primjenjiva kad su poznate vrijednosti monotonih značajki K i n (Zhang 1). Međutim, rezultate Zhangove metode 1 treba uzeti s oprezom, jer su tek tri visokolegirana čelika imala poznate vrijednosti ovih monotonih značajki, tako da metoda nije primijenjena na cijelom uzorku za

testiranje. Vrijednosti procijenjene primjenom ostalih empirijskih metoda iznimno su loše, s nijednim podatkom koji upada u pojas odstupanja $\pm 10\%$.

Na slici 6.4 prikazani su postotci odstupanja koeficijenta cikličkog deformacijskog očvršćivanja K' procijenjene odabranim empirijskim metodama i UNM razvijenom za sve čelike zajedno.



Slika 6.4 Postotak vrijednosti K' procijenjenih empirijskim metodama i umjetnim neuronskim mrežama primijenjenim na sve čelike zajedno koje odstupaju do 10, 20 i 30 % od eksperimentalnih vrijednosti


UNM razvijana za procjenu K' svih čelika zajedno bolja je od empirijskih metoda procjene što je posebice vidljivo na pojasu odstupanja do $\pm 10\%$ u koji ulazi 53 % podataka procijenjenih primjenom UNM, dok je najviši postotak dobiven empirijskom metodom 44 %.

6.4.1.3 Vrednovanje procijenjenih vrijednosti eksponenta cikličkog deformacijskog očvršćivanja n'

Postotak vrijednosti eksponenta cikličkog deformacijskog očvršćivanja n' za nelegirane, niskolegirane i visokolegirane čelike procijenjenih odabranim metodama (tablica 6.1) i umjetnim neuronskim mrežama koje od eksperimentalnih vrijednosti odstupaju do $\pm 10\%$, $\pm 20\%$ i $\pm 30\%$ prikazan je na slici 6.5.


Rezultati dobiveni primjenom UNM za sve tri skupine čelika podjednako su dobri, s 40 % do 48 % podataka koji odstupaju od eksperimentalnih vrijednosti do $\pm 10\%$ i oko 80 % unutar pojasa odstupanja $\pm 30\%$. Za pojas odstupanja $\pm 20\%$ postotci procijenjenih vrijednosti primjenom UNM se razlikuju za pojedine skupine. Postotak procijenjenih vrijednosti eksponenta n' koje od eksperimentalnih vrijednosti odstupaju do $\pm 20\%$ je 76 % za nelegirane, 60 % za niskolegirane i 50 % za visokolegirane čelike. Značajno poboljšanje točnosti procjene n' primjenom UNM vidljivo je kod visokolegiranih čelika, gdje 40 % vrijednosti n' dobivenih

primjenom UNM odstupa do $\pm 10\%$ od eksperimentalnih vrijednosti, naspram maksimalnih 20% dobivenih Lopezovom metodom za čelike podijeljene prema R_m/R_e (Lopez 1).



Slika 6.5 Postotak vrijednosti n' nelegiranih, niskolegiranih i visokolegiranih čelika procijenjenih empirijskim metodama procjene i umjetnim neuronskim mrežama koje odstupaju do 10, 20 i 30 % od eksperimentalnih vrijednosti

Na slici 6.6 prikazani su postotci odstupanja eksponenta cikličkog deformacijskog očvršćivanja n' procijenjene odabranim empirijskim metodama i UNM razvijenom za sve čelike zajedno.




Slika 6.6 Postotak vrijednosti n' procijenjenih empirijskim metodama i umjetnim neuronskim mrežama primijenjenim na sve čelike zajedno koje odstupaju do 10, 20 i 30 % od eksperimentalnih vrijednosti

Rezultati dobiveni UNM slični su onima dobivenim mrežama za procjenu n' niskolegiranih i visokolegiranih čelika. Rezultati mreže za procjenu n' svih čelika unutar pojaseva odstupanja $\pm 20\%$ i $\pm 30\%$ je 60% i 73% , dok je postotak odstupanja vrijednosti n' dobivenih mrežama razvijenim samo za niskolegirane čelike znatno viših 76% i 82% . U usporedbi s empirijskim metodama UNM je neznatno bolja od obje Lopezove metode i Lijeve metode unutar pojasa odstupanja $\pm 30\%$, dok su unutar pojasa odstupanja $\pm 10\%$ UNM za oko 10% uspješnije.

6.4.2 Vrednovanje procijenjenih zamornih parametara

6.4.2.1 Vrednovanje procijenjenih vrijednosti koeficijenta dinamičke čvrstoće σ_f'


Na slici 6.7 prikazan je postotak vrijednosti koeficijenta dinamičke čvrstoće σ_f' za nelegirane, niskolegirane i visokolegirane čelike procijenjenih odabranim metodama (tablica 6.2) i umjetnim neuronskim mrežama (UNM) koje od eksperimentalnih vrijednosti odstupaju do $\pm 10\%$, $\pm 20\%$ i do $\pm 30\%$.



Slika 6.7 Postotak vrijednosti σ_f' nelegiranih, niskolegiranih i visokolegiranih čelika procijenjenih empirijskim metodama procjene i umjetnim neuronskim mrežama koje odstupaju do 10, 20 i 30 % od eksperimentalnih vrijednosti

Procijenjene vrijednosti σ_f' svih skupina čelika primjenom UNM podjednako su dobre, s oko 90 % procijenjenih vrijednosti koje odstupaju do $\pm 20\%$ od eksperimentalnih vrijednosti. Rezultati vrednovanja za nelegirane čelike pokazali su da je u pojasevima odstupanja $\pm 10\%$ i $\pm 20\%$ UNM bolja od svih empirijskih metoda osim modificirane metode univerzalnih nagiba pravaca, koja je podjednako dobra. Za niskolegirane čelike UNM je uspješnija od svih empirijskih metoda, posebno u pojasu $\pm 20\%$, u koji ulazi 91 % vrijednosti procijenjenih primjenom UNM, naspram najboljih empirijskih metoda, uniformnog materijalnog zakona i metode medijana gdje je taj postotak 74 %. Za procjenu koeficijenta σ_f' visokolegiranih čelika UNM su se pokazale posebno uspješnima. Sve vrijednosti σ_f' procijenjene primjenom UNM odstupaju do najviše $\pm 30\%$ od odgovarajućih eksperimentalnih vrijednosti. Najboljom empirijskom metodom (modificiranom metodom univerzalnih nagiba pravaca) taj je postotak tek 30 % što je bitno manje od postotka vrijednosti unutar pojasa odstupanja $\pm 10\%$ dobivenih UNM.

Postotci odstupanja koeficijenta dinamičke čvrstoće σ_f' procijenjene odabranim empirijskim metodama i UNM razvijenom za sve čelike zajedno prikazani su na slici 6.8.




Slika 6.8 Postotak vrijednosti σ_f' procijenjenih empirijskim metodama i umjetnim neuronskim mrežama primijenjenim na sve čelike zajedno koje odstupaju do 10, 20 i 30 % od eksperimentalnih vrijednosti

UNM razvijene za sve čelike zajedno uspješnije su od empirijskih metoda procjene, ali manje uspješne od mreža razvijenim zasebno za svaku skupinu čelika s 76 % naspram 85–90 % podataka unutar pojasa do do ± 20 % u korist mreža razvijanih za nelegirane, niskolegirane i visokolegirane čelike.

6.4.2.2 Vrednovanje procijenjenih vrijednosti eksponenta dinamičke čvrstoće b


Na slici 6.9 prikazan je postotak vrijednosti eksponenta dinamičke čvrstoće b za nelegirane, niskolegirane i visokolegirane čelike procijenjenih odabranim metodama (tablica 6.2) i umjetnim neuronskim mrežama (UNM) koje od eksperimentalnih vrijednosti odstupaju do ± 10 %, ± 20 % i ± 30 %.

Za sve skupine čelika UNM su značajno uspješnije od empirijskih metoda za procjenu eksponenta b . Te razlike najvidljivije su u pojasevima odstupanja ± 20 % za nelegirane i niskolegirane čelike, kamo ulazi 81 % odnosno 65 % podataka, dok u isti pojas odstupanja ulazi tek 63 % i 46 % vrijednosti procijenjenih empirijskim metodama. Za visokolegirane čelike 80 % procijenjenih vrijednosti odstupaju do ± 30 % od eksperimentalnih vrijednosti koeficijenta b , što je mnogo više od 30 % podataka dobivenih empirijskim metodama procjene. Sve vrijednosti procijenjene uniformnim materijalnim zakonom odstupaju više od 30 % od eksperimentalnih vrijednosti, što ne iznenađuje s obzirom na to da su za razvoj te metode korišteni samo podaci za nelegirane i niskolegirane čelike.



Slika 6.9 Postotak vrijednosti b nelegiranih, niskolegiranih i visokolegiranih čelika procijenjenih empirijskim metodama procjene i umjetnim neuronskim mrežama koje odstupaju do 10, 20 i 30 % od eksperimentalnih vrijednosti

Na slici 6.10 prikazani su postotci odstupanja eksponenta dinamičke čvrstoće b procijenjene odabranim empirijskim metodama i UNM razvijenom za sve čelike zajedno.




Slika 6.10 Postotak vrijednosti b procijenjenih empirijskim metodama i umjetnim neuronskim mrežama primijenjenim na sve čelike zajedno koje odstupaju do 10, 20 i 30 % od eksperimentalnih vrijednosti

UNM razvijene za sve čelike zajedno uspješnije su od svih empirijskih metoda procjene, s čak 93 % procijenjenih vrijednosti koje odstupaju od eksperimentalnih do ± 30 %, dok je za sve empirijske metode taj postotak oko 70 %.

Rezultati vrednovanja procijenjenih vrijednosti za eksponent dinamičke čvrstoće b ukazuju na to da se taj parametar može vrlo uspješno procijeniti na osnovi odabranih monotonih značajki, te da mu ne treba pripisivati konstantu vrijednost kao što je to predloženo u svim vrednovanim empirijskim metodama.

6.4.2.3 Vrednovanje procijenjenih vrijednosti koeficijenta cikličkih deformacija ε_f'


Postotak vrijednosti koeficijenta cikličkih deformacija ε_f' za nelegirane, niskolegirane i visokolegirane čelike procijenjenih odabranim metodama (tablica 6.2) i umjetnim neuronskim mrežama (UNM) koje od eksperimentalnih vrijednosti odstupaju do $\pm 10\%$, $\pm 20\%$ i $\pm 30\%$ prikazan je na slici 6.11.



Slika 6.11 Postotak vrijednosti ε_f' nelegiranih, niskolegiranih i visokolegiranih čelika procijenjenih empirijskim metodama procjene i umjetnim neuronskim mrežama koje odstupaju do 10, 20 i 30 % od eksperimentalnih vrijednosti

Rezultati UNM za procjenu ε_f' najlošiji su od svih mreža koje su razvijane za procjenu cikličkih i zamornih parametara. Tek 34 % odnosno 30 % vrijednosti ε_f' niskolegiranih i visokolegiranih čelika odstupa do $\pm 30\%$ od eksperimentalnih vrijednosti. Ipak, za obje skupine ti postotci su viši od onih dobivenih empirijskim metodama procjene za koje se u tom pojasu odstupanja nalazi 26 %, odnosno 20 % procijenjenih vrijednosti ε_f' niskolegiranih i visokolegiranih čelika. Rezultati za nelegirane čelike mnogo su bolji za pojas odstupanja $\pm 30\%$, u koji ulazi 62 % vrijednosti procijenjenih primjenom UNM, dok je najviši postotak za empirijske metode 38 %. Ovakvi rezultati su i očekivani, s obzirom na to da za nelegirane i niskolegirane čelike nije utvrđena statistička značajnost neke monotone značajke za procjenu koeficijenta ε_f' , pa su korištene lako dostupne monotone značajke R_m , R_e i Z .

Na slici 6.12 prikazani su postotci odstupanja koeficijenta cikličkih deformacija ε_f' procijenjene odabranim empirijskim metodama i UNM razvijenom za sve čelike zajedno.




Slika 6.12 Postotak vrijednosti ε_f' procijenjenih empirijskim metodama i umjetnim neuronskim mrežama primijenjenim na sve čelike zajedno koje odstupaju do 10, 20 i 30 % od eksperimentalnih vrijednosti

Iako su UNM nešto bolje od empirijskih metoda, ovi rezultati nisu zadovoljavajući. Ovakvi rezultati su donekle očekivani s obzirom na to da se provođenjem unaprijedne selekcije za utvrđivanje monotonih značajki relevantnih za procjenu ε_f' nelegiranih i niskolegiranih čelika nije utvrdila niti jedna relevantna značajka, a za procjenu ε_f' visokolegiranih čelika to je tek omjer vlačne čvrstoće i modula elastičnosti R_m/E . Procjena koeficijenta cikličkih deformacija ε_f' na osnovi monotonih značajki problematična je i kod empirijskih metoda procjene. Tako metode u [48] i [76] povezuju ε_f' sa stvarnim istezanjem pri lomu ε_f iz monotonih eksperimenata, u [64] i [67] mu se dodjeljuje vrijednost te monotone značajke, tj. $\varepsilon_f' = \varepsilon_f$, dok mu Meggiolaro i Castro u [57] pripisuju konstantnu vrijednost za sve čelike.

6.4.2.4 Vrednovanje procijenjenih vrijednosti eksponenta cikličkih deformacija c

Postotak vrijednosti eksponenta cikličkih deformacija c za nelegirane, niskolegirane i visokolegirane čelike procijenjenih odabranim metodama (tablica 6.2) i umjetnim neuronskim mrežama (UNM) koje od eksperimentalnih vrijednosti odstupaju do $\pm 10\%$, $\pm 20\%$ i $\pm 30\%$ prikazan je na slici 6.13.


Umjetnim neuronskim mrežama uspješno su procijenjene vrijednosti eksponenta c za sve tri skupine čelika. U usporedbi s empirijskim metodama UNM daje podjednako dobre rezultate za procjenu c nelegiranih čelika u zadanim pojasevima odstupanja, s čak 69 % vrijednosti koje odstupaju do $\pm 10\%$. Međutim, ovaj postotak jednak je čak i za uži pojas odstupanja od $\pm 5\%$, dok kod empirijskih metoda on iznosi tek maksimalno 36 % (modif. UNP i metoda tvrdoće).



Slika 6.13 Postotak vrijednosti c nelegiranih, niskolegiranih i visokolegiranih čelika procijenjenih empirijskim metodama procjene i umjetnim neuronskim mrežama koje odstupaju do 10, 20 i 30 % od eksperimentalnih vrijednosti

Rezultati UNM za niskolegirane čelike značajno su bolji u pojasevima odstupanja do $\pm 10\%$ i $\pm 20\%$, kamo ulazi 52 % i 92 % procijenjenih vrijednosti. Za visokolegirane čelike rezultati dobiveni UNM su bolji od onih dobivenih empirijskim metodama za oko 10 % u svim pojasevima odstupanja.

Postotci odstupanja eksponenta cikličkih deformacija c procijenjene odabranim empirijskim metodama i UNM razvijenom za sve čelike zajedno prikazane su na slici 6.14.



Slika 6.14 Postotak vrijednosti c procijenjenih empirijskim metodama i umjetnim neuronskim mrežama primijenjenim na sve čelike zajedno koje odstupaju do 10, 20 i 30 % od eksperimentalnih vrijednosti


Rezultati UNM bolji su od empirijskih metoda za sve pojaseve odstupanja, ponajviše za pojas odstupanja $\pm 20\%$, kamo ulazi 86 % vrijednosti c procijenjenih s UNM, a najviše 73 % onih procijenjenih nekom od empirijskih metoda. No usporede li se rezultati s onima dobivenim primjenom UNM za svaku skupinu čelika zasebno, postotci odstupanja mreža za sve čelike

djeluju kao prosjek sve tri grupe, s tim da je i primjerice 50 % podataka unutar $\pm 10\%$ mnogo bolje od 30 % dobivenih mrežom za visokolegirane čelike, ali i mnogo manje od 69 % dobivenih UNM razvijenom za nelegirane čelike.

6.5 Vrednovanje umjetnih neuronskih mreža za procjenu cikličkog i zamornog ponašanja čelika

6.5.1 Vrednovanje amplituda deformacije $\Delta\sigma/2$ proračunatih na osnovi procijenjenih cikličkih parametara

Na slici 6.15 prikazan je postotak vrijednosti amplituda naprezanja $\Delta\sigma/2$ proračunatih na osnovi vrijednosti cikličkih parametara K' i n' procijenjenih empirijskim metodama i primjenom UNM koje odstupaju do $\pm 5\%$, $\pm 10\%$, $\pm 15\%$ i $\pm 20\%$ od vrijednosti proračunatih na osnovi eksperimentalnih vrijednosti K' i n' za nelegirane, niskolegirane i visokolegirane čelike.




Slika 6.15 Postotak vrijednosti $\Delta\sigma/2$ nelegiranih, niskolegiranih i visokolegiranih čelika proračunatih na osnovi cikličkih parametara procijenjenih empirijskim metodama i umjetnim neuronskim mrežama koje odstupaju do 5, 10, 15 i 20 % od $\Delta\sigma/2$ proračunatih na osnovi eksperimentalnih vrijednosti cikličkih parametara

Vrijednosti amplituda naprezanja $\Delta\sigma/2$ proračunatih na osnovi vrijednosti K' i n' dobivenih primjenom UNM vrlo dobro se podudaraju s vrijednostima proračunatim na osnovi eksperimentalnih vrijednosti tih parametara za nelegirane i niskolegirane čelike, s oko 94 % procijenjenih vrijednosti koje odstupaju do $\pm 20\%$ od eksperimentalnih vrijednosti. Za nelegirane čelike taj postotak je neznatno lošiji od onog najbolje metode procjene (Lijeva metoda), međutim UNM rezultiraju značajno točnijim procjenama unutar pojasa odstupanja $\pm 5\%$ i $\pm 10\%$. Ti postoci su za UNM 50 % i 74 %, naspram 32 % i 66 % dobivenih najboljom

(Lijevo) empirijskom metodom. Za niskolegirane čelike Lijeva metoda i Lopezova metoda za čelike podijeljene prema omjeru R_m/R_e uspješnije su od UNM u svim pojasevima odstupanja, a posebno za pojaseve odstupanja do $\pm 5\%$ i $\pm 10\%$. To je donekle očekivano, jer su obje metode razvijane na većinom nelegiranim i niskolegiranim čelicima. Dodatna prednost Lijeve metode je i to što se parametri K' i n' ne procjenjuju u potpunosti neovisno, već se n' računa iz procijenjenih vrijednosti R_e' i K' . Za visokolegirane čelike UNM su značajno uspješnije od empirijskih metoda, s oko 42 % vrijednosti $\Delta\sigma/2$ koje odstupaju do $\pm 5\%$ od eksperimentalnih vrijednosti (dvostruko više od najbolje empirijske metode). Uspješnost procjene ponašanja visokolegiranih čelika zasigurno bi se mogla poboljšati prikupljanjem dodatnih primjera za učenje i testiranje mreže.

Na slici 6.16 prikazano je odstupanje amplituda naprežanja $\Delta\sigma/2$ proračunatih na osnovi vrijednosti cikličkih parametara K' i n' procijenjenih empirijskim metodama i primjenom UNM za sve čelike zajedno koje odstupaju do $\pm 5\%$, $\pm 10\%$, $\pm 15\%$ i $\pm 20\%$ od vrijednosti proračunatih na osnovi eksperimentalnih vrijednosti K' i n' .

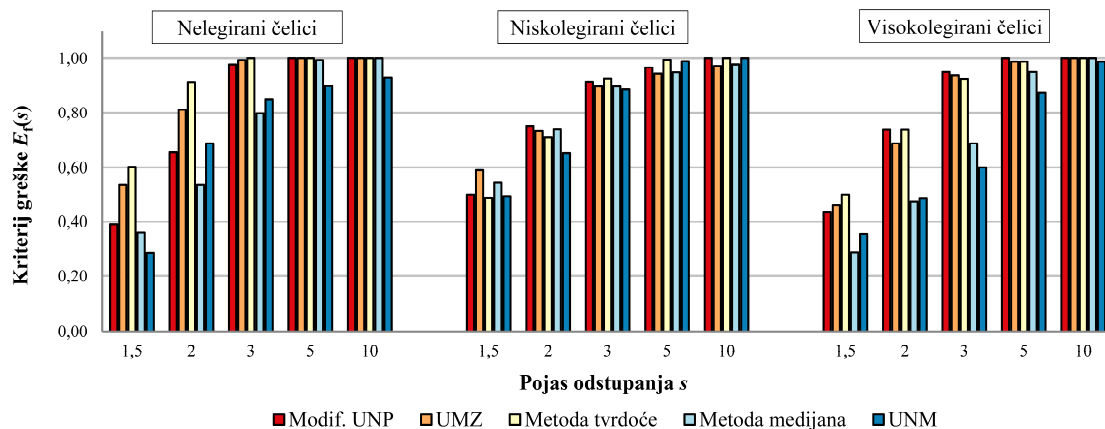


Slika 6.16 Postotak vrijednosti $\Delta\sigma/2$ proračunatih na osnovi cikličkih parametara procijenjenih empirijskim metodama i umjetnim neuronskim mrežama primijenjenim na sve čelike zajedno koje odstupaju do 5, 10, 15 i 20 % od $\Delta\sigma/2$ proračunatih na osnovi eksperimentalnih vrijednosti cikličkih parametara

UNM razvijene za sve čelike zajedno vrlo uspješno su primijenjene na procjenu amplituda ukupnog naprežanja $\Delta\sigma/2$, s 95 % proračunatih vrijednosti $\Delta\sigma/2$ koje odstupaju do $\pm 20\%$ od onih proračunatih na osnovi eksperimentalnih vrijednosti K' i n' . Međutim, mreža je tek podjednako uspješna kao i dvije najuspješnije empirijske metode procjene (Lopezova metoda za čelike podijeljene prema omjeru R_m/R_e i Lijeva metoda) i nešto manje uspješna od rezultata dobivenih zasebno za nelegirane i niskolegirane čelike unutar $\pm 20\%$ odstupanja, dok je uspješnija od UNM razvijenih za visokolegirane čelike.

6.5.2 Vrednovanje broja izmjena opterećenja do otkazivanja $2N_f$ proračunatih na osnovi procijenjenih zamornih parametara


Na slici 6.17 prikazana vrijednost kriterija greške $E_f(s)$, odnosno udio broja izmjena opterećenja do otkazivanja $2N_{f,pror}$ proračunatih na osnovi vrijednosti zamornih parametara σ_f' , b , ε_f' i c procijenjenih empirijskim metodama procjene i primjenom UNM za nelegirane, niskolegirane i visokolegirane čelike. Kriterij greške $E_f(s)$ izračunat je za pojaseve odstupanja s 1,5, 2, 3, 5 i 10 puta.



Slika 6.17 Vrijednosti kriterija greške $E_f(s)$ broja izmjena opterećenja do otkazivanja $2N_f$ proračunatih za nelegirane, niskolegirane i visokolegirane čelike na osnovi zamornih parametara σ_f' , b , ε_f' i c procijenjenih empirijskim metodama procjene i umjetnim neuronskim mrežama koje odstupaju do 1,5, 2, 3, 5 i do 10 puta od eksperimentalnih vrijednosti

Udio procijenjenih brojeva izmjena opterećenja do otkazivanja $2N_{f,pror}$ proračunatih na osnovi vrijednosti zamornih parametara σ_f' , b , ε_f' i c dobivenih primjenom UNM je, unatoč boljim rezultatima procjena pojedinih parametara, manji od udjela $2N_{f,pror}$ proračunatih na osnovi empirijskih metoda za sve tri skupine čelika. Za nelegirane čelike UNM daju značajno lošije udjele $2N_f$ od svih empirijskih metoda procjene u pojasu odstupanja do 2 i do 3 puta. Za niskolegirane čelike UNM daju približno iste rezultate kao i empirijske metode, tj. oko 90 % $2N_{f,pror}$ odstupa do 3 puta od broja izmjena opterećenja do otkazivanja $2N_{f,eksp}$ proračunatih na osnovi eksperimentalnih vrijednosti zamornih parametara.

Udio brojeva izmjena opterećenja do otkazivanja $2N_{f,pror}$ proračunatih na osnovi vrijednosti zamornih parametara σ_f' , b , ε_f' i c procijenjenih empirijskim metodama procjene i primjenom UNM razvijenih za sve čelike zajedno prikazan je na slici 6.18.



Slika 6.18 Vrijednosti kriterija greške $E_f(s)$ broja izmjena opterećenja do otkazivanja $2N_f$ proračunatih za sve čelike zajedno na osnovi zamornih parametara σ_f' , b , ε_f' i c procijenjenih empirijskim metodama procjene i umjetnim neuronskim mrežama koje odstupaju do 1,5, 2, 3, 5 i do 10 puta od eksperimentalnih vrijednosti

Mreže razvijene za sve čelike zajedno općenito daju nešto bolje vrijednosti kriterija greške $E_f(s)$ umjetnih neuronskih mreža u odnosu na mreže razvijane zasebno za nelegirane, niskolegirane i visokolegirane čelike. Udio podataka $2N_{f,pror}$ koji od $2N_{f,eksp}$ odstupaju 2 i 3 puta je 70 % i čak 93 % što je u razini većine empirijskih metoda procjene.

6.6 Zaključak

Analizom rezultata vrednovanja novopredloženog pristupa i usporedbom s rezultatima vrednovanja odabranih empirijskih metoda utvrđeno je da se predloženi pristup procjeni pokazao uspješnijim za procjenu većine cikličkih i zamornih parametara, ali i ponašanja čelika.

Uspješnost procjene parametara očituje se u većem postotku procijenjenih vrijednosti koje se nalaze unutar svih promatranih pojaseva odstupanja (npr. procjena cikličke granice tečenja R_e' nelegiranih i visokolegiranih čelika) i/ili značajno većim postotkom procijenjenih vrijednosti unutar pojedinih, užih pojaseva odstupanja. Primjer potonjeg je koeficijent cikličkog deformacijskog očvršćivanja K' nelegiranih čelika za koji 88 % vrijednosti procijenjenih UNM i 82 % vrijednosti procijenjenih najboljom empirijskom metodom odstupaju do $\pm 30\%$ od pripadajućih eksperimentalnih vrijednosti. Međutim, postotak podataka unutar pojasa $\pm 20\%$ je istih 88 % za UNM, ali bitno manjih 65 % vrijednosti procijenjenih najuspješnijom empirijskom metodom procjene. Procjena eksponenta dinamičke čvrstoće b pak, kao primjer vrlo uspješne procjene parametra primjenom UNM, ima i dodatnu važnost. U postojećim metodama tom se parametru vrlo često dodjeljivala konstantna vrijednost, dok se novim pristupom predloženim u ovom istraživanju pokazalo kako se taj parametar može vrlo uspješno

procijeniti UNM i to za sve skupine čelika (oko 80 % vrijednosti procijenjenih primjenom UNM za svaku skupinu čelika zasebno odstupa do ± 20 % od pripadajućih eksperimentalnih vrijednosti).

Usporedbom rezultata dobivenih UNM razvijenim zasebno za svaku skupinu čelika s onima razvijenim za sve čelike zajedno, ali i rezultata vrednovanja empirijskih metoda procjene, pokazano je da se razmatranjem svih čelika zajedno, bez uzimanja u obzir pojedinih skupina, najčešće dobivaju uprosječeni rezultati i gubi vrijedna informacija o specifičnosti skupina čelika, kao i o (ne)adekvatnosti pojedine metode za svaku skupinu. Primjer mnogo uspješnije procjene UNM razvijenom samo za jednu skupinu čelika je procjena koeficijenta dinamičke čvrstoće σ' visokolegiranih čelika, kojom sve procijenjene vrijednosti tog parametra odstupaju do ± 30 % od pripadajućih eksperimentalnih vrijednosti. Taj postotak dobiven najuspješnijom empirijskom metodom je vrlo skromnih 30 %.

Iako to nije bio primarni cilj istraživanja, provedeno je i vrednovanje primjene na ovaj način procijenjenih parametara na proračun amplituda naprezanja $\Delta\sigma/2$ odnosno broja izmjena opterećenja do otkazivanja $2N_f$, tj. na cikličko i zamorno ponašanje čelika. Rezultati procjene amplituda naprezanja $\Delta\sigma/2$ na osnovi procijenjenih cikličkih parametara pokazali su se boljima (za nelegirane i visokolegirane) ili podjednako dobrima (za niskolegirane čelike) u usporedbi s onima proračunatih na osnovi cikličkih parametara procijenjenih empirijskim metodama procjene. Vrednovanje broja izmjena opterećenja do otkazivanja $2N_f$ dobivenih na osnovi procijenjenih vrijednosti zamornih parametara pokazalo se nešto lošijim od onih proračunatih na osnovi najboljih empirijskih metoda, unatoč uspješnijoj procjeni pojedinačnih parametara.

Slijedom navedenog može se reći da su rezultati provedenog vrednovanja potvrdili da se umjetnim neuronskim mrežama, razvijanim zasebno za svaku skupinu nelegiranih, niskolegiranih i visokolegiranih čelika, i koristeći samo monotone značajke koje su se pokazale statistički značajnima za procjenu pojedinog parametra pojedine skupine čelika, mogu vrlo uspješno procjenjivati ciklički i zamorni parametri i ponašanje čelika grupiranih prema udjelu legirajućih elemenata.

7 Zaključak i smjernice za daljnji rad

U okviru provedenog istraživanja predložen je i razvijen novi pristup procjeni cikličkih i zamornih parametara čelika na osnovi monotonih značajki primjenom umjetnih neuronskih mreža koji omogućava vrlo uspješnu procjenu cikličkih i zamornih parametara te ponašanja nelegiranih, niskolegiranih i visokolegiranih čelika, čime je potvrđena hipoteza rada i postignut glavni cilj istraživanja.

U ovom istraživanju razvijena je potpuna i detaljna metodologija procjene cikličkih i zamornih parametara na osnovi monotonih značajki čelika primjenom umjetnih neuronskih mreža. Predložena metodologija kao prethodni korak uključuje provođenje detaljne statističke analize – unaprijedne selekcije (podvarijante postupne regresijske analize) s ciljem identifikacije monotonih značajki relevantnih za procjenu pojedinog cikličkog odnosno zamornog parametra svake skupine čelike, i integriranje tako stečenih saznanja u razvoj umjetnih neuronskih mreža za razmatrani problem. Detaljna statistička analiza koja prethodi razvoju umjetnih neuronskih mreža za procjenu cikličkih i zamornih parametara, odnosno čini njen neizostavan dio, nije poznata u prethodnim istraživanjima koja se bave ovom problematikom.

Provedeno sustavno istraživanje i kritički pregled postojećih pristupa i metoda procjene te analiza velikog broja eksperimentalnih podataka o materijalima omogućili su bolje razumijevanje problematike procjene cikličkih i zamornih parametara na osnovi monotonih značajki. Detaljnim statističkim analizama potvrđeno je postojanje statistički značajnih razlika između cikličkih i zamornih parametara nelegiranih, niskolegiranih i visokolegiranih čelika. Za čelike podijeljene u svaku od navedenih skupina utvrđeno je koje monotone značajke doprinose točnijoj procjeni spomenutih parametara pojedinih skupina čelika te se pokazalo da su za procjenu istog parametra različitih skupina čelika relevantni različiti skupovi monotonih značajki.

Skupina čelika koja je u postojećim metodama procjene često razmatrana isključivo u okviru skupina sastavljenih od svih čelika zajedno, ili čak potpuno zanemarivana, su visokolegirani čelici. Razlog tome je veliki rasap vrijednosti i razlike cikličkih i zamornih parametara

materijala unutar te skupine. Provedenim se istraživanjem, međutim, pokazalo da se predloženi pristup može uspješno primijeniti i za procjenu cikličkih i zamornih parametara i ponašanja visokolegiranih čelika, unatoč relativno skromnom broju eksperimentalnih podataka na kojima su provedene statističke analize i razvijene umjetne neuronske mreže za tu skupinu čelika.

Provedenim statističkim analizama došlo se i do važne spoznaje da se eksponent dinamičke čvrstoće b , kojem većina postojećih empirijskih metoda dodjeljuje konstantnu vrijednost, može vrlo uspješno procijeniti na osnovi relevantnih monotonih značajki i to za svaku od navedenih skupina čelika.

Vrednovanje rezultata dobivenih umjetnim neuronskim mrežama koje su razvijane zasebno za svaku skupinu čelika i uz korištenje samo onih monotonih značajki koje su se pokazale relevantnima za procjenu pojedinih parametara, pokazalo je da se njima bitno uspješnije nego empirijskim metodama mogu procjenjivati ciklički i zamorni parametri čelika. Međutim, osim vrednovanja uspješnosti procjene pojedinačnih parametara provedeno je i vrednovanje na osnovi njih proračunatih amplituda naprezanja $\Delta\sigma/2$ (cikličkog ponašanja) odnosno broja izmjena opterećenja do otkazivanja $2N_f$ (zamornog ponašanja). Utvrđeno je da se cikličko ponašanje čelika može vrlo uspješno procijeniti primjenom razvijenih umjetnih neuronskih mreža. S druge strane, vrednovanje broja izmjena opterećenja do otkazivanja $2N_f$ proračunatih na osnovi procijenjenih zamornih parametara pokazalo je da su razvijene mreže nešto manje uspješne u odnosu na najbolje empirijske metode procjene, usprkos uspješnijoj procjeni pojedinačnih parametara. Razlog tome može biti osjetljivost provedenih statističkih analiza i razvijenih umjetnih neuronskih mreža na sastav i veličinu uzorka te, posebice, raspon podataka na kojima se provodi istraživanje i razvoj, ali i vrednovanje. Umjetne neuronske mreže iznimno su osjetljive na sastav primjera za učenje i poznato je da ne mogu ekstrapolirati izvan područja na kojem su učile. U ovom se istraživanju utvrdilo i da mreže, usprkos strogoj kontroli i nastojanju da podaci korišteni za statističke analize, razvoj neuronskih mreža i njihovo vrednovanje pripadaju istoj distribuciji, ponekad rezultiraju manje točnim rezultatima. Razlog tome je upravo velika raznovrsnost i različitost kombinacija vrijednosti monotonih značajki čelika. Već i odstupanje samo jedne monotone značajke od uobičajene kombinacije vrijednosti za pojedini materijal rezultira greškom.

Slijedom rečenog valja napomenuti da ovo istraživanje nije provedeno s ciljem utvrđivanja kauzalnih veza između monotonih i cikličkih odnosno zamornih parametara. Metoda primijenjena u ovom istraživanju temeljena je na analizi i korištenju već postojećih podataka,

dok bi za utvrđivanje možebitne kauzalnosti, tj. uzročno-posljedičnih veza bilo nužno provesti statističko planiranje eksperimenta, uz potpunu kontrolu utjecajnih varijabli. Takvo istraživanje moguće je, ali za mnogo uži skup čelika, ili tek jedan materijal, s obzirom na to da na njegovo cikličko te osobito na zamorno ponašanje utječe niz faktora – kemijski sastav, toplinska obrada, mikrostruktura, stanje materijala, uvjeti okoliša i mnogi drugi. Takvo istraživanje rezultiralo bi velikim materijalnim troškovima i utroškom vremena te nije primjenjivo na širi problem procjene.

Istraživanje provedeno u okviru doktorske disertacije potaknulo je i dodatna pitanja i ideje za buduća istraživanja kojima bi se moglo proširiti i poboljšati rezultate procjene cikličkih i zamornih parametara čelika na osnovi monotonih značajki. Tijekom istraživanja utvrđeno je da rezultati statističkih analiza, ali i razvijenih umjetnih neuronskih mreža, bitno ovise o uzorku podataka na kojima je provedeno istraživanje. Stoga će prvi korak u nastavku istraživanja biti prikupljanje dodatnih podataka monotonih i cikličkih eksperimenata na sobnim, ali i povišenim temperaturama, kako bi se istraživanje moglo ponoviti i proširiti na sveobuhvatnijem uzorku podataka. Na ovaj način povećat će se primjenjivost razvijenog rješenja. Ovo je osobito važno za procjenu cikličkih i zamornih parametara visokolegiranih čelika.

Višeslojni perceptron, kao najkorištenija umjetna neuronska mreža, korišten je i u ovom istraživanju, no namjera je istražiti primjenjivost i drugih vrsta mreža, poput mreže s radijalno zasnovanom funkcijom. Osim umjetnih neuronskih mreža, rezultati provedenog istraživanja ukazuju na to da bi se i drugim naprednim regresijskim tehnikama, poput metode potporne vektorske regresije (engl. *support vector regression*, *SVR*), mogla unaprijediti procjena cikličkih i zamornih parametara s obzirom na trenutno dostupan uzorak podataka.

Zbog velikog interesa i značaja za industrijsku primjenu, usko vezanu za razvoj lakih konstrukcija, u planu je i primjena razvijene metodologije na druge skupine metalnih materijala, posebice aluminijske i titanijske slitine, koji zbog nedovoljnog broja trenutno dostupnih podataka nisu mogli biti obuhvaćeni ovim istraživanjem.

Popis literature

- [1] *AISI Bar Steel Fatigue Database*. URL: <http://barsteelfatigue.autosteel.org/>, pristupljeno 15. ožujka 2016.
- [2] Anderson, D. ; McNeill, G.: *Artificial Neural Networks Technology* (A DACS State-of-the-Art Report). Utica (NY) : Data & Analysis Center for Software, 1992.
- [3] Artymiak, P. ; Bukowski, L. ; Feliks, J. ; Narberhaus, S. ; Zenner, H.: Determination of S–N curves with the application of artificial neural networks. *Fatigue Fract. Eng. M.* **22** (1999) 723–728. doi: 10.1046/j.1460-2695.1999.t01-1-00198.x
- [4] *ASM Handbook, Vol. 01, Properties And Selection Irons, Steels, And High-Performance Alloys*. ASM International, 1993.
- [5] *ASM Handbook, Vol. 19, Fatigue and Fracture*. ASM International, 1996.
- [6] *ASTM Standard E606-92(1998): Standard practice for strain-controlled fatigue testing*. West Conshohocken (PA) : ASTM International, 1998. URL: www.astm.org
- [7] Basan, R.: *MATDAT Materials Properties Database*. V1.0. 2011. URL: <http://www.matdat.com/>, pristupljeno 15. siječnja 2016.
- [8] Basan, R.: *Zamor i oštećenje materijala boka zuba zupčanika* (Doktorska disertacija). Rijeka : Tehnički fakultet, Sveučilište u Rijeci, 2009.
- [9] Basan, R. ; Rubeša, D. ; Franulović, M. ; Križan, B.: A novel approach to the estimation of strain life fatigue parameters. *Procedia Eng.* **2** (2010) 417–426. doi: 10.1016/j.proeng.2010.03.046
- [10] Basan, R. ; Rubeša, D. ; Franulović, M. ; Marohnić, T.: Some considerations on the evaluation of methods for the estimation of fatigue parameters from monotonic properties. *Procedia Eng.* **101** (2015) 18–25. doi: 10.1016/j.proeng.2015.02.004
- [11] Basan, R. ; Franulović, M. ; Smokvina-Hanza, S.: Estimation of cyclic stress–strain curves for low-alloy steel from hardness. *Metallurgy* **49** (2010) 83–86.
- [12] Basan, R. ; Franulović, M. ; Prebil, I. ; Črnjarić-Žic, N.: Analysis of strain–life fatigue parameters and behaviour of different groups of metallic materials. *Int. J. Fatigue* **33** (2011) 484–491. doi: 10.1016/j.ijfatigue.2010.10.005

- [13] Basan, R. ; Marohnić, T. ; Prebil, I. ; Franulović, M.: Preliminary investigation of the existence of correlation between cyclic Ramberg–Osgood parameters and monotonic properties of low-alloy steels. Proceedings of the 3rd International conference MTSM 2013. Split, Hrvatska : Croatian society for mechanical technologies, 2013.
- [14] Bäuml, A. ; Seeger, T.: *Materials data for cyclic loading – Supplement 1*. Elsevier, 1990.
- [15] Blackmore, P. A.: A critical review of Baumel–Seeger method for estimating strain–life fatigue properties of metallic materials. *Eng. Integr.* **27** (2009) 6–11.
- [16] Boller, C. ; Seeger, T.: *Materials data for cyclic loading, part A–D*. Elsevier, 1987.
- [17] Devore, J.: *Probability and Statistics for Engineering and the Sciences*. 8th ed. Boston (MA) : Brooks/Cole Cengage Learning, 2011.
- [18] Dowling, N. E.: *Mechanical behavior of materials*. 3rd ed. Upper Saddle River (NJ) : Prentice Hall International, 2007.
- [19] *ERIS, Educational Repository for Intelligent Systems*. 2003. URL: eris.foi.hr
- [20] Fatemi, A. ; Zeng, Z. ; Plaseied, A.: Fatigue behavior and life predictions of notched specimens made of QT and forged microalloyed steels. *Int. J. Fatigue* **26** (2004) 663–672. doi: 10.1016/j.ijfatigue.2003.10.005
- [21] Figueira Pujol, J. C. ; Andrade Pinto, J. M.: A neural network approach to fatigue life prediction. *Int. J. Fatigue* **33** (2011) 313–322. doi: 10.1016/j.ijfatigue.2010.09.003
- [22] Frost, J.: *What Are the Effects of Multicollinearity and When Can I Ignore Them?*. Minitab Blog, 2013. URL: <http://blog.minitab.com/blog/adventures-in-statistics-2/what-are-the-effects-of-multicollinearity-and-when-can-i-ignore-them>
- [23] Furukawa, T. ; Hoffman, M.: Accurate cyclic plastic analysis using a neural network material model. *Eng. Anal. Bound. Elem.* **28** (2004) 195–204. doi: 10.1016/S0955-7997(03)00050-X
- [24] Games, P. A. ; Keselman, H. J. ; Clinch, J. J.: Tests for homogeneity of variance in factorial designs. *Psych. Bull.* **86** (1979) 5: 978–984. doi: 10.1037/0033-2909.86.5.978
- [25] Genel, K.: Application of artificial neural network for predicting strain–life fatigue properties of steels on the basis of tensile tests. *Int. J. Fatigue* **26** (2004) 1027–1035. doi: 10.1016/j.ijfatigue.2004.03.009
- [26] Ghajar, R. ; Naserifar, N. ; Sadati, H. ; Alizadeh K., J.: A neural network approach for predicting steel properties characterizing cyclic Ramberg–Osgood equation. *Fatigue Fract. Eng. M.* **34** (2011) 7: 534–544. doi:10.1111/j.1460-2695.2010.01545.x
- [27] Hagan, M. T. ; Demuth, H. B. ; Hudson Beale, M.: *Neural Network Design*. 2nd ed. Martin Hagan, 2014.

- [28] Haykin, S.: *Neural Networks and Learning Machines*. 3rd ed. Pearson, 2009.
- [29] Hatscher, A. ; Seeger T ; Zenner H.: Abschätzung von zyklischen Werkstoffkennwerten – Erweiterung und Vergleich bisheriger Ansätze. *Materialprüfung* **49** (2007) 3: 2–14. doi: 10.3139/120.100795
- [30] Jain, A. K. ; Mao, J. ; Mohiuddin, K. M.: Artificial Neural Networks: A Tutorial. *Computer* **29** (1996) 3: 31–44.
- [31] Janežič, M. ; Klemenc, J. ; Fajdiga, M.: A neural-network approach to describe the scatter of cyclic stress–strain curves. *Mater. Des.* **31** (2010) 438–448. doi: 10.1016/j.matdes.2009.05.044
- [32] Jen, Y.-M. ; Wang, W.-W.: Crack initiation life prediction for solid cylinders with transverse circular holes under in-phase and out-of-phase multiaxial loading. *Int. J. Fatigue* **27** (2005) 527–539. doi: 10.1016/j.ijfatigue.2004.09.007
- [33] Jeon, W.-S. ; Song, J.-H.: An expert system for estimation of fatigue properties of metallic materials. *Int. J. Fatigue* **24** (2002) 685–698. doi: 10.1016/S0142-1123(01)00184-0
- [34] Jones, D. J. ; Kurath, P.: *Cyclic Fatigue Damage Characteristics Observed for Simple Loadings Extended to Multiaxial Life Prediction* (NASA Contractor Report 182126). Urbana, Illinois : University of Illinois, 1988.
- [35] Kang, J.-Y. ; Choia, B.-I. ; Lee, H.-J. ; Kimb, J.-S. ; Kim, K.-J.: Neural network application in fatigue damage analysis under multiaxial random loadings. *Int. J. Fatigue* **28** (2006) 132–140. doi: 10.1016/j.ijfatigue.2005.04.012
- [36] Kim, K. S. ; Chen, X. ; Han, C. ; Lee, H. W.: Estimation methods for fatigue properties of steels under axial and torsional loading. *Int. J. Fatigue* **24** (2002) 783–793.
- [37] Koh, S. K. ; Stephens, R.I.: Mean stress effects on low cycle fatigue for a high strength steel. *Fatigue Fract. Eng. M.* **14** (1991) 14: 413–428. doi: 10.1111/j.1460-2695.1991.tb00672.x
- [38] Kutner, M. H. ; Nachtsheim, C. J. ; Neter, J. ; Li, W.: *Applied Linear Statistical Models*. 5th ed. McGraw-Hill/Irwin, 2004.
- [39] Landgraf, R. W. ; Morrow, J. ; Endo, T.: Determination of cyclic stress–strain curve. *J. Mater. (JMSLA)* **4** (1969) 1: 176–188.
- [40] Landgraf, R. W.: *Cyclic Deformation and Fatigue Behavior of Hardened Steels* (T.&A.M. Report No. 320). Urbana, Illinois : Universtiy of Illinois, 1968.
- [41] Lemaitre, J. ; Chaboche, J. L.: *Mechanics of Solid Materials*. Cambridge University Press, 1994.

- [42] Li, J. ; Sun, Q. ; Zhang, Z. ; Li, C. ; Qiao, Y.: Theoretical estimation to the cyclic yield strength and fatigue limit for alloy steels. *Mech. Res. Commun.* **36** (2009) 316–321. doi: 10.1016/j.mechrescom.2008.10.011
- [43] Li, J. ; Zhang, Z. ; Li, C.: An improved method for estimation of Ramberg–Osgood curves of steels from monotonic tensile properties. *Fatigue Fract. Eng. M.* **39** (2016) 412–426. doi: 0.1111/ffe.12366
- [44] Lopez, Z. ; Fatemi, A.: A method of predicting cyclic stress–strain curve from tensile properties for steels. *Mat. Sci. Eng. A* **556** (2012) 540–550. doi: 10.1016/j.msea.2012.07.024
- [45] MacKay, D. J. C.: Bayesian Interpolation. *Neural Comput.* **4** (1992) 3: 415–447. doi: 10.1162/neco.1992.4.3.415
- [46] MacKay, D. J. C.: A Practical Bayesian Framework for Backpropagation Networks. *Neural Comput.* **4** (1992) 3: 448–472. doi: 10.1162/neco.1992.4.3.448
- [47] MacKay, D. J. C.: *Bayesian Methods for Neural Networks: Theory and Applications* (Neural Networks Summer School, Course Notes). University of Cambridge, 1995. URL: <http://www.inference.phy.cam.ac.uk/mackay/BayesNets.html>
- [48] Manson, S. S.: Fatigue: A complex subject – some simple approximations. *Exp. Mech. SESA* **5** (1965) 7: 193–226.
- [49] Manson, S. S. ; Halford, G. R.: *Fatigue and durability of structural materials*. Materials Park (OH) : ASM International, 2005.
- [50] Marohnić, T. ; Basan, R. ; Franulović, M.: Evaluation of the Possibility of Estimating Cyclic Stress–strain Parameters and Curves from Monotonic Properties of Steels. *Procedia Eng.* **101** (2015) 277–284. doi:10.1016/j.proeng.2015.02.029
- [51] Marohnić, T. ; Basan, R.: Study of Monotonic Properties’ Relevance for Estimation of Cyclic Yield Stress and Ramberg–Osgood Parameters of Steels. *J. Mater. Eng. Perform.* **25** (2016) 11: 4812–4823. doi:10.1007/s11665-016-2311-1
- [52] Marohnić, T. ; Basan, R. ; Franulović, M.: Evaluation of Methods for Estimation of Cyclic Stress–Strain Parameters from Monotonic Properties of Steels. *Metals* **7** (2017) 1–15. doi: 10.3390/met7010017
- [53] Mathew, M. D. ; Kimb, D. W. ; Ryub, W.-S.: A neural network model to predict low cycle fatigue life of nitrogen-alloyed 316L stainless steel. *Mat. Sci. Eng. A* **474** (2008) 247–253. doi: 10.1016/j.msea.2007.04.018
- [54] *MATLAB i Neural Network Toolbox R2010b*. Programski paket, Natick (MA) : The MathWorks, Inc., 2010.

- [55] *MATLAB, Neural Network Toolbox, User's Guide, Ver. 8*. Dokumentacija, Natick (MA) : The MathWorks, Inc., 2015.
- [56] *MATLAB Documentation*. Dokumentacija, Natick (MA) : The MathWorks, Inc., 2015. URL: <https://www.mathworks.com/help/matlab/>
- [57] Meggiolaro, M. A. ; Castro, J. T. P.: Statistical evaluation of strain–life fatigue crack initiation predictions. *Int. J. Fatigue* **26** (2004) 5: 463–476. doi: 10.1016/j.ijfatigue.2003.10.003
- [58] Mendenhall, W. ; Sincich, T.: *A second Course in Statistics: Regression analysis*. 7th ed. Prentice Hall (Pearson Education), 2011.
- [59] *Minitab 17 One-Way ANOVA*, Minitab assistant white paper. State College, PA: Minitab, Inc., 2010. URL: www.minitab.com
- [60] *Minitab 17 Statistical Software*. Programski paket, State College (PA) : Minitab, Inc., 2010. URL: www.minitab.com
- [61] *Minitab 17 Support*. Dokumentacija, State College (PA) : Minitab, Inc., 2010. URL: www.minitab.com
- [62] *Minitab 17 Test for Standard Deviations (Two or More Samples)*, Minitab assistant white paper. State College (PA) : Minitab, Inc., 2014. URL: www.minitab.com
- [63] Montgomery, D. C. ; Runger, G. C.: *Applied Statistics and Probability for Engineers*. 3rd ed. John Wiley and Sons, Inc, 2003.
- [64] Muralidharan, U. ; Manson, S. S.: A modified universal slopes equation for estimation of fatigue characteristics of metals. *J. Eng. Mater. Technol.* **110** (1988) 1: 55–58.
- [65] Nguyen, D. ; Widrow, B.: Improving the learning speed of 2-layer neural networks by choosing initial values of the adaptive weights. Proceedings of the IJCNN, 1990, 3, 21–26.
- [66] Nieslony, A. ; El Dsoki, C. ; Kaufmann, H. ; Krug, P.: New method for evaluation of the Manson–Coffin–Basquin and Ramberg–Osgood equations with respect to compatibility. *Int. J. Fatigue* **30** (2008) 1967–1977. doi: 10.1016/j.ijfatigue.2008.01.012
- [67] Ong, J. H.: An improved technique for the prediction of axial fatigue life from tensile data. *Int. J. Fatigue* **15** (1993) 213–219.
- [68] Park, J. H. ; Song, J. H.: Detailed evaluation of methods for estimation of fatigue properties. *Int. J. Fatigue* **17** (1995) 365–373.
- [69] Peixoto, J. L.: Hierarchical Variable Selection in Polynomial Regression Models. *Am. Stat.* **41** (1987) 4: 311–313.

- [70] Peixoto, J. L.: A Property of Well-Formulated Polynomial Regression Models. *Am. Stat.* **44** (1990) 1: 26–30.
- [71] Pleune, T. T. ; Chopra, O. K.: Using artificial neural networks to predict the fatigue life of carbon and low-alloy steels. *Nucl. Eng. Des.* **197** (2000) 1-2: 1–12. doi: 10.1016/S0029-5493(99)00252-6
- [72] Ramberg, W. ; Osgood, W. R.: *Description of stress–strain curves by three parameters* (Technical note no. 902). Washington (DC) : National Advisory Committee for Aeronautics (NACA), 1943.
- [73] Roessle, M. L. ; Fatemi, A.: Strain-controlled fatigue properties of steels and some simple approximations. *Int. J. Fatigue* **22** (2000) 495–511. doi:10.1016/S0142-1123(00)00026-8
- [74] Rojas, R.: *Neural Networks: A Systematic Introduction*. Berlin : Springer–Verlag, 1996.
- [75] Smith, R. W. ; Hirschberg, M. H. ; Manson, S. S.: *Fatigue behavior of materials under strain cycling in low and intermediate life range* (Technical note D-1574). Cleveland (OH) : National Aeronautics and Space Administration (NASA), 1963.
- [76] Socie, D. F. ; Mitchell, M. R. ; Caulfield, E. M.: *Fundamentals of Modern Fatigue Analysis* (FCP Report No. 26). Urbana (IL) : University of Illinois, 1978.
- [77] Srinivasan, V. S. ; Valsan, M. ; Bhanu Sankara Rao, K. ; Mannan, S. L. ; Raj, B.: Low cycle fatigue and creep–fatigue interaction behavior of 316L(N) stainless steel and life prediction by artificial neural network approach. *Int. J. Fatigue* **25** (2003) 1327–1338. doi: 10.1016/S0142-1123(03)00064-1
- [78] Stephens, R. I. ; Fatemi, A. ; Stephens, R. R. ; Fuchs, H. O.: *Metal Fatigue in Engineering*. 2nd ed. New York (NY) : John Wiley & Sons, 2000.
- [79] Subramanya Sarma, V. ; Padmanabhan, K. A.: Low cycle fatigue behaviour of a medium carbon microalloyed steel. *Int. J. Fatigue* **19** (1997) 2: 135–140. doi: 10.1016/S0142-1123(96)00060-6
- [80] *Technical Report on Low Cycle Fatigue Properties Ferrous and Non-Ferrous of Materials* (J1099_197502). Society of Automotive Engineers (SAE), 1975.
- [81] *Technical Report on Low Cycle Fatigue Properties Ferrous and Non-Ferrous of Materials* (J1099_200208). Society of Automotive Engineers (SAE), 2002.
- [82] Tomasella, A. ; El Dsoki, C. ; Hanselka, H. ; Kaufmann, H.: A computational estimation of cyclic material properties using artificial neural networks. *Procedia Eng.* **10** (2011) 439–445. doi: 10.1016/j.proeng.2011.04.075

- [83] Troshchenko, V. T. ; Khamaza, L. A.: Strain–life curves of steels and methods for determining the curve parameters. Part 1. Conventional methods. *Strength Mater.* **42** (2010) 6: 647–659. doi:10.1007/s11223-010-9253-x
- [84] Troshchenko, V. T. ; Khamaza, L. A. ; Apostolyuk, V. A. ; Babich, Yu. N.: Strain–life curves of steels and methods for determining the curve parameters. Part 2. Methods based on the use of artificial neural networks. *Strength Mater.* **43** (2011) 1: 1–14. doi: 10.1007/s11223-011-9262-4
- [85] Vassilopoulos, A. P. ; Georgopoulos, E. F. ; Dionysopoulos, V.: Artificial neural networks in spectrum fatigue life prediction of composite materials. *Int. J. Fatigue* **29** (2007) 20–29. doi: 10.1016/j.ijfatigue.2006.03.004
- [86] Vignaux, P. D.: *William of Ockham*. Encyclopaedia Britannica Online, 1998. URL: www.britannica.com
- [87] Wang, Y.-Y. ; Yao, W.-X.: A multiaxial fatigue criterion for various metallic materials under proportional and nonproportional loading. *Int. J. Fatigue* **28** (2006) 401–408. doi: 10.1016/j.ijfatigue.2005.07.007
- [88] Williams, C. R. ; Lee, Y.-L. ; Rilly, J. T.: A practical method for statistical analysis of strain–life fatigue data. *Int. J. Fatigue* **25** (2003) 427–436. doi: 10.1016/S0142-1123(02)00119-6
- [89] Zhang, Z. ; Wu, W. ; Chen, D. ; Sun, Q. ; Zhao, W.: New Formula Relating the Yield Stress–Strain With the Strength Coefficient and the Strain-Hardening Exponent. *J. Mater. Eng. Perform.* **13** (2004) 509–512. doi: 10.1361/10599490420070
- [90] Zhang, Z. ; Li, J. ; Sun, Q. ; Qiao, Y. ; Li, C.: Two Parameters Describing Cyclic Hardening/Softening Behaviors of Metallic Materials. *J. Mater. Eng. Perform.* **18** (2009) 237–244. doi: 10.1007/s11665-008-9287-4
- [91] Zhang, Z. ; Qiao, Y. ; Sun, Q. ; Li, C. ; Li, J.: Theoretical estimation to the cyclic strength coefficient and the cyclic strain-hardening exponent for metallic materials: Preliminary study. *J. Mater. Eng. Perform.* **18** (2009) 245–254. doi: 10.1007/s11665-008-9286-5

Popis znakova i kratica

Znakovi

$2N_f$	broj izmjena opterećenja do otkazivanja
$2N_{f,eksp}$	broj izmjena opterećenja do otkazivanja proračunat na osnovi zamornih parametara dobivenih eksperimentom
$2N_{f,pror}$	broj izmjena opterećenja do otkazivanja proračunat na osnovi procijenjenih zamornih parametara
$2N_T$	broj izmjena opterećenja koji odgovara točki tranzicije
A	trenutna površina poprečnog presjeka, mm^2
A_0	početna površina poprečnog presjeka, mm^2
A_5	istezanje pri lomu za kratke ispitne uzorke, omjer početne duljine i promjera ispitnog uzorka kružnog poprečnog presjeka $l_0/d_0 = 5$, %
A_{80}	istezanje pri lomu ispitnog uzorka duljine $l_0 = 80$ mm, %
A_g	plastično istezanje
b	eksponent dinamičke čvrstoće
b_k	pristrani član u neuronskoj mreži
c	eksponent cikličkih deformacija
\mathbf{d}	vektor željenih izlaznih vrijednosti umjetne neuronske mreže
d_0	promjer ispitnog uzorka kružnog poprečnog presjeka, mm
$d_j(n)$	željena izlazna vrijednost neurona j u trenutku n
df_F	stupnjevi slobode punog modela
df_R	stupnjevi slobode reduciranog modela
E	modul elastičnosti, MPa
$E(n)$	ukupna trenutna vrijednost funkcije pogreške
$E_{ans,test}$	srednja vrijednost funkcije pogreške ansambla umjetnih neuronskih mreža na uzorku za testiranje
$E_f(s)$	kriterij greške
$E_j(n)$	funkcija pogreške neurona j u trenutku n
$E_{med,ans}$	medijan vrijednosti funkcije pogreške ansambla umjetnih neuronskih mreža

$E_{\min,ans}$	najmanja vrijednost funkcije pogreške ansambla umjetnih neuronskih mreža
E_{sred}	srednje kvadratno odstupanje
$E_{sred,ans}$	srednje kvadratno odstupanje ansambla umjetnih neuronskih mreža
E_w	suma kvadrata svih težina umjetne neuronske mreže
e	inženjerska deformacija
e_i	pogreška modela višestruke regresije
$e_j(n)$	pogreška neurona j u trenutku n
F	vlačna sila, N
F_0	vrijednost F -statistike iz jednofaktorske ANOVA-e
$f_{\alpha,a-1,(n-1)}$	kritična vrijednost kumulativne f -distribucije za razinu značajnosti α , stupnjeva slobode brojnika $a - 1$ i nazivnika $n - 1$
$f_{\alpha,k,n-p}$	kritična vrijednost kumulativne f -distribucije za razinu značajnosti α , stupnjeva slobode brojnika k i nazivnika $n - p$
$f_{\alpha,r,n-p}$	kritična vrijednost kumulativne f -distribucije za razinu značajnosti α , stupnjeva slobode brojnika r i nazivnika $n - p$
\mathbf{g}	gradijent funkcije pogreške
H	broj neurona u skrivenom sloju umjetne neuronske mreže
H_0	hipoteza koja se testira
H_1	alternativna hipoteza
HB	Brinellova tvrdoća, HB
I	broj ulaznih vektora u umjetnu neuronsku mrežu
i	broj uzoraka koji se uspoređuju jednofaktorskom ANOVA-om ili Welchovim testom; broj opažanja u modelu višestruke regresije; broj elemenata ulaznog vektora i vektora željenih izlaznih vrijednosti umjetne neuronske mreže
K	koeficijent deformacijskog očvršćivanja, MPa
K'	koeficijent cikličkog deformacijskog očvršćivanja, MPa
K_t	teorijski faktor koncentracije naprezanja
k	broj prediktorskih varijabli u modelu višestruke regresije; broj podskupova unakrsne validacije
l	trenutna duljina ispitnog uzorka, mm
l_0	početna duljina ispitnog uzorka, mm
MS_E	prosječna suma kvadrata pogreške (engl. <i>error mean square</i>)
MS_R	prosječna suma kvadrata odstupanja modela (engl. <i>regression mean square</i>)
MS_{Treat}	prosječna suma kvadrata odstupanja između uzoraka (engl. <i>treatment mean square</i>)

N_{eq}	broj jednadžbi za treniranje umjetne neuronske mreže
N_f	broj ciklusa opterećenja do otkazivanja
N_{tren}	broj primjera za učenje umjetne neuronske mreže
N_w	broj sinaptičkih veza umjetne neuronske mreže
n	eksponent deformacijskog očvršćivanja
n'	eksponent cikličkog deformacijskog očvršćivanja
n_i	broj opažanja u uzorku
O	broj izlaznih vektora iz umjetne neuronske mreže
R	regularizacijski član
R^2	koeficijent determinacije
R_{adj}^2	prilagođeni koeficijent determinacije
R_e	granica tečenja, MPa
R_e'	ciklička granica tečenja, MPa
R_j^2	koeficijent determinacije kad je jedan od prediktora u ulozi zavisne varijable
$R_{jack-knife}^2$	koeficijent determinacije za buduća predviđanja
R_m	vlačna čvrstoća, MPa
R_{pred}^2	koeficijent determinacije za buduća predviđanja na neovisnom uzorku
R_{seq}^2	parcijalni (sekvencijalni) koeficijent determinacije
R_ε	faktor asimetrije opterećenja
$RMSE_{sred, test}$	korijen srednjeg kvadratnog odstupanja ansambla umjetnih neuronskih mreža na uzorku za testiranje
r	koeficijent korelacije; stupanj slobode sekvencijalne sume kvadrata odstupanja
r_{test}	koeficijent korelacije između željenih i stvarnih izlaza mreže
S	inženjersko naprezanje, MPa
SS_E	suma kvadrata pogreške (engl. <i>error sum of squares</i>)
SS_R	suma kvadrata odstupanja modela (engl. <i>regression sum of squares</i>)
$SS_R(B B_j)$	sekvencijalna suma kvadrata odstupanja (engl. <i>sequential sum of squares</i>)
$SS_R(F)$	suma kvadrata odstupanja punog modela
$SS_R(R)$	suma kvadrata odstupanja reduciranog modela
SS_T	ukupna suma kvadrata odstupanja (engl. <i>total sum of squares</i>)
SS_{Treat}	suma kvadrata odstupanja između uzoraka (engl. <i>treatment sum of squares</i>)
s	pojas odstupanja
T	temperatura, °C
u_k	suma umnožaka ulaznih signala s težinama u umjetnoj neuronskoj mreži

VIF	faktor inflacije varijance (engl. <i>variance inflation factor</i>)
v_k	suma u_k i pristranog člana b_k
\mathbf{w}	vektor težina u mreži
w_{kj}	sinaptičke težine u umjetnoj neuronskoj mreži
X'	normalizirana vrijednost elementa ulaznog vektora
X_{\max}	maksimalna vrijednost elemenata ulaznog vektora u umjetnu neuronsku mrežu
X_{\min}	minimalna vrijednost elemenata ulaznog vektora u umjetnu neuronsku mrežu
\mathbf{x}	vektor ulaza u umjetnu neuronsku mrežu
x_{ij}	vrijednost j -tog prediktora za i -to opažanje u modelu višestruke regresije
x_j	prediktorska varijabla u modelu višestruke linearne regresije; ulazni signal j -te sinapse u neuron umjetne neuronske mreže
\bar{y}	srednja vrijednost zavisne varijable
y_i	vrijednost zavisne varijable za i -to opažanje u modelu višestruke regresije
\hat{y}_i	vrijednost zavisne varijable za i -to opažanje procijenjena modelom višestruke regresije
$y_j(n)$	stvarna izlazna vrijednost neurona j u trenutku n
y_k	izlaz iz neurona umjetne neuronske mreže
Z	smanjenje poprečnog presjeka pri lomu, %
α	tzv. novi parametar loma, %; razina značajnosti; koeficijent regularizacije sume kvadrata svih težina umjetne neuronske mreže
β	koeficijent regularizacije srednjeg kvadratnog odstupanja umjetne neuronske mreže
β_j	parametar regresije
Δl	produljenje ispitnog uzorka, mm
$\Delta \mathbf{w}$	vektor promjena težina vektora \mathbf{w} između dva koraka u učenju umjetne neuronske mreže
$\Delta \varepsilon$	raspon ukupne deformacije
$\Delta \varepsilon^*$	raspon elastične deformacije kod 10^4 ciklusa opterećenja
$\Delta \varepsilon/2$	amplituda ukupne deformacije
$\Delta \varepsilon_e$	raspon elastične deformacije
$\Delta \varepsilon_e/2$	amplituda elastične deformacije
$\Delta \varepsilon_p$	raspon plastične deformacije
$\Delta \varepsilon_p/2$	amplituda plastične deformacije

$\Delta\varepsilon_T/2$	amplituda ukupne deformacije koja odgovara točki tranzicije
$\Delta\sigma$	raspon normalnog naprezanja, MPa
$\Delta\sigma/2$	amplituda normalnog naprezanja, MPa
ε	ukupna deformacija; pogreška aproksimacije u modelu višestruke regresije
ε_e	elastična deformacija
ε_f	stvarno istežanje pri lomu
ε_f'	koeficijent cikličkih deformacija
ε_p	plastična deformacija
η	stopa učenja
λ	regularizacijski koeficijent
ν	Poissonov koeficijent
σ	naprezanje; varijanca uzorka
σ^2	standardna devijacija uzorka
σ_f	stvarno naprezanje pri lomu, MPa
σ_f'	koeficijent dinamičke čvrstoće, MPa
σ_m	srednje naprezanje, MPa
φ	aktivacijska funkcija neurona
φ_v	ukupna ekvivalentna plastična deformacija

Ostali indeksi

ans	ansambl mreža
j	ulazni signal kojeg j -ta sinapsa veže s neuronom k
k	redni broj neurona
max	najveća vrijednost
med	medijan
min	najmanja vrijednost
sred	srednja vrijednost
test	uzorak za testiranje
tren	uzorak za treniranje

Kratice

ANOVA	analiza varijance
BCM	Basquin–Coffin–Manson
BR	algoritam s Bayesovom regularizacijom
CAE	Computer Aided Engineering (hrv. računalom podržano inženjerstvo)
LM	Levenberg–Marquadtov algoritam
LM-rz	Levenberg–Marquadtov algoritam s ranim zaustavljanjem
Modif. UNP	modificirana metoda univerzalnih nagiba pravaca
<i>NaN</i>	Not-a-Number (engl.)
NČ	niskolegirani čelici
NeČ	nelegirani čelici
RO	Ramberg–Osgood
UMZ	uniformni materijalni zakon
UNM	umjetne neuronske mreže
VČ	visokolegirani čelici

Popis slika i tablica

Slike

Slika 1.1 Dijagram toka konstruiranja s obzirom na vijek trajanja, prema [78]	2
Slika 2.1 Dijagram ovisnosti naprezanja i deformacije σ – ε dobivenih monotonim vlačnim eksperimentom, prema [5]	10
Slika 2.2 Ovisnost stvarnih naprezanja i stvarnih plastičnih deformacija σ – ε_p , prema [5]	11
Slika 2.3 Ponašanje materijala pod djelovanjem cikličkog opterećenja u eksperimentima s konstantnom amplitudom deformacije $\Delta\varepsilon/2$: a) cikličko očvršćivanje, b) cikličko oslabljivanje, prema [41]	13
Slika 2.4 Histerezna petlja naprezanje–deformacija	14
Slika 2.5 Ciklička krivulja naprezanje–deformacija dobivena spajanjem vrhova stabiliziranih histerezni petlji, prema [8]	14
Slika 2.6 Ovisnost amplituda naprezanja o amplitudama plastičnih deformacija $\Delta\sigma/2$ – $\Delta\varepsilon_p/2$, prema [5]	15
Slika 2.7 Ovisnost broja izmjena opterećenja do otkazivanja o amplitudi elastične deformacije $\Delta\varepsilon_e/2$ – $2N_f$, prema [76]	19
Slika 2.8 Ovisnost broja izmjena opterećenja do otkazivanja o amplitudi plastične deformacije $\Delta\varepsilon_p/2$ – $2N_f$, prema [76]	19
Slika 2.9 Ovisnosti broja izmjena opterećenja do otkazivanja $2N_f$ o amplitudi elastične $\Delta\varepsilon_e/2$, plastične $\Delta\varepsilon_p/2$ i ukupne $\Delta\varepsilon/2$ deformacije, prema [5]	20
Slika 4.1 Dijagram toka za identifikaciju relevantnih monotonih značajki, prema [51]	60
Slika 5.1 Prikaz biološkog neurona, prema [30]	75
Slika 5.2 Nelinearni model neurona k , prema [28]	76
Slika 5.3 Vrste mrežne arhitekture, prema [30]	79
Slika 5.4 Potpuno povezani višeslojni perceptron s dva skrivena sloja, prema [28]	81
Slika 5.5 Tok ulaznih signala i signala pogreške u višeslojnom perceptronu, prema [28]	82
Slika 5.6 a) Prenaučen model, b) model koji dobro generalizira, prema [27]	86

Slika 5.7 Metoda ranog zaustavljanja, prema [28].....	88
Slika 5.8 k -struka unakrsna validacija, prema [28].....	88
Slika 5.9 Dijagram toka modeliranja umjetnih neuronskih mreža.....	91
Slika 5.10 Ovisnost funkcije pogreške o broju neurona u skrivenom sloju mreža treniranih za procjenu cikličke granice tečenja nelegiranih čelika R_e' , ispis iz programskog paketa MATLAB.....	99
Slika 5.11 Ovisnost koeficijenta determinacije R^2 i prilagođenog koeficijenta determinacije R_{adj}^2 o broju neurona u skrivenom sloju mreža treniranih za procjenu cikličke granice tečenja nelegiranih čelika R_e' , ispis iz programskog paketa MATLAB ..	100
Slika 5.12 Dijagram rasipanja vrijednosti cikličke granice tečenja R_e' dobivenih mrežom s 10 neurona u skrivenom sloju, 10-strukom unakrsnom validacijom i Levenberg–Marquadtovim algoritmom za učenje pogreške s ranim zaustavljanjem (sve mreže, testni uzorak), ispis iz programskog paketa MATLAB ..	102
Slika 6.1 Postotak vrijednosti R_e' nelegiranih, niskolegiranih i visokolegiranih čelika procijenjenih empirijskim metodama procjene i umjetnim neuronskim mrežama koje odstupaju do 5, 10, 15 i 20 % od eksperimentalnih vrijednosti.....	112
Slika 6.2 Postotak vrijednosti R_e' procijenjenih empirijskim metodama i umjetnim neuronskim mrežama primijenjenim na sve čelike zajedno koje odstupaju do 5, 10, 15 i 20 % od eksperimentalnih vrijednosti.....	113
Slika 6.3 Postotak vrijednosti K' nelegiranih, niskolegiranih i visokolegiranih čelika procijenjenih empirijskim metodama procjene i umjetnim neuronskim mrežama koje odstupaju do 10, 20 i 30 % od eksperimentalnih vrijednosti.....	114
Slika 6.4 Postotak vrijednosti K' procijenjenih empirijskim metodama i umjetnim neuronskim mrežama primijenjenim na sve čelike zajedno koje odstupaju do 10, 20 i 30 % od eksperimentalnih vrijednosti.....	115
Slika 6.5 Postotak vrijednosti n' nelegiranih, niskolegiranih i visokolegiranih čelika procijenjenih empirijskim metodama procjene i umjetnim neuronskim mrežama koje odstupaju do 10, 20 i 30 % od eksperimentalnih vrijednosti.....	116
Slika 6.6 Postotak vrijednosti n' procijenjenih empirijskim metodama i umjetnim neuronskim mrežama primijenjenim na sve čelike zajedno koje odstupaju do 10, 20 i 30 % od eksperimentalnih vrijednosti.....	116
Slika 6.7 Postotak vrijednosti σ_r' nelegiranih, niskolegiranih i visokolegiranih čelika procijenjenih empirijskim metodama procjene i umjetnim neuronskim mrežama koje odstupaju do 10, 20 i 30 % od eksperimentalnih vrijednosti.....	117

Slika 6.8 Postotak vrijednosti σ_f' procijenjenih empirijskim metodama i umjetnim neuronskim mrežama primijenjenim na sve čelike zajedno koje odstupaju do 10, 20 i 30 % od eksperimentalnih vrijednosti.....	118
Slika 6.9 Postotak vrijednosti b nelegiranih, niskolegiranih i visokolegiranih čelika procijenjenih empirijskim metodama procjene i umjetnim neuronskim mrežama koje odstupaju do 10, 20 i 30 % od eksperimentalnih vrijednosti.....	119
Slika 6.10 Postotak vrijednosti b procijenjenih empirijskim metodama i umjetnim neuronskim mrežama primijenjenim na sve čelike zajedno koje odstupaju do 10, 20 i 30 % od eksperimentalnih vrijednosti	119
Slika 6.11 Postotak vrijednosti ε_f' nelegiranih, niskolegiranih i visokolegiranih čelika procijenjenih empirijskim metodama procjene i umjetnim neuronskim mrežama koje odstupaju do 10, 20 i 30 % od eksperimentalnih vrijednosti	120
Slika 6.12 Postotak vrijednosti ε_f' procijenjenih empirijskim metodama i umjetnim neuronskim mrežama primijenjenim na sve čelike zajedno koje odstupaju do 10, 20 i 30 % od eksperimentalnih vrijednosti.....	121
Slika 6.13 Postotak vrijednosti c nelegiranih, niskolegiranih i visokolegiranih čelika procijenjenih empirijskim metodama procjene i umjetnim neuronskim mrežama koje odstupaju do 10, 20 i 30 % od eksperimentalnih vrijednosti	122
Slika 6.14 Postotak vrijednosti c procijenjenih empirijskim metodama i umjetnim neuronskim mrežama primijenjenim na sve čelike zajedno koje odstupaju do 10, 20 i 30 % od eksperimentalnih vrijednosti	122
Slika 6.15 Postotak vrijednosti $\Delta\sigma/2$ nelegiranih, niskolegiranih i visokolegiranih čelika proračunatih na osnovi cikličkih parametara procijenjenih empirijskim metodama i umjetnim neuronskim mrežama koje odstupaju do 5, 10, 15 i 20 % od $\Delta\sigma/2$ proračunatih na osnovi eksperimentalnih vrijednosti cikličkih parametara.....	123
Slika 6.16 Postotak vrijednosti $\Delta\sigma/2$ proračunatih na osnovi cikličkih parametara procijenjenih empirijskim metodama i umjetnim neuronskim mrežama primijenjenim na sve čelike zajedno koje odstupaju do 5, 10, 15 i 20 % od $\Delta\sigma/2$ proračunatih na osnovi eksperimentalnih vrijednosti cikličkih parametara.....	124
Slika 6.17 Vrijednosti kriterija greške $E_f(s)$ broja izmjena opterećenja do otkazivanja $2N_f$ proračunatih za nelegirane, niskolegirane i visokolegirane čelike na osnovi zamornih parametara σ_f' , b , ε_f' i c procijenjenih empirijskim metodama procjene i umjetnim neuronskim mrežama koje odstupaju do 1,5, 2, 3, 5 i do 10 puta od eksperimentalnih vrijednosti	125

Slika 6.18 Vrijednosti kriterija greške $E_f(s)$ broja izmjena opterećenja do otkazivanja $2N_f$ proračunatih za sve čelike zajedno na osnovi zamornih parametara σ_f' , b , ε_f' i c procijenjenih empirijskim metodama procjene i umjetnim neuronskim mrežama koje odstupaju do 1,5, 2, 3, 5 i do 10 puta od eksperimentalnih vrijednosti..... 126

Tablice

Tablica 3.1 Rezultati testa višestrukih usporedbi za homogenost varijance	41
Tablica 3.2 Rezultati jednofaktorske analize varijance i Welchovog testa za cikličke i zamorne parametre	42
Tablica 3.3 Rezultati post-hoc analize	43
Tablica 3.4 Utvrđene razlike između cikličkih i zamornih parametara nelegiranih, niskolegiranih i visokolegiranih čelika.....	43
Tablica 4.1 ANOVA za testiranje značajnosti regresije	49
Tablica 4.2 ANOVA za sekvencijalni F -test	52
Tablica 4.3 Pregled monotonih značajki za koje se statističkom analizom utvrđivala značajnost za procjenu cikličkih i zamornih parametara.....	57
Tablica 4.4 Prva tri koraka unaprijedne selekcije monotonih parametara za procjenu R_e' nelegiranih čelika	58
Tablica 4.5 Koeficijenti korelacije između cikličkih i monotonih parametara nelegiranih, niskolegiranih i visokolegiranih čelika i odgovarajuće P -vrijednosti.....	61
Tablica 4.6 Redoslijed ulaska monotonih parametara u modele regresijske analize za procjenu cikličkih parametara nelegiranih, niskolegiranih i visokolegiranih čelika.....	62
Tablica 4.7 Koeficijenti korelacije između zamornih i monotonih parametara nelegiranih, niskolegiranih i visokolegiranih čelika i odgovarajuće P -vrijednosti.....	66
Tablica 4.8 Redoslijed ulaska monotonih parametara u modele regresijske analize za procjenu zamornih parametara nelegiranih, niskolegiranih i visokolegiranih čelika.....	67
Tablica 4.9 Pregled monotonih značajki relevantnih za procjenu cikličkih parametara nelegiranih, niskolegiranih i visokolegiranih čelika.....	71
Tablica 4.10 Pregled monotonih značajki relevantnih za procjenu zamornih parametara nelegiranih, niskolegiranih i visokolegiranih čelika	72
Tablica 5.1 Neke vrste aktivacijskih funkcija umjetnog neurona, prema [27] i [28].....	78

Tablica 5.2 Analiza ansambla mreža dobivenih 10-strukom unakrsnom validacijom i Levenberg–Marquadtovim algoritmom za učenje pogreške s ranim zaustavljanjem – mreža s 5 neurona u skrivenom sloju	101
Tablica 5.3 Analiza ansambla mreža dobivenih 10-strukom unakrsnom validacijom i Levenberg–Marquadtovim algoritmom za učenje pogreške s ranim zaustavljanjem – mreža s 10 neurona u skrivenom sloju	102
Tablica 5.4 Pregled umjetnih neuronskih mreža odabranih za procjenu cikličkih parametara čelika	104
Tablica 5.5 Pregled umjetnih neuronskih mreža odabranih za procjenu zamornih parametara čelika	105
Tablica 6.1 Empirijske metode procjene cikličkih parametara i ponašanja čelika odabrane za usporedno vrednovanje.....	110
Tablica 6.2 Empirijske metode procjene zamornih parametara i ponašanja čelika odabrane za usporedno vrednovanje.....	111
Tablica B.1 Monotoni parametri nelegiranih čelika [7, 14, 16].....	163
Tablica B.2 Ciklički i zamorni parametri nelegiranih čelika [7, 14, 16].....	164
Tablica B.3 Monotoni parametri niskolegiranih čelika [7, 14, 16].....	164
Tablica B.4 Ciklički i zamorni parametri niskolegiranih čelika [7, 14, 16].....	166
Tablica B.5 Monotoni parametri visokolegiranih čelika [7, 14, 16].....	167
Tablica B.6 Ciklički i zamorni parametri visokolegiranih čelika [7, 14, 16].....	168
Tablica B.7 Monotoni parametri nelegiranih čelika [1].....	169
Tablica B.8 Ciklički i zamorni parametri nelegiranih čelika [1].....	170
Tablica B.9 Monotoni parametri niskolegiranih čelika [1].....	170
Tablica B.10 Ciklički i zamorni parametri niskolegiranih čelika [1].....	171
Tablica B.11 Monotoni parametri nelegiranih čelika [7, 14, 16, 73, 87].....	172
Tablica B.12 Ciklički i zamorni parametri nelegiranih čelika [7, 14, 16, 73, 87].....	172
Tablica B.13 Monotoni parametri niskolegiranih čelika [7, 14, 16, 40, 81].....	173
Tablica B.14 Ciklički i zamorni parametri niskolegiranih čelika [7, 14, 16, 40, 81].....	174
Tablica B.15 Monotoni parametri nelegiranih čelika [7, 14, 16, 20, 73, 80, 87].....	175
Tablica B.16 Ciklički i zamorni parametri nelegiranih čelika [7, 14, 16, 20, 73, 80, 87].....	175
Tablica B.17 Monotoni parametri niskolegiranih čelika [7, 14, 16, 37, 40, 79, 80].....	176
Tablica B.18 Ciklički i zamorni parametri niskolegiranih čelika [7, 14, 16, 37, 40, 79, 80].	177
Tablica B.19 Monotoni parametri nelegiranih čelika [1, 20, 87].....	177

Tablica B.20 Ciklički i zamorni parametri nelegiranih čelika [1, 20, 87].....	178
Tablica B.21 Monotoni parametri niskolegiranih čelika [1, 79].....	178
Tablica B.22 Ciklički i zamorni parametri niskolegiranih čelika [1, 79].....	179
Tablica B.23 Monotoni parametri visokolegiranih čelika [7, 14, 16, 32, 34, 75, 80].....	180
Tablica B.24 Ciklički i zamorni parametri visokolegiranih čelika [7, 14, 16, 32, 34, 75, 80]	180
Tablica C.1 Unaprijedna selekcija monotonih parametara za procjenu R_e' nelegiranih čelika	182
Tablica C.2 Unaprijedna selekcija monotonih parametara za procjenu K' nelegiranih čelika	182
Tablica C.3 Unaprijedna selekcija monotonih parametara za procjenu n' nelegiranih čelika	183
Tablica C.4 Unaprijedna selekcija monotonih parametara za procjenu R_e' niskolegiranih čelika	183
Tablica C.5 Unaprijedna selekcija monotonih parametara za procjenu K' niskolegiranih čelika	184
Tablica C.6 Unaprijedna selekcija monotonih parametara za procjenu n' niskolegiranih čelika	184
Tablica C.7 Unaprijedna selekcija monotonih parametara za procjenu R_e' visokolegiranih čelika	185
Tablica C.8 Unaprijedna selekcija monotonih parametara za procjenu K' visokolegiranih čelika	185
Tablica C.9 Unaprijedna selekcija monotonih parametara za procjenu n' visokolegiranih čelika	186
Tablica C.10 Unaprijedna selekcija monotonih parametara za procjenu σ_f' nelegiranih čelika	188
Tablica C.11 Unaprijedna selekcija monotonih parametara za procjenu b nelegiranih čelika	188
Tablica C.12 Unaprijedna selekcija monotonih parametara za procjenu σ_f' niskolegiranih čelika.....	189
Tablica C.13 Unaprijedna selekcija monotonih parametara za procjenu b niskolegiranih čelika	189
Tablica C.14 Unaprijedna selekcija monotonih parametara za procjenu c niskolegiranih čelika	190

Tablica C.15 Unaprijedna selekcija monotonih parametara za procjenu σ_f' visokolegiranih čelika.....	190
Tablica C.16 Unaprijedna selekcija monotonih parametara za procjenu b visokolegiranih čelika.....	191
Tablica C.17 Unaprijedna selekcija monotonih parametara za procjenu ε_f' visokolegiranih čelika.....	191
Tablica C.18 Unaprijedna selekcija monotonih parametara za procjenu c visokolegiranih čelika.....	192

Prilog A Empirijske metode procjene cikličkih i zamornih parametara metalnih materijala

A.1 Metode procjene cikličkih parametara

Izrazima (A.1) do (A.25) dane su najvažnije metode procjene cikličke granice tečenja R_e' i cikličkih Ramberg–Osgood parametara: koeficijenta cikličkog deformacijskog očvršćivanja K' i eksponenta cikličkog deformacijskog očvršćivanja n' .

Metode procjene cikličke granice tečenja R_e'

Lijeva metoda (2009) [42] – za čelike:

$$R_e' = (1 + Z)R_m \left(-\frac{0,002}{\ln(1 - Z)} \right)^{0,16} \quad (\text{A.1})$$

Lopez–Fatemijska metoda (2012) [44] – za čelike podijeljene prema omjeru R_m/R_e :

$$R_e' = 0,75R_e + 82 \quad \text{za } R_m/R_e > 1,2 \quad (\text{A.2})$$

$$R_e' = 3 \cdot 10^{-4} R_e^2 - 0,15R_e + 526 \quad \text{za } R_m/R_e \leq 1,2 \quad (\text{A.3})$$

Lopez–Fatemijska metoda (2012) [44] – za čelike:

$$R_e' = 8 \cdot 10^{-5} R_m^2 + 0,54R_m \quad (\text{A.4})$$

Modificirana Lijeva metoda (2016) [43] – za čelike:

$$R_e' = 0,089[(1 + Z)(R_m)]^{1,35} \cdot \left(-\frac{0,002}{\ln(1 - Z)} \right)^{0,216} + 120 \quad (\text{A.5})$$

Metode procjene koeficijenta cikličkog deformacijskog očvršćivanja K' i eksponenta cikličkog deformacijskog očvršćivanja n'

Zhangova metoda procjene (2009) [91] – za čelike, aluminijske i titanijske slitine kad su dostupni koeficijent deformacijskog očvršćivanja K i eksponent deformacijskog očvršćivanja n :

$$K' = 57K^{0,545} - 1220 \quad (\text{A.6})$$

$$n' = 1,06n \left(1 + \beta \left| 1 - \frac{R_m}{R_{p0,2}} \right| \right) \quad \text{za } \alpha < 5\% \text{ ili } 10\% \leq \alpha < 20\% \quad (\text{A.7})$$

$$n' = 1,06n \left(1 + \beta \left| 1 - \frac{\sigma_f}{R_m} \right| \right) \quad \text{za } 5\% < \alpha < 10\% \quad (\text{A.8})$$

$$n' = \frac{R_{p0,2}}{\sigma_f - R_m} n \quad \text{za } \alpha > 20\% \quad (\text{A.9})$$

gdje je

$$\alpha = Z \cdot \varepsilon_f, \quad (\text{A.10})$$

a

$$\begin{aligned} \beta &= +1 \quad \text{za } \sigma_f / R_{p0,2} < 1,6 \\ \beta &= -1 \quad \text{za } \sigma_f / R_{p0,2} > 1,6 \end{aligned} \quad (\text{A.11})$$

Zhangova metoda procjene (2009) [91] – za čelike, aluminijske i titanijske slitine kad nisu dostupni koeficijent deformacijskog očvršćivanja K i eksponent deformacijskog očvršćivanja n :

$$K' = 57 \left(\frac{\log \left(\frac{R_m^2 \sigma_f^3}{R_{p0,2}^5} \right)}{\sigma_f \varepsilon_f \frac{1}{3 \log(500 \varepsilon_f)}} \right)^{0,545} - 1220 \quad \text{za } \alpha < 5\% \text{ ili } 10\% \leq \alpha < 20\% \quad (\text{A.12})$$

$$K' = 57 \left(\frac{\sigma_f R_{p0,2}}{R_m} \varepsilon_f \frac{\log \left(\frac{\sigma_f^2}{R_{p0,2} R_m} \right)}{2 \log(500 \varepsilon_f)} \right)^{0,545} - 1220 \quad \text{za } 5\% < \alpha < 10\% \text{ ili } \alpha > 20\% \quad (\text{A.13})$$

$$n' = 1,06 \left(1 + \beta \left| 1 - \frac{R_m}{R_{p0,2}} \right| \right) \frac{\log \left(\frac{R_m^2 \sigma_f^3}{R_{p0,2}^5} \right)}{3 \log(500 \varepsilon_f)} \quad \text{za } \alpha < 5\% \text{ ili } 10\% \leq \alpha < 20\% \quad (\text{A.14})$$

$$n' = 1,06 \left(1 + \beta \left| 1 - \frac{\sigma_f}{R_m} \right| \right) \frac{\log \left(\frac{\sigma_f^2}{R_{p0,2} R_m} \right)}{2 \log(500 \varepsilon_f)} \quad \text{za } 5\% < \alpha < 10\% \quad (\text{A.15})$$

$$n' = \frac{R_{p0,2}}{\sigma_f - R_m} \frac{\log \left(\frac{\sigma_f^2}{R_{p0,2} R_m} \right)}{2 \log(500 \varepsilon_f)} \quad \text{za } \alpha > 20\% \quad (\text{A.16})$$

gdje su α i β isti kao u izrazima (A.10) i (A.11).

Lopez–Fatemijsva metoda (2012) [44] – za čelike podijeljene prema omjeru R_m/R_e :

$$K' = 1,16R_m + 593 \quad \text{za } R_m/R_e > 1,2 \quad (\text{A.17})$$

$$K' = 3 \cdot 10^{-4} R_m^2 + 0,23R_m + 619 \quad \text{za } R_m/R_e \leq 1,2 \quad (\text{A.18})$$

$$n' = -0,37 \log \left(\frac{0,75R_e + 82}{1,16R_m + 593} \right) \quad \text{za } R_m/R_e > 1,2 \quad (\text{A.19})$$

$$n' = -0,37 \log \left(\frac{3 \cdot 10^{-4} R_e^2 - 0,15R_e + 526}{3 \cdot 10^{-4} R_m^2 + 0,23R_m + 619} \right) \quad \text{za } R_m/R_e \leq 1,2 \quad (\text{A.20})$$

Lopez–Fatemijsva metoda (2012) [44] – za čelike:

$$n' = -0,33(R_e/R_m) + 0,4 \quad (\text{A.21})$$

Lijeva metoda (2016) [43] – za čelike podijeljene prema omjeru R_m/R_e :

$$K' = 2,16 \cdot 10^{-4} R_m^{2,1} + 738 \quad \text{za } R_m/R_e \leq 1,2 \quad (\text{A.22})$$

$$K' = 3,63 \cdot 10^{-4} R_m^2 + 0,68R_m + 570 \quad \text{za } 1,2 < R_m/R_e < 1,4 \quad (\text{A.23})$$

$$K' = 1,21R_m + 555 \quad \text{za } R_m/R_e \geq 1,4 \quad (\text{A.24})$$

$$n' = \frac{\log(K') - \log(R_e)}{\log 500} \quad \text{za sve čelike} \quad (\text{A.25})$$

A.2 Metode procjene zamornih parametara

Izrazima (A.26) do (A.38) dane su metode procjene zamornih parametara iz BCM izraza (15): koeficijenta dinamičke čvrstoće σ_f' , eksponenta dinamičke čvrstoće b , koeficijenta cikličkih deformacija ε_f' i eksponenta cikličkih deformacija c .

Mansonova metoda univerzalnih nagiba pravaca (engl. *original universal slopes method*) (1965) [48] – za sve materijale:

$$\frac{\Delta\varepsilon}{2} = 1,9018 \frac{R_m}{E} (2N_f)^{-0,12} + 0,7579 \varepsilon_f^{0,6} (2N_f)^{-0,6} \quad (\text{A.26})$$

Mansonova korelacijska metoda četiriju točaka (engl. *four-point correlation method*) (1965) [48] – za sve materijale:

$$\begin{aligned} \frac{\Delta\varepsilon}{2} = & \frac{1}{2} 10^{b \log 2 + \log\left(\frac{2,5\sigma_f}{E}\right)} (2N_f)^{\frac{\log\left(\frac{2,5\sigma_f}{0,9R_m}\right)}{\log\left(\frac{1}{4 \cdot 10^5}\right)}} + \\ & + \frac{1}{2} 10^{c \log \frac{1}{20} + \log\left(\frac{1}{4} \varepsilon_f^{\frac{3}{4}}\right)} (2N_f)^{\frac{1}{3} \log\left(\frac{0,0132 - \Delta\varepsilon_c^*}{1,91}\right) - \log \frac{1}{3} \left(\frac{1}{4} \varepsilon_f^{\frac{3}{4}}\right)}, \end{aligned} \quad (\text{A.27})$$

gdje je

$$\frac{\Delta\varepsilon_c^*}{2} = 10^{b \log(4 \cdot 10^4) + \log\left(\frac{2,5\sigma_f}{E}\right)} \quad (\text{A.28})$$

Mitchellova metoda (engl. *method by Mitchell*) (1977) [76] – za čelike Brinellove tvrdoće $HB \leq 500$ HB:

$$\frac{\Delta\varepsilon}{2} = \frac{R_m + 345}{E} (2N_f)^{-\frac{1}{6} \log\left[\frac{2(R_m + 345)}{R_m}\right]} + \varepsilon_f (2N_f)^c, \quad (\text{A.29})$$

gdje je

$c = -0,5$ za duktilne materijale,

$c = -0,6$ za krhke materijale.

Modificirana metoda univerzalnih nagiba pravaca Muralidharana i Mansona (engl. *modified universal slopes method*) (1988) [64] – za sve materijale:

$$\frac{\Delta\varepsilon}{2} = 0,623 \left(\frac{R_m}{E}\right)^{0,832} (2N_f)^{-0,09} + 0,0196 \varepsilon_f^{0,155} \left(\frac{R_m}{E}\right)^{-0,53} (2N_f)^{-0,56} \quad (\text{A.30})$$

Uniformni materijalni zakon Bäumela i Seegera (engl. *uniform material law*) (1990) [14] – za nelegirane i niskolegirane čelike:

$$\frac{\Delta\varepsilon}{2} = 1,5 \left(\frac{R_m}{E}\right) (2N_f)^{-0,087} + 0,59 \psi (2N_f)^{-0,58}, \quad (\text{A.31})$$

gdje je

$$\begin{aligned} \psi &= 1 \quad \text{za} \quad \frac{R_m}{E} \leq 0,003, \\ \psi &= 1,375 - 125 \frac{R_m}{E} \quad \text{za} \quad \frac{R_m}{E} \geq 0,003 \end{aligned} \quad (\text{A.32})$$

Uniformni materijalni zakon Bäumela i Seegera (engl. *Uniform Material Law*) (1990) [14] – za aluminijeve i titanijeve slitine:

$$\frac{\Delta\varepsilon}{2} = 1,67 \frac{R_m}{E} (2N_f)^{-0,095} + 0,35(2N_f)^{-0,69} \quad (\text{A.33})$$

Ongova modificirana korelacijska metoda četiriju točaka (engl. *modified four-point correlation method*) (1993) [67] – za sve materijale:

$$\frac{\Delta\varepsilon}{2} = \frac{\sigma_f}{E} (2N_f)^{\frac{1}{6}} \left\{ \log \left[0,16 \left(\frac{R_m}{E} \right)^{0,81} \right] - \log \left(\frac{\sigma_f}{E} \right) \right\} + \varepsilon_f (2N_f)^{\frac{1}{4}} \left[\log \left(\frac{0,00737 - \frac{\Delta\varepsilon_c^*}{2}}{2,074} \right) - \log \varepsilon_f \right], \quad (\text{A.34})$$

gdje je

$$\frac{\Delta\varepsilon_c^*}{2} = \frac{\sigma_f}{E} \left[10^{\frac{2}{3} \left\{ \log \left[0,16 \left(\frac{R_m}{E} \right)^{0,81} \right] - \log \left(\frac{\sigma_f}{E} \right) \right\}} \right] \quad (\text{A.35})$$

Metoda tvrdoće Roesslea i Fatemija (engl. *hardness method*) (2000) [73] – za čelike Brinellove tvrdoće 100 – 700 HB:

$$\frac{\Delta\varepsilon}{2} = \frac{4,25HB + 225}{E} (2N_f)^{-0,09} + \frac{0,32HB^2 - 487HB + 191000}{E} (2N_f)^{-0,56} \quad (\text{A.36})$$

Metoda medijana Meggiolaroa i Castroa (engl. *medians method*) (2004) [57] – za čelike:

$$\frac{\Delta\varepsilon}{2} = 1,5 \frac{R_m}{E} (2N_f)^{-0,09} + 0,45(2N_f)^{-0,59} \quad (\text{A.37})$$

Metoda medijana Meggiolaroa i Castroa (engl. *medians method*) (2004) [57] – za aluminijeve slitine:

$$\frac{\Delta\varepsilon}{2} = 1,9 \frac{R_m}{E} (2N_f)^{-0,11} + 0,28(2N_f)^{-0,66} \quad (\text{A.38})$$

Prilog B Podaci za provedbu statističke analize, razvoj umjetnih neuronskih mreža i vrednovanje procjene cikličkih i zamornih parametara čelika

B.1 Prikaz podataka za nelegirane, niskolegirane i visokolegirane čelike korištenih u istraživanju

U tablicama B.1 do B.24 dani su podaci za monotone, cikličke i zamorne parametre čelika. Podaci su grupirani prema namjeni i prema skupini čelika (nelegirani, niskolegirani i visokolegirani čelici).

U prilogu B.2 dani su podaci korišteni za provedbu statističkih analiza iz Poglavlja 3 – unaprijedne selekcije za određivanje monotonih značajki relevantnih za procjenu cikličkih i zamornih parametara svih skupina čelika. Isti podaci korišteni su i za razvoj umjetnih neuronskih mreža za procjenu cikličkih i zamornih parametara čelika.

Za razvoj umjetnih neuronskih mreža za procjenu cikličkih i zamornih parametara nelegiranih i niskolegiranih čelika prikupljeni su dodatni podaci dani u prilogu B.3.

Podaci korišteni za vrednovanje empirijskih metoda procjene i pristupa procjeni cikličkih i zamornih parametara nelegiranih i niskolegiranih čelika pomoću neuronskih mreža dani su u prilogu B.4.

Radi limitiranog broja prikupljenih podataka za visokolegirane čelike, za vrednovanje metoda procjene cikličkih i zamornih parametara visokolegiranih čelika korišten je i dio podataka iz priloga B.2. Ti su podaci u tablicama B.5 i B.6 označeni zvjezdicom. Dodatni podaci za vrednovanje empirijskih metoda procjene cikličkih i zamornih parametara visokolegiranih čelika, kao i umjetnih neuronskih mreža razvijenih u tu svrhu, dani su u prilogu B.5.

Siva polja u pojedinim tablicama upućuju na to da eksperimentalne vrijednosti pojedinih varijabli nisu bile dostupne u originalnoj literaturi, pa su izračunate prema izrazima (8), (9), (10), (11) odnosno (12). Masno otisnute vrijednosti su ispravljene vrijednosti iz izvorne literature koje su bile očigledna tiskarska pogreška. Vrijednosti cikličkih parametara K' i n' označene s "-c" nisu eksperimentalno određene, već izračunate iz eksperimentalnih vrijednosti zamornih parametara na osnovi uvjeta kompatibilnosti (16).

Prilikom prikupljanja i sistematiziranja podataka vodilo se računa o tome da se prikupljeni podaci maksimalno iskoriste, pa je primjerice dio podataka korišten za razvoj neuronskih mreža za procjenu cikličkih parametara čelika korišten i za vrednovanje metoda procjene zamornih parametara čelika, i obratno. Razlog unakrsnom korištenju podataka je intencija da se provede potpuno neovisno vrednovanje kako postojećih metoda procjene tako i novorazvijenih modela umjetnih neuronskih mreža. Ovo je moguće samo u slučaju da podaci korišteni za vrednovanje pojedine metode nisu bili primijenjeni i za njen razvoj. Kako je broj skupova podataka bio relativno mali (iako mnogo veći nego u većini postojećih metoda procjene) unakrsnim korištenjem podataka omogućeno je maksimalno iskorištavanje dostupnih podataka.

Valja reći da se zbog prethodno navedenog razloga dio podataka ponavlja u pojedinim tablicama, s obzirom na to da su podaci radi jasnoće i ponovljivosti istraživanja sistematizirani prema namjeni.

B.2 Podaci za nelegirane, niskolegirane i visokolegirane čelike korišteni za provedbu unaprijedne selekcije i razvoj umjetnih neuronskih mreža za procjenu cikličkih i zamornih parametara čelika

Tablica B.1 Monotoni parametri nelegiranih čelika [7, 14, 16]

Oznaka materijala	Monotoni parametri											
	DIN / SAE / drugo	$\frac{HB}{HB}$	$\frac{E}{MPa}$	$\frac{R_c \text{ ili } R_{p0,2}}{MPa}$	$\frac{R_m}{MPa}$	R_m/R_c	$\frac{R_m/E}{10^{-3}}$	$\frac{Z}{\%}$	$\frac{K}{MPa}$	n	$\frac{\sigma_f}{MPa}$	ϵ_f
1038 (SAE)			207000	347	610	1,758	2,947	55,5	511	0,071	956	0,590
Armco (komerc.)			210000	207	359	1,734	1,710	64	675	0,285	653	1,030
C 20	303		190000	224	414	1,848	2,179	70	330	0,061	953	1,190
C 10	183		217510	435	566	1,301	2,602	68	659	0,073	1205	1,130
Ck 15			196793	263	392	1,490	1,992	55	711	0,224	746	0,806
Ck 15			204500	320	434	1,356	2,122	67,5	394	0,067	848,7	1,126
Ck 15			202000	431,3	615,2	1,426	3,046	54	598	0,045	1011,7	0,776
Ck 15			203000	660	828	1,255	4,079	2,6	863	0,042	850,5	0,026
Ck 25			210000	307	464	1,511	2,210	65	924	0,276	982	1,050
Ck 25			210000	346	507	1,465	2,414	63	926	0,264	1027	0,994
Ck 25			210000	366	527	1,440	2,510	60	1033	0,264	997	0,916
Ck 35			210000	396	565	1,427	2,690	63	1134	0,264	1134	0,994
Ck 35			210000	394	593	1,505	2,824	62	1168	0,257	1169	0,968
Ck 35			210000	414	617	1,490	2,938	58	1216	0,258	1150	0,868
Ck 35			210000	480	656	1,367	3,124	74	1196	0,207	1468	1,347
Ck 35			210000	513	669	1,304	3,186	70	1121	0,18	1417	1,204
Ck 35			210000	542	730	1,347	3,476	68	1311	0,2	1473	1,139
Ck 35			210000	596	733	1,230	3,490	71	1170	0,152	1541	1,238
Ck 35			210000	587	780	1,329	3,714	67	1356	0,186	1514	1,109
Ck 45			207000	462	672	1,455	3,246	61	1288	0,235	1298	0,942
Ck 45			201500	380	684	1,800	3,395	36,8	735	0,092	987	0,460
Ck 45			208000	588	730	1,241	3,510	70	1154	0,148	1540	1,204
Ck 45			199000	466	737	1,582	3,704	54	1469	0,248	1296	0,777
Ck 45			207000	551	774	1,405	3,739	68	1297	0,166	1559	1,139
Ck 45			210000	652	787	1,207	3,748	68	1200	0,129	1568	1,139
Ck 45			206000	540	790	1,463	3,835	60	730	0,047	1400	0,916
Ck 45			210500	531	790	1,488	3,753	60	1219	0,0151	1271	0,777
Ck 45			206000	728	844	1,159	4,097	64	1208	0,108	1582	1,022
Ck 45			204000	702	863	1,229	4,230	66	1268	0,118	1651	1,079
Ck 45	260		199700	622	915	1,471	4,582	59	1606	0,18	1784	0,900
Ck 45	260		199700	622	915	1,471	4,582	59	1606	0,18	1784	0,900
Ck 45			205000	760	1018	1,339	4,966	0	1141	0,059	1018	0,000
St 37			210000	295	435	1,475	2,071	64	829	0,275	835	1,020
St 52-3			210000	400	597	1,493	2,843	63	1061	0,225	1083	0,980

Maseni udio legirajućih elemenata (%): C 0,02–0,50; Si 0,02–0,55; Mn 0,03–1,50; P 0,01–0,05; S 0,01–0,05; Cr 0,02–0,19; Mo 0,00–0,01; Ni 0,01–0,13; Cu 0,01–0,21; Al 0,04–0,07; N 0,00–0,01

Tablica B.2 Ciklički i zamorni parametri nelegiranih čelika [7, 14, 16]

Oznaka materijala	Ciklički parametri			Zamorni parametri				
	DIN / SAE / drugo	R_e' MPa	K' MPa	n'	σ_f' MPa	b	ε_f' MPa	c
1038 (SAE)		332	1207	0,208	1070	-0,115	0,537	-0,549
Armco (komerc.)		280	858	0,18	817	-0,105	0,6591	-0,556
C 20		239	1050	0,238	600	-0,09	0,103	-0,384
C 10		463	1381	0,176	875	-0,063	0,594	-0,613
Ck 15		249	824	0,193	807	-0,117	0,415	-0,528
Ck 15		269	813	0,178	984	-0,129	0,807	-0,587
Ck 15		492	1296	0,156	917	-0,07	0,073	-0,413
Ck 15		687	1165	0,085	1321	-0,087	1,7889	-0,911
Ck 25		278	1111	0,223	965	-0,117	0,537	-0,525
Ck 25		280	1345	0,252	959	-0,114	0,265	-0,453
Ck 25		303	1217	0,224	925	-0,105	0,298	-0,472
Ck 35		316	1534	0,254	1173	-0,119	0,349	-0,47
Ck 35		333	1460	0,238	1226	-0,121	0,503	-0,512
Ck 35		328	1355	0,229	1050	-0,107	0,329	-0,469
Ck 35		393	1033	0,156	1019	-0,092	0,947	-0,595
Ck 35		387	1081	0,165	845	-0,075	0,235	-0,46
Ck 35		430	1087	0,149	1004	-0,085	0,584	-0,568
Ck 35		447	1027	0,134	880	-0,068	0,321	-0,513
Ck 35		463	1106	0,14	1100	-0,087	0,941	-0,619
Ck 45		354	1391	0,22	987	-0,096	0,221	-0,439
Ck 45		336	1414	0,231	1326	-0,139	0,402	-0,528
Ck 45		420	1194	0,168	1006	-0,084	0,361	-0,502
Ck 45		368	1486	0,225	1123	-0,106	0,295	-0,476
Ck 45		464	1235	0,158	1012	-0,08	0,286	-0,51
Ck 45		472	1285	0,161	1017	-0,077	0,23	-0,476
Ck 45		481	980	0,115	987	-0,083	0,994	-0,715
Ck 45		462	1078	0,133	1405	-0,11	0,6065	-0,545
Ck 45		516	1217	0,138	1057	-0,075	0,34	-0,536
Ck 45		526	1243	0,138	1112	-0,075	0,432	-0,541
Ck 45		591	2407	0,226	2350	-0,148	0,447	-0,561
Ck 45		538	1762	0,191	2022	-0,151	0,517	-0,631
Ck 45		722	2075	0,17	1100	-0,064	0,019	-0,352
St 37		273	988	0,207	895	-0,111	0,7051	-0,569
St 52-3		389	1228	0,185	1193	-0,11	0,6601	-0,553

Tablica B.3 Monotoni parametri niskolegiranih čelika [7, 14, 16]

Oznaka materijala	Monotoni parametri											
	DIN / SAE / drugo	HB HB	E MPa	R_e ili $R_{p0,2}$ MPa	R_m MPa	R_m/R_e	R_m/E 10^{-3}	Z %	K MPa	n	σ_f MPa	ε_f
100Cr6			207000	1927	2016	1,046	9,739	12	2281	0,031	2230	0,120
11NiMnCrMo55			210000	745	852	1,144	4,057	57	1277	0,124	1327	0,834
14Mn5	225		206000	580	697	1,202	3,383	68	858	0,067	1222	1,150
16NiCrMo32	303		209000	891	939	1,054	4,493	63	963	0,011	1491	0,994
17MnCrMo33			214000	833	929	1,115	4,341	58	1285	0,099	1446	0,867

nastavlja se na idućoj stranici

Tablica B.3 Monotoni parametri niskolegiranih čelika [7, 14, 16] (nastavak s prethodne stranice)

Oznaka materijala	Monotoni parametri										
DIN / SAE / drugo	$\frac{HB}{HB}$	$\frac{E}{MPa}$	$\frac{R_c \text{ ili } R_{p0,2}}{MPa}$	$\frac{R_m}{MPa}$	R_m/R_c	$\frac{R_m/E}{10^{-3}}$	$\frac{Z}{\%}$	$\frac{K}{MPa}$	n	$\frac{\sigma_f}{MPa}$	ε_f
20Mn3		206000	910	960	1,055	4,660	43	1190	0,06	1090	0,561
22MnCrNi3		198000	1200	1510	1,258	7,626	42	2447	0,114	2034	0,549
22MnCrNi3		195000	1200	1586	1,322	8,133	3	2586	0,115	1669	0,026
23Mn4	304	207000	1008	1091	1,082	5,271	61	1185	0,026	1616	0,950
23NiCr4	256	208531	725	808	1,114	3,875	66	762	0,007	1215	1,080
25Mn3	140	200000	351	540	1,538	2,700	67	992	0,236	1173	1,100
25Mn5	289	207000	904	1008	1,115	4,870	49	1138	0,033	1284	0,680
28MnCu6		204000	330	580	1,758	2,843	64	938	0,19	950	1,030
30CrMo2		221000	780	898	1,151	4,063	67	1117	0,063	1692	1,120
30CrMo2		200250	1360	1429	1,051	7,136	55	1661	0,033	2085	0,790
30CrMoNiV511		212000	605	773	1,278	3,646	62	717	0,027	1332	0,968
30CrNiMo8		206000	700	910	1,300	4,417	66	1128	0,079	1168	0,708
30CrNiMo8		206000	700	910	1,300	4,417	66	1128	0,079	1168	0,708
30MnCr5	293	206000	820	950	1,159	4,612	64	1250	0,097	1445	1,068
34CrMo4		194000	780	881	1,129	4,541	71	1299	0,116	1740	1,238
34CrMo4		188000	847	939	1,109	4,995	69	1215	0,074	1795	1,171
34CrMo4		190000	893	978	1,095	5,147	67	1338	0,089	1787	1,109
34CrMo4		197000	980	1078	1,100	5,472	61	1382	0,07	1818	0,942
34CrMo 4		193000	1017	1088	1,070	5,637	65	1344	0,056	1903	1,050
4NiCrMn4		206000	454	623	1,372	3,024	76	753	0,081	1229	1,450
40CrMo4	293	208780	840	940	1,119	4,502	64	1300	0,094	1440	1,035
40NiCrMo6		205000	810	884	1,091	4,312	67	1378	0,142	1680	1,110
40NiCrMo6		190000	910	1015	1,115	5,342	62	1372	0,089	1808	0,970
40NiCrMo6		202000	953	1029	1,080	5,094	62	1448	0,1	1724	0,970
40NiCrMo6		193000	998	1067	1,069	5,528	62	1474	0,092	1761	0,970
40NiCrMo6		201000	1084	1146	1,057	5,701	59	1549	0,083	1857	0,890
40NiCrMo7		193500	635	829	1,306	4,284	43	1175	0,098	1201	0,570
40NiCrMo7		193500	1374	1471	1,071	7,602	38	1796	0,04	1920	0,480
41MnCr34		207280	800	930	1,163	4,487	62	1350	0,112	1390	0,960
42Cr4		193000	717	840	1,172	4,352	69	1240	0,118	1617	1,171
42Cr4		194000	813	921	1,133	4,747	65	1249	0,086	1674	1,050
42Cr4		192000	833	943	1,132	4,911	65	1289	0,09	1690	1,050
42Cr4		194000	845	952	1,127	4,907	62	1288	0,086	1689	0,968
42Cr4		195000	903	1006	1,114	5,159	62	1293	0,068	1716	0,968
42CrMo4		211400	998	1111	1,113	5,255	60	1469	0,069	1525	0,496
49MnVS3		210200	566	840	1,484	3,996	19	1428	0,194	1152	0,380
50CrMo4		205000	947	983	1,038	4,795	14,6	1042	0,018	926	0,157
50CrMo4		205000	970	1086	1,120	5,298	48,6	1132	0,026	1609	0,665
8Mn6		198000	821	869	1,058	4,389	53	1085	0,046	1434	0,750
8Mn6		198000	862	965	1,119	4,874	57	1227	0,054	1579	0,850
80Mn4		187500	502	931	1,855	4,965	16	1100	0,127	1060	0,174
WstE 460		210000	560	667	1,191	3,176	61	1096	0,153	1171	0,932

Maseni udio legirajućih elemenata (%): C 0,04–1,02; Si 0,06–0,68; Mn 0,01–1,43; P 0,01–0,04; S 0,00–0,06; Cr 0,03–1,89; Mo 0,01–1,13; Ni 0,02–1,90; Cu 0,01–0,57; Al 0,00–0,17; Co 0,00–0,21; Ti 0,00–0,04; V 0,06–0,24; Nb 0,00–0,03

Tablica B.4 Ciklički i zamorni parametri niskolegiranih čelika [7, 14, 16]

Oznaka materijala	Ciklički parametri			Zamorni parametri			
	R'_c MPa	K' MPa	n'	σ'_f MPa	b	ε'_f MPa	c
DIN							
100Cr6	1341	3328	0,146	2620	-0,093	0,145	-0,56
11NiMnCrMo55	663	1145	0,088	1194	-0,067	1,1759	-0,701
14Mn5	537	1436	0,158	1339	-0,111	1,7769	-0,845
16NiCrMo32	617	1080	0,09	1010	-0,054	0,9734	-0,693
17MnCrMo33	663	1252	0,102	1282	-0,07	1,185	-0,681
20Mn3	675	1313	0,107	1227	-0,068	0,765	-0,706
22MnCrNi3	1046	2149	0,112	3046	-0,141	0,542	-0,783
22MnCrNi3	1193	2759	0,135	2313	-0,095	0,0892	-0,576
23Mn4	656	1616	0,145	2177	-0,129	0,84	-0,688
23NiCr4	541	1221	0,131	1031	-0,07	0,737	-0,644
25Mn3	322	1219	0,214	985	-0,106	0,373	-0,493
25Mn5	608	1900	0,183	1137	-0,069	1,199	-0,74
28MnCu6	347	1151	0,193	1101	-0,111	0,495	-0,516
30CrMo2	579	1366	0,138	1211	-0,071	1,008	-0,652
30CrMo2	814	1758	0,124	1691	-0,08	0,814	-0,674
30CrMoNiV511	497	894	0,094	859	-0,059	0,603	-0,62
30CrNiMo8	573	972	0,085	1087	-0,07	1,312	-0,705
30CrNiMo8	522	995	0,095	1013	-0,064	1,1839	-0,673
30MnCr5	576	1618	0,166	1482	-0,106	2,7989	-0,824
34CrMo4	556	1198	0,124	1160	-0,078	0,65	-0,607
34CrMo4	624	1008	0,077	1082	-0,061	2,109	-0,77
34CrMo4	650	987	0,067	1131	-0,061	4,551	-0,848
34CrMo4	711	1373	0,106	1286	-0,063	0,518	-0,594
34CrMo 4	692	1310	0,103	1215	-0,058	0,703	-0,62
4NiCrMn4	505	1111	0,127	926	-0,062	0,842	-0,627
40CrMo4	583	1307	0,13	1274	-0,078	1,6739	-0,677
40NiCrMo6	586	1303	0,129	1131	-0,072	0,29	-0,54
40NiCrMo6	660	1392	0,12	1222	-0,067	0,325	-0,55
40NiCrMo6	659	1628	0,145	1195	-0,061	0,162	-0,467
40NiCrMo6	716	1292	0,095	1274	-0,064	0,612	-0,628
40NiCrMo6	758	1550	0,115	1360	-0,063	0,32	-0,551
40NiCrMo7	474	1332	0,167	1206	-0,095	0,536	-0,568
40NiCrMo7	905	1890	0,118	1880	-0,086	0,706	-0,662
41MnCr34	551	1340	0,143	1271	-0,082	1,248	-0,653
42Cr4	543	1161	0,122	1055	-0,071	0,458	-0,578
42Cr4	613	1147	0,101	1120	-0,065	0,658	-0,627
42Cr4	621	1192	0,105	1229	-0,072	1,149	-0,667
42Cr4	619	1207	0,107	1252	-0,073	1,294	-0,674
42Cr4	679	1153	0,085	1212	-0,064	1,2929	-0,716
42CrMo4	716	1367	0,104	1454	-0,075	1,508	-0,716
49MnVS3	520	1396	0,159	1440	-0,105	0,6025	-0,574
50CrMo4	774	1754	0,132	1081	-0,047	0,019	-0,323
50CrMo4	700	1568	0,13	1642	-0,092	1,355	-0,706
8Mn6	674	1258	0,101	1073	-0,055	0,203	-0,541
8Mn6	580	1256	0,125	1087	-0,068	0,312	-0,549
80Mn4	459	1859	0,225	1249	-0,101	0,175	-0,451
WstE 460	514	1194	0,128	1201	-0,085	0,8638	-0,625

Tablica B.5 Monotoni parametri visokolegiranih čelika [7, 14, 16]

Oznaka materijala	Monotoni parametri										
DIN	$\frac{HB}{HB}$	$\frac{E}{MPa}$	$\frac{R_e \text{ ili } R_{p0,2}}{MPa}$	$\frac{R_m}{MPa}$	R_m/R_e	$\frac{R_m/E}{10^{-3}}$	$\frac{Z}{\%}$	$\frac{K}{MPa}$	n	$\frac{\sigma_f}{MPa}$	ϵ_f
X10CrNi18-8		204000	245	635	2,592	3,113	79	1416	0,362	1908	1,563
X10CrNiNb18-9		210000	237	615	2,595	2,929	72			1398	1,273
X10CrNiNb18-9		210000	237	615	2,595	2,929	72			1398	1,273
X10CrNiTi18-9		210000	177	516	2,915	2,457	74			1211	1,347
X10CrNiTi18-9		210000	177	516	2,915	2,457	74			1211	1,347
X10CrNiTi18-9		210000	177	535	3,023	2,548	77			1321	1,470
X10CrNiTi18-9		210000	177	535	3,023	2,548	77			1321	1,470
X10CrNiTi18-9		210000	182	668	3,670	3,181	68			1429	1,139
X10CrNiTi18-9*		210000	211	677	3,209	3,224	69			1470	1,171
X10CrNiTi18-9		210000	211	677	3,209	3,224	67			1428	1,109
X10CrNiTi18-9		210000	214	529	2,472	2,519	74			1242	1,347
X10CrNiTi18-9		210000	214	529	2,472	2,519	74			1242	1,347
X15Cr13		210000	598	736	1,231	3,505	70			1622	1,204
X15Cr13		210000	598	736	1,231	3,505	70			1622	1,204
X15CrNiSi25-20		210000	271	630	2,325	3,000	69			1368	1,171
X15CrNiSi25-20*		210000	271	630	2,325	3,000	69			1368	1,171
X2CrNi18-9		192000	280	601	2,146	3,130	46	455	0,097	971	0,616
X2CrNiMo18-10		210000	373	700	1,877	3,333	75			1670	1,386
X20CrMo12-1*		210000	795	1013	1,274	4,824	47			1656	0,635
X20CrMo12-1		210000	795	1013	1,274	4,824	47			1656	0,635
X25CrNiMn25-20		193340	220	642	2,918	3,321	63	754	0,228	1360	1,010
X3CrNi19-9		186435	255	746	2,925	4,001	74	548	0,136	1920	1,370
X3CrNi19-9		172625	746	953	1,277	5,521	69	1114	0,063	2037	1,160
X5CrNi18-9		210000	207	611	2,952	2,910	75			1458	1,386
X5CrNi18-9		210000	207	611	2,952	2,910	83			1694	1,772
X5CrNi18-9		198000	242	666	2,752	3,364	82	484	0,113	2407	1,715
X5CrNiMo18-10		210000	228	665	2,917	3,167	81			1769	1,661
X5CrNiMo18-10*		210000	228	665	2,917	3,167	81			1769	1,661
X5CrNiMo18-10		210000	230	587	2,552	2,795	78			1476	1,514
X5CrNiMo18-10		210000	231	587	2,541	2,795	78			1476	1,514
X5CrNiMo18-10		210000	257	606	2,358	2,886	79			1830	1,561
X5NiCrTi2615		210000	777	1158	1,490	5,514	52			2008	0,734
X5NiCrTi26-15		210000	777	1158	1,490	5,514	52			2008	0,734
X6CrNi19-11		183000	325	650	2,000	3,552	80	1210	0,193	1400	1,610
X8CrNiTi18-10*		204000	222	569	2,563	2,789	76	349	0,062	1381	1,427

Maseni udio legirajućih elemenata (%): C 0,02–0,25; Si 0,27–1,50; Mn 0,41–2,00; P 0,02–0,04; S 0,00–0,02; Cr 11,40–25,00; Mo 0,02–2,62; Ni 0,21–24,65; Cu 0,06–0,31; Al 0,00–0,26; Co 0,11–0,22; Ti 0,00–2,50; W 0,00–0,99; V 0,00–0,28; N 0,05–0,25

Napomena: podaci o čelicima označeni zvjezdicom * nisu korišteni za razvoj umjetnih neuronskih mreža, nego za vrednovanje metoda procjene cikličkih i zamornih parametara visokolegiranih čelika

Tablica B.6 Ciklički i zamorni parametri visokolegiranih čelika [7, 14, 16]

Oznaka materijala	Ciklički parametri			Zamorni parametri			
	DIN	R_c' MPa	K' MPa	n'	σ_f' MPa	b	ε_f' MPa
X10CrNi18-8	307	2397	0,331	2032	-0,183	0,3249	-0,441
X10CrNiNb18-9	271	1967	0,319	1005	-0,121	0,127	-0,384
X10CrNiNb18-9	276	1667	0,289	1060	-0,123	0,23	-0,436
X10CrNiTi18-9	220	2264	0,375	1969	-0,208	0,652	-0,548
X10CrNiTi18-9	250	1535	0,292	1806	-0,193	1,72	-0,659
X10CrNiTi18-9	220	3080	0,424	3079	-0,253	0,976	-0,593
X10CrNiTi18-9	241	2097	0,348	1868	-0,194	0,803	-0,57
X10CrNiTi18-9	414	6179	0,435	1998	-0,144	0,081	-0,341
X10CrNiTi18-9*	496	3647	0,321	1968	-0,138	0,11	-0,393
X10CrNiTi18-9	455	8384	0,469	2046	-0,133	0,046	-0,276
X10CrNiTi18-9	228	2086	0,357	1858	-0,199	0,713	-0,558
X10CrNiTi18-9	251	1682	0,306	1740	-0,186	1,1359	-0,608
X15Cr13	497	987	0,11	962	-0,075	0,798	-0,68
X15Cr13	475	1056	0,128	932	-0,074	0,38	-0,579
X15CrNiSi25-20	289	2302	0,334	1512	-0,153	0,301	-0,465
X15CrNiSi25-20*	284	2242	0,332	1492	-0,152	0,289	-0,454
X2CrNi18-9	207	2807	0,419	1936	-0,202	0,412	-0,483
X2CrNiMo18-10	295	1232	0,23	997	-0,113	0,473	-0,511
X20CrMo12-1*	730	1301	0,093	1216	-0,062	0,49	-0,664
X20CrMo12-1	716	1325	0,099	1249	-0,066	0,556	-0,664
X25CrNiMn25-20	421	2267	0,271	1646	-0,154	0,302	-0,568
X3CrNi19-9	678	4634	0,309	2377	-0,152	0,068	-0,428
X3CrNi19-9	882	2313	0,155	2067	-0,112	0,301	-0,649
X5CrNi18-9	197	3331	0,455	1470	-0,179	0,161	-0,389
X5CrNi18-9	203	3001	0,434	1268	-0,16	0,134	-0,366
X5CrNi18-9	275	2872	0,378	1227	-0,137	0,104	-0,363
X5CrNiMo18-10	259	2674	0,376	1595	-0,163	0,252	-0,433
X5CrNiMo18-10*	259	2081	0,336	1999	-0,19	0,928	-0,572
X5CrNiMo18-10	256	1644	0,299	1491	-0,17	0,708	-0,568
X5CrNiMo18-10	247	2755	0,388	2508	-0,227	0,758	-0,582
X5CrNiMo18-10	313	2000	0,298	1314	-0,132	0,249	-0,445
X5NiCrTi2615	711	1543	0,125	1574	-0,083	1,109	-0,661
X5NiCrTi26-15	713	1617	0,132	1537	-0,08	0,662	-0,606
X6CrNi19-11	267	1628	0,291	986	-0,117	0,17	-0,399
X8CrNiTi18-10*	383	5234	0,421	1658	-0,134	0,067	-0,323

Napomena: podaci o čelicima označeni zvjezdicom * nisu korišteni za razvoj umjetnih neuronskih mreža, nego za vrednovanje metoda procjene cikličkih i zamornih parametara visokolegiranih čelika

B.3 Dodatni podaci za nelegirane i niskolegirane čelike korišteni za razvoj umjetnih neuronskih mreža za procjenu cikličkih i zamornih parametara čelika

B.3.1 Podaci za razvoj umjetnih neuronskih mreža za procjenu cikličkih parametara čelika

Tablica B.7 Monotoni parametri nelegiranih čelika [1]

Oznaka materijala	Monotoni parametri										
AISI	$\frac{HB}{HB}$	$\frac{E}{MPa}$	$\frac{R_e \text{ ili } R_{p0,2}}{MPa}$	$\frac{R_m}{MPa}$	R_m/R_e	$\frac{R_m/E}{10^{-3}}$	$\frac{Z}{\%}$	$\frac{K}{MPa}$	n	$\frac{\sigma_f}{MPa}$	ε_f
1020	135	207000	295	502	1,702	2,425	64	933	0,239	849	1,010
1022	195	200000	457	604	1,322	3,020	69	971	0,161	1587	1,160
1038	163	201000	331	582	1,758	2,896	54	1106	0,26	898	0,800
1038	185	219000	359	652	1,816	2,977	53	1186	0,219	1051	0,800
1038	245	218000	560	743	1,327	3,408	69	1231	0,169	1292	1,160
1045	222	209000	510	747	1,465	3,574	62	1334	0,199	1151	1,000
1090	259	219000	729	1090	1,495	4,977	14	1780	0,162	966	0,200
1090	272	214000	760	1124	1,479	5,252	38	1576	0,108	840	0,500
1090	309	213000	678	1147	1,692	5,385	22	1913	0,168	1151	0,200
1541	180	197000	471	783	1,662	3,975	55	1165	0,143	1207	0,800
1050M	205	211000	450	821	1,824	3,891	50	1819	0,274	1128	0,700
10V45	212	213000	465	765	1,645	3,592	48	1456	0,223	1131	0,700
10V45	269	216000	606	909	1,500	4,208	42	1520	0,168	1197	0,500
1141AL	223	216000	457	771	1,687	3,569	57	1394	0,216	1207	0,900
1141AL	277	227000	814	925	1,136	4,075	59	1205	0,074	1405	0,900
1141Nb	199	220000	418	659	1,577	2,995	53	1287	0,217	1000	0,800
1141Nb	241	217000	602	802	1,332	3,696	54	1199	0,126	1228	0,800
1141V	217	214000	450	725	1,611	3,388	49	1321	0,207	1087	0,700
1141V	229	220000	494	789	1,597	3,586	47	1379	0,187	1117	0,600
1141V	252	215000	610	797	1,307	3,707	58	1244	0,141	1243	0,900
1151V	205	206000	452	761	1,684	3,694	51	1346	0,19	1319	0,700
15B35	286	219000	866	940	1,085	4,292	65	1173	0,056	1747	0,100
15V24	243	207000	646	878	1,359	4,242	61	1318	0,129	1363	0,900
15V41	264	193000	666	1071	1,608	5,549	33	1670	0,148	767	0,395
C70	241	201000	765	964	1,260	4,796	17	1315	0,09	837	0,200

Tablica B.8 Ciklički i zamorni parametri nelegiranih čelika [1]

Oznaka materijala	Ciklički parametri			Zamorni parametri			
AISI	R_c' MPa	K' MPa	n'	σ_f' MPa	b	ε_f' MPa	c
1020	317	1171	0,2101	1055	-0,1166	0,565	-0,5465
1022	348	1180	0,1967	1100	-0,1077	0,662	-0,5418
1038	342	1340	0,2198	1039	-0,1062	0,303	-0,4794
1038	358	1420	0,2218	1004	-0,0984	0,202	-0,4399
1038	450	1242	0,1634	1179	-0,0904	0,626	-0,5383
1045	440	1302	0,1744	1346	-0,1086	1,174	-0,6192
1090	535	1877	0,202	1629	-0,115	0,339	-0,5213
1090	602	1964	0,1903	1715	-0,1046	0,798	-0,5996
1090	618	2163	0,2016	1858	-0,1157	0,449	-0,5723
1541	421	1400	0,1934	1237	-0,1075	0,369	-0,512
1050M	413	1987	0,2529	1552	-0,1246	0,377	-0,4927
10V45	436	1642	0,2133	1481	-0,1172	0,589	-0,5446
10V45	616	1691	0,1624	1588	-0,0996	0,78	-0,6322
1141AL	424	1515	0,2051	1168	-0,097	0,257	-0,4637
1141AL	593	1260	0,1212	1124	-0,0659	0,334	-0,525
1141Nb	405	1448	0,2051	1117	-0,0962	0,264	-0,4625
1141Nb	481	1254	0,1543	1080	-0,0793	0,361	-0,5083
1141V	447	1467	0,1913	1255	-0,1017	0,43	-0,5289
1141V	481	1441	0,1766	1326	-0,1034	0,602	-0,5813
1141V	487	1280	0,1541	1162	-0,0863	0,534	-0,5549
1151V	456	1473	0,1888	1430	-0,1157	0,819	-0,6084
15B35	645	1094	0,0849	1127	-0,0606	0,963	-0,6682
15V24	615	1453	0,1384	1481	-0,0939	0,817	-0,6359
15V41	712	1575	0,1278	1689	-0,094	0,87	-0,658
C70	572	1528	0,158	1561	-0,105	0,471	-0,56

Tablica B.9 Monotoni parametri niskolegiranih čelika [1]

Oznaka materijala	Monotoni parametri										
AISI	$\frac{HB}{HB}$	$\frac{E}{MPa}$	$\frac{R_c \text{ ili } R_{p0,2}}{MPa}$	$\frac{R_m}{MPa}$	R_m/R_c	$\frac{R_m/E}{10^{-3}}$	Z %	$\frac{K}{MPa}$	n	$\frac{\sigma_f}{MPa}$	ε_f
4140	325	207000	929	1043	1,123	5,039	61	1303	0,059	1519	1,000
4140	417	207000	1167	1240	1,063	5,990	47	1460	0,038	1537	0,640
4140	409	203000	1158	1248	1,078	6,148	48	1499	0,044	1311	0,646
4140	371	200000	1306	1401	1,073	7,005	48	1680	0,041	1771	0,700
4140	353	201000	1363	1514	1,111	7,532	48	1911	0,055	2071	0,650
4140	390	204000	1330	1537	1,156	7,534	42	2188	0,08	1705	0,600
4620	289	208000	688	998	1,451	4,798	58	1448	0,109	1530	0,900
5120	252	214000	780	1008	1,292	4,710	58	1277	0,074	1287	0,900
5140	305	218000	957	1039	1,086	4,766	53	1276	0,053	1445	0,800
5150	245	210000	472	867	1,837	4,129	56	1630	0,207	1382	0,800
8620	326	212000	694	991	1,428	4,675	54	1624	0,14	1411	0,776
8620	352	210000	796	1145	1,438	5,452	51	2132	0,165	1586	0,711
8620	382	214000	990	1311	1,324	6,126	52	2276	0,138	1711	0,736
8822	297	212000	884	946	1,070	4,462	67	1074	0,025	1170	1,115

nastavlja se na idućoj stranici

Tablica B.9 Monotoni parametri niskolegiranih čelika [1] (nastavak s prethodne stranice)

Oznaka materijala	Monotoni parametri										
AISI	$\frac{HB}{HB}$	$\frac{E}{MPa}$	$\frac{R_e \text{ ili } R_{p0,2}}{MPa}$	$\frac{R_m}{MPa}$	R_m/R_e	$\frac{R_m/E}{10^{-3}}$	$\frac{Z}{\%}$	$\frac{K}{MPa}$	n	$\frac{\sigma_f}{MPa}$	ε_f
8822	371	208000	1528	1723	1,128	8,284	50	2175	0,057	3387	0,672
9310	352	195000	990	1201	1,213	6,159	57	1796	0,094	2172	0,832
20MnCr5	301	194000	852	1053	1,236	5,428	57	1762	0,117	1991	0,832
20MnCr5	390	194000	1071	1337	1,248	6,892	52	1816	0,085	2351	0,740
4130AL	442	213000	1285	1483	1,154	6,962	44	1984	0,067	2055	0,600
41B17M (PS19)	277	213000	827	872	1,054	4,094	68	1031	0,042	1304	1,137
51B60	450	200000	1830	1970	1,077	9,850	22	2332	0,039	1968	0,200
86B20	336	205000	989	1034	1,046	5,044	64	1213	0,037	869	1,013
86B20	401	206000	1198	1502	1,254	7,291	60	2193	0,092	968	0,909

Tablica B.10 Ciklički i zamorni parametri niskolegiranih čelika [1]

Oznaka materijala	Ciklički parametri			Zamorni parametri			
AISI	$\frac{R_e'}{MPa}$	$\frac{K'}{MPa}$	n'	$\frac{\sigma_f'}{MPa}$	b	$\frac{\varepsilon_f'}{MPa}$	c
4140	670	1460	0,1254	1467	-0,0834	0,956	-0,6551
4140	851	1617	0,1013	1637	-0,0721	2,221	-0,7943
4140	856	1696	0,1101	1601	-0,0674	1,267	-0,7207
4140	852	1306	0,0686	1508	-0,064	2,81	-0,832
4140	911	1614	0,092	2192	-0,095	0,7	-0,635
4140	895	1591	0,0926	1684	-0,07	0,874	-0,677
4620	603	1824	0,178	1635	-0,1207	0,438	-0,5539
5120	628	1784	0,168	1284	-0,069	0,39	-0,562
5140	702	1329	0,1027	1354	-0,0691	1,647	-0,7478
5150	497	1485	0,1762	1544	-0,1142	1,136	-0,6382
8620	601	1872	0,1829	1639	-0,1007	0,469	-0,5473
8620	705	2078	0,1739	1910	-0,1028	0,595	-0,5871
8620	927	2137	0,1344	2210	-0,0987	0,525	-0,6184
8822	644	1154	0,0939	1095	-0,0525	1,097	-0,664
8822	1095	2055	0,101	2481	-0,1057	0,947	-0,8
9310	798	2098	0,129	1606	-0,076	0,275	-0,53
20MnCr5	613	2062	0,193	1356	-0,0703	0,24	-0,48
20MnCr5	976	2231	0,101	1994	-0,082	1,87	-0,8
4130AL	915	2151	0,1375	2294	-0,1013	1,443	-0,7255
41B17M (PS19)	611	1029	0,0838	1023	-0,0543	1,479	-0,7251
51B60	1272	2490	0,108	2582	-0,0833	0,452	-0,6396
86B20	705	1268	0,0943	1284	-0,0652	1,347	-0,7256
86B20	1075	2118	0,1091	2969	-0,1235	1,082	-0,7358

B.3.2 Podaci za razvoj umjetnih neuronskih mreža za procjenu zamornih parametara čelika

Tablica B.11 Monotoni parametri nelegiranih čelika [7, 14, 16, 73, 87]

Oznaka materijala	Monotoni parametri											
	DIN / SAE	$\frac{HB}{HB}$	$\frac{E}{MPa}$	$\frac{R_c \text{ ili } R_{p0,2}}{MPa}$	$\frac{R_m}{MPa}$	R_m/R_c	$\frac{R_m/E}{10^{-3}}$	$\frac{Z}{\%}$	$\frac{K}{MPa}$	n	$\frac{\sigma_f}{MPa}$	ε_f
1010			203000	200	331	1,655	1,631	80,4	534	0,185	870	1,630
1020	108		203000	255	393	1,541	1,936	64	400	0,072	795	1,022
1020	109		207000	262	441	1,683	2,130	61,8	738	0,19	865	0,962
1025			186000	306	547	1,788	2,941	62,6	1142	0,281	1085	0,983
1038	163		201000	331	582	1,758	2,896	54	1106	0,259	898	0,770
1038	195		219000	410	649	1,583	2,963	67	1183	0,221	1197	1,100
1038	185		219000	359	652	1,816	2,977	53	1186	0,219	1051	0,760
1090	259		203000	735	1090	1,483	5,369	14	1765	0,158	1254	0,150
1541	180		205000	475	783	1,648	3,820	55	1576	0,235	1409	0,800
1541	195		205000	475	906	1,907	4,420	42	1924	0,204	1395	0,540
1050(M)	205		211000	465	821	1,766	3,891	50	1819	0,274	1379	0,680
1050(M)	220		203000	460	829	1,802	4,084	34	1313	0,163	1177	0,420
1141 (A1FG)	223		216000	457	771	1,687	3,569	57	1394	0,216	1207	0,850
1141 (A1FG)	277		227000	814	925	1,136	4,075	59	1205	0,074	1405	0,880
1141 (NbFG)	199		220000	418	695	1,663	3,159	53	1287	0,217	999	0,760
1141 (NbFG)	241		217000	602	802	1,332	3,696	54	1199	0,126	1228	0,770
1141 (VFG)	217		214000	450	725	1,611	3,388	49	1321	0,207	1087	0,680
1141 (VFG)	229		220000	493	789	1,600	3,586	47	1379	0,187	1117	0,640
1141 (VFG)	252		215000	610	797	1,307	3,707	58	1244	0,141	1243	0,880
15B27	250		203000	772	847	1,097	4,172	69	1230	0,075	1839	1,171
15B27	264		203000	854	916	1,073	4,512	66,5	1279	0,065	1918	1,094
Ck 45			199000	432	659	1,525	3,312	58	1376	0,263	1231	0,868
St 42			206000	384	457	1,190	2,218	64	906	0,252	923	1,020
St 42			206000	384	457	1,190	2,218	64	906	0,252	923	1,020
St 52			206000	420	549	1,307	2,665	69	371	0,007	1192	1,171
St 52-3			205000	380	540	1,421	2,634	75	433	0,022	1289	1,386

Tablica B.12 Ciklički i zamorni parametri nelegiranih čelika [7, 14, 16, 73, 87]

Oznaka materijala	Ciklički parametri			Zamorni parametri				
	DIN / SAE	$\frac{R_c'}{MPa}$	$\frac{K'}{MPa}$	n'	$\frac{\sigma_f'}{MPa}$	b	$\frac{\varepsilon_f'}{MPa}$	c
1010		190	867-c	0,244-c	499	-0,1	0,104	-0,408
1020		208	1233-c	0,286c	697	-0,116	0,136	-0,405
1020		267	1962-c	0,321-c	1384	-0,156	0,337	-0,485
1025		288	1042-c	0,207-c	934	-0,107	0,59	-0,52
1038		342	1340	0,22	1043	-0,107	0,309	-0,481
1038		364	1330	0,208	1009	-0,097	0,225	-0,46
1038		358	1420	0,222	1004	-0,098	0,202	-0,44
1090		545	1611	0,174	1310	-0,091	0,25	-0,496

nastavlja se na idućoj stranici

Tablica B.12 Ciklički i zamorni parametri nelegiranih čelika [7, 14, 16, 73, 87] (nastavak s prethodne stranice)

Oznaka materijala	Ciklički parametri			Zamorni parametri			
	R_c' MPa	K' MPa	n'	σ_f' MPa	b	ε_f' MPa	c
1541	424	1416	0,194	1622	-0,135	0,515	-0,548
1541	469	950	0,114	1044	-0,083	0,513	-0,557
1050(M)	427	1673	0,22	989	-0,126	0,433	-0,512
1050(M)	523	1292	0,146	1094	-0,075	0,309	-0,502
1141 (A1FG)	424	1515	0,205	1168	-0,097	0,257	-0,464
1141 (A1FG)	591	1277	0,124	1127	-0,066	0,309	-0,514
1141 (NbFG)	405	1448	0,205	1117	-0,096	0,264	-0,462
1141 (NbFG)	481	1254	0,154	1080	-0,079	0,361	-0,508
1141 (VFG)	447	1467	0,191	1255	-0,102	0,43	-0,529
1141 (VFG)	481	1441	0,177	1326	-0,103	0,602	-0,581
1141 (VFG)	487	1270	0,154	1162	-0,086	0,534	-0,555
15B27	577	903-c	0,072-c	938	-0,057	1,689	-0,784
15B27	644	1026-c	0,075-c	1062	-0,059	1,575	-0,782
Ck 45	347	1439	0,229	1014	-0,1	0,223	-0,438
St 42	311	1053	0,196	750	-0,083	0,202	-0,44
St 42	362	1012	0,164	663	-0,083	0,0629	-0,477
St 52	352	1109	0,185	980	-0,1	0,495	-0,541
St 52-3	350	1050	0,177	1019	-0,109	0,846	-0,616

Tablica B.13 Monotoni parametri niskolegiranih čelika [7, 14, 16, 40, 81]

Oznaka materijala	Monotoni parametri										
	$\frac{HB}{HB}$	$\frac{E}{MPa}$	$\frac{R_c \text{ ili } R_{p0,2}}{MPa}$	$\frac{R_m}{MPa}$	R_m/R_c	$\frac{R_m/E}{10^{-3}}$	$\frac{Z}{\%}$	$\frac{K}{MPa}$	n	$\frac{\sigma_f}{MPa}$	ε_f
4142	380	206842	1378	1413	1,025	6,831	48	1892	0,051	1827	0,660
4142	380	207000	1378	1413	1,025	6,826	48	1892	0,051	2279	0,654
4142	400	200000	1447	1551	1,072	7,755	47	1765	0,032	2366	0,635
4142	450	207000	1584	1757	1,109	8,488	42	2069	0,043	2447	0,545
4142	450	206842	1585	1758	1,109	8,499	42	2071	0,043	2000	0,540
4142	450	200000	1860	1929	1,037	9,645	37	2054	0,016	2719	0,462
4142	475	207000	1722	1929	1,120	9,319	35	2321	0,048	2464	0,431
4142	475	206842	1723	1930	1,120	9,331	35	2322	0,048	2172	0,430
5160	430	203000	1488	1584	1,065	7,803	39,7	1941	0,0463	2241	0,506
1.8802		209000	460	614	1,335	2,938	55	923	0,15	1010	0,800
14Mn5	225	206000	580	697	1,202	3,383	68	858	0,067	1222	1,150
17MnCrMo33		206000	739	830	1,123	4,029	58	767	0,006	1550	0,868
28MnCu6		204000	330	580	1,758	2,843	64	938	0,19	950	1,030
40CrMo4		249000	934	1088	1,165	4,369	60	989	0,011	2085	0,916
40CrMo4		249000	937	1090	1,163	4,378	60	989	0,011	2089	0,916
41Cr4		200000	776	904	1,165	4,520	58	967	0,036	1688	0,868
43NiCr7-9		206000	1105	1174	1,062	5,699	56	1360	0,036	1636	0,830
M3		206900	580	875	1,509	4,229	48	1082	0,104	1447	0,654
StE 460		208000	510	682	1,337	3,279	48	1026	0,157	574	0,661

nastavlja se na idućoj stranici

Tablica B.13 Monotoni parametri niskolegiranih čelika [7, 14, 16, 40, 81] (nastavak s prethodne stranice)

Oznaka materijala	Monotoni parametri										
DIN / SAE	$\frac{HB}{HB}$	$\frac{E}{MPa}$	$\frac{R_c \text{ ili } R_{p0,2}}{MPa}$	$\frac{R_m}{MPa}$	R_m/R_c	$\frac{R_m/E}{10^{-3}}$	$\frac{Z}{\%}$	$\frac{K}{MPa}$	n	$\frac{\sigma_f}{MPa}$	ε_f
StE 460		208000	510	682	1,337	3,279	48	1026	0,157	574	0,661
StE 460		206842	1378	1413	1,025	3,279	48	1026	0,157	574	0,661
StE 460		207000	1378	1413	1,025	3,279	48	1026	0,157	574	0,661
StE 460		200000	1447	1551	1,072	3,279	32	1026	0,157	936	0,389
StE 690		207000	1584	1757	1,109	4,075	58	954	0,024	1446	0,867
StE 790		206842	1585	1758	1,109	3,981	22	727	0,112	965	0,251
TTSte 32		200000	1860	1929	1,037	2,670	63	970	0,214	995	1,000

Tablica B.14 Ciklički i zamorni parametri niskolegiranih čelika [7, 14, 16, 40, 81]

Oznaka materijala	Ciklički parametri			Zamorni parametri			
DIN / SAE	$\frac{R_c'}{MPa}$	$\frac{K'}{MPa}$	n'	$\frac{\sigma_f'}{MPa}$	b	$\frac{\varepsilon_f'}{MPa}$	c
4142	827	1974	0,14	1827	-0,08	0,45	-0,75
4142	1049	2266-c	0,124-c	2143	-0,094	0,637	-0,761
4142	955	1756-c	0,098-c	1787	-0,084	1,195	-0,859
4142	1156	1997-c	0,088-c	1937	-0,076	0,706	-0,869
4142	1068	2251	0,12	2000	-0,08	0,4	-0,73
4142	1105	1910-c	0,088-c	2079	-0,086	2,62	-0,972
4142	1338	2399-c	0,094-c	2161	-0,081	0,331	-0,854
4142	1344	3208	0,14	2172	-0,081	0,09	-0,66
5160	1062	1964-c	0,099-c	2054	-0,081	1,571	-0,821
1.8802	423	1196	0,168	1108	-0,096	0,4646	-0,543
14Mn5	529	2376	0,242	925	-0,09	0,062	-0,47
17MnCrMo33	550	1099	0,111	1052	-0,084	0,466	-0,689
28MnCu6	328	1255	0,216	1119	-0,122	0,724	-0,584
40CrMo4	674	1213	0,094	1190	-0,065	0,768	-0,679
40CrMo4	662	1110	0,083	1177	-0,065	1,397	-0,735
41Cr4	568	1675	0,174	1288	-0,093	0,221	-0,537
43NiCr7-9	726	1639	0,131	1655	-0,091	1,078	-0,692
M3	622	1340	0,123	1511	-0,093	1,684	-0,698
StE 460	396	1011	0,15	962	-0,088	0,5508	-0,563
StE 460	434	1181	0,161	1124	-0,094	0,1925	-0,437
StE 460	409	1176	0,17	849	-0,07	0,152	-0,415
StE 460	407	1288	0,185	1158	-0,101	0,2005	-0,44
StE 460	414	1146	0,164	1030	-0,103	0,666	-0,663
StE 690	527	1167	0,128	1191	-0,09	0,9113	-0,674
StE 790	407	1143	0,167	1116	-0,105	0,911	-0,636
TTSte 32	368	983	0,159	994	-0,095	0,2436	-0,464

B.4 Podaci za nelegirane i niskolegirane čelike korišteni za vrednovanje empirijskih metoda i umjetnih neuronskih mreža za procjenu cikličkih i zamornih parametara čelika

B.4.1 Podaci za vrednovanje empirijskih metoda i umjetnih neuronskih mreža za procjenu cikličkih parametara čelika

Tablica B.15 Monotoni parametri nelegiranih čelika [7, 14, 16, 20, 73, 80, 87]

Oznaka materijala	Monotoni parametri										
	DIN / SAE / AISI	HB	E MPa	R_c ili $R_{p0,2}$ MPa	R_m MPa	R_m/R_c	R_m/E 10^{-3}	Z %	K MPa	n	σ_f MPa
1020	108	203000	262	441	1,683	2,172	62	738	0,19	710	0,960
1038	195	219000	410	649	1,583	2,963	67	1183	0,221	1197	1,100
1045		202000	380	621	1,634	3,074	50,8	1185	0,23	985	0,710
1045	225	200000	634	724	1,142	3,620	65	1145	0,13	1227	1,040
1090	259	203000	735	1090	1,483	5,369	14	1765	0,158	1254	0,150
1541	180	205000	475	783	1,648	3,820	55	1576	0,235	1409	0,800
1541	195	205000	475	906	1,907	4,420	42	1924	0,204	1395	0,540
1050(M)	205	211000	465	821	1,766	3,891	50	1819	0,274	1379	0,680
1050(M)	220	203000	460	829	1,802	4,084	34	1313	0,163	1177	0,420
1141 (A1FG)	277	227000	814	925	1,136	4,075	59	1205	0,074	1405	0,880
1141 MA	259	212000	670	777	1,160	3,665	61,8	1153	0,122	1525	0,962
1141 MA	262	200000	524	875	1,670	4,375	40,2	1533	0,185	1325	0,514
Ck 45		199000	432	659	1,525	3,312	58	1376	0,263	1231	0,868
St 42		206000	384	457	1,190	2,218	64	906	0,252	923	1,020
St 42		206000	384	457	1,190	2,218	64	906	0,252	923	1,020
St 52		206000	420	549	1,307	2,665	69	371	0,007	1192	1,171
St 52-3		205000	380	540	1,421	2,634	75	433	0,022	1289	1,386

Tablica B.16 Ciklički i zamorni parametri nelegiranih čelika [7, 14, 16, 20, 73, 80, 87]

Oznaka materijala	Ciklički parametri			Zamorni parametri				
	DIN / SAE / AISI	R_c' MPa	K' MPa	n'	σ_f' MPa	b	ϵ_f' MPa	c
1020		241	772	0,18	896	-0,12	0,41	-0,51
1038		364	1330	0,208	1009	-0,097	0,225	-0,46
1045		345	1258	0,208	948	-0,092	0,26	-0,445
1045		414	1344	0,18	1227	-0,095	1	-0,66
1090		545	1611	0,174	1310	-0,091	0,25	-0,496
1541		424	1416	0,194	1622	-0,135	0,515	-0,548
1541		469	950	0,114	1044	-0,083	0,513	-0,557
1050(M)		427	1673	0,22	989	-0,126	0,433	-0,512
1050(M)		523	1292	0,146	1094	-0,075	0,309	-0,502
1141 (A1FG)		591	1277	0,124	1127	-0,066	0,309	-0,514

nastavlja se na idućoj stranici

Tablica B.16 Ciklički i zamorni parametri nelegiranih čelika [7, 14, 16, 20, 73, 80, 87] (nastavak s prethodne stranice)

Oznaka materijala	Ciklički parametri			Zamorni parametri				
	DIN / SAE / AISI	R_c' MPa	K' MPa	n'	σ_f' MPa	b	ε_f' MPa	c
1141 MA		493	1133	0,134	765	-0,04159	1,6641	-0,7044
1141 MA		564	1205	0,122	1296	-0,08855	1,0266	-0,6868
Ck 45		347	1439	0,229	1014	-0,1	0,223	-0,438
St 42		311	1053	0,196	750	-0,083	0,202	-0,44
St 42		362	1012	0,164	663	-0,083	0,0629	-0,477
St 52		352	1109	0,185	980	-0,1	0,495	-0,541
St 52-3		350	1050	0,177	1019	-0,109	0,846	-0,616

Tablica B.17 Monotoni parametri niskolegiranih čelika [7, 14, 16, 37, 40, 79, 80]

Oznaka materijala	Monotoni parametri										
	DIN / SAE / AISI	$\frac{HB}{HB}$	$\frac{E}{MPa}$	$\frac{R_c \text{ ili } R_{p0,2}}{MPa}$	$\frac{R_m}{MPa}$	R_m/R_c	$\frac{R_m/E}{10^{-3}}$	$\frac{Z}{\%}$	$\frac{K}{MPa}$	n	$\frac{\sigma_f}{MPa}$
4142	380	206842	1378	1413	1,025	6,831	48	1892	0,051	1827	0,660
4142	450	206842	1585	1758	1,109	8,499	42	2071	0,043	2000	0,540
5160	430	193000	1531	1669	1,090	8,648	42	2124	0,066	1931	0,870
9262	410	200000	1379	1565	1,135	7,825	32	1951	0,060	1855	0,380
1.8802		209000	460	614	1,335	2,938	55	923	0,150	1010	0,800
14Mn5	225	206000	580	697	1,202	3,383	68	858	0,067	1222	1,150
17MnCrMo33		206000	739	830	1,123	4,029	58	767	0,006	1550	0,868
23NiCr4	256	208531	725	808	1,114	3,875	66	762	0,007	1215	1,080
28MnCu6		204000	330	580	1,758	2,843	64	938	0,190	950	1,030
40CrMo4		249000	934	1088	1,165	4,369	60	989	0,011	2085	0,916
40CrMo4		249000	937	1090	1,163	4,378	60	989	0,011	2089	0,916
41Cr4		200000	776	904	1,165	4,520	58	967	0,036	1688	0,868
43NiCr7-9		207000	1105	1174	1,062	5,671	56	1360	0,036	1636	0,830
43NiCr7-9		206000	1105	1174	1,062	5,699	56	1360	0,036	1636	0,830
49MnVS3		206000	530	845	1,594	4,102	43	1390	0,180	1318	0,560
980X	225	194000	565	696	1,232	3,588	68	1248	0,130	1220	1,15
A723		200000	1170	1262	1,079	6,310	50	1483	0,037	2137	0,693
M3		206900	580	875	1,509	4,229	48	1082	0,104	1447	0,654
StE 460		208000	510	682	1,337	3,279	48	1026	0,157	574	0,661
StE 460		208000	510	682	1,337	3,279	48	1026	0,157	574	0,661
StE 460		208000	510	682	1,337	3,279	48	1026	0,157	574	0,661
StE 460		208000	510	682	1,337	3,279	48	1026	0,157	574	0,661
StE 460		208000	510	682	1,337	3,279	32	1026	0,157	936	0,389
StE 690		214000	810	872	1,077	4,075	58	954	0,024	1446	0,867
TTSte 32		209000	375	558	1,488	2,670	63	970	0,214	995	1,000

Tablica B.18 Ciklički i zamorni parametri niskolegiranih čelika [7, 14, 16, 37, 40, 79, 80]

Oznaka materijala	Ciklički parametri			Zamorni parametri				
	DIN / SAE / AISI	R_c' MPa	K' MPa	n'	σ_f' MPa	b	ε_f' MPa	c
4142		827	1974	0,14	1827	-0,08	0,45	-0,75
4142		1068	2251	0,12	2000	-0,08	0,4	-0,73
5160		1000	2310	0,15	1931	-0,071	0,4	-0,57
9262		1048	2013	0,089	1855	-0,057	0,38	-0,65
1.8802		423	1196	0,168	1108	-0,096	0,4646	-0,543
14Mn5		529	2376	0,242	925	-0,09	0,062	-0,47
17MnCrMo33		550	1099	0,111	1052	-0,084	0,466	-0,689
23NiCr4		576	1227	0,122	1272	-0,085	11,557	-0,907
28MnCu6		328	1255	0,216	1119	-0,122	0,724	-0,584
40CrMo4		674	1213	0,094	1190	-0,065	0,768	-0,679
40CrMo4		662	1110	0,083	1177	-0,065	1,397	-0,735
41Cr4		568	1675	0,174	1288	-0,093	0,221	-0,537
43NiCr7-9		705	1464	0,118	1127	-0,057	7,1959	-0,864
43NiCr7-9		726	1639	0,131	1655	-0,091	1,078	-0,692
49MnVS3		509	1245	0,14	1152	-0,09	0,6	-0,64
980X		558	1248	0,134	1055	-0,08	0,21	-0,53
A723		1014	1581	0,071	2123	-0,011	0,49	-0,783
M3		622	1340	0,123	1511	-0,093	1,684	-0,698
StE 460		396	1011	0,15	962	-0,088	0,5508	-0,563
StE 460		434	1181	0,161	1124	-0,094	0,1925	-0,437
StE 460		409	1176	0,17	849	-0,07	0,152	-0,415
StE 460		407	1288	0,185	1158	-0,101	0,2005	-0,44
StE 460		414	1146	0,164	1030	-0,103	0,666	-0,663
StE 690		527	1167	0,128	1191	-0,09	0,9113	-0,674
TTSte 32		368	983	0,159	994	-0,095	0,2436	-0,464

B.4.2 Podaci za vrednovanje empirijskih metoda i umjetnih neuronskih mreža za procjenu zamornih parametara čelika

Tablica B.19 Monotoni parametri nelegiranih čelika [1, 20, 87]

Oznaka materijala	Monotoni parametri											
	AISI / SAE	HB HB	E MPa	R_c ili $R_{p0,2}$ MPa	R_m MPa	R_m/R_c	R_m/E 10^{-3}	Z %	K MPa	n	σ_f MPa	ε_f
1020		135	207000	295	502	1,702	2,425	64	933	0,239	849	1,010
1022		195	200000	457	604	1,322	3,020	69	971	0,161	1587	1,160
1038		245	218000	560	743	1,327	3,408	69	1231	0,169	1292	1,160
1045			202000	380	621	1,634	3,074	50,8	1185	0,23	985	0,710
1045		222	209000	510	747	1,465	3,574	62	1334	0,199	1151	1,000
1090		259	219000	729	1090	1,495	4,977	14	1780	0,162	966	0,200
1541		180	197000	471	783	1,662	3,975	55	1165	0,143	1207	0,800
1050M		205	211000	450	821	1,824	3,891	50	1819	0,274	1128	0,700
10V45		212	213000	465	765	1,645	3,592	48	1456	0,223	1131	0,700

nastavlja se na idućoj stranici

Tablica B.19 Monotoni parametri nelegiranih čelika [1, 20, 87] (nastavak s prethodne stranice)

Oznaka materijala	Monotoni parametri										
AISI / SAE	$\frac{HB}{HB}$	$\frac{E}{MPa}$	$\frac{R_e \text{ ili } R_{p0,2}}{MPa}$	$\frac{R_m}{MPa}$	R_m/R_e	$\frac{R_m/E}{10^{-3}}$	$\frac{Z}{\%}$	$\frac{K}{MPa}$	n	$\frac{\sigma_f}{MPa}$	ε_f
10V45	269	216000	606	909	1,500	4,208	42	1520	0,168	1197	0,500
1141 MA	262	200000	524	875	1,670	4,375	40,2	1533	0,185	1325	0,514
1141AL	277	227000	814	925	1,136	4,075	59	1205	0,074	1405	0,900
1151V	205	206000	452	761	1,684	3,694	51	1346	0,19	1319	0,700
15V24	243	207000	646	878	1,359	4,242	61	1318	0,129	1363	0,900
15V41	264	193000	666	1071	1,608	5,549	33	1670	0,148	767	0,395
C70	241	201000	765	964	1,260	4,796	17	1315	0,09	837	0,200

Tablica B.20 Ciklički i zamorni parametri nelegiranih čelika [1, 20, 87]

Oznaka materijala	Ciklički parametri			Zamorni parametri			
DIN / SAE / AISI	$\frac{R_c'}{MPa}$	$\frac{K'}{MPa}$	n'	$\frac{\sigma_f'}{MPa}$	b	$\frac{\varepsilon_f'}{MPa}$	c
1020	317	1171	0,2101	1055	-0,1166	0,565	-0,5465
1022	348	1180	0,1967	1100	-0,1077	0,662	-0,5418
1038	450	1242	0,1634	1179	-0,0904	0,626	-0,5383
1045	345	1258	0,208	948	-0,092	0,26	-0,445
1045	440	1302	0,1744	1346	-0,1086	1,174	-0,6192
1090	535	1877	0,202	1629	-0,115	0,339	-0,5213
1541	421	1400	0,1934	1237	-0,1075	0,369	-0,512
1050M	413	1987	0,2529	1552	-0,1246	0,377	-0,4927
10V45	436	1642	0,2133	1481	-0,1172	0,589	-0,5446
10V45	616	1691	0,1624	1588	-0,0996	0,78	-0,6322
1141 MA	564	1205	0,122	1296	-0,08855	1,0266	-0,6868
1141AL	593	1260	0,1212	1124	-0,0659	0,334	-0,525
1151V	456	1473	0,1888	1430	-0,1157	0,819	-0,6084
15V24	615	1453	0,1384	1481	-0,0939	0,817	-0,6359
15V41	712	1575	0,1278	1689	-0,094	0,87	-0,658
C70	572	1528	0,158	1561	-0,105	0,471	-0,56

Tablica B.21 Monotoni parametri niskolegiranih čelika [1, 79]

Oznaka materijala	Monotoni parametri										
DIN / SAE / AISI	$\frac{HB}{HB}$	$\frac{E}{MPa}$	$\frac{R_e \text{ ili } R_{p0,2}}{MPa}$	$\frac{R_m}{MPa}$	R_m/R_e	$\frac{R_m/E}{10^{-3}}$	$\frac{Z}{\%}$	$\frac{K}{MPa}$	n	$\frac{\sigma_f}{MPa}$	ε_f
4140	325	207000	929	1043	1,123	5,039	61	1303	0,059	1519	1,000
4140	417	207000	1167	1240	1,063	5,990	47	1460	0,038	1537	0,640
4140	409	203000	1158	1248	1,078	6,148	48	1499	0,044	1311	0,646
4140	371	200000	1306	1401	1,073	7,005	48	1680	0,041	1771	0,700
4140	353	201000	1363	1514	1,111	7,532	48	1911	0,055	2071	0,650
4140	390	204000	1330	1537	1,156	7,534	42	2188	0,08	1705	0,600
4620	289	208000	688	998	1,451	4,798	58	1448	0,109	1530	0,900

nastavlja se na idućoj stranici

Tablica B.21 Monotoni parametri niskolegiranih čelika [1, 79] (nastavak s prethodne stranice)

Oznaka materijala	Monotoni parametri										
	DIN / SAE / AISI	$\frac{HB}{HB}$	$\frac{E}{MPa}$	$\frac{R_e \text{ ili } R_{p0,2}}{MPa}$	$\frac{R_m}{MPa}$	R_m/R_e	$\frac{R_m/E}{10^{-3}}$	$\frac{Z}{\%}$	$\frac{K}{MPa}$	n	$\frac{\sigma_f}{MPa}$
5120	252	214000	780	1008	1,292	4,710	58	1277	0,074	1287	0,900
5140	305	218000	957	1039	1,086	4,766	53	1276	0,053	1445	0,800
5150	245	210000	472	867	1,837	4,129	56	1630	0,207	1382	0,800
8620	326	212000	694	991	1,428	4,675	54	1624	0,14	1411	0,776
8620	352	210000	796	1145	1,438	5,452	51	2132	0,165	1586	0,711
8620	382	214000	990	1311	1,324	6,126	52	2276	0,138	1711	0,736
8822	297	212000	884	946	1,070	4,462	67	1074	0,025	1170	1,115
8822	371	208000	1528	1723	1,128	8,284	50	2175	0,057	3387	0,672
9310	352	195000	990	1201	1,213	6,159	57	1796	0,094	2172	0,832
20MnCr5	301	194000	852	1053	1,236	5,428	57	1762	0,117	1991	0,832
20MnCr5	390	194000	1071	1337	1,248	6,892	52	1816	0,085	2351	0,740
4130AL	442	213000	1285	1483	1,154	6,962	44	1984	0,067	2055	0,600
41B17M (PS19)	277	213000	827	872	1,054	4,094	68	1031	0,042	1304	1,137
49MnVS3		206000	530	845	1,594	4,102	43	1390	0,180	1318	0,560
86B20	336	205000	989	1034	1,046	5,044	64	1213	0,037	869	1,013
86B20	401	206000	1198	1502	1,254	7,291	60	2193	0,092	968	0,909

Tablica B.22 Ciklički i zamorni parametri niskolegiranih čelika [1, 79]

Oznaka materijala	Ciklički parametri			Zamorni parametri			
	DIN / SAE / AISI	$\frac{R_e'}{MPa}$	$\frac{K'}{MPa}$	n'	$\frac{\sigma_f'}{MPa}$	b	$\frac{\varepsilon_f'}{MPa}$
4140	670	1460	0,1254	1467	-0,0834	0,956	-0,6551
4140	851	1617	0,1013	1637	-0,0721	2,221	-0,7943
4140	856	1696	0,1101	1601	-0,0674	1,267	-0,7207
4140	852	1306	0,0686	1508	-0,064	2,81	-0,832
4140	911	1614	0,092	2192	-0,095	0,7	-0,635
4140	895	1591	0,0926	1684	-0,07	0,874	-0,677
4620	603	1824	0,178	1635	-0,1207	0,438	-0,5539
5120	628	1784	0,168	1284	-0,069	0,39	-0,562
5140	702	1329	0,1027	1354	-0,0691	1,647	-0,7478
5150	497	1485	0,1762	1544	-0,1142	1,136	-0,6382
8620	601	1872	0,1829	1639	-0,1007	0,469	-0,5473
8620	705	2078	0,1739	1910	-0,1028	0,595	-0,5871
8620	927	2137	0,1344	2210	-0,0987	0,525	-0,6184
8822	644	1154	0,0939	1095	-0,0525	1,097	-0,664
8822	1095	2055	0,101	2481	-0,1057	0,947	-0,8
9310	798	2098	0,129	1606	-0,076	0,275	-0,53
20MnCr5	613	2062	0,193	1356	-0,0703	0,24	-0,48
20MnCr5	976	2231	0,101	1994	-0,082	1,87	-0,8
4130AL	915	2151	0,1375	2294	-0,1013	1,443	-0,7255
41B17M (PS19)	611	1029	0,0838	1023	-0,0543	1,479	-0,7251
49MnVS3	509	1245	0,14	1152	-0,09	0,6	-0,64
86B20	705	1268	0,0943	1284	-0,0652	1,347	-0,7256
86B20	1075	2118	0,1091	2969	-0,1235	1,082	-0,7358

B.5 Podaci za visokolegirane čelike korišteni za vrednovanje empirijskih metoda i umjetnih neuronskih mreža za procjenu cikličkih i zamornih parametara čelika

Tablica B.23 Monotoni parametri visokolegiranih čelika [7, 14, 16, 32, 34, 75, 80]

Oznake materijala	Monotoni parametri										
AISI / DIN	$\frac{HB}{HB}$	$\frac{E}{MPa}$	$\frac{R_e \text{ ili } R_{p0,2}}{MPa}$	$\frac{R_m}{MPa}$	R_m/R_e	$\frac{R_m/E}{10^{-3}}$	$\frac{Z}{\%}$	$\frac{K}{MPa}$	n	$\frac{\sigma_f}{MPa}$	ε_f
304		183000	325	650	2,000	3,552	80	1210	0,193	1400	1,731
316	144	192682	251,5	550	2,187	2,854	73	640,9	0,159	1270	1,309
30304	160	186000	255	745	2,922	4,005	74			1916	1,370
30304	327	172000	745	951	1,277	5,529	69			2033	1,160
30310	145	193000	221	641	2,900	3,321	64			1158	1,010
X10CrNiTi18-9		210000	211	677	3,209	3,224	69			1470	1,171
X15CrNiSi25-20		210000	271	630	2,325	3,000	69			1368	1,171
X20CrMo12-1		210000	795	1013	1,274	4,824	47			1656	0,635
X5CrNiMo18-10		210000	228	665	2,917	3,167	81			1769	1,661
X8CrNiTi18-10		204000	222	569	2,563	2,789	76	349	0,062	1381	1,427

Tablica B.24 Ciklički i zamorni parametri visokolegiranih čelika [7, 14, 16, 32, 34, 75, 80]

Oznake materijala	Ciklički parametri			Zamorni parametri			
AISI	$\frac{R_e'}{MPa}$	$\frac{K'}{MPa}$	n'	$\frac{\sigma_f'}{MPa}$	b	$\frac{\varepsilon_f'}{MPa}$	c
304	279	1660	0,287	1000	-0,114	0,171	-0,402
316	297	904	0,179	1258,2	-0,097	0,121	-0,454
30304	717	6717	0,36	2413	-0,15	1,02	-0,69
30304	876	2520	0,17	2275	-0,12	0,89	-0,77
30310	345	1736	0,26	1655	-0,15	0,6	-0,57
X10CrNiTi18-9	496	3647	0,321	1968	-0,138	0,11	-0,393
X15CrNiSi25-20	289	2302	0,334	1512	-0,153	0,301	-0,465
X20CrMo12-1	730	1301	0,093	1216	-0,062	0,49	-0,664
X5CrNiMo18-10	259	2081	0,336	1999	-0,19	0,928	-0,572
X8CrNiTi18-10	383	5234	0,421	1658	-0,134	0,067	-0,323

Prilog C Rezultati postupne regresijske analize (unaprijedne selekcije)

C.1 Rezultati unaprijedne selekcije (postupne regresijske analize) monotonih značajki za procjenu cikličkih parametara nelegiranih, niskolegiranih i visokolegiranih čelika

U tablicama C.1 do C.9 dani su detaljni rezultati unaprijedne postupne regresije (unaprijedne selekcije) za određivanje monotonih značajki relevantnih za procjenu cikličkih parametara R_e' , K' i n' nelegiranih, niskolegiranih odnosno visokolegiranih čelika.

Crvenom bojom označene su vrijednosti koje su po nekom od kriterija utjecale na neuključivanje varijable u model. Vrijednosti otisnute masnim brojkama su prilagođeni koeficijent determinacije R_{adj}^2 i koeficijent determinacije za buduća predviđanja R_{pred}^2 krajnjeg modela za procjenu pojedinog cikličkog odnosno zamornog parametra i vrijednosti parcijalnog koeficijenta determinacije R_{seq}^2 varijabli (odnosno monotonih značajki) koje su uključene u model za procjenu pojedinog parametra.

Tablica C.1 Unaprijedna selekcija monotonih parametara za procjenu R_c / nelegiranih čelika

Varijable u modelu	$SS_E(F)$	$MS_E(F)$	$SS_R(B B_j)$	F-statistika	P-vrijednost	R_{adj}^2	R_{pred}^2	R_{seq}^2	VIF	Finalni model
R_m	100998	3156	371219	117,62	0,000	77,94	75,75			DA
$R_m^2 R_m$	87348	2818	13650	4,84	0,035	80,31	78,76	13,51		DA
$R_c R_m, R_m^2$	74950	2498	12397	4,96	0,034	82,54	80,41	14,19		DA
$R_c^2 R_m, R_m^2, R_c$	73446	2533	1504	0,59	0,447	82,30	79,65		>	
$R_{m/E} R_m, R_m^2, R_c$	74848	2581	102	0,04	0,844	81,96	77,85		>>	
$(R_m/E)^2 R_m, R_m^2, R_c, R_m/E$	72148	2577	2700	1,05	0,315	81,99	76,66		>>>	
$Z R_m, R_m^2, R_c$	53576	1847	21375	11,57	0,002	87,09	81,84	28,52		DA
$Z^2 R_m, R_m^2, R_c, Z$	52209	1865	1367	0,73	0,399	86,97	80,10		>	
$R_m/R_c R_m, R_m^2, R_c, Z$	52565	1877	1010	0,54	0,469	86,88	80,26		>>	
$(R_m/R_c)^2 R_m, R_m^2, R_c, Z, R_m/R_c$	52372	1940	194	0,10	0,754	86,44	77,28		>>	
$n R_m, R_m^2, R_c, Z$	46795	1671	6781	4,06	0,054	88,32	81,94	12,66		DA
$n^2 R_m, R_m^2, R_c, Z, n$	45438	1683	1357	0,81	0,377	88,24	81,06		>	
$\sigma_f R_m, R_m^2, R_c, Z, n$	46305	1715	490	0,29	0,597	88,02	80,11		>>	
$\sigma_f^2 R_m, R_m^2, R_c, Z, n, \sigma_f$	44019	1693	2286	1,35	0,256	88,17	80,33		>>	
$K R_m, R_m^2, R_c, Z, n$	46779	1733	16	0,01	0,925	87,89	81,10		>>	
$K^2 R_m, R_m^2, R_c, Z, n, K$	46475	1788	304	0,17	0,684	87,51	78,94		>>	
$E R_m, R_m^2, R_c, Z, n$	43455	1609	3339	2,07	0,161	88,75	78,61		>	
$E^2 R_m, R_m^2, R_c, Z, n, E$	39562	1582	2489	1,58	0,220	88,99	74,45		>	

Tablica C.2 Unaprijedna selekcija monotonih parametara za procjenu K' / nelegiranih čelika

Varijable u modelu	$SS_E(F)$	$MS_E(F)$	$SS_R(B B_j)$	F-statistika	P-vrijednost	R_{adj}^2	R_{pred}^2	R_{seq}^2	VIF	Finalni model
R_m	2336189	73006	1151883	15,78	0,000	30,93	21,57			DA
$R_m^2 R_m$	2173090	70100	163100	2,33	0,137	33,68	21,51			NE
$R_m/E R_m$	2132335	68785	203854	2,96	0,095	34,92	21,23	8,73	>>	
$(R_m/E)^2 R_m, R_m/E$	1995095	66503	137240	2,06	0,161	37,08	21,45		>>	
$K R_m$	2221240	71653	114949	1,60	0,215	32,21	18,83	4,92		NE
$K^2 R_m, K$	1984467	66149	236773	3,58	0,068	37,41	15,75	10,66		NE
$R_c R_m$	1902651	61376	433538	7,06	0,012	41,93	32,60			DA
$R_c^2 R_m, R_c$	1864346	62145	38305	0,62	0,439	41,21	28,76		>	
$Z R_m, R_c$	1864645	62155	38006	0,61	0,440	41,20	20,88		>>	
$Z^2 R_m, R_c, Z$	1859913	64135	4732	0,07	0,788	39,32	13,75			
$\sigma_f R_m, R_c$	1902635	63421	16	0,00	0,987	40,00	17,66			
$\sigma_f^2 R_m, R_c, \sigma_f$	1881710	64887	20925	0,32	0,574	38,61	4,17			
$E R_m, R_c$	1902664	63421	7	0,00	0,992	40,00	29,90			
$E^2 R_m, R_c, E$	1844569	63606	58074	0,91	0,347	39,92	15,52		>>	
$R_m/R_c R_m, R_c$	1869166	62306	33485	0,54	0,469	41,05	31,65		>>	
$(R_m/R_c)^2 R_m, R_c, R_m/R_c$	1827675	63023	41491	0,66	0,424	47,60	29,95		>>>	
$n R_m, R_c$	1684098	56137	218553	3,89	0,058	46,89	36,01	11,47		DA
$n^2 R_m, R_c, n$	1682008	58000	2091	0,04	0,851	45,13	29,32			

Tablica C.3 Unaprijedna selekcija monotonih parametara za procjenu n' nelegiranih čelika

Varijable u modelu	$SS_E(F)$	$MS_E(F)$	$SS_R(B B_j)$	F -statistika	P -vrijednost	R_{adj}^2	R_{pred}^2	R_{seq}^2	VIF	Finalni model
R_c	0,037956	0,001186	0,021486	18,11	0,000	34,15	27,80			DA
R_c^2	0,037822	0,001220	0,000134	0,11	0,742	32,27	21,12			
R_m/R_c	0,034771	0,001220	0,003245	2,90	0,099	37,84	31,49	8,55		DA
$(R_m/R_c)^2$	0,033124	0,001104	0,001587	1,44	0,240	38,70	30,89			
n	0,024240	0,000808	0,010471	12,96	0,001	55,14	45,88	30,17		DA
n^2	0,023920	0,000825	0,000320	0,39	0,538	54,21	42,98			
R_m	0,023552	0,000812	0,000688	0,85	0,365	54,91	35,64			
R_m^2	0,023507	0,000840	0,000045	0,05	0,819	53,39	27,45			
R_m/E	0,022939	0,000791	0,001301	1,65	0,210	56,09	39,98			
$(R_m/E)^2$	0,022930	0,000819	0,000009	0,01	0,919	54,54	26,59			
σ_f	0,023929	0,000825	0,000311	0,38	0,544	54,19	34,98			
σ_f^2	0,022205	0,000793	0,001723	2,17	0,152	55,97	30,37			
Z	0,024232	0,000836	0,000008	0,01	0,921	53,61	34,12			
Z^2	0,023549	0,000841	0,000638	0,81	0,375	53,31	19,99			
E	0,023832	0,000822	0,000408	0,50	0,487	54,38	41,15			
E^2	0,022841	0,000816	0,000991	1,21	0,280	54,71	39,70			
K	0,023911	0,000825	0,000329	0,40	0,533	54,23	36,37			
K^2	0,022886	0,000817	0,001026	1,25	0,272	54,62	36,23			

Tablica C.4 Unaprijedna selekcija monotonih parametara za procjenu R_c niskolegiranih čelika

Varijable u modelu	$SS_E(F)$	$MS_E(F)$	$SS_R(B B_j)$	F -statistika	P -vrijednost	R_{adj}^2	R_{pred}^2	R_{seq}^2	VIF	Finalni model
R_m	166422	3698	135505	366,39	0,000	88,82	87,71			DA
R_m^2	160521	3648	5901	1,62	0,210	88,97	86,69			
R_m/E	164677	3743	1745	0,47	0,498	88,68	87,31			
$(R_m/E)^2$	157113	3654	7564	2,07	0,157	88,95	86,36			
R_c	163199	3709	3222	0,87	0,356	88,79	84,54			
R_c^2	163084	3793	115	0,03	0,862	88,53	82,20			
K	156277	3552	10145	2,86	0,098	89,26	87,49	6,09		DA
K^2	125890	2928	30387	10,38	0,002	91,15	90,21	19,44		DA
σ_f	125613	2991	277	0,09	0,768	90,96	89,00			
σ_f^2	124174	3029	1439	0,48	0,495	90,84	88,17			
Z	125884	2997	6	0,00	0,964	90,94	88,02			
Z^2	124600	3039	1283	0,42	0,519	90,81	87,72			
R_m/R_c	71534	1703	54356	31,91	0,000	94,85	93,69	43,18		DA
$(R_m/R_c)^2$	64787	1580	6747	4,27	0,045	95,22	93,90	9,43		DA
n	63816	1595	971	0,61	0,440	95,18	92,85			
n^2	61354	1573	2462	1,56	0,218	95,24	92,77			
E	64053	1601	734	0,46	0,502	95,16	93,82			
E^2	64041	1642	13	0,01	0,930	95,04	93,53			

Tablica C.5 Unaprijedna selekcija monotonih parametara za procjenu K' niskolegiranih čelika

Varijable u modelu	$SS_E(F)$	$MS_E(F)$	$SS_R(B B_j)$	F -statistika	P -vrijednost	R_{adj}^2	R_{pred}^2	R_{seq}^2	V/F	Finalni model
R_m	2936352	65252	6094325	93,40	0,000	66,76	60,86			DA
R_m^2	2095525	47626	840827	17,65	0,000	75,74	72,07	28,63	>>	DA
R_m/E	2080064	48374	15461	0,32	0,575	75,36	69,17		>>	
$(R_m/E)^2$	2036963	48499	43101	0,89	0,351	75,30	61,17			
Z	1263226	29377	832299	28,33	0,000	85,04	83,15	39,72		DA
Z^2	1247067	29692	16159	0,54	0,465	84,88	82,82			
K	1253355	29842	9871	0,33	0,568	84,80	82,68			
K^2	1230935	30023	22420	0,75	0,393	84,71	82,70			
R_e	1256220	29910	7006	0,23	0,631	84,76	82,91		>>	
R_e^2	1217914	29705	38306	1,29	0,263	84,87	82,24		>>	
σ_f	1261191	30028	2035	0,07	0,796	84,70	81,89			
σ_f^2	1217444	29694	43746	1,47	0,232	84,87	82,24			
n	1257968	29952	5258	0,18	0,677	84,74	82,32			
n^2	1256454	30645	1515	0,05	0,825	84,39	80,93			
R_m/R_e	1260807	30019	2419	0,08	0,778	84,71	82,60			
$(R_m/R_e)^2$	1252145	30540	8662	0,28	0,597	84,44	80,45			
E	1243735	29613	19491	0,66	0,422	84,92	82,14			
E^2	1229105	29978	14630	0,49	0,489	84,73	78,94			

Tablica C.6 Unaprijedna selekcija monotonih parametara za procjenu n' niskolegiranih čelika

Varijable u modelu	$SS_E(F)$	$MS_E(F)$	$SS_R(B B_j)$	F -statistika	P -vrijednost	R_{adj}^2	R_{pred}^2	R_{seq}^2	V/F	Finalni model
R_m/R_e	0,031785	0,000706	0,020394	28,87	0,000	37,73	33,93			DA
$(R_m/R_e)^2$	0,030170	0,000686	0,001615	2,36	0,132	39,55	35,15	5,08		DA
n	0,031770	0,000722	0,000015	0,02	0,886	36,35	29,27	0,05		DA
n^2	0,028064	0,000653	0,003706	5,68	0,022	42,46	31,72	11,66		DA
σ_f	0,028057	0,000668	0,000008	0,01	0,915	41,11	28,85			
σ_f^2	0,027714	0,000676	0,000342	0,51	0,481	40,41	26,66			
Z	0,026362	0,000628	0,001703	2,71	0,107	44,67	33,50			
Z^2	0,026154	0,000638	0,000207	0,32	0,572	43,76	31,53			
R_e	0,027244	0,000649	0,000820	1,26	0,267	42,81	32,64			
R_e^2	0,027044	0,000660	0,000200	0,30	0,585	41,85	29,95			
R_m/E	0,027627	0,000658	0,000437	0,67	0,419	42,01	31,26			
$(R_m/E)^2$	0,027544	0,000672	0,000083	0,12	0,727	40,78	22,70			
R_m	0,027447	0,000653	0,000618	0,94	0,337	42,39	31,80			
R_m^2	0,027348	0,000667	0,000098	0,15	0,703	41,20	24,20			
K	0,027807	0,000662	0,000257	0,39	0,537	41,63	30,30			
K^2	0,027157	0,000662	0,000651	0,98	0,327	41,61	29,58			
E	0,027916	0,000665	0,000149	0,22	0,639	41,41	26,34			
E^2	0,027597	0,000673	0,000318	0,47	0,496	40,66	12,21			

Tablica C.7 Unaprijedna selekcija monotonih parametara za procjenu R_c visokolegiranih čelika

Varijable u modelu	$SS_E(F)$	$MS_E(F)$	$SS_R(B B_j)$	F -statistika	P -vrijednost	R_{adj}^2	R_{pred}^2	R_{seq}^2	VIF	Finalni model
R_m	287481	8712	918734	105,46	0,000	75,44	71,74			DA
$R_m^2 R_m$	257785	8056	29696	3,69	0,064	77,29	74,00	10,33		DA
$R_m/E R_m, R_m^2$	206937	6675	50848	7,62	0,010	81,18	76,95	19,72	>>	DA
$(R_m/E)^2 R_m, R_m^2, R_m/E$	190148	6338	16789	2,65	0,114	82,13	0,00		>>	
$R_c R_m, R_m^2, R_m/E$	204143	6805	2794	0,41	0,527	80,82	75,80	1,35	>>	DA
$R_c^2 R_m, R_m^2, R_m/E, R_c$	164431	5670	39712	7,00	0,013	84,02	80,40	19,19	>>	DA
$Z R_m, R_m^2, R_m/E, R_c, R_c^2$	162862	5817	1569	0,27	0,608	83,60	71,36	0,95	>>	DA
$Z^2 R_m, R_m^2, R_m/E, R_c, R_c^2, Z$	95034	3520	67829	19,27	0,000	90,08	83,12	41,6	>>	DA
$R_m/R_c R_m, \dots, Z, Z^2$	94977	3653	57	0,02	0,901	89,70	81,88		>>	
$(R_m/R_c)^2 R_m, \dots, Z, Z^2, R_m/R_c$	94792	3792	185	0,05	0,827	89,31	77,11		>>	
$E R_m, \dots, Z, Z^2$	89688	3450	5346	1,55	0,224	90,28	48,79		>>	
$E^2 R_m, \dots, Z, Z^2, E$	80929	3237	8759	2,71	0,113	90,88	13,44		>>	

Tablica C.8 Unaprijedna selekcija monotonih parametara za procjenu K' visokolegiranih čelika

Varijable u modelu	$SS_E(F)$	$MS_E(F)$	$SS_R(B B_j)$	F -statistika	P -vrijednost	R_{adj}^2	R_{pred}^2	R_{seq}^2	VIF	Finalni model
R_m/R_c	50320057	1524850	28219449	18,51	0,000	33,99	26,96			DA
$(R_m/R_c)^2 R_m/R_c$	41709633	1303426	8610424	6,61	0,015	43,57	37,48	17,11		DA
$R_c R_m/R_c, (R_m/R_c)^2$	41229183	1329974	480450	0,36	0,552	42,43	37,43		>>	
$R_c^2 R_m/R_c, (R_m/R_c)^2, R_c$	38334884	1277829	2894299	2,27	0,143	44,68	38,34			
$R_m R_m/R_c, (R_m/R_c)^2$	40060188	1292264	1649445	1,28	0,267	44,06	38,39			
$R_m^2 R_m/R_c, (R_m/R_c)^2, R_m$	37426028	1247534	2634159	2,11	0,157	45,99	40,52			
$R_m/E R_m/R_c, (R_m/R_c)^2, R_m$	38783271	1251073	2926362	2,34	0,136	45,84	40,59			
$(R_m/E)^2 R_m/R_c, (R_m/R_c)^2, R_m/E$	37086137	1236205	1697135	1,37	0,251	46,48	41,30			
$Z R_m/R_c, (R_m/R_c)^2, Z$	40050208	1291942	1659426	1,28	0,266	44,07	37,53			
$Z^2 R_m/R_c, (R_m/R_c)^2, Z$	39473972	1315799	576236	0,44	0,613	43,04	35,28			
$E R_m/R_c, (R_m/R_c)^2, Z$	38945025	1256291	2764608	2,20	0,148	45,61	40,29			
$E^2 R_m/R_c, (R_m/R_c)^2, E$	38447383	1281579	497641	0,39	0,538	44,52	34,54			

Tablica C.9 Unaprijedna selekcija monotonih parametara za procjenu n' visokolegiranih čelika

Varijable u modelu	$SS_E(F)$	$MS_E(F)$	$SS_R(B B_j)$	F -statistika	P -vrijednost	R_{adj}^2	R_{pred}^2	R_{seq}^2	VIF	Finalni model
R_c	0,091750	0,002780	0,311238	111,94	0,000	76,54	74,96			DA
R_c^2	0,008259	0,083491	0,002609	3,17	0,085	77,99	76,38	2,84		NE
R_m/R_c	0,080584	0,002518	0,011166	4,43	0,043	78,75	76,88	12,17		DA
$(R_m/R_c)^2$	0,080050	0,002582	0,000533	0,21	0,653	78,21	76,07			
$R_m R_c, R_m/R_c$	0,079954	0,002579	0,000619	0,24	0,628	78,24	76,20		\gg	
$R_m^2 R_c, R_m/R_c, R_m$	0,079747	0,002658	0,000218	0,08	0,777	77,57	75,05		\gg	
$R_m/E R_c, R_m/R_c$	0,079040	0,002550	0,001544	0,61	0,442	78,49	76,02		\gg	
$(R_m/E)^2 R_c, R_m/R_c, R_m/E$	0,078197	0,002607	0,000843	0,33	0,574	78,01	75,27		\gg	
$Z R_c, R_m/R_c$	0,078871	0,002544	0,001712	0,67	0,418	78,53	69,53			
$Z^2 R_c, R_m/R_c, Z$	0,070508	0,002350	0,008364	3,56	0,069	80,17	71,02	10,60		NE
$E R_c, R_m/R_c$	0,079398	0,002561	0,001186	0,46	0,501	78,39	75,57			
$E^2 R_c, R_m/R_c, E$	0,079394	0,002646	0,000004	0,00	0,970	77,67	69,04			

C.2 Rezultati unaprijedne selekcije (postupne regresijske analize) monotonih značajki za procjenu zamornih parametara nelegiranih, niskolegiranih i visokolegiranih čelika

U tablicama C.10 do C.18 dani su detaljni rezultati unaprijedne postupne regresije (unaprijedne selekcije) za određivanje monotonih značajki relevantnih za procjenu zamornih parametara σ_f' , b , ε_f' , c nelegiranih, niskolegiranih i visokolegiranih čelika.

Crvenom bojom označene su vrijednosti koje su po nekom kriteriju utjecale na neuključivanje varijable u model. Vrijednosti otisnute masnim brojkama su prilagođeni koeficijent determinacije R_{adj}^2 i koeficijent determinacije za buduća predviđanja R_{pred}^2 krajnjeg modela za procjenu pojedinog cikličkog odnosno zamornog parametra i vrijednosti parcijalnog koeficijenta determinacije R_{seq}^2 varijabli (odnosno monotonih značajki) koje su uključene u model za procjenu pojedinog parametra.

Podaci za procjenu ε_f' i c nelegiranih čelika te ε_f' niskolegiranih čelika nedostaju s obzirom na to da se odgovarajuće analize nisu mogle provesti, kako je objašnjeno u 4.4.2.4 i 4.4.2.5.

Tablica C.10 Unaprijedna selekcija monotonih parametara za procjenu σ_f' nelegiranih čelika

Varijable u modelu	$SS_E(F)$	$MS_E(F)$	$SS_R(B B_j)$	F -statistika	P -vrijednost	R_{adj}^2	R_{pred}^2	R_{seq}^2	VIF	Finalni model
R_m	2308743	72148	1132872	15,70	0,000	30,82	19,30			DA
R_m^2 R_m	2253079	72680	55664	0,77	0,388	30,31	0,00		>>>	NE
R_m/E R_m	2021117	65197	287626	4,41	0,444	37,49	15,50	12,45	>>>	NE
$(R_m/E)^2$ R_m , R_m/E	1989803	66327	31313	0,47	0,497	36,40	0,00		>>>	DA
K R_m	2097595	67664	211148	3,12	0,087	35,12	22,69	9,14		DA
K^2 R_m , K	1556395	51880	541200	10,43	0,003	50,25	27,42	25,80		DA
σ_f R_m , K , K^2	1398597	48227	157798	3,27	0,081	53,76	23,42	10,13		DA
σ_f^2 R_m , K , K^2 , σ_f	1266552	45234	132045	2,92	0,099	56,63	26,89	9,44		DA
R_e R_m , K , K^2 , σ_f , σ_f^2	1005413	37238	261139	7,01	0,013	64,29	35,16	20,62	>	DA
R_e^2 R_m , K , K^2 , σ_f , σ_f^2 , R_e	799526	30751	205887	6,70	0,016	70,51	55,82	20,48	>	DA
Z R_m , K , K^2 , σ_f , σ_f^2 , R_e , R_e^2	788513	31541	11012	0,35	0,560	69,76	51,60		>>>	DA
Z^2 R_m , ..., R_e^2 , Z	763081	31795	25432	0,80	0,380	69,51	50,76		>>>	DA
E R_m , ..., R_e , R_e^2	770604	30824	28922	0,94	0,342	70,44	48,43		>>>	DA
E^2 R_m , ..., R_e^2 , E	764249	31844	6355	0,20	0,659	69,47	45,30		>>>	DA
n R_m , ..., R_e , R_e^2	789208	31568	10317	0,33	0,573	69,73	50,20		>>>	DA
n^2 R_m , ..., R_e^2 , n	745193	31050	44015	1,42	0,245	70,23	49,84		>>>	DA
R_m/R_e R_m , ..., R_e , R_e^2	767782	30711	31744	1,03	0,319	70,55	38,35		>>>	DA
$(R_m/R_e)^2$ R_m , ..., R_e^2 , R_m/R_e	732112	30505	35670	1,17	0,290	70,75	32,88		>>>	DA

Tablica C.11 Unaprijedna selekcija monotonih parametara za procjenu b nelegiranih čelika

Varijable u modelu	$SS_E(F)$	$MS_E(F)$	$SS_R(B B_j)$	F -statistika	P -vrijednost	R_{adj}^2	R_{pred}^2	R_{seq}^2	VIF	Finalni model
R_m/R_e	0,012916	0,000404	0,005271	13,06	0,001	26,76	17,85			DA
$(R_m/R_e)^2$ R_m/R_e	0,010744	0,000347	0,002172	6,27	0,018	37,11	26,94	16,82		DA
R_e R_m/R_e , $(R_m/R_e)^2$	0,010708	0,000357	0,000037	0,10	0,751	35,24	16,00			DA
R_e^2 R_m/R_e , $(R_m/R_e)^2$, R_e	0,010703	0,000369	0,000005	0,01	0,912	33,03	0,00			DA
n R_m/R_e , $(R_m/R_e)^2$	0,010360	0,000345	0,000384	1,11	0,300	37,34	24,40			DA
n^2 R_m/R_e , $(R_m/R_e)^2$, n	0,009896	0,000341	0,000464	1,36	0,253	38,08	20,50			DA
E R_m/R_e , $(R_m/R_e)^2$	0,010328	0,000344	0,000416	1,21	0,280	37,53	16,71			DA
E^2 R_m/R_e , $(R_m/R_e)^2$, E	0,009536	0,000329	0,000792	2,41	0,131	40,33	18,05			DA
R_m R_m/R_e , $(R_m/R_e)^2$	0,010677	0,000356	0,000068	0,19	0,666	35,42	16,90			DA
R_m^2 R_m/R_e , $(R_m/R_e)^2$, R_m	0,010557	0,000364	0,000120	0,33	0,571	33,95	0,00			DA
R_m/E R_m/R_e , $(R_m/R_e)^2$	0,010628	0,000354	0,000016	0,33	0,571	35,72	17,16			DA
$(R_m/E)^2$ R_m/R_e , $(R_m/R_e)^2$, R_m/E	0,010348	0,000357	0,000280	0,78	0,383	35,25	0,00			DA
σ_f R_m/R_e , $(R_m/R_e)^2$	0,010356	0,000345	0,000388	1,12	0,298	37,36	19,12	3,61		DA
σ_f^2 R_m/R_e , $(R_m/R_e)^2$, σ_f	0,008053	0,000278	0,002303	8,29	0,007	49,61	28,77	22,24		DA
K R_m/R_e , $(R_m/R_e)^2$, σ_f	0,007754	0,000277	0,000299	1,08	0,307	49,75	20,79			DA
K^2 R_m/R_e , $(R_m/R_e)^2$, σ_f , σ_f^2	0,007525	0,000279	0,000224	0,80	0,378	49,40	0,00			DA
Z R_m/R_e , $(R_m/R_e)^2$, σ_f , σ_f^2	0,008051	0,000288	0,000002	0,01	0,935	47,83	16,32	0,25		DA
Z^2 R_m/R_e , $(R_m/R_e)^2$, σ_f , σ_f^2 , Z	0,007183	0,000266	0,000869	3,27	0,082	51,73	25,92	10,79		DA

Tablica C.12 Unaprijedna selekcija monotonih parametara za procjenu σ_f^2 niskolegiranih čelika

Varijable u modelu	$SS_E(F)$	$MS_E(F)$	$SS_R(B B_j)$	F -statistika	P -vrijednost	R_{adj}^2	R_{pred}^2	R_{seq}^2	VIF	Finalni model
R_m	2895773	64351	5569107	86,54	0,000	65,03	60,78			DA
R_m^2	2716974	61749	178179	2,90	0,096	66,44	37,15	6,15		NE
K	2350813	53428	544960	10,20	0,003	70,97	64,03	18,82		DA
K^2	1978045	46001	372768	8,10	0,007	75,00	62,03	15,86		DA
R_m/E	1846191	43957	131855	3,00	0,091	76,11	64,06	6,66	>>	
$(R_m/E)^2$	1846011	45025	180	0,00	0,950	75,53	57,44		>>	
R_c	1941807	46233	36239	0,78	0,381	74,88	61,32		>>	
R_c^2	1930074	47075	11723	0,25	0,620	74,42	55,23		>>	
Z	1978044	47096	1	0,00	0,996	74,41	59,08	0,00		DA
Z^2	1692497	41280	285547	6,92	0,012	77,57	64,13	14,43		DA
σ_f	1688365	42209	4131	0,10	0,756	77,06	62,75			
σ_f^2	1668392	42779	19974	0,47	0,498	76,75	55,70			
R_m/R_c	1605829	40146	86668	2,16	0,150	78,18	67,06	5,12		DA
$(R_m/R_c)^2$	1597618	40965	8211	0,20	0,657	77,47	65,87			
n	1565241	39131	127256	3,25	0,079	78,74	67,54	7,52	>>	NE
n^2	1565240	40134	1	0,00	0,996	78,19	64,87		>>	
E	1624896	40622	67601	1,66	0,204	77,92	63,92			
E^2	1624021	41642	874	0,02	0,886	77,37	62,66			

Tablica C.13 Unaprijedna selekcija monotonih parametara za procjenu b niskolegiranih čelika

Varijable u modelu	$SS_E(F)$	$MS_E(F)$	$SS_R(B B_j)$	F -statistika	P -vrijednost	R_{adj}^2	R_{pred}^2	R_{seq}^2	VIF	Finalni model
R_m/R_c	0,014693	0,000327	0,004088	12,51	0,001	20,03	15,69			DA
$(R_m/R_c)^2$	0,014407	0,000327	0,000286	0,87	0,355	19,80	13,65			
n	0,014444	0,000328	0,000249	0,76	0,388	19,60	14,79			
n^2	0,014249	0,000331	0,000195	0,59	0,448	18,84	12,52			DA
K	0,011746	0,000267	0,002947	11,04	0,002	34,62	24,33	20,05		DA
K^2	0,011637	0,000271	0,000108	0,40	0,530	33,71	15,24			DA
Z	0,011642	0,000271	0,000104	0,38	0,538	33,69	22,82	0,88		DA
Z^2	0,010631	0,000253	0,000101	3,99	0,052	38,00	30,57	8,68		DA
R_m	0,010610	0,000259	0,000020	0,08	0,781	36,61	26,49			
R_m^2	0,009932	0,000248	0,000679	2,73	0,106	39,19	23,78			
R_m/E	0,010606	0,000259	0,000025	0,10	0,757	36,64	27,33	0,24		DA
$(R_m/E)^2$	0,009759	0,000244	0,000847	3,47	0,070	40,24	33,61	7,99		DA
E	0,009549	0,000245	0,000210	0,86	0,361	40,03	31,75		>	
E^2	0,009376	0,000247	0,000173	0,70	0,407	39,56	30,89		>	
σ_f	0,009744	0,000250	0,000015	0,06	0,807	38,80	31,51		>>	
σ_f^2	0,009583	0,000252	0,000161	0,64	0,429	38,23	25,27		>>	
R_c	0,009754	0,000250	0,000005	0,02	0,893	38,74	29,32		>>	
R_c^2	0,009492	0,000250	0,000262	1,05	0,312	38,82	20,02		>>	

Tablica C.14 Unaprijedna selekcija monotonih parametara za procjenu c niskolegiranih čelika

Varijable u modelu	$SS_E(F)$	$MS_E(F)$	$SS_R(B B_j)$	F -statistika	P -vrijednost	R_{adj}^2	R_{pred}^2	R_{seq}^2	VIF	Finalni model
Z	0,413726	0,009194	0,069077	7,51	0,009	12,40	4,77			DA
Z^2	0,400848	0,009110	0,012878	1,41	0,241	13,20	0,00			DA
R_m/R_c	0,393166	0,008936	0,020561	2,30	0,136	14,86	4,49	7,37		DA
$(R_m/R_c)^2$	0,364171	0,008469	0,028995	3,42	0,071	19,31	4,63	4,64		DA
n	0,347276	0,008268	0,016895	2,04	0,160	21,22	6,89	5,19		DA
n^2	0,329248	0,008030	0,018028	2,24	0,142	31,80	13,14			DA
σ_f	0,323089	0,008077	0,006159	0,76	0,388	23,04	3,38			
σ_f^2	0,322600	0,008272	0,000488	0,06	0,809	21,19	0,00			
E	0,325379	0,008190	0,001663	0,20	0,655	21,97	10,76			
E^2	0,310076	0,008343	0,002206	0,26	0,610	20,51	0,44			
R_c	0,303075	0,007752	0,019172	2,47	0,124	26,14	7,67			
R_c^2	0,30394	0,007771	0,007001	0,90	0,348	25,96	8,33			
R_m	0,301272	0,007635	0,023854	3,12	0,085	27,26	9,37	7,24		NE
R_m^2	0,302498	0,007725	0,004122	0,53	0,469	26,40	9,22			
R_m/E	0,297471	0,007756	0,002896	0,37	0,545	26,10	6,47			
$(R_m/E)^2$	0,304761	0,007828	0,005027	0,64	0,428	25,42	5,72			
K	0,303383	0,007814	0,000634	0,08	0,777	25,55	4,42			
K^2		0,007984	0,001378	0,17	0,680	23,93	0,50			

Tablica C.15 Unaprijedna selekcija monotonih parametara za procjenu σ_f visokolegiranih čelika

Varijable u modelu	$SS_E(F)$	$MS_E(F)$	$SS_R(B B_j)$	F -statistika	P -vrijednost	R_{adj}^2	R_{pred}^2	R_{seq}^2	VIF	Finalni model
R_m/R_c	6159582	186654	1802424	9,66	0,004	20,29	13,56			DA
$(R_m/R_c)^2$	6075131	189848	84451	0,44	0,510	18,93	9,20			
R_c	5834987	182343	324595	1,78	0,192	22,13	15,46			
R_c^2	5389484	173854	445504	2,56	0,120	25,76	17,71			
R_m	5979737	186867	179845	0,96	0,334	20,20	14,46			
R_m^2	5573672	179796	406065	2,26	0,143	23,22	14,76			
R_m/E	5779965	180624	379617	2,10	0,157	22,87	16,19	6,16		DA
$(R_m/E)^2$	4816287	153364	963678	6,20	0,018	33,66	25,42	16,67		DA
E	4492912	149764	323375	2,16	0,152	36,05	28,60			
E^2	4492419	154911	493	0,00	0,955	33,85	23,38			
Z	4771462	159049	44825	0,28	0,599	32,08	17,98			
Z^2	4771370	164530	92	0,00	0,981	29,74	10,39			

Tablica C.16 Unaprijedna selekcija monotonihi parametara za procjenu b visokolegiranihi čelika

Varijable u modelu	$SS_E(F)$	$MS_E(F)$	$SS_R(B B_j)$	F -statistika	P -vrijednost	R_{adj}^2	R_{pred}^2	R_{seq}^2	VIF	Finalni model
R_m	0,034131	0,001034	0,001034	40,85	0,000	53,96	49,45			
$R_m^2 R_m$	0,025783	0,000806	0,008348	10,36	0,003	64,13	61,44	24,46		DA
$R_e R_m, R_m^2$	0,022247	0,000718	0,003537	4,93	0,034	68,05	64,59	13,72		DA
$R_c^2 R_m, R_m^2, R_e$	0,021122	0,000704	0,001125	1,60	0,216	68,66	65,88		>	
$R_{mf}/E R_m, R_m^2, R_e$	0,019778	0,000659	0,002469	3,75	0,062	70,65	66,62	11,10	>>	DA
$(R_m/E)^2 R_m, R_m^2, R_e, R_{mf}/E$	0,019031	0,000656	0,000746	1,14	0,295	70,79	67,13		>>	
$R_{mf}/R_e R_m, R_m^2, R_e, R_{mf}/E$	0,019085	0,000658	0,000692	1,05	0,314	70,70	67,27		>>	
$(R_m/R_c)^2 R_m, R_m^2, R_e, R_m/E, R_m/R_c$	0,018327	0,000655	0,000759	1,16	0,291	70,86	68,98		>>	
$Z R_m, R_m^2, R_e, R_m/E$	0,019695	0,000679	0,000083	0,12	0,730	69,77	62,00		>>	
$Z^2 R_m, R_m^2, R_e, R_m/E, Z$	0,018059	0,000645	0,001636	2,54	0,123	71,29	59,20		>>	
$E R_m, R_m^2, R_e, R_m/E$	0,019090	0,000658	0,000688	1,05	0,315	70,70	66,61		>>	
$E^2 R_m, R_m^2, R_e, R_m/E, E$	0,018828	0,000672	0,000262	0,39	0,538	70,07	53,14		>>	

Tablica C.17 Unaprijedna selekcija monotonihi parametara za procjenu ε_f visokolegiranihi čelika

Varijable u modelu	$SS_E(F)$	$MS_E(F)$	$SS_R(B B_j)$	F -statistika	P -vrijednost	R_{adj}^2	R_{pred}^2	R_{seq}^2	VIF	Finalni model
E	4,45630	0,1383	0,44930	3,25	0,081	6,20	0,00			
$E^2 E$	4,40370	0,1367	0,16060	1,17	0,288	6,68	3,53			NE
R_m/R_c	4,88380	0,1480	0,12980	0,88	0,356	0,00	0,00			
$(R_m/R_c)^2 R_m/R_c$	4,85734	0,15179	0,02650	0,17	0,679	0,00	0,00			
R_e	4,93177	0,14945	0,08189	0,55	0,464	0,00	0,00			
$R_c^2 R_e$	4,52837	0,14151	0,40340	2,85	0,101	4,03	0,00			
Z	4,97521	0,15076	0,03846	0,26	0,617	0,00	0,00			
$Z^2 Z$	4,96274	0,15509	0,01247	0,08	0,779	0,00	0,00			
R_m/E	5,00197	0,15157	0,01169	0,08	0,783	0,00	0,00			
$(R_m/E)^2 R_m/E$	3,23641	0,10114	1,76556	17,46	0,000	31,41	17,79	35,30	>>	DA
$R_m R_m/E, (R_m/E)^2$	2,96918	0,09578	0,26724	2,79	0,105	35,05	21,01		>>	
$R_m^2 R_m/E, (R_m/E)^2, R_m$	2,90114	0,09670	0,06804	0,70	0,408	34,42	6,60		>>	

Tablica C.18 Unaprijedna selekcija monotonih parametara za procjenu c visokolegiranih čelika

Varijable u modelu	$SS_E(F)$	$MS_E(F)$	$SS_R(B B_J)$	F -statistika	P -vrijednost	R_{adj}^2	R_{pred}^2	R_{seq}^2	VIF	Finalni model
R_e	0,295300	0,008948	0,148051	16,54	0,000	31,38	27,50			DA
$R_e^2 R_e$	0,284430	0,008888	0,018730	1,22	0,277	37,84	25,61			
$R_m/R_e R_e$	0,281910	0,008810	0,013385	1,52	0,227	32,44	27,23			
$(R_m/R_e)^2 R_e, R_m/R_e$	0,281829	0,009091	0,000085	0,01	0,923	30,28	22,38			
$R_m R_e$	0,241120	0,007535	0,054181	7,19	0,011	42,22	35,97	18,35		DA
$R_m^2 R_e, R_m$	0,180320	0,005817	0,060800	10,45	0,003	55,39	50,94	25,21		DA
$Z R_e, R_m, R_m^2$	0,180271	0,006009	0,000051	0,01	0,927	53,92	48,10			
$Z^2 R_e, R_m, R_m^2, Z$	0,179912	0,006204	0,000358	0,06	0,812	52,42	44,81			
$R_m/E R_e, R_m, R_m^2$	0,179967	0,005999	0,000355	0,06	0,810	54,00	48,64			
$(R_m/E)^2 R_e, R_m, R_m^2, R_m/E$	0,177077	0,006106	0,002890	0,47	0,497	53,17	0,00		>	
$E R_e, R_m, R_m^2$	0,180313	0,006010	0,000009	0,00	0,970	53,91	47,24			
$E^2 R_e, R_m, R_m^2, E$	0,178282	0,006148	0,002031	0,33	0,570	52,85	44,31			

Prilog D Primjeri MATLAB koda za učenje umjetnih neuronskih mreža

D.1 Primjeri koda za učenje umjetnih neuronskih mreža za procjenu cikličkih i zamornih parametara čelika

Umjetne neuronske mreže modelirane su pomoću programskog paketa MATLAB 2010b [54].

U prilogima D.2 i D.3 prikazani su primjeri koda za učenje umjetnih neuronskih mreža za procjenu cikličkih i zamornih parametara čelika korištenjem različitih algoritama za učenje pogreške i to

- Levenberg–Marquadtovog algoritma s ranim zaustavljanjem, kao primjerom koda za učenje pogreške kombiniranog s metodom ranog zaustavljanja, i
- algoritma koji koristi Bayesovu regularizaciju, kao primjerom koda za učenje pogreške koji ne koristi metodu ranog zaustavljanja.

Levenberg–Marquadtov algoritam za učenje bez implementiranog ranog zaustavljanja vrlo se malo se razlikuje od algoritma koji koristi Bayesovu regularizaciju, pa stoga nije prikazan. Svi korišteni algoritmi koriste metodu 10-struke unakrsne validacije.

D.2 Kod za učenje umjetne neuronske mreže za procjenu cikličke granice tečenja R_e' nelegiranih čelika pomoću 10-struke unakrsne validacije i Levenberg–Marquadtovog algoritma za učenje pogreške s ranim zaustavljanjem

```
% Primjena umjetnih neuronskih mreza za aproksimaciju funkcije -  
% predviđanja ciklicke granice tecenja Re niskolegiranih celika pomocu  
% Levenberg–Marquadtovog algoritma za ucenje s ranim zaustavljanjem i  
% 10-struke unakrsne validacije (engl. 10-fold cross-validation)  
  
% Skripta podrazumijeva da su definirane sljedece varijable:  
%  
% MP_UA_Re - ulazni podaci.  
% UA_Re - ciljani podaci.  
  
close all, clear all  
  
tic % pocetak mjerenja vremena  
  
load varUA_Re % ucitava potrebne varijable  
  
x = MP_UA_Re;  
t = UA_Re;  
  
var_t = mean(var(t',1)); % varijanca od target varijable, pristrana  
var_t_a = mean(var(t')); % varijanca od target varijable, nepristrana  
[I,obs]=size(x);  
[O,obs]=size(t);  
  
numNN = 10; % zadani broj treniranja  
numK = 10; % broj preklopa u kros-validaciji  
  
M = ceil(obs/numK); % length (valind & tstind)  
Ntrain = obs-2*M; % length (trnind)  
Ntraineq = Ntrain*O; % broj jednadzbi u sustavu  
  
% maksimalni broj neurona za koji nema overfitanja  
H = -1+ceil((Ntraineq-O)/(I+O+1));  
% maksimalni broj neurona za koji ce se trenirati mreza  
hiddenLayersize = ceil(1.5*H);  
  
rng('default')  
rngstate = cell(hiddenLayersize,numNN);  
ind0 = randperm(obs);  
  
Nw = zeros(hiddenLayersize,1); % broj tezina koje se 'uce'  
Ndof = zeros(hiddenLayerSize,1); % broj stupnjeva slobode  
  
k_no = 1:numK;  
obs_no = 1:obs;  
neurons = 1:hiddenLayerSize;
```

```

% formiranje varijabli u koje ce se upisivati dane vrijednosti
netsK = cell(numK,1);
nets = cell(hiddenLayerSize,numNN);
trK = cell(numK,1);
tr_all = cell(hiddenLayerSize,numNN);
yK = zeros(numK,obs);
yK_avg = zeros(1,obs);
Y_all = cell(hiddenLayerSize,numNN);
eK = zeros(numK,obs);
eK_avg = zeros(1,obs);
e_all = cell(hiddenLayerSize,numNN);

trainPerfK = zeros(numK,1);
valPerfK = zeros(numK,1);
testPerfK = zeros(numK,1);
perfK = zeros(numK,1);
perfK_a = zeros(numK,1);
trainPerformance = zeros(hiddenLayerSize,numNN);
valPerformance = zeros(hiddenLayerSize,numNN);
testPerformance = zeros(hiddenLayerSize,numNN);
performance = zeros(hiddenLayerSize,numNN);
performance_a = zeros(hiddenLayerSize,numNN);

rmse_trainK = zeros(numK,1);
rmse_valK = zeros(numK,1);
rmse_testK = zeros(numK,1);
rmseK = zeros(numK,1);
rmse_train = zeros(hiddenLayerSize,numNN);
rmse_val = zeros(hiddenLayerSize,numNN);
rmse_test = zeros(hiddenLayerSize,numNN);
rmse = zeros(hiddenLayerSize,numNN);

trainOutK = zeros(numK,obs);
valOutK = zeros(numK,obs);
testOutK = zeros(numK,obs);
trainOutputs = cell(hiddenLayerSize,numNN);
valOutputs = cell(hiddenLayerSize,numNN);
testOutputs = cell(hiddenLayerSize,numNN);

stopcritK = cell(numK,1);
numepochsk = zeros(numK,1);
bestepochK = zeros(numK,1);
stopcrit = cell(hiddenLayerSize,numNN);
numepochs = cell(hiddenLayerSize,numNN);
bestepoch = cell(hiddenLayerSize,numNN);

r_trainK = zeros(numK,1);
r_valK = zeros(numK,1);
r_testK = zeros(numK,1);
rK = zeros(numK,1);
r_train = zeros(hiddenLayerSize,numNN);
r_val = zeros(hiddenLayerSize,numNN);
r_test = zeros(hiddenLayerSize,numNN);
r = zeros(hiddenLayerSize,numNN);

R2trainK = zeros(numK,1);
R2train_aK = zeros(numK,1);
R2valK = zeros(numK,1);

```

```
R2testK = zeros(numK,1);
R2K = zeros(numK,1);
R2_aK = zeros(numK,1);
R2train = zeros(hiddenLayerSize,numNN);
R2train_a = zeros(hiddenLayerSize,numNN);
R2val = zeros(hiddenLayerSize,numNN);
R2test = zeros(hiddenLayerSize,numNN);
R2 = zeros(hiddenLayerSize,numNN);
R2_a = zeros(hiddenLayerSize,numNN);

resultK = zeros(numK,7);
result = cell(hiddenLayerSize,numNN);
minresult = cell(hiddenLayerSize,numNN);
meanresult = cell(hiddenLayerSize,numNN);
medresult= cell(hiddenLayerSize,numNN);
stdresult = cell(hiddenLayerSize,numNN);
maxresult= cell(hiddenLayerSize,numNN);

for j=1:hiddenLayerSize

    Nw(j,1) = (I+1)*hiddenLayerSize+(hiddenLayerSize+1)*0;
    Ndof(j,1) = Ntraineq-Nw(j,1);

    % postavljanje algoritma za učenje pogreske
    trainFcn = 'trainlm'; % Levenberg-Marquadtov algoritam za učenje
    net.trainParam.epochs = 1000; % maksimalni broj epoha (iteracija)

    % stvaranje mreže za aproksimaciju funkcije
    net = fitnet(j,trainFcn);

    % odabir funkcija za standardiziranje ulaza/izlaza
    net.input.processFcns = {'removeconstantrows','mapminmax','fixunknowns'};
    net.output.processFcns = {'removeconstantrows','mapminmax'};

    % odabir 'cilja' učenja - minimiziranje srednje kvadratne pogreske
    net.performFcn = 'mse'; % Mean Squared Error, srednja kvadratna pogreska

    mse_goal = 1e-03*var_t; % ciljana vrijednost mse
    minGrad = 1e-08*mse_goal; % ciljana vrijednost gradijenta

    % postavljanje zeljenih vrijednosti srednje kvadratne pogreske i
    % gradijenta kao uvjet za zaustavljanje treniranja mreže
    net.trainParam.goal = mse_goal;
    net.trainParam.min_grad = minGrad;

    % podjela uzorka u setove za treniranje, validaciju i testiranje -
    % podjela cijelog uzorka po indexu
    net.divideFcn = 'divideind';
    net.divideMode = 'sample';

    % odabir dostupnih dijagrama
    net.plotFcns = {'plotperform','plottrainstate','ploterrhist', ...
        'plotregression','plotfit'};

    for i=1:numNN

        for k=1:numK
```

```

rngstatek = rng;
rngstate{j,i} = rngstatek;

if k==numK
    valind = 1+M*(k-1):obs;
    testind = 1:M;
    trainind = [M+1:M*(k-1),M*(k+1):obs];
else
    if k==numK-1
        valind = 1+M*(k-1):M*k;
        testind = valind(1)+M:obs;
        trainind = 1:valind(1)-1;
    else
        valind = 1+M*(k-1):M*k;
        testind = valind+M;
        trainind = [1:valind(1)-1,testind(end)+1:obs];
    end
end

trainInd = ind0(trainind);
valInd = ind0(valind);
testInd = ind0(testind);
net.divideParam.trainInd = trainInd;
net.divideParam.valInd = valInd;
net.divideParam.testInd = testInd;

% konfiguriranje mreze - inicijalizacija tezina w i biasa b na
% nove nasumicno odabrane vrijednosti
net = configure(net,x,t);
disp(['No. of hidden nodes ' num2str(j) '/'
      num2str(hiddenLayerSize) ', Training ' num2str(i) '/'
      num2str(numNN) ', k-fold ' num2str(k) '/' num2str(numK)])

% treniranje mreze
[net, tr, y, e] = train(net,x,t);

% struktura u koju se upisuju svi podaci ovisno o broju
% iteracije trenutnog treniranja
trK{k,1} = tr;

% mreze za svaki preklop i numNN-to treniranje
netsK{k,1} = net;

yK(k,:) = y; % outputi od numK za trenutni numNN
yK_avg = mean(yK); % prosjek od yK
Y_all{j,i} = yK_avg; % prosjek rezultata od svih preklopa za
                    % za trenutni broj neurona i numNN

eK(k,:) = e; % pogreske od numK za trenutni numNN
eK_avg = mean(eK); % prosjek od e_k
e_all{j,i} = eK_avg; % prosjek rezultata od svih preklopa za
                    % za trenutni broj neurona i numNN

% ciljane vrijednosti (targeti) setova za treniranje,
% validaciju i testiranje
trainTargets = t .* tr.trainMask{1};
valTargets = t .* tr.valMask{1};

```

```
testTargets = t .* tr.testMask{1};

% mse za numK preklopa, trenutni broj neurona i numNN
trainPerfK(k,1) = perform(net,trainTargets,y);
valPerfK(k,1) = perform(net,valTargets,y);
testPerfK(k,1) = perform(net,testTargets,y);

perfK(k,1)= perform(net,t,y);
perfK_a(k,1)= Ntrained*perfK(k,1)/Ndof(j,1);

% rmse (root mean square error, korijen srednje kvadratne
% pogreske za numK preklopa, trenutni broj neurona i numNN
rmse_trainK(k,1) = sqrt(trainPerfK(k,1));
rmse_valK(k,1) = sqrt(valPerfK(k,1));
rmse_testK(k,1) = sqrt(testPerfK(k,1));
rmseK(k,1) = sqrt(perfK(k,1));

% vrijednosti koje producira mreza za setove za treniranje,
% validaciju i testiranje za numK preklopa, trenutni broj
% neurona i numNN
trainOutK(k,:) = y .* tr.trainMask{1};
valOutK(k,:) = y .* tr.valMask{1};
testOutK(k,:) = y .* tr.testMask{1};

% pregled performansi mreze u numK preklopa
stopcritk{k,1} = tr.stop; % kriterij zaustavljanja ucenja
numepochsk(k,1) = tr.num_epochs; % broj proteklih epoha
bestepochK(k,1) = tr.best_epoch; % epoha s najnim mse

% koeficijenti korelacije za za setove za treniranje,
% validaciju i testiranje za numK preklopa, trenutni broj
% neurona i numNN
[r_trainK(k,1)] = regression(trainTargets,trainOutK(k,:));
[r_valK(k,1)] = regression(valTargets,valOutK(k,:));
[r_testK(k,1)] = regression(testTargets,testOutK(k,:));
[rK(k,1)] = regression(t,y);

% koeficijenti determinacije za za setove za treniranje,
% validaciju, testiranje i cijeli uzorak za numK preklopa,
% trenutni broj neurona i numNN
R2trainK(k,1) = 1 - tr.best_perf/var_t;
R2train_aK(k,1) = 1 - (Ntrained/Ndof(j,1))*tr.best_perf/var_t_a;
R2valK(k,1) = 1 - tr.best_vperf/var_t;
R2testK(k,1) = 1 - tr.best_tperf/var_t;
R2K(k,1) = 1-mse(e)/var_t;
R2_aK(k,1) = 1-mse(e)/var_t_a;

% sumiranje rezultata
resultK = [bestepochK R2trainK R2train_aK R2valK R2testK R2K R2_aK];
minresultK = min(resultK);
meanresultK = mean(resultK);
medresultK = median(resultK);
stdresultK = std(resultK);
maxresultK = max(resultK);

end

% struktura gdje se upisuju podaci toka treniranja za svih num NN
```

```

% treniranja i velicine skrivenog sloja hiddenLayerSize
tr_all{j,i} = trK;

% mreze za hiddenLayerSize i numNN treniranja
nets{j,i} = netsK;

% uprosjeceni rezultati mse od svih numK za dani broj neurona i
% treniranja
trainPerformance(j,i) = mean(trainPerfK); % mse seta za treniranje
valPerformance(j,i) = mean(valPerfK); % mse seta za validaciju
testPerformance(j,i) = mean(testPerfK); % mse seta za testiranje
performance(j,i) = mean(perfK); % mse uzorka
performance_a(j,i) = mean(perfK_a); % prilagodjeni mse uzorka

% uprosjeceni rezultati rmse od svih numK preklopa za dani broj
% neurona i treniranja
rmse_train(j,i) = mean(rmse_trainK);
rmse_val(j,i) = mean(rmse_valK);
rmse_test(j,i) = mean(rmse_testK);
rmse(j,i) = mean(rmseK);

% vrijednosti koje producira mreza za setove za treniranje,
% validaciju i testiranje kao prosjecna vrijednost od svih numK
% preklopa za dani broj neurona i treniranja
trainOutputs{j,i} = mean(trainOutK);
valOutputs{j,i} = mean(valOutK);
testOutputs{j,i} = mean(testOutK);

% pregled performansi mreze u svim preklopima za dani broj neurona
% i treniranja
stopcrit{j,i} = stopcritK;
numepochs{j,i} = numepochsK;
bestepoch{j,i} = bestepochK;

% koeficijenti korelacije za za setove za treniranje, validaciju i
% testiranje kao prosjecna vrijednost od svih numK preklopa za dani
% broj neurona i treniranja
r(j,i) = mean(r_trainK);
r_train(j,i) = mean(r_trainK);
r_val(j,i) = mean(r_valK);
r_test(j,i) = mean(r_testK);

% koeficijenti determinacije za za setove za treniranje,
% validaciju, testiranje i cijeli uzorak kao prosjecna vrijednost
% od svih numK preklopa za dani broj neurona i treniranja
R2train(j,i) = mean(R2trainK);
R2train_a(j,i) = mean(R2train_aK);
R2val(j,i) = mean(R2valK);
R2test(j,i) = mean(R2testK);
R2(j,i) = mean(R2K);
R2_a(j,i) = mean(R2_aK);

% sumiranje rezultata
result{j,i} = resultK;
minresult{j,i} = minresultK; % minimalne vrijednosti rezultata
meanresult{j,i} = meanresultK; % srednje vrijednosti rezultata
medresult{j,i} = medresultK; % medijani rezultata
stdresult{j,i} = stdresultK; % standardna devijacija rezultata

```



```
maxresult{j,i}= maxresultK; % maksimalne vrijednosti rezultata

end

end

% minimalni mse seta za treniranje za dani broj neurona
[minperf_train,I_train] = min(trainPerformance',[],1);
minperf_train = minperf_train';
I_train = I_train';

% minimalni mse seta za validaciju za dani broj neurona
[minperf_val,I_val] = min(valPerformance',[],1);
minperf_val = minperf_val';
I_val = I_val';

% minimalni mse seta za testiranje za dani broj neurona
[minperf_test,I_test] = min(testPerformance',[],1);
minperf_test = minperf_test';
I_test = I_test';

% minimalni mse uzorka za dani broj neurona
[minperf,I_perf] = min(performance',[],1);
minperf = minperf';
I_perf = I_perf';

% maksimalni R^2 uzorka za dani broj neurona
[maxR2,I_R2] = max(R2',[],1);
maxR2 = maxR2';
I_R2 = I_R2';

% maksimalni prilagodjeni R^2 uzorka za dani broj neurona
[maxR2_a,I_R2_a] = max(R2_a',[],1);
maxR2_a = maxR2_a';
I_R2_a = I_R2_a';

% minimalni mse seta za treniranje i vraća index u minperf_train
[train_min,train_min_I] = min(minperf_train,[],1);
% minimalni mse seta za validaciju i vraća index u minperf_val
[val_min,val_min_I] = min(minperf_val,[],1);
% minimalni mse seta za testiranje i vraća index u minperf_test
[test_min,test_min_I] = min(minperf_test,[],1);
% minimalni mse uzorka i vraća index u minperf
[perf_min,perf_min_I] = min(minperf,[],1);

% maksimalni Rsq i index u maxR2
[R2_max,R2_max_I] = max(maxR2,[],1);

% summary = [hiddenLayerSize bestepoch finalgrad Rsq Rsq_a];

toc % kraj mjerenja vremena

% dijagram koji prikazuje minimalni postignuti mse (treniranja,
% validacije, testiranja i ukupni mse) u odnosu na broj neurona
figure(1)
hold on
xlabel('neurons')
ylabel('min. performance')
```

```
plot(neurons,minperf_train,'b',neurons,minperf_val,'g',neurons,
      minperf_test,'r',neurons,minperf,'k')
hold off

% dijagram koji prikazuje maksimalni postignuti R^2 (treniranja,
% validacije, testiranja i ukupni mse) u odnosu na broj neurona
figure(2)
hold on
xlabel('neurons')
ylabel('max Rsq')
scatter(neurons,maxR2,'ok')
scatter(neurons,maxR2_a,'+k')
hold off

save figure(1).fig
save figure(2).fig

% sacuvati sve varijable iz workspacea u poseban file za daljnju analizu
save wsUA_Re_LMxval
```

D.3 Kod za učenje umjetne neuronske mreže za procjenu eksponenta cikličkog deformacijskog očvršćivanja n' niskolegiranih čelika pomoću 10-struke unakrsne validacije i Bayesove regularizacije

```
% Primjena umjetnih neuronskih mreza za aproksimaciju funkcije -  
% predviđanja eksponenta cikličkog deformacijskog očvršćivanja  $n'$   
% niskolegiranih celika pomocu Bayesove regularizacije i 10-struke  
% unakrsne validacije (engl. 10-fold cross-validation)  
  
% Skripta podrazumijeva da su definirane sljedece varijable:  
%  
% MP_LA_n - ulazni podaci.  
% LA_n - ciljani podaci.  
  
close all, clear all  
  
tic % pocetak mjerenja vremena  
  
load varLA_n % ucitava potrebne varijable  
  
x = MP_LA_n;  
t = LA_n;  
  
var_t = mean(var(t',1)); % varijanca od target varijable, pristrana  
var_t_a = mean(var(t')); % varijanca od target varijable, nepristrana  
[I,obs]=size(x);  
[O,obs]=size(t);  
  
numNN = 10; % zadani broj treniranja  
numK = 10; % broj preklopa u kros-validaciji  
  
M = ceil(obs/numK); % length (valind & tstind)  
Ntrain = obs-2*M; % length (trnind)  
Ntraineq = Ntrain*O; % broj jednadzbi u sustavu  
  
% maksimalni broj neurona za koji nema overfitanja  
H = -1+ceil((Ntraineq-O)/(I+O+1));  
% maksimalni broj neurona za koji ce se trenirati mreza  
hiddenLayersize = ceil(1.5*H);  
  
rng('default')  
rngstate = cell(hiddenLayersize,numNN);  
ind0 = randperm(obs);  
  
Nw = zeros(hiddenLayersize,1); % broj tezina koje se 'uce'  
Ndof = zeros(hiddenLayerSize,1); % broj stupnjeva slobode  
  
k_no = 1:numK;  
obs_no = 1:obs;  
neurons = 1:hiddenLayerSize;  
  
% formiranje varijabli u koje ce se upisivati dane vrijednosti  
netsK = cell(numK,1);  
nets = cell(hiddenLayerSize,numNN);  
trK = cell(numK,1);
```

```

tr_all = cell(hiddenLayerSize,numNN);
yK = zeros(numK,obs);
yK_avg = zeros(1,obs);
Y_all = cell(hiddenLayerSize,numNN);
eK = zeros(numK,obs);
eK_avg = zeros(1,obs);
e_all = cell(hiddenLayerSize,numNN);

trainPerfK = zeros(numK,1);
testPerfK = zeros(numK,1);
perfK = zeros(numK,1);
perfK_a = zeros(numK,1);
trainPerformance = zeros(hiddenLayerSize,numNN);
testPerformance = zeros(hiddenLayerSize,numNN);
performance = zeros(hiddenLayerSize,numNN);
performance_a = zeros(hiddenLayerSize,numNN);

rmse_trainK = zeros(numK,1);
rmse_testK = zeros(numK,1);
rmseK = zeros(numK,1);
rmse_train = zeros(hiddenLayerSize,numNN);
rmse_test = zeros(hiddenLayerSize,numNN);
rmse = zeros(hiddenLayerSize,numNN);

trainOutK = zeros(numK,obs);
testOutK = zeros(numK,obs);
trainOutputs = cell(hiddenLayerSize,numNN);
testOutputs = cell(hiddenLayerSize,numNN);

stopcritK = cell(numK,1);
numepochSK = zeros(numK,1);
bestepochK = zeros(numK,1);
stopcrit = cell(hiddenLayerSize,numNN);
numepochs = cell(hiddenLayerSize,numNN);
bestepoch = cell(hiddenLayerSize,numNN);

r_trainK = zeros(numK,1);
r_testK = zeros(numK,1);
rK = zeros(numK,1);
r_train = zeros(hiddenLayerSize,numNN);
r_test = zeros(hiddenLayerSize,numNN);
r = zeros(hiddenLayerSize,numNN);

R2trainK = zeros(numK,1);
R2train_aK = zeros(numK,1);
R2testK = zeros(numK,1);
R2K = zeros(numK,1);
R2_aK = zeros(numK,1);
R2train = zeros(hiddenLayerSize,numNN);
R2train_a = zeros(hiddenLayerSize,numNN);
R2test = zeros(hiddenLayerSize,numNN);
R2 = zeros(hiddenLayerSize,numNN);
R2_a = zeros(hiddenLayerSize,numNN);

resultK = zeros(numK,6);
result = cell(hiddenLayerSize,numNN);
minresult = cell(hiddenLayerSize,numNN);
meanresult = cell(hiddenLayerSize,numNN);

```

```
medresult= cell(hiddenLayerSize,numNN);
stdresult = cell(hiddenLayerSize,numNN);
maxresult= cell(hiddenLayerSize,numNN);

for j=1:hiddenLayerSize

    Nw(j,1) = (I+1)*hiddenLayerSize+(hiddenLayerSize+1)*0;
    Ndof(j,1) = Ntraineq-Nw(j,1);

    % postavljanje algoritma za učenje pogreske
    trainFcn = 'trainbr'; % Bayesova regularizacija

    % stvaranje mreže za aproksimaciju funkcije
    net = fitnet(j,trainFcn);

    % odabir funkcija za standardiziranje ulaza/izlaza
    net.input.processFcns = {'removeconstantrows','mapminmax','fixunknowns'};
    net.output.processFcns = {'removeconstantrows','mapminmax'};

    % odabir ''cilja'' učenja - minimiziranje srednje kvadratne pogreske
    net.performFcn = 'mse'; % Mean Squared Error, srednja kvadratna pogreska

    mse_goal = 1e-02*var_t; % ciljana vrijednost mse
    minGrad = 1e-02*mse_goal; % ciljana vrijednost gradijenta

    % postavljanje zeljenih vrijednosti srednje kvadratne pogreske i
    % gradijenta kao uvjet za zaustavljanje treniranja mreže
    net.trainParam.goal = mse_goal;
    net.trainParam.min_grad = minGrad;

    % podjela uzorka u setove za treniranje, validaciju i testiranje -
    % podjela cijelog uzorka po indexu
    net.divideFcn = 'divideind';
    net.divideMode = 'sample';

    % odabir dostupnih dijagrama
    net.plotFcns = {'plotperform','plottrainstate','ploterrhist', ...
        'plotregression','plotfit'};

    for i=1:numNN

        for k=1:numK

            rngstateK = rng;
            rngstate{j,i} = rngstateK;

            if k==numK
                testind = 1+M*(k-1):obs;
                trainind = 1:testind(1)-1;
            else
                testind = 1+M*(k-1):M*k;
                trainind = [1:testind(1)-1,testind(end)+1:obs];
            end

            trainInd = ind0(trainind);
            testInd = ind0(testind);
            net.divideParam.trainInd = trainInd;
```

```

net.divideParam.testInd = testInd;

% konfiguriranje mreze - inicijalizacija tezina w i biasa b na
% nove nasumicno odabrane vrijednosti
net = configure(net,x,t);
disp(['No. of hidden nodes ' num2str(j) '/'
      num2str(hiddenLayerSize) ', Training ' num2str(i) '/'
      num2str(numNN) ', k-fold ' num2str(k) '/' num2str(numK)])

% treniranje mreze
[net, tr, y, e] = train(net,x,t);

% struktura u koju se upisuju svi podaci ovisno o broju
% iteracije trenutnog treniranja
trK{k,1} = tr;

% mreze za svaki preklop i numNN-to treniranje
netsK{k,1} = net;

yK(k,:) = y; % outputi od numK za trenutni numNN
yK_avg = mean(yK); % prosjek od yK
Y_all{j,i} = yK_avg; % prosjek rezultata od svih preklopa za
                    % za trenutni broj neurona i numNN

eK(k,:) = e; % pogreske od numK za trenutni numNN
eK_avg = mean(eK); % prosjek od e_k
e_all{j,i} = eK_avg; % prosjek rezultata od svih preklopa za
                    % za trenutni broj neurona i numNN

% ciljane vrijednosti (targeti) setova za treniranje, i
% testiranje
trainTargets = t .* tr.trainMask{1};
testTargets = t .* tr.testMask{1};

% mse za numK preklopa, trenutni broj neurona i numNN
trainPerfK(k,1) = perform(net,trainTargets,y);
testPerfK(k,1) = perform(net,testTargets,y);

perfK(k,1)= perform(net,t,y);
perfK_a(k,1)= Ntrained*perfK(k,1)/Ndof(j,1);

% rmse (root mean square error, korijen srednje kvadratne
% pogreske za numK preklopa, trenutni broj neurona i numNN
rmse_trainK(k,1) = sqrt(trainPerfK(k,1));
rmse_testK(k,1) = sqrt(testPerfK(k,1));
rmseK(k,1) = sqrt(perfK(k,1));

% vrijednosti koje producira mreza za setove za treniranje, i
% testiranje za numK preklopa, trenutni broj neurona i numNN
trainOutK(k,:) = y .* tr.trainMask{1};
testOutK(k,:) = y .* tr.testMask{1};

% pregled performansi mreze u numK preklopa
stopcritk{k,1} = tr.stop; % kriterij zaustavljanja učenja
numepochsk(k,1) = tr.num_epochs; % broj proteklih epoha
bestepochK(k,1) = tr.best_epoch; % epoha s najnižim mse

% koeficijenti korelacije za za setove za treniranje i

```

```
% testiranje za numK preklopa, trenutni broj neurona i numNN
[r_traink(k,1)] = regression(trainTargets,trainOutk(k,:));
[r_testk(k,1)] = regression(testTargets,testOutk(k,:));
[rk(k,1)] = regression(t,y);

% koeficijenti determinacije za za setove za treniranje,
% testiranje i cijeli uzorak za numK preklopa trenutni broj
% neurona i numNN
R2traink(k,1) = 1 - tr.best_perf/var_t;
R2train_ak(k,1) = 1 - (Ntraineq/Ndof(j,1))*tr.best_perf/var_t_a;
R2testk(k,1) = 1 - tr.best_tperf/var_t;
R2K(k,1) = 1-mse(e)/var_t;
R2_ak(k,1) = 1-mse(e)/var_t_a;

% sumiranje rezultata
resultk = [bestepochk R2traink R2train_ak R2testk R2K R2_ak];
minresultk = min(resultk);
meanresultk = mean(resultk);
medresultk = median(resultk);
stdresultk = std(resultk);
maxresultk = max(resultk);

end

% struktura gdje se upisuju podaci toka treniranja za svih num NN
% treniranja i velicine skrivenog sloja hiddenLayerSize
tr_all{j,i} = trk;

% mreze za hiddenLayerSize i numNN treniranja
nets{j,i} = netsk;

% uprosjeceni rezultati mse od svih numK za dani broj neurona i
% treniranja
trainPerformance(j,i) = mean(trainPerfk); % mse seta za treniranje
testPerformance(j,i) = mean(testPerfk); % mse seta za testiranje
performance(j,i)= mean(perfk); % mse uzorka
performance_a(j,i)= mean(perfk_a); % prilagodjeni mse uzorka

% uprosjeceni rezultati rmse od svih numK preklopa za dani broj
% neurona i treniranja
rmse_train(j,i) = mean(rmse_traink);
rmse_test(j,i) = mean(rmse_testk);
rmse(j,i) = mean(rmseK);

% vrijednosti koje producira mreza za setove za treniranje i
% testiranje kao prosjecna vrijednost od svih numK preklopa za dani
% broj neurona i treniranja
trainOutputs{j,i} = mean(trainOutk);
testOutputs{j,i} = mean(testOutk);

% pregled performansi mreze u svim preklopima za dani broj neurona
% i treniranja
stopcrit{j,i} = stopcritk;
numepochs{j,i} = numepochsk;
bestepoch{j,i} = bestepochk;

% koeficijenti korelacije za za setove za treniranje i testiranje
% kao prosjecna vrijednost od svih numK preklopa za dani broj
```

```

% neurona i treniranja
r(j,i) = mean(r_trainK);
r_train(j,i) = mean(r_trainK);
r_test(j,i) = mean(r_testK);

% koeficijenti determinacije za za setove za treniranje, testiranje
% i cijeli uzorak kao prosjecna vrijednost od svih numK preklopa za
% dani broj neurona i treniranja
R2train(j,i) = mean(R2trainK);
R2train_a(j,i) = mean(R2train_aK);
R2test(j,i) = mean(R2testK);
R2(j,i) = mean(R2K);
R2_a(j,i) = mean(R2_aK);

% sumiranje rezultata
result{j,i} = resultK;
minresult{j,i} = minresultK; % minimalne vrijednosti rezultata
meanresult{j,i} = meanresultK; % srednje vrijednosti rezultata
medresult{j,i} = medresultK; % medijani rezultata
stdresult{j,i} = stdresultK; % standardna devijacija rezultata
maxresult{j,i} = maxresultK; % maksimalne vrijednosti rezultata

end

end

% minimalni mse seta za treniranje za dani broj neurona
[minperf_train,I_train] = min(trainPerformance',[],1);
minperf_train = minperf_train';
I_train = I_train';

% minimalni mse seta za testiranje za dani broj neurona
[minperf_test,I_test] = min(testPerformance',[],1);
minperf_test = minperf_test';
I_test = I_test';

% minimalni mse uzorka za dani broj neurona
[minperf,I_perf] = min(performance',[],1);
minperf = minperf';
I_perf = I_perf';

% maksimalni R^2 uzorka za dani broj neurona
[maxR2,I_R2] = max(R2',[],1);
maxR2 = maxR2';
I_R2 = I_R2';

% maksimalni prilagodjeni R^2 uzorka za dani broj neurona
[maxR2_a,I_R2_a] = max(R2_a',[],1);
maxR2_a = maxR2_a';
I_R2_a = I_R2_a';

% minimalni mse seta za treniranje i vraća index u minperf_train
[train_min,train_min_I] = min(minperf_train,[],1);
% minimalni mse seta za testiranje i vraća index u minperf_test
[test_min,test_min_I] = min(minperf_test,[],1);
% minimalni mse uzorka i vraća index u minperf
[perf_min,perf_min_I] = min(minperf,[],1);

```



```
% maksimalni Rsq i index u maxR2
[R2_max,R2_max_I] = max(maxR2,[],1);

% summary = [hiddenLayerSize bestepoch finalgrad Rsq Rsq_a];

toc % kraj mjerenja vremena

% dijagram koji prikazuje minimalni postignuti mse (treniranja, testiranja
% i ukupni mse) u odnosu na broj neurona
figure(1)
hold on
xlabel('neurons')
ylabel('min. performance')
plot(neurons,minperf_train,'b',neurons,minperf_test,'r',neurons,minperf,'k')
hold off

% dijagram koji prikazuje maksimalni postignuti R^2 (treniranja, testiranja
% i ukupni mse) u odnosu na broj neurona
figure(2)
hold on
xlabel('neurons')
ylabel('max Rsq')
scatter(neurons,maxR2,'ok')
scatter(neurons,maxR2_a,'+k')
hold off

save figure(1).fig
save figure(2).fig

% sacuvati sve varijable iz workspacea u poseban file za daljnju analizu
save wSLA_n_BRxva]
```

Životopis

Tea Marohnić rođena je 20. rujna 1984. u Rijeci, gdje je 2003. završila Gimnaziju Andrije Mohorovičića. Iste godine upisuje sveučilišni dodiplomski studij strojarstva na Tehničkom fakultetu Sveučilišta u Rijeci. Tijekom svih 9 semestara studija stipendistica je Ministarstva znanosti, obrazovanja i športa A kategorije (državne stipendije osobito nadarenim redovitim studentima sveučilišnih i stručnih studija). Diplomirala je 10. rujna 2009. na konstrukcijskom usmjerenju među 10 % najboljih diplomiranih studenata sveučilišnih studija Tehničkog fakulteta te godine i stekla stručno zvanje diplomiranog inženjera strojarstva.

Od listopada 2009. do danas radi u suradničkom zvanju i na radnom mjestu asistenta iz znanstvenog područja Tehničkih znanosti, polja Strojstvo, grane Opće strojarstvo (konstrukcije) i to na Zavodu za konstruiranje u strojarstvu Tehničkog fakulteta u Rijeci (listopad 2009. – studeni 2010. i studeni 2015. – danas), i na Odjelu za politehniku Filozofskog fakulteta u Rijeci (srpanj 2011. – listopad 2015.). Sudjeluje u izvođenju nastave iz niza kolegija iz područja inženjerske grafike, konstrukcijskih elemenata, mehanike, čvrstoće materijala i dr. Od 2012.–2015. bila je ECTS koordinator Odsjeka za politehniku Filozofskog fakulteta Sveučilišta u Rijeci.

Akad. god. 2011/2012. upisuje poslijediplomski doktorski studij znanstvenog područja Tehničkih znanosti, polja Strojstvo, modul 5 – Konstruiranje u strojarstvu na Tehničkom fakultetu Sveučilišta u Rijeci, pod mentorstvom izv. prof. dr. sc. Roberta Basana. Tijekom studija sudjelovala je na više tečajeva, radionica i ljetnih škola usko vezanih za područje istraživanja. Akad. god. 2012/2013. provodi tri mjeseca na studijskom boravku na Fakulteti za strojništvo u Ljubljani, Slovenija (bilateralna stipendija Ministarstva znanosti, obrazovanja i športa RH i Ministrstva za visoko školstvo, znanost in tehnologijo Republike Slovenije).

U svojstvu suradnika bila je uključena u rad na bilateralnom hrvatsko-njemačkom znanstveno-istraživačkom projektu "Karakterizacija i modeliranje ponašanja materijala za lake i inovativne konstrukcije". Trenutno sudjeluje u radu istraživačkog projekta Hrvatske zaklade za znanost "Razvoj evolucijskih postupaka za karakterizaciju ponašanja bioloških tkiva (BIOMAT)" [IP-

2014-09-4982] i potporama Sveučilišta u Rijeci "Karakterizacija i modeliranje ponašanja materijala i konstrukcija za inovativne primjene" [13.09.1.2.09] i "Razvoj evolucijskih metoda za identifikaciju parametara materijala" [13.09.2.2.18].

Suautorica je četiri znanstvena rada objavljena u međunarodnim časopisima, od kojih su dva indeksirana u bazi podataka Current Contents te nekoliko znanstvenih radova i sažetaka u zbornicima radova međunarodnih konferencija.

Aktivno se služi engleskim, a pasivno talijanskim i slovenskim jezikom.

Popis objavljenih radova

Znanstveni radovi u časopisima:

1. Marohnić, T. ; Basan, R. ; Franulović, M.: Evaluation of Methods for Estimation of Cyclic Stress–Strain Parameters from Monotonic Properties of Steels. *Metals* **7** (2017) 1–15. doi: 10.3390/met7010017
2. Marohnić, T. ; Basan, R.: Study of Monotonic Properties' Relevance for Estimation of Cyclic Yield Stress and Ramberg–Osgood Parameters of Steels. *J. Mater. Eng. Perform.* **25** (2016) 11: 4812–4823. doi:10.1007/s11665-016-2311-1
3. Marohnić, T. ; Basan, R. ; Franulović, M.: Evaluation of the Possibility of Estimating Cyclic Stress–strain Parameters and Curves from Monotonic Properties of Steels. *Procedia Eng.* **101** (2015) 277–284. doi:10.1016/j.proeng.2015.02.029
4. Basan, R. ; Rubeša, D. ; Franulović, M. ; Marohnić, T.: Some considerations on the evaluation of methods for the estimation of fatigue parameters from monotonic properties. *Procedia Eng.* **101** (2015) 18–25. doi: 10.1016/j.proeng.2015.02.004

Znanstveni radovi u zbornicima skupova s međunarodnom recenzijom:

1. Marohnić, T. ; Basan, R. ; Franulović, M.: Influence of methodology and selection of monotonic properties on estimation of cyclic stress–strain parameters of steels. Proceedings of the 36th International Conference on Mechanics of Materials. Vormwald, M. (ur.). Darmstadt, Germany : Technische Universität Darmstadt – Institut für Stahlbau und Werkstoffmechanik, 2015. 33–41.
2. Basan, R. ; Marohnić, T. ; Franulović, M.: Estimation of fatigue parameters of 42CrMo4 steels. Proceedings of the 36th International Conference on Mechanics of Materials. Vormwald, M. (ur.). Darmstadt, Germany : Technische Universität Darmstadt – Institut für Stahlbau und Werkstoffmechanik, 2015. 20–32.
3. Basan, R. ; Marohnić, T. ; Prebil, I. ; Franulović, M.: Preliminary investigation of the existence of correlation between cyclic Ramberg–Osgood parameters and monotonic properties of low-alloy steels. Proceedings of the 3rd International conference MTSM

2013. Živković, D. (ur.). Split, Croatia : Croatian society for mechanical technologies, 2013.
4. Basan, R. ; Marohnić, T. ; Rubeša, D. ; Franulović, M.: Web-Based material properties and knowledge database – Support for design of efficient and lightweight products. 3rd Fatigue Symposium Leoben Conference Transcript. Eichsleder, W., Grün, F. (ur.). Leoben, Austria : Montanuniversität Leoben, Chair of Mechanical Engineering, 2012. 35–44.
5. Gregov, G. ; Marohnić, T. ; Žic, S.: Computer simulation of a laboratory hydraulic system. Proceeding of International Conference on Innovative Technologies, In-Tech 2010. Kudlaček, J., Barišić, B., Velay, X., Ohkura, K. (ur.). Prague, Czech Republic : Kudlaček, J., 2010. 448–452.

Sažeci u zbornicima skupova:

1. Basan, R. ; Marohnić, Tea.: Analysis of cyclic stress–strain and strain–life fatigue parameters and behaviour of high-alloy steels. 16th International Conference on New Trends in Fatigue and Fracture (Book of Abstracts). Božić, Ž. (ur.). Zagreb, Croatia : University of Zagreb, Faculty of Mechanical Engineering and Naval Architecture, 2016. 191–192.
2. Franulović, M. ; Basan, R. ; Marković, K. ; Marohnić, T.: Biomaterials characterization – parameters identification. 16th International Conference on New Trends in Fatigue and Fracture (Book of Abstracts). Božić, Ž. (ur.). Zagreb, Croatia : University of Zagreb, Faculty of Mechanical Engineering and Naval Architecture, 2016. 107–108.

PODACI O AUTORU I DOKTORSKOJ DISERTACIJI

1. AUTOR

Ime i prezime:	Tea Marohnić
Datum i mjesto rođenja:	20.09.1984., Rijeka
Naziv fakulteta, studija i godina završetka dodiplomskog studija:	Tehnički fakultet Sveučilišta u Rijeci Sveučilišni dodiplomski studij strojarstva, 2009.
Naziv fakulteta, smjera i godina završetka poslijediplomskog studija:	Tehnički fakultet Sveučilišta u Rijeci Konstruiranje u strojarstvu, 2017.
Sadašnje zaposlenje:	Tehnički fakultet Sveučilišta u Rijeci

2. DOKTORSKA DISERTACIJA

Naslov:	Procjena cikličkih i zamornih parametara čelika na osnovi njihovih monotonih značajki primjenom umjetnih neuronskih mreža
Broj stranica, slika, tablica i bibliografskih podataka:	222, 41, 63, 91
Znanstveno polje i grana:	Strojarstvo, Opće strojarstvo (konstrukcije)
Voditelj rada:	Izv. prof. dr. sc. Robert Basan, dipl. ing.
Fakultet na kojemu je rad obranjen:	Tehnički fakultet Sveučilišta u Rijeci

3. OBRANA I OCJENA

Datum prijave teme:	18.09.2012.
Datum predaje rada:	13.02.2017.
Datum prihvatanja ocjene rada:	31.03.2017.
Sastav Povjerenstva za ocjenu:	Prof. dr. sc. Domagoj Rubeša, dipl. ing. Izv. prof. dr. sc. Robert Basan, dipl. ing. Prof. dr. sc. Nelida Črnjarić-Žic, dipl. ing.
Datum obrane:	18. 04. 2017.
Sastav Povjerenstva za obranu:	Prof. dr. sc. Domagoj Rubeša, dipl. ing. Izv. prof. dr. sc. Robert Basan, dipl. ing. Prof. dr. sc. Nelida Črnjarić-Žic, dipl. ing.
Datum promocije:	

**PROCJENA CIKLIČKIH I ZAMORNIH PARAMETARA ČELIKA NA OSNOVI NJIHOVIH
MONOTONIH ZNAČAJKI PRIMJENOM UMJETNIH NEURONSKIH MREŽA**

Tea Marohnić

Sveučilište u Rijeci
Tehnički fakultet
Hrvatska

Ključne riječi: Zamor materijala
Čelici
Ciklički parametri
Zamorni parametri
Predviđanje vijeka trajanja
Statistička analiza
Umjetne neuronske mreže

Sažetak:

U doktorskoj disertaciji obrađen je problem procjene cikličkih Ramberg–Osgoodovih i zamornih Basquin–Coffin–Mansonovih parametara čelika na osnovi monotonih značajki primjenom umjetnih neuronskih mreža. Za potrebe istraživanja iz relevantne je literature i putem on-line baze podataka o materijalima MATDAT prikupljen velik broj eksperimentalnih podataka za čelike. Pregledom postojećih istraživanja utvrđeno je da se podjelom čelika u skupine prema kriteriju udjela legirajućih elemenata može poboljšati točnost procjene cikličkih i zamornih parametara na osnovi monotonih značajki. U skladu s tim, čelici su grupirani u nelegirane, niskolegirane i visokolegirane čelike. Različitost vrijednosti cikličkih i zamornih parametara spomenutih grupa čelika i formalno je potvrđena provođenjem jednofaktorske analize varijance i Welchovog testa. Dodatno provedenim post-hoc analizama utvrđena je različitost na razini parova nelegiranih, niskolegiranih i visokolegiranih čelika. Provođenjem unaprijedne selekcije određene su monotone značajke relevantne za procjenu svakog od cikličkih i zamornih parametara različitih skupina čelika. Na osnovi rezultata statističkih analiza, predložena je procjena cikličkih i zamornih parametara primjenom neuronskih mreža, zasebno za svaku skupinu čelika i uz korištenje samo onih monotonih značajki koje su se pokazale statistički relevantnim za procjenu pojedinog parametra. Za učinkovitije korištenje prikupljenih podataka u razvoju neuronskih mreža primijenjena je metoda k-struke unakrsne validacije. Rezultati dobiveni razvijenim umjetnim neuronskim mrežama vrednovani su usporedbom s eksperimentalnim vrijednostima cikličkih i zamornih parametara, ali i onima dobivenim postojećim empirijskim metodama procjene. Za odabrani skup podataka umjetne neuronske mreže pokazale su se uspješnijim od empirijskih metoda procjene većine cikličkih i zamornih parametara i ponašanja različitih skupina čelika. Razvijeni pristup procjeni cikličkih i zamornih parametara na osnovi lako dostupnih monotonih značajki primjenom neuronskih mreža može poslužiti jednostavnijem, točnijem i bržem određivanju opteretivosti i trajnosti čeličnih dijelova i konstrukcija u raznim industrijskim djelatnostima (automobilskoj, zrakoplovnoj i dr.). Razvojem pouzdanog sustava za procjenu cikličkih i zamornih parametara smanjuje se potreba za eksperimentalnom karakterizacijom cikličkog i zamornog ponašanja materijala u ranim fazama razvoja proizvoda u kojima se vrednuju različiti materijali i konstrukcijska rješenja, što za posljedicu ima i smanjenje troškova i vremena potrebnih za razvoj proizvoda.

Rad nije objavljen.

Mentor: Izv. prof. dr. sc. Robert Basan, dipl. ing.
Povjerenstvo za ocjenu: Prof. dr. sc. Domagoj Rubeša, dipl. ing.
Izv. prof. dr. sc. Robert Basan, dipl. ing.
Prof. dr. sc. Nelida Črnjarić-Žic, dipl. ing.
Povjerenstvo za obranu: Prof. dr. sc. Domagoj Rubeša, dipl. ing.
Izv. prof. dr. sc. Robert Basan, dipl. ing.
Prof. dr. sc. Nelida Črnjarić-Žic, dipl. ing.

Datum obrane: 18.04.2017.

Datum promocije:

Rad je pohranjen na Tehničkom fakultetu Sveučilišta u Rijeci.

(222, 41, 63, 91, hrvatski jezik)

DD UDK 539.388.1:669.14:519.23:004.032.26(043)

1. Procjena cikličkih i zamornih parametara ćelika
na osnovi njihovih monotonih značajki
primjenom umjetnih neuronskih mreža

I

Tea Marohnić

II

Sveučilište u Rijeci
Tehnički fakultet
Hrvatska

Ključne riječi:

Zamor materijala
Ćelici
Ciklički parametri
Zamorni parametri
Predviđanje vijeka trajanja
Statistička analiza
Umjetne neuronske mreže

ESTIMATION OF CYCLIC AND FATIGUE PARAMETERS OF STEELS BASED ON THEIR MONOTONIC PROPERTIES USING ARTIFICIAL NEURAL NETWORKS

Tea Marohnić

University of Rijeka
Faculty of Engineering
Croatia

Keywords: Fatigue of materials
Steels
Cyclic stress–strain parameters
Fatigue strain–life parameters
Lifetime prediction
Statistical analysis
Artificial neural networks

Summary:

Research presented in this doctoral thesis deals with estimation of cyclic Ramberg–Osgood and fatigue Basquin–Coffin–Manson parameters i.e. stress–strain and strain–life behaviour of steels on the basis of their monotonic properties using artificial neural networks. For the purpose of this study, a large number of experimental data for steels were collected from relevant literature and online Materials Properties Database MATDAT. The overview of existing methods showed that separate consideration of steels divided according to the content of alloying elements can improve the accuracy of estimations of cyclic and fatigue parameters on the basis of their monotonic properties. Thus, steels were divided into unalloyed, low-alloy and high-alloy steels. Differences among cyclic and fatigue parameters of steels divided in such a way were formally confirmed by performing one-way analysis of variance and Welch’s test. Additionally, pairwise differences between groups were found to exist by performing post-hoc analyses. Further detailed statistical analysis was performed by means of forward selection, and monotonic properties relevant for estimation of each cyclic and fatigue parameter of each group of steels were determined. Based on results of performed statistical analyses, estimation of cyclic and fatigue parameters using artificial neural networks was proposed, separately for each parameter and each steel subgroup, using only monotonic properties that proved to be relevant for estimation of particular parameter. Data collected were efficiently used in artificial neural network development by implementing k-fold cross-validation technique. Results obtained by artificial neural networks have been evaluated by comparison with experimental values and values obtained using existing empirical estimation methods. For used test data, artificial neural networks proved to be more successful than empirical methods for estimation of most of the cyclic and fatigue properties and behaviour of different steel subgroups. Proposed and developed estimation of cyclic and fatigue parameters from readily available monotonic properties using artificial neural networks can facilitate faster and more accurate load capacity and durability analyses of steel components and structures during early stages of product design in various industrial applications (automotive, aeronautical etc.). Furthermore, it can contribute to the reduction of the need for experimental characterisation of material behavior and help decrease time and costs of product development. This thesis has not been published.

Mentor: Assoc. prof. Robert Basan, D. Sc.

Reviewers: Prof. Domagoj Rubeša, D. Sc.
Assoc. prof. Robert Basan, D. Sc.
Prof. Nelida Črnjarić-Žic, D. Sc.

Examiners: Prof. Domagoj Rubeša, D. Sc.
Assoc. prof. Robert Basan, D. Sc.
Prof. Nelida Črnjarić-Žic, D. Sc.

Oral examination: April 18th 2017.

Degree conferred:

This thesis is deposited in the library of the University of Rijeka, Faculty of Engineering.
(222, 41, 63, 91, Croatian language)

DD	1.	Estimation of cyclic and fatigue parameters of steels based on their monotonic properties using artificial neural networks	Tea Marohnić	University of Rijeka Faculty of Engineering Croatia
I	II	Keywords:	Fatigue of materials Steels Cyclic stress-strain parameters Fatigue strain-life parameters Lifetime prediction Statistical analysis Artificial neural networks	

UDC 539.388.1:669.14:519.23:004.032.26(043)