

GENETSKO MODELIRANJE ELEKTRIČNE PREVODNOSTI PREOBLIKOVANEGA MATERIALA

GENETIC MODELING OF ELECTRICAL CONDUCTIVITY OF FORMED MATERIAL

Leo Gusel¹, Miran Brežočnik²

¹Univerza v Mariboru, Fakulteta za strojništvo, Laboratorij za preoblikovanje materiala, Smetanova 17, 2000 Maribor, Slovenija

²Univerza v Mariboru, Fakulteta za strojništvo, Laboratorij za inteligentne obdelovalne sisteme, Smetanova 17, 2000 Maribor, Slovenija
leog@uni-mb.si

Prejem rokopisa – received: 2005-01-25; sprejem za objavo – accepted for publication: 2005-05-23

V prispevku smo predstavili metodo genetskega programiranja za uspešno določitev natančnih modelov spremembe električne prevodnosti hladno preoblikovane zlitine CuCrZr. Glavna značilnost metode genetskega programiranja, ki spada med evolucijske metode modeliranja, je, da rešitev ne iščemo po vnaprej določenih poteh ter da sočasno obravnavamo množico enostavnih objektov. Čedalje natančnejšim rešitvam smo se približevali postopoma, med postopkom simulirane evolucije. V prispevku smo predstavili le nekatere najuspešnejše oziroma najprimernejše genetske modele. Natančnost genetskih modelov je bila preverjena na množici preskusnih točk. Primerjali smo tudi natančnost genetsko dobljenih modelov in modela, dobljenega po deterministični metodi regresije. Primerjava je pokazala, da se genetski modeli dosti manj odmikajo od eksperimentalnih rezultatov in da so bolj raznoliki. Prav raznolikost nam omogoča, da se, glede na zahteve, odločimo za optimalen model, s katerim lahko matematično opišemo ali napovedujemo spremembo električne prevodnosti zlitine v okviru eksperimentalnega okolja.

Ključne besede: genetsko programiranje, modeliranje, hladno preoblikovanje, električna prevodnost, bakrove zlitine

In the paper a genetic programming method for efficient determination of accurate models for the change of electrical conductivity of cold formed alloy CuCrZr was presented. The main characteristic of genetic programming method, which is one of evolutionary methods for modeling, is its non-deterministic way of computing. No assumptions about the form and size of expressions were made in advance, but they were left to the self organization and intelligence of evolutionary process. Only the best models, gained by genetic programming were presented in the paper. Accuracy of the best models was proved with the testing data set. The comparison between deviation of genetic models results and regression models results concerning the experimental results has showed that genetic models are much more precise and more varied than regression model. The variety of genetic models allows us, concerning the demands, to decide for an optimal genetic model for mathematical description and prediction of change of electrical conductivity in the frame of experimental environment.

Key words: genetic programming, modeling, cold forming, electrical conductivity, copper alloys

1 UVOD

Poznanje vpliva hladnega preoblikovanja na mehanske, fizikalne, električne in kemične lastnosti materiala je pomembno predvsem z vidika kakovosti izdelka in ekonomičnosti proizvodnje, saj omogoča natančnejše načrtovanje preoblikovalnega postopka in napoved posameznih lastnosti izdelka vnaprej, torej že pred procesom preoblikovanja ¹. Da bi dobili čim natančnejše podatke o mehanskih in drugih lastnostih materiala, je treba določiti model, ki je resničnim razmeram čim bolj podoben. Modeliranje lastnosti materiala pomeni iskanje matematičnih izrazov, ki zagotavljajo kar najboljše prileganje med odvisnimi in neodvisnimi parametri, za kar se uporabljajo predvsem deterministične metode, katerih glavna značilnost so natančno določeni koraki, ki vodijo do rešitve ². V zadnjih letih pa se vse bolj uveljavljajo nedeterministične metode modeliranja, med katere spada tudi genetsko programiranje. Glavna značilnost vseh evolucijskih metod, in s tem tudi metode genetskega programiranja, je, da rešitev ne iščemo po vnaprej določenih (determinističnih) poteh in da sočasno obravnavamo množico enostavnih objektov ³.

V članku predstavljamo metodo genetskega programiranja za uspešno in učinkovito modeliranje in določitev natančnih modelov spremembe električne prevodnosti hladno preoblikovane zlitine CuCrZr. Na osnovi eksperimentalno ugotovljenega vpliva stopnje deformacije in še nekaterih parametrov pri hladnem preoblikovanju bakrove zlitine smo poiskali model sistema, ki ima evolucijski potencial v primerjavi z okoljem enak nič ali čim bližje nič. To pomeni, da v matematični obliki kar najbolje opiše vplivnost neodvisnih spremenljivk na spremembo električne prevodnosti. Pri genetskem modeliranju smo se omejili le na iskanje najboljših modelov spremembe električne prevodnosti zlitine CuCrZr, vendar je metodo genetskega programiranja možno uporabiti tudi za modeliranje drugih lastnosti materiala v okviru eksperimentalnega okolja.

2 GENETSKO PROGRAMIRANJE

Genetsko programiranje (*GP*) je metoda evolucijskega računanja in je v bistvu razširitev metode genetskih algoritmov. Strukture, ki so izpostavljene

$t = 0$
 ustvari začetno populacijo $P(t)$
 ovrednoti $P(t)$
ponavljaj
 spreminjaj $P(t) \rightarrow P(t+1)$
 ovrednoti $P(t+1)$
 $t = t + 1$
dokler ni izpolnjeno ustavitveno merilo


Slika 1: Splošna shema algoritmov *GP*
Figure 1: General scheme of *GP* algorithms

prilagajanju, so hierarhično organizirani organizmi (računalniški programi) z dinamično spreminjajočo se obliko in velikostjo⁴. Populacija organizmov se pri *GP* spreminja in prilagaja po načelih naravne selekcije in genetskih operacij. Vsak posamezen organizem v populaciji je ovrednoten glede na uspešnost izvedenega dela v določenem problemskem okolju. Temu ovrednotenju pravimo prilagojenost. Cilj metode *GP* je poiskati tisti organizem iz množice računalniških programov, ki najbolje reši dani problem oziroma ima najboljšo prilagojenost.

Slika 1 prikazuje splošno shemo genetskega *GP*³. Reševanje problema se začne z ustvarjanjem populacije naključnih organizmov $P(t)$, kjer je t čas oziroma števec generacij. V naslednjem koraku izračunamo prilagojenost organizmov. Tiste, ki bolje rešijo dani problem, pogosteje izberemo za spreminjanje z genetskimi operacijami. S spreminjanjem enega ali več organizmov ustvarjamo potomce, ki pomenijo novo generacijo. To ovrednotimo in postopek ponavljamo tako dolgo, dokler ni izpolnjeno ustavitveno merilo, ki je lahko največje predpisano število generacij ali pa zadostna kakovost rešitve.

Nabor vseh možnih rešitev je pri genetskem programiranju nabor vseh možnih kombinacij funkcij, ki jih lahko sestavimo iz nabora funkcij F in nabora terminalov T . Nabor funkcij F lahko vsebuje: osnovne računske operacije (x , $+$, $-$, $/$), druge matematične funkcije (\cos , \exp , \lg), Boolove operacije (AND, OR, NOT), pogojne operatorje in iteracijske funkcije. Nabor terminalov T lahko vsebuje številске konstante, logične konstante (NIL, T) ter spremenljivke. Z naključno izbiro ene izmed funkcij iz nabora F in nabora terminalov T ustvarimo začetne organizme. V našem primeru so organizmi matematični izrazi. Verjetnost izbire je enaka za vse funkcije in terminale. V drugem koraku izračunamo prilagojenost posameznega matematičnega izraza tako, da vanj vstavimo vrednosti vhodnih spremenljivk za posamezno meritev. V našem primeru prilagojenost izračunamo po definiciji³:

$$\Delta = \frac{\sum_{i=1}^n \Delta_i}{n} \quad (2.1)$$



Slika 2: Prikaz operacije križanja matematičnih izrazov
Figure 2 Crossover operation of mathematical expressions in *GP*

kjer je Δ povprečni odmik modelnih rezultatov, n je število vseh merilnih točk, Δ_i pa odmik v posamezni merilni točki i in je definirano kot:

$$\Delta_i = \left| \frac{M_i - E_i}{E_i} \right| \cdot 100 \%$$

kjer sta M_i modelni in E_i eksperimentalni rezultat. Postopek ponovimo za vse meritve. V tretjem koraku sledi spreminjanje matematičnih izrazov z genetskimi operacijami. Izkaže se, da pri *GP* zadostujeta operaciji reprodukcije in križanja, medtem ko je mutacija manj vplivna⁵. Z reprodukcijo prenesemo v naslednjo generacijo tiste matematične izraze, ki so uspešnejši (boljša prilagojenost). Z operacijo križanja pa poteka izmenjava genetskega materiala med posameznimi organizmi, tako da iz dveh starševskih organizmov (matematičnih izrazov) nastaneta dva potomca.

Slika 2 prikazuje genetsko operacijo križanja. Z naključno izbiro točke križanja dobimo dva odlomka (krepkeje označeno) in dva ostanka starševskih organizmov. Potomca 1 in 2 dobimo z medsebojno zamenjavo odlomkov med dvema ostankoma starševskih organizmov. Nato sledi zaporedno ponavljanje drugega in tretjega koraka. Problem je rešen, ko vsaj en matematični izraz v populaciji izpolni ustavitveno merilo. Ker pa *GP* temelji na verjetnosti, ni zagotovljeno, da bomo uspešne rešitve dobili v vsakem zagonu sistema za genetsko programiranje. Zaradi tega je priporočljivo poiskati rešitev v več neodvisnih zagonih (civilizacijah).

3 EKSPERIMENTALNO DELO

Namen ekperimentalnega dela je bil ugotoviti, kako na spremembo električne prevodnosti (a) zlitine CuCrZr pri hladnem preoblikovanju z vlečenjem vplivata stopnja deformacije (ϵ_e) in koeficient trenja uporabljenega maziva (μ). Pri tem smo namenoma vzeli zelo vpliven parameter (ϵ_e) in parameter (μ), ki v manjši meri vpliva na spremembo¹. Za preizkusni material smo uporabili zlitino CuCrZr, ki razen bakra, ki je osnova, vsebuje še 0,71 % Cr in 0,05 % Zr. Zlitino v obliki palice s premerom 20 mm smo hladno vlekli na vlečni klopi s hitrostjo 20 m/min in pri kotu vlečne matrice $2\alpha = 28^\circ$. Za mazivo smo uporabili tri različna olja s koeficientom trenja $\mu = 0,07$, $0,11$ in $0,16$. Z vsakim od treh maziv smo postopoma vlekli palice do različnih končnih

premerov in dobili šest različno hladno deformiranih vzorcev zlitine.

Skupno smo torej dobili osemnajst različnih vzorcev, pri katerih smo očistili čelno površino. Tako pripravljene vzorce smo izmerili električno prevodnost pri temperaturi 20 °C z instrumentom za merjenje električne prevodnosti Sigmatest D 2.068 (Inst. Foerster) pri merilni frekvenci 120 kHz. Zaradi natančnosti rezultatov so bile izvedene po tri meritve za vsak vzorec ter nato izračunane srednje vrednosti za električno prevodnost posameznega vzorca. Vrednosti parametrov in rezultati meritev so zbrani v **tabeli 1**.

Tabela 1: Rezultati meritev električne prevodnosti a hladno vlečenih vzorcev

Table 1: Measurements results of electrical conductivity a of cold drawn specimens

i	ε_e	μ	a (m / (Ω mm ²))
surovec	–	–	50,33
1	0,10	0,07	49,85
2	0,21	0,07	49,16
3	0,32	0,07	48,35
4	0,44	0,07	46,30
5	0,57	0,07	44,25
6	0,71	0,07	43,10
7	0,10	0,11	49,60
8	0,32	0,11	47,60
9	0,71	0,11	43,00
10	0,10	0,16	49,10
11	0,44	0,16	45,50
12	0,71	0,16	42,20
13	0,21	0,11	48,52
14	0,44	0,11	46,14
15	0,57	0,11	44,18
16	0,21	0,16	48,90
17	0,32	0,16	47,55
18	0,57	0,16	44,40

4 REZULTATI IN DISKUSIJA

4.1. Genetski parametri

Genetsko okolje za modeliranje z *GP* je prvih 12 meritev iz **tabele 1**, ki jih uporabimo kot datoteko za učenje. Drugih šest meritev (od $i = 13$ do $i = 18$) pa je preskusna datoteka za preverjanje genetskih modelov. Neodvisni spremenljivki sta stopnja deformacije in koeficient trenja maziva, odvisna spremenljivka pa električna prevodnost. Med velikim številom uspešnih rešitev (matematičnih izrazov), ki dovolj natančno opisujejo zvezo med odvisno in neodvisnima spremenljivkama, so v članku prikazni le trije končni genetski modeli: najnatančnejši in dva najenostavnejša.

Genetsko modeliranje je bilo v celoti izvedeno s programom za genetsko programiranje, razvitem v laboratoriju za preoblikovanje na FS, Maribor. Program je napisan v programskem jeziku AutoLisp. Načeloma je možno uporabiti katerikoli programski jezik, ki lahko

vrednoti računalniške programe (npr. pascal, basic, C), vendar ima AutoLisp nekatere značilnosti, ki so še posebej primerne za genetsko programiranje: hitro ovrednotenje programa, zapis programov v drevesni strukturi in s tem lažji dostop do drevesa računalniških programov in podprogramov, identičnost v obliki podatkov in programov. Program vsebuje 49 modulov oziroma samostojnih programskih enot, ki tvorijo celoto ter jih lahko razdelimo na problemsko neodvisne in problemsko odvisne dele. Jedro programa predstavlja problemsko neodvisen del, problemsko odvisen del pa med drugim predstavlja izračun evolucijskega programa, ki se za različne probleme izračunava različno. Za izbiro naključnih točk genetskih operacij križanja in mutacije smo v programu uporabili Park-Millerjev generator naključnih števil, ki se najpogosteje uporablja v genetskem programiranju ter je tudi osnova za ustvarjanje naključnih realnih števil na določenem intervalu. Čas trajanja posamezne civilizacije (procesiranja programa) je odvisen od samega problema, od vhodnih evolucijskih parametrov, števila generacij ter od zmogljivosti računalnika. V našem primeru je bil čas procesiranja od 5 minut do 15 minut na zelo zmogljivem osebni računalniku. Pri kompleksnejših problemih lahko procesiranje traja tudi več ur. Program je zasnovan tako, da lahko razvoj posamezne civilizacije natančno ponovimo, kar nam omogoča opazovanje vpliva evolucijskih parametrov na končno rešitev.

Modeliranje smo izvedli v več poskusih, ki se med seboj razlikujejo po številu in vrsti funkcijskih in terminalskih celic. Izbrali smo dva različna nabora funkcij $F:(+, -, x, /)$ in $(+, -, x, /, EXP)$. Pri vseh preizkusih smo omejili število neodvisnih civilizacij na 100. Za vsako civilizacijo smo določili velikost populacije (500), največje število generacij (50), kar pomeni 2500000 genetsko razvitih modelov samo za en nabor funkcij. Prav tako smo predpisali verjetnost reprodukcije (0,1), verjetnost križanja (0,9) ter največjo dovoljeno globino organizmov (10).

4.2. Najboljši generirani modeli

Najboljši model po merilu najmanjšega odmika od eksperimentalnih rezultatov je bil generiran z naborom funkcij $F = (+, -, x, /)$ in ima povprečni odmik od eksperimentalnih rezultatov 0,21 % ter vsebuje 95 genov. V programskem jeziku LISP se glasi:

$$\begin{aligned} &(-(+ (+ (+ (* (+ -8,37046 \mu) (- \varepsilon 6,62217))) (+ (\% \mu \mu) \\ &-5,08276)) (\% (* \varepsilon \varepsilon) (+ (* (- \varepsilon \mu) (* \varepsilon 8,64746)) (+ (\% \\ &(+ (+ \mu \varepsilon) -5,08276) (+ (+ \mu \varepsilon) (- \varepsilon \mu))) \varepsilon)))) (\% \mu (+ (* \\ &(* (+ \varepsilon (* \varepsilon \mu)) (\% -2,74262 2,99582)) (* \varepsilon 6,62217)) \\ &(- \varepsilon 6,62217)) (+ (\% \mu \mu) -5,08276)))) (+ (\% (* (* (+ (+ \\ &\mu \varepsilon) (* \varepsilon \mu)) (+ 2,73117 \mu)) (* \varepsilon \varepsilon)) (+ (+ \mu \varepsilon) (* \varepsilon \mu))) \\ &(+ \mu \varepsilon))) \end{aligned}$$

Opomba: v enačbi * pomeni x (znak za množenje).

Zgornji izraz lahko zapišemo v matematični obliki:

$$51,47 + \varepsilon(\mu - 9,37) + \mu(-7,622 + (-4,082 - 6,062(\varepsilon - 6,622)\varepsilon^2(1 + \mu))^{-1}) + \varepsilon^2[(-2,731 - \mu) + (\varepsilon + 8,647\varepsilon(\varepsilon - \mu) + 0,5(\varepsilon + \mu - 5,082)/\varepsilon)^{-1}] \quad (4.2.1)$$

Podrobnejši potek evolucije najboljšega modela je prikazan na slikah 3 in 4. Slika 3 prikazuje krivuljo povprečnih deležev odklikov med eksperimentalnimi rezultati in najboljšim genetskim modelom vsake generacije. Najboljši model v prvi generaciji ima povprečni delež odklika 12,5 %, nato pa že v peti generaciji dosežemo delež odklika 1,5 %. V deseti generaciji je delež odklika 0,51 % in nato dokaj enakomerno in počasneje pada do zadnje, 50. generacije, kjer dobimo model z najmanjšim povprečnim deležem odklika. Položnost krivulje po 30. generacije kaže na to, da se prilagojenost najboljših modelov od te točke naprej le počasi izboljšuje. Sklepamo lahko, da tudi pri večjem številu generacij (npr. 200) ne bi dobili modela z bistveno manjšim odklikom.


S slike 4, ki prikazuje krivuljo števila vseh genov n_g najboljših modelov posamezne generacije, lahko sklepamo o zapletenosti oziroma velikosti posameznega modela. V prvi generaciji smo dobili zapleten model s kar 83 geni, že v drugi generaciji pa je evolucija ustvarila model s samo devetimi geni. V naslednjih generacijah se je število vseh genov najboljšega modela počasi, a vztrajno večalo. Največje število genov (95) dobimo v zadnji generaciji pri najnatančnejšem modelu.

Ker pri modeliranju z GP ne predpišemo oblike in velikosti rešitve, ampak je to prepuščeno evoluciji, smo kot rezultat dobili tudi preproste genetske modele, ki pa so kljub temu dovolj natančni. Dva najboljša, zapisana v matematični obliki, sta:

$$50,9 + e^{\varepsilon} - 14,1 \varepsilon_e \quad (4.2.2)$$

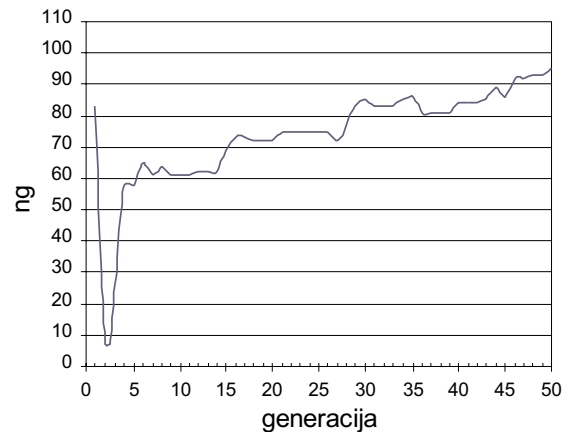
$$49,86 - 8,562 \varepsilon_e \quad (4.2.3)$$

Modela (4.2.2) in (4.2.3) sta zanimiva predvsem zato, ker se v obeh pojavlja samo ena neodvisna spremen-



Slika 3: Krivulja povprečnih deležev odklika Δ med najboljšim modelom posamezne generacije in eksperimentalnimi rezultati ($F = +, -, x, /$)

Figure 3: Percentage discrepancy curve Δ between the best model of individual generation and experimental results ($F = +, -, x, /$)



Slika 4: Krivulja števila vseh genov n_g najboljšega modela v vsaki generaciji ($F = +, -, x, /$)

Figure 4: Curve of all genes n_g of the best model in each generation ($F = +, -, x, /$)

ljivka (stopnja deformacije ε_e), kar pomeni, da je evolucija sama postopoma izločila manj vplivno spremenljivko (μ). Model (4.2.3) vsebuje le eno funkcijsko celico (operacijo odštevanja) in je zaradi enostavnosti in dovolj dobre natančnosti zelo primeren za praktično uporabo.

4.3 Primerjava genetskih in regresijskih modelov

Zanimala nas je še primerjava natančnosti in zapletenosti genetskih modelov z modeli, izračunanimi z regresijsko metodo, ki se na tem področju največ uporablja. Ta metoda je najpogosteje uporabljana deterministična metoda modeliranja ⁶. Za modeliranje smo uporabili večparametrsko regresijsko metodo, s katero lahko izračunamo povezavo med eno odvisno (el. prevodnost a) in več neodvisnimi spremenljivkami (stopnja deformacije ε_e in koeficient trenja maziva μ). Modeliranje je bilo izvedeno z računalniškim programom za večparametrsko regresijo. Dobili smo regresijski model z obliko:


$$a = 50,531 - 8,758\varepsilon_e + 16,53 \mu - 4,072 \varepsilon_e^2 - 124,946 \mu^2 + 6,006 \varepsilon_e \mu \quad (4.3.1)$$

Povprečni odklik Δ posameznih genetskih modelov in regresijskega modela od eksperimentalnih rezultatov ter njihova zapletenost je nazorno prikazana v tabeli 2.

Tabela 2: Natančnost in kompleksnost genetskih in regresijskih modelov

Table 2: Accuracy and complexity of genetic and regression models

Model	Povprečni odklik od eksp. rezultatov Δ , izražen v (%)			Kompleksnost modela
	Preskusna datoteka	Datoteka za učenje	Skupaj	
GP (4.2.1)	0,20	0,23	0,21	velika
GP (4.2.2)	0,65	0,79	0,72	majhna
GP (4.2.3)	1,16	1,31	1,23	zelo majhna
REG (4.3.1)	0,94	0,56	0,75	srednja



Slika 5: Odmik Δ modelnih rezultatov od rezultatov eksperimenta v posamezni merilni točki i

Figure 5: Deviation Δ of model results from the experimental results in singular measurement point i

Potrjeno je nepisano pravilo *GP*, da je navadno najnatančnejši model tudi najbolj zapleten, saj je povprečni odmik modela (4.2.1) na preskusni datoteki in datoteki za učenje najmanjši in je le 0,20 % oziroma 0,23 %. Ta model bi izbrali v primeru, kadar je glavno merilo natančnost. Če pa potrebujemo enostavne modele (ob zadovoljivi natančnosti), potem izberemo model (4.2.2) ali (4.2.3). Regresijski model ima v primerjavi z najboljšim genetskim modelom slabšo natančnost, je pa enostavnejši. V primerjavi z enostavnim genetskim modelom (4.2.2) je natančnost regresijskega modela v povprečju približno enaka, vendar je genetski model enostavnejše oblike. Velja pripomniti, da je odvisnost el. prevodnosti od deformacije in koeficienta trenja relativno enostavna, vendar je kljub temu najboljši genetski model v povprečju 3,5-krat natančnejši od regresijskega. V primeru zelo kompleksnih relacij odvisne in neodvisnih spremenljivk bi bila razlika v natančnosti obeh modelov še večja v prid genetskega.

Diagram na **sliki 5** prikazuje absolutne vrednosti odmika modelnih rezultatov od eksperimenta v vsaki posamezni merilni točki. Model (4.2.1) ima zelo majhno amplitudo odmika, saj so se v procesu evolucije v vsako nadaljnjo generacijo prenašali le najbolj prilagojeni organizmi. Največji odmik je v merilni točki 7, kjer je 0,51 %. Pri modelu (4.2.3) je bilo število generacij

mного manjše, kar pomeni manj možnosti za razvoj uspešnih modelov, zato je amplituda odmika večja. Največji odmik je v točki 3 (2,5 %). Pri tem genetskem modelu je mnogo večji odmik na preskusnih točkah, kar je verjetno posledica majhnega števila teh točk in s tem manjša možnost natančnega prilagajanja. Enaka ugotovitev velja tudi za regresijski model (4.3.1).

5 SKLEPI

Na osnovi dobljenih rezultatov in analiz lahko povzamemo naslednje bistvene sklepe:

- Metoda modeliranja z genetskim programiranjem se je izkazala ne le kot alternativa konvencionalnim postopkom modeliranja, temveč kot primerna in zanesljiva metoda izračunavanja zelo natančnih sprememb električne prevodnosti hladno preoblikovane zlitine.
- Pri istem genetskem okolju dobimo veliko število različnih genetskih modelov, ki se med seboj razlikujejo v natančnosti in zapletenosti. Vzrok za to je nedefinirana pot reševanja genetskega programiranja – postopek je prepuščen evoluciji.
- Primerjava med najboljšimi genetskimi in regresijskimi modeli pokaže, da so genetski modeli sicer bolj zapleteni, vendar dosti natančnejši od regresijskih.
- Raznolikost uspešnih genetskih modelov omogoča lažjo izbiro ustreznega modela glede na različna merila in lastnosti, ki jih od modela pričakujemo.
- Genetske modele je možno uporabiti za napovedovanje spremembe električne prevodnosti hladno preoblikovane zlitine v okviru eksperimentalnega okolja.

6 LITERATURA

- ¹ Lange, K.; *Handbook of metal forming*; McGraw Hill: New York, 1991
- ² Barnes, W.; *Statistical Analysis for Engineers and Scientists – a computer based approach*, The University of Texas at Austin, McGraw – Hill, New York 1994
- ³ Koza, J. R.; *Genetic programming*; The MIT Press: Massachusetts, 1992
- ⁴ Mitchell, T. M.; *Machine learning*; McGraw-Hill, 1997
- ⁵ Bäck, T.; Hammel, U.; Schwefel, H.-P. Evolutionary computation: Comments on the history and current state. *IEEE Transaction on Evolutionary Computation* 1 (1997) 1, 3–17
- ⁶ Montgomery, D. C.; Runger, G. C.; Hubele, N. F. *Engineering statistics*; Second Edition, John Wiley & Sons; New York, 2001