

Toplo stiskanje jekla za poboljšanje CF53

Hot compression of CF53 tempering steel

MILAN TERČELJ¹, IZTOK PERUŠ², GORAN KUGLER¹, RADO TURK¹

¹Oddelek za materiale in metalurgijo, Univerza v Ljubljani,
Aškerčeva cesta 12, 1000 Ljubljana, Slovenija;

E-mail: milan.trcelj@ntf.uni-lj.si, goran.kugler@ntf.uni-lj.si, rado.turk@ntf.uni-lj.si

²FAGG, Univerza v Ljubljani, Jamova 2, 1000 Ljubljana, Slovenija;

E-mail: iperus@siol.net

Received: June 1, 2005 Accepted: November 24, 2005

Povzetek: Na fizikalnemu simulatorju termomehanskih metalurških stanj Gleeble 1500 je bilo izvedeno toplo stiskanje cilindričnih vzorcev iz jekla za poboljšanje (CF53). Za potrebe optimiranja tehnologij toplega preoblikovanja je napovedovanje krivulj tečenja z empiričnimi in fenomenološkimi modeli premajhne natančnosti, zato se v zadnjem času za njihovo napovedovanje vključujejo metode umetne inteligence, med katerimi pogosto opazimo uporabo nevronske mreže. Uspešnost metode je povezana s težavami glede izbire optimalne arhitekture plasti nevronske mreže, omejitve števila vhodnih parametrov, itd. Z namenom, da te postopke racionaliziramo, smo eksperimentalno bazo krivulj tečenja uporabili za napovedovanje s CAE NN (angl. "Conditional Average Estimator Neural Network"), ki so sposobne modeliranja fizikalnih zakonov tudi v področjih velikih gradientov. Natančnost napovedovanja je praktično v območju 0-3 %. Za dano bazo toplih krivulj tečenja CF53 jekla je bila izračunana tudi aktivacijska energija.

Abstract: By means of hot compression tests carried out on a Gleeble 1500 thermomechanical simulator the deformation behaviour of CF53 tempering steel was investigated over a wide range of temperatures (900-1200 °C) and with a strain rate of 0.1-8 s⁻¹ and true strains of 0-0.6. Due to the poor accuracy in predicting flow stress curves for the needs of optimizing hot forming technologies by empirical and phenomenological models, it is nowadays current practice to employ neural networks for their prediction. This approach is justified only in the case of predicting ability on the entire area of testing and not only the measured data. This study confirmed the good predictive power of CAE NN (Conditional Average Estimator Neural Network) to predict flow stress curves since it can model physical laws in areas of high gradients. The accuracies achieved are practically within 3 %; an average is error of 1 %. We also calculated the activation energy for deformed steel.

Ključne besede: CF53 jeklo za poboljšanje, toplo stiskanje, krivulje tečenja, CAE nevronske mreže, aktivacijska energija.

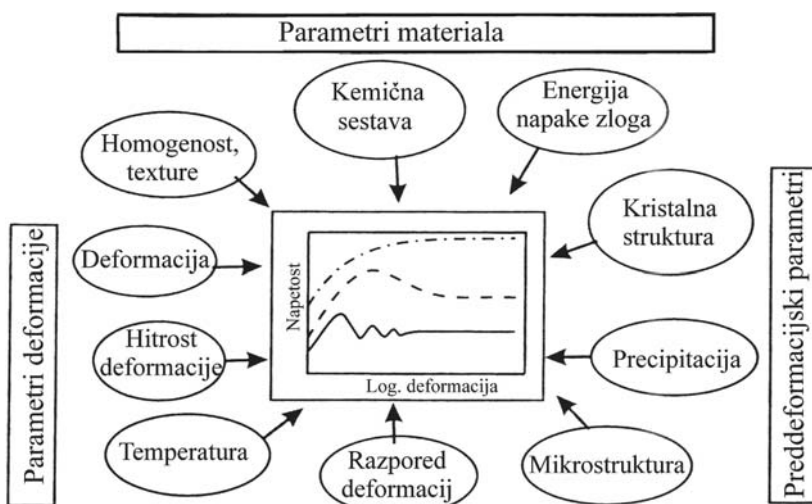
Key words: CF53, hot compression, flow stress, CAE neural network, activation energy.

UVOD

Na krivulje tečenja med toplo deformacijo jekel vpliva veliko faktorjev (slika 1), katerih vplivi so zelo kompleksni. Zato so zveze med temi faktorji in krivuljami tečenja nelinearne in prostorsko zelo razgibane (predvsem v prostoru napetost - deformacija – hitrost deformacije) [1-2]. Posledično so tudi opisi krivulj tečenja med toplo deformacijo z empiričnimi, kot tudi fenomenološkimi modeli velikokrat premalo natančni. Fizikalni modeli so že zelo izpopolnjeni, so pa bolj ali manj še vedno omejeni na dokaj čiste kovine in jih za namene industrijskih aplikacij še ne uporabljamo [3]. Razvoj konstitutivnih enačb od čistih empiričnih do bolj fizikalno podprtih še vedno ostaja cilj znanstvenih raziskav. Kljub vedno novim konstitutivnim modelom za opis krivulj tečenja pa v natančnosti napovedovanja ni prišlo do vidnega napredka, saj je le-ta za aplikativne namene še vedno nezadovoljiva in se giblje v območju običajnega variiranja testnih parametrov vroče predelave med 2

in 60 %. Iskanje novih poti zato ostaja še naprej predmet intenzivnih študij [4-11]. V zadnjem času se kot učinkovito sredstvo ponujajo BP nevronske mreže (BP NN), vendar tudi tu nastopajo težave glede izbire optimalne arhitekture plasti, vključevanja števila vhodnih vplivnih parametrov, unifikacije vrednosti parametrov, itd. Natančnost interpolacijskega napovedovanja z BP nevronskimi mrežami je sicer boljša kot v primeru empiričnih funkcijskih zapisov in se v giblje v mejah npr. med 0 – 7 % za hitroreznna jekla in 0 – 9 % za ogljikova jekla [3,11-12].

Hodgson and Kong [13-14] poročata o potrebni natančnosti znotraj 5 % pri napovedovanju napetosti tečenja za učinkovito optimiranje tehnologij toplega valjanja. To med drugim zahteva povsem kontrolirano izvajanje nastavljenih parametrov preiskusa, na kar med drugim precej vpliva zadostna togost samega eksperimentalnega sistema. Iz izkušenj vemo, da so eksperimentalni podatki, posebno starejšega



Slika 1. Parametri, ki vplivajo na krivulje tečenja [2].

datuma, premalo zanesljivi za današnje zahteve napovedovanja. Žal so velikokrat še naprej osnova za namene računalniškega simuliranja procesov vročega preoblikovanja, ko je potrebno npr. opisati tok snovi, prenos toplote, maksimalne obremenitve na preoblikovalnem stroju ter lokalne obremenitve (mehanske, termične, tribološke, itd.) na preoblikovalnem orodju. Zato določevanje zanesljivih krivulj tečenja ostaja še nadalje predmet intenzivnih študij [8,15].

Eno takšnih področij, ki zahteva zanesljivo poznavanje krivulj tečenja, so tudi jekla za poboljšanje, in to ne-le v fazi njihove metalurške izdelave (npr. valjanje polizdelkov), pač pa tudi kasneje pri študiju obnašanja materiala med izdelavo izdelka npr. toplo utopno kovanje). CF53 jeklo za poboljšanje uporabljamo za izdelavo konstrukcijskih delov, ki so pri uporabi izpostavljeni velikim in časovno spreminjajočim obremenitvam (npr. vzmeti, sorniki, pogonske gredi, vretena, odmične gredi, večji zobniki, itd). V študijo vključeno jeklo izdelujemo po konvecionalni poti t.j. najprej vlivamo v bloke, nato valjamo na valjalnem stroju do gredic dimenzijskega območja kvadrat 50 - 90 mm. Tako dobljene gredice, razrezane na določene dolžine, lahko služijo tudi kot vhodni material za utopno kovanje. Optimiranje plastičnega preoblikovanja omenjenega jekla je usmerjeno v zmanjšanje števila dogrevanj med toplim preoblikovanjem (valjanjem) na manjše dimenzije, za kar moramo maksimalno

izkoristiti preoblikovalne lastnosti jekla pri intenziviranju plana valjanja (optimalno razporediti redukcije presekov glede na energetsko-obremenitvene zmožnosti samega valjalnega stroja ter trdnostne karakteristike valjev).

V dostopni literaturi se karakterizacije preoblikovalnih lastnosti jekel za poboljšanje nanašajo predvsem na torzijske preizkuse [16-17], podatki na osnovi tlačnih preizkusov pa so redkejši. V tem prispevku podajamo krivulje tečenja, dobljene s pomočjo toplega stiskanja cilindričnih vzorcev, iz jekla za poboljšanje CF53, deformiranega pri različnih temperaturah in hitrostih deformacije. S pomočjo te baze so nato krivulje tečenja napovedovane s pomočjo CAE nevronske mreže. Pri tem sta bila uporabljena tako konstantni, kot tudi nekonstantni parametra gladkosti.


EXPERIMENT

Vzorci in material

Kemična sestava jekla za poboljšanje je podana v tabeli 1. Cilindrični vzorci tipa Rastegew in dimenzij $\phi = 8 \text{ mm} \times 12 \text{ mm}$ so bili izdelani iz okrogle palice $\phi = 60 \text{ mm}$, ki je bila predhodno valjana iz gredice $250 \text{ mm} \times 250 \text{ mm}$. Vhodno mikrostrukturo uporabljenih vzorcev podaja slika 2, iz katere so razvidna zrna lamelarnega perlita in zrna ferita.

Tabela 1. Kemična sestava cilindričnih vzorcev iz CF53 (wt %).

C	S	Si	Cr	Ni	Al	Cu	Mn	Mo	P	Sn
0,55	0,042	0,24	0,22	0,05	0,034	0,14	0,69	0,02	0,027	0,010




Slika 2. Začetna mikrostruktura cilindričnih vzorcev iz CF53, (zrna lamelnega perlita in zrna ferita).

Testna naprava in testni pogoji

Tople stiskalne preizkuse smo izvedli na Gleeble 1500 testni napravi, ki omogoča fizikalno simulacijo želenih termomehanskih metalurških stanj. Slika 3 prikazuje ureditev testne celice za toplo stiskanje. Za zmanjšanje trenja med stiskanim cilindričnim

vzorcem in orodjem ter preprečevanje njunega medsebojnega zvarjanja smo uporabili grafitno mazivo.

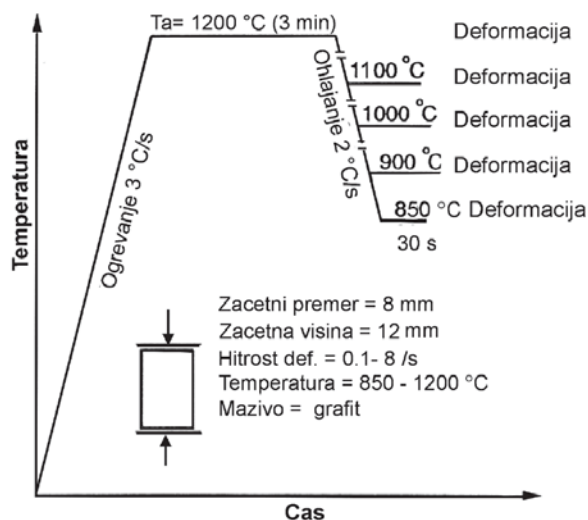
Testni pogoji toplega stiskanja cilindričnih vzorcev so podani v tabeli 2. Izvedeno je bilo v temperaturnem območju med 900 - 1200 °C, pri treh različnih hitrostih deformacije



Slika 3. Shematičen prikaz izvedbe tlačnega preizkusa na simulatorju termomehanskih stanj Gleeble 1500.

Tabela 2. Vrednosti glavnih parametrov testiranja.

Jeklo	Ta [°C]	Temperaturno območje [°C]	Hitrost deformacije s ⁻¹
CF53	1200	900 -1200	0,1 , 1, 8

**Slika 4.** Shematski prikaz poteka temperature testiranih cilindričnih vzorcev.

(0,1, 1, 8 s⁻¹) in ob predhodnem ogrevanju cilindričnih vzorcev (slika 4). Hitrost ogrevanja je znašala 3 °C/s, čemur je sledilo triminutno zadrževanje na temperaturi (Ta) 1200 °C, nato ohlajanje s hitrostjo 2 °C/s na temperaturo deformacije ter ponovno 30 sekundno zadrževanje na načrtovani temperaturi deformacije. Po deformaciji so bili vzorci naglo gašeni z vodo.

UPORABA CAE NEVRONSKIH MREŽ PRI NAPOVEDI KRIVULJ TEČENJA

Teoretične osnove in izrazi

V članku obravnavamo problem, kako oceniti/napovedati krivulje tečenja v odvisnosti od znanih vplivnih parametrov kot so temperatura, deformacija in hitrost

deformacije. Prvo spremenljivko - eno točko krivulje tečenja - običajno imenujemo izhodni parameter, znane vplivne parametre pa vhodne parametre problema.

Za določitev neznanega izhodnega parametra (npr. za eno točko krivulje tečenja) s CAE nevronske mreže je potrebna baza podatkov, ki vsebuje zadostno število zanesljivih in primerno razporejenih empiričnih podatkov. Baza podatkov vsebuje empirične podatke, ki ustrezajo vhodnim in izhodnim parametrom opazovanega pojava. Vsako posamično opazovanje poljubnega fizikalnega pojava tako matematično predstavimo z *modelnim vektorjem*, pri čemer vhodni in izhodni parametri pojava ustrezajo komponentam tega vektorja. Na primer, če je pri temperaturi $T = 950$ °C, deformaciji 0,3 in hitrosti deformacije 5 s⁻¹

izmerjena napetost 350 MPa, lahko modelni vektor zapišemo kot $\{950, 0,3, 5; 350\}$. Baza podatkov vsebuje končno število takšnih modelnih vektorjev.

Tipično shemo strukture CAE nevronske mreže lahko najdemo v literaturi [18-19]. Po tem pristopu lahko vsak izhodni parameter oz. komponento obravnavanega modelnega vektorja (t.j. vektorja z znanimi vhodnimi parametri in neznanimi izhodnimi parametri) napovemo s pomočjo izraza:

$$\hat{r}_k = \sum_{n=1}^N C_n \cdot r_{nk} \quad (1),$$

kjer je

$$C_n = \frac{c_n}{\sum_{j=1}^N c_j} \quad (2)$$

in

$$c_n = \exp \left[\frac{-\sum_{i=1}^L (p_i - p_{ni})^2}{2w^2} \right] \quad (3).$$

Pri tem je \hat{r}_k napovedan (ocenjen) k -ti izhodni parameter (npr. *napetost*), r_{nk} je enak izhodni parameter, ki ustreza n -temu modelnemu vektorju iz baze podatkov, N je število modelnih vektorjev v bazi podatkov, p_{ni} je i -ti vhodni parameter n -tega modelnega vektorja v bazi podatkov (npr. *temperatura*, *deformacija*, *hitrost deformacije*), p_i je i -ti vhodni parameter obravnavanega modelnega vektorja in L je število vhodnih parametrov obravnavanega pojava.

Enačba 1 kaže, da se napoved izhodnega parametra določi kot kombinacija vseh izhodnih parametrov iz baze podatkov.

Posamezne uteži so odvisne od podobnosti med vhodnimi parametri p_i obravnavanega modelnega vektorja in enakimi vhodnimi parametri p_{ni} modelnih vektorjev iz baze podatkov. C_k je merilo podobnosti. Neznana vrednost izhodnega parametra je torej izračunana tako, da je modelni vektor, sestavljen iz znanih (vhodnih) in neznanih (izhodnih) parametrov, maksimalno konsistenten z modelnimi vektorji iz celotne baze podatkov.

Parameter w predstavlja širino Gaussove funkcije in ga imenujemo parameter gladkosti, saj določa gladkost rešitve. V splošnem velja, da manjša kot je vrednost w , slabše je posploševanje metode, in obratno, večja kot je vrednost w , boljše je posploševanje metode, vendar na račun zmanjšanja natančnosti. V praksi se zato primerna vrednost w določa z iteracijskim postopkom, kjer najboljši w ustreza primerno gladkim rešitvam problema ob istočasni minimizaciji napake napovedi. Potrebno je poznavanje obravnavanega pojava, nekaj izkušenj in logično-tehničnega razmisleka.

Izbira konstatnega w ustreza najbolj osnovnemu pristopu uporabe metode. V praksi pa se v nekaterih primerih izkaže, da nekonstantna vrednost w pogosto daje boljše rezultate. Pri uporabi nekonstatnega w lahko še vedno uporabimo enačbo 1, vendar ob izbiri primerne, lokalno ocenjene vrednosti w_i , pri čemer indeks i označuje i -ti vhodni parameter. Izraz za c_n (glej enačbo 1) se lahko zapiše kot

$$c_n = \exp \left[-\sum_{i=1}^L \frac{(p_i - p_{ni})^2}{2w_i^2} \right] \quad (4).$$

Važno je omeniti, da so izrazi enačb 1-3 izpeljani povsem teoretično [18-20] ob predpostavki konstantne (ne)zanesljivosti empiričnih podatkov. Razširitev te metode z uporabo nekonstantnega w (enačba 4) pa temelji na fizikalnih razmišljanjih. Medtem ko konstanten w ustreza kroglji v L -dimenzionalnem hiperprostoru (L je število vhodnih parametrov), ustreza nekonstanten w večosnemu elipsoidu v istem prostoru [21-22].

Proces učenja

Originalen predlog CAE metode [18] sestoji iz dveh delov. Prvi del ustreza tako imenovanemu procesu samoorganizacije nevronov. V primeru uporabe relativno majhnih baz podatkov lahko ta del brez večjih težav opustimo. Drugi del ustreza matematičnemu opisu obravnavanega pojava z uporabo optimalne cenilke, opisanem v prejšnjem poglavju. Iz tega vidika ustreza proces učenja enostavni predstavitvi baze podatkov CAE nevronskih mrež. Še več, v primerjavi s klasičnimi nevronskimi mrežami (BP NN), je testiranje uspešnosti modela bistveno enostavnejše. Namesto uporabe približno 70 % podatkov za učenje in preostalih 30 % za testiranje, je uporabljen drugačen pristop. Izhodni parameter, npr. napetost v krivulji *napetost-temperatura-deformacija-hitrost deformacije*, je napovedan za vsako točko krivulje iz baze podatkov, pri tem pa je obravnavan modelni vektor začasno izvzet iz baze podatkov. Z nekaj takšnimi poskusi se določi optimalna vrednost parametra gladkosti.

Da bi kvantitativno ocenili natančnost CAE metode pri napovedovanju krivulj tečenja, smo uporabili naslednjo enačbo, ki računa

kvadratni koren vsote kvadratov odstopanj za vsako deformacijsko opazovanje:

$$RMSSD = \sqrt{\frac{\sum_{i=1}^N (\hat{r}_k - r_k)^2}{N}} \quad (5).$$

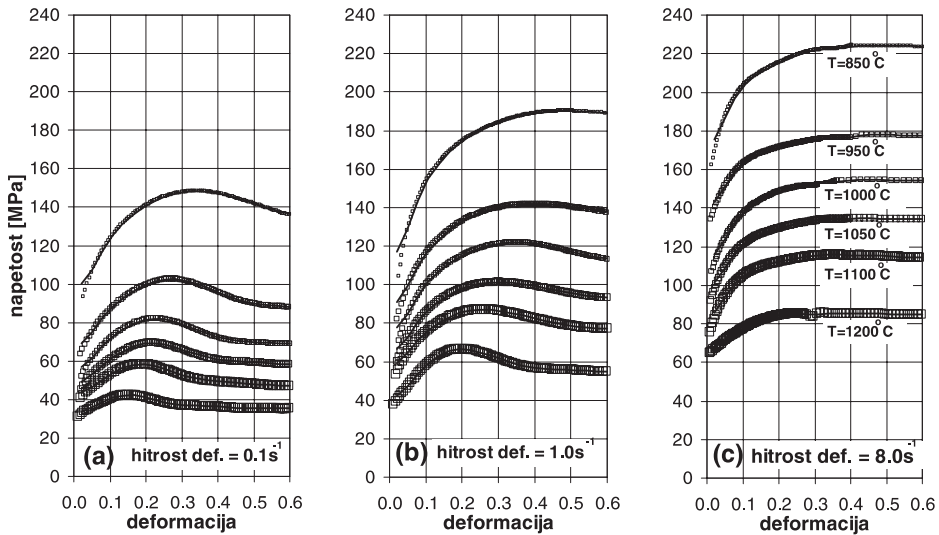
Napoved se smatra kot dobra, če je RMSSD vrednost znotraj 5 % povprečne krivulje tečenja za obravnavano stanje [11], pri čemer se povprečna krivulja tečenja s_{mfs} izračuna kot

$$\sigma_{\text{mfs}} = \frac{1}{\varepsilon} \int \sigma \, d\varepsilon \quad (6)$$

Krivulje tečenja in CAE napovedi pri uporabi konstantnega parametra gladkosti

Krivulje tečenja za jeklo CF53 pri različnih temperaturah in različnih hitrostih deformacije so prikazane na Sliki 5. Krivulje tečenja najprej hitro naraščajo z deformacijo do neke konstantne vrednosti, potem pa padejo do neke konstantne vrednosti pri višjih deformacijah. Ta oblika toplih krivulj tečenja je tipična za materiale, kjer med plastično deformacijo poteka tudi dinamična rekristalizacija. Rezultati za jeklo CF53 kažejo na relativno dobro ujemanje med eksperimentalnimi in napovedanimi vrednostmi krivulj tečenja. To je posledica dejstva, da so relacije med vhodnimi in izhodnimi parametri relativno enostavne. Uporaba konstantnega w je smiselna (enačba 3).

Slike kažejo relacije *napetost-deformacija* za različne temperature med 850 °C in 1200 °C, pri treh različnih hitrostih deformacij: 0,1 s⁻¹, 1 s⁻¹ in 8 s⁻¹. Večja odstopanja lahko opazimo le pri manjših deformacijah kjer so večji gradienti krivulj tečenja. Omeniti velja, da bi



Slika 5. Krivulje tečenja za jeklo CF53 – eksperimentalne in napovedane vrednosti pri uporabi konstantnega parametra gladkosti ($w=0.03$).

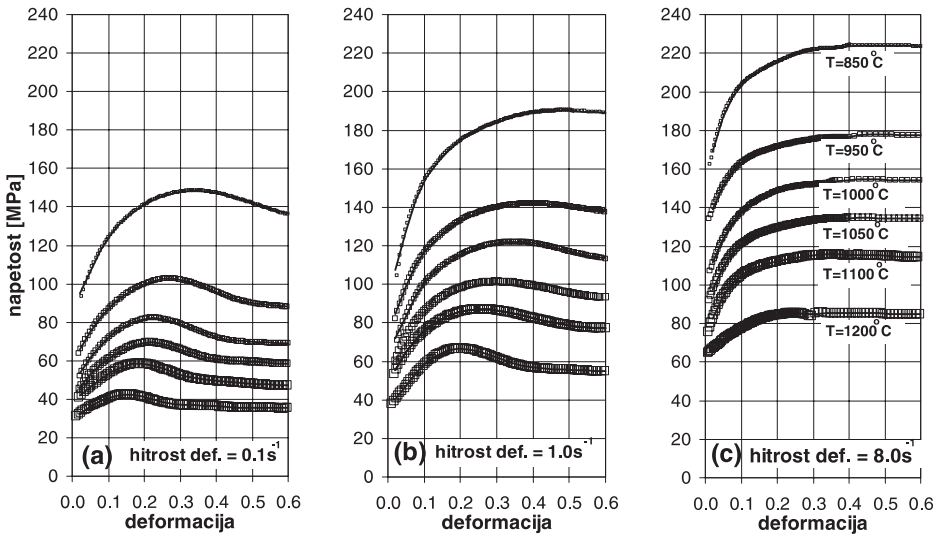
načeloma lahko uporabili manjše vrednosti w , s čimer bi izboljšali rezultate na tem območju, vendar bi potem poslabšali rezultati na drugih območjih. Dosežena natančnost pri učnih podatkih je od 0,5 % do 1,1 %, s povprečno napako okoli 0,8 %. Natančnost napovedi na testnih podatkih je 0,6 % do 1,3 %, s povprečno napako okoli 1 %. Dobljene napake so v povprečju znotraj meja zahtevanih natančnosti.

Krivulje tečenja in CAE napovedi pri uporabi nekonstatnega parametra gladkosti


Slika 6 jasno kaže bistveno izboljšanje rezultatov krivulj tečenja v območju deformacij med 0,02 in 0,1. Rezultati nakazujejo, da lahko modeliranje krivulj tečenja izboljšamo z uporabo nekonstatnega parametra gladkosti (enačba 4).

Dosežena natančnost pri učnih podatkih je od 0,1 % do 0,3 %, s povprečno napako okoli 0,2 %. Natančnost napovedi na testnih podatkih je 0,2 % do 0,6 %, s povprečno napako okoli 0,5 %. Dobljene napake so v povprečju precej bolj znotraj meja zahtevanih natančnosti kot jih navajajo različni avtorji pri uporabi klasičnih nevronske mreže z uporabo BP algoritma. Večja natančnost v obravnavanem primeru je tudi posledica večje razpoložljive gostote podatkov.

Sposobnost CAE nevronske mreže za interpolacijo je potrjena s prikazom napovedanih krivulj tečenja preko celega območja na katerem je bila trenirana. Slika 7 kaže tridimenzionalno sliko krivulj tečenja kot funkcijo temperatur in deformacij pri različnih hitrostih deformacij. Pri hitrosti deformacije $0,1 \text{ s}^{-1}$ je razvidno rahlo progresivno naraščanje preoblikovalne trdnosti s padanjem temperature deformacije. Ta trend je pri hitrosti deformacije 1 s^{-1} in 8 s^{-1} še manj izrazit.



Slika 6. Krivulje tečenja za jeklo CF53 - eksperimentalne in napovedane vrednosti pri uporabi nekonstatnega parametra gladkosti ($w_e = w_T = 0,03$, $w_{e(e=0,02)} = 0,01$, $w_{e(e=0,60)} = 0,03$).



Slika 7. Prostorska predstavitev krivulj tečenja za jeklo CF53 – eksperimentalne in napovedane vrednosti pri uporabi nekonstatnega parametra gladkosti ($w_e = 0,03$, $w_T = 0,10$, $w_{e(e=0,02)} = 0,01$, $w_{e(e=0,60)} = 0,03$).

DISKUSIJA

Iz maksimalnih napetosti tečenja za različne temperature in hitrosti deformacije smo izračunali konstante hiperbolične sinusne enačbe 7 [26].

$$Z = \dot{\epsilon} \exp(Q / RT) = A(\sinh \alpha \sigma)^n \tag{7}$$

To enačbo najprej logaritmiramo in takole preuredimo

$$\ln(\sinh(\alpha \sigma)) = \frac{1}{n} \ln(\dot{\epsilon}) + \frac{Q}{RnT} - \frac{1}{n} \ln(A), \tag{8}$$

nato pa definiramo funkcijo c^2 , ki minimizira razliko med izračunanimi in izmerjenimi vrednostmi napetosti tečenja [25]

$$\chi^2 = \sum_{i=1}^N \frac{(z_i - a_1 x_i - a_2 y_i - a_3)^2}{e_i^2}, \tag{9}$$

kjer je N število meritev, $z_i = \ln(\sinh \alpha \sigma_i)$, $x_i = \ln \dot{\epsilon}_i$ in $y_i = 10^4 T^{-1}$. Ostale oznake so $a_1 = n^{-1}$, $a_2 = 10^{-4} Q n^{-1} R^{-1}$ in $a_3 = n^{-1} \ln A$. Pri napaki upoštevamo samo napako napetosti z_i , ki jo lahko izrazimo kot

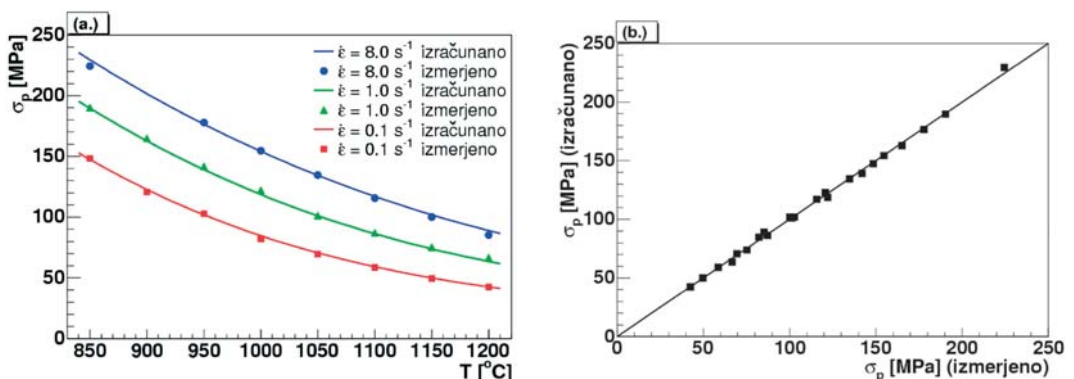
$e_i = \alpha e_i^\sigma \coth \alpha \sigma_i$, kjer so e_i^σ napake izmerjenih napetosti. Podrobnosti postopka minimizacije zgornje enačbe 9 najdemo v [23]. Funkcija c^2 ima minimum pri $Q = 316,86 \text{ kJ mol}^{-1}$, $\alpha = 0,00945 \text{ MPa}^{-1}$, $n = 5,3$ in $A = 1,88 \cdot 10^{12} \text{ s}^{-1}$. Ta vrednost je primerljiva z območjem vrednosti ($Q = 280 - 330 \text{ kJ mol}^{-1}$) sorodnih jekel za poboljšanje, ki so bile dobljene po tangentni metodi na osnovi rezultatov, dobljenih iz torzijskih preizkusov [16-17].

Primerjavo odvisnosti maksimalne napetosti tečenja od temperature, med izračunanimi in izmerjenimi vrednostmi za tri različne hitrosti deformacije, prikazuje slika 8a. Na sliki 8b pa je podana primerjava med izračunanimi in izmerjenimi maksimalnimi napetostmi tečenja. Iz obeh slik je razvidno, da za obravnavano jeklo izbrana empirična enačba 8 odlično opiše zvezo med hitrostjo deformacije, temperaturo in maksimalno napetostjo tečenja.

Kemična sestava jekel od šarže do šarže, čeprav v dovoljenih mejah, stalno niha. Vpliv kemične sestave (posebno karbidotvornih

elementov) na napetost tečenja avtorji pri njihovem napovedovanju rešujejo z vpeljavo ogljikovega ekvivalenta, saj pri uporabi BP nevronske mreže veliko število vhodnih vplivnih parametrov vpliva na natančnost napovedovanja. V primeru uporabe CAE nevronske mreže pa teh težav nimamo, saj lahko uporabimo poljubno število vhodnih parametrov, torej lahko upoštevamo tudi vsak legirni element posebej [24-25].

Pri uporabi običajnih BP nevronske mreže moramo najprej določiti optimalno arhitekturo nevronske mreže, t.j. določiti število plasti in število nevronov v teh plasteh, saj doslej še ni jasnih navodil za izbiro teh parametrov. Pri uporabi CAE nevronske mreže imamo fiksno število skritih plasti, število nevronov v plasti pa je odvisno od števila modelnih vektorjev. Inženir se lahko posveti modeliranju pojava in ne izgublja časa z določanjem abstraktnih parametrov nevronske mreže. Bistvena prednost CAE metode v prikazanem primeru je enostavnost in relativno dobra natančnost predlaganih modelov. Pomembno dejstvo, ki dodatno opravičuje uporabo CAE nevronske



Slika 8. Primerjava med izmerjeno in izračunano odvisnostjo maksimalne napetosti tečenja od temperature za tri različne hitrosti $0,1 \text{ s}^{-1}$, 1 s^{-1} , 8 s^{-1} (a.) in primerjava med izmerjenimi in izračunanimi maksimalnimi napetostmi (b.).

mrež je, da se parametri med preizkusom spreminjajo; CAE nevronske mreže so namreč na osnovi tako dobljene baze podatkov sposobne določiti realne krivulje tečenja pri konstantnih pogojih.

V obravnavanem primeru so bile pri meritvah upoštevane samo tri različne hitrosti deformacij. Znano je, da je mogoče skozi tri točke v najboljšem primeru napeljati kvadratno krivuljo oz. polinom drugega reda, ki opisuje pojav. Brez vnaprej znane zakonitosti, ki bi jo upoštevali v CAE modelu, je opisovanje pojava v smeri hitrosti deformacij relativno slabo. Predvidevamo, da bomo v prihodnjih raziskavah CAE metodo lahko dopolnili tako, da bo v primeru premajhnega števila podatkov za katerikoli vhodni parameter pojava (v opisanem primeru hitrosti deformacije) mogoče upoštevati vnaprej predpostavljeno oz. poznano zakonitost. To dejstvo se namreč s pridom izkorišča pri optimizaciji experimentalnega dela, težje pa ga je upoštevati v matematičnih modelih krivulj tečenja brez a-priori predpostavk.

5. ZAKLJUČKI

Za potrebe optimiranja tehnologije toplega preoblikovanja jekla za poboljšanje CF53, namenjenega predvsem za strojne dele, ki so lahko izpostavljeni visokim mehanskim obremenitvam, smo na Gleeble 1500 izvedli tople stiskalne preizkuse. Temperaturno,

deformacijsko in hitrostno deformacijsko območje ustreza območju toplega valjanja. Preizkusili smo metodo napovedovanja krivulj tečenja s pomočjo umetne inteligence (CAE NN). Oblike krivulj tečenja kažejo na procese dinamične rekristalizacije med toplo deformacijo.

Študija je potrdila odlično napovedno sposobnost CAE nevronske mreže za napovedovanje krivulj tečenja. Pri tem smo uporabili dva pristopa in sicer metodo konstantnega parametra gladkosti ter metodo nekonstantnega parametra gladkosti. Slednji daje boljše rezultate predvsem zaradi boljše sposobnosti modeliranja fizikalnih zakonitosti v področjih velikih gradientov. Dosežene natančnosti so praktično znotraj območja 5 %, v povprečju znaša napaka 3 %. Pri uporabi CAE nevronske mreže ne potrebujemo določevanja optimalne arhitekture plasti mreže, s »poskus-napaka« postopkom pa enostavno določamo optimalne vrednosti parametra gladkosti pri razpoložljivi bazi podatkov. Postopek napovedovanja z CAE NN je enostavnejši v primerjavi BP NN, natančnost napovedovanja pa je na isti ravni. Izračunali smo tudi aktivacijsko energijo za CF53, ki znaša $Q = 316,86 \text{ kJ mol}^{-1}$.

Zahvala

Avtorji se zahvaljujejo Unior-u Zreče za izdelavo vzorcev.

LITERATURA

- [1] KOOP, R., LUCE, R., LEISTEN, B., WOLSKÉ, M., TSCHIRNICH, M., REHRMANN, T., VOLLES, R., (2001): Flow stress measuring by use of cylindrical compression test and special application to meta forming processes, *Steel Research*, 72, 394-401.
- [2] SCHOTEN, K., BLECK, W., DAHL, W. (1998): Modelling of flow curves for hot deformation, *Steel Research*, 69, 193-197.
- [3] KUGLER, G., TURK, R. (2004): Modeling the dynamic recrystallization under multi-stage hot deformation, *Acta Materialia*, 52/16, 4659-4668.
- [4] LIU, J., CHANG, H., HSU, T.Y., RUAN, X. (2000): Prediction of the flow stress of high speed steel during hot deformation using a BP artificial neural network, *Journal of Materials Processing Technology*, 103, 200-205.
- [5] HATA, N., KAKADO, J.I., KIKUCHI, S., TAKUDA, H. (1985): Modelling on flow stress of plain carbon steel at elevated temperatures, *Steel research*, 56/11, 575-582.
- [6] RAO, K.P., HAWBOLT, E.B. (1992): Development of constitutive relationships using compression testing of medium carbon steel, *Trans. ASME* 114, 116-123.
- [7] KLIBER, J., SCHINDLER, I. (1997): Mathematical description of stress-strain curve in metal forming processes, *Metalurgija*, 36/1, 9-13.
- [8] DAVENPORT, S.B., SILK, N.J., SPARKS, C.N., SELLARS, C.M., (2000): Development of constitutive equations for modelling of hot rolling, *Materials Science and Technology*, 16, 539-546.
- [9] LIU, J., CHANG, H., WU, R., HSU, T.Y., RUAN, X. (2000): Investigation on hot deformation behaviour of AISI T1 high-speed steel, *Materials characterization*, 45, 175-186.
- [10] MCQUEEN, H.J., RYAN, N.D. (2002): Constitutive analysis in hot working, *Materials Science and Engineering A*, 322, 43-63.
- [11] PHANIRAJ, M.P., LAHIRI, A.K. (2003): The applicability of neural network to predict flow stress for carbon steels, *Journal of Materials Processing Technology*, 141, 219-227.
- [12] RAO, K.P., PRASAD, Y.K.D.V. (1995): Neural network approach to flow stress evaluation in hot deformation, *Journal of Materials Processing Technology*, 53, 552-566.
- [13] HODGSON, P.D., KONG, L.X., DAVIES, C.H.J. (1999): The prediction of the hot strength of steels with an integrated phenomenological and artificial neural network model, *Journal of Materials Processing Technology*, 87, 131-138.
- [14] KONG, L.X., HODGSON, P.D. (1999): The application of constitutive and artificial neural network model to predict the hot strength of steels, *ISIJ Int.* 39/10, 991-998.
- [15] CHENG, Y.W., TOBLER, R.L., FILLA, B.J., COAKLEY, K.J. (1999): Constitutive behaviour modeling of steels under hot rolling conditions, NIST Technical Note 1500-6, *Materials Reliability Series*, 39-49.
- [16] MCQUEEN, H.J., RYAN, N.D. (2002): Constitutive analysis in hot working, *Materials Science and Engineering A*, 322, 42-63.
- [17] MCQUEEN, H.J., YUE, S., RYAN, N.D., FRY, E. (1995): Hot working characteristics of steels in austenitic state, *Journal of Materials Processing Technology*, 53, 293-310.
- [18] GRABEC, I., SACHSE, W. (1997): Synergetics of Measurement, Prediction and Control. ISBN 3-540-57048-9, *Springer-Verlag*.
- [19] GRABEC, I. (1990): Self-Organization of Neurons Described by the Maximum-Entropy Principle. *Biol.Cybern*, 63, 403.
- [20] PERUŠ, I., FAJFAR, P., GRABEC, I. (1994): Prediction of the seismic capacity of RC structural walls by non-parametric multidimensional regression, *Earthquake Eng. Struct. Dyn.* 23, 1139-1155.
- [21] FAJFAR, P., PERUŠ, I. (1997): A non-parametric approach to attenuation relations. *Journal of Earthquake Engineering*, 1(2), 319.
- [22] PERUŠ, I., FAJFAR, P. (1997): A non-parametric approach for empirical modelling of engineering problems, *Engineering Modelling*, 10(1-4), 7.
- [23] KUGLER, G., KNAP, M., PALKOVSKI, H., TURK, R. (2004): Estimation of activation energy for calculating the hot workability properties of metals, *Metalurgia*, 43/4, 267-272.
- [24] TERČELJ, M., PERUŠ, I., TURK, R. (2003): Suitability of CAE neural network and FEM for predicting of wear on die radii in hot forging, *Tribology International*, 36, 573-583.
- [25] TURK, R., PERUŠ, I., TERČELJ, M. (2004): New starting points for prediction of tool wear in hot forging, *Int. J. of Machine Tools & Manufacture*, 44/12-13, 1319-1331.
- [26] SELLARS, C.M., MCG. TEGART, W.J. (1972): *Int. Metall. Rev.*, 17, 1-24.