

Hledání optimálních hodnot parametrů v modelech přirozeného deformačního odporu prostřednictvím umělých neuronových sítí a genetických algoritmů

Searching for Optimal Values of Parameters in Natural Flow Stress Models Utilizing Artificial Neural Networks and Genetic Algorithms

Ing. Petr Opěla, Ph.D.; prof. Ing. Ivo Schindler, CSc.; Ing. Petr Kawulok, Ph.D.; Ing. Rostislav Kawulok, Ph.D.; Ing. Stanislav Rusz, Ph.D.; Ing. Vojtěch Ševčák

VŠB – Technická univerzita Ostrava, Fakulta materiálově-technologická, Regionální materiálově technologické výzkumné centrum, 17. listopadu 2172/15, 708 00 Ostrava-Poruba, Česká republika

Počítačové simulace tvářecích procesů vyžadují mimo jiné i znalost vývoje přirozeného deformačního odporu (PDO) tvářeného materiálu v závislosti na udílené deformaci, teplotě a deformační rychlosti. Uvedené závislosti (stanovené experimentálně) jsou často popisovány matematickými modely, které sestávají z pomocných proměnných (parametrů) závislých na teplotách a deformačních rychlostech. Přesnost jejich popisu tedy ovlivňuje přesnost výsledných modelů. Možnosti popisu těchto parametrů s využitím tzv. inteligentních algoritmů jsou předmětem předkládané práce. Popisováno bylo celkem pět parametrů, jež jsou součástí dvou modelů PDO. Jejich popis byl v první řadě realizován jedním prediktivním vztahem, jehož konstanty byly vždy pro konkrétní parametr stanoveny s využitím genetických algoritmů. V druhé řadě byl popis realizován s nasazením vícevrstevných dopředných umělých neuronových sítí se zpětným šířením chybového signálu. Grafické a statistické srovnání ukazuje na vyšší přesnost popisu při využití neuronových sítí, což lze připsat jejich větší univerzálnosti.

Klíčová slova: přirozený deformační odpor; umělé neuronové sítě; genetické algoritmy

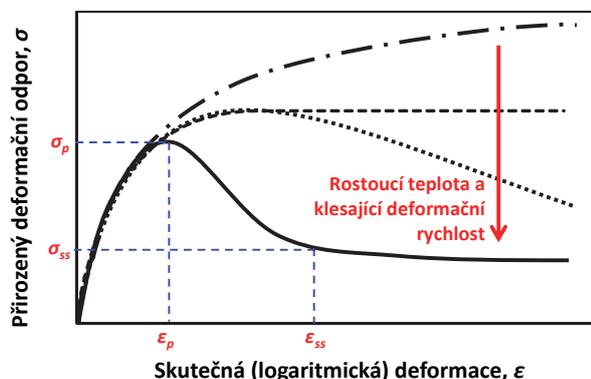
Bulk-forming processes (e.g., rolling, forging, etc.) are accompanied by the response of formed material against forming load – this response is known as flow stress. So-called natural flow stress is then a key material characteristic – it is used for instance at numerical simulations of given forming process (performed by finite element methods). The natural flow stress is influenced by the level of strain, strain rate, and temperature. These dependencies are experimentally obtained by e.g., uniaxial compression or torsion tests. For future computer treatment of the obtained data, it is appropriate to describe them mathematically. This description is usually performed by the so-called flow stress models. Unfortunately, the dependence of the natural flow stress on the strain, strain rate, and temperature can be very complicated; especially in the case of hot forming processes. That's the reason why the flow stress models usually contain auxiliary variables – parameters, which are firstly described in relation to temperature and strain rate and only then inserted into the flow stress models. So, it is clear, that the prediction capability of these models is directly connected with the accuracy of description of their parameters. Possibilities of the description of these parameters by use of so-called intelligent algorithms are the subject of this paper. The investigation was realized on the five parameters, which were the part of two flow stress models. The one predictive relationship firstly described experimental values of these parameters. The unique constants of this relation were for each parameter determined by the use of genetic algorithms. As the second approach, multi-layer feed-forward artificial neural networks with the back propagation learning algorithm were employed to describe these parameters. Graphical and statistical results have shown that the utilizing the artificial neural network approach allows the attainment of higher prediction capability.

Key words: natural flow stress; artificial neural networks; genetic algorithms

Procesy objemového (hutnického) tváření (např. válcování, kování, tažení) jsou doprovázeny odezvou tvářeného materiálu na působení tvářecích sil – tzv. deformační odpor. Deformační chování daného materiálu (např. ocel, hliníková slitina o konkrétním chemickém složení) lze definovat tzv. přirozeným deformačním odporem (PDO), jenž je určován za jednoosého stavu napjatosti. Je to materiálová charakteristika, jejíž velikost je závislá na termomechanických podmínkách (teplota deformace, deformační rychlost a velikost deformace). Uvedenou závislost lze vyjádřit graficky pomocí tzv. napětových

křivek. Různé průběhy těchto křivek (tvarová různorodost vyskytující se často i v rámci jednoho materiálu) jsou schematicky znázorněny na obr. 1 [1]. Znalost vývoje PDO zkoumaného materiálu v závislosti na uvedených termomechanických podmínkách je základem pro numerické simulace tvářecích procesů (realizovaných např. s využitím MKP – metody konečných prvků) [2, 3]. Pro nově zaváděný materiál je závislost PDO na výše zmíněných termomechanických podmínkách určována v první řadě experimentálně, především jednoosými zkouškami tlakem, zkouškami krutem. Zmíněné zkoušky jsou

realizovány vždy jen pro určité teploty a deformační rychlosti z rozsahu pokrývajícího předpokládaný interval tvářecích podmínek. Za účelem pozdější predikce PDO i pro další kombinace termomechanických podmínek (např. pro potřeby MKP simulací) je nezbytné experimentálně získané napěťové křivky matematicky popsat. Pro potřeby tohoto popisu bylo navrženo mnoho matematických modelů [2].



Obr. 1 Schématické znázornění různých typů napěťových křivek [1]
Fig. 1 Schematic representation of different types of flow curves [1]

Vzhledem k tvarové různorodosti popisovaných napěťových křivek (obr. 1) je převážná část těchto modelů založená na využívání různých pomocných proměnných (parametrů), které umožňují popis rozdělit na jednodušší kroky. Nejčastěji používanými parametry jsou souřadnice maximálního deformačního odporu (napěťového píku – ϵ_p , σ_p), či souřadnice počátku tzv. ustáleného plastického toku – ϵ_{ss} , σ_{ss} , jak je opět patrné z obr. 1. Tyto a další parametry se každý zvlášť popisují v závislosti na teplotě a deformační rychlosti. Teprve pak jsou vkládány do modelů PDO. Přesný popis těchto parametrů tedy hraje klíčovou roli při dosažení precizního celkového popisu napěťových křivek [4].

Parametry modelů PDO jsou nejčastěji popisovány různými, již dříve odvozenými prediktivními vztahy, jež vyjadřují fixní a praxí prověřenou závislost konkrétního parametru na teplotě a deformační rychlosti. Popis pro daný materiál pak sestává z vyčíslení materiálových konstant. U jednodušších vztahů (např. mocninných) lze tyto konstanty snadno získat lineární regresí, jež umožňuje dosažení minima kritériální funkce (např. střední kvadratické odchylky) analytickou cestou [5]. Složitější vztahy však vyžadují nasazení některé z numerických metod. Minimalizace kritériální funkce je pak často realizována prostřednictvím gradientních algoritmů [6]. Progresivní způsob hledání optimálních materiálových konstant nabízí i stále diskutovanější genetické algoritmy (GA) [7]. Velmi slibnou alternativou ke klasickým prediktivním vztahům představují tzv. umělé neuronové sítě (UNS), které nejsou omezeny pevně stanovenou závislostí mezi proměnnými [7 – 9].

Předmětem předkládané práce je vyzkoušet na sadě experimentálních napěťových křivek oceli C45 popis parametrů dvou modelů PDO s nasazením inteligentních algoritmů. Diskutované parametry jsou v první řadě

popisány pomocí běžného prediktivního vztahu, jehož materiálové konstanty jsou vyčísleny s využitím genetických algoritmů. V druhé řadě je popis realizován s nasazením umělých neuronových sítí. Cílem je porovnat oba přístupy s ohledem na celkovou přesnost popisu sady napěťových křivek, která byla pořízena v širokém intervalu termomechanických podmínek, a tudíž vykazuje i značnou tvarovou rozmanitost, jak je schématicky znázorněno na obr. 1.

1. Experimentální data

Pro účely předložené práce byla zvolena sada dvaceti experimentálních napěťových křivek oceli C45. Tuto sadu se podařilo sestavit s využitím experimentálně naměřených dat ze série jednoosých zkoušek tlakem za tepla realizovaných na simulátoru deformací HDS-20. Zkoušky tlakem byly provedeny pro dvacet kombinací teplot a deformačních rychlostí. Teploty deformace: 1173, 1273, 1373, 1473 a 1553 K; deformační rychlosti: 0,1; 1; 10 a 100 s⁻¹. Každý test byl realizován v rozsahu hodnot skutečné deformace 0 až 1,0. Výsledkem každého testu je jedna napěťová křivka (tj. závislost $\sigma - \epsilon$), odpovídající jedné kombinaci teploty a deformační rychlosti. Experimentální práce byly již dříve detailně diskutovány v [10].

2. Popis deformačního odporu za tepla

2.1 Modely přirozeného deformačního odporu

K vyjádření napěťových křivek za tepla, popisujících vývoj PDO v závislosti na aplikovaných termomechanických podmínkách lze využít celou řadu matematických modelů [2, 11]. A. Cingara a H. J. McQueen (1992) [12] navrhli model pro precizní popis napěťových křivek za tepla, platný pro rozsah skutečné deformace $\epsilon = \langle 0, \epsilon_p \rangle$, jak vyjadřuje vztah (1). Modifikací tohoto modelu [13] bylo možno získat vztah umožňující popis pro deformace $\epsilon \geq \epsilon_p$ podle rov. (2):

$$\sigma = \sigma_p \cdot \left[\frac{\epsilon}{\epsilon_p} \cdot \exp \left(1 - \frac{\epsilon}{\epsilon_p} \right) \right]^c, \quad (1)$$

$$\sigma = \sigma_{ss} + (\sigma_p - \sigma_{ss}) \cdot \left[\frac{\epsilon}{\epsilon_p} \cdot \exp \left(1 - \frac{\epsilon}{\epsilon_p} \right) \right]^s. \quad (2)$$

Proměnná σ (MPa) reprezentuje přirozený deformační odpor (PDO) a ϵ (-) skutečnou čili logaritmickou-deformaci. Dolní index p označuje koordináty maximálního deformačního odporu (napěťového píku). Dolní index ss označuje souřadnice odpovídající počátku ustáleného plastického toku (Steady-State), jak jej názorně ukazuje obr. 1. Parametry c (-) a s (-) představují exponent deformačního zpevnění, respektive odpevnění [12, 13].

2.2 Experimentální hodnoty parametrů modelů PDO

Výše uvedené modely PDO podle rov. (1) a (2) zahrnují dohromady pět parametrů (ϵ_p , σ_p , σ_{ss} , c , s), které je potřeba

matematicky popsat v závislosti na teplotě deformace a deformační rychlosti. Prvním krokem je stanovení experimentálních hodnot těchto parametrů pro testované kombinace termomechanických podmínek.

Z experimentálních grafických závislostí (napětových křivek) lze pro každou kombinaci teploty a deformační rychlosti stanovit maximální hodnotu PDO (tj. σ_p) a jí odpovídající hodnotu deformace (tj. ε_p). Z některých křivek lze odečíst i hodnotu PDO na ustáleném plastickém toku (tj. σ_{ss}). Ke stanovení všech těchto parametrů se využívají napětové křivky schematicky znázorněné na obr. 1. Experimentální hodnoty exponentů c a s lze pro každou kombinaci teploty a deformační rychlosti stanovit lineární regresí z logaritmického vyjádření rov. (1), tedy $\ln(\sigma/\sigma_p)$ vs. $\ln(\varepsilon/\varepsilon_p) + 1 - \varepsilon/\varepsilon_p$ [12], respektive rov. (2), tedy $\ln[(\sigma - \sigma_{ss})/(\sigma_p - \sigma_{ss})]$ vs. $\ln(\varepsilon/\varepsilon_p) + 1 - \varepsilon/\varepsilon_p$ [13].

2.3 Popis parametrů modelů PDO s nasazením genetických algoritmů

Genetické algoritmy (GA) spadají do skupiny heuristických evolučních algoritmů [14, 15]. Vycházejí z teorie přirozeného výběru a principů genetiky formulovaných Ch. Darwinem (1859) [16]. Samotný algoritmus byl formulován J. H. Hollandem (1975) [17].

V rámci předložené práce byly genetické algoritmy využity pro nalezení optimálního řešení jednoho z prediktivních vztahů, umožňujících popis parametrů ve výše uvedených modelech PDO. Tento vztah lze vyjádřit následujícím funkčním předpisem [13]:

$$y_i(\dot{\varepsilon}, T, p) = p_1 \cdot \dot{\varepsilon}_i^{\left(p_2 - p_3 \frac{1}{T_i}\right)} \cdot \exp(-p_4 \cdot T_i) \quad (3)$$

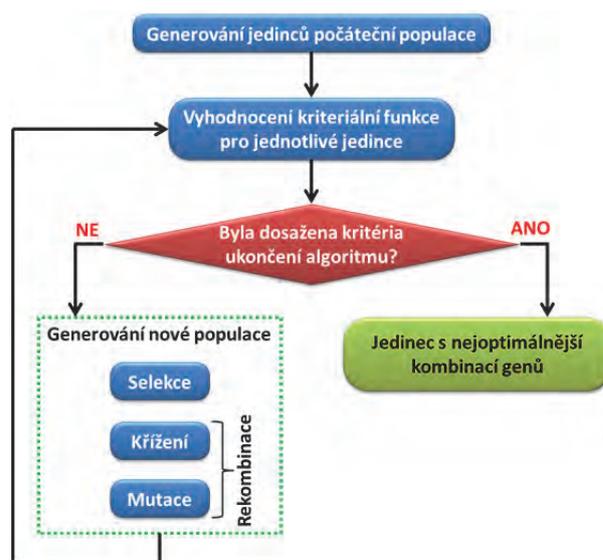
V rov. (3) představuje $y_i(\dot{\varepsilon}, T, p)$ predikovanou hodnotu sledovaného parametru modelu PDO (tj. ε_p , σ_p , σ_{ss} , c či s) pro i -tou kombinaci teploty T_i (K) a deformační rychlosti $\dot{\varepsilon}_i$ (s^{-1}). Tato rovnice byla vybrána z důvodu své přesnosti a univerzálnosti popisu. Umožňuje přesně popsat všechny výše uvedené parametry [13]. Mnohdy jsou pro popis uvedených parametrů využívány různé vztahy, např. mocninový pro popis ε_p či inverzní sinus-hyperbolický pro popis σ_p [4]. Značná nejednotnost popisu panuje především při popisu exponentů zpevnění a odpevnění. Dle rov. (3) se pro každý parametr modelu PDO nalézají vhodné hodnoty materiálových konstant p_1 (různé), p_2 (-), p_3 (K) a p_4 (K^{-1}) [13]. Řešení spočívá v minimalizaci tzv. kritériální (fitness) funkce, zde vyjádřené prostřednictvím střední kvadratické odchylky δ [18]. V našem případě tedy hledáme následující minimum:

$$\min_p \delta = \frac{1}{n} \cdot \sum_{i=1}^n \left[p_1 \cdot \dot{\varepsilon}_i^{\left(p_2 - p_3 \frac{1}{T_i}\right)} \cdot \exp(-p_4 \cdot T_i) - y_i \right]^2 \quad (4)$$

V rov. (4) y_i představuje i -tou experimentální hodnotu sledovaného parametru modelu PDO, kde $i = \{1, n\}$ je i -tá kombinace teploty a deformační rychlosti ($n = 20$).

Průběh minimalizace kritériální funkce δ prostřednictvím genetického algoritmu je schematicky vyobrazen na obr. 2.

V první fázi GA dochází k inicializaci prvotní populace. Populací je zde myšlena množina předem definovaného počtu jedinců (tab. 1). Jedinec je na základě analogie s biologickou předlohou reprezentován sadou chromosomů (tvořených geny), udávajících genom jedince. Konkrétní sada genů obsažená v genomu poskytuje genotyp (obecnou genetickou informaci). V našem případě je genom každého jedince reprezentován pouze jedním chromosomem. Hovoří se pak o tzv. haploidním jedinci. Chromosom každého jedince je tvořen čtyřmi geny, jejichž alely (hodnoty) odpovídají hodnotám hledaných materiálových konstant rov. (3), potažmo (4), tedy p_1 , p_2 , p_3 a p_4 . Každý jedinec v populaci proto představuje potenciální řešení zadaného problému – v našem případě minimalizace funkce δ (4). Každá populace tedy vždy reprezentuje určitý počet prvků ze stavového prostoru (prostoru možných řešení). U první generace (aktuální populace) mohou být jedinci generováni buď náhodně, nebo lze využít hrubého odhadu např. z předchozího modelování [14, 15, 19, 20]. Druhý způsob je výhodnější varianta.



Obr. 2 Schématické znázornění průběhu genetického algoritmu [7]

Fig. 2 Schematic representation of genetic algorithm course [7]

Ve druhé fázi je každému jedinci přiřazena na základě funkce δ hodnota fitness, tj. dochází k ohodnocení jedinců dané populace. V tomto případě je úkolem GA minimalizovat funkci v rov. δ (4). Z toho vyplývá, že nejlepšího hodnocení dosahují ti jedinci, jejichž kombinace genů vrací nižší δ -hodnoty [14, 15, 19, 20].

Ve třetí fázi dochází k vyhodnocení kritérií možného ukončení algoritmu. Příčinou ukončení může být např. nalezení jedince s hodnotou fitness menší nebo rovnou hodnotě požadované, dosažení maximálního počtu generací (iterací) či maximálního výpočtového času [14, 15, 19, 20].

Za předpokladu, že ani jedna z podmínek ukončení algoritmu nebyla dosažena, dochází ke vzniku nové generace jedinců. Tvorba nových generací slouží k dalšímu prohledávání stavového prostoru s cílem nalézt optimálnější řešení. Vzhledem k velkým rozměrům stavového prostoru však není ve většině případů možné tento celý prostor prohledat a vyhodnotit. Z tohoto důvodu se tvorba nových generací řídí následujícím, evolucí motivovaným postupem, umožňujícím prohledávat relevantní oblasti stavového prostoru [14, 15, 19, 20].

Prvním krokem při tvorbě nové generace je tzv. selekce, tedy výběr jedinců z předchozí generace (rodiče), kteří se budou podílet na vzniku generace nové. V souladu s Darwinovou teorií evoluce dochází k napodobování tzv. přirozeného výběru, kdy jsou upřednostňováni ti jedinci, jejichž vlastnosti jim umožňují nejlépe se přizpůsobit danému prostředí (tzn., mají vhodný fenotyp). V našem případě se jedná o jedince s nižší hodnotou kritériální funkce δ . Přílišné upřednostňování nejlepších jedinců (tzv. velký selekční tlak) však nemusí nutně vést ke vzniku kvalitnější generace, a to z důvodu rizika uvíznutí kritériální funkce v lokálním minimu. Je tedy potřeba zajistit výběr i dostatečného množství slabších jedinců, protože i tito jedinci potencionálně mohou obsahovat genetickou informaci důležitou pro nalezení vhodného řešení. Pro výběr vhodných jedinců existuje hned několik metod (např. ruletová selekce, pořadová selekce či turnajový výběr) [14, 15, 19, 20].

Po selekci následuje tzv. rekombinace, sestávající ze dvou operací: křížení a mutace. Křížení spočívá ve výměně informací (genů) mezi dvěma jedinci (rodiči) vybranými na základě předchozí operace selekce z předchozí generace. Vznikají tak jedinci generace nové. Část jedinců předchozí generace (tzv. elitní jedinci) přecházejí do nové generace přímo, a to čistě na základě nejvyšší vhodnosti. Křížení však nevnáší do populace žádnou novou genetickou informaci. Pro účely obohacení stávajícího genofondu je proto využívána mutace, která spočívá v náhodné změně alely některého genu. Tato nová genetická informace má za úkol zabránit uvíznutí algoritmu v lokálním minimu. Zmutovaný jedinec se totiž vyskytuje mimo doposud prohledávanou část stavového prostoru. Dochází tak k rozšíření prozkoumávané oblasti možných řešení s cílem dosažení globálního minima kritériální funkce [14, 15, 19, 20].

Stejně jako u předchozí generace, jsou i jedinci nové generace ohodnoceni (je jim přiřazena hodnota fitness). Následně opět dochází k vyhodnocení kritérií možného ukončení algoritmu. Dokud není dosaženo některého z ukončovacích kritérií, dochází ad infinitum ke vzniku stále nových generací [14, 15, 19, 20].

Tab. 1 zahrnuje specifikace genetického algoritmu, použité při řešení našeho minimalizačního problému.

Optimální hodnoty materiálových konstant rov. (3), získané výše uvedeným GA přístupem, jsou pro sledovanou ocel C45 uvedeny zaokrouhleně v tab. 2. Řešení GA pro optimalizaci parametrů při stanovení PDO bylo

realizováno s použitím softwaru GNU Octave-4.2.1 [21] s nadstavbovým nástrojem GA Package [22].

Tab. 1 Specifikace genetického algoritmu
Tab. 1 Genetic algorithm specifications

Parametr GA	Nastavení
Kritériální funkce	sřední kvadratická odchylka
Maximální počet generací	400
Velikost populace	50
Počet genů jedince	4
Počet elitních jedinců	2
Podíl populace pro křížení	0,8

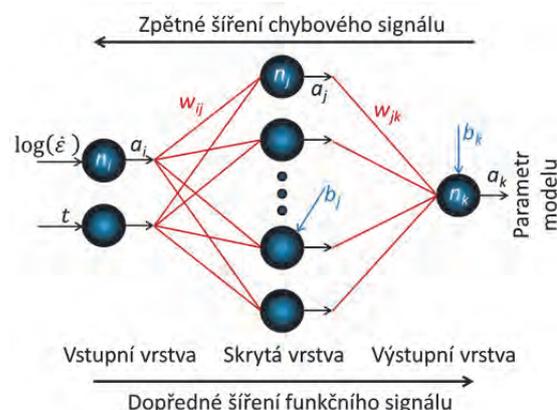
Tab. 2 Materiálové konstanty rov. (3) získané GA přístupem
Tab. 2 Material constants of eq. (3) by GA approach

y	p_1 (různé)	p_2 (-)	p_3 (K)	p_4 (K ⁻¹)
ε_p	8,8	0,6	582	$2,4 \cdot 10^{-3}$
σ_p	$11,8 \cdot 10^3$	0,5	429	$3,7 \cdot 10^{-3}$
σ_{ss}	$14,2 \cdot 10^3$	0,5	449	$3,9 \cdot 10^{-3}$
c	$2,2 \cdot 10^{-2}$	-0,2	83	$-2,0 \cdot 10^{-3}$
s	0,5	$-2,3 \cdot 10^{-2}$	-219	$-1,7 \cdot 10^{-3}$

2.4 Popis parametrů modelů PDO s nasazením umělých neuronových sítí

Obdobně, jako výše diskutované genetické algoritmy se i umělé neuronové sítě (UNS) řadí mezi matematické přístupy inspirované biologií, konkrétně procesy zpracovávání informací v neuronové síti lidského mozku, jak je popsal H. Spencer (1872) [23]. Matematický model biologického neuronu byl prvně formulován W. S. McCullochem a W. H. Pittsem (1943) [24].

Pro potřeby popisu výše diskutovaných parametrů modelů PDO (v závislosti na teplotě a deformační rychlosti) byla využita tzv. vícevrstvá dopředná umělá perceptronová síť se zpětným šířením chybového signálu [7]; perceptron je zobecněný model neuronu navržený F. Rosenblattem (1958) [25].



Obr. 3 Schématické znázornění architektury třívrstvé dopředné umělé neuronové sítě [26]

Fig. 3 Schematic illustration of the three-layer feed-forward artificial neural network architecture [26]

Obecná architektura (topologie) UNS byla pro řešení dané problematiky (tj. pro parametry modelů PDO oceli C45) navržena již v [26]. Schematicky je zachycena na obr. 3. Vstupní vektory nezávisle proměnných (tj. teploty a deformační rychlosti) jsou propojeny s vektorem závisle proměnné (tj. popisovaným parametrem modelu PDO) skrze sadu umělých neuronů uspořádaných do tří vrstev. Neuronů jsou mezi jednotlivými vrstvami propojeny pomocí tzv. synaptických vah (w_{ij} , w_{jk}).

Popis, potažmo predikci sledovaného parametru modelu PDO lze v případě navržené UNS (obr. 3) matematicky vyjádřit následujícími vztahy (označováno jako dopředné šíření funkčního signálu) [27]:

$$a_i = n_i, \quad (5)$$

$$n_j = \sum_{i=1}^I (w_{ij} \cdot a_i) + b_j, \quad (6)$$

$$a_j = \varphi(n_j), \quad (7)$$

$$n_k = \sum_{j=1}^J (w_{jk} \cdot a_j) + b_k, \quad (8)$$

$$a_k = \psi(n_k). \quad (9)$$

Každá vrstva obsahuje specifický počet neuronů: vstupní vrstva $i = \langle 1, I \rangle$, skrytá vrstva $j = \langle 1, J \rangle$ a výstupní vrstva $k = \langle 1, K \rangle$. Hodnota $I = 2$ (odpovídá počtu vstupních vektorů). Hodnota $K = 1$ (odpovídá počtu výstupních vektorů). Hodnota J je určována ad hoc v závislosti na povaze popisovaných dat. Konstanty w_{ij} a w_{jk} reprezentují synaptické váhy spojující i -tý neuron vstupní vrstvy s j -tým neuronem skryté vrstvy a j -tý neuron skryté vrstvy s k -tým neuronem vrstvy výstupní. Konstanty b_j a b_k představují prahové hodnoty j -tého neuronu skryté vrstvy a k -tého neuronu vrstvy výstupní. Proměnné n_i , n_j a n_k reprezentují vektory vnitřního potenciálu (vážené sumy) i -tého neuronu vstupní vrstvy, j -tého neuronu skryté vrstvy a k -tého neuronu výstupní vrstvy. Proměnné a_i , a_j , a_k představují výstupní vektory z i -tého, j -tého a k -tého neuronu vstupní, skryté a výstupní vrstvy, které jsou získávány aktivací vnitřních potenciálů jednotlivých neuronů na základě aktivačních (přenosových) funkcí (φ pro skrytou vrstvu a ψ pro vrstvu výstupní) [27].

Navrženou neuronovou síť je potřeba tzv. adaptovat [28], tj. určit optimální hodnoty synaptických vah a prahů (w_{ij} , w_{jk} , b_j a b_k) tak, aby síť vracela hodnoty sledovaného parametru s co nejnižší odchylkou od experimentálních dat. To se nazývá také jako proces učení. Adaptace spočívá v minimalizaci kritériální funkce vyjádřené střední kvadratickou odchylkou δ [18]:

$$\min_{w,b} \delta = \frac{1}{n} \cdot \sum_{i=1}^n (r_i)^2. \quad (10)$$

V rov. (10), r_i udává i -tou hodnotu vektoru residuí na výstupu neuronové sítě. Minimalizace odchylky δ v rov. (10) byla provedena s využitím gradientního algoritmu navrženého K. Levenbergem [29], modifikovaného D. W. Marquardtem (metoda LM) [30], jejichž závěry shrnuje také [6]. Vzhledem ke složitě

matematické struktury vícevrstvé neuronové sítě byl aplikovaný algoritmus minimalizace kombinován s tzv. zpětným šířením chybového signálu (metoda Back-Propagation BP) [31, 32]. Tento způsob umožňuje výpočet vektoru residuí na neuronech skryté vrstvy (nutné pro adaptaci vah w_{ij} a prahů b_j). Určitou alternativu procesu učení UNS představuje i výše diskutovaná minimalizace metodou GA; metoda BP s LM algoritmem je však běžnější [7, 8, 27].

Proces adaptace UNS vyžaduje rozdělení datového souboru na tři množiny: trénovací (vzory pro učení), validační (ověření odezvy sítě během učení) a testovací (ověření predikční kapacity sítě) [33]. Trénovací množina obsahuje 12 kombinací teplot a deformačních rychlostí (tj. 60 % datových bodů): 1553 K (0,1; 100 s⁻¹); 1473 K (1; 10; 100 s⁻¹); 1373 K (0,1; 10 s⁻¹); 1273 K (1; 10 s⁻¹); 1173 K (0,1; 1; 100 s⁻¹). Validační množina obsahuje 4 kombinace (tj. 20 % datových bodů): 1553 K (1 s⁻¹); 1373 K (100 s⁻¹); 1273 K (0,1 s⁻¹); 1173 K (10 s⁻¹). Testovací množina obsahuje 4 kombinace (tj. 20 % datových bodů): 1553 K (10 s⁻¹); 1473 K (0,1 s⁻¹); 1373 K (1 s⁻¹); 1273 K (100 s⁻¹) [26].

Vektory vstupních proměnných (tj. teploty a logaritmu deformační rychlosti) vykazují rozdílnou distribuci dat a rozměry. Tento fakt snižuje rychlost konvergence a přesnost predikce. Z tohoto důvodu byly tyto vstupní vektory normalizovány, jak o tom detailně pojednává [26].

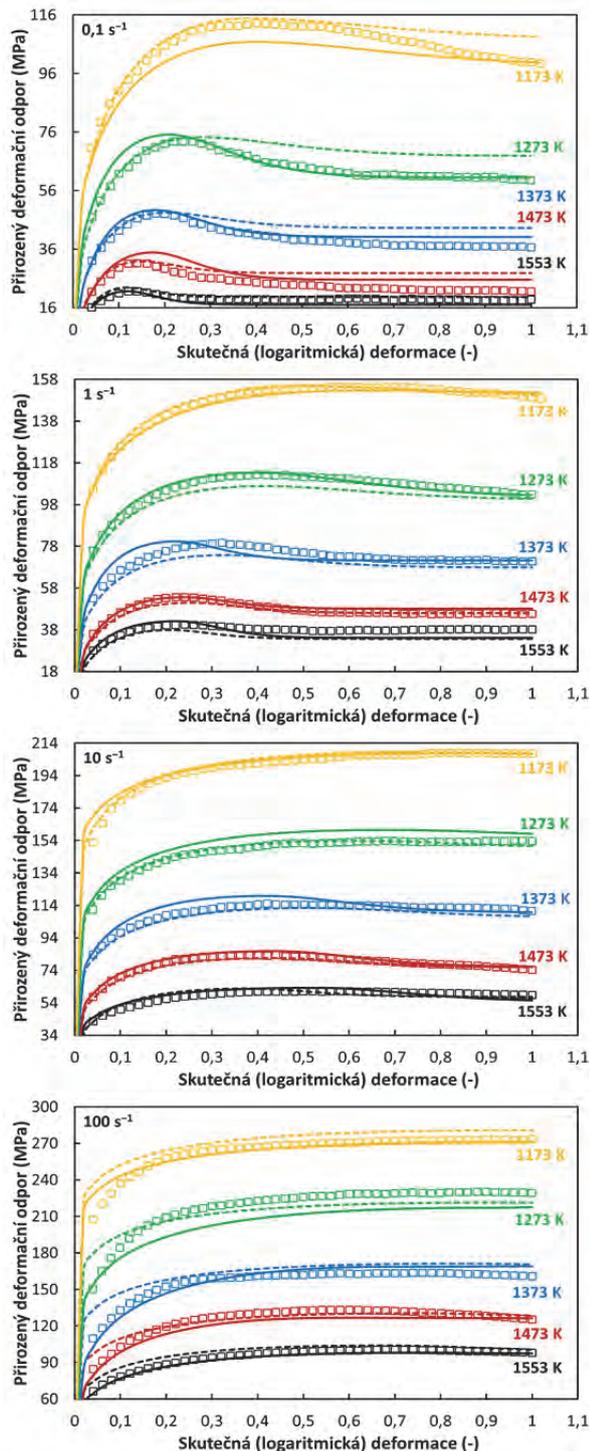
Optimální počet neuronů ve skryté vrstvě je určován na základě výsledků, které jsou vraceny různými architekturami UNS. Optimální počet skrytých neuronů UNS, stanovený pro jednotlivé parametry modelů PDO, je následující: ε_p (5), σ_p (3), σ_{ss} (3), c (8), s (6) [26]. Obecné parametry využití architektury UNS shrnuje tab. 3. Sestavení a adaptace výše uvedených UNS bylo provedeno v softwaru GNU Octave-4.2.1 [21] s využitím balíčku nástrojů Neural Network Package [34].

Tab. 3 Specifikace architektury aplikovaných neuronových sítí [26]
Tab. 3 Architecture specifications of the applied neural networks [26]

Parametr UNS	Nastavení
Typ UNS	vícevrstvá
Šíření funkčního signálu	dopředné
Typ učení (trénování) sítě	s učitelem
Metoda trénování	zpětná propagace chybového signálu
Kritériální funkce	střední kvadratická odchylka
Algoritmus minimalizace kritériální funkce	Levenberg-Marquardt
Přenosová funkce φ	hyperbolický tangens
Přenosová funkce ψ	lineární

3. Výsledky a diskuse

Hodnoty parametrů ε_p , σ_p , σ_{ss} , c , s stanovené metodami GA a UNS byly dosazeny do modelů PDO vyjádřených v rov. (1) a (2). Výsledné závislosti jsou graficky prezentovány na obr. 4.



Obr. 4 Experimentální a predikované napět'ové křivky oceli C45; čtverečky – experiment, plné křivky – umělé neuronové síť, přerušované křivky – genetické algoritmy

Fig. 4 Experimental and predicted flow curves of the C45 steel; squares – experiment, full lines – artificial neural networks, dashed lines – genetic algorithms

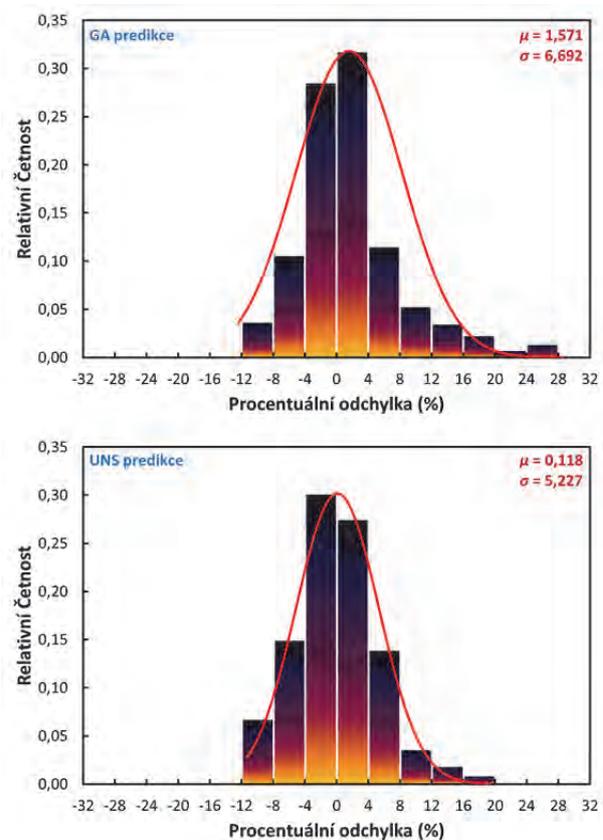
Porovnání výsledků získaných využitím obou metod ukazuje na jejich vysokou přesnost v popisu závislosti PDO oceli C45 na zvolených termomechanických parametrech deformace. U GA metody nicméně lze v porovnání s metodou UNS pozorovat určité nepřesnosti. Je to především o nadhodnocování velikosti PDO

v počáteční fázi napět'ových křivek u deformační rychlosti 100 s^{-1} .

Za účelem kvantifikace získaných výsledků bylo další hodnocení provedeno statisticky na základě relativní procentuální odchylky η (%) [8]:

$$\eta_i = \frac{y(x_i) - y_i}{y_i} \cdot 100. \quad (11)$$

Proměnná y_i (MPa) reprezentuje i -tou hodnotu vektoru experimentálně stanoveného přirozeného deformačního odporu, $y(x_i)$ odpovídá i -té hodnotě vektoru predikovaného. Proměnná η_i (%) odpovídá příslušné i -té hodnotě relativní procentuální odchylky. Distribuce η -odchylky je graficky zachycena na obr. 5. Výšky sloupců prezentovaných histogramů zde odpovídají relativní četnosti výskytu η -odchylky.



Obr. 5 Distribuce η -odchylky přirozeného deformačního odporu oceli C45

Fig. 5 Distribution of the η -value of the natural flow stress of the C45 steel

Z tohoto statistického srovnání je patrné, že η -odchylka stanovená pro metodu GA se pohybuje v širším intervalu (-12 % až 28 %), než odchylka pro UNS (-12 % až 20 %). Za účelem podrobnější analýzy byly dále pro η -odchylku stanoveny dva indikátory, a to její střední hodnota μ (%) a směrodatná odchylka σ (%) [35]:

$$\mu = \frac{1}{n} \cdot \sum_{i=1}^n \eta_i, \quad (12)$$

$$\sigma = \sqrt{\frac{1}{n} \cdot \sum_{i=1}^n (\eta_i - \mu)^2} \quad (13)$$

Oba indikátory jsou uvedeny na obr. 5. Vyšší přesnost popisu je dána hodnotou μ pohybující se blíže k nule a nižší hodnotou σ . Hodnota μ pro UNS je k nule blíže než u metody využívající GA. Také směrodatná odchylka σ je u UNS nižší než u metody GA. Porovnání středních hodnot a směrodatných odchylek u obou metod potvrzuje vyšší přesnost popisu metodou založenou na UNS. Důvodem vyšší přesnosti u metody využívající UNS je patrně její univerzální matematická struktura. Genetické algoritmy představují dosti robustní metodu pro stanovování optimálních hodnot konstant v prakticky jakémkoli funkčním předpisu. Určité omezení však představuje onen samotný funkční předpis. Jeho matematická struktura je pevně předepsána. Mění se pouze hodnoty konstant, jak se to provádí podle rov. (3) popisující parametry modelů pro PDO. Tento matematický vztah a jemu podobné pak nemusí vždy umožňovat správný popis ani při sebelepším stanovení příslušných konstant. Naproti tomu umělé neuronové sítě jsou charakteristické svou univerzální matematickou strukturou, jak je patrné z obr. 3 a rov. (5) až (9). Libovolně lze tedy měnit počet neuronů skryté vrstvy, popřípadě počet skrytých vrstev. Pro řešení každého problému by tedy mělo být možné nalézt vhodnou architekturu sítě, která v kombinaci s optimálními hodnotami synaptických vah a prahů (tj. po adaptaci) bude vracet velmi přesné výsledky.

Závěry

Předložená práce se zabývá možnostmi nasazení inteligentních algoritmů pro účely nalezení optimálních hodnot parametrů (pomocných proměnných) v modelech popisujících přirozený deformační odpor za tepla (PDO). Diskutovány jsou dva přístupy – přístup založený na genetických algoritmech a přístup využívající vícevrstvé dopředné umělé neuronové sítě se zpětným šířením chybového signálu. Výzkum byl realizován na sadě dvaceti napěťových křivek oceli C45, experimentálně sestavených na základě jednoosých zkoušek tlakem v intervalu teplot deformace 1173 až 1553 K a intervalu deformačních rychlostí 0,1 až 100 s⁻¹. Skutečné deformace dosahovaly hodnoty 1,0. Tyto křivky byly matematicky popsány dvěma modely PDO, které společně umožňují popis v širokém rozsahu deformací. Oba modely čítají dohromady pět parametrů, závislých na teplotě deformace a deformační rychlosti. Těmito parametry byly souřadnice napěťového píku, napětí na ustáleném plastickém toku a exponent zpevnění a odpevnění. Experimentální hodnoty těchto parametrů byly popsány s pomocí obou výše uvedených přístupů a následně dosazeny do modelů PDO. Predikované a experimentální hodnoty PDO byly porovnány graficky i statisticky. Výsledky ukázaly dobrou přesnost obou dvou přístupů. Vyšší přesnosti predikce dosahuje metoda založená na umělých neuronových sítích.

Poděkování

Tato práce vznikla při řešení projektu č. LO1203 "Regionální materiálově technologické výzkumné centrum - program udržitelnosti" financovaného Ministerstvem školství, mládeže a tělovýchovy České republiky

Literatura

- [1] EBRAHIMI, R., SOLHJOO, S. Characteristic Points of Stress-Strain Curve at High Temperature. *International Journal of ISSI*, 4 (2007) 1-2, 24-27.
- [2] GRONOSTAJSKI, Z. The Constitutive Equations for FEM Analysis. *Journal of Materials Processing Technology*, 106 (2000) 1-3, 40-44. Dostupné z doi:10.1016/S0924-0136(00)00635-X
- [3] SHAFAAAT, M. A., OMIDVAR, H., FALLAH, B. Prediction of Hot Compression Flow Curves of Ti-6Al-4V Alloy in $\alpha + \beta$ Phase Region. *Materials & Design*, 32 (2011) 10, 4689-4695. Dostupné z doi:10.1016/j.matdes.2011.06.048
- [4] SCHINDLER, I., BOŘUTA, J. *Utilization Potentialities of the Torsion Plastometer*. Žory: OLDPRINT, 1998, 140 s. ISBN 83-910722-0-7.
- [5] LI, H. Y. et al. Constitutive Modeling for Hot Deformation Behavior of T24 Ferritic Steel. *Computational Materials Science*, 53 (2012) 1, 425-430. Dostupné z doi: 10.1016/j.commatsci.2011.08.031
- [6] ROWEIS, Sam. Levenberg-Marquardt Optimization [online]. [vid. 2018-02-07]. Dostupné z: <https://cs.nyu.edu/~roweis/notes/lm.pdf>
- [7] WU, Si-Wei et al. The Improvement on Constitutive Modeling of Nb-Ti Micro Alloyed Steel by Using Intelligent Algorithms. *Materials & Design*, 116 (2017), 676-685. Dostupné z doi: 10.1016/j.matdes.2016.12.058
- [8] QUAN, G. Z. et al. Modeling the Hot Deformation Behaviors of As-Extruded 7075 Aluminum Alloy by an Artificial Neural Network with Back-Propagation Algorithm. *High Temperature Materials and Processes*, 36 (2017) 1, 1-13. Dostupné z doi: 10.1515/htmp-2015-0108
- [9] FU, R. Q., T. W. XU and Z. X. PAN Modeling of the Adsorption of Bovine Serum Albumin on Porous Polyethylene Membrane by Back-Propagation Artificial Neural Network. *Journal of Membrane Science*, 251 (2005) 1-2, 137-144. Dostupné z doi: 10.1016/j.memsci.2004.11.007
- [10] OPĚLA, P. et al. Hot Flow Stress Models of the Steel C45. *Metalurgija*, 54 (2015) 3, 469-472. ISSN 0543-5846.
- [11] SZTIWERTNIA, K. (ed.). *Recrystallization* [online]. Rijeka: InTech, 2012 [vid. 2018-04-27]. Chapter 9, Mathematical Modeling of Single Peak Dynamic Recrystallization Flow Stress Curves in Metallic Alloys. ISBN: 978-953-51-0122-2. Dostupné z: <https://www.intechopen.com/books/recrystallization/mathematical-modeling-of-single-peak-dynamic-recrystallization-flow-stress-curves-in-metallic-alloys>
- [12] CINGARA, A., McQUEEN, H. J. New Formula for Calculating Flow Curves from High Temperature Constitutive Data for 300 Austenitic Steels. *Journal of Materials Processing Technology*, 36 (1992) 1, 31-42. Dostupné z doi:10.1016/0924-0136(92)90236-L
- [13] OPĚLA, P. et al. New Model Predicting Flow Curves in Wide Range of Thermomechanical Conditions of 38MnVS6 Steel. In *Metal 2016: 25th Anniversary International Conference on Metallurgy and Materials: Conference Proceedings, Brno, 25.5.-27.5.2016*. Ostrava: Tanger Ltd, 2017, s. 458-463. ISBN 978-80-87294-67-3.
- [14] MITCHELL, M. *An Introduction to Genetic Algorithms*. Cambridge: The MIT Press, 1998, 158 s. ISBN 0-262-13316-4.
- [15] HAUPT, R. L., HAUPT, S. E. *Practical Genetic Algorithms*. 2nd edition. Hoboken: John Wiley & Sons, Inc., 2004, 253 s. ISBN 0-471-45565-2.
- [16] DARWIN, CH. *On the Origin of Species by Means of Natural Selection, or the Preservation of Favoured Races in the Struggle for Life*. London: John Murray, Albemarle Street, 1859, 502 s.

- [17] HOLLAND, J. H. *Adaptation in Natural and Artificial Systems*. Michigan: University of Michigan Press, 1975, 183 s. ISBN 0472084607.
- [18] GAUSS, C. F. *Theoria Combinationis Observationum Erroribus Minimis Obnoxiae*. Göttingen: apud Henricum Dieterich, 1823, 58 s. Dostupné z: <https://ia801407.us.archive.org/4/items/theoriacombinat00gausgoog/theoriacombinat00gausgoog.pdf>
- [19] WHITLEY, D. A Genetic Algorithm Tutorial. *Statistics and Computing*, 4 (1994) 2, 65-85. ISSN 0960-3174. Dostupné z doi: 10.1007/BF00175354
- [20] MICHALEWICZ, Z. *Genetic Algorithms + Data Structures = Evolution Programs*. 3rd edition. New York: Springer-Verlag Berlin Heidelberg, 1996. ISBN 3-540-60676-9.
- [21] GNU Octave [online]. [vid. 2018-07-26]. Dostupné z: <https://www.gnu.org/software/octave/>
- [22] GA [online]. Octave-Forge – Extra Packages for GNU Octave [vid. 2018-07-26]. Dostupné z: <https://octave.sourceforge.io/ga/index.html>
- [23] SPENCER, H. *The Principles of Psychology*. London: Williams and Norgate, 1872.
- [24] McCULLOCH, W. S., PITTS, W. H. A Logical Calculus of Ideas Immanent in Nervous Activity. *The bulletin of mathematical biophysics*, 5 (1943) 4, 115-133. ISSN 0007-4985. Dostupné z doi: 10.1007/BF02478259
- [25] ROSENBLATT, F. The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain. *Psychological Review*. 65 (1958) 6, 386-408. Dostupné z doi: 10.1037/h0042519
- [26] OPĚLA, P. et al. Popis napěťových křivek při tváření za tepla s využitím prediktivních modelů a umělých neuronových sítí. *Kovárství*, 64 (2018), 8-13. ISSN 1213-9289.
- [27] LV, J., REN, H., GAO, K. Artificial Neural Network-based Constitutive Relationship of Inconel 718 Superalloy Construction and its Application in Accuracy Improvement of Numerical Simulation. *Applied Sciences*, 7 (2017) 2. ISSN 2076-3417. Dostupné z doi: 10.3390/app7020124
- [28] Principles of Training Multi-Layer Neural Network Using Back propagation [online]. [vid. 2018-07-27]. Dostupné z: http://home.agh.edu.pl/~vlsi/AI/backp_t_en/backprop.html
- [29] LEVENBERG, K. A Method for the Solution of Certain Non-Linear Problems in Least Squares. *Quarterly of Applied Mathematics*, 2 (1944) 2, 164-168. ISSN 1552-4485. Dostupné z doi: 10.1090/qam/10666
- [30] MARQUARDT, D. W. An Algorithm for Least-Squares Estimation of Nonlinear Parameters. *Journal of the Society for Industrial and Applied Mathematics*, 11 (1963) 2, 431-441. ISSN 2168-3484. Dostupné z doi: 10.1137/0111030
- [31] RUMELHART, D. E. et al. *Parallel Distributed Processing: Explorations in the Microstructure of Cognition: vol. 1: Foundations*. Cambridge: The MIT Press, 1986. ISBN 9780262181204.
- [32] McCLELLAND, J. L. et al. *Parallel Distributed Processing: Explorations in the Microstructure of Cognition vol. 2: Psychological and Biological Models*. Cambridge: The MIT Press, 1986. ISBN 9780262181235.
- [33] SCHMID, M. D. A Neural Network Package for Octave – User's Guide – Version: 0.1.9.1 [online]. 2009. [vid. 2017-10-04]. Dostupné z: https://mafiadoc.com/a-neural-network-package-for-octave-user39s-guide-version-0191_59b4e5641723ddcc6daf493.html
- [34] Octave's Neural Network Package [online]. Source Forge [vid. 2018-07-30]. Dostupné z: <https://sourceforge.net/projects/octnnetb/>
- [35] Mean, Mode, Median, and Standard Deviation [online]. [vid. 2018-07-30]. Dostupné z: <http://www.ltconline.net/green/courses/201/descstat/mean.htm>

ArcelorMittal Tubular Products Ostrava má na svařovně trub nové svařovací zdroje

Firemní měsíčník AMO – říjen 2018, str. 11

Investice za více než 5 mil. CZK byla realizována v srpnu 2018 na svařovacím agregátu číslo jedna svařovny trub z důvodu zvyšujících se nároků na kvalitu dodávaných trubek. Svařovna trub vyrábí trubky v rozsahu průměrů 323,9 mm až 1020 mm s tloušťkou stěny 5,0 mm až 14,6 mm.

Jednalo se o výměnu svařovacích zdrojů pro svařování spirálových trubek pod tavidlem. Dodavatelem svařovacích zdrojů byla americká firma LINCOLN ELECTRIC, jejíž moderní invertorové zdroje plně využívají technické možnosti současné doby. Mají rychlou reakci oblouku, velmi stabilní hoření oblouku a umožňují operátorovi jednoduché řízení procesu v reálném čase.

Celkem byly instalovány čtyři svařovací zdroje. Dva zdroje jsou určeny pro vnitřní svar a další dva pro vnější svar. Jednotlivé páry jsou vzájemně propojeny, přičemž může svařovat buď jeden zdroj, nebo oba současně v tandemovém uspořádání.

Celkový elektrický příkon všech čtyř zdrojů je 208 kW a maximální výstupní proud jednoho zdroje je 1000 A.

Investice vedla ke zvýšení rychlosti svařování o 25 % při současném zajištění větší stability oblouku a na svařovacím agregátu číslo jedna tak vzrostla produktivita. U rozměru trub 1016 × 14,6 mm došlo na jedné směně k nárůstu výroby z 45 t na 53 t, tj. o 8 t.