

## WYZNACZANIE NIEKTÓRYCH CHARAKTERYSTYK STALI W OPARCIU O TYP WYKRESU CTPi PRZY UŻYCIU SZTUCZNYCH SIECI NEURONOWYCH

BOGDAN PAWŁOWSKI, PAWEŁ POPOWICZ

### *DETERMINATION OF SELECTED CHARACTERISTICS OF STEELS, BASED ON THE TYPE OF THE CCT DIAGRAM, USING ARTIFICIAL NEURAL NETWORKS*

#### *Abstract*

*The paper focuses on classification of steels using the artificial neural network (ANN) approach. The steels are grouped into classes according to the Wever and Rose TTT diagrams. It is also shown that the accuracy of ANN predictions of some characteristics of steels (critical temperatures  $A_{c3}$ ) can be improved if the ANN learning data, based on the chemical compositions of steels, are initially arranged into different types of TTT diagrams*

### 1. WPROWADZENIE

Przy stosowaniu metod komputerowych do symulowania kinetyki przemian fazowych stali i wyznaczania konkretnych własności produktów tych przemian często zachodzi potrzeba uprzedniego pogrupowania stali ze względu na ich skład chemiczny w odpowiednie grupy i klasy. Dostępne w literaturze wzory empiryczne pozwalające przykładowo na obliczenie temperatury  $M_s$  (temperatura początku przemiany martenzytycznej),  $B_s$  (temperatura początku przemiany bainitycznej),  $A_{c1}$  (temperatura początku przemiany perlitu w austenit) czy  $A_{c3}$  (temperatura końca przemiany ferrytu w austenit) lub określenie udziałów objętościowych poszczególnych składników strukturalnych (Steven i Haynes 1956, Andrews 1965) w zależności od składu chemicznego stali, zapewnia-

ją odpowiedni poziom wiarygodności uzyskanych wyników pod warunkiem, że składy chemiczne stali mieszczą się w pewnych przedziałach, dla których wyznaczono stosowane w obliczeniach zależności empiryczne. W niektórych pracach (Dobrzański i Sitek 2000) do pogrupowania stali posłużono się tzw. czynnikiem stopowym AF (alloy factor), który określa udział procentowy poszczególnych pierwiastków stopowych w stali, przy zachowaniu różnych współczynników wagowych poszczególnych pierwiastków.

Dobrym kryterium umożliwiającym wstępne pogrupowanie stali (przed dokonywaniem odpowiednich obliczeń) jest znana od dawna klasyfikacja wykresów CTPi (Czas – Temperatura – Przemiana w warunkach izotermicznych) według Wevera i Rosego jak i według Jecha (Wever i Rose 1958, Jech 1977). Uzasadnia to fakt, że podział wykresów CTPi na odpowied-

nie typy związane jest z wpływem pierwiastków stopowych na kształt linii początku i końca zachodzących przemian fazowych oraz na ewentualne oddzielenie zakresów przemian dyfuzyjnych od pośrednich, a więc na warunki zachodzenia przemian austenitu i własności produktów tych przemian.

W niniejszej pracy do klasyfikacji stali według typu wykresu CTPi oraz do wyznaczenia niektórych charakterystyk (temperatury  $M_s$ ,  $A_c1$  i  $A_c3$ ) stali zastosowano sztuczne sieci neuronowe. Celem pracy było sprawdzenie czy nauczanie sieci neuronowych w oparciu o zbiory składów chemicznych stali o tym samym typie wykresów CTPi daje inne (lepsze lub gorsze) wyniki niż w przypadku gdy nauczanie prowadzone jest na zbiorach składów chemicznych stali o różnych typach wykresów CTPi.

## 2. KLASYFIKACJA WYKRESÓW CTP


Wykresy CTP zawierają ilościowe dane dotyczące zależności mikrostruktury i własności stali od czasu i temperatury przemiany przechłodzonego austenitu. W zależności od sposobu chłodzenia opracowywane są różnego typu wykresy CTP:

- wykresy CTPi – dla przemian zachodzących w warunkach izotermicznych,
- wykresy CTPc – dla przemian zachodzących podczas ciągłego chłodzenia.

Z wykresów CTPi można określić kinetykę prze-

mian fazowych zachodzących w warunkach izotermicznych przy różnych temperaturach. Hartowność poszczególnych stali i stopów o wiele lepiej charakteryzują wykresy CTPc. Wykresy tego typu stosuje m.in. w celu ustalenia twardości czy też mikrostruktury stali hartowanej, odpuszczanej lub normalizowanej. Na podstawie tych wykresów bardzo łatwo jest określić krytyczną szybkość chłodzenia, czyli najmniejszą szybkość chłodzenia z temperatury austenitowania zapewniającą uzyskanie wyłącznie struktury martenzytycznej. Wielu badaczy starało się sklasyfikować typy wykresów CTPi dla stali stopowych. Klasyfikacje te zmieniały się z czasem w miarę jak poznawano i przeprowadzano coraz to dokładniejsze badania. Najbardziej chyba dokładną, uwzględniającą największą liczbę wyników badań i najbardziej znaną jest klasyfikacja Wevera i Rosego. Za podstawę klasyfikacji przyjęto kształt krzywych początku i końca przemian. Wyróżniono 5 typów wykresów CTPi:

1. Typ I – obejmuje wykresy z jednym maksimum szybkości przemiany. Krzywe początku i końca przemiany mają kształt litery C (rysunek 1a).
2. Typ II – w skład tego typu wchodzi wykresy których krzywa początku przemiany ma charakter ciągły, natomiast na krzywej końca przemiany zaznacza się wydłużenie czasu przemiany (rysunek 1b)
3. Typ III – występują dwa maksima szybkości przemiany (rysunek 1c). Nie nastąpiło jeszcze całkowite rozsunięcie przemian perlitycznej i bainitycznej.



Rysunek 1. Wykresy CTPi według klasyfikacji Wevera i Rosego (A – austenit, F – ferryt, P – perlit, B – bainit, M – martenzyt).



- Typ IV – rozdział przemian perlitycznej i bainitycznej jest całkowity. Między tymi przemianami występuje zakres trwałości austenitu (rysunek 1d).
- Typ V – obejmuje przede wszystkim stale wysokostopowe o małej zawartości węgla. Mała zawartość węgla podnosi temperaturę  $M_s$ , co przy jednoczesnym obniżeniu granicy przemiany bainitycznej powoduje, iż zakres przemiany martenzytycznej całkowicie przesłania przemianę bainityczną (rysunek 1e).

Innym rodzajem klasyfikacji wykresów CTPi jest klasyfikacja Jecha. Wykresy CTPi również zostały podzielone na 5 typów:

- Typ I – jedno maksimum szybkości przemiany. Nie występuje przemiana bainityczna (rysunek 2a).
- Typ II – zaznacza się wydłużenie czasów końca przemian perlitycznej i bainitycznej, natomiast krzywa początku przemiany ma wciąż charakter ciągły (rysunek 2b).
- Typ III – obejmuje te wykresy, w których następuje rozdzielenie maksimów szybkości przemiany perlitycznej i bainitycznej. Dalszemu wydłużeniu ulegają czasy końca przemian (rysunek 2c).
- Typ IV – dwa maksima szybkości przemiany, przemiany perlityczna i bainityczna nie zachodzą do końca (rysunek 2d).
- Typ V – nastąpiło całkowite rozsuniecie przemian perlitycznej i bainitycznej. Między nimi znajduje się zakres trwałości austenitu (rysunek 2e).


### 3. CZYNNIK STOPOWY AF

Wartość czynnika stopowego AF, zgodnie z normą ASTM A225-1985, wyznacza się na podstawie sumy iloczynów procentów masowych poszczególnych pierwiastków stopowych w stali i odpowiednich współczynników.

Poniżej przedstawiono porównanie zakresów wartości czynnika stopowego AF z odpowiednimi typami wykresów CTPi. W tym celu wyznaczono dla każdego z dwóch opracowanych zbiorów składów chemicznych (użytych następnie do uczenia sieci neuronowych rozpoznawania typu wykresu CTPi) odpowiadający mu czynnik stopowy AF, a następnie po-

Tablica 1. Wartości czynników stopowych AF dla różnych typów wykresów CTPi.

| Typ wykresu CTPi             | Minimalna wartość czynnika stopowego AF | Maksymalna wartość czynnika stopowego AF |
|------------------------------|---|--|
| Klasyfikacja Wevera i Rosego |   |  |
| I                            | 1                                       | 7  |
| II                           | 3                                       | 14                                       |
| III                          | 9                                       | 37                                       |
| IV                           | 12                                      | 217                                      |
| V                            | 75                                      | 193                                      |
| Klasyfikacja Jecha           |   |  |
| I                            | 2                                       | 5  |
| II                           | 6                                       | 20                                       |
| III                          | 8                                       | 19                                       |
| IV                           | 12                                      | 31                                       |
| V                            | 17                                      | 202                                      |



Rysunek 2. Wykresy CTPi według klasyfikacji Jecha (A – austenit, F – ferryt, P – perlit, B – bainit, M – martenzyt).



równano z typem wykresu CTPi (tablica 1).

Jak widać z danych zamieszczonych w tablicy 1, zakresy zmienności wartości czynników stopowych AF dla różnych typów wykresów CTPi zachodzą na siebie. Zachodzenie na siebie zakresów zmienności czynnika stopowego AF nie występuje natomiast, gdy stale zostaną uprzednio pogrupowane w odpowiednie rodzaje pod względem zastosowań (stale do nawęglania, stale do ulepszania cieplnego), jak to przedstawiono w pracy (Dobrzański i Sitek 2000). W niniejszej pracy postanowiono się jednak oprzeć na wstępnym podziale stali ze względu na typ wykresu CTPi według klasyfikacji Wevera i Rosego (jako najbardziej popularnej), gdyż pozwala to już na wstępie dokonać podziału ze względu na różną kinetykę przemian austenitu a nie tylko z uwagi na zawartość pierwiastków stopowych.

#### 4. ZASTOSOWANIE SIECI NEURONOWEJ DO KLASYFIKACJI WYKRESÓW CTPi I WYZNACZANIA NIEKTÓRYCH CHARAKTERYSTYK STALI

Zgodnie z opinią, wyrażoną m.in. przez Tadeusiewicza (2001), sztuczne sieci neuronowe mogą być z powodzeniem stosowane w zagadnieniach związanych np. z klasyfikacją, pod warunkiem pewności istnienia zależności pomiędzy sygnałami wejściowymi a nieznanymi wartościami wynikowymi. Założenie to w przypadku zależności pomiędzy składem chemicznym stali a jej wykresem CTPi jest oczywiście prawdziwe, na co dowody można znaleźć na przykład w pracy Malkiewicza (1976), opisującej m.in. wpływ pierwiastków stopowych na kinetykę przemian przechłodzonego austenitu.

Celem tej części niniejszej pracy było takie nauczanie sieci neuronowej aby na podstawie przykładowych

składów chemicznych stali sieć potrafiła rozpoznać i zakwalifikować wykres CTPi danej stali do wykresów odpowiedniego typu. W tym celu przygotowano zbiór uczący składający się z przykładowych składów chemicznych i odpowiadających im typów wykresów

Tablica 2. Zakres zmienności składów chemicznych zbioru uczącego.

| Pierwiastek | % masowe min. | % masowe max. |
|-------------|---------------|---------------|
| C           | 0,12          | 2,08          |
| Mn          | 0,00          | 1,98          |
| Si          | 0,00          | 1,62          |
| Cr          | 0,00          | 13,90         |
| Mo          | 0,00          | 2,61          |
| Ni          | 0,00          | 4,03          |
| V           | 0,00          | 2,52          |
| W           | 0,005         | 18,25         |

CTPi (dane zaczerpnięto z dostępnych atlasów wykresów CTPi (Wever i Rose 1958, Jech 1977)). Zbiór składa się z 50 składów chemicznych stali (od konstrukcyjnych poprzez narzędziowe aż do wysokostopowych stali specjalnych) pogrupowanych w 5 klas. Każda klasa odpowiada danemu typowi wykresów CTPi według klasyfikacji Wevera i Rosego. Pojedynczy ciąg uczący składa się z procentów masowych ośmiu pierwiastków stopowych jako dane wejściowe oraz pięciu wartości prawda lub fałsz dla poszczególnych typów wykresów CTPi jako dane wyjściowe. Pierwiastki wchodzące w skład ciągu uczącego to: węgiel, mangan, krzem, chrom, molibden, nikiel, wanad oraz wolfram. Zakres zmienności składów chemicznych podano w tablicy 2.

Dla potrzeb niniejszej pracy, po fazie wstępnych testów zdecydowano się na wybór sieci trzywarstwowej, z jedną warstwą ukrytą. Liczba danych wejściowych (procenty masowe pierwiastków wymienionych w tablicy 2) określiła z góry liczbę 8 neuronów w warstwie wejściowej. Warstwa ukryta składa się z 7 neuronów a warstwa wyjściowa z 5 neuronów, odpowiadającym pięciu typom wykresów CTPi.

Tablica 3. Dane zawarte w zbiorze testującym, rzeczywisty typ wykresu CTPi oraz typ wyznaczony przez sieć neuronową

| %C   | %Mn  | %Si  | %Cr   | %Mo  | %Ni  | %V   | %W    | Rzeczywisty typ wykresu | Typ wykresu wyznaczony przez sieć |
|------|------|------|-------|------|------|------|-------|-------------------------|-----------------------------------|
| 1,03 | 0,17 | 0,22 | 0,07  | 0,01 | 0,10 | 0,02 | 0,00  | I                       | I                                 |
| 0,44 | 0,66 | 0,31 | 0,15  | 0,00 | 0,00 | 0,02 | 0,00  | I                       | I                                 |
| 0,24 | 0,21 | 1,06 | 0,79  | 0,02 | 0,18 | 0,10 | 0,00  | II                      | II                                |
| 0,16 | 1,14 | 0,27 | 1,00  | 0,00 | 0,12 | 0,05 | 0,00  | II                      | II                                |
| 0,36 | 0,25 | 0,49 | 1,54  | 0,03 | 0,21 | 0,01 | 0,00  | III                     | III                               |
| 0,41 | 0,65 | 0,29 | 1,45  | 0,00 | 0,15 | 0,00 | 0,00  | III                     | III                               |
| 0,97 | 0,31 | 0,18 | 4,11  | 2,61 | 0,25 | 2,51 | 3,23  | IV                      | IV                                |
| 0,81 | 0,33 | 0,15 | 3,77  | 0,44 | 0,12 | 1,07 | 18,25 | IV                      | IV                                |
| 0,12 | 0,74 | 0,79 | 12,82 | 0,05 | 0,25 | 0,00 | 0,00  | V                       | V                                 |
| 0,42 | 0,29 | 0,38 | 13,80 | 0,01 | 0,21 | 0,00 | 0,00  | V                       | V                                 |



Zastosowana sztuczna sieć neuronowa uczona była metodą wstecznej propagacji błędu (backpropagation) z liniową funkcją aktywacji neuronów (poza warstwą wyjściową o logistycznej funkcji aktywacji). Symulacji sieci neuronowej dokonano na komputerze klasy IBM PC z procesorem Intel Celeron 400 MHz.

W celu przetestowania nauczonej już sieci, w oparciu o atlasy wykresów CTPi (Wever i Rose 1958, Jech 1977), przygotowano zbiór testujący. Zbiór ten zawierał 10 składów chemicznych stali, które nie były użyte wcześniej do nauki sieci. Składy chemiczne wchodzące w skład tego zbioru dobrano w taki sposób aby procenty masowe poszczególnych pierwiastków mieściły się w granicach zmienności składów chemicznych stali użytych w procesie nauczania sieci. Składy chemiczne stali użyte do testowania sieci, rzeczywisty typ wykresu CTPi oraz typ wyznaczony przez uprzednio nauczoną sieć pokazano w tabelicy 3.

Jak widać z danych pokazanych w tabelicy 3, dla dziesięciu, losowo wybranych składów chemicznych sieć neuronowa bezbłędnie określa typ wykresu CTPi według klasyfikacji Wevera i Rosego. Analogiczne wyniki uzyskano dla sieci rozpoznającej typ wykresu CTPi zgodnie z klasyfikacją Jecha.

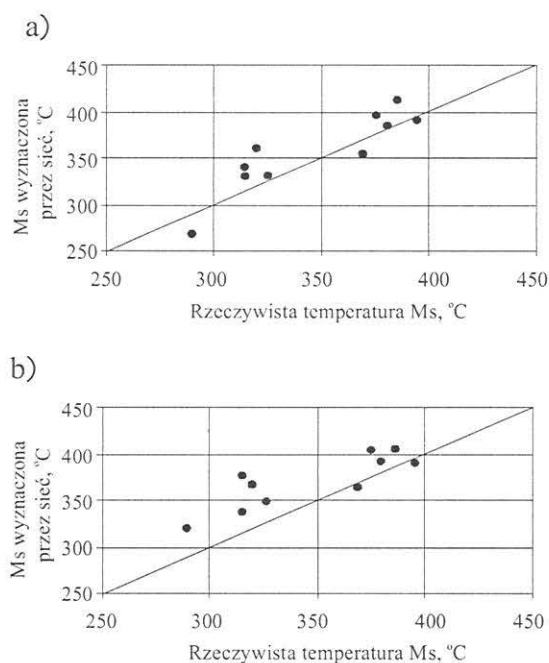
W dalszej części pracy podjęto próbę sprawdzenia, czy nauczanie sieci neuronowych w oparciu o zbiory składów chemicznych stali przynależnych do jednego typu klasyfikacji wykresów CTPi daje inne wyniki niż w przypadku gdy nauczanie prowadzone jest na zbiorach składów chemicznych stali o różnych typach wykresów CTPi.

Do procesu nauczania i testowania sieci wybrano stale o wykresach CTPi zawierających się w typie III i IV według klasyfikacji Wevera i Rosego. Przygotowano dwa zbiory uczące, każdy zawierający 20 składów chemicznych stali (jako dane wejściowe) oraz rzeczywiste wartości temperatury  $M_s$ ,  $A_{c1}$  i  $A_{c3}$  (dane wyjściowe). Pierwszy zbiór zawierał 10 składów chemicznych stali o III typie i 10 składów stali o IV typie wykresów CTPi. Drugi zbiór uczący składał się tylko ze składów chemicznych stali mających III typ wykresu CTPi. Zbiór testujący w każdym z powyższych eksperymentów składał się z 10 składów chemicznych stali, nie użytych uprzednio w procesie nauczania sieci, których wykresy CTP należą do III typu w klasyfikacji Wevera i Rosego.

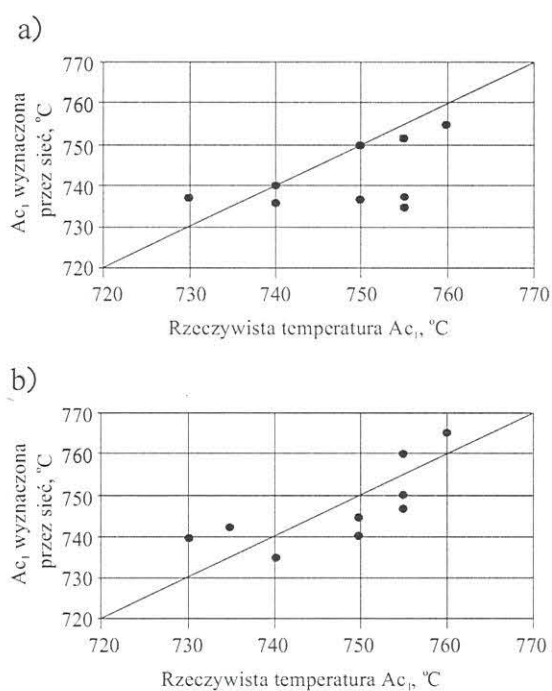
W tej części pracy użyto trzech sieci neuronowych (dla wyznaczania odpowiednio temperatury  $M_s$ ,  $A_{c1}$  i  $A_{c3}$ ) o takiej samej architekturze – 8 neuronów w warstwie wejściowej, 5 w warstwie ukrytej i jednym neuronem w warstwie wyjściowej, z zastosowaniem metody wstecznej propagacji błędu i z nieliniową funkcją aktywacji neuronów (tangens hiperboliczny). Podobnie jak i w poprzednich przypadkach wartości współczynnika uczenia (learning rate) jak i pędu (mo-

mentum) były optymalizowane automatycznie przez sztuczną sieć neuronową

Na rysunku 3 przedstawiono porównanie rzeczywistych wartości temperatury  $M_s$  z wartościami wyznaczonymi przez sztuczną sieć neuronową uczoną na zbiorze zawierającym składki chemiczne stali o wykresach III i IV typu (rysunek 3a) oraz analogiczne porównanie dla sieci uczonej na składach chemicznych stali o wykresach CTPi tylko III typu klasyfika-



Rysunek 3. Wyniki testu sieci przewidującej temperaturę  $M_s$  uczonej na zbiorze o III i IV typie wykresów CTPi (a) oraz uczonej na

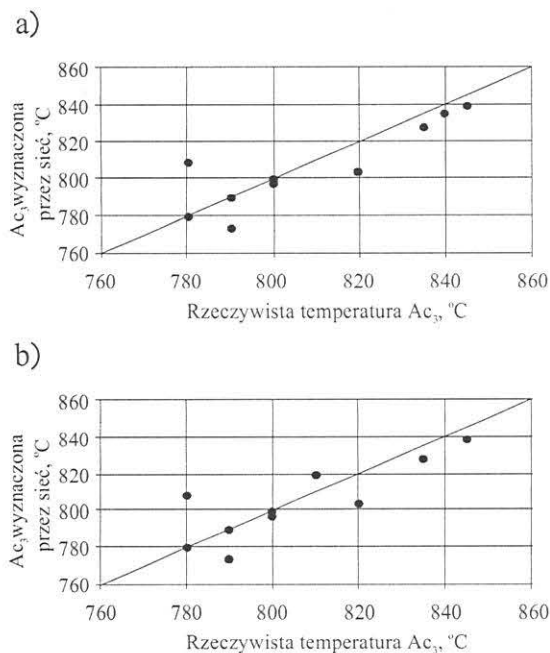


Rysunek 4. Wyniki testu sieci przewidującej temperaturę  $A_{c1}$  uczonej na zbiorze o III i IV typie wykresów CTPi (a) oraz uczonej na zbiorze o tylko III typie wykresów CTPi (b).





cji (rysunek 3b). Analogiczne porównanie dla temperatur  $Ac_1$  i  $Ac_3$  przedstawiono odpowiednio na rysunkach 4a, b oraz 5a, b. W tabelicy 4 zestawiono natomiast porównanie zgodności wyznaczonych przez sieci neuronowe temperatur  $Ms$ ,  $Ac_1$  i  $Ac_3$  z wartościami rzeczywistymi. Zgodność tą określa współczynnik korelacji  $r$ .



Rysunek 5. Wyniki testu sieci przewidującej temperaturę  $Ac_3$  uczonej na zbiorze o III i IV typie wykresów CTPi (a) oraz uczonej na zbiorze o tylko III typie wykresów CTPi (b).

Tabela 4. Porównanie zgodności wartości temperatur  $Ms$ ,  $Ac_1$  i  $Ac_3$  wyznaczonych przez sieć z wartościami rzeczywistymi.

| Temperatura | Współczynnik korelacji $r$  |  |
|-------------|---|--|
|             | Sieć uczona na składach chemicznych stali o III i IV typie wykresu CTPi | Sieć uczona na składach chemicznych stali tylko o III typie wykresu CTPi |
| $Ms$        | 0,88  | 0,82   |
| $Ac_1$      | 0,53  | 0,74   |
| $Ac_3$      | 0,87  | 0,83   |

## 5. PODSUMOWANIE

Otrzymane wyniki świadczą o tym, że nauczanie sieci neuronowych w oparciu o zbiory składów chemicznych stali o tym samym typie wykresów CTP daje inne wyniki niż w przypadku gdy nauczanie prowadzone jest na zbiorach składów chemicznych stali o różnych typach wykresów CTPi. Z danych zestawionych w tabelicy 4 wynika, że temperatury  $Ms$  i  $Ac_3$  są przewidywane przez sieci neuronowe, przy dwóch różnych zasadach uczenia, na zbliżonym poziomie

zgodności z danymi rzeczywistymi (współczynnik korelacji w granicach 0,82–0,88). Istotna różnica wystąpiła natomiast przy wyznaczaniu temperatury  $Ac_1$ . Wyniki obliczeń sieci uczonej na składach chemicznych stali tylko o III typie wykresu CTPi wykazały o wiele lepszą zgodność z danymi eksperymentalnymi (współczynnik korelacji wyniósł 0,74) niż sieć uczona na zbiorze stali o różnych typach wykresów CTPi (współczynnik korelacji 0,53). Współczynnik korelacji jest jednak niższy (0,74) niż współczynniki korelacji uzyskane przy wyznaczaniu temperatur  $Ms$  i  $Ac_3$  (odpowiednio 0,82 i 0,83). Uzasadnione to jest faktem, że temperatury  $Ms$  i  $Ac_3$  zależą przede wszystkim od zawartości węgla w stali, a w mniejszym stopniu od zawartości pierwiastków stopowych, jak to ma miejsce w przypadku temperatury  $Ac_1$ .

Ma to zresztą swoje odbicie w publikowanych w literaturze wzorach empirycznych pozwalających na obliczenie tych temperatur (np. Andrews 1965, Steven i Haynes 1956). Wzory te mają najczęściej następującą postać:

$$\text{Temperatura (Ms lub } Ac_3) = K - a_C(C) - a_{Mn}(Mn) - a_{Cr}(Cr) \dots$$

gdzie symbole w nawiasach oznaczają zawartość procentową poszczególnych pierwiastków a współczynniki  $a_x$  (dla  $x = C, Mn, Si, Cr, Ni, Mo$  i  $V$ ) oraz stała  $K$  są wyznaczone doświadczalnie. Z zestawienia wartości współczynników  $a_x$  zamieszczonego w pracy Trzaski i wsp. (2001) widać, że najsilniejszy jest wpływ węgla (wartość współczynnika  $a_C$  w zakresie od 539 do 1000) a wartości współczynników  $a_x$  pozostałych pierwiastków stopowych są o rząd wielkości mniejsze (np.  $a_{Mn}$  w zakresie od 30,4 do 70).

Natomiast temperatura  $Ac_1$  praktycznie zależy tylko od zawartości pierwiastków stopowych, podobnie jak typ wykresu CTPi. Przykładowo, empiryczny wzór Andrews (1965) uzależnia wartość tej temperatury od zawartości czterech pierwiastków –  $Mn, Si, Cr$  i  $Ni$ :

$$Ac_1 = 723 - 10,7(Mn) + 29,1(Si) + 16,9(Cr) - 16,9(Ni).$$

Z badań przeprowadzonych przez Dobrzańskiego i wsp. (2001) czy też przedstawionych w pracy Pawłowskiego (2001) wynika zresztą, że sieci neuronowe dokładniej przewidują temperaturę  $Ac_1$  niż wyniki uzyskane za pomocą wzorów empirycznych, mających jak to ma miejsce w przypadku powyższego wzoru Andrews charakter liniowy. Równania liniowe nie ujmują bowiem ze swojej natury bardzo ważnej cechy jaką jest synergia oddziaływań poszczególnych pierwiastków na kinetykę przemian przechłodzonego austenitu. W pracach (Dubiel 1996, Jędrzejewska-Strach 1995, Strach 1995) wykazano bowiem znaczące różnice w wpływie poszczególnych pierwiastków na ki-

netykę przemian austenitu w zależności od tzw. „tła”, czyli zawartości pozostałych pierwiastków stopowych.

## 6. WNIOSKI

Z zamieszczonych powyżej wyników można wysnuć następujące wnioski:

1. sztuczne sieci neuronowe są w stanie bardzo dobrze określić typ wykresu CTPi stali w oparciu o jej skład chemiczny,
2. zgodność wyznaczania przez sieć neuronową charakterystyk (temperatury  $M_s$  i  $A_{c_3}$ ) zależnych głównie od jednego pierwiastka (węgla) z danymi rzeczywistymi nie zależy w sposób istotny od uprzedniego pogrupowania zbiorów uczących na podstawie składu chemicznego (typu wykresu CTPi),
3. w przypadku gdy sztuczna sieć neuronowa ma wyznaczać charakterystyki stali zależne przede wszystkim od zawartości pierwiastków stopowych (np. temperaturę  $A_{c_1}$ ) a w małym stopniu lub w ogóle niezależne od zawartości węgla, korzystnie jest stosować wstępny podział stali zgodnie z charakteryzującymi je wykresami CTPi.

## UWAGA KOŃCOWA

Pracę zrealizowano ze środków KBN (nr umowy AGH 10.10.110.199).

## LITERATURA

- Andrews, K.W., 1965, Empirical formulae for the calculation of some transformation temperatures, *J. Iron and Steel Institute*, 203, 721-727.
- Dobrzański, L.A., Sitek, W., 2000, Modelowanie zależności między składem chemicznym a hartownością stali konstrukcyjnych, *Proceedings of The Scientific Conference on the Occasion of the 55<sup>TH</sup> Anniversary of the Faculty of Mechanical Engineering of the Silesian University of Technology*, Gliwice, 161-168.

- Dobrzański, L.A., Trzaska, J., Pozimska, K., 2001, Zastosowanie sztucznych sieci neuronowych do wyznaczania temperatur  $A_{c_1}$  i  $A_{c_3}$  stali konstrukcyjnych, *Proceedings of the 10th Jubilee International Scientific Conference Achievements in Mechanical & Materials Engineering*, Gliwice-Kraków-Zakopane, 179-182.
- Dubiel, M., 1996, *Przemiany fazowe w stopach modelowych imitujących osnowę zahartowanych stali konstrukcyjnych i nierdzewiejących*, Praca doktorska, AGH, Kraków.
- Jech, J., 1977, *Tepelne zpracovani oceli*, SNTL – Nakladatelství Technické Literatury, Praha.
- Jędrzejewska-Strach, A., 1995, *Wpływ manganu na kinetykę przemian fazowych, strukturę i własności stopów modelowych stali konstrukcyjnych*, Praca doktorska, AGH, Kraków.
- Malkiewicz, T., 1976, *Metaloznawstwo stopów żelaza*, wyd. II, PWN, Warszawa-Kraków.
- Pawłowski, B., 2001, Wykorzystanie sztucznych sieci neuronowych do prognozowania niektórych charakterystyk stali do ulepszenia cieplnego, *Hutnik-Wiadomości Hutnicze*, 68, 281-283.
- Steven W. i Haynes A.G., 1956, The temperature of formation of martensite and bainite in low-alloy steels. Some effects of chemical composition, *J. Iron and Steel Institute*, vol. 183, part 4, 349-359.
- Strach M., 1995, *Struktura i własności stali krzemowych oceniane na podstawie badań stopów modelowych o różnym stężeniu krzemu i węgla*, Praca doktorska AGH, Promotor J.Pacyna.
- Tadeusiewicz R., 2001, Problem wyboru właściwej architektury sieci neuronowej, *Informatyka w technologii materiałów*, Nr 1, Tom 1, 3-22.
- Trzaska J., Pozimska K. i Dobrzański L.A., 2001, Zastosowanie sztucznych sieci neuronowych do wyznaczania temperatury początku przemiany martenzytycznej stali konstrukcyjnych, *Mat. Konf. XXXIX Szkoła Inżynierii Materiałowej*, Kraków-Wisła, 2-5.X.2001, 429-432.
- Wever F., Rose A., 1954-1958, *Atlas zur Wärmebehandlung der Stähle*, cz.I, Verlag Stahleisen, Düsseldorf.

Artykuł otrzymano 4 lutego 2002 r.

