

5. Modelowanie własności stali szybkotnących

Głównym celem przeprowadzonych badań jest opracowanie metodyki projektowania nowych stali szybkotnących o wymaganych własnościach użytkowych. Przyjęto, że przy projektowaniu stali szybkotnących kryterium stanowić będą twardość oraz odporność na rozprzestrzenianie się pęknięć wyrażona wartością współczynnika intensywności naprężeń K_{Ic} . Dlatego też w pierwszej kolejności opracowano modele:

- twardości stali szybkotnących,
- odporności stali na pękanie wyrażonej wartością współczynnika intensywności naprężeń K_{Ic} .

Pierwszy opracowany model umożliwia obliczenie twardości stali szybkotnącej wyłącznie na podstawie składu chemicznego stali oraz parametrów obróbki cieplnej, tj. temperatury austenityzowania oraz odpuszczania. Do jego opracowania wykorzystano wyniki prac [62, 63, 114, 134, 216] nad wpływem pierwiastków stopowych na efekt twardości wtórnej, a także dane zawarte w katalogach oraz normach przedmiotowych dotyczących stali szybkotnących [110, 174]. Wyniki wcześniejszych prac [199] potwierdzają, że możliwe jest wykorzystanie danych katalogowych oraz z norm do opracowania założonego modelu, przez co zwiększa się jego adekwatność oraz uniwersalność.

Drugi opracowany model pozwala na określenie odporności na pękanie stali szybkotnących, wyrażonej wartością współczynnika K_{Ic} , na podstawie składu chemicznego stali oraz parametrów obróbki cieplnej bez konieczności wykonywania całego szeregu złożonych i czasochłonnych badań metaloznawczych. W tym przypadku wykorzystano wyniki badań własnych wybranych gatunków stali szybkotnących zestawionych w tabeli 4.

5.1. Modele twardości stali szybkotnących i ich weryfikacja

Przy opracowaniu modeli twardości wykorzystano wyniki badań przeprowadzonych na nowo opracowanych stalach szybkotnących, normach przedmiotowych oraz katalogach producentów. Szczegółowe informacje dotyczące stężeń pierwiastków stopowych dla

nowoopracowanych stali, zaczerpniętych z norm oraz z katalogów producentów stali, podano odpowiednio w tabelach 1-3. Zakres temperatury austenitowania, dla którego opracowano dane doświadczalne wynosi 1120°C-1280°C, natomiast zakres temperatury odpuszczania wynosi 480°C-630°C.

Wyniki badań uzupełniających nie były wykorzystane przy tworzeniu modeli, a posłużyły jedynie do ostatecznej weryfikacji doświadczalnej opracowanych modeli.

Jako narzędzi do opracowania modeli umożliwiających obliczenie twardości stali szybkoznących wyłącznie na podstawie składu chemicznego i temperatury austenitowania oraz temperatury odpuszczania zastosowano:

- metodę statystyczną regresji wielokrotnej,
- sztuczne sieci neuronowe.

Jako podstawowe założenie przyjęto wstępnie, że twardość stali zależy od stężeń podstawowych pierwiastków stopowych występujących w tych stalach: węgla, chromu, wolframu, molibdenu, wanadu i kobaltu, oraz temperatury austenitowania i odpuszczania.

W metodzie regresji wielokrotnej przyjęto ogólną postać równania - modelu:

$$HRC = \sum_{i=1}^k a_i f_i(X) \quad (2)$$

gdzie: a_i – współczynniki równania regresji, HRC - twardość stali, f_i - funkcje zmiennych równania, X - wektor zmiennych równania, ($X = [\% C, \% Cr, \dots, Ta, To]$).

W ramach badań rozpatrzono kilkadziesiąt postaci równania (2), a współczynniki a_i wyznaczono metodą regresji klasycznej (najmniejszych kwadratów).

W drugiej metodzie do obliczania twardości stali szybkoznących, zastosowano sztuczne sieci neuronowe typu perceptron wielowarstwowy wykorzystując różne metody uczenia. Przyjęto stałą liczbę neuronów wejściowych (8), jako konsekwencję podstawowego założenia, że twardość zależy od C, Cr, W, V, Co i Co oraz temperatury austenitowania i odpuszczania. Analizowane sieci posiadały 1 wyjście odpowiadające twardości stali. W badaniach modyfikowano liczbę warstw oraz neuronów ukrytych.

Adekwatność opracowanych modeli badano analizując błąd pomiędzy twardością obliczoną a odpowiadającą jej twardością zmierzoną doświadczalnie.

Jako kryterium przyjęto średni błąd dla testowanego zbioru danych:

$$R = \frac{\sum_{i=1}^N (|HRC_{oi} - HRC_{zi}|)}{N} \quad (3)$$

gdzie: N – liczebność zbioru testowego, HRC_{oi} – twardość obliczona (i -ta), HRC_{zi} – twardość zmierzona (i -ta).

Przyjęto, że adekwatnym jest model, który pozwoli na uzyskanie wartości błędu obliczeń ok. 1 HRC.

Model statystyczny

W oparciu o opracowany zbiór danych doświadczalnych przeanalizowano kilkadziesiąt fenomenologicznych modeli matematycznych do obliczania twardości stali na podstawie stężenia pierwiastków stopowych i temperatur obróbki cieplnej stali szybkotnących.

Wyniki analizy tych modeli matematycznych wskazują, że wykonane obliczenia twardości dla różnych postaci równania matematycznego zbiegają do wartości błędu obliczeń 0,7 HRC. Uznano zatem, że jest to graniczna dokładność obliczeń możliwa do uzyskania dla modelu matematycznego. Stąd też model (4) wykazujący błąd obliczeń 0,71 HRC uznano za najlepszy i zastosowano w dalszych analizach, m.i.n. obliczeń krzywych odpuszczania dla wybranych gatunków stali przedstawionych na rysunkach 31-37.

$$HRC = 5,1 \cdot C - 0,13 \cdot Cr - 0,06 \cdot W + 0,11 \cdot Mo - 0,81 \cdot V + 0,17 \cdot Co - 21,4 \cdot Ta - 1,63 \cdot To + 0,37 \cdot Ta^2 - 4,86 \cdot To^2 + 58,23 \sqrt{(ToTa)} - 23,46 \cdot (Ta/To) \quad (4)$$

Zwrócić należy uwagę, że w przypadku temperatur austenitowania i odpuszczania dokonano ich normalizacji poprzez podzielenie przez 100. Tak więc korzystając z opracowanych modeli matematycznych rzeczywista temperatura powinna być w ten sposób prezentowana jako zmienna w modelu. I tak np. jeżeli rzeczywista temperatura austenitowania wynosi 1200°C, to w modelu należy podać jej wartość po znormalizowaniu, czyli 12.

Model sieci neuronowej

W dalszej kolejności do modelowania twardości wtórnej zastosowano sztuczne sieci neuronowe. Podstawę do zaprojektowania sieci neuronowych stanowią wyniki badań eksperymentalnych zawierających informacje o składach chemicznych oraz badaniach twardości stali zestawionych w tablicach 14-16. W sumie dysponowano zbiorem 2714 wzorców, co można uznać za ilość wystarczającą do opracowania w pełni adekwatnego modelu sieci neuronowych.

W odniesieniu do struktury zaprojektowanych sieci neuronowych przyjęto założenie, że sieć posiada 8 wejść, odpowiadających wartości stężeń sześciu podstawowych pierwiastków stopowych występujących w tej grupie stali oraz temperaturom austenitowania i odpuszczania oraz jedno wyjście, odpowiadające twardości. Do zaprojektowania, uczenia i testowania sieci neuronowych użyto programu STATISTICA Neural Networks wersja 4.0 F firmy StatSoft.

Sieci neuronowe jako narzędzie do modelowania numerycznego, są narzędziem bardziej uniwersalnym i zdolnym do odwzorowań złożonych funkcji aniżeli zastosowana wcześniej metoda statystyczna regresji. Przystosowanie sieci neuronowych do wykonania określonego zadania nie wymaga bowiem precyzowania algorytmu i zapisywania go w postaci programu komputerowego lub postaci konkretnego modelu matematycznego. Proces ten zastępuje uczenie przy użyciu ciągu typowych pobudeń i odpowiadających im pożądanym reakcji.

W przypadkach, w których fizykalna natura zjawiska jest nie do końca poznana, szczególnie pożądana staje się podstawowa cecha sieci neuronowych, jaką jest zdolność do generalizacji, czyli uogólniania wiedzy dla nowych danych nie prezentowanych w trakcie nauki. Sieci neuronowe nie wymagają zgromadzenia i bieżącego dostępu do całej wiedzy na temat zagadnienia, wykazują tolerancję na nieciągłości, przypadkowe zaburzenia lub braki w zbiorze uczącym. Pozwala to na zastosowanie ich tam, gdzie pojawiają się problemy z przetwarzaniem i analizą danych, z ich klasyfikacją czy predykcją.

W modelu matematycznym sztucznego neuronu sygnały wejściowe neuronu są sumowane z odpowiednią wagą i poddawane działaniu nieliniowej funkcji aktywacji (np. typu skoku jednostkowego), co prowadzi do otrzymania sygnału wyjściowego y_i opisanego równaniem [153]:

$$y_i = f\left(\sum_{j=1}^N W_{ij} x_j\right) \quad (5)$$

gdzie: x_j ($j=1,2,\dots,N$) – sygnały wejściowe, W_{ij} - współczynniki wagowe (wagi), $f()$ – funkcja aktywacji.

Sieci neuronowe posiadają zdolności adaptacyjne, umożliwiające ich przystosowanie do wykonania konkretnego zadania przez dobór struktury i metody oraz parametrów uczenia. Podczas procesu uczenia następuje adaptacyjny dobór wag połączeń między elementami przetwarzającymi, umożliwiającą działanie sieci, polegające na odwzorowaniu danych wejściowych w wyjściowe z możliwie małym błędem. Odbywająca się w kolejnych cyklach adaptacja wag może być wyrażona zależnością [153]:

$$W_{ij}(n+1) = W_{ij}(n) + \Delta W_{ij}(n) \quad (6)$$

gdzie: n - numer cyklu uczącego, $W_{ij}(n)$ – poprzednia waga, $W_{ij}(n+1)$ – nowa waga łącząca neuron i -ty z j -tym.

Błąd działania sieci, okreśłany mianem błędu średniokwadratowego, opisuje równanie [153]:

$$Q(n) = \sum_{m=1}^{N_L} \varepsilon_i^{(L)^2}(n) = \sum_{i=1}^{N_L} (d_i^{(L)}(n) - y_i^{(L)}(n))^2 \quad (7)$$

gdzie: $\varepsilon_i^{(L)}$ – błąd na wyjściu i -tego neuronu warstwy ostatniej (L) sieci, $d_i^{(L)}$ – sygnał wzorcowy, $y_i^{(L)}$ – sygnał na wyjściu neuronu.

Uczenie sieci prowadzone jest w celu minimalizacji funkcji błędu. Do metod wykorzystywanych szczególnie często należy zaliczyć metody gradientowe. Informacje o kierunku najszybszego wzrostu funkcji błędu zawarte są w wektorze gradientu, który zbudowany jest z pochodnych cząstkowych funkcji błędu po poszczególnych wagach sieci. Wektory wag ulegają modyfikacji zgodnie z równaniem [153]:

$$W(n+1) = W(n) + \mu p(W(n)) \quad (8)$$


gdzie: $p(W(n))$ – kierunek minimalizacji funkcji błędu, μ – współczynnik uczenia.

Spośród algorytmów wykorzystywanych do uczenia sieci jednokierunkowych wielowarstwowych zastosowano metodę uczenia opartą na algorytmie wstecznej propagacji błędów. Sygnał błędów dla tej metody obliczany jest począwszy od warstwy wyjściowej, przez warstwy ukryte, w kierunku warstwy wejściowej. Dla określenia minimum funkcji błędów obliczana jest suma kwadratów błędów na wyjściu sieci zgodnie z równaniem (7). Wartości początkowe wag dobierane są zwykle w sposób losowy, a dla ich modyfikacji wykorzystywany jest algorytm najszybszego spadku. Tempo zmian wag modyfikowanych przez algorytm jest uzależnione od współczynnika uczenia. Mała wartość współczynnika uczenia prowadzi do niezwykle powolnej zbieżności, zapewnia jednak stabilniejszy i dokładniejszy przebieg procesu uczenia. Jeżeli powierzchnia błędów nie jest skomplikowana, to zwiększenie współczynnika uczenia pozwala na szybsze osiągnięcie akceptowalnego poziomu błędów nie zwiększając niebezpieczeństwa pominięcia jego minimum. Zwiększenie tempa uczenia sieci przy jednoczesnym zapewnieniu stabilności procesu, umożliwia wprowadzenie do modyfikacji wag dodatkowego czynnika określanego mianem momentu. Nowy kierunek poszukiwania minimum funkcji błędów, z zastosowaniem momentu, jest wyrażony przez sumę ważoną bieżącego gradientu i poprzednio znalezionej kierunku. Czynniki momentu pozwalają także niejednokrotnie na opuszczenie minimum lokalnej funkcji błędów, powodując zmianę wag prowadzącą do chwilowego wzrostu wartości tej funkcji.

Kolejnym, wykorzystanym algorytmem do uczenia sieci neuronowych, jest algorytm gradientów sprzężonych. Gradient błędów, obliczany w trakcie jednej epoki treningowej, jest sumą gradientów błędów dla każdego przypadku. W metodzie tej poszukiwanie minimum funkcji błędów odbywa się wzdłuż wybranych kierunków na powierzchni błędów. Dla funkcji jednej zmiennej proces ten przeprowadzany jest w dwóch etapach. W pierwszym, poszukiwane są trzy punkty, z których środkowy reprezentuje mniejszą wartość funkcji błędów od dwóch pozostałych. Drugi etap sprowadza się do zawężenia obszaru poszukiwań i trwa do momentu odnalezienia położenia minimum z zadowalającą dokładnością. Odnalezienie punktu minimalnego powoduje przejście algorytmu do następnego poszukiwania liniowego minimum funkcji błędów, realizowanego w kolejnej epoce wzdłuż prostej tworzącej z poprzednim kierunkiem kierunek sprzężony. Kolejny krok algorytmu gradientów sprzężonych nie powoduje pogorszenia uzyskanego wcześniej wyniku dzięki metodzie wyznaczania kierunków sprzężonych, gwarantującej zachowanie uzyskanych poprzednio minimów. Podstawą do wyznaczenia kierunków sprzężonych jest założenie, że funkcja błędów w pobliżu minimów

lokalnych jest w przybliżeniu kwadratowa. Aktualizacja wag jest przeprowadzana jednokrotnie w trakcie jednej epoki treningowej. Podstawę do modyfikacji wag stanowi wartość gradientu uśredniona względem wszystkich przypadków prezentowanych w jednej epoce. Uczenie sieci neuronowej przy pomocy algorytmu gradientów sprzężonych nie wymaga określania współczynnika uczenia ani wartości momentu. Wielkości występujące w tej metodzie, których rolę można porównać z momentem bezwładności i współczynnikiem uczenia nie są stałe, ale zmieniają się w sposób matematycznie optymalny [153].

Z wykorzystaniem programu Statistica Neural Network wygenerowano kilkaset sieci neuronowych o różnej liczbie neuronów w warstwach ukrytych. Część z nich została na wstępnym etapie projektowania wyeliminowana ze względu na zbyt duży błąd lub zbyt dużą liczbę neuronów w warstwach ukrytych. Po zakończeniu procesu uczenia lub w jego trakcie obserwowano wykres błędu uczenia każdej sieci. Na jego podstawie sprawdzano czy sieć nie uległa przeuczeniu, a sieci przeuczone zostały usunięte z dalszej analizy. Jako wskaźniki jakości sieci przyjęto średni błąd bezwzględny, iloraz odchyłeń standardowych oraz współczynnik korelacji. Ostatecznie spośród całego zbioru opracowanych sieci przyjęto jedną - perceptron wielowarstwowy o strukturze 8-7-1 (tzn. 8 wejść, 7 neuronów w warstwie ukrytej, 1 wyjście), o średnim błędzie obliczeń wynoszącym 0,59 HRC. Wskaźniki jakości opracowanej sieci zestawiono w tabeli 17.




Rys. 36. Struktura najlepszej opracowanej sieci neuronowej MLP 8-7-1

Tabela 17.
Wskaźniki jakości opracowanej sieci neuronowej do obliczania twardości stali


Struktura sieci	Metoda uczenia/liczba epok treningowych	Zbiór		
		uczący	walidacyjny	testowy
		Średni błąd bezwzględny, HRC		
MLP 8-7-1	BP/50 CG/462	0,53	0,57	0,59
		Iloraz odchyłeń standardowych		
		0,23	0,25	0,27
		Współczynnik korelacji		
		0,97	0,97	0,96
BP – wsteczna propagacja błędów				
CG – gradienty sprzężone				

Opracowane modele twardości poddano dodatkowej weryfikacji, w oparciu o wyniki badań uzupełniających opisanych w punkcie 4.1. Z wykorzystaniem opracowanych modeli wykonano obliczenia twardości dla stali o składach chemicznych podanych w tabeli 4. Następnie oszacowano błąd obliczeń zgodnie z równaniem (3), który dla modelu statystycznego oraz sieci neuronowej wynosi odpowiednio 0,99 HRC oraz 1,01 HRC. Należy więc uznać, że opracowane modele w pełni spełniają przyjęte założenia dokładności obliczeń. Na rysunkach 37-39 przedstawiono porównanie wyników obliczeń weryfikacyjnych. Natomiast na rysunkach 40-42 przedstawiono porównanie obliczonych oraz doświadczalnych krzywych odpuszczania dla sześciu stali spośród tworzących w zbiór danych wykorzystanych do opracowania modeli.

5. Modelowanie własności stali szybkotnących




Rys. 37. Porównanie wyników doświadczalnych i obliczeń twardości z zastosowaniem opracowanej sieci neuronowej oraz modelu matematycznego dla stali HS6-5-2




Rys. 38. Porównanie wyników doświadczalnych i obliczeń twardości z zastosowaniem opracowanej sieci neuronowej oraz modelu matematycznego dla stali HS18-0-1

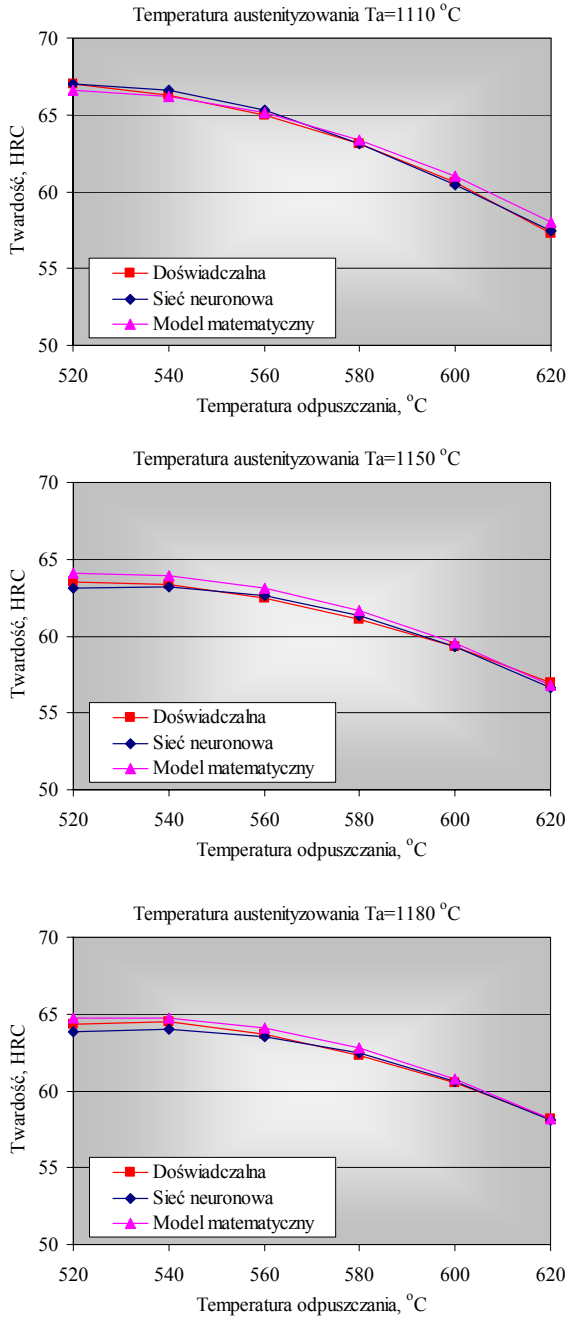
5. Modelowanie własności stali szybkotnących




Rys. 39. Porównanie wyników doświadczalnych i obliczeń twardości z zastosowaniem opracowanej sieci neuronowej oraz modelu matematycznego dla stali HS10-4-3-10



Rys. 40. Porównanie wyników doświadczalnych i obliczeń twardości z zastosowaniem opracowanej sieci neuronowej oraz modelu matematycznego dla stali typu 9-2-2+Si



Rys. 41. Porównanie wyników doświadczalnych i obliczeń twardości z zastosowaniem opracowanej sieci neuronowej oraz modelu matematycznego dla stali HS3-3-2



Rys. 42. Porównanie wyników doświadczalnych i obliczeń twardości z zastosowaniem opracowanej sieci neuronowej oraz modelu matematycznego dla stali HS2-9-1-8

5.2. Model odporności na pękanie stali szybkotnących

Spośród nielicznych modeli przedstawionych w literaturze pozwalających na ocenę odporności na pękanie różnych materiałów, wskazanych w punkcie 1.2, jedynie jeden opisany w pracy [132] ma zastosowanie dla stali szybkotnących. Umożliwia on obliczanie współczynnika K_{IC} stali szybkotnących na podstawie twardości i parametrów opisujących mikrostrukturę (udziału węglików f_{carb} , udziału austenitu szcążkowego f_{aust} oraz od średniej odległości między węglkami d_p) zgodnie z zależnością:

$$K_{IC} = 1,363 \left(\frac{HRC}{HRC - 53} \right) \cdot \left[\sqrt{E \cdot d_p} \cdot (f_{carb})^{-1/6} \cdot (1 + f_{aust}) \right] \quad (9)$$

gdzie: f_{aust} – udział austenitu szcążkowego, f_{carb} – udział węglików, E – moduł Younga stali, d_p – średnia odległość między węglkami, HRC – twardość stali w skali C Rockwella .

Średnia odległość między węglkami d_p może być obliczona wg zależności [132]:

$$d_p = D_p (1 - f_{carb}) \cdot \sqrt{\frac{2}{3} \cdot f_{carb}} \quad (10)$$

gdzie: D_p - średnia średnica węglików.

Badania nad modelowaniem odporności na pękanie rozpoczęto od weryfikacji modelu (9). W tym celu przeprowadzono obliczenia testowe dla wybranych gatunków stali dla różnych stanów obróbki cieplnej. Wykorzystano przy tym wyniki badań struktury, opisanych w punkcie 4.3 i dodatkowo wyniki badań wykonanych rentgenowskich metodą Averbacha-Cohena udziału austenitu szcążkowego.

Wyniki przeprowadzonych badań weryfikacyjnych wskazały na niepełną trafność tego modelu, gdyż błąd względny oceny wartości współczynnika K_{IC} wynosił nawet do 50% jego wartości eksperymentalnej. Należy nadmienić, że model (9) został opracowany w oparciu o wyniki badań stali szybkotnącej M2 (HS 6-5-2) poddanej obróbce cieplnej w próżni w ograniczonym zakresie temperatury odpuszczania (jedynie 500 i 540 °C). Zamieszczone wyniki badań mikrostruktury wskazują, że udział martenzytu szcążkowego w tej stali w zależności od wariantu obróbki cieplnej wynosi od 1,1% do 25,7%. W przypadku

konwencjonalnych stali szybkociągłych poddanych obróbce cieplnej w kąpielach solnych udział martenzytu szczątkowego po dwukrotnym odpuszczaniu jest pomijalny lub jest na progu wykrywalności metod rentgenowskich [39]. Wydaje się, że właśnie to stanowić może przyczynę dużych błędów w ocenie wartości współczynnika K_{Ic} . Ponadto zastosowanie tego modelu do oceny odporności na pękanie wiąże się z koniecznością wykonywania całego szeregu złożonych i czasochłonnych badań metaloznawczych, co stanowiło bezpośrednią przyczynę zaniechania dalszych prac z jego wykorzystaniem do modelowania współczynnika intensywności naprężeń K_{Ic} .

Dlatego dalsze prace miały na celu opracowanie modelu pozwalającego na określenie odporności na pękanie stali szybkociągłych wyłącznie na podstawie składu chemicznego stali oraz parametrów obróbki cieplnej, na podstawie wyników badań opisanych w punkcie 3.

Jako narzędzia do modelowania zastosowano sztuczne sieci neuronowe. W odniesieniu do struktury zaprojektowanych sieci neuronowych, analogicznie jak dla w przypadku modelowania twardości, przyjęto założenia, że sieć posiada 8 wejść, odpowiadających wartości stężeń sześciu podstawowych pierwiastków stopowych występujących w tej grupie stali oraz temperaturom austenitowania i odpuszczania, oraz jedno wyjście, odpowiadające wartości współczynnika intensywności naprężeń K_{Ic} ,

Do zaprojektowania, uczenia i testowania sieci neuronowych użyto programu STATISTICA Neural Networks wersja 4.0 F firmy StatSoft. Po wprowadzeniu danych uczących do programu przystąpiono do procesu projektowania sieci neuronowej.

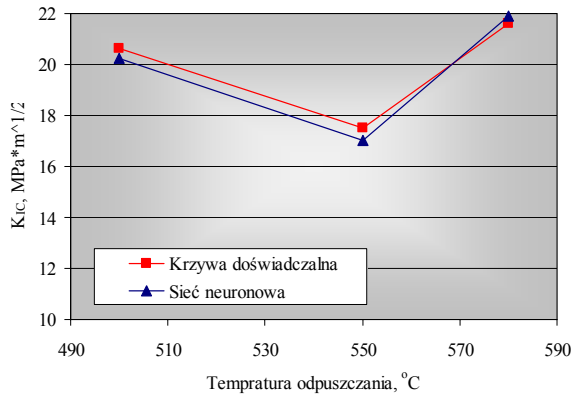
Przy pomocy programu wygenerowano kilkadziesiąt sieci neuronowych o różnej ilości neuronów w warstwie ukrytej. Około połowa z nich została od razu wyeliminowana ze względu na zbyt duży błąd lub zbyt dużą liczbę neuronów w warstwach ukrytych. Po zakończeniu procesu uczenia lub w jego trakcie obserwowano wykres błędu uczenia każdej sieci. Na jego podstawie sprawdzano czy sieć nie uległa przeuczeniu, a sieci przeuczone zostały usunięte z dalszej analizy. Jako wskaźniki jakości sieci przyjęto średni błąd bezwzględny, iloraz odchyłeń standardowych oraz współczynnik korelacji. Ostatecznie spośród całego zbioru opracowanych sieci przyjęto jedną - perceptron wielowarstwowy o strukturze 8-6-1 (tzn. 8 wejść, 6 neuronów w warstwie ukrytej, 1 wyjście), o średnim błędzie obliczeń wynoszącym $0,39 \text{ MPa}\cdot\text{m}^{1/2}$. Wskaźniki jakości opracowanej sieci zestawiono w tabeli 18. Na rysunkach 44-54 przedstawiono porównanie obliczeń współczynnika K_{Ic} z danymi doświadczalnymi.

Tabela 18


Wskaźniki jakości opracowanej sieci neuronowej do obliczania współczynnika K_{Ic}

Struktura sieci	Metoda uczenia/liczba epok treningowych	Zbiór	
		uczący	walidacyjny
MLP 8-6-1	BP/50 CG/56	Średni błąd bezwzględny, MPa·m ^{1/2}	
		0,39	0,39
		Iloraz odchyłeń standardowych	
		0,15	0,22
		Współczynnik korelacji	
		0,99	0,98


BP – wsteczna propagacja błędów; CG – gradienty sprzężone




Rys. 43. Porównanie obliczeń współczynnika K_{Ic} z danymi doświadczalnymi dla stali HS6-5-2, temperatura austenitizowania $T_a=1150^\circ\text{C}$



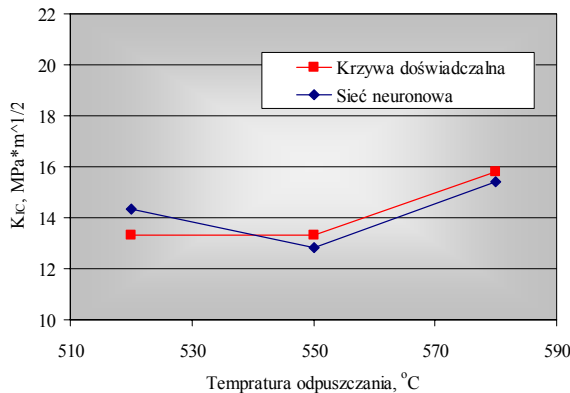
Rys. 44. Porównanie obliczeń współczynnika K_{Ic} z danymi doświadczalnymi dla stali HS6-5-2, temperatura austenitizowania $T_a=1190^\circ\text{C}$



Rys. 45. Porównanie obliczeń współczynnika K_{Ic} z danymi doświadczalnymi dla stali HS6-5-2, temperatura austenitzowania $T_a=1225^\circ\text{C}$




Rys. 46. Porównanie obliczeń współczynnika K_{Ic} z danymi doświadczalnymi dla stali HS18-0-1, temperatura austenitzowania $T_a=1180^\circ\text{C}$




Rys. 47. Porównanie obliczeń współczynnika K_{Ic} z danymi doświadczalnymi dla stali HS18-0-1, temperatura austenitzowania $T_a=1220^\circ\text{C}$


5. Modelowanie własności stali szybkotnących




Rys. 48. Porównanie obliczeń współczynnika K_{Ic} z danymi doświadczalnymi dla stali HSI8-0-1, temperatura austenitizowania $T_a=1255^\circ\text{C}$



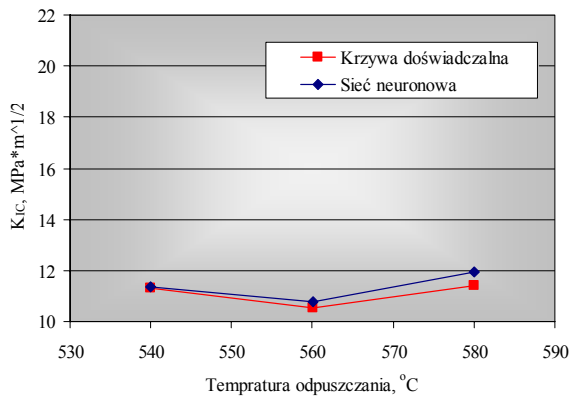
Rys. 49. Porównanie obliczeń współczynnika K_{Ic} z danymi doświadczalnymi dla stali HSI8-0-1, temperatura austenitizowania $T_a=1280^\circ\text{C}$




Rys. 50. Porównanie obliczeń współczynnika K_{Ic} z danymi doświadczalnymi dla stali HSI10-4-3-10, temperatura austenitizowania $T_a=1180^\circ\text{C}$



Rys. 51. Porównanie obliczeń współczynnika K_{Ic} z danymi doświadczalnymi dla stali HS10-4-3-10, temperatura austenitowania $T_a=1200^{\circ}\text{C}$



Rys. 52. Porównanie obliczeń współczynnika K_{Ic} z danymi doświadczalnymi dla stali HS10-4-3-10, temperatura austenitowania $T_a=1225^{\circ}\text{C}$



Rys. 53. Porównanie obliczeń współczynnika K_{Ic} z danymi doświadczalnymi dla stali HS10-4-3-10, temperatura austenitowania $T_a=1240^{\circ}\text{C}$