

ZESZYTY STUDENCKICH KÓŁ NAUKOWYCH

Zastosowanie sztucznych sieci neuronowych do symulacji wpływu wybranych pierwiastków na hartowność stali

A. Skorupa^a, W. Sitek^b, J.Trzaska^b

^a Student Politechniki Śląskiej, Wydział Mechaniczny Technologiczny, Kierunek Inżynieria Materiałowa

^b Politechnika Śląska, Wydział Mechaniczny Technologiczny, Instytut Materiałów Inżynierskich i Biomedycznych
email: wojciech.sitek@polsl.pl, jacek.trzaska@polsl.pl

Streszczenie: Tematem tej pracy było opracowanie modeli sieci symulujących wpływ stężeń masowych pierwiastków na twardość hartowanej stali konstrukcyjnej i maszynowej. W tym celu zostały wykorzystane sztuczne sieci neuronowe. Badanie zostały przeprowadzone w trzech etapach. W pierwszym etapie sieci neuronowe zostały nauczone w oparciu o zbiór danych uzyskany metodami eksperymentalnymi. Kolejny etap polegał na wyborze najlepszych modeli sieci neuronowych. Na końcu została wykonana symulacja wpływu węgla oraz pierwiastka stopowego (miedzi, chromu, molibdenu, manganu, krzemu, niklu) na twardość stali. Badania wykonano dla trzech różnych stężeń pozostałych pierwiastków stopowych: średnim, średnim pomniejszonym o odchylenie standardowe, średnim powiększonym o odchylenie standardowe. Po dokonaniu analizy można było stwierdzić, że zbiór danych składał się z za małej liczby.

Abstract: Subject of this study was to develop artificial neural network models to simulate the impact of the mass concentration of the elements on the hardness of construction and machine steel. For this purpose, artificial neural network has been used. The study was performed in three stages. In the first stage, neural network has been trained on the basis of a set of data obtained by experimental methods. In the next step, has been selected the best models of neural networks. At the end, has been made computer simulation the impact of carbon and alloying element (copper, chromium, molybdenum, manganese, sulfur and nickel) on the hardness of steel. Research has been done in three different concentrations of the rest of the alloying elements: average concentration, average concentration reduced by the standard deviation and average concentration augmented by the standard deviation. After analysis, it could be seen that the data set consisted of a small number of data.

Słowa kluczowe: sztuczne sieci neuronowe, predykcja twardości, hartowność stali, symulacja komputerowa

1. WSTĘP

1.1.Sztuczne sieci neuronowe i ich historia

Omawiając sztuczne sieci neuronowe należy zadać sobie pytanie: „kiedy można powiedzieć, że system stworzony przez człowieka jest inteligentny?”. Za zwiastun sztucznych sieci neuronowych można uznać model sieci zbudowanej z sztucznych neuronów opisany przez Warrena S. McCullocha oraz Waltera Pittsa w 1943 roku. Już w 1957 roku została zbudowana przez Franka Rosenblatta oraz Charlesa Wightmana najprostsza sieć neuronowa, typu perceptron. Układ ten był częściowo elektryczny, a częściowo elektromechaniczny. Zadaniem pierwszej sieci neuronowej, opracowanej przez człowieka, było rozpoznawanie znaków alfanumerycznych wraz z procesem uczenia, który funkcjonował jako metoda programowania systemu. Niestety sieć ta nie działała całkiem dobrze, układ chociaż uczył się poprawnie, miał kłopoty z nieco bardziej złożonymi znakami. W latach 70. zainteresowanie tematem sieci neuronowych gwałtownie uległo zmniejszeniu na skutek publikacji Marvina Minsky'ego i Seymoura Paperta, która dowodziła że metoda perceptronów ma niezwykle małe, ograniczone zastosowanie, m.in. poprzez brak możliwości obliczenia funkcji logicznej XOR. Dowody przedstawione przez Minsky'ego oraz Paperta zablokowały finansowanie badań dotyczących sieci neuronowych w USA. Jednakże badania były nadal prowadzone, na mniejszą skalę, co zaowocowało publikacją szeregu rezultatów udowadniających, że sztuczne sieci neuronowe dają możliwość rozwiązywania wielu złożonych problemów. Dopiero po 15 latach, w 1987 roku, sieci neuronowe znów stały się obiektem szerszych zainteresowań. W tamtym roku odbyła się niezwykle ważna konferencja First International Conference on Neural Network (Pierwsze Międzynarodowa Konferencja o Sieciach Neuronowych) w San Diego. W latach 80. powstały prace naukowe na temat obiecujących się dobrze nieliniowych wielowarstwowych sieci neuronowych. W tym okresie powstało wiele neurokomputerów, takich jak: Mark III, Anza czy Parallon [4, 7]. Obecnie sztuczna inteligencja, ciągle badana i udoskonalana, znalazła wiele zastosowań. Poprzez zagadnienia dotyczące sztucznej inteligencji, przy użyciu różnych technik komputerowych można rozwiązać wiele problemów, również z dziedzin niesformalizowanych, czyli dziedzin, które nie wykazują się podbudową matematyczną, takich jak medycyna czy prawo. Może ona przyjąć wiele form [7]

1.2.Definicja i zastosowanie sztucznych sieci neuronowych

Sztuczne sieci neuronowa są uniwersalnym narzędziem do modelowania przeznaczonym do rozwiązywania różnej klasy zadań, takich jak: klasyfikacja, regresja, prognozowanie szeregów czasowych czy autoasocjacja [1, 9].

Do sieci neuronowych wprowadza się pewne zmienne wejściowe (czyli dane), jej wyjścia zaś definiują zmienne wyjściowe (czyli rozwiązania). Sieci neuronowe posiadają umiejętność uczenia się podstawie dostarczonych przykładów. Dlatego też mogą one być stosowane m.in. wszędzie tam, gdzie na podstawie pewnych znanych faktów wnioskuje się o nieznanymi informacjach. Sieci neuronowe wykazują wiele zalet do których można zaliczyć [5]:

- łatwość w użytkowaniu,
- umiejętność generalizowania zdobytej wiedzy,
- szeroki zakres zastosowań,

- możliwość rozwiązywania problemów pomimo braku znajomości analitycznej zależności między danymi wejściowymi oraz wyjściowymi.

Nie są one również pozbawione wad, takich jak [5]:


- możliwość przeuczenia sieci neuronowej,
- problematyczny wybór architektury sieci neuronowej oraz interpretacji wyników dla niedoświadczonego użytkownika,
- podawanie przybliżonych wyników obliczeń.

Sieć neuronowa to zbiór prostych procesów (zwanymi też neuronami) połączonych w odpowiedni sposób. Jest to również technika modelowania, która jest zdolna do odwzorowania niezwykle skomplikowanych funkcji. Wzbudza ona duże zainteresowanie, gdyż znalazła zastosowanie w rozwiązywaniu szerokiego zakresu problemów. Można jej używać tam, gdzie pojawiają się problemy z predykcją, klasyfikacją oraz sterowaniem. Przykładami zastosowań sztucznych sieci neuronowych są [10]:

- prognozowania cen akcji,
- prognozowania ryzyka, w momencie udzielenia kredytu,
- diagnostyki układów elektrycznych,
- dobór surowców,
- rozpoznawanie pisma,
- optymalizacja procesu leczenia,
- systemy identyfikujące sygnały,
- tworzenie gier komputerowych.

1.3. Budowa i działanie sztucznych sieci neuronowych

Podstawowym elementem systemu nerwowego jest komórka nerwowa, czyli neuron. Neuron składa się z ciała komórki (somy) oraz otaczających go dwóch typów wypustek. Jednym z rodzajów wypustek są dendryty, które wprowadzają informacje do neuronu, natomiast jedyna wypustka przekazująca dalej dane została nazwana aksonem. Za pomocą aksonów neuron przesyła impulsy dalej, do wielu innych neuronów. Informacje przekazywane są przez synapsy, które wzmacniają bądź osłabiają pobudzenie. Komórka nerwowa sumuje impulsy pobudzające i hamujące, w celu sprawdzenia czy ich suma algebraiczna przekracza pewną wartość progową. Jeżeli warunek jest spełniony, to sygnał na wyjściu neuronu jest przesyłany dalej do kolejnej komórki nerwowej. Budowę komórki nerwowej przedstawiono na rys.1 [6, 8].



Rys. 1. Budowa komórki nerwowej; 1- soma, 2- dendryty, 3- akson, 4- synapsy [6]
 Fig. 1. Construction of a nerve cell; 1- soma, 2- dendrites, 3- axon, 4- synapse [6]

Sztuczna sieć neuronowa jest bardzo uproszczonym modelem struktury mózgu, opartym na opracowanym w 1943 r. przez W. S. McCullocha i W. Pittsa modelu neuronu biologicznego w postaci sztucznego neuronu, którego schemat zaprezentowano na rys. 2. Sygnały wejściowe X_0, X_1, \dots, X_n odpowiadają impulsom nerwowym przesyłanym przez inne komórki nerwowe, przy czym przyjmuje się, że $X_0 = 1$. Tworzą one wektor wejściowy $X = (X_0, X_1, \dots, X_n)$. By móc obliczyć siłę oddziaływania sygnałów wejściowych na neuron, wprowadzono funkcję potencjału postsynaptycznego g . Przyjmuje się, że ma ona wartość sumy tzn. sygnały wejściowe są mnożone przez wagi synaptyczne: W_0, W_1, \dots, W_n tworzące wektor wag: $W = (W_0, W_1, \dots, W_n)$. Wagi synaptyczne odgrywają rolę regulatora własności transmisyjnych synaps neuronu występującego w organizmach żywych, co sprawia, że jedne z wejść do sztucznego neuronu odpowiadają synapsom pobudzającym, natomiast inne synapsom hamującym. Mnożenie sygnałów wejściowych przez wagi synaptyczne odpowiada osłabieniu i wzmocnieniu sygnału napływającego do neuronu. Po przemnożeniu sygnału wejściowego przez wagi następuje ich zsumowanie, które daje wynik sygnału v (1):

$$v = g(W, X) = \sum_{i=0}^n W_i X_i \quad (1)$$

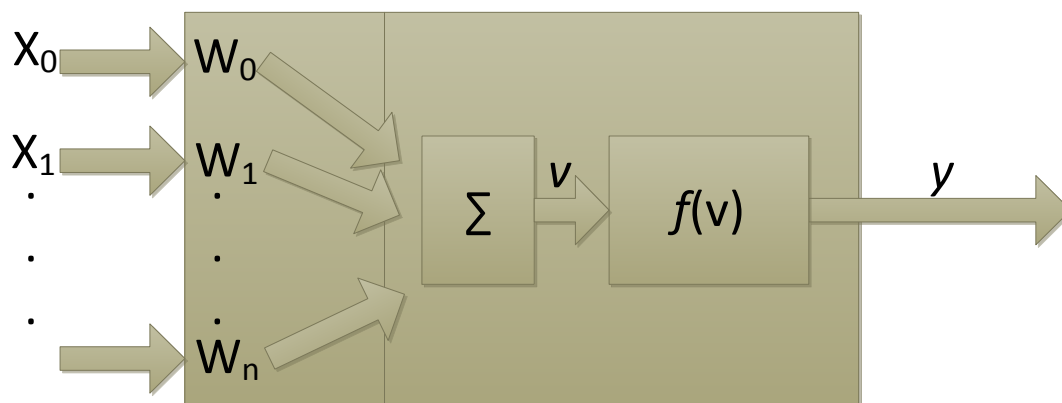
Otrzymany sygnał odpowiada sumarycznej sile pobudzeniowego potencjału postsynaptycznego. Następnie należy sprawdzić, czy sygnał osiągnął wartość progową, czyli wartość konieczną do aktywacji neuronu. Do sprawdzenia używa się funkcji aktywacji f , która dla sygnału v generuje sygnał wyjściowy y z neuronu (2):

$$y = f(v) \quad (2)$$

W. S. McCulloch i W. Pitts zastosowali funkcję skokową Heavside'a jako funkcję aktywacji, która jest oznaczana jako $1(v)$ oraz zdefiniowana w poprzez (3):

$$1(v) = \begin{cases} 1, & \text{jeśli } v \geq 0 \\ 0, & \text{jeśli } v < 0 \end{cases} \quad (3)$$

Zgodnie z tym równaniem funkcja skokowa Heaviside'a dla wartości sygnału mniejszych od zera daje 0, natomiast dla wartości większych przypisuje 1. Trzecią, w kolejności przetwarzania sygnałów, funkcją w modelu neuronu jest funkcja wyjścia [6, 10].



Rys. 2. Schemat budowy sztucznego neuronu [6]

Fig. 2. Scheme of construction of an artificial neuron [6]

1.4. Uczenie sztucznych sieci neuronowych

Sztuczne sieci neuronowe, a w szczególności pojedyncze neurony, można uczyć, podobnie jak mózg ludzki, który posiada tę zdolność. Celem nauki jest wprowadzenie wektora na wejście neuronu, tak by neuron mógł poprawnie reagować na pokazane wzorce. Proces nauki rozpoczyna się od losowego zainicjowania wektora wag oraz ustawienie ciągu uczącego na wejściu danego neuronu. Następnie jest wprowadzany następny wektor. Dla nowego wektora zostanie obliczony sygnał oraz funkcja wyjścia. Główną ideą procesu nauki neuronu jest poprawienie wag zależnie od jego reakcji na pokazany wzorec. Po poprawieniu wag zostaje wprowadzony kolejny wektor ciągu uczącego. W momencie pokazania neuronowi wszystkich wektorów ciągu uczącego, można dopiero stwierdzić, czy neuron został poprawnie nauczony rozpoznawania wzorców. Poprawnie nauczony neuron przyjmuje takie wagi, że otrzymywana jest prawidłowa reakcja na wzorce. Gdy otrzymany wynik jest niezadawalający należy powtórzyć cały proces nauki od początku. Ogólny schemat procesu uczenia neuronu został zaprezentowany na rys. 3. [4, 5, 6].

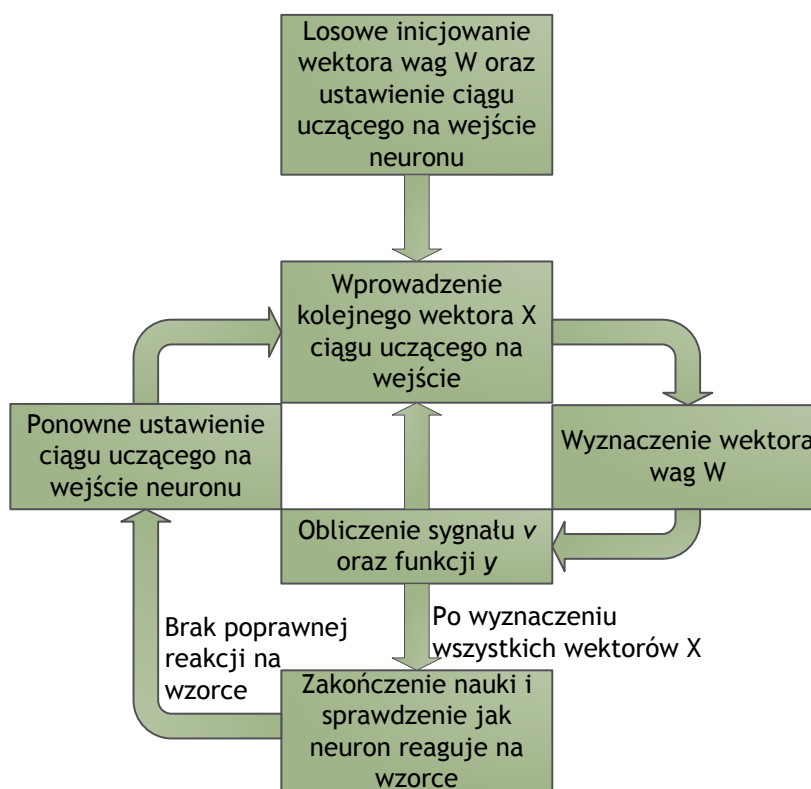
Istnieją dwie główne grupy technik nauki neuronu. Są nimi:

- uczenie z nauczycielem,
- uczenie bez nauczyciela.

W pierwszej technice nauczania ciąg uczący przyjmuje postać (4):

$$U = ((X(1), u(1)), (X(2), u(2)), \dots, (X(M), u(M))) \quad (4)$$

dla której $X(j) = (X_0(j), X_1(j), \dots, X_n(j))$, $j = 1, \dots, M$ jest wektorem wejściowym o numerze j , natomiast $u(j)$ to sygnał, który zgodnie z wymaganiami wygenerować powinien neuron po pokazaniu mu tego wektora. Jeżeli dla każdego wzorca $X(j)$ jest generowany sygnał wyjściowy $y(j)$ równy żądanemu sygnałowi $u(j)$, to można stwierdzić poprawną reakcję neuronu na wzorce.



Rys. 3. Ogólny schemat procesu nauczaniu neuronu [6]

Fig. 3. The general scheme of the process of neuron teaching [6]

W przypadku nauki bez nauczyciela dla ciągu (5):

$$U = (x(1), x(2), \dots, x(M)) \quad (5)$$

neuron musi samodzielnie zmienić swoje wagi, tak by dla podobnych wzorców generować taki sam sygnał wyjściowy, natomiast dla różnych wzorców inne sygnały wyjściowe [1, 6].

1.5. Hartowność stali

Hartowność, określana inaczej jako podatność stali na hartowanie, to miara przyrostu twardości w wyniku procesu hartowania. Hartowanie to proces polegający na nagraniu warstwy wierzchniej przedmiotu do temperatury hartowania, a następnie gwałtownym chłodzeniu w ośrodku chłodzącym takim jak olej lub woda. Hartowność jest jednym z głównych kryteriów doboru stali konstrukcyjnej [2, 3].

Na hartowność stali mają wpływ [2, 3]:

- utwardzalność,
- przehartowność.

Utwardzalność jest miarą zależności największej możliwej do uzyskania twardości po hartowaniu od warunków austenitizowania. Jej wartość jest zależna od warunków austenitizowania oraz stężenia masowego węgla w austenicie.

Przehartowność, czyli zależność przyrostu twardości w procesie hartowania od szybkości chłodzenia, zależy od stężenia masowego węgla oraz pierwiastków stopowych w roztworze stałym podczas austenitizowania. Ponadto na przehartowność ma wpływ

jednorodność austenitu i wielkość ziarna. Miarą przehartowności jest krytyczna szybkość hartowania [2, 3].

W celu określenia hartowności stali jest stosowana m.in. próba Jominy'ego hartowania od czoła. Polega ona na ochładzaniu przez strumień wody czołowej powierzchni próbki, która ma kształt walca o średnicy 25 mm oraz długości 100 mm. Na materiałach zahartowanych tym sposobem wykonuje się pomiary twardości wzdłuż zeszlifowanych tworzących próbki w odległości co 2 mm, zaczynając na czole próbki. Kolejnym krokiem jest sporządzenie wykresu zależności twardości od odległości od czoła próbki. Na wykresie tym, zwanym krzywą hartowności, po naniesieniu wyników pomiarów z dwóch przeciwległych tworzących, powstaje obszar między maksymalnymi oraz minimalnymi wartościami twardości. Obszar ten nazywa się pasmem hartowności. Hartowność służy jako jedno z kryterium doboru stali konstrukcyjnej [3].

2. PRACA WŁASNA

2.1. Materiał i metody obliczeń

Do opracowania modelu sieci neuronowych, których zadaniem jest predykcja wpływu stężeń poszczególnych pierwiastków stopowych na twardość stali w odległości 3 mm od czoła próbki, został użyty odpowiednio przygotowany zbiór danych. Składa się on z 150 wytopów stali konstrukcyjnej i maszynowej różniących się od siebie stężeniem takich pierwiastków jak: węgiel, mangan, krzem, chrom, nikiel, molibden oraz miedź. Dla każdego gatunku stali zostały wykonane pomiary twardości w odległości 3 mm od czoła próbki.

W tabelicy 1. została przedstawiona analiza statystyczna wykonana dla pierwiastków wykorzystywanych w zbiorze danych. Zakres stężeń masowych stanowi jednocześnie zakres zmian zmiennych niezależnych, w którym można stosować opracowany w niniejszej pracy model. Na podstawie tabelicy 2. można stwierdzić, że korelacja pomiędzy zmiennymi wejściowymi nie ma większego wpływu na odpowiedź modelu.

Tablica 1. Analiza statystyczna stężeń wykonana dla poszczególnych pierwiastków
Table 1. Statistical analysis performed for the concentrations of individual elements

Pierwiastek	C	Mn	Si	Cr	Ni	Mo	Cu
Wartość maksymalna [%]	0,62	1,21	0,37	1,70	1,50	0,43	0,32
Wartość minimalna [%]	0,12	0,49	0,13	0,09	0,04	0,01	0,07
Mediana [%]	0,27	0,72	0,25	1,03	0,17	0,16	0,16
Wartość średnia [%]	0,31	0,81	0,26	0,98	0,36	0,14	0,17
Odchylenie stand. [%]	0,12	0,23	0,04	0,30	0,30	0,10	0,05

Tablica 2. Korelacja poszczególnych pierwiastków
 Table 2. Correlation of individual elements

	C	Mn	Si	Cr	Ni	Mo	Cu
C	1						
Mn	-0,537	1					
Si	-0,004	0,233	1				
Cr	-0,403	0,035	-0,124	1			
Ni	-0,177	-0,441	-0,101	0,292	1		
Mo	-0,338	-0,262	-0,066	0,242	0,482	1	
Cu	0,216	-0,175	-0,021	-0,283	-0,061	0	1

Cały zbiór danych został losowo podzielony na trzy mniejsze podzbiory: uczący, walidacyjny i testujący. W skład każdego podzbioru wchodziła następująca liczba wytopów:

- zbiór uczący- 75 wytopów (50%),
- zbiór walidacyjny- 37 wytopów (24,67%),
- zbiór testowy- 38 wytopów (25,33%).

Do opracowania modeli zależności między składem chemicznym stali, a twardością w określonej odległości od czoła próbki Jominy zastosowano sztuczne sieci neuronowe. Przyjęto rodzaj sieci MLP z jedną warstwą ukrytą o liczbie neuronów w warstwie wejściowej uzależnionej od liczby zmiennych niezależnych, tj. stężeń masowych pierwiastków. Twardość stali określono na podstawie poziomu aktywacji neuronu w warstwie wejściowej. Obliczenia przeprowadzono dla różnej liczby neuronów w warstwie ukrytej. Analizowano wpływ liczby neuronów na przyjęte wskaźniki oceny jakości działania sieci neuronowych. Sieć oceniano na podstawie:

- średniego błędu bezwzględnego,
- ilorazu odchylenia standardowego,
- współczynnika korelacji.

Wartości tych wskaźników powinny być zbliżone dla zbiorów uczącego, walidacyjnego i testowego. Oczekiwane wartości to:

- średni błąd bezwzględny- jak najmniejszy,
- iloraz odchylenia standardowego- 0,
- współczynnik korelacji- 1.

Podczas procesu projektowania sieci neuronowych ustalono następujące parametry:

- liczbę neuronów w warstwie ukrytej,
- metodę skalowania zmiennych,
- funkcję błędu,
- funkcje aktywacji,
- funkcję potencjału postsynaptycznego,
- metody i parametry uczenia.

2.2. Wyniki obliczeń

Dla badanej odległości od czoła próbki opracowano trzy modele sztucznych sieci neuronowych o różnej liczbie neuronów w warstwie ukrytej. Analizowano liczbę neuronów w zakresie do ośmiu. Liczę neuronów w warstwie ukrytej ograniczono ze względu na liczbę przypadków w zbiorze uczącym. Wymagana liczba przykładów uczących zależy od liczby połączeń (wag) między neuronami w sieci. Sieci neuronową uczono metodą wstecznej propagacji błędu (BP) i metodą gradientów sprzężonych (CG), liczbę epok treningowych dobierano eksperymentalnie. Zastosowano metodę skalowania min-max, która umożliwia przeskalowanie wartości wejściowej proporcjonalnie do przedziału [0, 1]. Została zastosowana funkcja błędu w postaci sumy kwadratów. Dla warstwy pierwszej oraz trzeciej została użyta liniowa z nasyceniem funkcja aktywacji. W warstwie drugiej wykorzystano z liniową funkcję aktywacji. Zastosowano liniową funkcję potencjału postsynaptycznego PSP dla wszystkich trzech warstw. Charakterystykę trzech wybranych sieci neuronowych dla badanej odległości od czoła próbki przedstawiono w tablicach 3-5.

Sieć X3.8.2 przedstawiona w tablicy 3. została wybrana jako najlepsza. Wszystkie sieci wykazują dość dobre własności, jednakże sieci z tablic 4. oraz 5. posiadają większe różnice wartości odchylenia oraz jego ilorazu pomiędzy poszczególnymi zbiorami.

Tablica 3. Charakterystyka sztucznej sieci neuronowej (sieć X3.8.2)

Table 3. Characteristics of artificial neural network (network X3.8.2)

Nazwa sieci	Sieć X3.8.2		
Struktura sieci	7-5-1		
Metoda i parametry uczenia sieci	BP50, CG120		
Rodzaj zbioru	Uczący	Walidacyjny	Testowy
Średni błąd bezwzględny, HRC	0,73	0,75	0,93
Odchylenie standardowe błędu, HRC	1,02	0,97	1,19
Iloraz odchylenia	0,155	0,152	0,177
Korelacja	0,988	0,989	0,984

Tablica 4. Charakterystyka sztucznej sieci neuronowej (sieć X3.5.2)

Table 4. Characteristics of artificial neural network (network X3.5.2)

Nazwa sieci	Sieć X3.5.2		
Struktura sieci	7-5-1		
Metoda i parametry uczenia sieci	BP50, CG14		
Rodzaj zbioru	Uczący	Walidacyjny	Testowy
Średni błąd bezwzględny, HRC	0,75	0,65	0,94
Odchylenie standardowe błędu, HRC	0,97	0,95	1,40
Iloraz odchylenia	0,150	0,138	0,216
Korelacja	0,989	0,99	0,978

Tablica 5. Charakterystyka sztucznej sieci neuronowej (sieć X3.7.1)

Table 5. Characteristics of artificial neural network (network X3.7.1)

Nazwa sieci	Sieć X3.7.1		
Struktura sieci	7-7-1		
Metoda i parametry uczenia sieci	BP50, CG18		
Rodzaj zbioru	Uczący	Walidacyjny	Testowy
Średni błąd bezwzględny, HRC	1,05	0,70	0,91
Odchylenie standardowe błędu, HRC	1,37	0,85	1,12
Iloraz odchylenia	0,20	0,142	0,174
Korelacja	0,980	0,99	0,986

2.3. Wykresy symulacji wpływu stężeń pierwiastków na twardość materiału

Poniżej został przedstawiony szereg wykresów, które symulują zależność twardości od stężeń węgla oraz drugiego pierwiastka (manganu, krzemu, chromu, niklu, molibdenu oraz miedzi), przy stałych, średnich, stężeniach pozostałych pierwiastków (tabl. 6). Otrzymane twardości zostały zasymulowane przez najlepszą otrzymaną sieć neuronową. Symulacje nie powinny być stosowane dla sum stężeń pierwiastków, które nie mieszczą się w przedziale wyznaczonym przez sumy ich minimów oraz maksimów przedstawionych w tabelicy 7.

Tablica 6. Średnie stężenia masowe pierwiastków, dla których zostały sporządzone wykresy (rys. 4.-9.)

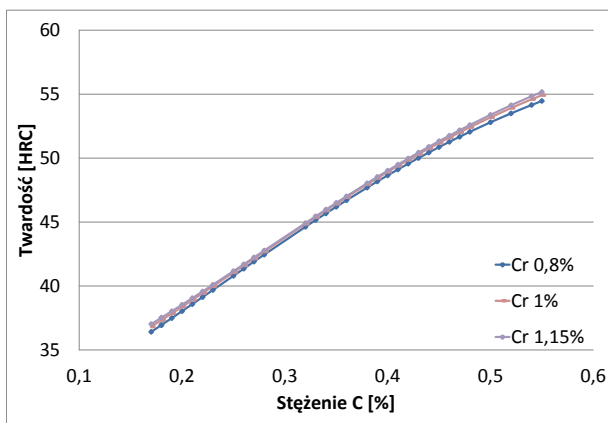
Table 6. Average concentrations of mass elements, which were drawn graphs (fig. 4.-9.)

Pierwiastek	Mn	Si	Cr	Ni	Mo	Cu
Wartość średnia [%]	0,81	0,26	0,98	0,36	0,14	0,17

Tablica 7. Sumy granicznych stężeń pierwiastków


Table 7. The sum of the elements concentrations limit

Pierwiastki	Minimum	Maksimum
Wszystkie pierwiastki (%)	5,9	19,82
C+Mn (%)	0,65	1,49
C+Si (%)	0,36	0,91
C+Cr (%)	0,49	1,87
C+Ni (%)	0,27	1,77
C+Mo (%)	0,19	0,72
C+Cu (%)	0,26	0,86
Ni+Mo (%)	0,05	1,8
Ni+Cr (%)	0,23	3,22
Cr+Mo (%)	0,13	2,02
C+Ni+Mo (%)	0,31	1,99
C+Ni+Cr (%)	0,62	3,36
C+Cr+Mo (%)	0,54	2,16




Rys. 4. Symulacja wpływu C oraz Cr na twardość stali w odległości 3 mm od czoła próbki (stężenie masowe pozostałych pierwiastków jak w tabl. 6.).

Fig. 4. Simulation of C and Cr on the hardness of the steel at a distance of 3 mm from the front of the sample (mass concentration of other elements as in the table 6.).




Rys. 5. Symulacja wpływu C oraz Cu na twardość stali w odległości 3 mm od czoła próbki (stężenie masowe pozostałych pierwiastków jak w tabl. 6.).

Fig. 5. Simulation of C and Cu on the hardness of the steel at a distance of 3 mm from the front of the sample (mass concentration of other elements as in the table 6.).




Rys. 6. Symulacja wpływu C oraz Mn na twardość stali w odległości 3 mm od czoła próbki (stężenie masowe pozostałych pierwiastków jak w tabl. 6.).

Fig. 6. Simulation of C and Mn on the hardness of the steel at a distance of 3 mm from the front of the sample (mass concentration of other elements as in the table 6.).




Rys. 7. Symulacja wpływu C oraz Mo na twardość stali w odległości 3 mm od czoła próbki (stężenie masowe pozostałych pierwiastków jak w tabl. 6.).

Fig. 7. Simulation of C and Mo on the hardness of the steel at a distance of 3 mm from the front of the sample (mass concentration of other elements as in the table 6.).



Rys. 8. Symulacja wpływu C oraz Ni na twardość stali w odległości 3 mm od czoła próbki (stężenie masowe pozostałych pierwiastków jak w tabl. 6.).

Fig. 8. Simulation of C and Ni on the hardness of the steel at a distance of 3 mm from the front of the sample (mass concentration of other elements as in the table 6.).



Rys. 9. Symulacja wpływu C oraz Si na twardość stali w odległości 3 mm od czoła próbki (stężenie masowe pozostałych pierwiastków jak w tabl. 6.).

Fig. 9. Simulation of C and Si on the hardness of the steel at a distance of 3 mm from the front of the sample (mass concentration of other elements as in the table 6.).

3. PODSUMOWANIE

Tematem tej pracy było opracowanie modeli sieci symulujących wpływ stężeń masowych pierwiastków na twardość hartowanej stali konstrukcyjnej i maszynowej. W tym celu zostały wykorzystane sztuczne sieci neuronowe. Badanie zostały przeprowadzone w trzech etapach. W pierwszym etapie sieci neuronowe zostały nauczone w oparciu o zbiór danych uzyskany metodami eksperymentalnymi. Następnie wybrano najlepsze modele sieci neuronowych dla każdej odległości od czoła próbki. Na końcu została wykonana symulacja wpływu węgla oraz pierwiastka stopowego (miedzi, chromu, molibdenu, manganu, krzemu, niklu) na twardość stali. Badania wykonano dla trzech różnych stężeń pozostałych pierwiastków stopowych: średnim, średnim pomniejszonym o odchylenie standardowe, średnim powiększonym o odchylenie standardowe.

Sztuczna sieć neuronowa, z powodu zbioru składającego się z tylko 150 zbadanych wytopów, nie była w stanie nauczyć poprawnej predykcji twardości materiału w zależności od stężenia pierwiastków stopowych. Pomimo dość dobrych wyników statystycznych sieci neuronowe w praktyce nie potrafiły przewidzieć twardości dla granicznych stężeń pierwiastków (np. dla sytuacji, gdy stężenia masowe wszystkich pierwiastków naraz mają maksymalną wartość stężenia, jaką osiągnęły w zbiorze). Z tego powodu potrzeba było opracować założenia dotyczące stężeń pierwiastków. Sieć została przeuczona. Rozwiązaniem problemu może być rozszerzenie zbioru o nowe wyniki pomiarów wykonanych dla innych gatunków stali konstrukcyjnych i maszynowych. Symulacje potwierdziły również, iż komputerowe metody obliczanie hartowności ciągle nie są w stanie podać wyników z dokładnością porównywalną do metod eksperymentalnych.

LITERATURA

1. M. Białko; *Podstawowe właściwości sieci neuronowych i hybrydowych systemów ekspertowych*; Wydawnictwo Uczelniane Politechniki Koszalińskiej; Koszalin; 2000
2. L. A. Dobrzański; *Materiały inżynierskie i projektowanie materiałowe*, Wydawnictwo Naukowo-Techniczne; Warszawa; 2006.
3. L. A. Dobrzański; *Podstawy nauki o materiałach i metaloznawstwo*; Wydawnictwo Naukowo-Techniczne; Warszawa; 2003
4. M. Flasiński; *Wstęp do sztucznej Inteligencji*; Wydawnictwo Naukowe PWN, Warszawa; 2011
5. S. Osowski; *Sieci neuronowe w ujęciu algorytmicznym*; Wydawnictwo Naukowo-Techniczne; Warszawa, 1996
6. L. Rutkowski; *Metody i techniki sztucznej inteligencji*; Wydawnictwo Naukowe PWN; Warszawa; 2009
7. R. Tadeusiewicz; *Sieci neuronowe*; Akademicka Oficyna Wydawnicza; Warszawa; 1993
8. R. Tadeusiewicz, T. Gąciarz, B. Borowik, B. Leper; *Odkrywanie właściwości sieci neuronowych przy użyciu programów w języku C#*; Polska Akademia Umiejętności; Kraków; 2007.
9. J. Trzaska; *Metody sztucznej inteligencji w inżynierii materiałowej*; wykład własny; Gliwice; 2014
10. P. Wójtowicz; *Polska wersja Statistica Neural Networks*; StatSoft Polska; Kraków; 2006

