

LESZEK A. DOBRZAŃSKI, TOMASZ TAŃSKI*

ZASTOSOWANIE SIECI NEURONOWYCH DO OPTYMALIZACJI WARUNKÓW OBRÓBKII CIEPLNEJ STOPÓW Mg-Al

APPLICATION OF NEURAL NETWORKS FOR OPTIMISATION OF Mg-Al ALLOYS HEAT TREATMENT CONDITIONS

Streszczenie

W artykule przedstawiono analizę komputerową optymalizacji warunków obróbki cieplnej i własności mechanicznych stopów Mg-Al z wykorzystaniem sieci neuronowych jako techniki numerycznego modelowania.

Słowa kluczowe: obróbka cieplna, stopy Mg-Al, twardość

Abstract

In this paper was presented the computer aided analysis of heat treatment condition optimisation as well mechanical properties of Mg-Al alloys using neural networks as a numerical modelling technique.

Keywords: heat treatment, Mg-Al alloys, hardness

* Prof. dr hab. inż. Leszek Adam Dobrzański, dr h.c., dr inż. Tomasz Tański, Instytut Materiałów Inżynierskich i Biomedycznych, Wydział Mechaniczny Technologiczny, Politechnika Śląska.

1. Wstęp

Rozwój nowoczesnych narzędzi informatycznych, w tym metod sztucznej inteligencji, powoduje, że są one coraz powszechniej wykorzystywane w różnych dziedzinach nauki i techniki. Również w obszarze inżynierii materiałowej trendy te są w świecie od kilku lat zauważalne dzięki szerokim możliwościom aplikacyjnym pozwalającym na rozwiązywanie nowych zagadnień, jak i tych uznanych za klasyczne. Na możliwości metod numerycznych istotnie wpływa także postępujący rozwój technologii informatycznych, które pozwalają na znaczący wzrost mocy obliczeniowych oraz obniżenie kosztów systemów cyfrowych.

W inżynierii materiałowej stosowane są różnego typu metody obliczeniowe pozwalające na przybliżanie oraz predykcję zjawisk zachodzących w materiałach podczas wytwarzania, procesów technologicznych przetwórstwa oraz eksploatacji materiałów inżynierskich w różnych warunkach pracy. Do technik stosowanych w ogólnie pojętym komputerowym wspomaganiu (CAx) można zaliczyć metody stochastyczne, np. metodę Monte Carlo, metody numeryczne rozwiązywania równań matematycznych, np. metoda elementów skończonych (MES), szeroko rozumiane metody sztucznej inteligencji, np. algorytmy genetyczne, sztuczne sieci neuronowe, lub logikę rozmytą. Coraz bardziej popularne są systemy hybrydowe łączące w sobie kilka metod w celu uzyskania wyników bardziej odzwierciedlających rzeczywiste zjawiska. Metody numeryczne są stosowane także w innych dziedzinach wiedzy i bardzo trudno byłoby obecnie wskazać przynajmniej jeden obszar nauki, w której nie wykorzystano możliwości aplikacyjnych komputerowe wspomaganie.

Sieci neuronowe są techniką numerycznego modelowania, zdolną do odwzorowywania złożonych funkcji. Obecnie sieci neuronowe mają charakter nieliniowy, co umożliwia użytkownikowi swobodne i łatwe tworzenie modeli nieliniowych opisujących cechy modelowanych obiektów. Zaletą sieci neuronowych jest fakt, że pozwalają one poszukiwać modeli numerycznych dla słabo znanych zjawisk i procesów, przy czym użytkownik sieci nie musi deklarować żadnej z góry zadanej formy poszukiwanego modelu, a nawet nie musi być pewny, że w ogóle jakaś dająca się matematycznie opisać zależność istnieje [1, 3–7].

Charakterystyczną cechą sieci neuronowych jest możliwość ich uczenia za pomocą tzw. algorytmów uczenia, które umożliwiają adaptację parametrów sieci do specyfiki rozwiązywanego problemu. Stopień złożoności sieci neuronowej oraz efektywność uczenia charakteryzują algorytmy uczenia. Zastosowane algorytmy uczenia wyznaczają podstawowy podział sieci neuronowych ze względu na sposób uczenia.

Wyróżnia się dwa typy algorytmów uczenia:

1. **Algorytmy realizujące uczenie nadzorowane** – z nauczycielem. Algorytmy te modyfikują wagi i wartości progowe, korzystając ze zbiorów uczących, zawierających zarówno wartości wejściowe, jak i zadane wartości wyjściowe.
2. **Algorytmy realizujące uczenie nienadzorowane** – bez nauczyciela. Algorytmy te modyfikują wagi i wartości progowe, wykorzystując zbiory uczące, zawierające jedynie wartości wejściowe (w przypadku tych algorytmów wartości wyjściowe w zbiorze danych nie są wymagane, a w przypadku ich wystąpienia są ignorowane) [3–7].

Celem niniejszego artykułu jest określenie optymalnych warunków obróbki cieplnej dla badanych stopów Mg-Al z wykorzystaniem sieci neuronowych.

2. Metody badań

Optymalizację warunków obróbki cieplnej, tj. temperatury i czasu wygrzewania w trakcie przesycania i starzenia oraz szybkości chłodzenia po przesycaniu, przeprowadzono na podstawie prób twardości obejmujących w sumie kilkadziesiąt możliwych kombinacji. Wyniki optymalizacji posłużyły do opracowania metodyki projektowania materiałowego najkorzystniejszych własności fizycznych i mechanicznych opracowanych stopów MCMgAl12Zn1, MCMgAl9Zn1, MCMgAl6Zn1, MCMgAl3Zn1 (tabela 1).

Tabela 1

Skład chemiczny analizowanych stopów

Stężenie masowe pierwiastków stopowych w badanych stopach [%]												
Al	Zn	Mn	Cu	Si	Fe	Ni	Sn	Pb	Be	Zr	Ce	Mg
11,894	0,55	0,22	0,0064	0,050	0,02	0,0008	0,0007	0,045	0,0006	0,003	0,01	87,2
9,399	0,84	0,24	0,0018	0,035	0,007	0,0009	0,0042	0,059	0,0005	0,003	0,01	89,4
5,624	0,46	0,16	0,0024	0,034	0,07	0,0017	0,0009	0,034	0,0003	0,003	0,01	93,6
2,706	0,21	0,10	0,0018	0,032	0,005	0,0020	0,0008	0,013	0,0001	0,003	0,01	96,9

Przesycanie (woda, powietrze, piec) dla badanych materiałów przeprowadzono w temperaturze 400, 415 i 430°C w czasie 10, 20 i 30 godzin. Natomiast po przesycaniu w wodzie wykonano starzenie z chłodzeniem na powietrzu w zakresie temperatury od 150 do 210°C co 20°C i w czasie 5, 10 i 15 godzin. Dla każdej próbki wykonano odpowiednio pięć prób i obliczono średnią arytmetyczną, otrzymując w rezultacie 27 przypadków średniej twardości dla każdego ze stopów po przesycaniu oraz 108 przypadków po starzeniu. Powstała macierz obejmowała łącznie 540 przypadków wartości średnich uzyskanych z prób twardości dla stanu po przesycaniu i starzeniu, stanowiąc jednocześnie zbiór danych niezbędny do komputerowej analizy przy wykorzystaniu sieci neuronowych.

3. Omówienie wyników badań

Zastosowane sieci neuronowe pozwoliły na opracowanie modelu zależności pomiędzy:

- stężeniem aluminium, temperaturą i czasem przesycania, ośrodkiem chłodzącym, a twardością,
- stężeniem aluminium, temperaturą i czasem przesycania, temperaturą i czasem starzenia a twardością.

Zbiór danych dla przesycania i starzenia podzielono w sposób losowy na trzy podzbiory: uczący, walidacyjny i testowy. W przypadku sieci obliczającej twardość po przesycaniu liczba przypadków wynosiła odpowiednio: 68, 20, 20, natomiast dla sieci obliczającej twardość po starzeniu: 231, 100, 101. Dane ze zbioru uczącego zastosowano do modyfikacji wag sieci, dane ze zbioru walidacyjnego, do oceny sieci w trakcie procesu uczenia, natomiast pozostała część wartości (zbiór testowy) przeznaczono do niezależnego określenia sprawności sieci po całkowitym zakończeniu procedury jej tworzenia. Dane wykorzystywane w procesie uczenia i testowania sieci poddano normalizacji. Zastosowano skalowanie względem odchylenia od wartości minimalnej zgodnie z funkcją mini-max. Funkcja mini-max transformuje dziedzinę zmiennych do przedziału (0, 1). Rodzaj sieci,

liczbę neuronów w warstwie (warstwach) ukrytej, metodę i parametry uczenia określono, obserwując wpływ tych wielkości na przyjęte wskaźniki oceny jakości sieci.

Jako podstawowe wskaźniki oceny jakości modelu wykorzystano następujące wielkości:

– średni błąd bezwzględny prognozy sieci, który obliczono według zależności:

$$E_j = \frac{1}{n} \sum_{i=1}^n (|X_{zi} - X_{oi}|) \quad (1)$$

gdzie:

- E_j – błąd dla j -tej własności,
- n – liczba danych w zbiorze,
- X_{zi} – i -ta wartość twardości zmierzona,
- X_{oi} – i -ta wartość obliczeniowa.

– iloraz odchyłeń standardowych [8],

– współczynnik korelacji Pearsona błędów predykcji i odchylenia standardowego zmiennej wyjściowej wartości twardości doświadczalnej i twardości obliczonej przez sieć.

Zarówno dla sieci obliczającej twardość po przesycaniu, jak i po przesycaniu i starzeniu, jako optymalną ustalono sieć jednokierunkową typu MLP (perceptron wielowarstwowy) z jedną warstwą ukrytą i pięcioma neuronami w tej warstwie. Ponadto zastosowano funkcję błędu oraz logistyczną funkcję aktywacji, wykorzystując metodę uczenia opartą na algorytmie gradientów sprzężonych. Proces uczenia zakończono po 101 epokach treningowych dla sieci obliczającej twardość po przesycaniu i 195 epokach dla sieci obliczającej twardość po przesycaniu i starzeniu. W czasie uczenia sieci obserwowano wykres błędu uczenia dla zbioru uczącego i walidacyjnego. Proces uczenia zakończono, gdy błąd zbioru walidacyjnego zaczynał rosnąć. Wskaźnik jakości sieci przedstawiono w poniższych tabelach (tabela 2, 3).

Tabela 2

Wskaźniki oceny jakości sieci neuronowej opracowanej do obliczania twardości po przesycaniu


Wskaźniki oceny jakości modelu	Zbiór danych		
	uczący	walidacyjny	testowy
błąd średni, HRF	1,1	1,1	1,1
iloraz odchyłeń standardowych	0,1	0,08	0,08
współczynnik korelacji	0,99	0,99	0,99

Tabela 3

Wskaźniki oceny jakości sieci neuronowej opracowanej do obliczania twardości po przesycaniu i starzeniu

Wskaźniki oceny jakości modelu	Zbiór danych		
	uczący	walidacyjny	testowy
błąd średni, HRF	1,5	1,5	1,5
iloraz odchyłeń standardowych	0,09	0,09	0,09
współczynnik korelacji	0,99	0,99	0,99

Na podstawie opracowanych modeli sieci neuronowych wykonano symulację wpływu temperatury oraz czasu przesycania i starzenia, a także stężenia aluminium na twardość analizowanych odlewniczych stopów magnezu (rys. 1).



Rys. 1. Symulacja wpływu temperatury i czasu starzenia na twardość odlewniczego stopu magnezu: a) MCMgAl12Zn1, b) MCMgAl9Zn1, c) MCMgAl6Zn1, d) MCMgAl3Zn1 przy założonej temperaturze i czasie przesycania 430°C i 10 godzin, wyniki uzyskane przy pomocy symulacji komputerowej z wykorzystaniem sieci neuronowych

Fig. 1. Ageing time and temperature influence on hardness of the cast magnesium alloys: a) MCMgAl12Zn1, b) MCMgAl9Zn1, c) mcmgal6zn1, d) mcmgal3zn1 by assumed temperature and ageing time of 430°C and 10 hours, the results are achieved by mind of computer simulation using neural networks

Otrzymane wyniki jednoznacznie wskazują na to, że najkorzystniejszym rodzajem obróbki cieplnej zarówno pod względem optymalnych warunków pracy oraz zużytej energii i czasu potrzebnych na przeprowadzenie przesycania i starzenia, jak i pod względem uzyskania najkorzystniejszych własności mechanicznych jest przesycanie w temperaturze 430°C przez 10 godzin i starzenie w temperaturze 190°C przez 15 godzin (tabela 4).

Warunki obróbki cieplnej badanych stopów

Oznaczenie stanu obróbki cieplnej	Parametry obróbki cieplnej		
	temperatura [°C]	czas wygrzewania [h]	sposób chłodzenia
0	Stan odlany		
1 – przesycanie	430	10	woda
2 – przesycanie	430	10	powietrze
3 – przesycanie	430	10	piec
4 – starzenie	190	15	powietrze

4. Wnioski

Istota badań dotyczyła zaprojektowania materiału o najkorzystniejszych własnościach fizycznych i mechanicznych. W celu zwiększenia jego twardości, wytrzymałości oraz odporności na zużycie ścierne zdecydowano się na optymalizację składu chemicznego oraz technologii obróbki cieplnej z uwzględnieniem ośrodków chłodzących. Ponadto opracowano model sieci neuronowych pozwalający na symulację wpływu temperatury oraz czasu przesycania i starzenia, a także stężenia aluminium na twardość analizowanych odlewniczych stopów magnezu (rys. 1). Na podstawie tego modelu stwierdzono, że najkorzystniejszym rodzajem obróbki cieplnej zarówno pod względem zużytej energii i czasu potrzebnego na przeprowadzenie przesycania i starzenia, jak i pod względem uzyskania najkorzystniejszych własności mechanicznych, jest przesycanie w temperaturze 430°C z wygrzewaniem przez 10 godzin i starzenie w temperaturze 190°C przez 15 godzin.

Literatura

- [1] Bishop C., *Neural Networks for Pattern Recognition*, Oxford University Press, London 1995.
- [2] Korbicz J., Obuchowicz A., Uściński D., *Sztuczne sieci neuronowe*, Akademicka Oficyna Wydawnicza PLJ, Warszawa 1994.
- [3] Masters T., *Sieci neuronowe w praktyce*, WNT, Warszawa 1996.
- [4] Nałęcz M., Ducha W., Korbicz J., Rutkowskiego L., Tadeusiewicz R., *Biocybernetyka i Inżynieria Biomedyczna*, tom 6, Sieci neuronowe, EXIT, Warszawa 2000.
- [5] Tadeusiewicz R., *Elementarne wprowadzenie do techniki sieci neuronowych z przykładowymi programami*, Akademicka Oficyna Wydawnicza PLJ, Warszawa 1998.
- [6] Tadeusiewicz R., *Sieci neuronowe*, Akademicka Oficyna Wydawnicza RM, Warszawa 1993.
- [7] Żuranda J., Barski M., Jędruch W., *Sztuczne sieci neuronowe*, PWN, Warszawa 1996.
- [8] Praca zbiorowa, *Statistica Neural Networks, wprowadzenie do sieci neuronowych*, Statsoft 2001.