

Teresa PAMUŁA

ZASTOSOWANIE SIECI NEURONOWEJ DO MODELOWANIA WŁAŚCIWOŚCI SPOIN

Streszczenie. Artykuł przedstawia neuronowy model właściwości niskowęglowej spoiny. Zaproponowano dwumodułową konstrukcję modelu wiążącego informację obrazową mikrostruktury z wybranymi własnościami mechanicznymi. Moduł wejściowy określa parametry mikrostruktury na podstawie zdjęć mikroskopowych spoiny. Stan wyjść tego modułu jest wektorem wejść dla modułu neuronowego wyznaczającego własności mechaniczne.

APPLICATION OF NEURON NETWORKS FOR MODELLING WELD DEPOSIT PROPERTIES

Summary. The paper presents a discussion of modelling properties of low carbon weld deposits with the use of neuron networks. A two-module model was designed to interpret the contents of microscopic images of the welds and combine it with weld properties. The input module determines the parameters of weld microstructures from microscopic images. The states of outputs constitute an input vector of the following module, which evaluates chosen mechanical properties of the welds.

1. WSTĘP

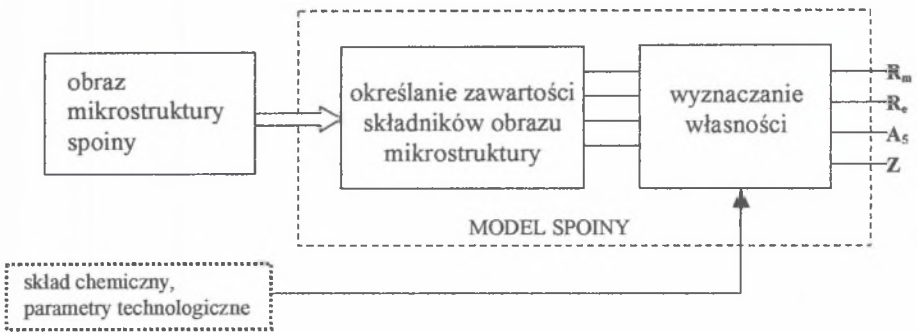
Przedstawione w literaturze neuronowe modele własności spoin wiążą parametry mikrostruktury spoiny oraz jej skład chemiczny z własnościami mechanicznymi [1]. Parametry mikrostruktury spoiny podawane są na wejście modelu w postaci procentowej zawartości różnych postaci składników – zwykle ferrytów. Zawartość tych składników wyznaczana jest najczęściej przez analizę zdjęć mikroskopowych z wykorzystaniem systemów przetwarzania obrazów [2].

Biorąc pod uwagę podwójną przydatność sieci neuronowej do analizy obrazów oraz wyznaczania własności, zaproponowano włączenie analizy mikrostruktury do modelu własności spoiny.

W przypadku stali niskostopowych i niskowęglowych spoiny posiadają najczęściej strukturę ferrytyczną. Postacie ferrytu posiadają charakterystyczne cechy geometryczne, pozwalające jednoznacznie identyfikować je na obrazie. Trudnością w opracowaniu efektywnych metod analizy jest konieczność analizy dużego wycinka spoiny w celu uzyskania małych błędów w ocenie ilościowej zawartości składników.

2. KONSTRUKCJA MODELU

W toku badań ustalono przydatność podziału modelu na dwa moduły. Taki podział umożliwi równoległą pracę nad udoskonalaniem modelu. Moduły w postaci odrębnych sieci neuronowych mają własne specyficzne struktury sieci. Zaproponowano konstrukcję składającą się z modułu określania zawartości składników obrazu mikrostruktury i dołączonego w szereg modułu wyznaczania własności mechanicznych – rys. 1.



Rys. 1. Model własności spoiny

Fig. 1. Weld deposit properties model

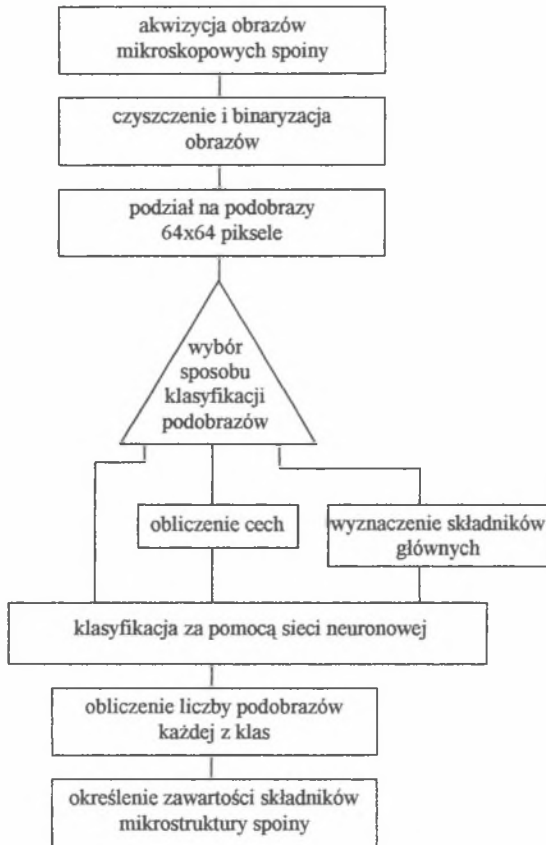
Takie rozwiązanie pozwala precyzyjniej przedstawić własności spoiny. Rozbudowując model, można uzupełnić moduł wyjściowy o dodatkowe wejścia reprezentujące, np.: skład chemiczny materiałów spoiny, energię spawania, geometrię złącza spawanego.

Moduł określania zawartości składników obrazu mikrostruktury może stanowić samodzielny model zawartości spoiny, użyteczny na przykład do klasyfikacji spoin według rozmiaru i rodzaju ziaren mikrostruktury.

3. OKREŚLANIE ZAWARTOŚCI SKŁADNIKÓW OBRAZU MIKROSTRUKTURY

Funkcją realizowaną przez moduł określania zawartości składników obrazu mikrostruktury jest odwzorowanie zawartości obrazu na wektor opisujący proporcje składników ferrytowych.

Obrazy przedstawiają 250-krotne powiększenia mikrostruktury spoiny w rozdzielczości 576x512 pikseli. Tak duża liczba danych nie może być podana na wejścia sieci neuronowej, dlatego należy zredukować ilość danych.



Rys.2. Schemat blokowy przetwarzania obrazów mikrostruktury spoiny
Fig.2. Block diagram of weld microstructure images processing

Zaproponowano podział obrazu na podobrazy o rozmiarze 64x64 piksele i redukcję informacji przez wyznaczenie cech lub składników głównych tych podobrazów. Schemat blokowy na rys. 2. ilustruje tok przetwarzania.

Binaryzację wykonano metodą cząstki błędzącej [4]. Taki sposób binaryzacji znacznie polepsza kontrast obrazu i likwiduje błędy spowodowane nierównomiernością oświetlenia, przyczyniając się do istotnej poprawy widoczności ferrytu drobnoziarnistego. Uzyskany obraz dodatkowo przetworzono z użyciem operacji morfologicznych, eliminując izolowane piksele oraz zamykając kontury ziaren ferrytów.

Do realizacji zadania klasyfikacji zaproponowano wykorzystanie sieci jednokierunkowych, trójwarstwowych i czterowarstwowych.

Zaproponowano trzy sposoby klasyfikacji podobrazów:

- na podstawie wartości pikseli obrazu oznaczających stopień szarości,
- na podstawie wartości określających cechy obrazu, takie jak np.: pola powierzchni dwóch największych obiektów na obrazie, średnia z wartości pikseli itp.,
- według składników głównych każdego podobrazu wyznaczonych za pomocą sieci samoorganizującej się (PCA).

Wyboru optymalnej struktury sieci dokonano na podstawie badań sieci o różnych strukturach oraz z użyciem kilku sposobów wyznaczania wag. Założono, że miarą przydatności sieci jest stopień rozpoznania grupy 200 obrazów testowych nie należących do ciągu uczącego sieć.

Skuteczność działania sieci klasyfikującej obrazu na podstawie wartości pikseli nie zależała od sposobu doboru wag neuronów w sieci, lecz głównie od liczby warstw i liczby neuronów w poszczególnych warstwach. Najlepiej rozpoznawała obrazu testowe czterowarstwowa sieć o architekturze 128-64-16-3 z wagami ustalonymi metodą TRAINGDX [5]. Uzyskano maksymalną „rozpoznawalność” na poziomie 75%.

Sposób klasyfikacji oparty na cechach obrazu wymagał wydzielenia obiektów na obrazie i obliczenia cech tych obiektów. Wykorzystano elementarne metody wstępnego przetwarzania obrazów. Przeprowadzono badanie przydatności kilkunastu cech obiektów i określono minimalny 7-elementowy zbiór cech, najlepiej opisujący rodzaje ferrytów na obrazach spoin. Wybrano cechy, takie jak: procentowa zawartość białych pikseli, energia tekstury, kontrast tekstury, entropia tekstury, suma pól powierzchni dwóch największych obiektów na obrazie, średnie wydłużenie, średnia ciągłość. W związku z niewielką liczbą wejść (7) liczba neuronów w poszczególnych warstwach została znacznie zmniejszona w stosunku do sieci używanych w klasyfikacji pikselowej. Liczbę neuronów w poszczególnych warstwach wyznaczono doświadczalnie, zgodnie z zasadami i uwagami zawartymi w pracy [6]. Uzyskano bardzo dobre wyniki rozpoznania (śr. 90%) w wielu wypadkach rozpoznawane były wszystkie obrazu testowe.

Określanie cech obiektów na obrazie stanowi pewną niedogodność ze względu na konieczność wykorzystania specyficznego oprogramowania przetwarzania obrazów niekompatybilnych z sieciami neuronowymi. Podjęto próbę wykorzystania analizy składników głównych – PCA, łatwo implementowaną w postaci sieci neuronowej, do redukcji informacji

obrazowej [7]. Biorąc pod uwagę duże zróżnicowanie danych, na obrazach z poszczególnych klas wyznaczono dla każdego obrazu 100 składników głównych. Analiza histogramów występowania składników umożliwiła wybór 7 składników głównych, najlepiej wyróżniających klasy obrazów. Badania wykazały, że ta metoda klasyfikacji jest dokładniejsza niż metoda pikselowa, gorsza jednak od klasyfikacji według cech. Sumaryczny błąd oceny struktury spoiny nie powinien przekroczyć 16% (5% błąd wynikający z liczby próbek, 11% maksymalny błąd metody).

4. WYZNACZANIE WŁASNOŚCI SPOIN

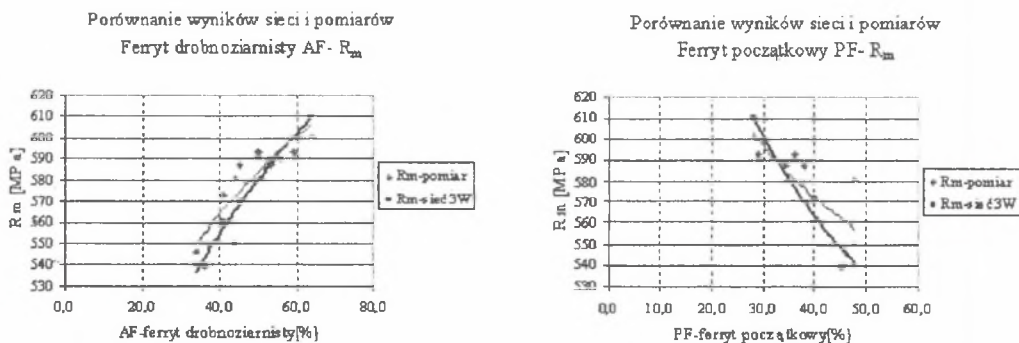
W badaniach wykorzystano dane pomiarowe z prac [3, 8]. Sprawdzano działanie sieci jednokierunkowych trój- i czterowarstwowych typu backpropagation. Stosowano różne metody uczenia. Do prognozowania właściwości mechanicznych na podstawie parametrów struktury zastosowano sieć neuronową o strukturze 3-2-9-5.

Wejściami sieci są parametry struktury - PF, AC, AF. Sygnały wyjściowe to właściwości mechaniczne spoiny, takie jak:

- wytrzymałość na rozciąganie R_m ,
- granica plastyczności R_e ,
- wydłużenie względne A_5 ,
- przewężenie względne Z .

Do uczenia wybrano metodę Levenberga-Marquardta, która jest jedną z najszybszych metod uczenia sieci typu backpropagation.

Porównanie wartości wyjść sieci z danymi z pomiarów zawierają wykresy z rys. 3.



Rys.3. Wykresy zależności granicy plastyczności R_e od parametrów mikrostruktury
Fig.3. Plots of R_e as a function of microstructure parameters

5. WNIOSKI

Badania wykazały, że możliwa jest ocena mikrostruktur spoin za pomocą sieci neuronowej z dokładnością zbliżoną do tradycyjnych metod analizy obrazów. Zaletą sieci neuronowej jest zdolność prawidłowego rozpoznania klasy obrazu nawet wtedy, gdy wartości jednej lub dwóch cech (z siedmiu) obrazu znacznie odbiegają od wzorca z ciągu uczącego. Sieć neuronowa umożliwia automatyczną ocenę parametrów struktury i może stanowić moduł w modelu własności mechanicznych.

Przedstawione wyniki zastosowania sieci neuronowych do modelowania mikrostruktury i własności mechanicznych spoin niskowęglowych i niskostopowych wskazują na prawidłowe rozpoznanie i właściwe propozycje rozwiązań zarówno struktury, jak i algorytmów przetwarzania modelu własności spoiny.

LITERATURA

1. Bhadeshia H.K.D.H.: Materials Algorithms Project-Neural, www.msm.cam.ac.uk/map/mapmain.html.
2. Szala J.: Metilo. Politechnika Śląska, Katedra Nauki o Materiałach, Katowice 1999.
3. Czwarnóg B.: Wpływ warunków wysokoenergetycznego spawania MAG w osłonie mieszanek gazowych Ar-He-CO₂ na własności spoin. Praca doktorska. Politechnika Krakowska, Kraków 1999.
4. Smółka B., Bal A, Kubiczek D.: Binarzacja linii papilarnych metodą cząstki błędzącej. Techniki informatyczne w medycynie, Jaszowiec 1999.
5. Pamuła T.: Application of neural networks to microstructure classification with the use of image features. Journal of Medical Informatics and Technologies, Katowice 2000.
6. Duch W, Korbicz J., Rutkowski L., Tadeusiewicz R.: Sieci neuronowe., PAN, Akademicka Oficyna Wydawnicza Exit, Warszawa 2000.
7. Osowski S.: Sieci neuronowe w ujęciu algorytmicznym. WNT, Warszawa 1996.
8. Adamiec P.: Metalurgiczne aspekty własności spoin łuku krytego w złączach ze stali C-Mn. Zeszyty Naukowe Pol. Śl., Mechanika z.80, Gliwice 1984.

Recenzent: Prof. dr hab. inż. Jan Piecha

Abstract

The paper presents a discussion of modelling properties of low carbon welds with the use of neuron networks. A two module model was designed to interpret the contents of microscopic images of the welds and combine it with the contents of a database of weld properties. The input module determines the parameters of weld microstructures from microscopic images. The state of outputs constitute the input vector of the following module, which evaluates chosen mechanical properties of the welds.