

Teresa PAMUŁA

ZASTOSOWANIE SIECI NEURONOWEJ DO OKREŚLANIA WŁASNOŚCI POŁĄCZEŃ SPAWANYCH

Streszczenie. W artykule przedstawiono próbę zastosowania sieci neuronowej do oceny struktur spoin niskowęglowych. Zaproponowano użycie trójwarstwowej jednokierunkowej nieliniowej sieci do przetwarzania obrazów mikroskopowych spoin i powiązania ich z bazą danych własności. Zastosowano sigmoidalną funkcję przejścia. Naukę sieci przeprowadzono wykorzystując metodę propagacji wstecznej z różnymi współczynnikami uczenia dla każdej z warstw.

Mikroskopowe obrazy spoin potraktowano jak tekstury i przygotowano ciągi uczące dla sieci wykorzystując metody klasyfikacji tekstur.

THE NEURAL NETWORK APPLICATION FOR ASSESSING THE PROPERTIES OF WELDED JOINTS

Summary. The paper presents an attempt to apply a neural network for assessing the properties of low carbon welds. A three layer unidirectional non linear net was designed to interpret the contents of microscopic images of the welds and combine it with the contents of a database of weld properties. For this purpose a sigmoidal transfer functions were used. The course of the net training was carried out using backpropagation idea with different learning rates and momentum coefficients for the net layers.

The weld images were treated as textures. A method for preparing training sequences was devised, based on texture analysis methods.

1. WSTĘP

Do wykonywania konstrukcji spawanych najczęściej wykorzystuje się niskostopowe i niskowęglowe stale konstrukcyjne. Dla konstruktora istotne są wypadkowe własności mechaniczne pospawanych elementów. Sposób spawania determinuje strukturę i własności

mechaniczne złączy spawanych. Dostarczana energia cieplna podczas wykonywania spoiny i szybkość chłodzenia decydują o strukturze spoiny (rys. 1). W toku badań przyjmuje się zwykle, że parametrem odwzorowującym dostarczaną energię jest energia przypadająca na jednostkę długości spoiny podczas wykonywania spawu zwana energią liniową.

W wyniku analizy metalograficznej spoin niskowęglowych stwierdzono, że struktura wtórna, pojawiająca się w spoinach w wyniku przemiany austenitu, może w dużym stopniu decydować o własnościach spoin, zwłaszcza o ich udarności. W takich spoinach można wyróżnić trzy odmiany ferrytu zgodnie z klasyfikacją Międzynarodowego Instytutu Spawalnictwa, a mianowicie:

- ferryt początkowy (FP),
- ferryt uboczny płytkowy (bocznopłytkowy) (FB),
- ferryt drobnopłytkowy (FD).

W pracy [7] określono zależność między energią liniową a powierzchnią zajmowaną przez odmiany ferrytu na obrazie mikroskopowym spoin, którą ilustruje tabl. 1.

Tablica 1

Udział powierzchniowy ferrytu w spoinie T.I.M.E.

Lp.	[kJ/cm] ²	Udział powierzchniowy [%]			
		Ferryt początkowy	Ferryt bocznopłytkowy	Ferryt drobnopłytkowy	Inne
1	9,60	6,79	0,39	92,08	0,74
2	16,80	17,26	3,06	79,04	0,64
3	22,40	21,59	3,00	74,81	0,60
4	32,30	25,82	3,69	69,93	0,56
5	45,9	39,04	3,70	56,80	0,46

Z analizy danych zamieszczonych w tablicy wynika, że zwiększenie energii liniowej powoduje zwiększenie obszaru zajmowanego przez ferryt początkowy. Udział powierzchniowy ferrytu bocznopłytkowego nie ulega większym zmianom przy wzroście energii. Powiększanie obszaru ferrytu początkowego odbywa się kosztem zmniejszenia powierzchni ferrytu drobnopłytkowego.


Przedstawione zależności mają charakter monotoniczny. Na podstawie analizy obrazu spoiny, tj. udziału powierzchniowego składników, można jednoznacznie określić energię liniową.

Energia liniowa spawu określa własności mechaniczne spoiny [7]. Wiążąc obraz spoiny z bazą danych o jej własnościach, można uzyskać (przydatne w praktyce spawalniczej) narzędzie określania własności spoin.

Do realizacji tego zadania zaproponowano wykorzystanie teorii sieci neuronowych. Sieć neuronowa umożliwiła klasyfikację i znajdowanie związków między zbiorami cech.

Zastosowanie sieci neuronowej wymaga:

- określenia jej optymalnej struktury,
- wybrania funkcji przejścia i sposobu uczenia,
- określenia ciągów uczących.



Rys. 1. Przykładowe obrazy mikroskopowe spoin o powiększeniu 250x

Fig. 1. Instances of microscopic images of welds mag. 250x

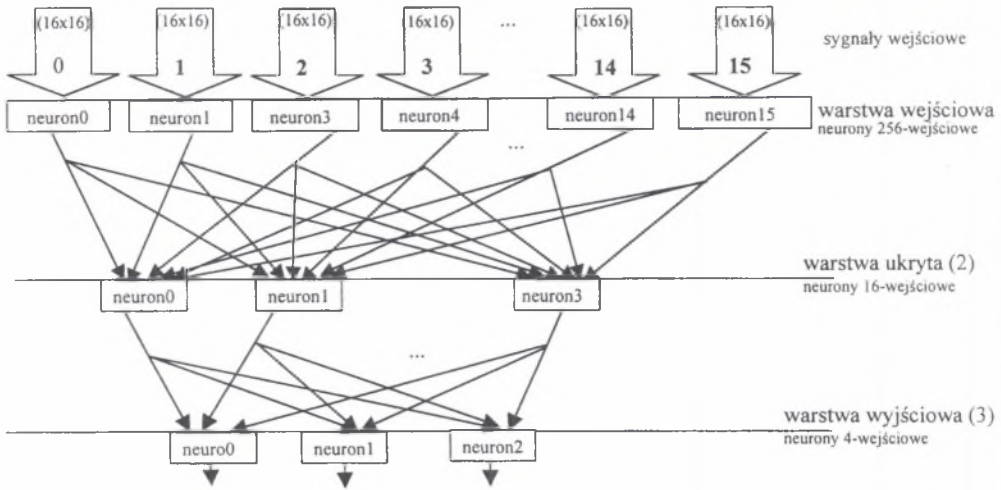
2. STRUKTURA SIECI NEURONOWEJ

Powierzchnia spoiny jest strukturą niejednorodną. Przyjęto teksturową reprezentację za wartości obrazu spoiny. Tekstura określa lokalne cechy statystyczne obrazu. Mikroskopowy obraz spoiny w 250-krotnym powiększeniu obejmuje wycinek o powierzchni około 0,5% całego przekroju spoiny. Rozmiar odmian ferrytu uzasadnia przyjęcie podstawowego rozmiaru tekstury na 64x64 piksele. Stąd wycinek obejmuje kilkadziesiąt tekstur. W celu określenia cech spoiny z dostatecznie małym błędem należy poddać wspólnej analizie zbiory co najmniej kilkunastu losowo wybranych wycinków spoiny tak, aby stanowiły one nie mniej niż 5 % całkowitej powierzchni.


Na podstawie informacji z wyjść sieci o liczbie tekstur z danej klasy (w cyklu) można określić udział powierzchniowy składników spoiny odwzorowanych przez tekstury, a w dalszej kolejności powiązać go z własnościami mechanicznymi spawu.

Do rozpoznawania obrazów tekstur (64x64 piksele) zastosowano trójwarstwową nieliniową sieć neuronową. Zastosowano sigmoidalną funkcję przejścia neuronu. Sprawdzone kilka konfiguracji sieci i wybrano optymalną ze względu na efektywność uczenia się. Na rys. 2 przedstawiono wybraną strukturę sieci.

Proces uczenia sieci przeprowadzono metodą propagacji wstecznej. W toku przeprowadzonych cykli uczenia dobrano optymalne współczynniki nauki kolejnych warstw sieci. Współczynniki uczenia były największe dla warstwy wyjściowej.



Rys. 2. Schemat połączeń sieci neuronowej dla obrazu 64x64
 Fig. 2. Neural network diagram for a 64x64 image



Rys. 3. Podział obrazu na podobrazy o rozdzielczości 64x64 piksele (obraz po binaryzacji)
 Fig. 3. Partitioning of image into 64x64 pixel patches

2.1. Wstępne przetworzenie obrazu

W celu zredukowania różnic w naświetleniu obrazów i zmniejszeniu rozmiaru informacji podawanej na sieć obrazy pomiarowe zostały zbinaryzowane z progiem równym średniej wartości pikseli na obrazie. Binaryzację wykonano globalnie dla całego obrazu (binaryzacja lokalna – dla obrazów 64x64 - powodowała niepotrzebne ujawnienie szczegółów).

2.2. Podział obrazu

Do celów analizy obraz podzielono na podobrazy o rozmiarach 64x64 piksele (dla obrazu o powiększeniu 250-krotnym). Takie podejście eliminuje 2 problemy:

- umożliwia zwiększenie długości ciągu uczącego przez wprowadzenie dużej liczby małych obrazów,
- uniezależnia wynik od liczby obrazów wykonanych dla danej spoiny (o własnościach można wnioskować dopiero na podstawie analizy kilkunastu lub więcej obrazów, które stanowią ok. 5% powierzchni danej spoiny).

3. DOBÓR CIĄGU UCZĄCEGO

Do uzyskania dużej dokładności klasyfikacji istotne są rozmiary zbioru uczącego oraz jakość obrazów wzorcowych wykorzystanych do nauki sieci. Przygotowanie takich zbiorów jest uciążliwe i bardzo pracochłonne. Zaproponowano wykorzystanie metod klasyfikacji tekstur do analizy zawartości mikroskopowych obrazów spoin i przygotowania ciągów uczących. W ten sposób można odejść od uciążliwego wyodrębniania obiektów, w tym przypadków odmian ferrytu, a wykorzystać prostsze algorytmy statystycznej obróbki pikseli obrazu.

Obraz mikroskopowy spoiny potraktowany został jako obraz teksturowy. W celu doboru prawidłowych ciągów uczących obrazy poklasyfikowano według cech obrazów teksturowych.


Do uczenia sieci o strukturze przedstawionej na rys.4 przygotowano 240 obrazów tekstur, po 80 z każdej z 3 klas (w początkowym etapie badań uwzględniono tylko 3 rodzaje obrazów, docelowo będzie ich 4 lub więcej). Klasy obrazów tekstur różnią się proporcją białych pikseli i czarnych, a także liczbą elementów o małej powierzchni (ferryt drobnoziarnisty) i o dużej powierzchni (ferryt początkowy, boczno płytkowy).

3.1. Cechy obrazów teksturowych

Cechy obrazów teksturowych można obliczyć na podstawie macierzy przyległości (co-occurrence-Matrix).

Przykładowa macierz przyległości dla obrazu o 4 kolorach:


0	3	3	0	3	3	0
0	3	3	0	3	3	0
2	1	2	1	1	1	2
0	3	3	0	3	3	0
0	3	3	0	3	3	0
2	1	2	1	1	1	2



	0	1	2	3	a
0	0	0	0	8	
1	0	0	6	0	
2	0	6	0	0	
3	8	0	0	8	
b					

Przykładowa macierz przyległości dla obrazu binarnego.

0	1	1	0	1	1	0
0	1	1	0	1	1	0
1	1	1	1	1	1	1
0	1	1	0	1	1	0
0	1	1	0	1	1	0
1	1	1	1	1	1	1



	0	1	a
0	0	8	
1	8	20	
b			

Wybrane cechy obrazów teksturowych:

ENERGIA

$$E = \sum_{i=1}^N \sum_{j=1}^N [C_{\delta}(i, j)]^2$$

KONTRAST

$$K = \sum_{i=1}^N \sum_{j=1}^N (i - j)^2 C_{\delta}(i, j)$$

ENTROPIA

$$Et = - \sum_{i=1}^N \sum_{j=1}^N C_{\delta}(i, j) \log C_{\delta}(i, j)$$

JEDNORÓDNOŚĆ

$$E = \sum_{i=1}^N \sum_{j=1}^N \frac{C_{\delta}(i, j)}{1 + |i - j|}$$

3.2. Wybór obrazów ciągu uczącego

Obrazy (wielkości 64x64 piksele) do ciągu uczącego zostały wybrane na podstawie wyżej wymienionych cech obrazów teksturowych. Potraktowanie tych obrazów jako teksturowe umożliwiło zautomatyzowanie sposobu wyboru obrazów dla ciągu uczącego, który liczy po 80 elementów dla każdej z trzech klas.

W tablicy 2 przedstawiono zakresy wartości takich cech, jak: energia, kontrast, entropia dla klas obrazu tekstury o rozmiarze 64x64 piksele. Minimalne i maksymalne wartości dla danej cechy wyznaczono doświadczalnie na podstawie badań cech kilkuset obrazów, do których wykorzystano oprogramowanie własne wykonane w środowisku zintegrowanym DELPHI.

W wyniku tych badań stwierdzono, że wygląd ponad 90% obrazów spełniających kryteria przynależności do danej klasy (tabl. 2) jest zgodny z przewidywanym. W celu zwiększenia dokładności wnioskowania w następnych badaniach dołożone zostaną dodatkowe kryteria przynależności obrazu do danej klasy.

Tablica 2

Zakresy wartości cech obrazów teksturowych dla danej klasy obrazów
ciągu uczącego

Rodzaj obrazu	Energia		Kontrast		Entropia	
	Min	Max	Min	Max	Min	Max
kl.1	$53 \cdot 10^5$	$60 \cdot 10^5$	800	1100	-2800	-1800
kl.2	$61 \cdot 10^5$	$66 \cdot 10^5$	500	700	-1800	-1300
kl.3	$67 \cdot 10^5$	$84 \cdot 10^5$	400	600	-1300	-800

Przykładowe obrazy klasy 1



Przykładowe obrazy klasy 2



Przykładowe obrazy klasy 3




Rys. 4. Przykładowe obrazy mikroskopowe
Fig. 4. Instances of microscopic images

4. WYNIKI BADAŃ

Wyniki rozpoznania sieci dla obrazów testowych po 150000 iteracji przy 240-elementowym ciągu uczącym, po 80 obrazów o rozdzielczości 64x64 z każdej z trzech klas.

Przykładowe wyniki rozpoznania obrazu spoiny o powiększeniu 250-krotnym przedstawiono na rys.5. Numery na obrazie oznaczają przynależność podobrazu do jednej z trzech klas. Możemy w ten sposób uzyskać informację o zawartości procentowej

elementów z danej klasy na jednym obrazie lub w cyklu obrazów z danej spiny, co umożliwia obliczenie własności mechanicznych tej spiny.



Rys. 5. Podział obrazu na podobrazy o rozmiarze 64x64 piksele
Fig. 5. Partitioning of image into 64x64 pixel patches

Każdy z obrazów jest wprowadzany do sieci i po sprawdzeniu wszystkich podobrazów można podać procentową zawartość elementów graficznych z klasy 1, 2 lub 3 na obrazie.

Na przykładowym obrazie procentowa zawartość elementów z każdej klasy jest następująca:

- klasy 1 jest $8/30 * 100\% \approx 27\%$,
- klasy 2 jest $15/30 * 100\% = 50\%$,
- klasy 3 jest $7/30 * 100\% \approx 23\%$.

5. WYŻSZA JAKOŚĆ ROZPOZNAWANIA. WNIOSKI

W celu podniesienia klasy diagnostycznej sieci przewidziano dalsze prace eksperymentalne w obszarach:

- dodatkowych klas obrazów,
- zmian algorytmu uczenia sieci,
- zmian struktury sieci,
- zwiększenie rozmiaru ciągu uczącego.

Opracowana sieć neuronowa umożliwia klasyfikację spoin ze względu na proporcje zawartości ferrytów. Uzyskane wyniki potwierdzają konieczność przygotowania znacznie obszerniejszej bazy sklasyfikowanych obrazów spoin, tak aby można było zwiększyć dokładność uczenia sieci. Analiza czasu nauki sieci wykazała konieczność modyfikacji algorytmu uaktualniania wag oraz zwiększenia mocy obliczeniowej komputera w celu osiągnięcia odpowiednich czasów przetwarzania obrazów tak dużej bazy danych.

Literatura

1. Osowski S.: Sieci neuronowe w ujęciu algorytmicznym. WNT, Warszawa 1996.
2. Pamuła T.: Środowisko programowe systemu przetwarzania obrazów do określania parametrów ruchu drogowego. Zeszyty Naukowe Politechniki Śląskiej, Transport z.30, Gliwice 1998.
3. Tadeusiewicz R.: Sieci neuronowe. Akademicka Oficyna Wydawnicza, Warszawa 1993.
4. Tadeusiewicz R.: Elementarne wprowadzenie do techniki sieci neuronowych z przykładowymi programami. Akademicka Oficyna Wydawnicza, Warszawa 1998.
5. Korbicz J., Obuchowicz A., Uciński D.: Sztuczne sieci neuronowe. Akademicka Oficyna Wydawnicza, Warszawa 1994.
6. Webber C. J. S.: Feature recognition with minimal assumptions by neural self organisation. TSI Intelligent Automation and Soft Computing, vol. 9 1998.
7. Adamiec J.: Praca doktorska, Katowice 2000.
8. Bhadeshia H.K.D.H.: Neural Networks in Materials Science, ISIJ International 1999.

Recenzent: Prof. J.Piecha

Abstract

The paper presents an attempt to apply a neural network for assessing the properties of low carbon welds. The properties are determined by the microstructure of the welds. This structure is formed in the process of melting and cooling of steel in the weld. The process and the resulting structure may be described using a set of variables such as: linear energy of welding, ferrite content and weld properties.

A three layer unidirectional non linear net was designed to analyse the welding data. Microscopic images of the welds, were used as inputs and combined with the contents of a database of weld properties. The course of the net training, was carried out using the backpropagation scheme with different learning rates and momentum coefficients for the net layers.

The weld images were treated as textures. A method for preparing training sequences was devised, based on texture analysis methods.

The application of the proposed neural network proved to be successful. Further research is needed to optimise the learning rate and fidelity of structure recognition.