

Sebastian DUDZIK, Waldemar MINKINA
POLITECHNIKA CZĘSTOCHOWSKA, WYDZIAŁ ELEKTRYCZNY,
Al. Armii Krajowej 17, 42-200 Częstochowa

Dwuetaповy algorytm wyznaczania głębokości defektów z zastosowaniem aktywnej termografii dynamicznej

Dr inż. Sebastian DUDZIK

Ukończył w roku 2000 Wydział Elektryczny Politechniki Częstochowskiej. W 2007 r. obronił z wyróżnieniem pracę doktorską. Jest autorem i współautorem trzech monografii, w języku polskim i angielskim oraz ponad 30 publikacji z zakresu dokładności pomiarów termowizyjnych i zastosowań metod sztucznej inteligencji do modelowania złożonych zjawisk wymiany ciepła. Specjalizuje się w aktywnej termografii dynamicznej. Jest współautorem dwóch patentów.



e-mail: sebdud@el.pcz.czest.pl

Prof. dr hab. inż. Waldemar MINKINA

Ukończył w 1977 r. Wydział Elektryczny Politechniki Częstochowskiej, doktorat w 1983 r. w Instytucie Metrologii Elektrycznej Politechniki Wrocławskiej, habilitacja w 1995 r. na Wydziale Automatyki Politechniki Lwowskiej, tytuł prof. nauk technicznych w 2006 r. na AGH w Krakowie. Jest autorem i współautorem 7 książek i monografii, ponad 140 publikacji oraz 14 patentów i zgłoszeń patentowych. Specjalizuje się w problematyce termometrii, termografii, pomiarów cieplnych, nauk komputerowych i informatycznych.



e-mail: minkina@el.pcz.czest.pl

Streszczenie

W pracy zaprezentowano dwuetaповy algorytm wyznaczania głębokości defektów materiałowych. W celu oszacowania głębokości defektu zastosowano dwie sztuczne sieci neuronowe uczone z użyciem danych uzyskanych za pomocą termografii aktywnej. W pierwszym etapie algorytmu przeprowadzana jest detekcja (lokalizacja) defektów za pomocą sieci klasyfikacyjnej. W etapie drugim sieć regresyjna wyznacza głębokość defektu zlokalizowanego w etapie pierwszym. W pracy zaprezentowano wyniki symulacji algorytmu a także zaproponowano kryteria oceny dokładności wyznaczania głębokości.

Słowa kluczowe: aktywna termografia dynamiczna, sieci neuronowe, wyznaczanie głębokości defektu.

A two-stage algorithm for defect depth estimation using active thermography

Abstract

In the paper a two-stage neural algorithm for defect detection and characterization is presented. In order to estimate the defect depth, two neural networks trained on data obtained using active thermography were employed. The first stage of the algorithm is developed to detect the defect and uses a classification neural network. Then the defect depth is estimated using a regressive neural network. In this work the results of experimental investigations using the infrared time resolved radiometry method are described. The sequences of thermograms of the investigated sample were recorded for three phases of the heat process i.e. heating, cooling and both. The experiments were conducted using a test sample made of material with a low thermal diffusivity. In the paper the results of simulations are presented as well. The 10-fold cross-validation procedure was applied to testing data. The simulations were performed using the PCA routine for the data obtained from the three above-mentioned heat process phases occurred in the investigated material sample.

Keywords: active thermography, neural networks, defect depth estimation.


1. Wprowadzenie

1.1. Wyznaczanie głębokości defektów z zastosowaniem termografii aktywnej

Aktywna termografia dynamiczna umożliwia wykrywanie defektów materiałowych bez zmiany właściwości badanych obiektów [1-3]. Oprócz wykrycia defektu, często niezbędna jest identyfikacja jego parametrów, takich jak np. głębokość [1, 4-7]. Na rys. 1 przedstawiono schemat próbki badanego materiału z zaznaczeniem parametrów defektu podlegających identyfikacji.

Na rys. 1 przyjęto następujące oznaczenia: x, y, z – współrzędne przestrzenne, a_0 – dyfuzyjność cieplna materiału próbki w obszarze pozbawionym defektu, a_{def} – dyfuzyjność cieplna materiału w obszarze defektu, z_{def} – głębokość defektu, L_{def} – grubość defektu (wymiar przestrzenny defektu w kierunku określonym przez

współrzedną z), R_{def} – opór cieplny defektu. Wyznaczanie głębokości defektów stanowi złożone zagadnienie odwrotne wymiany ciepła [8].



Rys. 1. Parametry defektu

Fig. 1. Parameters of the defect

Z uwagi na skomplikowaną postać analityczną zależności opisujących zagadnienie odwrotne, w niniejszej pracy do wyznaczania głębokości defektów zastosowano sztuczne sieci neuronowe [7, 9, 10].

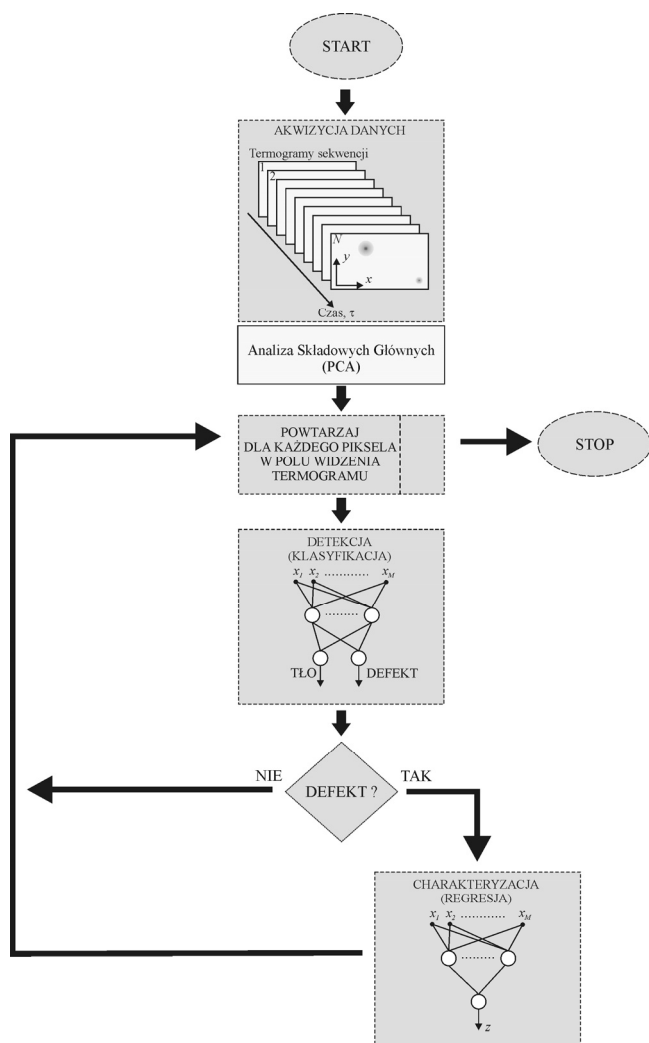
1.2. Dwuetaповy algorytm wyznaczania głębokości defektu

W niniejszym artykule zaprezentowano wyniki badań dwuetaповego neuronowego algorytmu wyznaczania głębokości defektów. Stanowi on połączenie neuronowego algorytmu klasyfikacji umożliwiającego wykrycie defektu oraz neuronowego algorytmu regresji pozwalającego na wyznaczenie głębokości defektu [10]. Algorytm działa w dwóch trybach: trybie nauki i trybie odtwarzania. Działanie w trybie nauki przebiega niezależnie dla dwóch sieci neuronowych tj. sieci klasyfikacyjnej i sieci regresyjnej. Pierwszym etapem działania algorytmu w trybie odtwarzania jest rejestracja sekwencji termogramów powierzchni próbki testowej. W kolejnych krokach, dla każdego piksela w polu widzenia termogramu zarejestrowanej sekwencji przeprowadzana jest detekcja czyli określenie, czy dany piksel należy do obszaru defektu, czy do obszaru tła. Następnie, jeżeli rozpatrywany piksel pola widzenia, został sklasyfikowany jako defekt, neuronowy algorytm regresji wyznacza głębokość defektu leżącego pod elementem powierzchni reprezentowanym przez ten piksel. Algorytm przerywa działanie, gdy dla wszystkich pikseli w polu widzenia analizowanego termogramu, sklasyfikowanych jako należące do obszarów defektów, zostaje wyznaczona głębokość.

W pracy przyjęto, że sklasyfikowany obiekt stanowi przebieg czasowy przyrostu temperatury nad temperaturę początkową, zarejestrowany w określonym punkcie powierzchni badanej próbki (dla określonego piksela). Neuronowy algorytm klasyfikacji przyporządkowuje poszczególne piksele termogramu powierzchni badanej próbki do dwóch klas, reprezentujących odpowiednio

defekt lub jego brak. Na wejście klasyfikatora neuronowego podaje się przetworzone za pomocą procedury PCA wartości przyrostów temperatury powierzchni próbki wzorcowej nad temperaturę początkową dla poszczególnych pikseli [7, 11]. Liczba wejść sieci jest równa liczbie wybranych składowych głównych a liczba wektorów uczących liczbie pikseli termogramu, należących do pola widzenia obejmującego powierzchnię badanej próbki. Liczba składowych głównych a co za tym idzie liczba wejść sieci wybrana została na podstawie kryterium skumulowanej wariancji objaśnianej, która w tym przypadku przyjęła wartość 98%. Jeden neuron wyjściowy reprezentuje klasę, której przyporządkowany jest defekt, natomiast drugi – klasę oznaczającą brak defektu.

W drugim etapie algorytmu dwuetapowego zastosowano sieć regresyjną. Podobnie jak w algorytmie klasyfikacji utworzono wejściowe wektory uczące. Sieć regresyjna posiada jedno wyjście. W trakcie nauki, na wyjście tej sieci podaje się wartość głębokości defektu przynależną danemu pikselowi w analizowanym polu widzenia termogramu. Nauka przeprowadzana jest za pomocą algorytmu propagacji wstecznej. Jak wspomniano wyżej algorytm dwuetapowy stanowi połączenie algorytmów klasyfikacji i regresji. Schemat neuronowego algorytmu dwuetapowego przedstawiono na rys. 2.




Rys. 2. Schemat neuronowego algorytmu dwuetapowego
Fig. 2. Scheme of the two-stage neural algorithm

2. Badania eksperymentalne

Badania eksperymentalne neuronowego algorytmu dwuetapowego przeprowadzono na stanowisku, którego schemat przedstawiono na rys. 3 [6, 7, 11]. Stanowisko składa się z zamkniętej


komory badawczej (1) umożliwiającej odizolowanie procesu pomiarowego od wpływu promieniowania otoczenia oraz elementów pomiarowo sterujących, znajdujących się poza komorą. Wewnątrz komory znajduje się kamera termowizyjna FLIR ThermoCAM PM595 (2), dwie lampy (3), każda o mocy 250 W. Dodatkowo wewnątrz komory umieszcza się badaną próbkę (4). Poza komorą znajdują się komputer stacjonarny (5) do rejestracji sekwencji termogramów w czasie rzeczywistym oraz układ interfejsów cyfrowych (6) współpracujący z kartą cyfrowej akwizycji obrazów z kamery termowizyjnej (ang. *frame grabber*).

W badaniach, użyto próbki testowej, wykonanej z polimetakrylanu metylu (PMMA). Dyfuzyjność cieplną próbki, na podstawie danych producenta obliczono jako równą $0,12 \cdot 10^{-6} \text{ m}^2 \cdot \text{s}^{-1}$.



Rys. 3. Stanowisko do badań metodą długiego impulsu cieplnego [6, 7, 11]
Fig. 3. The measuring stand used for the stepped heating method [6, 7, 11]


W badanej próbce materiału wytworzono powietrzne defekty materiałowe. Defekty zlokalizowano na głębokościach: $z_1 = 1,0 \text{ mm}$, $z_2 = 1,2 \text{ mm}$, $z_3 = 1,4 \text{ mm}$, $z_4 = 1,6 \text{ mm}$, $z_5 = 1,8 \text{ mm}$, $z_6 = 2,0 \text{ mm}$, $z_7 = 2,2 \text{ mm}$, $z_8 = 2,4 \text{ mm}$, $z_9 = 2,6 \text{ mm}$ względem wierzchniej strony próbki. Powierzchnię próbki pokryto czarnym, matowym lakierem o dużej wartości pasmowego współczynnika emisyjności ($\varepsilon \approx 0,9$). Wymiary i rozmieszczenie defektów wytworzonych w badanej próbce materiału przedstawiono na rys. 4.



Rys. 4. Wymiary i rozmieszczenie defektów w badanej próbce materiału
Fig. 4. Dimensions and localization of defects in the investigated material sample

Powierzchnię badanej próbki nagrzewano impulsem cieplnym o całkowitej mocy elektrycznej 500 W i czasie trwania 120 s, przy czym dla zwiększenia jednorodności zastosowano dwie lampy.

Na rys. 7 zaprezentowano przykładowy wynik procedury walidacji krzyżowej sieci regresyjnej zastosowanej w drugim etapie opisywanego algorytmu. Jest to mapa głębokości wyznaczona przez sieć uczoną z użyciem zbioru HEAT&COOL. Mapę wyznaczono dla danych testowych.



Rys. 7. Mapa głębokości defektów wyznaczona przez sieć neuronową uczoną przy użyciu zbioru HEAT&COOL (etap regresji) – dane testowe

Fig. 7. The map of defect depth generated using the neural network trained with the HEAT&COOL dataset (regression stage) – testing data

Wartości średnich granicznych błędów wyznaczania głębokości w obszarze defektu dla algorytmu dwuetapowego obliczono na podstawie mapy głębokości defektów wygenerowanej przez algorytm regresyjny w etapie 2. Dane wejściowe (piksele) dla algorytmu regresyjnego (etap 2) zostały wskazane przez algorytm klasyfikacyjny (etap 1). Wartości średnich granicznych błędów względnych wyznaczania głębokości w obszarach defektów, obliczone na podstawie walidacji krzyżowej zbiorów danych HEAT, COOL i HEAT&COOL zestawiono w tabeli 2.

Tab. 2. Średnie graniczne błędy względne wyznaczania głębokości w obszarach defektów (algorytm dwuetapowy) – dane testowe

Tab. 2. Relative mean errors of depth estimation in the defected areas (two-stage algorithm) – testing data

		z_R (mm):								
		1,0	1,2	1,4	1,6	1,8	2,0	2,2	2,4	2,6
δ_{z-TEST} (%)	HEAT	2,0	2,6	2,1	2,2	0,8	2,6	4,3	2,4	2,6
	COOL	2,4	2,9	2,2	2,4	2,9	2,4	1,6	1,7	1,5
	HEAT&COOL	1,5	2,0	1,9	2,3	1,5	1,9	2,1	1,6	1,1
	COOL									

4. Wnioski

Na podstawie wyników badań symulacyjnych neuronowego algorytmu dwuetapowego, sformułowano następujące wnioski:

- Analizując wyniki badań pierwszego etapu opisywanego algorytmu zestawione w tabeli 1 należy stwierdzić, że mniejsze wartości błędów klasyfikacji w poszczególnych obszarach defektów uzyskuje się dla zbiorów danych HEAT&COOL (faza nagrzewania i stygnięcia) oraz COOL (faza stygnięcia). Nieco większe wartości błędów klasyfikacji obserwuje się dla zbioru HEAT (faza nagrzewania).
- Biorąc pod uwagę niewielkie różnice wartości błędów, należy stwierdzić, że klasyfikacja przeprowadzana w pierwszym etapie algorytmu daje podobne rezultaty dla każdej analizowanej fazy procesu cieplnego zachodzącego w badanych próbkach.
- Największy błąd klasyfikacji na danych testowych zaobserwowano dla fazy nagrzewania i głębokości $z_R = 1,4$ mm. Błąd ten wyniósł 8.3% – tabela 1.
- Porównując wyniki badań analizowanego algorytmu, zestawione w tabeli 2 należy stwierdzić, że najmniejsze wartości średnich granicznych błędów względnych w poszczególnych obszarach defektów na danych testowych, uzyskuje się dla zbioru da-

nych reprezentującego nagrzewanie i stygnięcie badanej próbki testowej (HEAT&COOL).

- Dodatkowo, można zauważyć, że różnice w wartościach średnich granicznych błędów względnych w poszczególnych obszarach defektów na danych testowych, wyznaczone dla wszystkich analizowanych faz procesu wymiany ciepła nie różnią się znacząco od siebie.
- Na podstawie danych z tabeli 2 można wyciągnąć wniosek, że możliwe jest ograniczenie czasu rejestracji sekwencji (skrócenie czasu pomiaru z 420 s do 120 s), bez znaczącej utraty dokładności wyznaczania głębokości.
- Największą wartość średniego granicznego błędu względnego wyznaczania głębokości w obszarze defektu na danych testowych zaobserwowano dla fazy nagrzewania (zbiór danych HEAT) dla defektu o głębokości $z_R = 2,2$ mm. Wartość ta wyniosła 4.3%.
- Najmniejszą wartość średniego granicznego błędu względnego wyznaczania głębokości w obszarze defektu na danych testowych zaobserwowano dla fazy nagrzewania i stygnięcia (zbiór danych HEAT&COOL) dla defektu o głębokości $z_R = 2,6$ mm. Wartość ta wyniosła 1.1%.

5. Literatura

- [1] Maldague X.P.: Theory and practice of infrared technology for nondestructive testing. John Wiley & Sons Interscience, New York, 2001.
- [2] Dudzik S.: Zastosowanie morfologii matematycznej do wykrywania defektów materiałowych z wykorzystaniem aktywnej termografii w podczerwieni, rozdz. 3 w monografii: Wybrane problemy współczesnej termografii i termometrii w podczerwieni, pod red. W. Minkiny, Wydawnictwo Politechniki Częstochowskiej, Częstochowa, str. 62-78.
- [3] Dudzik S.: A simple method for defect area detection using active thermography, Opto-Electronics Review, Vol. 17, Issue 4, pp. 338–344, 2009.
- [4] Gleiter A., Spiessberger C., Busse G.: Phase angle thermography for depth resolved characterization, 9-th International Conference on Quantitative Infrared Thermography QiRT, Kraków, 2–5 lipca 2008, str. 435–441.
- [5] Vallerand S., Maldague X.P.: Defect characterization in pulsed thermography: a statistical method compared with Kohonen and Perceptron neural networks, NDT&E International 33, 2000, pp. 307–315.
- [6] Dudzik S.: Application of the naive Bayes classifier to defect characterization using active thermography, Journal of Nondestructive Evaluation, (31) 4, 2012, pp. 383-392.
- [7] Dudzik S.: Analysis of the accuracy of a neural algorithm for defect depth estimation using PCA processing from active thermography data, Infrared Physics and Technology, (56) 2013, pp. 1-7.
- [8] Alifanow O.M.: Inverse Heat Transfer Problems, Springer-Verlag, Berlin, Heidelberg, 1994.
- [9] Dudzik S.: Investigations of a heat exchanger using infrared thermography and artificial neural networks, Sensors & Actuators: A. Physical 166–1, 2011, pp. 149–156.
- [10] Dudzik S.: Wyznaczanie głębokości defektów materiałowych z zastosowaniem aktywnej termografii dynamicznej i sztucznych sieci neuronowych, Wydawnictwo Politechniki Częstochowskiej, Częstochowa, 2013.
- [11] Van Der Heijden F., Duin R., de Ridder D., Tax D.M.J.: Classification, parameter estimation and state estimation: An engineering approach using MATLAB, John Wiley & Sons, 2004.