

**Sebastian DUDZIK**

POLITECHNIKA CZĘSTOCHOWSKA, WYDZIAŁ ELEKTRYCZNY, INSTYTUT ELEKTRONIKI I SYSTEMÓW STEROWANIA  
Al. Armii Krajowej 17, 42-200 Częstochowa

## Ocena wpływu błędu określania emisyjności powierzchni na błąd wyznaczania głębokości defektu z zastosowaniem termografii aktywnej i sztucznej sieci neuronowej

Dr inż. Sebastian DUDZIK



Ukończył w roku 2000 Wydział Elektryczny Politechniki Częstochowskiej. W 2007 r. obronił z wyróżnieniem pracę doktorską. Od 2008 roku jest zatrudniony na stanowisku adiunkta na Wydziale Elektrycznym Politechniki Częstochowskiej. 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.

e-mail: [sebdud@el.pcz.czest.pl](mailto:sebdud@el.pcz.czest.pl)

### Streszczenie

W pracy zaprezentowano algorytm wyznaczania głębokości defektów, metodą aktywnej termografii w podczerwieni. Podstawą działania algorytmu jest sztuczna sieć neuronowa uczona z zastosowaniem przebiegów czasowych temperatury, zarejestrowanych za pomocą kamery termowizyjnej na powierzchni próbki testowej. Dodatkowo w pracy zaprezentowano wyniki analizy wpływu błędu określania emisyjności powierzchni próbki testowej na dokładność wyznaczania głębokości defektów powietrznych za pomocą opisywanego algorytmu.

**Słowa kluczowe:** Termografia aktywna, sieć neuronowa, wyznaczanie głębokości defektu.

### An analysis of systematic interactions in defect depth estimation using active thermography and artificial neural network

#### Abstract

In this work the investigation results of an algorithm for defect depth estimation are presented. This algorithm uses an active thermography data and artificial neural network. In introduction a model of temperature measurement with an infrared camera is described. Further, in Section 1.1 the main error sources in the passive thermographic procedure are pointed out. The algorithm of defect depth estimation is presented in Section 1.3. It is based on the artificial neural network trained with the temporal evolutions of temperature of the investigated specimen, recorded with use of an infrared camera. In Section 2, the methodology and results of the experimental research using the stepped heating method are described. In the investigations two specimens containing aerial defects were used. The specimens were made of polymethyl methacrylate. Based on the thermal inspections of the specimen surface, three training datasets were created. They represented three phases of the heat transfer process occurring in the investigated specimens (i.e. heating, cooling, heating and cooling). In Section 3 the methodology and results of the simulation research are presented. In particular, the influence of the emissivity error on the accuracy of defect depth estimation was examined. The simulation results as the components of the relative error of defect depth estimation connected with the emissivity error are shown in Figs. 9, 10. Based on the simulations, the quantitative conclusions regarding the algorithm sensitivity to the emissivity error are formulated.

**Keywords:** active thermography, artificial neural network, defect depth estimation.

## 1. Wprowadzenie

### 1.1. Termografia pasywna

Do określenia rozkładu temperatury na powierzchni badanego obiektu może być wykorzystana kamera termowizyjna [1].

W modelu pomiaru temperatury kamerą termowizyjną niezbędne jest uwzględnienie strumienia promieniowania cieplnego emitowanego przez badaną powierzchnię, emitowanego przez otoczenie i odbitego od badanej powierzchni oraz emitowanego przez samą atmosferę. Zgodnie z modelem pomiaru zastosowanym w kamerach FLIR ThermoCAM PM595, wartość temperatury obiektu wyraża się następującą funkcją [1]:

$$T_{ob} = f(\varepsilon_{ob}, T_{atm}, T_0, \omega, d), \quad (1)$$

gdzie:  $\varepsilon_{ob}$  – pasmowy współczynnik emisyjności powierzchni badanego obiektu;  $T_{atm}$  – temperatura atmosfery w K,  $T_0$ , K – temperatura otoczenia, tj. temperatura obiektów, znajdujących się w sąsiedztwie obiektu badanego, których promieniowanie odbija się od tego obiektu,  $\omega$  – wilgotność względna atmosfery, rozumiana jako uśredniona wilgotność warstwy atmosfery pomiędzy kamerą a badanym obiektem,  $d$ , m – odległość pomiędzy kamerą i obiektem.

Szczegółowa analiza modelu (1) została przeprowadzona między innymi w pracy [1]. Wynika z niej, że wszystkie wielkości wejściowe opisywanego modelu mają wpływ na wyniki pomiaru temperatury. Niemniej jednak największy wpływ na błąd pomiaru temperatury systemem termowizyjnym w warunkach badań nieniszczących prowadzonych metodą długiego impulsu cieplnego ma błąd  $\Delta\varepsilon_{obs}$ , związany z określeniem emisyjności powierzchni badanego obiektu (w tym przypadku emisyjności powierzchni badanej próbki materiału). W niniejszej pracy oszacowano wpływ tego błędu na dokładność wyznaczania głębokości defektu za pomocą termografii aktywnej i neuronowego algorytmu wyznaczania głębokości defektów.

### 1.2. Metoda długiego impulsu cieplnego


W termografii aktywnej badany materiał poddaje się wymuszeniu cieplnemu a następnie rejestruje się odpowiedź w formie niestabilnego pola temperatury powierzchni badanego obiektu. Zależnie od metody wymuszenia znane są różne metody badań, takie jak np.: termografia impulsowa (ang. *pulsed thermography*) lub termografia impulsowo-fazowa (ang. *phase-pulsed thermography*) [2]. W niniejszej pracy jako metodę badawczą zastosowano nagrzewanie długim impulsem cieplnym (ang. *stepped heating, time-resolved infrared radiometry*) [2, 3]. W metodzie tej, zwiększanie temperatury powierzchni jest monitorowane przez cały czas trwania wymuszenia w postaci długiego impulsu cieplnego. Badana próbka jest nagrzewana w sposób ciągły przy niskiej mocy wymuszenia [4, 5].

### 1.3. Neuronowy algorytm wyznaczania głębokości defektu

Proces ilościowego wyznaczania głębokości defektu nazywany jest charakteryzacją [2], przy czym defekt rozumie się, jako nieciągłość (np. ubytek) badanego materiału w ściśle określonym obszarze próbki. W niniejszej pracy do wyznaczania głębokości powietrznych defektów materiałowych zastosowano algorytm oparty na regresyjnej sieci neuronowej [6]. Schemat algorytmu przedstawiono na rys. 1.

Pierwszym etapem algorytmu jest rejestracja sekwencji czasowych termogramów. Następnie zostaje uformowany wektor uczący, składający się z wartości wejściowych, uzyskanych na podsta-


wie temperatur przyporządkowanych do określonego piksela, wyznaczonych dla każdej chwili czasowej. Wartości wejściowe sieci uzyskuje się w wyniku analizy składowych głównych PCA [5]. W tym przypadku, liczba wejść sieci równa jest liczbie wybranych składowych głównych  $M$ , zależnej od liczby chwil czasowych  $N$  (tj. liczby zarejestrowanych termogramów).



Rys. 1. Schemat neuronowego algorytmu wyznaczania głębokości defektu  
Fig. 1. Scheme of the neural algorithm for defect depth estimation

## 2. Badania eksperymentalne

Schemat stanowiska do badań eksperymentalnych zaprezentowano na rys. 2.




Rys. 2. Stanowisko do charakteryzacji defektów metodą długiego impulsu cieplnego  
Fig. 2. Experimental setup used in the stepped heating method


Na rys. 2 przyjęto następujące oznaczenia: 1 – zamknięta komora badawcza izolująca od niekorzystnego wpływu promieniowania otoczenia [4, 5], 2 – długofalowa kamera termowizyjna FLIR ThermoCAM PM595, 3 – lampy modelujące, każda o mocy 250 W, 4 – badana próbka, 5 – komputer PC wyposażony w kartę framegrabbera i oprogramowanie do akwizycji sekwencji termogramów w czasie rzeczywistym, 6 – moduł cyfrowego interfejsu komunikacyjnego.

W badaniach użyto dwóch próbek testowych P-1 i P-2, wykonanych z polimetakrylanu metylu. Powierzchnie próbek pokryto lakierem o emisyjności odpowiednio  $\varepsilon = 0,98$  w przypadku próbki PT-1 i  $\varepsilon = 0,90$  w przypadku próbki PT-2. W obu próbkach od spodniej strony nawiercono, nieprzelotowe otwory, prostopadłe do powierzchni próbek, wytwarzając powietrzne defekty materiałowe o średnicy 10 mm. Rozmieszczenie i głębokości defektów w próbkach P-1 i P-2 zaprezentowano odpowiednio na rys. 3 i 4.


W trakcie badań eksperymentalnych, powierzchnię obu próbek nagrzewano impulsem cieplnym o całkowitej mocy elektrycznej 500 W i czasie trwania 120 s. Jako źródło wymuszenia cieplnego zastosowano dwie lampy, każda o mocy 250 W. Sekwencje termogramów rejestrowano w trakcie trwania fazy nagrzewania i przez 300 s fazy stygnięcia.




Rys. 3. Rozmieszczenie defektów w próbce P-1  
Fig. 3. Arrangement of defects in P-1 specimen



Rys. 4. Rozmieszczenie defektów w próbce P-2  
Fig. 4. Arrangement of defects in P-2 specimen



Rys. 5. Termogram powierzchni próbki P-1 przy  $\tau = 120$   
Fig. 5. Thermogram of the P-1 specimen surface at  $\tau = 120$



Rys. 6. Termogram powierzchni próbki P-2 przy  $\tau = 120$   
Fig. 6. Thermogram of the P-2 specimen surface at  $\tau = 120$

Częstotliwość próbkowania ustalono na 1 Hz. Przykładowe termogramy powierzchni próbek P-1 i P-2 zarejestrowane w chwili  $\tau = 120$  s (koniec fazy nagrzewania) przedstawiono odpowiednio na rys. 5 i 6.

### 3. Badania symulacyjne

#### 3.1. Metodyka badań

W niniejszej pracy, do nauki sieci wykorzystano sekwencje termogramów powierzchni próbek P-1 i P-2, zarejestrowane w trakcie badań eksperymentalnych. W symulacjach opisanego wyżej algorytmu wykorzystano sekwencje obrazujące nieustalone pola temperatur na powierzchniach próbek dla 120 s fazy nagrzewania, 300 s fazy stygnięcia oraz 420 s cyklu nagrzewania i stygnięcia.

Na podstawie wyżej opisanych sekwencji, dla każdej z badanych próbek, utworzono trzy zestawy danych uczących  $DS-1$ ,  $DS-2$  i  $DS-3$ . Symulacje modelu (1) przeprowadzono metodą przyrostów [1]. Na podstawie symulacji modelu (1) wyznaczono składową błąd bezwzględnego pomiaru temperatury  $\delta T_{ob}$ , związaną z błędem określania emisyjności  $\Delta \varepsilon_{ob}$ . Składowe: bezwzględną  $\Delta z_\varepsilon$  i względną  $\delta z_\varepsilon$ , błąd neuronowego algorytmu wyznaczania głębokości defektu, związane z emisyjnością powierzchni próbki obliczono jako:

$$\Delta z_\varepsilon = z_{NET}^\varepsilon - z_R, \text{ mm}; \quad \delta z_\varepsilon = \frac{z_{NET}^\varepsilon}{z_R} \cdot 100, \% \quad (2)$$

gdzie:  $z_{NET}^\varepsilon$  – głębokość wyznaczona przez algorytm charakterystyki, jako wartość średnia głębokości obliczonej przez grupę dziesięciu sieci neuronowych biorących udział w procedurze walidacji krzyżowej, dla pikselu reprezentującego środek obszaru defektu.  $z_R$  – głębokość defektu zadawana w procesie uczenia sieci (znana wartość poprawna).

#### 3.2. Wyniki badań symulacyjnych

Symulacyjną analizę wrażliwości modelu pomiaru temperatury (1) przeprowadzono w odniesieniu do błędu względnego określania emisyjności. Wartości wielkości wejściowych, przyjęte podczas symulacji, zestawiono w tabeli 1.


Tab. 1. Zestawienie wartości wielkości wejściowych w badaniach symulacyjnych modelu (1)

Tab. 1. Values of the input quantities used in simulations of model (1)

Próbka	$\varepsilon_{ob}$	$T_0, \text{K}$	$T_{am}, \text{K}$	$\omega$	$d, \text{m}$
P-1	0,98	295	295	0,5	1,0
P-2	0,90	295	295	0,5	1,0


Przykładowe przebiegi przyrostu temperatury powierzchni próbki P-1 wyznaczone dla zadanych wartości błędów emisyjności powierzchni  $\delta \varepsilon_{ob} = 0\%$  (przebieg nieodstrojony) oraz  $\delta \varepsilon_{ob} = -5\%$  i  $\delta \varepsilon_{ob} = +2\%$  zaprezentowano na rys. 7. Przebiegi uzyskano dla punktu środkowego obszaru defektu o głębokości  $z_R = 1,3$  mm oraz przyjmując wartość dokładną emisyjności równą 0,98 (tab. 1). Na rys. 8 zaprezentowano przebiegi przyrostu temperatury powierzchni próbki P-2 obliczone dla błędów emisyjności powierzchni  $\delta \varepsilon_{ob} = 0\%$ ,  $\delta \varepsilon_{ob} = -5\%$  i  $\delta \varepsilon_{ob} = +5\%$ . Przebiegi te uzyskano dla punktu środkowego obszaru defektu o głębokości  $z_R = 2,0$  mm oraz przyjmując wartość dokładną emisyjności równą 0,90 (tab. 1).

Przykładowe wyniki symulacji neuronowego algorytmu wyznaczania głębokości defektów w próbkach P-1 i P-2, uzyskane na podstawie zależności (2), zaprezentowano na rys. 9 i 10.




Rys. 7. Przebiegi przyrostu temperatury powierzchni próbki P-1 uzyskane na podstawie symulacji modelu (1)

Fig. 7. Temporal evolutions of the temperature rise of the P-1 specimen surface obtained from simulations of model (1)



Rys. 8. Przebiegi przyrostu temperatury powierzchni próbki P-2 uzyskane na podstawie symulacji modelu (1)

Fig. 8. Temporal evolutions of the temperature rise of the P-2 specimen surface obtained from simulations of model (1)




Rys. 9. Wyniki symulacji neuronowego algorytmu wyznaczania głębokości defektu w próbce P-2

Fig. 9. Simulation results of the neural algorithm for defect depth estimation in P-2 specimen

W badaniach przetestowano sieci neuronowe o architekturach 15-5-5-1 w przypadku próbki P-1 oraz 15-10-7-1 w przypadku próbki P-2. Liczba wejść obu sieci równa była 15, co odpowiadało 15 składowym wybranym w procedurze analizy składowych głównych (PCA) czasowych przebiegów przyrostu temperatury

powierzchni próbek. Obie sieci miały 1 wyjście, reprezentujące wartość głębokości defektu.

Na rys. 9 przedstawiono składowe błędy względnego wyznaczenia głębokości defektu związane z emisyjnością powierzchni próbki P-1, obliczone dla poszczególnych głębokości defektów. Wykresy zaprezentowane na rys. 9 przedstawiają wyniki symulacji grupy sieci neuronowych uczonych na zbiorze danych *DS-3* reprezentującym nagrzewanie i stygnięcie.



Rys. 10. Wyniki symulacji neuronowego algorytmu wyznaczenia głębokości defektu w próbce P-2

Fig. 10. Simulation results of the neural algorithm for defect depth estimation in P-2 specimen

Składowe błędy względnego wyznaczenia głębokości defektu związane z emisyjnością powierzchni próbki P-2 zaprezentowano na rys. 10. Wykresy z rys. 10 uzyskano na podstawie symulacji grupy sieci neuronowych uczonych na zbiorze danych *DS-3*. Na podstawie wykresów 9, 10 możliwe jest oszacowanie, ile wynosi błąd względny wyznaczenia głębokości (odniesiony do znanej wartości poprawnej) przy określonym błędzie względnym wyznaczenia emisyjności powierzchni próbki testowej.

#### 4. Wnioski

Na podstawie wyników badań zaprezentowanych w niniejszej pracy, sformułowano następujące wnioski.

- Algorytm oparty na regresyjnej sieci neuronowej może być wykorzystany do wyznaczenia głębokości defektów powietrznych zlokalizowanych na głębokościach od 0,8 do 2,6 mm w materiałach o małej dyfuzyjności cieplnej, zbliżonej do badanego w niniejszej pracy polimetakrylanu metylu.
- Najmniejsze wartości błędów wyznaczenia głębokości defektu w obu badanych próbkach uzyskano używając sztucznych sieci neuronowych uczonych na danych reprezentujących cykl nagrzewania i stygnięcia badanych próbek, tj. zbiór danych uczących oznaczony *DS-3* – rys. 9, 10.
- Uwzględniając powyższe stwierdzono, że opisany algorytm, uczony z użyciem wyżej wymienionego zbioru danych jest najmniej wrażliwy na oddziaływania systematyczne wynikające z błędów określenia emisyjności powierzchni.
- Należy stwierdzić, że największą wrażliwość na wpływ wymienionych wyżej oddziaływań systematycznych wykazują algorytmy uczone z użyciem zbioru danych uczących reprezentującego fazę nagrzewania, tj. zbioru *DS-1*.
- Przy odpowiednim doborze danych uczących (tj. fazy procesu cieplnego), wartość składowej błędnej względnej algorytmu, związanej z emisyjnością powierzchni badanej próbki nie przekracza 8%, dla błędów emisji  $\delta\epsilon_{ob} = \pm 5\%$  – rys. 10.

#### 5. Literatura

- [1] Minkina W., Dudzik S.: *Infrared Thermography: Errors and Uncertainties*, John Wiley & Sons, Chichester, 2009.
- [2] Maldague X.P.: *Theory and practice of infrared technology for nondestructive testing*, John Wiley & Sons Interscience, 2001.
- [3] Dudzik S.: Approximation of thermal background applied to defect detection using the methods of active thermography, *Metrology and Measurement Systems* 17 (4), 2010, 621–636.
- [4] Dudzik S.: Application of the naive Bayes classifier to defect characterization using active thermography, *Journal of Nondestructive Evaluation*, (31) 4, 2012, pp. 383-392, DOI: 10.1007/s10921-012-0149-5.
- [5] 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, DOI: 10.1016/j.infrared.2012.08.006.
- [6] Dudzik S.: Investigations of a heat exchanger using infrared thermography and artificial neural networks, *Sensors & Actuators: A. Physical* 166 (1), 2011, 149–156.

otrzymano / received: 19.12.2012

przyjęto do druku / accepted: 03.06.2013

artykuł recenzowany / revised paper

**INFORMACJE****Informacja redakcji dotycząca  
artykułów współautorskich**

W miesięczniku PAK od numeru 06/2010 w nagłówkach artykułów współautorskich wskazywany jest autor korespondujący (Corresponding Author), tj. ten z którym redakcja prowadzi wszelkie uzgodnienia na etapie przygotowania artykułu do publikacji. Jego nazwisko jest wyróżnione drukiem pogrubionym. Takie oznaczenie nie odnosi się do faktycznego udziału współautora w opracowaniu artykułu. Ponadto w nagłówku artykułu podawane są adresy korespondencyjne wszystkich współautorów.

Wprowadzona procedura wynika z międzynarodowych standardów wydawniczych.

Redakcja