

Stanisław CHUDZIK

POLITECHNIKA CZĘSTOCHOWSKA, WYDZIAŁ ELEKTRYCZNY,
Al. Armii Krajowej 17, 42-200 Częstochowa

Zastosowanie sztucznych sieci neuronowych do wyznaczenia współczynnika dyfuzyjności cieplnej

Dr inż. Stanisław CHUDZIK

Adiunkt w Zakładzie Techniki Mikroprocesorowych, Automatyki i Pomiarów Ciepłych na Wydziale Elektrycznym Politechniki Częstochowskiej. Stopień naukowy doktora uzyskał w 2003 r. na wyżej wymienionym Wydziale. Specjalizuje się w zakresie zjawisk dyfuzji ciepła, modelowania rozkładu pól temperatury, wykorzystania algorytmów numerycznych w pomiarach cieplnych, projektowania systemów pomiarowych oraz wyznaczania parametrów cieplnych materiałów.

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



Streszczenie

W artykule przedstawiono wyniki badań nad opracowywaną metodą wyznaczenia współczynnika dyfuzyjności cieplnej materiału termoizolacyjnego. W metodzie tej wykorzystano wymuszenie temperatury o charakterze harmonicznym oraz do pomiaru rozkładu temperatury planowane jest użycie kamery termowizyjnej. W badaniach symulacyjnych wykorzystano stworzony do tego celu trójwymiarowy model zjawiska dyfuzji ciepła w badanej próbce materiału. Do rozwiązania współczynnikowego zagadnienia odwrotnego zaproponowano koncepcję wykorzystania sztucznej sieci neuronowej.

Słowa kluczowe: sztuczne sieci neuronowe, przewodność cieplna, dyfuzyjność cieplna, materiały termoizolacyjne.

Determination of thermal diffusivity using artificial neural networks

Abstract

The paper presents the results of research on methods for determining the coefficient of thermal diffusivity of thermal insulating material. This method uses periodic heating as an excitation and an infrared camera for measuring the temperature distribution on the tested material surface. A three-dimensional model of the phenomenon of heat diffusion in a sample of the tested material was used for simulation investigations. To solve the coefficient inverse problem, there is proposed an idea of using an artificial neural network. The periodic heating technique is based on diffusion of a heat wave in the specimen, which is a response to the temperature harmonic excitation – Section 2. The model of a nonstationary heat flow process in the sample of material is based on a three-dimensional heat-conduction model and includes the third kind Fourier boundary conditions. For solving the system of partial differential equations, used to describe the model, the finite element method was applied [1, 2, 10]. The usability of the artificial neural network [7, 8, 9] in solving the inverse heat transfer problem in a sample of heat insulation material is presented – Section 3. The network determines the value of effective thermal diffusivity on the basis of the amplitude decrease ΔA of the thermal wave on the specimen surface, and the time in which the thermal wave moves by the distance Δz on the specimen side surface. During selection of the optimal neural network architecture many configurations were assessed. Additionally, the influence of the input quantities errors on the estimated values of the thermal parameters was also analysed using the Monte Carlo technique [12]. Simulations of the heat flow process, network training and testing processes and analysis of the error sensitivity were carried out in the Matlab environment.

Keywords: artificial neural networks, thermal diffusivity, thermo-insulating materials.

1. Wstęp

Testowanie jakości materiału termoizolacyjnego zazwyczaj koncentruje się na określeniu wartości współczynnika przewodzenia ciepła λ . Służą do tego celu specjalne aparaty płytowe wykorzystujące metodę ustalonej wymiany ciepła [1, 2]. Współczynnik

przewodzenia ciepła charakteryzuje właściwość materiału dla stanu ustalonego przepływu ciepła. Aby móc określić stany dynamiczne dyfuzji ciepła w badanym materiale konieczna jest znajomość współczynnika dyfuzyjności cieplnej a , zwanego także współczynnikiem wyrównywania temperatury. Znajomość tych dwóch parametrów pozwala określić trzeci podstawowy parametr cieplny, jakim jest pojemność cieplna $\rho \cdot c_p$. Parametry te związane są następującą zależnością:

$$a = \frac{\lambda}{\rho \cdot c_p} \quad (1)$$

Ze względu na małą wartość współczynnika pojemności cieplnej $\rho \cdot c_p$ materiału termoizolacyjnego, trudne jest jego wyznaczenie metodą kalometryczną. Dlatego określenie współczynnika dyfuzyjności cieplnej materiału termoizolacyjnego może być w tym przypadku alternatywnym rozwiązaniem.

Autor niniejszego artykułu pracuje nad rozwinięciem metod dynamicznych wyznaczania parametrów cieplnych materiałów termoizolacyjnych. Prowadzone badania obejmują między innymi możliwości wykorzystania sztucznych sieci neuronowych do rozwiązania współczynnikowego zagadnienia odwrotnego dla procesów dyfuzji ciepła w wybranych modelach stanowisk pomiarowych, które wykorzystywałyby teorię stanu nieustalonego przepływu ciepła [2, 3, 4, 5, 6].

2. Metoda termofalowa i model zjawiska dyfuzji ciepła

Metoda termofalowa bazuje na zjawisku dyfuzji fali ciepła w badanej próbce, będącej odpowiedzią na zadane wymuszenie temperaturowe o charakterze harmonicznym:

$$T = T(0, t) = T_0 + T_m \cdot \cos \omega t \quad (2)$$

gdzie: T_0 – temperatura początkowa, T_m – amplituda zmian temperatury wymuszenia, $\omega = 2\pi f$ – częstotliwość kątowna. Przy małych głębokościach wnikanie okresowych zmian temperatury zagadnienie to można rozpatrywać jako jednowymiarowe przewodzenie ciepła w płaskim ciele półnieskończonym:


$$T(x, t) = T_0 + T_m \cdot \exp\left(-\sqrt{\frac{\omega}{2a}} x\right) \cdot \cos\left(\omega t - \sqrt{\frac{\omega}{2a}} x\right) \quad (3)$$

Można zauważyć, że wewnątrz ciała półnieskończonego temperatura zmienia się według funkcji cosinus o odpowiednio malejącej amplitudzie z przesunięciem fazy.

W celu zamodelowania zjawiska dyfuzji ciepła w badanej próbce, stworzono trójwymiarowy model matematyczny oparty na równaniu ogólnym Fouriera-Kirchhoffa:

$$\rho c_p \frac{\partial T}{\partial t} - \nabla \cdot (\lambda \nabla T) = Q \quad (4)$$

gdzie: ρ – gęstość, c_p – ciepło właściwe, λ – współczynnik przewodzenia ciepła, Q – wydajność objętościowa źródła ciepła, T – temperatura, t – czas, ∇ – operator Hamiltona.

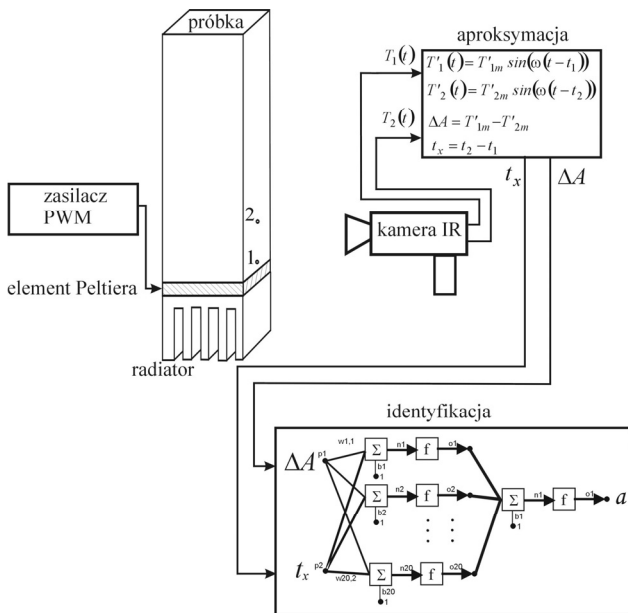


Rys. 1. Próbkę badaną z zaznaczonymi punktami pomiaru zmian temperatury na jej powierzchni
 Fig. 1. Specimen of the tested material – the proposed method

Próbkę materiału (rys. 1) o wymiarach (xyz) 0,04 x 0,04 x 0,12 m, została zamodelowana w prostokątnym, trójwymiarowym układzie współrzędnych, jako wycinek symetrycznej ćwiartki. Następnie model został zdyskretyzowany na elementy skończone. Dla powierzchni podstawy prostopadłościennej próbki przyjęto wymuszenie temperaturowe o charakterze harmonicznym opisane (2). Dla pozostałych powierzchni przyjęto warunki brzegowe trzeciego rodzaju tzw. warunki Fouriera $\alpha \in (5 \div 30) \text{ W}/(\text{m}^2 \cdot \text{K})$. Dla modelowanej próbki materiału przyjęto wartości parametrów cieplnych typowe dla styropianu: $\lambda = 0,04 \text{ W}/(\text{m} \cdot \text{K})$, $a = 2,4 \cdot 10^{-6} \text{ m}^2/\text{s}$.

3. Koncepcja wykorzystania sztucznej sieci neuronowej

Wysunięto koncepcję wykorzystania sztucznej sieci neuronowej [7, 8, 9], która na podstawie wyznaczonego z eksperymentu czasu przemieszczania się amplitudy fali cieplnej na powierzchni bocznej badanej próbki t_x oraz zmiany amplitudy fali cieplnej ΔA dla przyjętego odcinka Δz (rys. 2), wyznaczyłaby wartość współczynnika dyfuzyjności cieplnej, współczynnikowe zagadnienie odwrotne dyfuzji [10]. Przyjmuje się ponadto, powtarzalną w pomiarach, wartość wymuszenia cieplnego o charakterze harmonicznym.



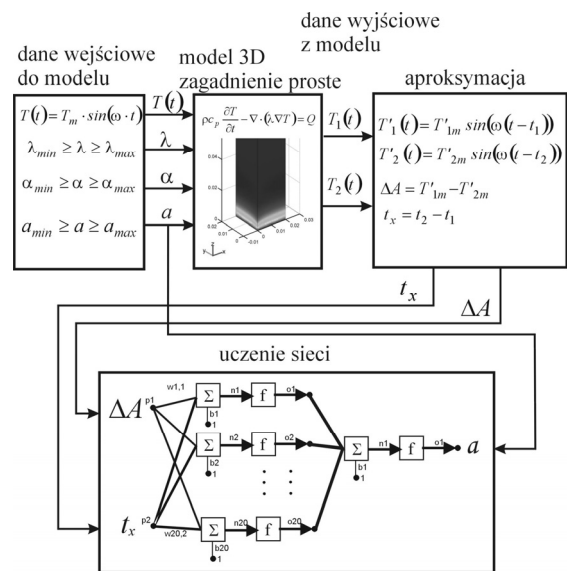
Rys. 2. Koncepcja autorskiej metody pomiarowej wykorzystującej sztuczną sieć neuronową
 Fig. 2. The principle of the method for measuring the coefficient of thermal diffusivity using an artificial neural network

W celu określenia przydatności sieci neuronowej dla zamodelowania opisywanego przypadku, stworzono model matematyczny zachodzącego zjawiska [11], wygenerowano wektory uczące dla sieci neuronowej oraz porównano odpowiedzi nauczonej sieci neuronowej z wartościami zadanymi dla testowanych przebiegów.

Dla zagadnienia prostego przyjętego modelu dyfuzji ciepła w badanej próbce, wyznaczone wartości wyjściowe: czas t_x i zmiana amplitudy fali cieplnej ΔA dla przyjętego odcinka Δz , zależą od kombinacji wartości następujących współczynników: przewodzenia ciepła na powierzchni próbki α , przewodzenia ciepła próbki λ , oraz dyfuzyjności cieplnej próbki a .

Liczba wektorów uczących rośnie geometrycznie w stosunku do liczby przyjętych wartości danych wejściowych. Każdy współczynnik będzie przyjmował 10 wartości z założonego przedziału: $a \in (1,0 \div 6,0) \cdot 10^{-6} \text{ m}^2/\text{s}$, $\lambda \in (2,0 \div 8,0) \cdot 10^{-2} \text{ W}/(\text{m} \cdot \text{K})$ i $\alpha \in (5,0 \div 15) \text{ W}/(\text{m}^2 \cdot \text{K})$. Kombinacja tych wartości daje 1000 wektorów uczących.

Na rys. 3 przedstawiono sposób, w jaki dane wejściowe ΔA i t_x , prezentowane są na wejściu przykładowej sieci neuronowej. Nauczona sieć neuronowa będzie identyfikować wartość dyfuzyjności cieplnej a materiału.

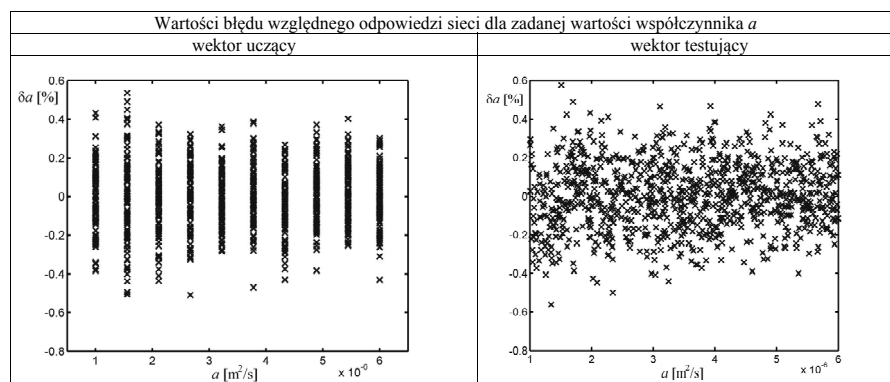


Rys. 3. Sposób, w jaki dane wejściowe, prezentowane są na wejściu przykładowej sieci neuronowej – proces uczenia i testowania sieci
 Fig. 3. Training process of the neural network with input and output quantities

W celu sprawdzenia, czy sieć poprawnie odpowiada dla innych wartości parametrów modelu cieplnego zjawiska: α , λ i a , niż te zawarte w wektorach uczących, wygenerowano wektory testujące. Każdy współczynnik będzie przyjmował 10 wylosowanych wartości z założonego przedziału: $a \in (1,0 \div 6,0) \cdot 10^{-6} \text{ m}^2/\text{s}$, $\lambda \in (2,0 \div 8,0) \cdot 10^{-2} \text{ W}/(\text{m} \cdot \text{K})$ i $\alpha \in (5,0 \div 15) \text{ W}/(\text{m}^2 \cdot \text{K})$. Kombinacja tych wartości daje 1000 ciągów testujących. W tabeli 1 przedstawiono wartości błędu względnego, z jakim odpowiadała sieć dla zadanej w wektorach uczącym oraz testującym wartości współczynnika a . Wartość błędów odpowiedzi sieci nie przekroczyła 0,6%.

W dalszych badaniach modelowych badano wpływ błędów pomiarowych mierzonych wielkości wejściowych na wartość zidentyfikowanego parametru cieplnego. W symulacjach wykorzystano zasadę propagacji rozkładów prawdopodobieństwa, jako podstawy obliczania niepewności, realizowanej poprzez matematyczny model pomiaru przy zastosowaniu metody Monte Carlo. Zasada ta została sformułowana w dokumencie [12], który przedstawia zalecenia dotyczące obliczania niepewności w sytuacji, gdy niespełnione są warunki dla zastosowania „prawa propagacji niepewności”, szczególnie ze względu na złożoność modelu pomiaru. Otrzymane wyniki symulacji wykazały, że przy założonych niepewnościach pomiarów wielkości wejściowych, niepewność względna wyznaczonej dyfuzyjności cieplnej a na poziomie ufności 0,95 nie przekroczyła 4%.

Tab. 1. Wartości błędu względnego, z jakim odpowiadała sieć dla zadanej w wektorze uczącym oraz testującym wartości współczynnika a
 Tab. 1. The relative error of the coefficient a in the learning and testing vectors



4. Wnioski

Otrzymane wyniki symulacji potwierdzają przydatność metody termofalowej dla pomiarów termowizyjnych do wyznaczenia współczynnika dyfuzyjności cieplnej materiałów termoizolacyjnych. Koniecznym jest jednak uwzględnienie w modelu matematycznym zjawiska, rzeczywistych warunków brzegowych panujących na powierzchniach bocznych próbki.

W rozpatrywanej metodzie istnieje możliwość wykorzystania algorytmu strojonego modelu opartego na minimalizacji błędu średniokwadratowego do rozwiązania współzależnego zagadnienia odwrotnego. Algorytm ten wymaga jednak stosunkowo dużej liczby operacji matematycznych. Wpływa to na zwiększenie czasu pomiaru związanego z obliczeniami numerycznymi oraz podnosi koszt budowy systemu pomiarowego. Alternatywą jest zaproponowana koncepcja wykorzystania sztucznej sieci neuronowej. Nauczona sieć neuronowa na podstawie zmierzonych metodą termowizyjną odpowiedzi temperaturowych na powierzchni bocznej badanej próbki, szybko określiłaby identyfikowany parametr termofizyczny. Otrzymane wyniki badań potwierdzają przydatność wykorzystania metod sztucznej inteligencji w rozwiązaniu współzależnego zagadnienia odwrotnego z wykorzystaniem termowizyjnej metody pomiaru.

Wykorzystanie metod stykowych do pomiaru temperatury powierzchni próbki materiału termoizolacyjnego dyskwalifikuje je ze względu na wystąpienie znaczącego błędu pomiaru. Błąd ten wynika z zaburzenia pola temperatury, jakie powoduje umieszczenie na powierzchni badanej próbki czujnik temperatury.

W dalszym etapie badań przewiduje się przeprowadzenie eksperymentu z wykorzystaniem kamery termowizyjnej w celu weryfikacji otrzymanych wyników badań symulacyjnych. Niniejszy artykuł stanowi wycinek większego problemu pomiaru parametrów cieplnych materiałów termoizolacyjnych.

5. Literatura

- [1] Praca zbiorowa: Pomiary cieplne. WNT, Warszawa 1995.
- [2] Minkina W., Chudzik S.: Pomiary parametrów cieplnych materiałów termoizolacyjnych – przyrządy i metody. Wydawnictwo Politechniki Częstochowskiej, Częstochowa 2004.
- [3] Chudzik S.: The idea of using artificial neural network in measurement system with hot probe for testing parameters of heat-insulating materials, *Measurement* 42, 2009, 764–770.
- [4] Chudzik S.: The idea of the measurement system for quick test of thermal parameters of heat-insulating materials, *Advances in measurement Systems*, edited by Milind Kr. Sharma, In-Tech, Vukovar 2010, 445-465.
- [5] Chudzik S., Minkina W.: An idea of a measurement system for determining thermal parameters of a heat insulation materials, *Metrology and Measurement Systems* 18, 2011, 261-273.
- [6] Chudzik S.: Mesuring system with a dual needle probe for testing the parameters of heat-insulating materials, *Measurement Science and Technology* 22, 2011, 075703.
- [7] Daponde P., Grimaldi D.: Artificial neural networks in measurements. *Measurement* 23, 1998, 93-115.
- [8] Osowski S.: Sieci neuronowe w ujęciu algorytmicznym. WNT Warszawa 1996.
- [9] Turias I., Gutierrez J., Galindo P.: Modelling the effective thermal conductivity of a unidirectional composite by the use of artificial neural networks. *Composites Science and Technology* 65, 2005, 609–619.
- [10] Praca zbiorowa, red. Szargut J.: Modelowanie numeryczne pól temperatury. WNT, Warszawa 1992.
- [11] Gajda J., Szyper M.: Modelowanie i badania symulacyjne systemów pomiarowych. Nakładem Akademii Górniczo-Hutniczej, Kraków 1998.
- [12] JCGM (Joint Committee for Guides in Metrology): Guide to the Expression of Uncertainty in Measurement?. Supplement 1. Numerical Methods for the Propagation of Distributions, 2004.

otrzymano / received: 15.10.2012

przyjęto do druku / accepted: 03.12.2012

artykuł recenzowany / revised paper

INFORMACJE

Bezpłatny dostęp do artykułów opublikowanych w PAK

Realizując idee Open Access przez miesięcznik PAK informujemy, że artykuły opublikowane w PAK są dostępne w wersji elektronicznej. Dostęp do artykułów opublikowanych jest bezpłatny, z zachowaniem 1 roku karencji. Artykuły w łatwy sposób można znaleźć korzystając z wyszukiwarki artykułów. Bazę artykułów można przeszukać po nazwisku autora, tytule artykułu lub po słowach kluczowych.

Tadeusz SKUBIS
 Redaktor naczelny Wydawnictwa PAK