

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

Koncepcja wykorzystania metody termofalowej oraz pomiarów termowizyjnych do wyznaczania parametrów cieplnych materiałów termoizolacyjnych

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

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 artykule przedstawiono wyniki badań nad opracowywaną metodą wyznaczania parametrów cieplnych materiałów termoizolacyjnych. W metodzie tej wykorzystano wymuszenie temperatury o charakterze harmonicznym. Do pomiaru rozkładu temperatury w eksperymencie użyto kamery termowizyjnej. W badaniach symulacyjnych wykorzystano stworzony trójwymiarowy model zjawiska dyfuzji ciepła w badanej próbce materiału. Do rozwiązania współzmiennikowego zagadnienia odwrotnego zaproponowano koncepcję wykorzystania sztucznej sieci neuronowej.

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

The concept of using periodic heating technique for determination of thermal parameters of heat insulation materials

Abstract

The paper presents results of research on the developed method for determining thermal parameters of a thermal insulating material [2]. This method applies periodic heating as an excitation and an infrared camera is used to measure the temperature distribution on the surface of the tested material – Sections 2 and 3. The author proposed the use of a three-dimensional model of the heat diffusion in a material sample. For solving the system of partial differential equations, the finite element method was applied [11] – Section 2. To solve the coefficient inverse problem, an approach using an artificial neural network is proposed – Section 3. The usability of the artificial neural network in solving the inverse heat transfer problem in a sample of heat insulation material is presented [12, 13]. The network determines the value of effective thermal conductivity and effective thermal diffusivity on the basis of the temperature distribution on the surface of the tested material. Additionally, the influence of the input quantity errors on the estimated values of the thermal parameters was also analysed using the Monte Carlo technique [15] – Section 4. A trained neural network based on the temperature responses on the lateral surface of the sample measured by infrared thermography, quickly would determine the thermo-physical parameters. The obtained results confirm the usefulness of applying artificial intelligence methods to solving the coefficient inverse problem when using infrared measurement methods.

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

1. Wstęp

Na rynku materiałów budowlanych obserwuje się znaczny popyt na różnego rodzaju materiały termoizolacyjne. Najczęściej są to: płyty styropianowe, włókniny syntetyczne, maty wykonane z wełny mineralnej, pianki poliuretanowej, włókna szklanego. Do określenia jakości tych materiałów, najczęściej wykorzystywana jest metoda stykowa oparta na ustalonych warunkach wymiany

ciepła, wykorzystująca aparaty płytowe [1, 2]. Metoda ta pozwala wyznaczyć jedynie współczynnik przewodzenia ciepła badanego materiału i wymaga użycia, w warunkach laboratoryjnych, dużych i ciężkich systemów pomiarowych oraz długiego odcinka czasu na dokonanie pomiaru. Dlatego też, podejmowane są prace nad stworzeniem systemów pomiarowych, nieposiadających takich ograniczeń.

Autorzy niniejszego artykułu pracują nad rozwinięciem metod dynamicznych wyznaczania parametrów cieplnych materiałów termoizolacyjnych. Prowadzone badania obejmują między innymi możliwości wykorzystania sztucznych sieci neuronowych do rozwiązania współzmiennikowego zagadnienia odwrotnego dla procesów dyfuzji ciepła w wybranych modelach stanowisk pomiarowych, które wykorzystywałyby teorię stanu nieustalonego przepływu ciepła [2 ÷ 7].

W artykule przedstawiono zagadnienie dotyczące określenia podstawowych parametrów termofizycznych materiału termoizolacyjnego: współczynnika dyfuzyjności cieplnej a , m^2/s , współczynnika przewodzenia ciepła λ , $W/(m \cdot K)$ oraz ciepła właściwego c_p , $J/(kg \cdot K)$. Parametry te związane są następującą zależnością:

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

Zatem wystarczającym jest wyznaczenie dwóch z nich.

2. Metoda termofalowa i model zjawiska dyfuzji ciepła


Metoda termofalowa [8 ÷ 10] bazuje na zjawisku dyfuzji ciepła w badanej próbce, będącej odpowiedzią na zadane wymuszenie temperaturowe o charakterze harmonicznym.

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

$$\rho c_p \frac{\partial T}{\partial t} - \nabla \cdot (\lambda \nabla T) = Q, \quad (2)$$

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


Próbka materiału (rys. 1) o wymiarach (x, y, z) $0,04 \times 0,04 \times 0,12$ m, została zamodelowana w prostokątnym, trójwymiarowym układzie współrzędnych, jako wycinek symetrycznej ćwiartki.



Rys. 1. Próbkę badaną z zaznaczonymi punktami pomiaru zmian temperatury na jej powierzchni

Fig. 1. The specimen of the tested material – the proposed method

Następnie model został zdyskretyzowany na elementy skończone [11]. Dla powierzchni podstawy prostopadłościennej próbki przyjęto wymuszenie temperaturowe o charakterze harmonicznym – rys. 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: $\lambda = 0,04 \text{ W}/(\text{m} \cdot \text{K})$, $a = 2,4 \cdot 10^{-6} \text{ m}^2/\text{s}$.



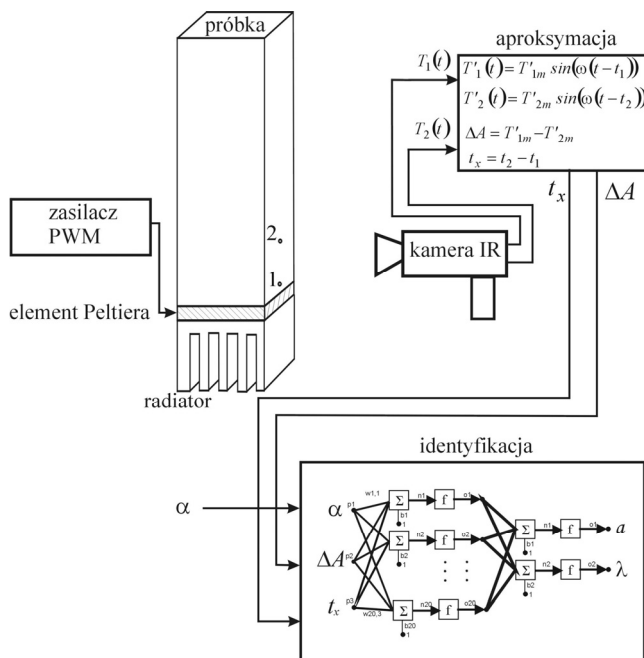
Rys. 2. Przykładowe przebiegi czasowe przyrostu temperatur 1- $T_1(t)$, 2- $T_2(t)$, 3- $T_3(t)$ oraz zaznaczony czas opóźnienia fali cieplnej - t_x i spadek amplitudy - ΔA dla przyjętych współrzędnych punktów pomiaru oddalonych od siebie o $\Delta z = 5 \text{ mm}$

Fig. 2. Example waveforms of the temperature increase at time 1- $T_1(t)$, 2- $T_2(t)$, 3- $T_3(t)$ for the measurement points distant from each other by $\Delta z = 5 \text{ mm}$

3. Rozwiązanie współczynnikowego zagadnienia odwrotnego

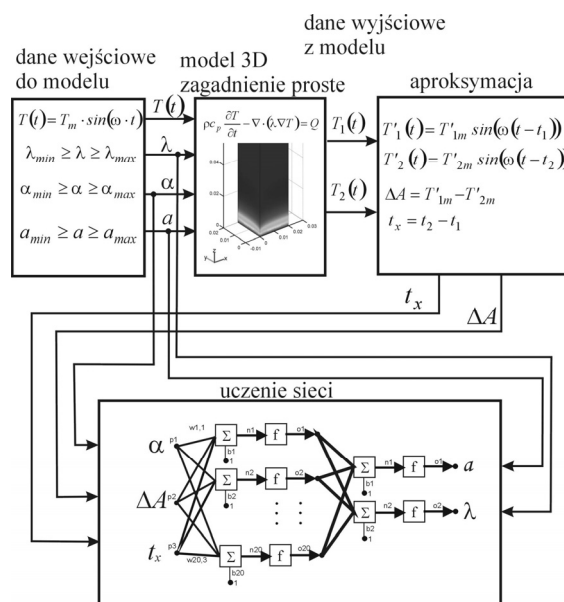
Wysunięto koncepcję wykorzystania sztucznej sieci neuronowej [12, 13], która na podstawie wyznaczonego z eksperymentu czasu przemieszczania się amplitudy fali cieplnej na powierzchni bocznej badanej próbki t_x oraz zmiany amplitudy fali cieplnej ΔA dla przyjętego odcinka Δz (rys. 1 i 3), wyznaczyłaby wartość współczynnika dyfuzyjności cieplnej a oraz współczynnika przewodzenia ciepła λ – współczynniki zagadnienia odwrotnego dyfuzji ciepła [11]. Przyjmuje się ponadto, powtarzalną w pomiarach, wartość wymuszenia cieplnego o charakterze harmonicznym. W przedstawianej koncepcji metody pomiarowej konieczna jest znajomość wartości współczynnika przejmowania ciepła α na powierzchni badanej próbki.

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



Rys. 3. Koncepcja autorskiej metody pomiarowej wykorzystującej sztuczną sieć neuronową oraz kamerę termowizyjną

Fig. 3. Principle of the experiment to measure the coefficient of thermal diffusivity - using an artificial neural network and a thermovision camera



Rys. 4. Sposób, w jaki dane wejściowe, prezentowane są na wejściu przykładowej sieci neuronowej – proces uczenia i testowania sieci

Fig. 4. The training process of the neural network with input and output quantities

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: przejmowania ciepła na powierzchni próbki α , przewodzenia ciepła próbki λ , oraz dyfuzyjności cieplnej próbki a .

Liczba wektorów uczących rośnie geometrycznie w stosunku do ilości 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.

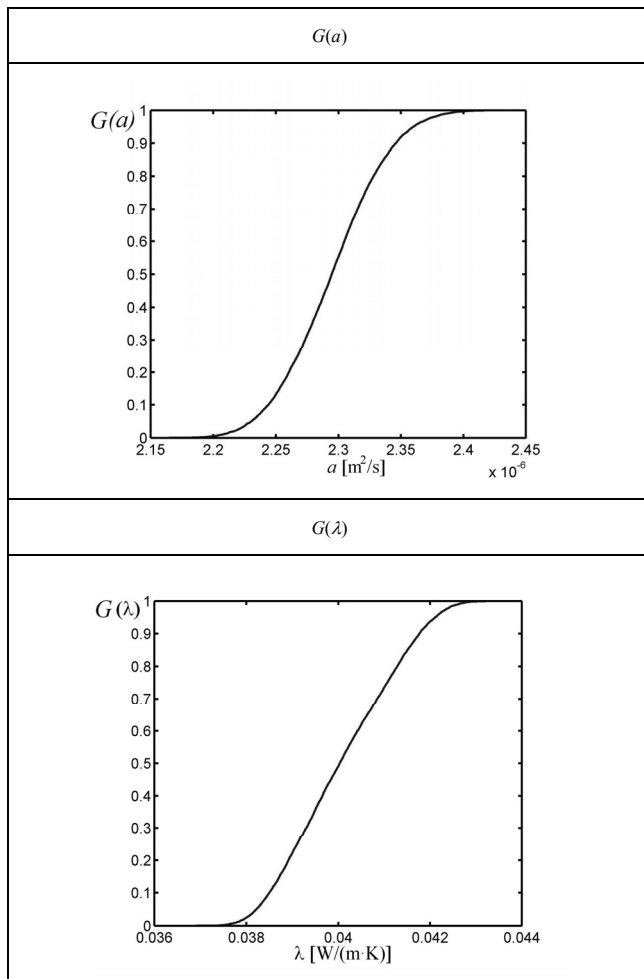
Na rys. 4 przedstawiono sposób, w jaki dane wejściowe ΔA , t_x i a prezentowane są na wejściu przykładowej sieci neuronowej.

Nauczona sieć neuronowa identyfikuje wartość dyfuzyjności cieplnej a oraz wartość współczynnika przewodzenia ciepła λ materiału.

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 współczynników a oraz λ . Można zauważyć, że błąd względny odpowiedzi sieci dla zadanej wartości współczynników a i λ w wektorach uczących i testujących nie przekracza odpowiednio 0,6% i 2%. Są to wartości wystarczające dla założeń przyjętych w projekcie.

Tab. 1. Wyznaczone dystrybuanty $G(a)$ i $G(\lambda)$ dla wielkości wyjściowych sieci neuronowej

Tab. 1. The relative error of coefficient a in the learning and testing vectors



Bardzo ważnym czynnikiem określającym przydatność nauczonej sieci neuronowej jest wpływ błędów pomiarowych wielkości mierzonych na wyniki identyfikacji parametrów cieplnych przez wspomnianą sztuczną sieć neuronową. Nie zawsze dobra zdolność sieci do uogólniania idealnego modelu, idzie w parze z jej małą wrażliwością na występujące w praktyce błędy pomiarowe w wektorze danych wejściowych.

4. Wpływ błędów pomiarowych mierzonych wielkości wejściowych na wartość identyfikowanych parametrów cieplnych

W dalszych badaniach modelowych zbadano wpływ błędów pomiarowych mierzonych wielkości wejściowych na wartość identyfikowanego parametru cieplnego. Założono, że opisywane urządzenie pomiarowe będzie wykorzystywane w pomiarach przemysłowych. Dlatego wystarczającym warunkiem jest przyjęcie niepewności identyfikowanych parametrów cieplnych rzędu kilku %.

W modelu przyjęto, że wpływ na wynik identyfikacji parametrów mają:

1. błąd pomiaru przyrostu temperatury związany z pomiarem wykonywanym kamerą termowizyjną $\Delta T(t)$ [14],
2. błąd pomiaru długości przyjętego odcinka $\Delta(z)$
3. błąd określenia współczynnika przejmowania ciepła na powierzchni próbki $\Delta\alpha$.

Przyjęto, że wyżej wymienione wielkości wejściowe opisane są przez symetryczne, prostokątne rozkłady prawdopodobieństwa o następujących szerokościach połowkowych: $\Delta T(t) = 1,0 \text{ K}$; $\Delta(z) = 0,1 \text{ mm}$; $\Delta\alpha = 0,5 \text{ W}/(\text{m}^2\cdot\text{K})$.

W symulacjach wykorzystano zasadę propagacji rozkładów prawdopodobieństwa, jako podstawę obliczania niepewności, realizowanej poprzez matematyczny model pomiaru przy zastosowaniu metody Monte Carlo. Zasada ta została sformułowana w dokumencie [15], który przedstawia zalecenia dotyczące obliczania niepewności w sytuacji, gdy niespełnione są warunki dla zastosowania „prawa propagacji niepewności”, szczególnie ze względu na złożoność modelu pomiaru.

Symulacje przeprowadzono dla założonych wartości parametrów próbki: $a = 2,3 \cdot 10^{-6} \text{ m}^2/\text{s}$, $\alpha = 10 \text{ W}/(\text{m}^2\cdot\text{K})$, $\lambda = 4,0 \cdot 10^{-2} \text{ W}/(\text{m}\cdot\text{K})$. Wyznaczono dystrybuanty $G(a)$ i $G(\lambda)$ dla wielkości wyjściowych sieci neuronowej, wyznaczonych z modelu matematycznego na podstawie przyjętych wyżej rozkładów wielkości wejściowych – tabela 1.

W tabeli 2 przedstawiono wyznaczone z rozkładu wielkości wyjściowej a i λ następujące parametry: wartość oczekiwaną, odchylenie standardowe oraz przedział ufności dla poziomu prawdopodobieństwa 0,95.

Tab. 2. Wyznaczone parametry rozkładu prawdopodobieństwa dla identyfikowanych parametrów

Tab. 2. The relative error of coefficient a in the learning and testing vectors

Parametr	Wartość średnia	Odchylenie standardowe	Przedział ufności dla $p=0,95$
$a, \text{ m}^2/\text{s}$	$2,30 \cdot 10^{-6}$	$3,93 \cdot 10^{-8}$	$[2,22 \cdot 10^{-6}; 2,37 \cdot 10^{-6}]$
$\lambda, \text{ W}/(\text{m}\cdot\text{K})$	$4,01 \cdot 10^{-2}$	$1,20 \cdot 10^{-3}$	$[3,80 \cdot 10^{-2}; 4,23 \cdot 10^{-2}]$

Otrzymane wyniki wskazują, że przy założonych wyżej niepewnościach pomiarów wielkości wejściowych, niepewność względna wyznaczonej dyfuzyjności cieplnej a i współczynnika przewodzenia ciepła λ na poziomie ufności 0,95 nie przekroczy odpowiednio 4 % i 6%.

W przypadku, gdy w proponowanej metodzie należy dodatkowo wyznaczyć wartość współczynnika przewodzenia ciepła λ , konieczna jest znajomość wartości współczynnika przejmowania ciepła α na powierzchni próbki w czasie dokonywania pomiaru.

Wartość współczynnika przejmowania ciepła α na powierzchni próbki można oszacować korzystając z teorii podobieństwa do zagadnień przejmowania ciepła. Teoria podobieństwa oparta jest na analizie równań różniczkowych opisujących badane zjawisko. Pozwala ona, bez rozwiązywania równań różniczkowych, na określenie warunków podobieństwa rozpatrywanych zjawisk w modelu fizycznym.

W badaniach, wstępnie przyjęto wartość współczynnika przejmowania ciepła α na powierzchni próbki, opierając się na teorii podobieństwa oraz korzystając z danych literaturowych dla wybranych podstawowych przypadków (kształtów) modeli wymiany ciepła [16]. Przy niedokładnej ocenie właściwości powietrza i warunków jego przepływu przy powierzchni próbki, szacowana wartość współczynnika przejmowania ciepła może znacznie odbiegać od rzeczywistości. W przedstawianej metodzie pomiarowej proponuje się dwa sposoby określenia współczynnika przejmowania ciepła α na powierzchni badanej próbki:

1. Budowa i wykorzystanie specjalnego α -kalorymetru o kształcie i wymiarach identycznych jak próbka badana,
2. Wykorzystanie próbki wzorcowej materiału o znanych parametrach cieplnych.

Szczegółowy opis proponowanych sposobów zostanie przedstawiony w przyszłych publikacjach.

5. Wnioski

Otrzymane wyniki symulacji potwierdzają przydatność metody termofalowej oraz pomiarów termowizyjnych do wyznaczania parametrów cieplnych materiałów termoizolacyjnych. Koniecznym jest jednak uwzględnienie w modelu matematycznym zjawiska, rzeczywistych warunków brzegowych panujących na powierzchniach bocznych próbki - przepływ poprzeczny ciepła w próbce. Częstotliwość wymuszenia temperaturowego – rys. 2, powinna być oszacowana na podstawie wyznaczonej efektywnej głębokości wnikania fal temperaturowych [8, 9], która zależy od parametrów cieplnych badanego materiału. Ponadto dobór odległości Δz (w symulacjach przyjęto $\Delta z = 5$ mm) wynika z parametrów użytej kamery i jest on kompromisem między rozdzielczością geometryczną a rozdzielczością temperaturową kamery [14]. W proponowanej metodzie można zmianę amplitudy fali cieplnej ΔA zastąpić stosunkiem amplitud, jeśli zakłada się, że amplituda zmian wymuszenia cieplnego nie będzie w pomiarach powtarzalna.

W rozpatrywanej metodzie istnieje możliwość wykorzystania algorytmu strojonego modelu opartego na minimalizacji błędu średniokwadratowego do rozwiązania współczynnikowego zagadnienia odwrotnego. Algorytm ten wymaga jednak stosunkowo dużej ilości 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.

Dobór struktury sztucznej sieci neuronowej powinien być realizowany nie tylko na podstawie otrzymanych wyników symulacji dla wektorów uczących i testujących, ale także na podstawie analizy wyników badań dotyczących wpływu błędów pomiarowych wielkości wejściowych na wyniki identyfikacji parametrów cieplnych przez nauczoną strukturę sztucznej sieci neuronowej. Nie zawsze dobra zdolność sieci do uogólniania idealnego modelu, idzie w parze z jej małą wrażliwością na występujące w praktyce błędy pomiarowe w wektorze danych wejściowych. Wykorzysta-

nie metod sztucznej inteligencji do rozwiązania współczynnikowego zagadnienia odwrotnego ograniczone jest do przyjętych w procesie uczenia przedziałów zmienności identyfikowanych parametrów cieplnych.

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 umieszczony 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. Niżej artykuł stanowi wycinek większego problemu dotyczącego pomiaru parametrów cieplnych materiałów termoizolacyjnych.

6. 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, ISBN 83-7193-216-2.
- [3] Chudzik S.: Measurement of thermal parameters of a heat insulating material using infrared thermography. *Infrared Physics and Technology*, 55, 2012, 73-83.
- [4] Chudzik S.: Measurement of thermal diffusivity of insulating material using the artificial neural network. *Measurement Science and Technology*, 23, 2012, 065602.
- [5] 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.
- [6] 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.
- [7] Chudzik S.: Measuring system with a dual needle probe for testing the parameters of heat-insulating materials. *Measurement Science and Technology*, 22, 2011, 075703.
- [8] Marinetti S., Bison P.G., Grinzato E., Musico A.: Thermal diffusivity measurement of stainless steel by periodic heating technique. *AITA Adv. Infrared Technol. Appl. Venezia* 1999, 316–321.
- [9] Maldague X.: *Theory and Practice of Infrared Technology for Nondestructive Testing*. John Wiley & Sons, Inc., New York, 2001.
- [10] Gralewicz G., Owczarek G., Więcek B.: Investigations of single and multilayer structures using lock-In thermography – possible applications. *JOSE Int. J. Occupat. Saf. Ergon.* 11, 2005, 211–215.
- [11] Praca zbiorowa, Szargut J. (red.): *Modelowanie numeryczne pól temperatury*. WNT, Warszawa 1992.
- [12] Daponde P., Grimaldi D.: Artificial neural networks in measurements. *Measurement* 23, 1998, 93-115.
- [13] Osowski S.: *Sieci neuronowe w ujęciu algorytmicznym*. WNT Warszawa 1996.
- [14] Minkina W., Dudzik S.: *Infrared Thermography – Errors and Uncertainties*. John Wiley & Sons Ltd., Chichester, 2009.
- [15] *Guide to the Expression of Uncertainty in Measurement. Supplement 1. Numerical Methods for the Propagation of Distributions – projekt dokumentu Międzynarodowego Biura Miar z 16.03.2004.*
- [16] Taler J., Duda P.: *Solving Direct and Inverse Heat Conduction Problems*. Springer, Berlin 2006.