

Stanisław CHUDZIK, Sławomir GRYŚ, Waldemar MINKINA
POLITECHNIKA CZĘSTOCHOWSKA, WYDZIAŁ ELEKTRYCZNY

Wykorzystanie sztucznych sieci neuronowych w zagadnieniu odwrotnym dyfuzji ciepła

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 ciepłych, projektowania systemów pomiarowych oraz wyznaczania parametrów ciepłych materiałów.

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



Dr inż. Sławomir GRYŚ

Absolwent Wydziału Elektrycznego Politechniki Częstochowskiej. Stopień naukowy doktora nauk technicznych uzyskał w 2003 r. Jest autorem podręcznika, współautorem patentu, monografii i kilkudziesięciu artykułów publikowanych w czasopiśmie krajowych, zagranicznych oraz materiałach konferencyjnych. Jego zainteresowania naukowe obejmują zagadnienia metrologiczne, elektronikę i nauki informatyczne.

e-mail: grysz@el.pcz.czyst.pl



Prof. dr hab. inż. Waldemar MINKINA

Ukończył w roku 1977 Wydział Elektryczny Politechniki Częstochowskiej, doktorat w 1983 r. w Instytucie Metrologii Elektrycznej Politechniki Wrocławskiej, habilitacja w 1995 r. na Wydziale Automatyki Politechniki Lwowskiej. W roku 2006 uzyskał tytuł profesora nauk technicznych. Jest autorem i współautorem 5 monografii z metrologii oraz ponad 100 publikacji. Specjalizuje się w problematyce dotyczącej szeroko rozumianej termometrii, termografii komputerowej, pomiarów ciepłych oraz nauk informatycznych.

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



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 szklane. Do określenia jakości wspomnianych 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 ciepłych 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 [3, 4].

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

2. Koncepcja systemu pomiarowego wykorzystującego sondę cieplną

Przedstawiana koncepcja systemu pomiarowego oparta jest na wykorzystaniu sondy cieplnej, którą można wbić w miękki materiał termoizolacyjny poddawany badaniu. Sondy cieplne działające na zasadzie liniowego źródła ciepła wykorzystywane są zazwyczaj do pomiaru przewodności ciał sypkich i lepkich cieczy [5, 6, 7]. W przypadku materiałów termoizolacyjnych takich jak wełna mineralna czy styropian, ich struktura (ponad 90% objętości porowatej struktury wypełnia gaz) pozwala na wbicie w materiał, bez jego zniszczenia, cienkiej sondy w kształcie igły. Znane koncepcje wykorzystania sondy cieplnej do wyznaczania współczynnika przewodności cieplnej [2, 5, 6, 7, 8] korzystają z wyprowadzonych z równania Fouriera uproszczonych zależności, które jednak nie zapewniają dokładnych wyników.

Streszczenie

W artykule przedstawiono koncepcję wykorzystania sztucznych sieci neuronowych do rozwiązania współczynnikowego zagadnienia odwrotnego dyfuzji ciepła. Opisywane rozwiązanie jest częścią projektu, którego celem jest opracowanie systemu pomiarowego wykorzystującego sondę cieplną do doraźnej kontroli parametrów ciepłych materiałów termoizolacyjnych. Przedstawiono wybrane wyniki badań symulacyjnych pozwalających porównać różne architektury sieci neuronowych. Symulacje obejmują proces uczenia i testowania sieci. Zbadano także wpływ błędów pomiarowych wielkości wejściowych na identyfikowane przez sieć neuronową parametry cieplne materiału. Przedstawiane symulacje przeprowadzono w środowisku Matlab.

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

Use of artificial neural networks for solving the heat diffusion inverse problem

Abstract


The paper presents an idea of a measurement system with a hot probe for testing thermal parameters of heat insulation materials. In contrast to classical methods of linear heat source [1, 2, 5, 6, 7, 8], there are not assumed any significant simplifications in the model of heat flow in the material sample. The model of non-stationary heat flow in the material sample with a hot probe and auxiliary thermometer is based on a two-dimensional heat-conduction model and includes the heat capacity of the probe handle [3, 4, 9, 10]. The finite element method was used for solving the system of partial differential equations describing the model [11, 12] – Sections 2 and 3. The usability of the artificial neural network [14] for solving the inverse heat transfer problem in a sample of heat insulation material is presented [13, 15]. The network determines the values of the effective thermal conductivity and diffusivity on the basis of the temperature responses of the hot probe and auxiliary thermometer. In order to select the optimal neural network architecture, there were compared many network configurations in Sections 4, 5 and 6. Additionally, the influence of input quantity errors on the estimated values of the thermal parameters was analysed using the Monte Carlo method [16, 17, 18] – Sections 7 and 8. The simulations of the heat flow process, network training and testing processes as well as the analysis of the error sensitivity were carried out in the Matlab environment.

W przypadku materiałów termoizolacyjnych, które posiadają stosunkowo mały współczynnik $\rho \cdot c_p$, $J/(K \cdot m^3)$, pojemność cieplna badanej próbki jest porównywalna z pojemnością cieplną sondy. Dlatego model matematyczny zjawiska nie powinien zakładać tak daleko posuniętych uproszczeń.

Koncepcja systemu pomiarowego zakłada możliwość określenia trzech podstawowych parametrów cieplnych (a , λ , $\rho \cdot c_p$) wymienionych we wstępie. Parametry te związane są następującą zależnością:

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

Wystarczy, więc wyznaczyć dwa z nich. W tym celu przyjęto, że system pomiarowy będzie rejestrował przebieg przyrostu temperatury sondy cieplnej T_G działającej na zasadzie liniowego źródła ciepła oraz dokonywany będzie pomiar przyrostu temperatury T_D w badanej próbce w odległości 8 mm od osi symetrii sondy cieplnej. W projekcie założono, że średnica sondy cieplnej wyniesie 2mm a średnica dodatkowego czujnika temperatury 1mm – rys. 1.



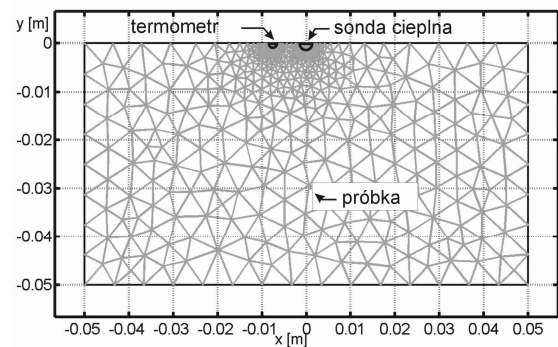
Rys. 1. Szkic projektu kompletnej sondy
Fig. 1. Predesign of a thermal probe

3. Model matematyczny oraz wyniki symulacji zjawiska dyfuzji ciepła w badanej próbce

W celu zamodelowania zjawiska dyfuzji ciepła w przykładowej próbce materiału, w którą wbito kompletną sondę pomiarową, stworzono jej dwuwymiarowy model matematyczny. Do tego celu wykorzystano przyborek *Partial Differential Equation Toolbox*, pracujący w środowisku MATLAB-a. W układzie współrzędnych XY zamodelowano przekrój poprzeczny połowy symetrycznej części próbki z umieszczoną w niej sondą pomiarową. W modelu, dla brzegów próbki materiału termoizolacyjnego w kształcie rozległej kwadratowej płyty, przyjęto uproszczony warunek brzegowy $\frac{\partial T}{\partial x} = 0$. Przy założonych parametrach materiału próbki, jej

wymiary poprzeczne zapewniają mały wpływ warunku brzegowego. W związku z tym, badaną próbkę, można traktować jako nieskończenie rozległą. Umieszczenie rzeczywistego termometru w strukturze badanego obiektu, wprowadza zawsze pewne zaburzenie rozkładu pola temperaturowego. Dlatego nie zawsze temperatura zmierzona tym termometrem określa rzeczywistą temperaturę panującą w obiekcie [4, 9]. Z tego względu, w omawianym modelu, ujęto zarówno model sondy cieplnej jak i dodatkowego termometru umieszczonego obok w odległości 8 mm. Przyjęto średnicę sondy cieplnej: $\varnothing = 2\text{mm}$, dodatkowego termometru: $\varnothing = 1\text{mm}$, oraz ich parametry cieplne: $a = 3,38 \cdot 10^{-6} \text{ m}^2/\text{s}$, $\lambda = 15 \text{ W}/(\text{m} \cdot \text{K})$.

Parametry cieplne sondy i termometru zaczerpnięto z [10]. Na rys. 2 przedstawiono siatkę dyskretyzacji zamodelowanej próbki. Do wyznaczenia rozkładu temperatury w czasie dla każdego elementu dyskretyzacji modelu próbki, wykorzystano metodę elementów skończonych [11, 12].



Rys. 2. Przekrój poprzeczny połowy symetrycznej części próbki z pograżoną w niej sondą pomiarową oraz siatką dyskretyzacji
Fig. 2. Half section of the sample with thermal probe and the discrete mesh

4. Koncepcja wykorzystania sieci neuronowej do rozwiązania zagadnienia odwrotnego


Algorytm wyznaczenia parametrów cieplnych materiału z wykorzystaniem rozwiązania zagadnienia prostego dyfuzji ciepła oraz optymalizacji błędu średniokwadratowego, został szczegółowo przedstawiony w poprzednich publikacjach [3, 4]. Jego zaletą jest możliwość uwzględnienia dowolnych, zmiennych warunków brzegowych występujących w czasie pomiaru. Kształt wymuszenia temperatury w czasie może być dowolny i jest uwzględniany w obliczeniach. Jednak algorytm ten wymaga stosunkowo dużej ilości operacji matematycznych, które z kolei wymuszają wykorzystanie jednostki o znacznej mocy obliczeniowej. Rozwiązanie takie wpływa na zwiększenie czasu pomiaru związanego z obliczeniami numerycznymi oraz znacznie podnosi koszt budowy ewentualnego systemu pomiarowego.

W związku z tym, w prowadzonych pracach została wysunięta koncepcja wykorzystania sztucznej sieci neuronowej [13, 14, 15], która na podstawie zmierzonych odpowiedzi temperaturowych sondy cieplnej i dodatkowego termometru oraz znajomości wartości gęstości strumienia ciepła oddanego przez sondę cieplną do próbki, określiłaby zidentyfikowane parametry termofizyczne.

5. Proces uczenia sieci neuronowej


Wykorzystując metodę elementów skończonych do rozwiązania zagadnienia prostego dyfuzji ciepła, wygenerowano ciągi uczące dla sieci neuronowej. W związku z faktem, że wyznaczenie współczynników a oraz λ zależy od kombinacji przebiegów wartości chwilowych przyrostu temperatury sondy cieplnej w jej osi symetrii $T_G(t)$ oraz przyrostu temperatury termometru dodatkowego $T_D(t)$, proces uczenia sieci jest nieco bardziej złożony. Wygenerowano ciągi uczące dziewięciu wybranych wartości chwilowych przebiegu przyrostu temperatury sondy cieplnej $T_G(t)$ oraz dziewięciu wybranych wartości chwilowych przebiegu przyrostu temperatury termometru dodatkowego $T_D(t)$ dla kombinacji wartości współczynników a i λ . Przyjęto, że każdy współczynnik będzie przyjmował 10 wartości z założonego przedziału: $a \in (1 \div 3) \cdot 10^{-6} \text{ m}^2/\text{s}$ i $\lambda \in (3 \div 5) \cdot 10^{-2} \text{ W}/(\text{m} \cdot \text{K})$. Kombinacja tych wartości daje 100 ciągów uczących.

Na rys. 3 przedstawiono sposób, w jaki dane wejściowe $T_G(t)$ oraz $T_D(t)$, prezentowane są na wejściu przykładowej sieci neuronowej, która na ich podstawie identyfikuje parametry cieplne materiału. Przykładowe ciągi uczące przebiegów wartości chwilowych przyrostu temperatury w osi symetrii sondy cieplnej $T_G(t)$ przedstawiono na rys. 4. Przykładowe ciągi uczące przebiegów wartości chwilowych przyrostu temperatury termometru dodatkowego $T_D(t)$ przedstawiono na rys. 5.




Rys. 3. Przykładowa sieć neuronowa z prezentacją danych wejściowych $T_G(t)$, $T_D(t)$ i wyjściowych a i λ .

Fig. 3. Hypothetical architecture of the neural network with input and output quantities



Rys. 4. Przykładowe ciągi uczące przebiegów wartości chwilowych przyrostu temperatury sondy cieplnej $T_G(t)$. 1) $a=1,0 \cdot 10^{-6} \text{ m}^2/\text{s}$, $\lambda=3,0 \cdot 10^{-2} \text{ W}/(\text{m}\cdot\text{K})$; 2) $a=3,0 \cdot 10^{-6} \text{ m}^2/\text{s}$, $\lambda=5,0 \cdot 10^{-2} \text{ W}/(\text{m}\cdot\text{K})$

Fig. 4. Exemplary training vectors of the heating probe temperature $T_G(t)$ instantaneous values



Rys. 5. Przykładowe ciągi uczące przebiegów wartości chwilowych przyrostu temperatury termometru dodatkowego $T_D(t)$. 1) $a=3,0 \cdot 10^{-6} \text{ m}^2/\text{s}$, $\lambda=5,0 \cdot 10^{-2} \text{ W}/(\text{m}\cdot\text{K})$; 2) $a=1,0 \cdot 10^{-6} \text{ m}^2/\text{s}$, $\lambda=3,0 \cdot 10^{-2} \text{ W}/(\text{m}\cdot\text{K})$

Fig. 5. Exemplary training vectors of the auxiliary thermometer temperature $T_D(t)$ instantaneous values

Badana sieć posiada 18 wejść, na które podaje się 9 wybranych wartości chwilowych z przebiegu czasowego temperatury $T_G(t)$, oraz 9 wybranych wartości chwilowych z przebiegu czasowego temperatury $T_D(t)$, będących odpowiedzią na zadane wymuszenie cieplne sondy.

W celu sprawdzenia, czy sieć poprawnie odpowiada dla średnich wartości parametrów a i λ z przedstawianych ciągów uczących, dla kombinacji wartości współczynników a i λ , wygenerowano ciągi testujące. Przyjęto, że każdy współczynnik będzie przyjmował 100 wartości z założonego przedziału: $a \in \langle 1,0 \div 3,0 \rangle \cdot 10^{-6} \text{ m}^2/\text{s}$ i $\lambda \in \langle 3,0 \div 5,0 \rangle \cdot 10^{-2} \text{ W}/(\text{m}\cdot\text{K})$. Kombinacja tych wartości daje 10 000 ciągów testujących.

Proces obliczenia przedstawiono w pracy modelu dyfuzji ciepła dla 10 000 kombinacji wartości parametrów cieplnych a i λ badanej próbki, metodą elementów skończonych, na nowoczesnym komputerze klasy PC, zajmuje około 3-4 doby.

6. Wyniki uczenia i testowania sieci

W ramach prac badawczych przeprowadzono szereg symulacji próbnych dla wielu architektur sztucznych sieci neuronowych. Celem ich było określenie możliwie optymalnej konfiguracji przyjętej sieci. W założeniach projektu przyjęto, że sieć neuronowa musi posiadać możliwie prostą strukturę, tak, aby można było ją łatwo zaimplementować w programie, prostego, ośmiobitowego mikrokontrolera. Sieć taka musi jednak z odpowiednią dokładnością aproksymować model zjawiska dyfuzji dla współczynnika odwrotnego zagadnienia odwrotnego. Ponadto sieć powinna w odpowiednim stopniu uogólniać model zjawiska dyfuzji, tak, aby wynik identyfikacji był możliwie mało wrażliwy na występujące błędy pomiarowe w danych wejściowych.

W dalszej części artykułu przedstawiono wyniki symulacji dla najbardziej reprezentatywnych architektur badanych sieci neuronowych poczynając od bardziej złożonych struktur a kończąc na możliwie prostych rozwiązaniach.

Numeracja poszczególnych architektur sieci w przedstawionej poniżej liście, obowiązuje w tabelarycznych zestawieniach wyników przedstawionych dalej.

Sieci neuronowe o radialnych funkcjach bazowych – RBF (ang. Radial Basis Functions) [14]:


- 1) Klasyczna sieć neuronowa RBF
- 2) Sieć neuronowa GRNN
- 3) Sieć neuronowa RBF o zadanym błędzie odpowiedzi.
- 4) Klasyczne nieliniowe sieci neuronowe [14]:
- 4) Sieć trójwarstwowa, 20 i 10 neuronów z funkcją aktywacji tangens hiperboliczny odpowiednio w pierwszej i drugiej warstwie, 25 epok uczenia
- 5) Sieć trójwarstwowa, 20 i 10 neuronów z funkcją aktywacji tangens hiperboliczny odpowiednio w pierwszej i drugiej warstwie, 1000 epok uczenia
- 6) Sieć dwuwarstwowa, 20 neuronów z funkcją aktywacji tangens hiperboliczny w pierwszej warstwie, 25 epok uczenia
- 7) Sieć dwuwarstwowa, 20 neuronów z funkcją aktywacji tangens hiperboliczny w pierwszej warstwie, 50 epok uczenia
- 8) Sieć dwuwarstwowa, 20 neuronów z funkcją aktywacji tangens hiperboliczny w pierwszej warstwie, 1000 epok uczenia
- 9) Sieć dwuwarstwowa, 10 neuronów z funkcją aktywacji tangens hiperboliczny w pierwszej warstwie, 25 epok uczenia
- 10) Sieć dwuwarstwowa, 10 neuronów z funkcją aktywacji tangens hiperboliczny w pierwszej warstwie, 50 epok uczenia.

Ze względu na ograniczoną objętość artykułu wyniki uczenia i testowania sieci neuronowych w formie wykresów przedstawiono przykładowo jedynie dla parametru a dla klasycznej sieci RBF-rysunki 6, 7, 8. Całość wyników zebrano w tabeli 1.


Tab. 1. Wyniki uczenia i testowania wybranych architektur sieci

Tab. 1. Results of learning and testing stages of selected network architectures

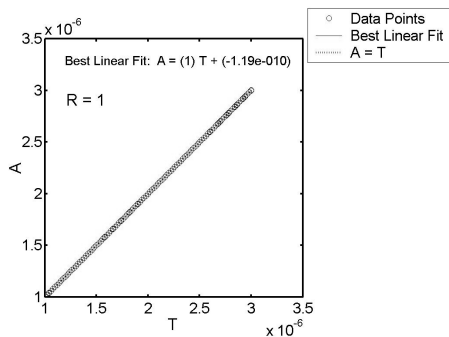
Architektura sieci	Uczenie sieci		Test sieci							
	$ \delta\alpha_{\text{min}} $ %	$ \delta\alpha_{\text{max}} $ %	$ \delta\lambda_{\text{min}} $ %	$ \delta\lambda_{\text{max}} $ %	Dyfuzyjność cieplna a		Przewodność cieplna λ			
					R	A=aT+b	R	A=aT+b		
1)	$2,8 \cdot 10^{-3}$	$1,7 \cdot 10^{-5}$	0,08	$2,4 \cdot 10^{-3}$	1	1	$-1,19 \cdot 10^{10}$	1	1	$-2,34 \cdot 10^8$
2)	2,5	0,23	26	6	0,989	0,956	$-1,19 \cdot 10^7$	0,997	0,979	$9,87 \cdot 10^{-4}$
3)	0,08	0,07	0,8	1,2	1	1	$5,43 \cdot 10^{10}$	1	0,998	$8,88 \cdot 10^{-5}$
4)	0,01	$5,0 \cdot 10^{-3}$	0,6	0,08	1	1	$4,83 \cdot 10^{10}$	1	1	$6,85 \cdot 10^{-6}$
5)	$3,8 \cdot 10^{-3}$	$1,5 \cdot 10^{-3}$	0,03	0,01	1	1	$-4,50 \cdot 10^{11}$	1	1	$5,97 \cdot 10^{-7}$
6)	0,01	$3,0 \cdot 10^{-3}$	0,5	0,09	1	1	$3,77 \cdot 10^{10}$	1	1	$1,29 \cdot 10^{-6}$
7)	0,5	0,18	1,5	0,4	1	1	$-2,16 \cdot 10^{13}$	1	1	$1,04 \cdot 10^{-5}$
8)	0,02	0,01	0,4	0,06	1	1	$-5,00 \cdot 10^{10}$	1	1	$3,39 \cdot 10^{-6}$
9)	0,2	0,1	1,1	1,1	1	1	$6,87 \cdot 10^{10}$	1	0,999	$2,20 \cdot 10^{-5}$
10)	0,4	0,09	1,7	0,45	1	1	$-1,09 \cdot 10^9$	1	1	$1,98 \cdot 10^{-5}$



Rys. 6. Wartości błędu względnego, z jakim odpowiadała sieć dla zadanej w ciągu uczącym wartości współczynnika dyfuzyjności cieplnej a
Fig. 6. Relative error of the network response δa for thermal diffusivity a at the training stage.



Rys. 7. Wartości błędu względnego, z jakim odpowiadała sieć dla zadanej w ciągu testującym wartości współczynnika dyfuzyjności cieplnej a
Fig. 7. Relative error of the network response for thermal diffusivity a at the testing stage



Rys. 8. Wynik procesu testowania nauczonej sieci metodą analizy regresji liniowej dla wyznaczanego przez sieć parametru dyfuzyjności cieplnej a :
 T – wartość zadana, A – odpowiedź sieci, R – współczynnik korelacji
Fig. 8. Linear regression method for heat diffusivity: T – given training output value of a , A – network answer, R – correlation coefficient

Przeprowadzone symulacje uczenia i testowania sieci RBF wykazały możliwość wykorzystania ich w przedstawianym zagadnieniu. Sieci te wykazywały jednak dużą tendencję do tzw. „przeuczenia”. Świadczy to o konieczności zmniejszania liczby neuronów w sieci poprzez użycie odpowiednich funkcji z możliwością takiej implementacji, bądź zmniejszenie rozmiarów wektorów uczących. Ponadto w celu poprawienia możliwości uogólniania modelu przez sieć neuronową RBF można zastosować odpowiedni preprocessing w stosunku do danych liczbowych wektora wejściowego oraz postprocessing w stosunku do danych liczbowych wektora wyjściowego sieci. Jednak przetwarzanie danych wejściowych oraz wyjściowych dodatkowo komplikuje implementa-

cję programową algorytmu. W tym przypadku nie byłoby to optymalne rozwiązanie przedstawianego problemu.

Większą elastyczność aproksymacji modelu dla współczynnika zagadnienia odwrotnego, wykazywały prostsze struktury nieliniowych sieci neuronowych. Symulacje wykazały, że optymalnym rozwiązaniem jest przyjęcie neuronów z funkcją aktywacji tangens hiperboliczny w warstwie wejściowej oraz ukrytej. W przypadku warstwy wyjściowej wystarczające są neurony z liniową funkcją aktywacji.

Wyniki symulacji dla sieci trójwarstwowej, z ukrytą warstwą neuronów, wykazały jej bardzo dobre możliwości aproksymacyjne zadanego modelu. Sieć 4), – tab. 1, osiągała zadowalające wyniki już po 25 epokach uczenia. Dzięki szerokim możliwościom doboru architektury takiej sieci, oraz parametrów uczenia, nie występował efekt przeuczenia sieci 5). Przy 1000 epokach uczenia, błąd odpowiedzi sieci był mniejszy, zarówno dla wektora uczącego jak i testującego.

Zbadano także możliwości aproksymacyjne sieci dwuwarstwowych. Błąd odpowiedzi tych sieci był nieco większy niż dla sieci trójwarstwowych, lecz przy odpowiedniej ilości neuronów w warstwie wejściowej oraz odpowiednio długiemu procesowi uczenia, osiągnięto możliwie optymalną architekturę sieci neuronowej 8) – nieliniowa, dwuwarstwowa sieć neuronowa: 20 neuronów z funkcją aktywacji tangens hiperboliczny w warstwie wejściowej, 2 neurony z liniową funkcją aktywacji w warstwie wyjściowej. Nie można jednak na tym etapie badań przyjmować tej architektury jako ostatecznej. Bardzo ważnym czynnikiem określającym przydatność nauczonej sieci neuronowej jest wpływ błędów pomiarowych 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.

7. Wpływ błędów pomiarowych na wyniki identyfikacji parametrów cieplnych przez struktury sztucznych sieci neuronowych

W dalszych badaniach modelowych zbadano wpływ błędów pomiarowych mierzonych wielkości wejściowych na wartości identyfikowanych parametrów cieplnych. Założono, że opisywany system pomiarowy będzie wykorzystywany w pomiarach przemysłowych. Dlatego wystarczającym warunkiem jest przyjęcie niepewności identyfikowanych parametrów cieplnych rzędu kilku %.


W przedstawianym modelu systemu pomiarowego przyjęto, że wpływ na wynik identyfikacji parametrów mają: błędy wnoszone przez tory pomiarowe przyrostu temperatur sondy cieplnej $T_G(t)$ i termometru dodatkowego $T_D(t)$, błąd pomiaru mocy cieplnej P_G dostarczonej do sondy oraz błąd pomiaru odległości r pomiędzy sondą cieplną i termometrem dodatkowym. Przyjęto, że wyżej wymienione wielkości wejściowe opisane są przez symetryczne, prostokątne rozkłady prawdopodobieństwa o następujących szerokościach połowkowych: $\Delta T_G(t)=0,1K$; $\Delta T_D(t)=0,05K$; $\Delta P_G=1 \text{ mW/m}$; $\Delta r=0,1 \text{ mm}$.

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 [16], który przewidziano jako uzupełnienie pozycji [17]. Dokument przedstawia zalecenia dotyczące obliczania niepewności w sytuacji, gdy niespełnione są warunki dla zastosowania „prawa propagacji niepewności”, szczególnie ze względu na złożoność modelu pomiaru [16, 18].

Symulacje przeprowadzono dla założonych pięciu przypadków wartości identyfikowanych parametrów próbki:


- $a=2,5 \cdot 10^{-6} \text{ m}^2/\text{s}$ oraz $\lambda=4,0 \cdot 10^{-2} \text{ W}/(\text{m} \cdot \text{K})$,
- $a=1,5 \cdot 10^{-6} \text{ m}^2/\text{s}$ oraz $\lambda=3,3 \cdot 10^{-2} \text{ W}/(\text{m} \cdot \text{K})$,
- $a=3,5 \cdot 10^{-6} \text{ m}^2/\text{s}$ oraz $\lambda=4,7 \cdot 10^{-2} \text{ W}/(\text{m} \cdot \text{K})$,
- $a=3,5 \cdot 10^{-6} \text{ m}^2/\text{s}$ oraz $\lambda=3,3 \cdot 10^{-2} \text{ W}/(\text{m} \cdot \text{K})$,
- $a=1,5 \cdot 10^{-6} \text{ m}^2/\text{s}$ oraz $\lambda=4,7 \cdot 10^{-2} \text{ W}/(\text{m} \cdot \text{K})$.

Litery poszczególnych pięciu przypadków wartości identyfikowanych parametrów próbki w przedstawionej powyżej liście, obowiązują w tabelarycznym zestawieniu wyników przedstawionym w dalszej części artykułu. Wygenerowanie wartości wejściowych dla liczby losowań $M=10^6$ i przeliczenie modelu zjawiska dla jednego punktu przyjętych wartości parametrów cieplnych, zajmowało średnio czas około 6 dni. Dlatego też do symulacji przyjęto 5 par wartości parametrów a i λ . Dla każdej pary wyznaczono dystrybuanty $G(a)$ i $G(\lambda)$ wielkości wyjściowych poprzez ich model matematyczny na podstawie przyjętych wyżej rozkładów wielkości wejściowych. Ze względu na ograniczoną objętość artykułu wyniki wpływu błędów pomiarowych na wyniki identyfikacji parametrów cieplnych przez sieci neuronowe w formie wykresów dystrybuanty przedstawiono jedynie przykładowo dla klasycznej sieci RBF- rysunki 8 i 9. Całość wyników zebrano w tabeli 2, w której przedstawiono wyznaczone z rozkładów wielkości wyjściowych a i λ następujące parametry: wartość oczekiwaną, odchylenie standardowe oraz przedział ufności dla poziomu prawdopodobieństwa 0,95. Parametry wyznaczono dla dziesięciu wybranych architektur sieci neuronowych (kolumna 1) dla pięciu punktów płaszczyzny zmienności identyfikowanych parametrów a i λ (kolumna 2).



Rys. 8. Dystrybuanta dla wartości współczynnika dyfuzyjności cieplnej a

Fig. 8. Distribution function for thermal diffusivity a



Rys. 9. Dystrybuanta dla wartości współczynnika przewodzenia ciepła λ

Fig. 9. Distribution function for thermal conductivity λ

Wyniki symulacji dla sieci trójwarstwowej, z ukrytą warstwą neuronów, wykazały jej bardzo dobre możliwości aproksymacyjne. Sieć jednak wykazywała znaczący wpływ błędów pomiarowych w wektorach wielkości wejściowych na wyniki identyfikowanych przez sieć parametrów cieplnych. Przy odpowiednio długim procesie uczenia struktury sieci wpływ ten można było zmniejszyć. Przy 1000 epokach uczenia, błąd odpowiedzi sieci był mniejszy i spełniał założenia projektowe.

Tab. 2. Wyznaczone parametry rozkładu prawdopodobieństwa
Tab. 2. Parameters of probability distribution

Typ sieci	Parametry ident.	Dyfuzyjność cieplna a m ² /s			Przewodność cieplna λ W/(m·K)		
		Wartość oczekiwana	Odchylenie standardowe	Przedział ufności dla $p=0,95$	Wartość oczekiwana	Odchylenie standardowe	Przedział ufności dla $p=0,95$
1)	a)	2,50·10 ⁻⁶	1,21·10 ⁻⁷	[2,27·10 ⁻⁶ ;2,74·10 ⁻⁶]	4,00·10 ⁻²	2,11·10 ⁻⁴	[3,96·10 ⁻² ; 4,04·10 ⁻²]
	b)	1,50·10 ⁻⁶	1,26·10 ⁻⁷	[1,26·10 ⁻⁶ ;1,75·10 ⁻⁶]	3,30·10 ⁻²	1,86·10 ⁻⁴	[3,26·10 ⁻² ; 3,34·10 ⁻²]
	c)	3,50·10 ⁻⁶	1,13·10 ⁻⁷	[3,29·10 ⁻⁶ ;3,72·10 ⁻⁶]	4,70·10 ⁻²	2,35·10 ⁻⁴	[4,66·10 ⁻² ; 4,74·10 ⁻²]
	d)	3,50·10 ⁻⁶	1,34·10 ⁻⁷	[3,25·10 ⁻⁶ ;3,75·10 ⁻⁶]	3,30·10 ⁻²	1,86·10 ⁻⁴	[3,26·10 ⁻² ; 3,34·10 ⁻²]
	e)	1,50·10 ⁻⁶	0,99·10 ⁻⁷	[1,31·10 ⁻⁶ ;1,70·10 ⁻⁶]	4,70·10 ⁻²	2,33·10 ⁻⁴	[4,65·10 ⁻² ; 4,74·10 ⁻²]
2)	a)	2,51·10 ⁻⁶	6,51·10 ⁻⁸	[2,41·10 ⁻⁶ ;2,63·10 ⁻⁶]	4,00·10 ⁻²	0,42·10 ⁻⁴	[3,99·10 ⁻² ; 4,01·10 ⁻²]
	b)	1,52·10 ⁻⁶	4,20·10 ⁻⁸	[1,45·10 ⁻⁶ ;1,58·10 ⁻⁶]	3,31·10 ⁻²	5,50·10 ⁻⁴	[3,22·10 ⁻² ; 3,38·10 ⁻²]
	c)	2,99·10 ⁻⁶	0,62·10 ⁻⁸	[2,98·10 ⁻⁶ ;3,00·10 ⁻⁶]	4,60·10 ⁻²	0,21·10 ⁻⁴	[4,59·10 ⁻² ; 4,60·10 ⁻²]
	d)	2,97·10 ⁻⁶	2,07·10 ⁻⁸	[2,92·10 ⁻⁶ ;2,99·10 ⁻⁶]	3,20·10 ⁻²	0,28·10 ⁻⁴	[3,20·10 ⁻² ; 3,21·10 ⁻²]
	e)	1,51·10 ⁻⁶	2,97·10 ⁻⁸	[1,46·10 ⁻⁶ ;1,56·10 ⁻⁶]	4,70·10 ⁻²	4,07·10 ⁻⁴	[4,64·10 ⁻² ; 4,71·10 ⁻²]
3)	a)	2,50·10 ⁻⁶	2,73·10 ⁻⁸	[2,45·10 ⁻⁶ ;2,55·10 ⁻⁶]	4,00·10 ⁻²	2,32·10 ⁻³	[3,96·10 ⁻² ; 4,04·10 ⁻²]
	b)	1,50·10 ⁻⁶	1,56·10 ⁻⁸	[1,45·10 ⁻⁶ ;1,53·10 ⁻⁶]	3,30·10 ⁻²	2,07·10 ⁻³	[3,26·10 ⁻² ; 3,33·10 ⁻²]
	c)	3,49·10 ⁻⁶	3,75·10 ⁻⁸	[3,43·10 ⁻⁶ ;3,56·10 ⁻⁶]	4,70·10 ⁻²	2,56·10 ⁻³	[4,66·10 ⁻² ; 4,75·10 ⁻²]
	d)	3,48·10 ⁻⁶	4,98·10 ⁻⁸	[3,40·10 ⁻⁶ ;3,57·10 ⁻⁶]	3,30·10 ⁻²	2,07·10 ⁻³	[3,26·10 ⁻² ; 3,33·10 ⁻²]
	e)	1,50·10 ⁻⁶	1,22·10 ⁻⁸	[1,48·10 ⁻⁶ ;1,52·10 ⁻⁶]	4,70·10 ⁻²	2,46·10 ⁻³	[4,66·10 ⁻² ; 4,74·10 ⁻²]
4)	a)	2,49·10 ⁻⁶	3,07·10 ⁻⁷	[1,91·10 ⁻⁶ ;3,05·10 ⁻⁶]	3,98·10 ⁻²	2,82·10 ⁻³	[3,43·10 ⁻² ; 4,53·10 ⁻²]
	b)	1,52·10 ⁻⁶	2,49·10 ⁻⁷	[1,09·10 ⁻⁶ ;1,99·10 ⁻⁶]	3,28·10 ⁻²	2,87·10 ⁻³	[2,75·10 ⁻² ; 3,83·10 ⁻²]
	c)	3,48·10 ⁻⁶	1,55·10 ⁻⁷	[3,18·10 ⁻⁶ ;3,77·10 ⁻⁶]	4,70·10 ⁻²	2,56·10 ⁻³	[4,20·10 ⁻² ; 5,14·10 ⁻²]
	d)	3,48·10 ⁻⁶	2,49·10 ⁻⁷	[2,99·10 ⁻⁶ ;3,95·10 ⁻⁶]	3,29·10 ⁻²	2,47·10 ⁻³	[2,83·10 ⁻² ; 3,74·10 ⁻²]
	e)	1,50·10 ⁻⁶	1,61·10 ⁻⁷	[1,16·10 ⁻⁶ ;1,78·10 ⁻⁶]	4,68·10 ⁻²	2,36·10 ⁻³	[4,26·10 ⁻² ; 5,14·10 ⁻²]
5)	a)	2,50·10 ⁻⁶	6,33·10 ⁻⁸	[2,38·10 ⁻⁶ ;2,63·10 ⁻⁶]	4,00·10 ⁻²	4,89·10 ⁻⁴	[3,90·10 ⁻² ; 4,10·10 ⁻²]
	b)	1,50·10 ⁻⁶	6,61·10 ⁻⁸	[1,41·10 ⁻⁶ ;1,99·10 ⁻⁶]	3,30·10 ⁻²	4,68·10 ⁻⁴	[3,21·10 ⁻² ; 3,39·10 ⁻²]
	c)	3,50·10 ⁻⁶	3,75·10 ⁻⁸	[3,35·10 ⁻⁶ ;3,65·10 ⁻⁶]	4,70·10 ⁻²	5,12·10 ⁻⁴	[4,60·10 ⁻² ; 4,80·10 ⁻²]
	d)	3,50·10 ⁻⁶	7,63·10 ⁻⁸	[3,32·10 ⁻⁶ ;3,68·10 ⁻⁶]	3,30·10 ⁻²	4,36·10 ⁻⁴	[3,21·10 ⁻² ; 3,38·10 ⁻²]
	e)	1,50·10 ⁻⁶	9,10·10 ⁻⁸	[1,42·10 ⁻⁶ ;1,58·10 ⁻⁶]	4,70·10 ⁻²	5,64·10 ⁻⁴	[4,59·10 ⁻² ; 4,81·10 ⁻²]
6)	a)	2,48·10 ⁻⁶	2,66·10 ⁻⁷	[1,98·10 ⁻⁶ ;2,97·10 ⁻⁶]	4,05·10 ⁻²	3,52·10 ⁻³	[3,39·10 ⁻² ; 4,74·10 ⁻²]
	b)	1,50·10 ⁻⁶	2,33·10 ⁻⁷	[1,06·10 ⁻⁶ ;1,92·10 ⁻⁶]	3,30·10 ⁻²	3,67·10 ⁻³	[2,59·10 ⁻² ; 3,99·10 ⁻²]
	c)	3,47·10 ⁻⁶	2,80·10 ⁻⁷	[2,94·10 ⁻⁶ ;3,97·10 ⁻⁶]	4,67·10 ⁻²	2,46·10 ⁻³	[4,21·10 ⁻² ; 5,12·10 ⁻²]
	d)	3,42·10 ⁻⁶	3,33·10 ⁻⁷	[2,80·10 ⁻⁶ ;3,40·10 ⁻⁶]	3,28·10 ⁻²	4,27·10 ⁻³	[2,49·10 ⁻² ; 4,12·10 ⁻²]
	e)	1,49·10 ⁻⁶	1,20·10 ⁻⁷	[1,09·10 ⁻⁶ ;1,87·10 ⁻⁶]	4,70·10 ⁻²	2,76·10 ⁻³	[4,15·10 ⁻² ; 5,19·10 ⁻²]
7)	a)	2,53·10 ⁻⁶	2,74·10 ⁻⁸	[2,48·10 ⁻⁶ ;2,58·10 ⁻⁶]	4,05·10 ⁻²	4,29·10 ⁻⁴	[3,97·10 ⁻² ; 4,13·10 ⁻²]
	b)	1,49·10 ⁻⁶	2,30·10 ⁻⁸	[1,45·10 ⁻⁶ ;1,54·10 ⁻⁶]	3,29·10 ⁻²	4,16·10 ⁻⁴	[3,21·10 ⁻² ; 3,37·10 ⁻²]
	c)	3,41·10 ⁻⁶	2,95·10 ⁻⁸	[3,35·10 ⁻⁶ ;3,45·10 ⁻⁶]	4,56·10 ⁻²	4,05·10 ⁻⁴	[4,49·10 ⁻² ; 4,64·10 ⁻²]
	d)	3,42·10 ⁻⁶	3,02·10 ⁻⁸	[3,27·10 ⁻⁶ ;3,39·10 ⁻⁶]	3,27·10 ⁻²	4,01·10 ⁻⁴	[3,19·10 ⁻² ; 3,34·10 ⁻²]
	e)	1,49·10 ⁻⁶	2,24·10 ⁻⁸	[1,44·10 ⁻⁶ ;1,53·10 ⁻⁶]	4,70·10 ⁻²	4,65·10 ⁻⁴	[4,61·10 ⁻² ; 4,79·10 ⁻²]
8)	a)	2,50·10 ⁻⁶	4,48·10 ⁻⁸	[2,41·10 ⁻⁶ ;2,59·10 ⁻⁶]	4,00·10 ⁻²	5,72·10 ⁻⁴	[3,89·10 ⁻² ; 4,11·10 ⁻²]
	b)	1,50·10 ⁻⁶	3,51·10 ⁻⁸	[1,43·10 ⁻⁶ ;1,57·10 ⁻⁶]	3,30·10 ⁻²	5,53·10 ⁻⁴	[3,19·10 ⁻² ; 3,41·10 ⁻²]
	c)	3,50·10 ⁻⁶	5,15·10 ⁻⁸	[3,40·10 ⁻⁶ ;3,60·10 ⁻⁶]	4,70·10 ⁻²	6,12·10 ⁻⁴	[4,58·10 ⁻² ; 4,82·10 ⁻²]
	d)	3,50·10 ⁻⁶	5,97·10 ⁻⁸	[3,38·10 ⁻⁶ ;3,61·10 ⁻⁶]	3,30·10 ⁻²	5,65·10 ⁻⁴	[3,19·10 ⁻² ; 3,41·10 ⁻²]
	e)	1,50·10 ⁻⁶	3,18·10 ⁻⁸	[1,44·10 ⁻⁶ ;1,56·10 ⁻⁶]	4,70·10 ⁻²	5,77·10 ⁻⁴	[4,59·10 ⁻² ; 4,81·10 ⁻²]
9)	a)	2,51·10 ⁻⁶	2,12·10 ⁻⁷	[2,12·10 ⁻⁶ ;2,91·10 ⁻⁶]	4,00·10 ⁻²	3,22·10 ⁻³	[3,38·10 ⁻² ; 4,61·10 ⁻²]
	b)	1,51·10 ⁻⁶	2,26·10 ⁻⁷	[1,08·10 ⁻⁶ ;1,93·10 ⁻⁶]	3,30·10 ⁻²	2,87·10 ⁻³	[2,76·10 ⁻² ; 3,83·10 ⁻²]
	c)	3,52·10 ⁻⁶	3,75·10 ⁻⁷	[3,10·10 ⁻⁶ ;3,96·10 ⁻⁶]	4,70·10 ⁻²	3,56·10 ⁻³	[4,03·10 ⁻² ; 5,37·10 ⁻²]
	d)	3,52·10 ⁻⁶	3,50·10 ⁻⁷	[2,90·10 ⁻⁶ ;4,20·10 ⁻⁶]	3,30·10 ⁻²	2,97·10 ⁻³	[2,73·10 ⁻² ; 3,86·10 ⁻²]
	e)	1,50·10 ⁻⁶	1,82·10 ⁻⁷	[1,15·10 ⁻⁶ ;1,84·10 ⁻⁶]	4,69·10 ⁻²	3,16·10 ⁻³	[4,10·10 ⁻² ; 5,31·10 ⁻²]
10)	a)	2,50·10 ⁻⁶	7,07·10 ⁻⁸	[2,36·10 ⁻⁶ ;2,64·10 ⁻⁶]	4,00·10 ⁻²	1,02·10 ⁻³	[3,81·10 ⁻² ; 4,21·10 ⁻²]
	b)	1,50·10 ⁻⁶	5,72·10 ⁻⁸	[1,39·10 ⁻⁶ ;1,61·10 ⁻⁶]	3,30·10 ⁻²	1,07·10 ⁻³	[3,12·10 ⁻² ; 3,49·10 ⁻²]
	c)	3,49·10 ⁻⁶	8,38·10 ⁻⁸	[3,33·10 ⁻⁶ ;3,66·10 ⁻⁶]	4,70·10 ⁻²	1,26·10 ⁻³	[4,48·10 ⁻² ; 4,95·10 ⁻²]
	d)	3,48·10 ⁻⁶	8,46·10 ⁻⁸	[3,31·10 ⁻⁶ ;3,64·10 ⁻⁶]	3,30·10 ⁻²	0,87·10 ⁻³	[3,14·10 ⁻² ; 3,81·10 ⁻²]
	e)	1,50·10 ⁻⁶	6,79·10 ⁻⁸	[1,37·10 ⁻⁶ ;1,63·10 ⁻⁶]	4,70·10 ⁻²	1,36·10 ⁻³	[4,46·10 ⁻² ; 4,95·10 ⁻²]

Błąd odpowiedzi sieci dwuwarstwowych był nieco większy niż dla sieci trójwarstwowych, lecz przy odpowiedniej ilości neuronów w warstwie wejściowej oraz odpowiednio długiemu procesowi uczenia, osiągnięto mały wpływ błędów pomiarowych w wektorach wielkości wejściowych na wyniki identyfikowanych przez sieć parametrów cieplnych. Jako optymalną przyjęto następującą architekturę sieci neuronowej – nieliniowa, dwuwarstwowa sieć neuronowa: 20 neuronów z funkcją aktywacji tangens hiperboliczny w warstwie wejściowej, 2 neurony z liniową funkcją aktywacji w warstwie wyjściowej.

8. Wnioski

Przedstawione wyniki symulacji wskazują, że istnieje możliwość wykorzystania w praktyce przedstawianej koncepcji systemu pomiarowego, wykorzystującego sieć neuronową do rozwiązania zagadnienia odwrotnego. Rozwiązanie to pozwala na identyfikację parametrów cieplnych materiału dla powtarzalnych wartości wymuszenia cieplnego sondy. Niewątpliwą zaletą takiego rozwiązania jest możliwość stosowania termometrów o większej średnicy, które można „wbicić” w określony przekrój badanej próbki. Rozwiązanie to nie wymaga specjalnego stanowiska pomiarowego. Wykorzystanie sieci neuronowej pozwala zbudować system pomiarowy na bazie prostego mikrokontrolera, w którego programie można zaimplementować strukturę nauczonej sieci neuronowej. Przedstawione rozwiązanie pozwala maksymalnie uprościć zarówno stanowisko pomiarowe jak i użyty system pomiarowy, względnie prosty i tani mikrokontroler. Planowane są dalsze prace

badawcze związane z eksperymentalną weryfikacją przedstawionego modelu systemu pomiarowego. Niniejszy artykuł stanowi wycinek większego problemu pomiaru parametrów cieplnych materiałów termoizolacyjnych.

Praca naukowa finansowana ze środków na naukę (Ministerstwo Nauki i Szkolnictwa Wyższego) w latach 2007-2009 jako projekt badawczy nr N N505 312933.

9. Literatura

- [1] С. Е. Платунов: Теплофизические измерения и приборы; Изд. „Машиностроение”, Ленинград 1986.
- [2] Praca zbiorowa: Pomiar ciepła. WNT, Warszawa 1995.
- [3] W. Minkina, S. Chudzik: System pomiarowy do wyznaczenia współczynnika wyrównywania temperatury metodą dynamiczną. Sympozjum Modelowanie i Symulacja Systemów Pomiarowych, Krynica 1998, 272-279.
- [4] W. Minkina, S. Chudzik: Pomiar parametrów cieplnych materiałów termoizolacyjnych – przyrządy i metody. Wydawnictwo Politechniki Częstochowskiej, Częstochowa 2004, ISBN 83-7193-216-2.
- [5] C. Gobbe, S. Iserna, B. Ladevie: Hot strip method: application to thermal characterisation of orthotropic media. International Journal of Thermal Sciences 43, 2004, 951-958.
- [6] J. Sylos Cintra, W. Santos: Numerical analysis of sample dimensions in hot wire thermal conductivity measurements. Journal of the European Ceramic Society 20, 2000, 1871-1875.
- [7] I.H. Tavman, S. Tavman: Measurement of thermal conductivity of dairy products; Journal of Food Engineering 41, 1999, 109-114.
- [8] A. Bouguerra, O. Ait-Mokhtar, M. Amiri, B. Diop: Measurement of thermal conductivity, thermal diffusivity and heat capacity of highly porous building materials using transient plane source technique. Int. Comm Heat Mass Transfer 28, 2001, 1065-1078.
- [9] J. Gajda. M. Szyper: Modelowanie i badania symulacyjne systemów pomiarowych, Nakładem Akademii Górniczo-Hutniczej, Kraków 1998.
- [10] Praca zbiorowa, red. И. С. Григорьева: Физические величины, Справочник. Энергоатомиздат, Москва 1991.
- [11] A. Bejan: Heat transfer, John Wiley & Sons, New York 1993.
- [12] Praca zbiorowa, red. Szargut J.: Modelowanie numeryczne pól temperatury. WNT, Warszawa 1992.
- [13] P. Daponte, D. Grimaldi: Artificial neural networks in measurements. Measurement 23, 1998, 93-115.
- [14] S. Osowski: Sieci neuronowe w ujęciu algorytmicznym. WNT Warszawa 1996.
- [15] I. Turias, J. Gutierrez, P. Galindo: Modelling the effective thermal conductivity of a unidirectional composite by the use of artificial neural networks. Composites Science and Technology 65, 2005, 609-619.
- [16] 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.
- [17] Wyrażanie niepewności pomiaru. Przewodnik. Wydawnictwo GUM, 1999.
- [18] P. Fotowicz: Wyrażanie niepewności pomiaru w świetle najnowszych propozycji Międzynarodowego Biura Miar. IV Konferencja Podstawowe Problemy Metrologii, Ustroń 2005, 37-45.

Artykuł recenzowany

INFORMACJE

Studia Podyplomowe

Wydział Elektryczny Politechniki Śląskiej w Gliwicach, Katedra Metrologii, Elektroniki i Automatyki
ogłasza nabór na Dwusemestralne Zaoczne Studia Podyplomowe

Organizacja i Akredytacja Laboratoriów

Studia prowadzone są na Wydziale Elektrycznym Politechniki Śląskiej w Gliwicach, w systemie zaocznym w każdą sobotę lub w co drugi weekend (do wyboru) przez dwa semestry. Zajęcia prowadzone są przez nauczycieli akademickich ze stopniem co najmniej doktora oraz przez zaproszonych Gości o uznanym dorobku i autorytecie. Studia obejmują 200 godzin dydaktycznych. Rozpoczęcie Studiów nastąpi po skompletowaniu odpowiedniej liczby kandydatów na dany rodzaj studiów.

Organizator studiów:

Katedra Metrologii, Elektroniki i Automatyki Politechniki Śląskiej, 44-100 Gliwice, ul. Akademicka 10, tel. 032 237 12 41, fax: 032 237 20 34, e-mail: re2@polsl.pl lub agnieszka.skorkowska@polsl.pl, <http://imeia.elekt.polsl.pl>

Kierownik studiów:

Prof. dr hab. inż. Tadeusz SKUBIS