

**Stanisław CHUDZIK, Waldemar MINKINA**  
POLITECHNIKA CZĘSTOCHOWSKA

## Model systemu pomiarowego do kontroli parametrów cieplnych materiałów termoizolacyjnych z sondą cieplną

Dr inż. Stanisław CHUDZIK

Adiunkt w Zakładzie Techniki Mikroprocesorowych, Automatyki i Pomiarów Ciepłych na Wydziale Elektrycznym Politechniki Częstochowskiej. Stopień naukowy doktora uzyskał w 2003r. 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.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 ponad 100 publikacji, 4 patentów oraz 3 zgłoszeń patentowych. Promotor 3 obronionych oraz 1 otwartej pracy doktorskiej. Specjalizuje się w problematyce dotyczącej szeroko rozumianej termometrii, termografii komputerowej, pomiarów cieplnych oraz teorii i techniki wymiany ciepła.



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

### Streszczenie

W artykule przedstawiono model koncepcji systemu pomiarowego wykorzystującego odpowiednią sondę cieplną do kontroli parametrów cieplnych materiałów termoizolacyjnych. Przedstawiany system pomiarowy wykorzystuje sztuczne sieci neuronowe do rozwiązania współzmiennikowego zagadnienia odwrotnego dyfuzji ciepła w materiale. Symulacje zjawiska dyfuzji ciepła oraz proces uczenia sieci neuronowej przeprowadzono w środowisku programowym Matlab.

**Słowa kluczowe:** sieci neuronowe, przewodność cieplna.

## Model of measurement system with thermal probe for testing parameters of heat-insulating materials

### Abstract

The article presents model of measurement system with thermal probe for testing thermal parameters of heat-insulating materials. Measurement system uses the artificial neural network in order to solve the coefficient inverse problem for solid. The network learning process and simulation analyses are based on the Matlab.

**Keywords:** neural networks, thermal conductivity.

## 1. Wstęp

Znaczący udział w ilości wytwarzanej energii na świecie ma energia cieplna wykorzystywana w przemyśle w wielu procesach produkcyjnych oraz w budownictwie mieszkaniowym. Aby ograniczyć maksymalnie ilość traconego ciepła przenikającego do otoczenia przez przegrodę budowlaną, stosuje się dodatkowo w przegrodzie specjalne materiały termoizolacyjne. Odpowiednio zaprojektowana termoizolacja budynku i użycie dobrych jakościowo materiałów termoizolacyjnych zapewnia właścicielowi obniżenie kosztów utrzymania takiego budynku [1,6] oraz wnosi wymierny wkład w ochronę środowiska.

W związku z powyższym można uznać, że ważnym zagadnieniem jest kontrola parametrów termofizycznych materiałów termoizolacyjnych takich jak styropian czy wełna mineralna, które najczęściej wykorzystywane są w budownictwie. W artykule przedstawiono zagadnienie dotyczące określenia właściwości termofizycznych rozpatrywanego ośrodka, tj. określenia podstawowych parametrów termofizycznych materiału termoizolacyjnego: współczynnika dyfuzyjności cieplnej  $a$ ,  $m^2/s$ ,

współczynnika przewodzenia ciepła  $\lambda$ ,  $W/(m^2 K)$ , oraz ciepła właściwego  $c_p$ ,  $J/(kg K)$ .

## 2. Koncepcja systemu pomiarowego wykorzystującego sondę cieplną

Obecnie w laboratoriach najczęściej wykorzystywana jest metoda stykowa oparta na ustalonych warunkach wymiany ciepła, wykorzystująca aparaty płytowe [15,18]. Metoda ta pozwala wyznaczyć jedynie współczynnik przewodzenia ciepła badanego materiału, wymaga użycia dużych i ciężkich systemów pomiarowych oraz długiego odcinka czasu na dokonanie pomiaru. Dlatego też podejmowane są prace nad stworzeniem koncepcji systemów pomiarowych, nie posiadających takich ograniczeń jak obecnie wykorzystywane aparaty do wyznaczania parametrów cieplnych materiałów termoizolacyjnych.


Przedstawiana koncepcja systemu pomiarowego oparta jest na wykorzystaniu sondy cieplnej, którą można byłoby wbić w miękki materiał termoizolacyjny. Zazwyczaj sondy cieplne działające na zasadzie liniowego źródła ciepła wykorzystywane są do pomiaru przewodności ciał sypkich i lepkich cieczy [19,21]. 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. Znaną koncepcję wykorzystania sondy cieplnej do wyznaczania współczynnika przewodności cieplnej [4,9,19,20,21], korzystają z wyprowadzonych z równania Fouriera uproszczonych zależności, które nie zapewniają dokładnych wyników. 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 daleko posuniętych uproszczeń.

Koncepcja systemu pomiarowego zakłada możliwość określenia trzech podstawowych parametrów cieplnych ( $a$ ,  $\lambda$ ,  $\rho \cdot c_p$ ) 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 1 cm od osi symetrii sondy cieplnej. W projekcie założono, że średnica sondy cieplnej wyniesie 2mm a średnica dodatkowego czujnika temperatury 1mm – rys.1.



Rys. 1. Szcik projektu kompletnej sondy  
Fig. 1. Predesign of thermal probe

Przy obecnych możliwościach technologicznych produkcji czujników temperatury, przyjęte wielkości średnic są możliwe do osiągnięcia. Długość sondy pomiarowej nie została jeszcze w projekcie dokładnie przyjęta. Ważne jest jedynie, aby jej długość była wielokrotnie większa od jej średnicy. Przedstawiony w dalszej części artykułu dwuwymiarowy model matematyczny zjawiska dyfuzji ciepła zakłada, że sonda jest nieskończenie długa. W praktycznym wykonaniu można przyjąć, że długość sondy wyniesie ok. 10-20 cm w zależności od grubości badanych próbek.

### 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 [12]. Ze względu na przyjęty model w dwuwymiarowym układzie współrzędnych, zakłada się, że sonda pomiarowa jest nieskończenie długa, podobnie jak grubość badanej próbki. W układzie współrzędnych XY zamodelowano przekrój poprzeczny połowy symetrycznej części próbki z umieszczoną w niej sondą pomiarową – rys.2. 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:  $a = 2,2 \cdot 10^{-6} \text{ m}^2/\text{s}$ ,  $\lambda = 0,04 \text{ W}/(\text{m}\cdot\text{K})$ , jej wymiary poprzeczne zapewniają mały wpływ warunku brzegowego. W związku z tym, badaną próbkę, można traktować jako nieskończenie rozległą.



Rys. 2. Szcik przekroju poprzecznego połowy symetrycznej części próbki z pogrążoną w niej sondą pomiarową  
Fig. 2. Sketch of a half section of sample with thermal probe

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 [8,13,14]. Z tego względu w omawianym modelu ujęto zarówno model sondy cieplnej jak i dodatkowego termometru umieszczonego obok w odległości 1cm. Przyjęto średnicę sondy cieplnej:  $\varnothing = 2\text{mm}$ , dodatkowego termometru:  $\varnothing = 1\text{mm}$ , oraz ich parametry cieplne:  $a = 8,2 \cdot 10^{-7} \text{ m}^2/\text{s}$ ,  $\lambda = 1,7 \text{ W}/(\text{m}\cdot\text{K})$ . Parametry cieplne sondy i termometru zaczerpnięto z [16]. Na rys.3 przedstawiono przykład siatki dyskretyzacji próbki z rys.2, utworzonej w postaci trójkątnych elementów skończonych [2,3,17]. Do rozwiązania zagadnienia prostego, czyli wyznaczenia rozkładu temperatury w czasie dla każdego elementu dyskretyzacji modelu próbki, wykorzystano metodę elementów skończonych [17].



Rys. 3. Przekrój poprzeczny połowy symetrycznej części próbki z pogrążoną w niej sondą pomiarową oraz siatką dyskretyzacji  
Fig. 3. A half section of sample with thermal probe and discrete mesh

### 4. Koncepcja wykorzystania sieci neuronowej do rozwiązania zagadnienia odwrotnego

Algorytm wyznaczenia parametrów cieplnych materiału z wykorzystaniem metody MRS oraz optymalizacji błędu średniokwadratowego, został szczegółowo przedstawiony w poprzednich publikacjach [13,14]. 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 została wysunięta koncepcja wykorzystania sztucznej sieci neuronowej [2,5,11,21], która na podstawie zmierzonych odpowiedzi temperaturowych sondy cieplnej i dodatkowego termometru oraz znajomości wartości gęstości strumienia ciepła oddanego przez sondę cieplną do próbki, określiłaby identyfikowane parametry termofizyczne.


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

### 5. Proces uczenia sieci neuronowej

Wykorzystując metodę elementów skończonych wygenerowano ciągi uczące dla sieci neuronowej. W związku z faktem, że wyznaczenie współczynników  $a$  oraz  $\lambda$  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  $\lambda$ . Przyjęto, że każdy współczynnik będzie przyjmował 10 wartości z założonego przedziału:  $a \in (1,3 \div 4,0) \cdot 10^{-6} \text{ m}^2/\text{s}$  i  $\lambda \in (3,2 \div 5,0) \cdot 10^{-2} \text{ W}/(\text{m}\cdot\text{K})$ . Kombinacja tych wartości daje 100 ciągów uczących.

Przykładowe ciągi uczące przebiegów wartości chwilowych przyrostu temperatury w osi symetrii sondy cieplnej  $T_G(t)$  przedstawiono na rys.4.




Rys. 4. Przykładowe ciągi uczące przebiegów wartości chwilowych przyrostu temperatury sondy cieplnej  $T_G(t)$

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

Przykładowe ciągi uczące przebiegów wartości chwilowych przyrostu temperatury termometru dodatkowego  $T_D(t)$  przedstawiono na rys.5.

Na podstawie próbnych symulacji, uwzględniając możliwości obliczeniowe użytego komputera, określono architekturę sieci neuronowej. Jest to dwuwarstwowa sieć składająca się z 20 neuronów z funkcją aktywacji tangens hiperboliczny w pierwszej warstwie. W drugiej warstwie są dwa neurony z liniową funkcją aktywacji. 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  $P_G=3,1 \text{ W}/\text{m}$ .




Rys. 5. Przykładowe ciągi uczące przebiegów wartości chwilowych przyrostu temperatury termometru dodatkowego  $T_D(t)$

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

Sieć neuronową poddano procesowi uczenia, polegającemu na zadawaniu na jej wejście kolejnych wektorów uczących a na jej wyjścia zadanych wartości współczynnika  $a$  i  $\lambda$ . Sieć neuronowa osiągała zadowalające wyniki już po około 20 epokach uczenia. Uczenie odbywało się tradycyjnym algorytmem wstecznej propagacji błędów.


## 6. Wyniki symulacji modelowych

W celu sprawdzenia, czy sieć poprawnie odpowiada dla pośrednich wartości  $a$  i  $\lambda$  z przedstawianych ciągów uczących, zasymulowano odpowiedzi dla 100 wartości współczynnika dyfuzyjności cieplnej  $a$ , zawartego w przedziale  $(1,3 \div 4,0) \cdot 10^{-6} \text{ m}^2/\text{s}$  oraz 100 wartości współczynnika przewodzenia ciepła  $\lambda$ , zawartego w przedziale  $(3,2 \div 5,0) \cdot 10^{-2} \text{ W}/(\text{m}\cdot\text{K})$ . Dało to w sumie 10000 wektorów testujących. Na rys.6 przedstawiono wartości błędów względnego, z jakim odpowiadała sieć dla danej wartości współczynnika  $a$ .



Rys. 6. Wartości procentowe błędów względnego  $\Delta a$  z jakim odpowiadała sieć dla danej wartości współczynnika  $a$

Fig. 6. Relative error of the network response  $\Delta a$  for thermal diffusivity  $a$



Rys. 7. Wartości procentowe błędów względnego  $\Delta \lambda$  z jakim odpowiadała sieć dla danej wartości współczynnika  $\lambda$

Fig. 7. Relative error of the network response  $\Delta \lambda$  for thermal conductivity  $\lambda$

Na rys.7 przedstawiono wartości błędów względnego, z jakim odpowiadała sieć dla danej wartości współczynnika  $\lambda$ . Można zauważyć, że wartości błędów identyfikacji parametrów cieplnych nauczonej sieci neuronowej są pomijalnie małe.

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 połówkowych:  $\Delta T_G(t)=0,1\text{K}$ ;  $\Delta T_D(t)=0,05\text{K}$ ;  $\Delta P_G=1\text{ mW/m.}$ ;  $\Delta r=0,1\text{ mm}$ .


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 [10], który przewidziano jako uzupełnienie pozycji [22]. Dokument przedstawia zalecenia dotyczące obliczania niepewności w sytuacji, gdy nie spełnione są warunki dla zastosowania „prawa propagacji niepewności”, szczególnie ze względu na złożoność modelu pomiaru [7,10].

Symulacje przeprowadzono dla następujących wartości identyfikowanych parametrów próbki:  $a=2,5\cdot 10^{-6}\text{ m}^2/\text{s}$  oraz  $\lambda=4,0\cdot 10^{-2}\text{ W/(m}\cdot\text{K)}$ . Wyznaczono dwie dystrybuanty  $G(a)$  i  $G(\lambda)$  dla wielkości wyjściowych (rys.8) poprzez ich model matematyczny na podstawie przyjętych wyżej rozkładów wielkości wejściowych.

W tabeli 1 przedstawiono wyznaczone z rozkładów wielkości wyjściowych następujące parametry: wartość średnią, odchylenie standardowe oraz przedział ufności dla poziomu prawdopodobieństwa 0,95. Otrzymane wyniki wskazują, że przy założonych wyżej niepewnościach pomiarów wielkości wejściowych, niepewność względna wyznaczanych parametrów cieplnych  $a$  i  $\lambda$  na poziomie ufności 0,95 nie przekroczy odpowiednio 8% i 3,5%.

Tab. 1. Wyznaczone parametry rozkładu prawdopodobieństwa  
Tab. 1. Parameters of a probability distribution

Parametr	Wartość średnia	Odchylenie standardowe	Przedział ufności dla p=0,95
$a$	$2,50\cdot 10^{-6}$	$1,0\cdot 10^{-7}$	$[2,70\cdot 10^{-6}; 2,30\cdot 10^{-6}]$
$\lambda$	$4,00\cdot 10^{-2}$	$6,3\cdot 10^{-4}$	$[4,13\cdot 10^{-2}; 3,88\cdot 10^{-2}]$



Rys. 8. Dystrybuanta dla wartości współczynnika przewodzenia ciepła  $\lambda$   
Fig. 8. Distribution function for thermal conductivity  $\lambda$

## 7. 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 „wbici” w określony przekrój badanej próbki. Rozwiązanie to nie wymaga budowania 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 strukturę stanowiska pomiarowego jak i użytego systemu pomiarowego, opartego o prosty i tani mikrokontroler. Prowadzone są dalsze prace badawcze związane z eksperymentalną weryfikacją przedstawionego modelu systemu pomiarowego.

## 8. Literatura

- [1] Al-Homoud M.: Performance characteristics and practical applications of common building thermal insulation materials. *Building and Environment* 40, 2005, 353–366.
- [2] Aquino W., Brigham J.: Self-learning finite elements for inverse estimation of thermal constitutive models. *International Journal of Heat and Mass Transfer* 49, 2006, 2466–2478.
- [3] Bejan A.: Heat transfer, John Wiley & Sons, New York 1993.
- [4] Bouguerra A., Ait-Mokhtar O., Amiri M. Diop B.: 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.
- [5] Daponte P., Grimaldi D.: Artificial neural networks in measurements. *Measurement* 23, 1998, 93–115.
- [6] Dyzman B.: Wpływ grubości styropianu na efekty ekonomiczne docieplenia budynku. *Materiały Budowlane* 1, 1997, 16–17.
- [7] Fotowicz P.: Wyrażanie niepewności pomiaru w świetle najnowszych propozycji Międzynarodowego Biura Miar. IV Konferencja Podstawowe Problemy Metrologii, Ustroń 2005, 37–45.
- [8] Gajda J. Szyper M.: Modelowanie i badania symulacyjne systemów pomiarowych, Nakładem Akademii Górniczo-Hutniczej, Kraków 1998.
- [9] Gobbé C., Iserna S., Ladevie B.: Hot strip method: application to thermal characterisation of orthotropic media. *International Journal of Thermal Sciences* 43, 2004, 951–958.
- [10] 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
- [11] MATLAB Neural network toolbox. User’s Guide. MathWorks 1997.
- [12] MATLAB Partial Differential Equation Toolbox. User’s Guide. MathWorks 1997.
- [13] Minkina W., Chudzik S.: System pomiarowy do wyznaczania współczynnika wyrównywania temperatury metodą dynamiczną. *Symposium Modelowanie i Symulacja Systemów Pomiarowych, Krynica 1998, 272–279.*
- [14] Minkina W., Chudzik S.: *Pomiary parametrów cieplnych materiałów termoizolacyjnych – przyrządy i metody.* Wydawnictwo Politechniki Częstochowskiej, Częstochowa 2004.
- [15] Платунов С. Е.: *Теплофизические измерения и приборы*; Изд. „Машиностроение”, Ленинград 1986.
- [16] Praca zbiorowa, red. И. С. Григорьева: *Физические величины, Справочник.* Энергоатомиздат, Москва 1991.
- [17] Praca zbiorowa, red. Szargut J.: *Modelowanie numeryczne pól temperatury.* WNT, Warszawa 1992.
- [18] Praca zbiorowa: *Pomiary cieplne.* WNT, Warszawa 1995.
- [19] Sylos Cintra J., Santos W.: Numerical analysis of sample dimensions in hot wire thermal conductivity measurements. *Journal of the European Ceramic Society* 20, 2000, 1871–1875.
- [20] Tavman I.H., Tavman S.: Measurement of thermal conductivity of dairy products; *Journal of Food Engineering* 41, 1999, 109–114.
- [21] Turias I, Gutierrez J., Galindo P.: Modelling the effective thermal conductivity of an unidirectional composite by the use of artificial neural networks. *Composites Science and Technology* 65, 2005, 609–619.
- [22] *Wyrażanie niepewności pomiaru.* Przewodnik. Wydawnictwo GUM, 1999.