

# Wykrywanie defektów z wykorzystaniem termografii aktywnej i algorytmu $k$ -średnich

Sebastian Dudzik

Politechnika Częstochowska, Wydział Elektryczny, Instytut Optoelektroniki i Systemów Pomiarowych,  
ul. Armii Krajowej 17, 42-200 Częstochowa

**Streszczenie:** W pracy przedstawiono nową metodę wykrywania defektów materiałowych z wykorzystaniem termografii aktywnej. W celu zwiększenia kontrastu cieplnego dokonano przetwarzania wstępnego zarejestrowanej sekwencji termogramów metodami morfologii matematycznej. Do wykrywania defektów zastosowano algorytm  $k$ -średnich. W pracy zbadano wpływ miary odległości używanej w opisywanym algorytmie oraz doboru danych wejściowych na efektywność opisywanej metody. Eksperyment przeprowadzono dla próbki wykonanej z kompozytu zbrojonego włóknem węglowym (CFRP). W badaniach stwierdzono, że najmniejsze błędy wykrywania defektów za pomocą opisywanej metody uzyskuje się dla kwadratowej odległości euklidesowej.

**Słowa kluczowe:** algorytm  $k$ -średnich, wykrywanie defektów, termografia aktywna

## 1. Wprowadzenie

### 1.1. Zastosowanie metod grupowania do wykrywania defektów materiałowych

Do wykrywania defektów w obiektach – bez zmiany właściwości materiałów, z których zostały one wykonane – stosowane są różne metody, w tym metody ultradźwiękowe, magnetyczno-proszkowe lub wizualne [1]. W przypadku, gdy defekty znajdują się w strefie przypowierzchniowej (w praktyce nie głębiej niż jeden centymetr, zależnie od dyfuzyjności cieplnej materiału i energii źródła wymuszenia) możliwe jest zastosowanie termografii aktywnej [2–5]. W każdej z metod termografii aktywnej badany obiekt (próbki materiału) nagrzewa się za pomocą wybranej metody wymuszenia (np.: fotoelektrycznie lub za pomocą drgań mechanicznych). W wyniku nagrzewania, w zależności od właściwości cieplnych materiału, warunków początkowych i brzegowych ustalonych w eksperymencie, na powierzchni badanego obiektu powstaje nieustalony rozkład temperatury. Rozkład ten jest następnie rejestrowany z określoną częstotliwością próbkowania za pomocą kamery termowizyjnej [6] w formie sekwencji termogramów. W dalszej kolejności, w celu wykrycia defektu, zarejestrowana sekwencja jest poddawana przetwarzaniu, z wykorzystaniem wybranych metod, w tym metod uczenia maszynowego [7–10]. W trakcie przetwarzania zarejestrowane pole temperatury przybiera formę

przebiegów czasowych dla każdego z pikseli znajdujących się w polu widzenia termogramu powierzchni badanego obiektu. Z punktu widzenia metod uczenia maszynowego przebiegi te stanowią wielowymiarowe obserwacje, które można interpretować jako punkty w  $n$ -wymiarowej przestrzeni cech, przy czym cechy to chwile czasowe wynikające z częstotliwości próbkowania.

Jedną z metod uczenia maszynowego, w grupie tzw. metod bez nadzoru jest analiza skupień, zwana również klasteryzacją lub grupowaniem [11, 12]. Analiza skupień polega na podziale zbioru obiektów na podzbiory, przy czym w poszczególnych podzbiorach znajdują się obiekty „podobne” do siebie. Podobieństwo określa się na podstawie specjalnej metryki (funkcji podobieństwa), której wartość uzyskiwana jest z wykorzystaniem poszczególnych cech grupowanych obiektów. Ostatecznie w wyniku grupowania powstaje  $k$  zbiorów obiektów, wykazujących podobieństwo w sensie kryterium określonego metryką podobieństwa. Istnieje wiele metod grupowania, w tym: metody hierarchiczne [13], metody  $k$ -średnich oraz metody grupowania rozmytego [14]. W niniejszej pracy zastosowano algorytm  $k$ -średnich. Podstawowa postać algorytmu działa w następujący sposób [14]:

#### Etap 1. Inicjalizacja

a. Przyjmuje się, że przynależność poszczególnych obiektów do grup nie jest znana. Założmy, że zbiór obiektów opisany jest następującą macierzą o wymiarach  $n \times d$ :

$$\mathbf{O} = \begin{pmatrix} x_{11} & x_{12} & \dots & x_{1d} \\ x_{21} & x_{22} & \dots & x_{2d} \\ \vdots & \vdots & \vdots & \vdots \\ x_{n1} & x_{n2} & \dots & x_{nd} \end{pmatrix}, \quad (1)$$

gdzie:  $n$  – liczba obiektów,  $d$  – liczba cech.

#### Autor korespondujący:

Sebastian Dudzik, sebdu@el.pcz.czyst.pl

#### Artykuł recenzowany

nadesłany 09.07 2019 r., przyjęty do druku 10.09. 2019 r.



Zezwala się na korzystanie z artykułu na warunkach licencji Creative Commons Uznanie autorstwa 3.0

- b. Określa się liczbę skupień (grup)  $k$  oraz rozmieszcza się centroidy reprezentujące grupy w położeniach początkowych w przestrzeni cech. Należy podkreślić, że początkowe rozmieszczenie centroidów ma duży wpływ na ostateczny wynik grupowania i może decydować o ostatecznym czasie wykonania algorytmu.
- c. Na podstawie odległości między poszczególnymi punktami danych a centroidami oblicza się początkową macierz odległości. Do obliczeń używane są różne miary odległości, w tym np. odległość euklidesowa [11]. W dalszej kolejności każdy obiekt ze zbioru  $\mathbf{O}$  przypisuje się do centroidu. Niech  $\mathbf{O}$  będzie zbiorem danych, zawierających  $n$  przypadków i reprezentowanym za pomocą macierzy (1), a  $\{C_1, C_2, \dots, C_k\}$  będzie oznaczać zbiór  $k$  rozłącznych grup w zbiorze  $\mathbf{O}$ . Obiekt  $x$  przypisuje się do grupy początkowej  $C_i^0$ , spełniającej następujący warunek:

$$C_i^0 = \left\{ \mathbf{x} : L(\mathbf{x}, \mu(C_i^0)) \leq L(\mathbf{x}, \mu(C_j^0)), \forall j, 1 < j < k \right\}, \quad (2)$$

gdzie:  $\mu(C_j^0)$  – początkowe położenie centroida  $j$ -tej grupy,  $L(\dots)$  – odległość między obiektami w przestrzeni cech.

**Etap 2. Iteracja**

- a. Przeprowadza się aktualizację położenia centroidów. Nowe współrzędne centroidów w kroku  $t + 1$  oblicza się jako średnią arytmetyczną współrzędnych wszystkich obiektów należących do grupy reprezentowanej przez ten centroid w kroku  $t$ , zgodnie z zależnością:

$$\mu(C_i^{(t+1)}) = \frac{\sum_{\mathbf{x} \in C_i^t} \mathbf{x}}{|C_i^t|}, \quad (3)$$

w szczególności, w pierwszej iteracji  $t = 0$ , tj. nowe współrzędne centroidów oblicza się na podstawie początkowych położenia centroidów w każdej z początkowych grup.

- b. Oblicza się macierz odległości i przypisuje się obiekty do nowych centroidów w kroku  $t + 1$ , przy czym nowe grupy spełniają warunek:

$$C_i^{(t+1)} = \left\{ \mathbf{x} : L(\mathbf{x}, \mu(C_i^{(t+1)})) \leq L(\mathbf{x}, \mu(C_j^{(t+1)})), \forall j, 1 < j < k \right\}, \quad (4)$$

- c. Kroki 2a i 2b są powtarzane tak długo, jak długo centroidy zmieniają swoje położenia. Prowadzi to do minimalizacji następującej funkcji błędu:

$$E = \sum_{i=1}^k \sum_{\mathbf{x} \in C_i} L(\mathbf{x}, \mu(C_i)). \quad (5)$$

Opisany algorytm zastosowano do grupowania danych reprezentujących przebiegi czasowe temperatur powierzchni zarejestrowane w badaniach eksperymentalnych.

**1.2. Zastosowanie metod grupowania do wykrywania defektów materiałowych**

Celem badań prezentowanych w niniejszej pracy było określenie przydatności algorytmu  $k$ -średnich do grupowania danych pochodzących z pomiarów termowizyjnych. Z kolei grupowanie miało za zadanie rozróżnienie między pikselami pola widzenia termogramu reprezentującymi obszary defektu i pikselami

reprezentującymi obszar tła (obszar pozbawiony defektu). Do ilościowego oszacowania dokładności wykrywania defektu zastosowano następujące kryteria:

- 1. Błąd w obszarze defektu:

$$\delta_d = \frac{N_d}{N_{wd}} \cdot 100 \quad [\%], \quad (6)$$

gdzie:  $N_d$  – liczba pikseli w grupie przypisanej obszarowi defektu, tj. pikseli, które przez algorytm  $k$ -średnich zostały wskazane jako piksele reprezentujące obszar powierzchni nad defektem,  $N_{wd}$  – całkowita liczba pikseli w obszarze defektu.

- 2. Błąd w obszarze tła:

$$\delta_s = \frac{N_s}{N_{us}} \cdot 100 \quad [\%], \quad (7)$$

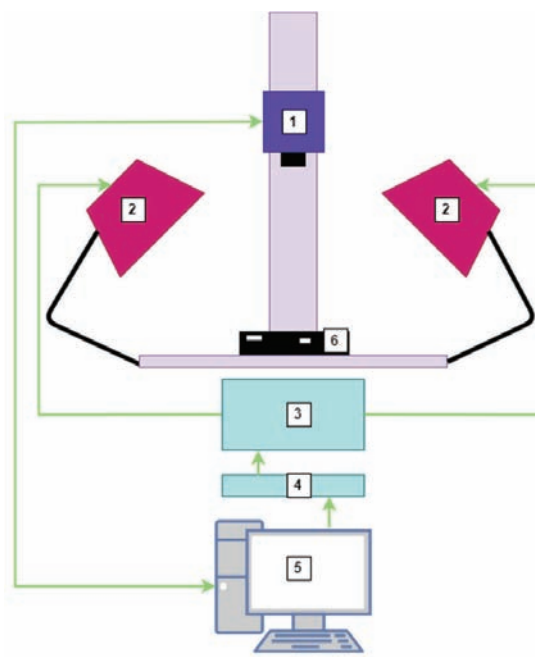
gdzie:  $N_s$  – liczba pikseli w grupie przypisanej obszarowi tła, tj. pikseli, które przez algorytm  $k$ -średnich zostały wskazane jako piksele reprezentujące obszar powierzchni, pod którym nie występują defekty,  $N_{us}$  – całkowita liczba pikseli w obszarze tła.

Wartości  $N_{wd}$  i  $N_{us}$  we wzorach (6), (7) zostały wyznaczone na podstawie mapy defektów stworzonej w oparciu o pomiary rzeczywistych wymiarów i położenia defektów wytworzonych w badanej próbce, której schemat zaprezentowano na rys. 2.

**2. Badania eksperymentalne**

**2.1. Metodyka badań**

Badania eksperymentalne przeprowadzono na stanowisku do wykrywania defektów metodami termografii aktywnej. Schemat stanowiska zaprezentowano na rys. 1.



Rys. 1. Schemat stanowiska do wykrywania defektów metodami termografii aktywnej


Fig. 1. Diagram of the defect detection station by active thermography methods

W skład stanowiska wchodzi następujące elementy: 1 – przemysłowa kamera termowizyjna IRS336-NDT o rozdzielczości geometrycznej 240 px × 320 px z niechłodzonym detektorem bolometrycznym o rozdzielczości termicznej NETD < 30 mK,

2 – lampa halogenowa o mocy 1 kW, 3 – moduł sterowania źródłami wymuszeń cieplnych, 4 – moduł sprzętowy AT IRXBOX odpowiedzialny za sprzętowe wyzwalanie rejestracji termogramów oraz sterowanie źródłami wymuszenia cieplnego (moduł jest z kolei sterowany za pośrednictwem karty cyfrowej akwizycji danych DAC) i źródła wymuszenia cieplnego wraz z kartą cyfrowej akwizycji danych, 5 – komputer stacjonarny wyposażony w oprogramowanie IRNDT do rejestracji sekwencji termogramów oraz sterowania źródłem wymuszenia cieplnego, 6 – próbka badanego materiału.


Jak wspomniano wcześniej opisywaną metodę przetestowano dla próbki wykonanej z kompozytu CFRP. Kompozyt ten z uwagi na swoje właściwości (wysoka sztywność, wysoka odporność chemiczna i cieplna itp.) znajduje zastosowanie w wielu gałęziach przemysłu, w tym w przemyśle samochodowym, budownictwie, sprzęcie sportowym a także w przemyśle lotniczym. Z tego powodu, bardzo ważne staje się opracowanie i rozwijanie metod wykrywania defektów w kompozytach CFRP. Należy podkreślić, że kompozyty CFRP wykazują anizotropię z punktu widzenia właściwości cieplnych (różne wartości dyfuzyjności cieplnej zależnie od kierunku), dlatego też wykrywanie defektów metodami termografii aktywnej jest trudniejsze niż w innych materiałach. W niniejszej pracy badaniom poddano próbkę w kształcie prostokąta o grubości 5 mm, wykonaną z opisanego kompozytu. W próbce wykonano sztuczne defekty w kształcie nieprzelotowych, płaskodennych otworów kwadratowych. Wymiary próbki i rozmieszczenie defektów przedstawiono na rys. 2.

Defekty zlokalizowano na głębokościach  $z_1 = 3,6$  mm,  $z_2 = 2,6$  mm,  $z_3 = 1,9$  mm i  $z_4 = 1,2$  mm względem wierzchniej (nagrzewanej) strony próbki.




Rys. 2. Wymiary próbki i schemat rozmieszczenia defektów

Fig. 2. Dimensions of defects and material sample



Rys. 3. Termogram powierzchni próbki w chwili  $\tau = 0$  s względem początku fazy stygnięcia

Fig. 3. Thermogram of the sample surface at  $\tau = 0$  s from the beginning of the cooling phase



Rys. 4. Termogram powierzchni próbki w chwili  $\tau = 20$  s względem początku fazy stygnięcia

Fig. 4. Thermogram of the sample surface at  $\tau = 20$  s from the beginning of the cooling phase

W trakcie eksperymentu próbka była nagrzewana za pomocą lamp halogenowych przez 120 s. Po tym czasie działanie wymuszenia zostało zatrzymane i w ciągu następnym 120 s fazy stygnięcia prowadzona była rejestracja niestabilnego pola temperatury na powierzchni próbki z częstotliwością próbkowania 5 Hz. W wyniku rejestracji uzyskano sekwencję termogramów powierzchni. Wyniki eksperymentu zaprezentowano w dalszej części pracy.

## 2.2. Wyniki

Wyniki badań eksperymentalnych zaprezentowano na rys. 3, 4. Na rys. 3. przedstawiono termogram sekwencji obrazujący pole temperatury badanej próbki zarejestrowane w chwili  $\tau = 0$  s względem początku fazy stygnięcia. Termogram sekwencji obrazujący pole temperatury zarejestrowane w chwili  $\tau = 20$  s względem początku fazy stygnięcia zaprezentowano na rys. 4.

## 3. Symulacje

### 3.1. Metodyka badań

W wyniku badań eksperymentalnych przeprowadzonych na stanowisku przedstawionym na rys. 1 uzyskano sekwencję termogramów powierzchni badanej próbki. W dalszym ciągu przeprowadzono przetwarzanie sekwencji w następujących krokach:

1. Zwiększenie kontrastu każdego z termogramów sekwencji z wykorzystaniem przekształcenia morfologicznego obrazu TOP-HAT [15, 16]. Do przetwarzania termogramów zastosowano element strukturalny typu DIAMOND wielkości  $r = 48$  px.
2. Zastosowanie algorytmu  $k$ -średnich do grupowania danych reprezentujących przebiegi czasowe temperatury zarejestrowane dla każdego z pikseli pola widzenia termogramu powierzchni badanej próbki kompozytu. W trakcie grupowania zastosowano dwie metryki odległości:

$$L_e(\mathbf{x}, \mu(C_i)) = (\mathbf{x} - \mu(C_i))(\mathbf{x} - \mu(C_i))^T, \quad (8)$$

$$L_M(\mathbf{x}, \mu(C_i)) = \sum_{j=1}^d |\mathbf{x} - \mu(C_i)|, \quad (9)$$

gdzie:  $L_e(\mathbf{x}, \mu(C_i))$  – kwadratowa odległość euklidesowa,  $L_M(\mathbf{x}, \mu(C_i))$  – odległość typu Manhattan (odległość miejska).

Dodatkowo, w badaniach przyjęto dwa warianty danych wejściowych:

- I przebiegi temperatury na powierzchni badanej próbki dla każdego pikseli w polu widzenia termogramu, rejestrowane od początku fazy stygnięcia przez kolejne 120 s,
  - II przebiegi temperatury na powierzchni badanej próbki dla każdego pikseli w polu widzenia termogramu, rejestrowane od chwili  $\tau = 20$  s względem zakończenia fazy nagrzewania przez kolejne 100 s fazy stygnięcia.
3. Wyznaczenie błędów wykrywania defektów, opisanych zależnościami (6), (7).
  4. Analiza wyników badań i sformułowanie wniosków.

### 3.2. Wyniki

Przykładowe wyniki działania opisanego wyżej algorytmu grupowania zaprezentowano na rys. 5–8. Na rys. 5 i 6 przedstawiono mapy defektów wygenerowane przez algorytm  $k$ -średnich z zastosowaniem pierwszego wariantu danych wejściowych


dla kwadratowej odległości euklidesowej oraz odległości typu Manhattan, wyrażonych odpowiednio zależnościami (8) i (9). Z kolei mapy defektów wygenerowane dla drugiego wariantu danych wejściowych zaprezentowano na rys. 7 i 8.

Ważnym etapem badań było oszacowanie dokładności wykrywania defektów w odniesieniu do liczby wykrytych pikseli. Z tego powodu w pracy, dla każdego wariantu danych wejściowych i obu metryk odległości wyznaczono błędy opisane zależnościami (6) i (7). Wartości błędów zebrano w tabeli 1.


Tabela 1. Wartości błędów wyrażonych zależnościami (6) i (7)

Table 1. The values of errors described by (6) and (7)


Wariant danych wejściowych	Metryka odległości	$\delta_d$ [%]	$\delta_s$ [%]
I	$L_\epsilon$	45,6	3,0
	$L_M$	7,0	13,0
II	$L_\epsilon$	7,8	9,6
	$L_M$	1,5	39,0




Rys. 5. Wynik grupowania algorytmem k-średnich dla pierwszego wariantu danych wejściowych i odległości  $L_\epsilon$   
 Fig. 5. The result of clustering using the k-means algorithm for the first input data case and  $L_\epsilon$  distance metrics



Rys. 6. Wynik grupowania algorytmem k-średnich dla pierwszego wariantu danych wejściowych i odległości  $L_M$   
 Fig. 6. The result of clustering using the k-means algorithm for the first input data case and  $L_M$  distance metrics



Rys. 7. Wynik grupowania algorytmem k-średnich dla drugiego wariantu danych wejściowych i odległości  $L_\epsilon$   
 Fig. 7. The result of clustering using the k-means algorithm for the second input data case and  $L_\epsilon$  distance metrics



Rys. 8. Wynik grupowania algorytmem k-średnich dla drugiego wariantu danych wejściowych i odległości  $L_M$   
 Fig. 8. The result of clustering using the k-means algorithm for the second input data case and  $L_M$  distance metrics

### 3. Wnioski końcowe

W pracy przedstawiono badania algorytmu k-średnich do wykrywania defektów w kompozycie CFRP z użyciem termografii aktywnej. Na podstawie wyników sformułowano następujące wnioski:

- Wstępne przetwarzanie sekwencji termogramów z użyciem przekształceń morfologicznych znacznie zwiększa kontrast cieplny, a co za tym idzie efektywność grupowania algorytmem k-średnich.
- Zastosowanie algorytmu k-średnich przetwarzającego przebiegi czasowe temperatury zarejestrowane dla poszczególnych pikseli pola widzenia termogramu powierzchni próbki pozwala na automatyczne rozróżnienie między obszarami defektów i obszarami pozbawionymi defektów (obszarami tła).
- W trakcie badań zaobserwowano dużą wrażliwość algorytmu k-średnich na zastosowaną metrykę odległości.
- Dodatkowo, stwierdzono, że efektywność wykrywania defektu w dużym stopniu zależy od wariantu danych wejściowych, tj. od tego, jaka faza procesu cieplnego zostanie poddana grupowaniu.
- Najlepsze wyniki w sensie występujących jednocześnie najmniejszych błędów zdefiniowanych zależnościami (8) i (9) w obszarze defektu i obszarze tła uzyskano dla kwadratu odległości euklidesowej  $L_\epsilon$  i drugiego wariantu danych wejściowych (przebiegi temperatury na powierzchni badanej próbki dla każdego piksela w polu widzenia termogramu,

zarejestrowane od chwili  $\tau = 20$  s względem zakończenia fazy nagrzewania przez kolejne 100 s fazy stygnięcia) – tabela 1.

Analizując otrzymane wyniki badań należy stwierdzić, że uzyskane wartości błędów, zarówno w obszarze defektu, jak i tła zdefiniowane wzorami (8) i (9) nie przekraczają 10% mimo tego, że grupowanie prowadzone było dla materiału anizotropowego. Z tego powodu można uznać, że opisywany algorytm stanowi użyteczne narzędzie przetwarzania danych w zastosowaniu do wykrywania defektów z wykorzystaniem termografii aktywnej.

### Bibliografia

1. Lewińska-Romicka A., *Badania nieniszczące. Podstawy defektoskopii*, WNT, Warszawa 2001.
2. Maldague X.P., *Theory and practice of infrared technology for nondestructive testing*, John Wiley & Sons Interscience, New York 2001.
3. Gleiter A., Spiessberger C., Busse G., *Phase angle thermography for depth resolved characterization*, Proc. 9<sup>th</sup> International Conference on Quantitative Infrared Thermography QiRT, Kraków, July 2–5, 2009, 435–441, DOI: 10.1063/1.3114300.
4. Dudzik S., *A simple method for defect area detection using active thermography*, “Opto-Electronics Review”, Vol. 17, No. 4, 2009, 338–344, DOI: 10.2478/s11772-009-0016-9.
5. Grys S., Minkina W., Vokorokos L., *Automated characterisation of subsurface defects by active IR thermographic testing*

- Discussion of step heating duration and defect depth determination, “Infrared Physics & Technology” Elsevier, Vol. 68, 2015, 84–91, DOI: 10.1016/j.infrared.2014.11.005.
6. Minkina W., Dudzik S., *Infrared Thermography – Errors and Uncertainties*, John Wiley & Sons, Chichester 2009.
  7. Russ J.C., *Image Processing Handbook*, CRC Press LLC 2002.
  8. Dudzik S., *Two-stage neural algorithm for defect detection and characterization uses an active thermography*, “Infrared Physics and Technology”, Vol. 71, 2015, 187–197, DOI: 10.1016/j.infrared.2015.03.003.
  9. Trétout H., David D., Martin J., Dissenter Y., Court M., Avenas-Payan M., *An evaluation of artificial neural networks applied to infrared thermograph inspection of composite aerospace structures*, Review of Progress in Quantitative, Nondestructive Evaluation (14A), 827–834, DOI: 10.1007/978-1-4615-1987-4\_103.
  10. Benítez H.D., Loaiza H., Caicedo E., Ibarra-Castanedo C., Bendada A., Maldague X.P., *Defect characterization in infrared non-destructive testing with learning machines*, “NDT & E International”, Vol. 42, No. 7, 2009, 630–643, DOI: 10.1016/j.ndteint.2009.05.004.
  11. Witten I.H., Eibe F., *Data Mining. Practical Machine Learning Tools and Techniques*, Elsevier 2005.
  12. Everitt B.S., Landau S., Leese M., Stahl D., *Cluster analysis*, John Wiley & Sons 2011.
  13. Jain A.K., Dubes R.C., *Algorithms for clustering data*, Prentice Hall, Englewood Cliffs N.J., 1998.
  14. Guojun G., Ma C., Wu J., *Data Clustering: Theory, Algorithms, and Applications*, ASA-SIAM Series on Statistics and Applied Probability, SIAM, Philadelphia, ASA, Alexandria, VA, 2007.
  15. Malina W., Smiatacz M., *Cyfrowe przetwarzanie obrazów*, Akademicka Oficyna Wydawnicza EXIT, Warszawa 2008.
  16. Dudzik S., *Zastosowanie transformacji TOP-HAT do przetwarzania sekwencji termogramów*, „Zeszyty Naukowe Wydziału Elektrotechniki i Automatyki Politechniki Gdańskiej”, Nr 54, 2017, 35–38, XLIX Międzynarodowa Konferencja Metrologów, Częstochowa/Koszęcin, 4–6 września 2017.

## Detection of Defects Using Active Thermography and k-Means Algorithm

**Abstract:** The paper presents a new method of detecting material defects using active thermography. In order to increase the thermal contrast, preprocessing of the recorded sequence of thermograms was carried out using mathematical morphology methods. The k-means algorithm was used to detect defects. The work examined the impact of distance measure used in the described algorithm and the selection of input data on the effectiveness of the described method. The experiment was carried out for a sample made of carbon fiber reinforced composite (CFRP). Studies have shown that the smallest errors in defect detection using the described method are obtained for the square Euclidean distance.

**Keywords:** k-means algorithm, defect detection, active thermography

### dr hab. inż. Sebastian Dudzik

sebdud@el.pcz.czest.pl  
ORCID: 0000-0002-9559-7115



Dr hab. inż. Sebastian Dudzik specjalizuje się w tematyce termografii w podczerwieni ze szczególnym uwzględnieniem termografii ilościowej oraz badań nieniszczących z wykorzystaniem aktywnej termografii dynamicznej. Jest autorem i współautorem monografii w języku polskim i angielskim oraz rozdziałów w monografiach, a także kilkadziesiąt prac z zakresu dokładności pomiarów w termografii w podczerwieni, zastosowania termografii oraz algorytmów uczenia maszynowego do modelowania i analizy złożonych zjawisk wymiany ciepła. Jest twórcą oprogramowania do analizy wrażliwości modeli pomiarowych stosowanych w nowoczesnych kamerach termowizyjnych oraz oprogramowania do przetwarzania danych radiometrycznych w paśmie podczerwieni. Jest współautorem czterech patentów zarejestrowanych w Urzędzie Patentowym RP.