

Łukasz Tomczak*, Volodymyr Mosorov*, Daniel Kaczorowski*

Nowa metoda detekcji defektów tekstury w automatycznej inspekcji wizyjnej

1. Wprowadzenie

Detekcja defektów w powierzchniach takich materiałów jak: stal [1], płytki ceramiczne [2], materiały tekstylne [3], papier [4], skały [5] jest ważną dziedziną w przemysłowych systemach inspekcji. Detekcja defektów tekstury może być zdefiniowana jako proces służący określeniu położenia pikseli, których cechy takie jak jasność lub układ w teksturze znacznie różnią się w stosunku do pozostałych pikseli tekstury, stanowiących tło [1]. Jest ona szeroko wykorzystywana w wizyjnych systemach inspekcji.

Wiele algorytmów służących do wykrywania uszkodzeń w powierzchniach teksturowych wykorzystuje w tym celu zbiory uczące złożone z próbek obrazów tychże powierzchni. Jednakże wybór i przygotowanie zbiorów uczących jest procesem bardzo czasochłonnym i może stać się źródłem błędów. Ponadto nie jest łatwo przygotować zbiór uczący tak, aby automatyczny system detekcji był w stanie poradzić sobie z różnorodnością badanych materiałów. W przeciwieństwie do wielu algorytmów detekcji defektów tekstury opisanych w literaturze, prezentowane podejście, do zaklasyfikowania obszaru powierzchni teksturowej jako defektu, nie wymaga przygotowania zbioru uczącego, składającego się z tekstur określonego materiału, co znacznie upraszcza jej zastosowanie w automatycznym systemie detekcji.

2. Opis algorytmu

Początkowo kolorowy obraz analizowanej tekstury materiału jest konwertowany do obrazu monochromatycznego i dzielony na L kwadratowych obszarów o tym samym rozmiarze. Wartość L jest ustalana w sposób empiryczny. Na rysunku 1b przedstawiono przykładową teksturę materiału tekstylnego podzieloną na 289 obszarów.

Następnie przedstawiany algorytm wykorzystuje rozkład macierzy według wartości szczególnych SVD (*Singular Value Decomposition*) [6] i techniki przetwarzania obrazów w celu wyznaczenia cech opisujących każdy z obszarów tekstury. Dekompozycja SVD jest szeroko wykorzystywaną techniką służącą do rozkładu macierzy na kilka komponentów macierzowych zawierających wiele użytecznych cech macierzy oryginalnej.

* Katedra Informatyki Stosowanej, Politechnika Łódzka

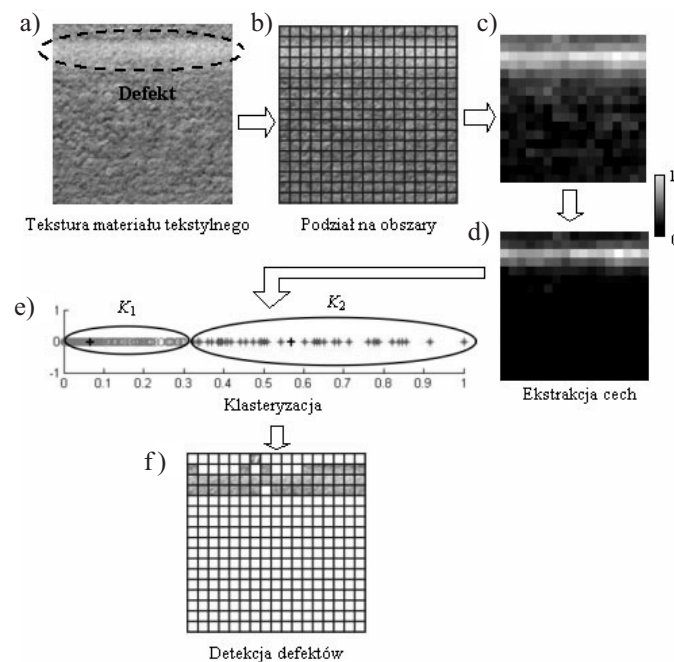
Niech monochromatyczny obraz cyfrowy obszaru p tekstury będzie reprezentowany przez macierz A_p o rozmiarze $n \times n$, gdzie $p = 1, \dots, L$. Dekompozycja SVD jest opisana za pomocą równania

$$A_p = U_p \Lambda_p V_p^T \quad (1)$$

gdzie U_p i V_p są macierzami ortogonalnymi, a Λ_p jest macierzą diagonalną. Macierze U_p , V_p i Λ_p są zdeterminowane przez macierz źródłową A_p . W proponowanej metodzie jedynie macierz Λ_p jest wykorzystana w celu uzyskania cech opisujących każdy z obszarów analizowanej tekstury. Wartości współczynników na diagonalu macierzy Λ_p są ułożone w porządku rosnącym

$$\sigma_p^1 \geq \sigma_p^2 \geq \dots \geq \sigma_p^n \geq 0 \quad (2)$$

W celu uzyskania cechy opisującej pojedynczy obszar tekstury o numerze p wykorzystano jedynie współczynnik σ_p^1 . Podczas badań zauważono w sposób empiryczny, że jest on najbardziej efektywny, jeśli chodzi o wykrywanie strukturalnych różnic w obrazie, takich jak defekty tekstury. Przykładowe współczynniki σ_p^1 obliczone dla obszarów tekstury materiału tekstylnego zaprezentowano na rysunku 1c. Zostały one uprzednio przeskalowane do przedziału $[0, \dots, 1]$ i przedstawione w odcieniach skali szarości.



Rys. 1. Algorytm detekcji defektów tekstury
Opis w tekście

W celu uwydatnienia współczynników σ_p^1 o wysokich wartościach, które odpowiadają defektom tekstury i zmniejszenia współczynników σ_p^1 o niskich wartościach, reprezentujących obszary tekstury pozbawione defektów, wykorzystano podstawowe techniki przetwarzania obrazów, jakimi są operacje punktowe [7]. Każdy piksel obrazu jest w nich zastępowany nowym pikselem, którego wartość uzyskano na podstawie wartości piksela źródłowego. W większości przypadków w tym celu wykorzystuje się funkcję jednoargumentową zgodnie, z którą następuje przetwarzanie poszczególnych pikseli obrazu.

W przedstawionym algorytmie wykorzystano funkcję kwadratową (równanie (3)), ponieważ uwydatnia ona piksele o wysokich poziomach jasności (w prezentowanej metodzie współczynniki σ_p^1 oznaczające defekt), jednocześnie zmniejszając wartość jasności ciemnych pikseli

$$S_p = (\sigma_p^1)^2 \quad (3)$$

Uzyskane wartości S_p są wykorzystywane jako cechy opisujące obszary tekstury. Przykładowe wartości S_p obliczone dla obszarów tekstury materiału tekstylnego zostały przeskalowane do przedziału $[0, \dots, 1]$ i przedstawione w odcieniach skali szarości na rysunku 1d.

Ostatecznie prezentowany algorytm wykorzystuje klasteryzację metodą rozmytych c-środków FCM (*fuzzy c-means*) [8] w celu zaklasyfikowania każdego obszaru do jednej z dwóch klas:

- 1) klasy defektu,
- 2) klasy pozbawionej defektu.

Metoda ta ze względu na stosunkowo prostą implementację i dobre wyniki jest jedną z częściej wykorzystywanych metod klasteryzacji rozmytej. Klasteryzacja taka przyporządkowuje każdej próbce stopień przynależności do każdego z c klastrów. Łączny stopień przynależności każdej próbki do wszystkich klastrów jest równy 1. W proponowanej metodzie przyjęto, że dane zawierają dwa klastry K_1 i K_2 ($c = 2$). Klaster K_1 reprezentuje obszary tekstury pozbawione defektu, klaster K_2 natomiast obszary w których ten defekt występuje. Za klaster reprezentujący uszkodzenie uznano klaster mniej liczny. Próbką jest przyporządkowana do klastra, jeżeli jej stopień przynależności do niego jest największy. Na rysunku 1e przedstawiono dwa klastry uzyskane za pomocą klasteryzacji próbek odpowiadających obszarom, na które została podzielona tekstura materiału tekstylnego przedstawiona na rysunku 1a.

Po procesie klasteryzacji następuje podjęcie decyzji, czy analizowaną teksturę uznać za zawierającą defekty czy też nie. W tym celu wykorzystano następującą regułę decyzyjną

$$\frac{|c_1 - c_2|}{\delta} > r \quad (4)$$

gdzie:

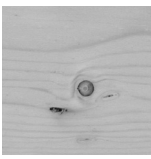

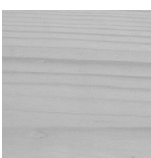
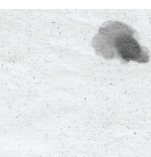
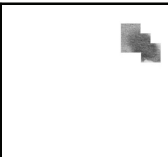
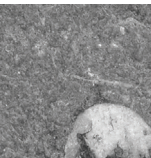



- c_1 i c_2 – współrzędne środków klastrów K_1 i K_2 ,
- δ – średnica całego zbioru wartości S_p ,
- r – wartość progowa.

Gdy równanie (4) jest spełnione, tekstura zostaje uznana za zawierającą defekty. Wartość współczynnika określono empirycznie na 0,5. Przy takiej wartości przedstawiany algorytm najbardziej efektywnie rozróżniał tekstury zawierające defekty i tekstury ich pozbawione. Na rysunku 1f przedstawiono przykłady defektów wykrytych w teksturze materiału tekstylnego.

3. Wyniki eksperymentu

W celu przetestowania prezentowanego podejścia i porównania go z innymi metodami wykorzystano przykładowe tekstury naturalne, pochodzące z darmowej bazy obrazów Image After, która znajduje się na stronie internetowej www.imageafter.com.

Tablica 1
Przykładowe tekstury naturalne oraz wykryte defekty

Material	Tekstura	Defekty
drewno		
drewno		brak defektu
papier		
skała		
metal		

Proponowana metoda została zaimplementowana w środowisku Matlab 7.0 i wykorzystana do detekcji defektów w takich teksturach materiałów, jak: drewno, papier, skała, metal oraz materiał tekstylny. Użyto kolorowych obrazów o rozdzielczości 400×400 pikseli. W tabelicy 1 przedstawiono wyniki detekcji defektów dla pięciu tekstur. Liczbę obszarów, na jakie zostały podzielone analizowane tekstury, ustalono empirycznie na 289.

Rozmiar defektu możliwego do wykrycia jest zależny od przyjętego rozmiaru obszarów, na jakie została podzielona analizowana tekstura, czyli od ich liczby. Jeżeli przyjęty rozmiar obszarów jest większy od defektu, defekt może nie zostać wykryty. Sytuacja taka występuje dla tekstury i drewna metalu, gdzie defekty o rozmiarach dużo mniejszych od rozmiaru obszarów, nie zostały wykryte. Należy jednak pamiętać, że zmniejszanie rozmiaru obszarów powoduje wydłużenie czasu potrzebnego na dokonanie analizy tekstury, który musi być jak najkrótszy w automatycznych systemach, przeprowadzających inspekcję w czasie rzeczywistym.

4. Wnioski

W niniejszym artykule zaproponowano nową metodę detekcji defektów tekstury, która może znaleźć zastosowanie w automatycznych systemach dokonujących wizyjnej inspekcji jakości materiałów takich, jak: drewno, papier, materiał tekstylny, metal czy skały.

Przedstawione podejście w celu wykrycia defektu występującego w teksturze i określenia jego położenia wykorzystuje dekompozycję SVD, techniki przetwarzania obrazów oraz klasteryzację za pomocą metody rozmytych c-środków.

W przeciwieństwie do wielu innych metod detekcji defektów tekstury nie wymaga przygotowania zbioru uczącego, co znacznie ułatwia jej praktyczne zastosowanie w automatycznym systemie inspekcji.

Literatura

- [1] Wiltschi K., Pinz A., Lindeberg T.: *An automatic assessment scheme for steel quality inspection*. Machine Vision and Applications, 2000, 113–128
- [2] Elbehery H., Hefnawy A., Elewa M.: *Visual Inspection for Fired Ceramic Tile's Surface Defects using Wavelet Analysis*. 1st International Computer Engineering Conference New Technologies for the Information Society, Egypt, 2004
- [3] Stojanovic R., Mitropulos P., Koulamas C.: *Real-time vision-based system for textile fabric inspection*. Real-Time Imaging, 2001, 507–518
- [4] Maaenpaa T., Turtinen M., Pietikainen M.: *Real-Time Surface Inspection by texture*. Real-Time Imaging, 2003, 289–296
- [5] Partio M., Cramariuc B., Gabbouj: *Rock Texture Retrieval Using Gray Level Co-occurrence Matrix*. 5th Nordic Signal Processing Symposium, Norway, 2002
- [6] Emmett J. Ientilucci: *Using the Singular Value Decomposition*. Chester F. Carlson Center for Imaging Science, Rochester Institute of Technology, 2003
- [7] Jahne B.: *Digital image processing*. Springer, Berlin, 2002
- [8] Höppner F., Klawonn F., Kruse R.: *Fuzzy Cluster Analysis*. Amazon, Wiley, 1999

