

## Rozpoznawanie obiektów morskich na podstawie obrazów FLIR metodą analizy obrazów własnych (eigenimages)

**Streszczenie.** W referacie przedstawiono metodę rozpoznawania obiektów morskich na podstawie ich obrazów wykonanych przez sensory podczerwieni (FLIR – forward looking infra-red) z wykorzystaniem metody analizy obrazów własnych (eigenimages). Metoda ta oparta jest na metodzie analizy głównych składowych (PCA – Principal Component Analysis). W końcowym fragmencie pracy przedstawiono wstępne wyniki badania metody klasyfikacji obiektów morskich dla pewnego zbioru obrazów FLIR obiektów zarejestrowanych na Morzu Bałtyckim.

**Abstract.** This paper presents a method of recognition of maritime objects based on FLIR (forward looking infra-red) sensor images using eigenimages analysis method. The method is an extension of Principal Component Analysis (PCA) method. In last part of the paper are presented preliminary test results of the classification method for a set of FLIR images registered in the Baltic Sea. (Recognition of maritime objects based on FLIR images using eigenimages analysis method. A method of recognition of maritime objects based on FLIR (forward looking infra-red) sensor images

**Słowa kluczowe:** rozpoznawanie obrazów FLIR, segmentacja, metoda analizy głównych składowych PCA, metoda obrazów własnych.

**Keywords:** FLIR images recognition, segmentation, principal component analysis method, eigenimages method.

### Wprowadzenie

Zadanie rozpoznawania obiektów morskich na podstawie obrazów FLIR sprowadza się do odpowiedzi na pytanie, czy obiekt zawarty w obrazie jest rzeczywiście obiektem morskim (w szczególności możemy zawęzić zbiór interesujących nas obiektów do pewnego podzbioru), a w przypadku uzyskania odpowiedzi pozytywnej oczekujemy odpowiedzi na kolejne pytanie, czy rozpoznawany obiekt należy do którejś z klas obiektów wcześniej sklasyfikowanych, a jeśli tak, to do której. Proces rozpoznawania jest procesem wieloetapowym, a wyniki rozpoznania noszą cechy przypadkowości. Niemniej jednak obrazy tego samego obiektu wykonywane w różnych warunkach mają cechy wspólne, które zwane są cechami dystyngtywnymi. Ich wartości decydują o odpowiedziach na wcześniej sformułowane pytania. W niniejszej pracy wykorzystano przestrzeń obrazów własnych (eigenimages), najczęściej kojarzoną z przestrzenią cech charakterystycznych obrazów twarzy (eigenfaces), wykorzystywaną w rozpoznawaniu twarzy [1,3,5,6,7,8].

Ze względu na to, że przedmiotem pracy jest rozpoznawanie obiektów morskich na podstawie obrazów FLIR, do zbioru cech charakterystycznych zaliczamy przede wszystkim sylwetkę obiektu oraz rozkład jasności poszczególnych punktów obrazu (jasność ma tutaj interpretację temperatury punktu). W pracy zbiór cech charakterystycznych jest nazywany sylwetką własną (eigen silhouette).

Metoda PCA [4] wymaga, aby obrazy obiektów miały taki sam rozmiar (np.  $M \times N$ ,  $N$  kolumn i  $M$  wierszy). Każdy obraz traktujemy jako wektor kolumnowy o wymiarach  $MN \times 1$ , który powstaje jako sekwencja kolumn oryginalnego obrazu. Wartość jasności każdego piksela jest cechą każdego obrazu. Należy więc dążyć do eliminacji cech nieistotnych lub słabo istotnych.

Metoda PCA pozwala na uszeregowanie cech obrazów (wartości jasności pikseli) w ciąg nierosnący od pikseli o największej rozróżnialności (największej wariancji) cechy jasności w zbiorze obrazów wzorcowych) począwszy do pikseli o najmniejszej rozróżnialności (najmniejszej wariancji) cechy jasności w zbiorze obrazów wzorcowych). W naturalny sposób można z obrazu wyeliminować piksele, dla których wariancja jasności w zbiorze obrazów wzorcowych wynosi zero lub jest mała. Metoda PCA bazuje na liniowym przekształceniu Loeva-Karhunen przestrzeni  $M \times N$  wymiarowej w przestrzeń  $K$  wymiarową ( $K < M \times N$ ).

PCA przekształca zbiór obrazów wzorcowych w zbiór sylwetek własnych.

Ważną cechą metody PCA jest możliwość określenia dowolnego oryginalnego obrazu za pomocą kombinacji liniowej sylwetek własnych. W procesie rozpoznawania obrazów w pierwszej kolejności wyznaczany jest wektor wag dla rozpoznawanego obrazu. Wektor wag określa położenie obiektu w  $K$ -wymiarowej przestrzeni sylwetek własnych. Stosując wybraną miarę odległości w przestrzeni sylwetek własnych możemy określić, który z obiektów wzorcowych położony jest najbliżej w stosunku do analizowanego obiektu.

Należy zauważyć, że zaprezentowana procedura może być zastosowana do sytuacji, gdy obrazy zebrane w bazie wzorców są pogrupowane w klastry reprezentujące typy obiektów, a zadanie rozpoznania polega na rozpoznaniu typu obiektu. Jako punkty odniesienia w przestrzeni sylwetek własnych reprezentujących klastry przyjmuje się punkty średnie w klastrze [2].

### Określenie sylwetek własnych obiektów morskich na podstawie obrazów FLIR

Niech obraz sylwetki obiektu morskiego  $I(x,y)$  będzie dwuwymiarową tablicą  $M \times N$  zawierającą liczby całkowite 8-bitowe określające wartość jasności każdego piksela (obraz achromatyczny). Tablicę tę przekształca się najczęściej w wektor o wymiarze  $M \times N$  [1,6,7], stąd dla rozmiaru obrazu  $256 \times 512$  otrzymamy wektor o długości 131.072 lub ekwiwalentnie punkt w przestrzeni 131.072 wymiarowej. Zbiór obrazów obiektów morskich, które będziemy traktować jako obrazy wzorcowe stanowić będzie zbiór punktów tej przestrzeni. Punkty te nie są rozłożone w przestrzeni przypadkowo, ponieważ posiadają pewne podobieństwo, stąd mogą być opisane w przestrzeni o mniejszej liczbie wymiarów. Główną ideą metody PCA lub przekształcenia Loeve-Karhunen jest znalezienie takiego zbioru wektorów ortonormalnych, które najlepiej opisują taką podprzestrzeń.

W pierwszej kolejności metoda PCA zapewnia możliwość zbudowania nowej przestrzeni, w której dowolny rozpoznawany obraz sylwetki będzie liniową kombinacją wektorów określanych jako sylwetki własne bazy sylwetek wzorcowych. Wektory te są wektorami własnymi macierzy kowariancji macierzy zbudowanej z kolumn – obrazów bazy obrazów wzorcowych. Poniżej przedstawiono sposób wyznaczania sylwetek własnych obrazów zawartych w

zbiorze treningowym zwanym w pracy bazą obrazów wzorcowych.

Niech  $\Gamma$  będzie zbiorem obrazów wzorcowych  $\Gamma_1, \Gamma_2, \dots, \Gamma_M$ . Każdy obraz jest wektorem o długości  $M \times N$ , stąd

$$(1) \quad \Gamma = \{\Gamma_i \in \mathbb{R}^{M \times N}, i = 1, \dots, M\}$$

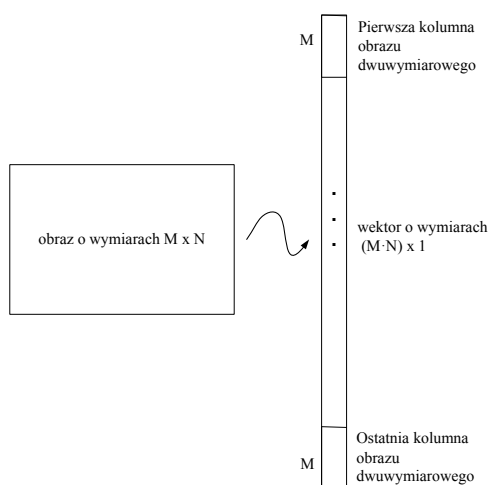
W [6,7] sformułowano wymagania dotyczące obrazów w bazie wzorców – obrazy powinny być takich samych rozmiarów, a środek sylwetki powinien być w środku obrazu.

Sposób budowy wektorów  $\Gamma_i$  został przedstawiony na rysunku 1. Wektor średni  $\Psi$  wyznaczany jest zgodnie ze wzorem

$$(2) \quad \Psi = \frac{1}{M} \sum_{i=1}^M \Gamma_i$$

Każdy obraz  $\Gamma_i$  różni się od obrazu średniego o wektor

$$(3) \quad \Phi_i = \Gamma_i - \Psi$$



Rys. 1. Ilustracja zamiany obrazu dwuwymiarowego na wektor [1,8]

Zbiór tych wektorów jest przedmiotem analizy głównych składowych PCA. Wyznaczane są wektory własne  $u_i$  i wartości własne  $\lambda_i$  macierzy kowariancji

$$(4) \quad C = \frac{1}{M} \sum_{i=1}^M \Phi_i \Phi_i^T = AA^T$$

gdzie macierz  $A = [\Phi_1 \Phi_2 \dots \Phi_M]$ .

Wektory własne  $u_k$  są wyznaczane w taki sposób, aby maksymalizować wyrażenie

$$(5) \quad \lambda_k = \frac{1}{M} \sum_{i=1}^M (u_k^T \Phi_i)^2$$

przy ograniczeniach

$$(6) \quad u_i^T u_j = \begin{cases} 1, & \text{dla } i = j \\ 0, & \text{w przypadku przeciwnym} \end{cases}$$

Wektory własne oraz wartości własne spełniają następujące równania

$$(7) \quad Cu_i = \lambda_i u_i \quad \text{oraz} \quad AA^T u_i = \lambda_i u_i$$

Macierz kowariancji  $C$  ma wymiar  $(M \times N) \times (M \times N)$  i jest symetryczną macierzą liczb rzeczywistych i określa  $M \times N$  wektorów własnych i wartości własnych. Ze względu na rozmiary macierzy  $C$  w praktycznych zagadnieniach problem obliczeniowy staje się bardzo złożony, więc należy znaleźć inną metodę wyznaczania wektorów własnych.

Należy zauważyć, że w bazie wzorców posiadamy  $M$  wzorców (wektorów), stąd interesować nas będzie jedynie  $M$  istotnych wektorów własnych. Zamiast posługiwać się macierzą kowariancji  $A^T A$  rozważmy macierz  $AA^T$  i jej wektory własne  $v_i$  ( $i=1, \dots, M$ ) [1,6,7]. Z definicji możemy napisać

$$(8) \quad A^T A v_i = \mu_i v_i \quad (i=1, \dots, M)$$

Mnożąc obie strony przez macierz  $A$  otrzymujemy

$$(9) \quad AA^T A v_i = \mu_i A v_i \quad (i=1, \dots, M)$$

Porównując (6) i (8) możemy napisać, że

$$(10) \quad \lambda_i = \mu_i$$

$$(11) \quad u_i = A v_i$$

Z (11) wynika, że

$$(12) \quad u_i^j = \sum_{k=1}^M \Phi_k^j v_i^k$$

Stąd można napisać

$$(13) \quad u_i = \sum_{k=1}^M \Phi_k v_i^k$$

co oznacza, że wektor  $u_i$  jest liniową kombinacją wektorów  $\Phi_k$ , stanowiących bazę obrazów wzorcowych.

Wektory  $u_i, i=1, \dots, M$ , są wektorami ortogonalnymi, stąd należy je znormalizować, aby stały się wersorami osi w nowym układzie współrzędnych:

$$(14) \quad u_i := \frac{u_i}{\|u_i\|}$$

W przypadku gdy liczność bazy obrazów jest duża, w procesie rozpoznawania możemy wykorzystać część wektorów własnych odpowiadających największym wartościom własnym. W dalszej części pracy zakładamy, że spośród  $M$  wektorów zostanie wykorzystanych  $M' < M$  wektorów własnych.

Każdą znormalizowaną sylwetkę z bazy wzorców (zbioru treningowego) możemy przedstawić jako liniową kombinację  $M'$  sylwetek własnych w przestrzeni  $M'$ -wymiarowej:

$$(15) \quad \Phi_i = \Gamma_i - \Psi = \sum_{j=1}^{M'} \omega_j^i u_j$$


Stąd możemy napisać w postaci iloczynu skalarnego

$$(16) \quad \omega_j^i = u_j^T \Phi_i$$

Oznacza to, że współrzędna sylwetki z bazy wzorców jest jej rzutem na oś współrzędnych nowego układu, czyli jest wartością iloczynu skalarnego sylwetki znormalizowanej (tzn. że odpowiadający jej wektor jest przesunięty do początku nowego układu współrzędnych) przez wersor osi nowego układu (rys. 2). Każda

znormalizowana sylwetka z bazy wzorców jest reprezentowana przez wektor:

$$(17) \quad \Omega_i^T = [\omega_1^i, \omega_2^i, \dots, \omega_{M'}^i], \quad i = 1, 2, \dots, M$$



Rys. 2. Ilustracja sposobu wyznaczania sylwetki wzorcowej w nowym przesuniętym, obróconym i zredukowanym układzie współrzędnych

### Wykorzystanie własnych sylwetek obiektów morskich w procesie klasyfikacji ich obrazów

Proces rozpoznawania nowego obrazu (obraz powinien mieć ten sam rozmiar oraz mieć środek sylwetki w środku obrazu) jest realizowany w trzech etapach:

1. Wyznaczenie nowego obrazu znormalizowanego  $\Phi_n$  rozpoznawanego obiektu według (3).
2. Projektacja obrazu znormalizowanego  $\Phi_n$  na przestrzeń własną bazy wzorców sylwetek – wyznaczenie składowych wektora  $\hat{\Phi}_n$  w nowym układzie współrzędnych według (15), przy czym składowe wektora wag  $\omega_j^n$  określone są za pomocą iloczynów skalarnych (16), co prowadzi ostatecznie do otrzymania wektora wartości cech rozpoznawanego obiektu

$$(18) \quad \Omega_n^T = [\omega_1^n, \omega_2^n, \dots, \omega_{M'}^n]$$

3. Wyznaczenie odległości  $e_d = \|\Phi_n - \hat{\Phi}_n\|$  wektora sylwetki od własnej przestrzeni bazy wzorców.
4. Jeżeli  $e_d > \varepsilon_d$ , to stwierdzamy, że sylwetka zawarta w rozpoznawanym obrazie nie jest sylwetką obiektu morskiego i kończymy rozpoznawanie.
5. Jeżeli  $e_d \leq \varepsilon_d$ , to znajdujemy  $e_r = \min_{i=1, \dots, M} \|\Omega_n - \Omega^i\|$ .
6. Jeżeli  $e_r > \varepsilon_r$ , to stwierdzamy, że sylwetka zawarta w rozpoznawanym obrazie nie jest sylwetką obiektu morskiego zawartą w bazie wzorców i kończymy rozpoznawanie.
7. Jeżeli  $e_r \leq \varepsilon_r$ , to znajdujemy


$$i^* = \arg \min_{i=1, \dots, M} \|\Omega_n - \Omega^i\| \text{ i stwierdzamy, że obraz } \Gamma_n$$

został rozpoznany jako obraz o numerze  $i^*$  w bazie wzorców.

Problem rozpoznawania sylwetki zawartej w obrazie został zilustrowany na rysunku 3. Sylwetka  $\Phi_1$  została rozpoznana jako obraz numer 2 w bazie wzorców. Sylwetka  $\Phi_2$  nie reprezentuje żadnego obiektu morskiego. Sylwetka  $\Phi_3$  reprezentuje obiekt morski, natomiast brak jest odpowiedniego wzorca w bazie wzorców.

Jako odległość w przestrzeni własnej bazy wzorców można przyjąć odległość euklidesową, natomiast w [6] stwierdzono, iż należy rozważyć zastosowanie odległości Mahalonobisa

$$(19) \quad \|\Omega_n - \Omega^i\| = \sum_{j=1}^{M'} \frac{1}{\lambda_j} (\omega_j^n - \omega_j^i)^2$$



Rys. 3. Ilustracja procesu rozpoznawania sylwetek obiektów

### Wstępne wyniki badania metody rozpoznawania


W niniejszym rozdziale zaprezentowano fragmenty wstępnych wyników badań rozpoznawania obiektów morskich na podstawie obrazów FLIR metodą PCA.

Baza wzorców liczyła 11 obrazów obiektów morskich, których sylwetki otrzymane w wyniku wstępnego przetwarzania, segmentacji i wtórnego przetwarzania zostały przedstawione na rysunku 4



Rys. 4. Baza wzorców treningowych do badania procesu rozpoznawania obiektów morskich

Proces uzyskiwania achromatycznych obrazów sylwetek został zilustrowany na kolejnych rysunkach. Na rysunku 5 przedstawiono wynik realizacji operacji usuwania stałych elementów zobrazowania będących artefaktami kamery FLIR.



Rys. 5. Termogram obiektu morskiego przed (z lewej) i po usunięciu elementów stałych (z prawej)



Rys. 6. Achromatyczny obraz sylwetki obiektu morskiego uzyskany na podstawie obrazu FLIR w procesie segmentacji

Na rys. 6 przedstawiono przykładowy wynik realizacji operacji segmentacji obrazu achromatycznego. Na obrazie zachowano informacje dotyczące temperatury poszczególnych fragmentów okrętu.

Obraz uśredniony  $\Psi$  na podstawie obrazów zawartych w bazie danych wzorców przedstawionej na rysunku 5 przedstawiono na rysunku 7.



Rys. 7. Obraz uśredniony  $\Psi$  w bazie wzorców przedstawionej na rysunku 5


W pierwszym etapie badań rozpoznawano obiekty morskie innych obrazów znanych sylwetek, wykonanych w innych warunkach termalnych otoczenia, z innej odległości i przy minimalnie zmienionym kącie aspektu. Algorytm poprawnie rozpoznawał klasy obiektów.

W drugim etapie rozpoznawano na podstawie ich obrazu przy kącie aspektu rzędu kilkunastu stopni. Poprawność rozpoznawania spadła do 60-80%. Ta sytuacja powinna podlegać dalszym badaniom.

W trzecim etapie rozpoznawano obiekt niebędący obiektem morskim (rys. 8).



Rys. 8. Obiekt nierozpoznany jako obiekt morski.



Rys. 9. Sylwetka obiektu morskiego niebędącego w bazie wzorców i prawidłowo rozpoznanego jako obiekt morski bez określenia jego typu

W ostatnim etapie badań wycofano jeden z obrazów z bazy wzorców a następnie poddano go procedurze rozpoznawania. Czynności te powtórzono dwukrotnie dla różnych wzorców, każdorazowo jednak zwracając poprzedni wzorec.

W pierwszym przypadku prawidłowo rozpoznano obiekt morski bez rozpoznania jego typu (rys. 9). W drugim przypadku obiekt rozpoznano jako obiekt morskich i

określono jego typ, co było błędem, gdyż obiekt nie znajdował się w bazie wzorców.

## Podsumowanie

Przedstawiona praca przedstawia zastosowanie metody analizy głównych składowych PCA do rozpoznawania obiektów morskich na podstawie obrazów FLIR.

Z otrzymanych wyników badań wynika jednoznacznie, że rozpoznawanie obiektów metodą analizy głównych składowych jest możliwe. Aby poprawić skuteczność rozpoznawania należy zwrócić uwagę na kilka istotnych czynników.

Po pierwsze baza treningowa, na podstawie której dokonuje się rozpoznawania obiektów, powinna mieć jak największe rozmiary. Zwiększa to prawdopodobieństwo poprawnego sklasyfikowania obiektu. Nierozpoznanie obiektu powinno być sygnałem do przeprowadzenia analiz zmierzających do rozszerzenia bazy wzorców.

Po drugie bardzo ważną rzeczą jest dobór metody segmentacji. Od niej w dużej mierze zależy, czy sylwetka obiektu zostanie poprawnie rozpoznana. Należy pamiętać, że od poprawnego określenia sylwetki zależy wartość wektorów biorących udział w rozpoznawaniu obiektu.

Na jakość procesu segmentacji mają również wpływ warunki, w jakich zostało zrobione zdjęcie, kąt aspektu, pod jakim dane zdjęcie zostało wykonane, oraz odległość kamery od danego obiektu. Warto zauważyć, że sylwetka obiektu zmienia się wraz z kątem obserwacji obiektu (kątem aspektu, zaś odległość obiektu od kamery wpływa na jakość obrazu.

Kolejnym elementem mającym wpływ na poprawność podejmowanych decyzji o nierozpoznaniu obiektu jako obiektu morskiego lub o rozpoznaniu typu obiektu są wartości graniczne odległości sylwetek własnych w przestrzeni wzorców. Wartości te powinny być dobrane eksperymentalnie.

Reasumując należy stwierdzić, że metoda PCA wraz z jej rozszerzeniem o sylwetki własne może być stosowana do skutecznego rozpoznawania obiektów morskich na podstawie obrazów FLIR, natomiast należy prowadzić dalsze badania mające na celu podniesienie jej skuteczności.

## LITERATURA

- [1] Atalay I., Face Recognition Using Eigenface, Istanbul Technical University, Turkey, 1996. URL [http://www.ilkeratalay.com/download/eigenfaces\\_msc\\_thesis.pdf](http://www.ilkeratalay.com/download/eigenfaces_msc_thesis.pdf) (dostęp 20.10.2014 r.)
- [2] Gouaillieri V., Gagnon L., Ship Silhouette Recognition Using Principal Components Analysis, SPIE Proc. #3164, conference "Applications of Digital Image Processing XX", San Diego, 1997
- [3] Jafri R., Arabina H. R., A Survey of Face Recognition Techniques, Journal of Information Processing Systems, Vol.5, No.2, June 2009
- [4] Smith L. I., A tutorial on principal components analysis, February 2002. URL [http://www.cs.otago.ac.nz/cosc453/student\\_tutorials/principal\\_components.pdf](http://www.cs.otago.ac.nz/cosc453/student_tutorials/principal_components.pdf) (d. 20.10.2014 r.)
- [5] Tat-Jun Chin, Suter D., A Study of the Eigenface Approach for Face Recognition, MECSE-6-2004, Monash University, 2004
- [6] Turk M., Pentland A., Eigenfaces for Recognition, Journal of Cognitive Neuroscience, vol. 3, no. 1, pp. 71-86, 1991. URL <http://www.cs.ucsb.edu/~mturk/Papers/jcn.pdf> (d. 20.10.2014 r.)
- [7] Turk M., Pentland A., Face Recognition Using Eigenface. Proc. IEEE Conference on Computer Vision and Pattern Recognition, pp586-591. IEEE, June 1991. URL <http://www.cs.wisc.edu/~dyer/cs540/handouts/mturk-CVPR91.pdf> (d. 20.10.2014 r.)
- [8] Zhao W., Chellappa R., Phillips P.J., Rosenfeld A., Face Recognition: A Literature Survey, ACM Computing Surveys, Vol. 35, No. 4, December 2003, 399-458

**Autor:** dr inż. Tadeusz Pietkiewicz, Wojskowa Akademia Techniczna, Instytut Radioelektroniki, ul. Gen. S. Kaliskiego 2, 00-908 Warszawa, E-mail: [tpietkiewicz@wat.edu.pl](mailto:tpietkiewicz@wat.edu.pl)