

## Automatyczna generacja cech z wykorzystaniem anizotropowego trójwymiarowego algorytmu SIFT dla potrzeb segmentacji danych pochodzących z Tomografii Komputerowej

**Streszczenie.** W artykule przedstawiono algorytm, w implementacji dla trójwymiarowych danych obrazowych, generacji punktów charakterystycznych oraz wektorów cech. Algorytm wykorzystuje anizotropowe rozszerzenie algorytmu SIFT. Zaproponowana metodologia została wykorzystana do określenia właściwości separacyjnych wektorów dla potrzeb segmentacji danych tomograficznych pacjentów z nowotworem prostaty. Właściwości separacyjne zostały potwierdzone na podstawie klasyfikacji techniką gRBF SVM z wykorzystaniem sprawdzianu krzyżowego.

**Abstract.** In the paper, a 3D version of algorithm generating points and feature vectors is shown. The algorithm is based on anisotropic implementation of SIFT technique. Proposed solution was used to define separation properties of vectors in CT data segmentation context. These properties were confirmed using gRBF SVM and cross-validation. (*Automatic features generation based on 3D anisotropic SIFT for Computed Tomography data segmentation*).

**Słowa kluczowe:** ekstrakcja cech, tomografia komputerowa, SIFT, radioterapia  
**Keywords:** feature extraction, CT, SIFT, radiotherapy

### Wstęp

Wyodrębnianie struktur anatomicznych z obrazowych danych medycznych jest zadaniem niezwykle trudnym. Przykładowo, w przypadku danych pochodzących z tomografii komputerowej (TK), ze względu na podstawy fizyczne metody powstawania obrazu, różne struktury anatomiczne zbudowane z podobnych tkanek, o zbliżonym współczynniku pochłaniania promieniowania X, mają przypisane zbliżone wartości w skali H.U. W przypadku przełyku, jelita cienkiego czy grubego wartości te zmieniają się w zależności od wypełnia. Ze względu na skończoną rozdzielczość przestrzenną danych często występuje problem z jednoznacznym wskazaniem granic pomiędzy organami (np. pęcherz, prostata). Nadmienione właściwości powodują, iż zastosowanie klasycznych algorytmów segmentacji nie przynosi spodziewanych efektów.

Najczęściej wykorzystywaną cechą jako kryterium opisu dla klasycznych algorytmów segmentacji są wartości przypisane do pikseli/wokseli, bądź wartość modułu gradientu [1,2]. Dla obrazów medycznych, w większości przypadków, wartości przypisane do pikseli nie umożliwiają skutecznego wyodrębnienia poszukiwanych struktur anatomicznych, ze względu na zbliżone parametry tkanki na oddziaływanie z promieniowaniem X.

Jednym z rozwiązań jest zmiana przestrzeni, w której przeprowadzana jest segmentacja. Zamiast wykorzystywać bezpośrednio informację pochodzącą z obrazów można wygenerować inny opis będący bardziej selektywny w kontekście poszukiwanych obiektów. Transformacja opisu zwykle sprowadza się do przypisania wektora cech do konkretnych punktów w obrazie, co redukuje wielkość problemu numerycznego oraz pozwala zastosować cechy, które skuteczniej pozwolą odróżnić obiekty w danych obrazowych. Przykładem techniki, w której można zastosować takie podejście są Aktywne Modele Kształtu i Wyglądu (ang. *Active Shape and Appearance Models*) [3-6].

W pracy zaproponowano automatyczną metodę generacji cech, które mogą zostać wykorzystane jako składnik kryterium podczas segmentacji. Generacja cech wykorzystuje trójwymiarową wersję algorytmu SIFT (ang. *Scale Invariant Feature Transform*) [6,7]. Ze względu na różne wartości odległości pomiędzy wokselami w danych tomograficznych zaimplementowano wersję algorytmu uwzględniającą anizotropię danych. Umożliwiło to

generowanie cech z uwzględnieniem rzeczywistych odległości pomiędzy punktami, wyrażonych w milimetrach, dzięki czemu zachowano spójność wyników w ramach próbki z populacji pacjentów z nowotworem prostaty pochodzących z udostępnionej bazy obrazów.

### Generacja wektora cech

Wykorzystany w pracy algorytm SIFT, charakteryzujący się odpornością na zakłócenia, umożliwia detekcję i opis lokalnych cech na obrazie, które są niezależne od skali, rotacji, położenia oraz w pewnym zakresie od zmiany kąta widzenia [6]. Właściwości te są pożądane w kontekście generacji wektorów cech dla potrzeb segmentacji. Algorytm składa się z kilku etapów, które finalnie prowadzą do wygenerowania wektorów opisujących punkty charakterystyczne [6]:

- Skalo-przestrzenna detekcja cech: w tym etapie przeprowadzana jest detekcja punktów, które potencjalnie mogą stanowić punkty charakterystyczne w obrazie. Niezmienniczość względem skali zapewnia się wykorzystując piramidę Gaussa. W ramach piramidy obrazu są filtrowane maskami Gaussa o różnej wartości odchylenia standardowego  $\sigma$ . Odchylenia standardowe w ramach oktafów są kolejnymi krotnościami (w przeprowadzonych eksperymentach krotności nie są całkowite) odchylenia dla pierwszego poziomu piramidy. Zbiór oktafów definiuje się jako funkcja:

$$(1) \quad L(\mathbf{x}, \sigma) = G(\mathbf{x}, \sigma) * \mathbf{I}(\mathbf{x})$$

gdzie \* jest operacją splotu,  $G$  anizotropową maską Gaussa, a  $\mathbf{I}$  trójwymiarowym obrazem o współrzędnych  $\mathbf{x}=[x_1, x_2, x_3]$ . Następnie tworzy się funkcję różnicy transformat  $D$  (ang. *Difference of Gaussian, DoG*) wyznaczaną jako różnica obrazów sąsiadujących w oktawie różniących się wartością  $\sigma$  (2).

$$(2) \quad D(\mathbf{x}, \sigma_i) = L(\mathbf{x}, \sigma_{i+1}) - L(\mathbf{x}, \sigma_i)$$

- Lokalizacja punktów charakterystycznych: z wyznaczonych w poprzednim etapie punktów wybierane są te, które spełniają zestaw 3 warunków [8]:

$$(3) \quad \begin{aligned} \sum \det_2^P(H) &> 0 \\ \text{tr}(H) \cdot \det(H) &> 0 \\ \frac{\text{tr}(H)^3}{\det(H)} &< \frac{(2t+1)^3}{t^2} \end{aligned}$$

gdzie  $H$  - macierz Hessego,  $\text{tr}(H)$  - ślad macierzy,  $\det(H)$  - wyznacznik macierzy, a  $\det_2^P(H)$  - suma głównych minorów drugiego rzędu,  $t$  - wartość progowa dobierana eksperymentalnie,

- przypisanie orientacji: w następnym etapie dla punktów charakterystycznych, na podstawie zmian jasności najbliższego otoczenia określa się przestrzenną orientację. Na podstawie lokalnych właściwości obrazu opisanych przez gradient z wartości wokseli określane są pierwsze trzy cechy punktów charakterystycznych to jest: moduł gradientu (promień wodzący)  $P$  i orientacja opisana przez dwa kąty: azymutalny  $\theta$  i zenitalny -  $\varphi$ . Wielkości te można wyznaczyć za pomocą zależności [8] (4-6):

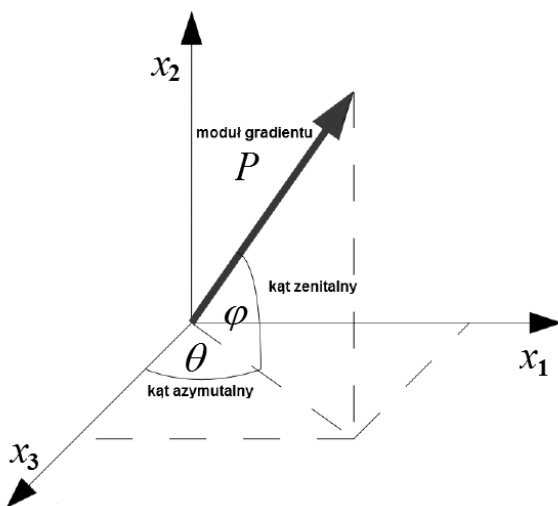
$$(4) \quad P = \sqrt{L_{x_1}^2 + L_{x_2}^2 + L_{x_3}^2}$$

$$(5) \quad \theta = \arctan \frac{L_{x_1}}{L_{x_3}}$$

$$(6) \quad \varphi = \arctan \frac{L_{x_2}}{\sqrt{L_{x_1}^2 + L_{x_3}^2}}$$

Na rysunku 1 przedstawiono interpretację graficzną wielkości opisujących punkty charakterystyczne. Na podstawie tych wielkości określana jest dominująca orientacja na bazie rozkładu orientacji wokół punktu charakterystycznego.

W pracy w przeciwieństwie do oryginalnej implementacji [6] uwzględniono anizotropowość danych tomograficznych.




Rys. 1. Graficzna interpretacja kątów  $\theta$ ,  $\varphi$  oraz modułu gradientu  $P$  dla przykładowego punktu charakterystycznego. Źródło: [8]

Ostatnim etapem jest wyznaczenie deskryptora, które polega na transformacji w wektor cech lokalnych zmian w wartościach wokół punktów charakterystycznych.

Powstała trójwymiarowa przestrzeń o rozmiarze  $N_x \times N_x \times N$  zostaje najpierw obrócona w punkcie charakterystycznym o jego dominującą orientację: w celu uzyskania stabilności deskryptora względem obrotu.

Deskryptor zbudowany jest ze zbioru znormalizowanych histogramów. Każda próbka dodana do histogramu jest ważona przez moduł gradientu, aby uwzględnić szybkość

zmian wartości pikseli jako dominującą przy opisie orientacji. Dodatkowo odległość punktu charakterystycznego od wartości gradientów otoczenia została włączona do wag punktów w histogramie. W tym celu zostało użyte symetryczne okno Gaussa. Przykładowy histogram przedstawiono na rysunku 2.



Rys. 2. Znormalizowany histogram orientacji. Źródło: [13]

Wektor cech punktu charakterystycznego ma 258 wymiarów składających się z dwóch kątów dominującej orientacji punktu charakterystycznego oraz 8 histogramów tworzących deskryptor otoczenia punktu charakterystycznego.


### Wektory cech dla danych tomograficznych

Zaproponowane podejście zostało przetestowane na zbiorze 34 trójwymiarowych obrazów tomograficznych pacjentów z nowotworem prostaty leczonych w Świętokrzyskim Centrum Onkologii w Kielcach.

Ze względu na podobny charakter danych obrazowych parametry metody zostały dobrane zgodnie z publikacją [9]. Parametr  $\sigma$  wykorzystany w pierwszej części algorytmu miał wartości różne w zależności od osi, co było konsekwencją anizotropii danych tomograficznych. Przyjęte wartości w kolejnych oktawach przedstawia tabela 1. Parametr  $t$  w warunkach wyboru punktu charakterystycznego (4) przyjęto równy 10. Przykładowe, automatycznie wygenerowane punkty charakterystyczne dla jednego pacjenta przedstawiono na rysunku 3.


Tabela 1. Wartości  $\sigma$  wykorzystane do generacji masek Gaussa dla każdej z oktaf. Pierwszy wiersz stosunek odchyleń w osiach  $x_1$  i  $x_2$ ; Drugi wiersz odchylenie standardowe dla osi  $x_3$

	$\sigma_0$	$\sigma_1$	$\sigma_2$	$\sigma_3$	$\sigma_4$	$\sigma_5$
$\frac{\sigma_{x_1}}{\sigma_{x_2}}$	1.1	1.23	1.39	1.55	1.75	1.96
$\sigma_{x_3}$	0.21	0.24	0.27	0.30	0.34	0.38



Rys. 3. Przykładowe punkty charakterystyczne wygenerowane przez algorytm SIFT

Sumaryczna liczba punktów charakterystycznych wygenerowanych w sposób automatyczny przez algorytm SIFT dla analizowanych obrazów tomograficznych przedstawia rysunek 4. Struktury anatomiczne o największej objętości to jest głowy kości udowych oraz odbytnica generują relatywnie więcej cech niż mniejsze narządy.



Rys 4. Histogram liczby wektorów cech charakterystycznych wygenerowanych przez SIFT dla bazy pacjentów. p- prostata, b- pęcherz, r- odbytnica, fL- główka kości udowej lewej, fR- główka kości udowej prawej, sm- pęcherzyki nasienne

#### Walidacja i wyniki

Wygenerowane za pomocą algorytmu SIFT wektory cech zostały poddane procesowi klasyfikacji w celu oceny przydatności metody do separacji struktur anatomicznych poddawanych napromienianiu oraz chronionych przed otrzymaniem nadmiernej dawki podczas napromieniania od wiązki terapeutycznej (struktury promieniowrażliwe). Klasyfikacja bazowała na technice maszyny wektorów nośnych (ang. *Support Vector Machine*, SVM) [10]. Ten klasyfikator został użyty ze względu na efektywność działania w wielowymiarowej przestrzeni cech, możliwość podziału klas, które nie są rozdzielne liniowo czy też możliwością klasyfikacji klas niecałkowicie rozdzielnych [11]. Idea metody sprowadza się do poszukiwania hiperpłaszczyzny, która wraz z maksymalnym marginesem  $M$ , odległością między dwoma klasami, rozdzieli dane na dwie rozłączne grupy cech. W pracy wykorzystano rozszerzenie SVM dla klasyfikacji wieloklasowej wraz z gaussowską radialną funkcją bazową (ang. *gaussian Radial Basis Function*, gRBF) opisaną przez:

$$(7) \quad K(c_i, c_{i'}) = \exp\left(-\gamma \sum_{j=1}^p (c_{ij} - c_{i'j})^2\right)$$

gdzie współczynnik  $\gamma$  wynosił 0.1 i został dobrany zgodnie z zaleceniami podanymi w [12],  $i$  i  $i'$  to indeksy kolejnych par wektorów cech.

Zastosowanie klasyfikatora umożliwia sprawdzenie właściwości separacyjnych wektora cech przypisanego do klasy obrysowanej struktury anatomicznej. Specyficzność wektorów można określić za pomocą parametru definiującego skuteczność klasyfikacji.

W procesie klasyfikacji założono 6 klas odpowiadających poszczególnym strukturom anatomicznym istotnym z punktu widzenia radioterapii nowotworu prostaty (prostata, głowy kości udowych, pęcherz, odbytnica i pęcherzyki nasienne).

Do oceny skuteczności separacji wykorzystano metrykę F1 (ang. *F1 score*). Rozpatruje ona precyzję  $p$  i czułość  $r$  klasyfikacji:

$$(8) \quad F1 = 2 \frac{p \cdot r}{p + r}$$

Średni błąd zdolności przewidywania klasyfikatora zdefiniowano jako:


$$(9) \quad score = \frac{1}{k} \sum_{i=1}^k F1_i \cdot 100\%$$

Wyniki zostały uzyskane z zastosowaniem sprawdzianu krzyżowego w wersji kontrolowanej walidacji, polegającej na podziale zbioru testowego i uczącego ze względu na przynależność cechy do pojedynczego pacjenta. Testy zostały przeprowadzone dla 61954 punktów zlokalizowanych wewnątrz struktur anatomicznych i 57776 punktów na powierzchni narządów. Średnio przypadało około 200 punktów na powierzchnię i 200 wewnątrz na każdą ze struktur.

Otrzymana średnia wartość *score* wynosi 58.3% przy odchyleniu standardowym wynoszącym 12% dla punktów wewnątrz struktur oraz 60.6% dla punktów zlokalizowanych na powierzchni przy odchyleniu standardowym równym 9.2%. Wyniki zostały porównane z wektorami cech, zbudowanymi bezpośrednio z wartości wokseli. W porównaniu wykorzystano te same punkty jak w przypadku metodologii bazującej na SIFT. Otrzymane wyniki przedstawiono w tabeli 2. Potwierdzają one lepsze właściwości separacyjne wektorów generowanych zgodnie z algorytmem SIFT w porównaniu do klasycznego podejścia obejmującego bezpośrednio wykorzystanie wartości wokseli. Dodatkowo odchylenie standardowe dla wartości wokseli jako wektorów cech jest ok. 2-krotnie większe niż dla wektorów cech generowanych przez SIFT. Na tej podstawie można wnioskować o wyższej precyzji opisu struktur przez wektory generowane algorytmem SIFT.

Tabela 2. Porównanie skuteczności separacji dla wektorów cech wygenerowanych zgodnie z techniką SIFT oraz bazujących bezpośrednio na wartościach wokseli

	SIFT		Wartości wokseli	
	Punkty wewnątrz struktur	Punkty na powierzchni	Punkty wewnątrz struktur	Punkty na powierzchni
Średnia [%]	58.2	60.6	55.2	51.8
Odchylenie standardowe[%]	12	9.2	24.3	22.4



Rys. 5. Skuteczność klasyfikatora dla wszystkich narządów z rozdzielaniem na lokalizację punktów wewnątrz i na powierzchni struktur dla poszczególnych pacjentów z wykorzystaniem metodologii SIFT

Skuteczność klasyfikacji dla wszystkich narządów z rozbiciem na poszczególnych pacjentów przedstawia rysunek 5. Niższe wartości skuteczności dla punktów wewnątrz struktur wynikają z jednorodnego rozkładu wartości w ramach tych struktur. Rozkład wartości nie różni się dla pęcherza i prostaty (tkanki z których zbudowane są te organy mają praktycznie taki sam współczynnik pochłaniania promieniowania rentgenowskiego).

#### Podsumowanie

W artykule przedstawiono anizotropową wersję algorytmu SIFT, który został wykorzystany do generacji wektorów cech. Wektory dla punktów znajdujących się wewnątrz i na powierzchni struktur anatomicznych zostały przetestowane pod kątem właściwości separacyjnych umożliwiających rozróżnienie poszczególnych struktur. Uzyskane wyniki porównano z wektorami cech będącymi wartościami wokseli wokół punktów. W połączeniu z algorytmami segmentacji bazującymi na modelach organów możliwe jest przeprowadzenie skutecznej segmentacji danych tomograficznych dla potrzeb wspierania procesu planowania leczenia pacjentów z nowotworem prostaty.

*Badania zostały sfinansowane ze środków przeznaczonych na działalność statutową w ramach Grantu Dziekańskiego. W pracy wykorzystano obrazowe dane medyczne pozyskane w ramach projektu MNiSW / NCN nr NN518 497739.*

#### LITERATURA

- [1] Sonka, M., Hlavac V., Boyle R. *Image processing, analysis, and machine vision*. Cengage Learning, (2014)
- [2] Heimann T., Meinzer H.P., Statistical shape models for 3D medical image segmentation: a review. *Medical image analysis* 13 (2009) n.4, 543-563.
- [3] Cootes, T.F., Edwards G.J., Taylor C.J. Active appearance models. *IEEE Transactions on pattern analysis and machine intelligence* 23 (2001) n.6, 681-685.

- [4] Skalski, A., Kos A., Zieliński T. Using ASM in CT data segmentation for prostate radiotherapy *Computer Vision and Graphics. Springer Berlin Heidelberg*, (2012) 610-617
- [5] Kos, A., et al. "Comparison of ASM and AAM-based segmentation of prostate image in the CT scans for radiotherapy planning." *NTAV/SPA* (2012): 27-29.
- [6] Lowe, D.G., Object recognition from local scale-invariant features." *Computer vision, 1999. The proceedings of the seventh IEEE international conference on*. 2 (1999)
- [7] Lowe, D.G., Distinctive image features from scale-invariant keypoints. *International journal of computer vision*, 60 (2004) n.2, 91-110.
- [8] Flitton G.T., Breckon T.P., Bouallagu N.M. Object recognition using 3D SIFT in complex CT volumes. *BMVC*, (2010), 1–12.
- [9] Allaire S., et al. Full orientation invariance and improved feature selectivity of 3D SIFT with application to medical image analysis. *Computer Vision and Pattern Recognition Workshops, 2008. CVPRW'08*. (2008) 1–8
- [10] Cortes C., Vapnik V., Support-vector networks. *Machine learning*, 20 (1995) n.3, 273–297.
- [11] Mountrakis G., Im J., Ogole C., Support vector machines in remote sensing: A review, *ISPRS Journal of Photogrammetry and Remote Sensing*, 66 (2011) n.3, 247-259.
- [12] Hastie T., et al. *An Introduction to Statistical Learning with Applications in R*. Springer, New York, i edition, 2013.
- [13] Szczotka A., Projekt i implementacja aplikacji z bazą obrazów z tomografii komputerowej (CT) wykorzystywanych do planowania radioterapii pacjentów z chorobą nowotworową prostaty. Praca inżynierska, AGH (2015)

---

**Autorzy:** dr inż. Andrzej Skalski, inż. Agnieszka Szczotka, AGH Akademia Górniczo-Hutnicza, Katedra Metrologii i Elektroniki, al. Mickiewicza 30, 30-059 Kraków, E-mail: [skalski@agh.edu.pl](mailto:skalski@agh.edu.pl); dr n. med. Piotr Kędzierawski, mgr Tomasz Kuszewski, Świętokrzyskie Centrum Onkologii w Kielcach, ul. Artwińskiego 3, 25-734 Kielce, dr hab. n. med. Paweł Kukołowicz, profesor COI, Centrum Onkologii-Instytut im. Marii Skłodowskiej-Curie, Zakład Fizyki Medycznej, ul. Wawelska 15B, 02-034 Warszawa,