

mgr inż. Agnieszka Stankiewicz
dr inż. Tomasz Marciniak
prof. dr hab. inż. Adam Dąbrowski
Wydział Informatyki
Katedra Sterowania i Inżynierii Systemów
Pracownia Układów Elektronicznych
i Przetwarzania Sygnałów
Politechnika Poznańska
ul. Piotrowo 3a, 60-965 Poznań

dr hab. n. med. Marcin Stopa
dr n. med. Piotr Rakowicz
lek. med. Elżbieta Marciniak
Oddział Kliniczny Okulistyki
z Pododdziałem Okulistyki Dziecięcej
Szpitala Klinicznego im. H. Święcickiego
Uniwersytetu Medycznego w Poznaniu
ul. Grunwaldzka 16/18, 60-780 Poznań
Katedra Optometrii
i Biologii Układu Wzrokowego
Uniwersytetu Medycznego w Poznaniu
ul. Rokietnicka 5D, 60-806 Poznań

Analiza obrazów OCT niskiej jakości

Słowa kluczowe: optyczna tomografia koherentna (OCT), segmentacja obrazów, teoria grafów

STRESZCZENIE

W artykule przedstawiono aspekty automatycznej segmentacji obrazu w celu oznaczenia warstw siatkówki oka ludzkiego. Zwrócono uwagę na problemy występujące przy komputerowym przetwarzaniu obrazów uzyskanych z wykorzystaniem spektralnej optycznej tomografii koherentnej (OCT). Pokazano prawidłowość segmentacji warstw siatkówki dla zestawu skanów 3D o niskim wskaźniku jakości. Wskazano na możliwe sposoby poprawy tego procesu. Podczas badań eksperymentalnych korzystano z tzw. B-skanów uzyskanych za pomocą urządzenia Copernicus HR.

1. WPROWADZENIE

Medyczna biometria oka jest we współczesnej diagnostyce okulistycznej istotnym elementem procesu rozpoznawania zmian chorobowych. Wykorzystywane są zwłaszcza dwie techniki:

- biometria ultradźwiękowa, w której wykorzystuje się fale ultradźwiękowe do mierzenia odległości między poszczególnymi strukturami oka. W przypadku tej techniki wymagany jest kontakt głowicy aparatu z okiem pacjenta (USG – ultrasonography)
- biometria optyczna, w której stosowana jest optyczna tomografia koherentna (OCT – optical coherence tomography), a jej zaletą jest brak wymagania bezpośredniego kontaktu urządzenia z gałką oczną.


Urządzenie OCT wytwarza wiązkę światła, która koncentruje się na siatkówce oka. Światło, które odbija się od wewnętrznych struktur oka, jest interferometrycznie analizowane przez urządzenie. Obrazy OCT umożliwiają wizualizację warstw siatkówki i są wykonywane różnymi technikami. Starszym rozwiązaniem jest tzw. technika TD (time domain), która wykorzystuje ruchome lustro i rejestrację z wykorzystaniem fotodiody [1]. Współczesne urządzenia OCT bazują na rozwiązaniu spektralnym (SD – spectral domain), w którym lustro jest nieruchome, natomiast rejestratorem jest spektrometr. Wynikiem pomiaru

z wykorzystaniem tych urządzeń jest zestaw obrazów przekrojów (tzw. B-skanów), które są zbudowane z zestawu A-skanów (amplitude modulation scan). Pojedynczy B-skan jest obrazem zaszumionym, dlatego w celu poprawy jakości stosowana jest operacja uśredniania, jeżeli chcemy obserwować pojedynczy przekrój. W przypadku akwizycji zestawu B-skanów dla obrazu 3D nie stosuje się operacji uśredniania, ponieważ szybkość akwizycji urządzenia OCT to standardowo od 50 000 do 70 000 A-skanów na sekundę [2, 3], czyli jeżeli chcemy uzyskać obraz 3D złożony ze 100 B-skanów o rozdzielczości poziomej 800 A-skanów, wówczas można oszacować, że czas akwizycji będzie równy ok. 1,6 sekundy. Czas ten nie powinien być wydłużany, aby zapobiec artefaktom związanym z mimowolnymi ruchami gałki ocznej. Niektórzy producenci urządzeń OCT stosują technologie śledzenia ruchu gałki ocznej, aby zapobiec tym problemom.

Kluczowym elementem do skutecznego działania oprogramowania diagnostycznego jest prawidłowe wyznaczenie poszczególnych warstw siatkówki. Dokładnie przeprowadzona segmentacja jest operacją wstępną w kolejnych etapach wizualizacji.

Standardowe oprogramowanie urządzeń OCT zawiera algorytmy automatycznej segmentacji warstw, które bazują np. na: analizie jasności obrazu [4], technice aktywnych konturów [5], rozpoznawaniu wzorców [6], teorii grafów [7, 8], czy technikach grupowania [9, 10]. Automatyczna segmentacja warstw siatkówki na obrazach OCT wymaga pokonania wielu problemów, takich jak: szum [11], nierównomierność odbicia światła przez tkanki [12], pochłanianie światła przez naczynia krwionośne, nieoczekiwany ruch pacjenta, zależność algorytmu segmentacji od urządzenia [13]. Szczególną trudność wprowadza również obecność zmian chorobowych [14], które uwzględniamy w naszych analizach.

Jakość B-skanu może być oceniana za pomocą stosunku sygnału do szumu (SNR - signal to noise ratio), jakości sygnału (SS - signal strenght) oraz indeksów jakości (QI - quality index). Dwa pierwsze wskaźniki (SNR i SS) mogą być wyznaczone przez producenta urządzenia, natomiast QI oblicza się na podstawie histogramu obrazu i jest wskaźnikiem zbliżonym do oceny subiektywnej, dokonywanej przez eksperta [15]. Indeks jakości QI jest obliczany przez oprogramowanie urządzenia. Przykładowo w przypadku urządzenia Copernicus HR (firmy OPTOPOL Technology Sp. z o.o., Zawiercie, Polska) dla QI poniżej 4 wskazane jest powtórne badanie, dla wartości powyżej 6 zestaw obrazów ma wystarczająco dobrą jakość. Dla wartości pomiędzy 4 a 6 producent sugeruje ostrożność analizy otrzymanych wyników pomiaru [2]. Trzeba pamiętać, że zmiany chorobowe (np. zaćma) powodują, że powtórne pomiary nie będą skutkowały poprawą jakości obrazu. Dodatkowo w każdym urządzeniu OCT może być stosowana inna skala jakości obrazu, co może utrudniać porównywanie skanów otrzymanych z różnych urządzeń, przy korzystaniu ze wskaźników wyznaczanych przez producentów.



Rys. 1. Przykładowe badanie OCT 3D – 100×800×1010: (a) rekonstrukcja funduszu, (b) B-skan nr 53 z oznaczeniami eksperta, QI=5,29, (c) B-skan nr 53 z automatycznymi oznaczeniami, (d) B-skan nr 8 QI=2,01 z automatycznymi oznaczeniami

Na rysunku 1 pokazano B-skany uzyskane podczas badania OCT 3D, wykonane za pomocą urządzenia Copernicus. Dokonano akwizycji 100 B-skanów – każdy o rozdzielczości 800 pikseli w poziomie i 1010 pikseli w pionie. Uśredniony wskaźnik QI wyznaczony przez oprogramowanie producenta był równy 4,52. Możemy zauważyć, że skan na rys. 1c ma dobrą jakość tzn. $QI=5,29$, ale i tak zmiany chorobowe powodują błędy w procesie segmentacji, w stosunku do ręcznych oznaczeń wykonanych przez eksperta (rys. 1b). Z kolei skan na rys. 1d, który nie obejmuje zmian chorobowych, ma niską jakość wynikającą z akwizycji, co także skutkuje problemami z prawidłową segmentacją tych obrazów.

2. SEGMENTACJA WARSTW SIATKÓWKI NA OBRAZACH OCT

Jak wspomniano powyżej, w diagnostyce chorób oczu kluczową rolę odgrywa określenie struktury morfologicznej siatkówki, poprzez analizę jej warstw. Zaprezentowany eksperyment miał na celu zbadanie wpływu jakości obrazu OCT na poprawność automatycznej segmentacji warstw siatkówki. Do tego celu wykorzystano algorytm analizy obrazu opierający się na teorii grafów [16]. Następnie dokonano próby poprawy skuteczności segmentacji poprzez usunięcie z obszaru analizy fragmentów obrazu o niskim poziomie sygnału. Wyniki eksperymentu przedstawione zostały w punkcie 4.

2.1 Algorytm segmentacji oparty na teorii grafów

Podstawą zastosowanego algorytmu jest wykorzystanie pojedynczego obrazu B-skanu OCT jako grafu, w którym każdy piksel traktowany jest jako węzeł tego grafu, a połączenia pomiędzy węzłami – krawędziami. Poprzez wybranie zbioru połączonych ze sobą krawędzi można utworzyć ścieżkę od początkowego do końcowego węzła. Celem algorytmu jest wybranie ścieżki charakteryzującej się najniższą całkowitą sumą wag (m.in. wykorzystując algorytm Dijkstry) jako granicy pomiędzy dwoma warstwami siatkówki.

Wiedząc, iż warstwy siatkówki są strukturami w przeważającej mierze ciągłymi zarówno w płaszczyźnie pojedynczego obrazu jak i pomiędzy przekrojami, rozszerzono algorytm o ograniczenie obszaru przeszukiwań grafu dla dwóch najbardziej wyróżniających się warstw na podstawie informacji o nich, znalezionych na sąsiadujących przekrojach (obrazach).

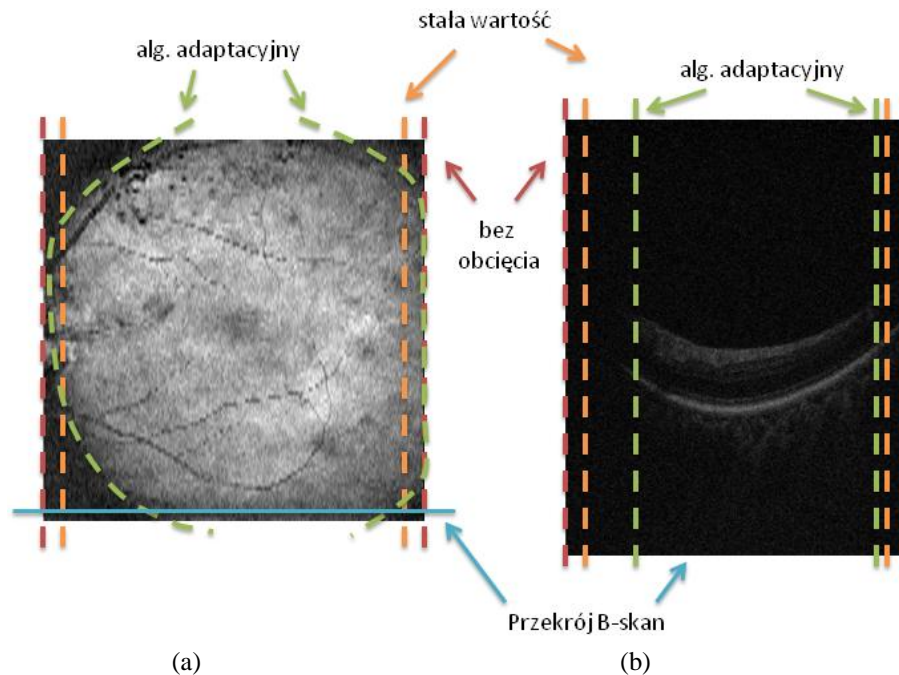
2.2. Usunięcie obszaru obrazu o niskim poziomie sygnału

Szczegółowa analiza obrazów B-skanów OCT wykazała, iż istnieją regiony skanów o bardzo niskim poziomie sygnału, co powoduje, że warstwy siatkówki są prawie całkowicie niewidoczne przy bocznych krawędziach obrazu. Jest to spowodowane niedoświetleniem tkanek na peryferiach wykonanego skanu. Przykładowy przekrój posiadający tego typu wadę oraz odpowiadający mu zrekonstruowany obraz fundus zostały przedstawione na rys. 2. Ponieważ sytuacja ta jest sprzeczna z założeniem algorytmu o ciągłości warstw na całej szerokości obrazu wskazuje to na jeden z głównych powodów błędów podczas automatycznej segmentacji obrazu. Błąd segmentacji rozumiany jest jako oznaczenie granicy warstwy na obrazie na innej wysokości niż oznaczenie referencyjne (dla danej kolumny obrazu).

W trakcie badań podjęto próbę pokonania tej przeszkody poprzez dokonanie obcięcia fragmentu obrazu B-skanu w okolicy jego bocznych krawędzi. Określenie fragmentu obrazu, który ma zostać usunięty najlepiej przeprowadzić technikami adaptacyjnymi. Pomimo, że wymagają one większych nakładów obliczeniowych, to pozwalają uzyskać lepsze wyniki niż stosowanie prostszej (szybszej) metody usuwania krawędzi o stałej szerokości.

Rysunek 2 przedstawia omówione sposoby usuwania obszarów o słabej jakości. Linia przerywana ilustruje przykładowe miejsca cięcia obrazu: linia czerwona – obraz wyjściowy bez obcinania krawędzi, linia pomarańczowa – obcięcie krawędzi obrazu o stałą szerokość,

linia zielona – obcięcie obrazu o szerokość obliczoną na podstawie jasności obrazu w danej kolumnie. W rozdziale 4 zamieszczone zostały wyniki przeprowadzonych eksperymentów porównujących skuteczność zaproponowanych metod ograniczenia wpływu niskiej jakości sygnału.



Rys. 2. Ilustracja trzech badanych możliwości ograniczenia wpływu obszaru o niskim poziomie sygnału na poprawność działania algorytmu automatycznej segmentacji na przykładzie: (a) zrekonstruowanego obrazu fundus oraz (b) wybranego obrazu B-skanu

3. DANE I OPROGRAMOWANIE

Do badania skuteczności proponowanej metody wykorzystano serię skanów 3D OCT otrzymanych przy użyciu urządzenia Copernicus HR, za pomocą którego zebrano obrazy siatkówki 30 pacjentów z symptomami patologii interfejsu szkliskowo-siatkówkowego. Średnia wieku badanych pacjentów jest równa 70 lat. Dla każdego z badanych wykonano skan OCT plamki żółtej obejmujący obszar o rozmiarach $8 \times 8 \times 2$ mm, co odpowiada $100 \times 800 \times 1010$ punktom skanu OCT (100 B-skanów o rozmiarach 800×1010 pikseli).

Metodologia przeprowadzonego eksperymentu obejmuje ręczne oznaczenie poprawnej segmentacji wybranych siedmiu warstw poprzez grupę ekspertów z Oddziału Okulistycznego Szpitala Klinicznego im. H. Święcickiego Uniwersytetu Medycznego im. K. Marcinkowskiego w Poznaniu oraz automatyczną segmentację wykorzystującą proponowaną metodę opartą na teorii grafów. Określenie poprawności działania algorytmu polegało na obliczeniu średniej arytmetycznej bezwzględnej wartości błędu w pikselach (2) oraz odchylenia standardowego (3) pomiędzy ręcznymi oraz automatycznymi oznaczeniami:

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n |x_i| \quad (2)$$

$$\sigma = \sqrt{\frac{\sum_{i=1}^n x_i^2}{n} - \bar{x}^2} \quad (3)$$

gdzie x_i to kolejne wartości błędu (w pikselach) pomiędzy oznaczeniami ręcznymi i automatycznymi, \bar{x} to średnia arytmetyczna wszystkich błędów, n to liczba pikseli, dla których występują oznaczenia zarówno ręczne jak i automatyczne. Należy przy tym

zauważyć, iż ze względu na odmienny charakter określania granicy pomiędzy warstwami przez eksperta oraz w wyniku działania algorytmu, różnica pomiędzy oznaczeniami nie przekraczająca wartości 5 pikseli została określona jako poprawne oznaczenie warstwy, a błąd takiego oznaczenia uznany został za zerowy.

W przeprowadzonym eksperymencie wykorzystano algorytm zaimplementowany w środowisku Matlab/Simulink w celu oznaczenia następujących siedmiu granic warstw siatkówki: ILM (ang. inner limiting membrane), NFL/GCL (ang. nerve fiber layer / ganglion cell layer), IPL/INL (ang. inner plexiform layer / inner nuclear layer), INL/OPL (ang. inner nuclear layer / outer plexiform layer), OPL/ONL (ang. outer plexiform layer / outer nuclear layer), IS/OS (ang. inner segments / outer segments of photoreceptors), oraz RPE/Choroid (ang. retinal pigment epithelium).

4. WYNIKI

W tym punkcie przedstawiono wyniki działania algorytmu automatycznej segmentacji siedmiu warstw siatkówki na przykładzie wybranego pacjenta, dla którego zrekonstruowany obraz fundus oraz wybrany przekrój zostały pokazane na rys. 2. Badanie to, wykonane przy użyciu urządzenia Copernicus HR, zostało poddane analizie jakości przez wbudowane w urządzenie OPTOPOL SOCT oprogramowanie. Parametr QI dla tego skanu 3D wynosi od 0,88 do 5,79 dla poszczególnych przekrojów ze średnią wartością 4,17, a więc jakość skanu można zakwalifikować jako słabą.

Przeprowadzony eksperyment miał na celu przetestowanie dwóch zaproponowanych metod poprawy skuteczności automatycznej analizy obrazu:

- dodatkowego śledzenia powierzchni ILM i IS/OS oraz
- dwóch metod usuwania peryferyjnych fragmentów po obu stronach obrazu: o 40 pikseli (10 % szerokości obrazu) oraz adaptacyjnego.

Wyniki przeprowadzonego eksperymentu zostały zawarte w tabeli 1 i przedstawione na rys. 3. Analizując wyniki przeprowadzonego eksperymentu można zauważyć, iż zarówno ograniczenie przeszukiwanego obszaru (śledzenia warstw), jak i wykluczenie obszarów o niskim poziomie sygnału powoduje znaczną poprawę sprawności algorytmu.

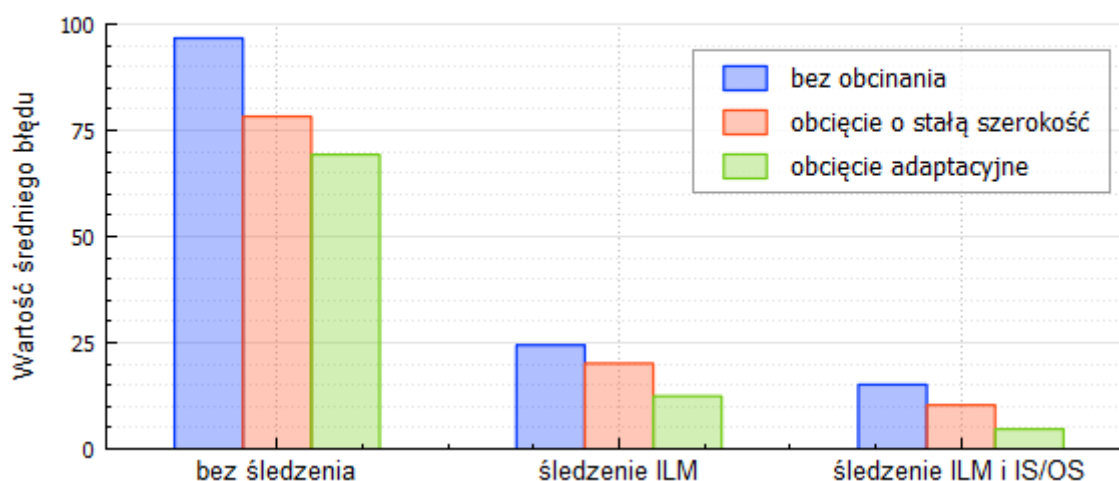
Tab. 1 Średnia wartość bezwzględnego błędu dla algorytmu automatycznej segmentacji warstw siatkówki

metoda	algorytm podstawowy			dodatkowe śledzenie warstwy ILM			dodatkowe śledzenie warstw ILM oraz IS/OS		
	średni błąd [px]	odchylenie standardowe [px]	procentowy udział błędnych oznaczeń	średni błąd [px]	odchylenie standardowe [px]	procentowy udział błędnych oznaczeń	średni błąd [px]	odchylenie standardowe [px]	procentowy udział błędnych oznaczeń
bez obcinania	96,7	85,5	65,7%	24,4	49,4	44,6%	15,1	37,4	39,1%
z obcięciem o 10%	78,3	96,9	52,6%	20,1	41,4	38,3%	10,3	29,4	31,3%
z adaptacyjnym obcięciem	69,3	88,0	46,3%	12,4	24,3	31,8%	4,7	10,8	24,8%

W przypadku dodatkowego śledzenia warstw ILM i IS/OS prawie dwa razy mniej pikseli jest błędnie wysegmentowanych, przy czym średni błąd maleje od 6- do ponad 14-krotnie. Z kolei wykluczenie z analizy części obrazu o słabym sygnale pozwala nawet na 3-krotne zmniejszenie średniego błędu segmentacji wszystkich warstw.

Pomimo, iż z procentowego udziału błędów dla najlepszego połączenia metod wynika, iż nawet ¼ pikseli jest błędnie segmentowana, to jednak jest to oznaczenie w bardzo bliskiej odległości do rzeczywistych granic pomiędzy warstwami, na co wskazuje średni błąd w wysokości 4,7 pikseli. To oznacza dużą skuteczność proponowanych metod.

Średni błąd automatycznej segmentacji



Rys. 3. Wykres średniego błędu automatycznej segmentacji dla poszczególnych metod

Dokonana segmentacja warstw pozwoliła na wygenerowanie wirtualnej mapy profilu odległości pomiędzy wybranymi warstwami. Jest to rodzaj analizy stosowany przez specjalistów w dziedzinie okulistyki w celu oszacowania nieprawidłowości w strukturze siatkówki. Rys. 4 przedstawia wirtualne mapy pomiędzy warstwą ILM a IS/OS dla ręcznych (a) oraz automatycznych (b, c, d) oznaczeń. Kołowa siatka ETDRS (o średnicach kół odpowiednio 1, 3 i 6 mm) nałożona na obraz służy jako siatka referencyjna do analiz medycznych.

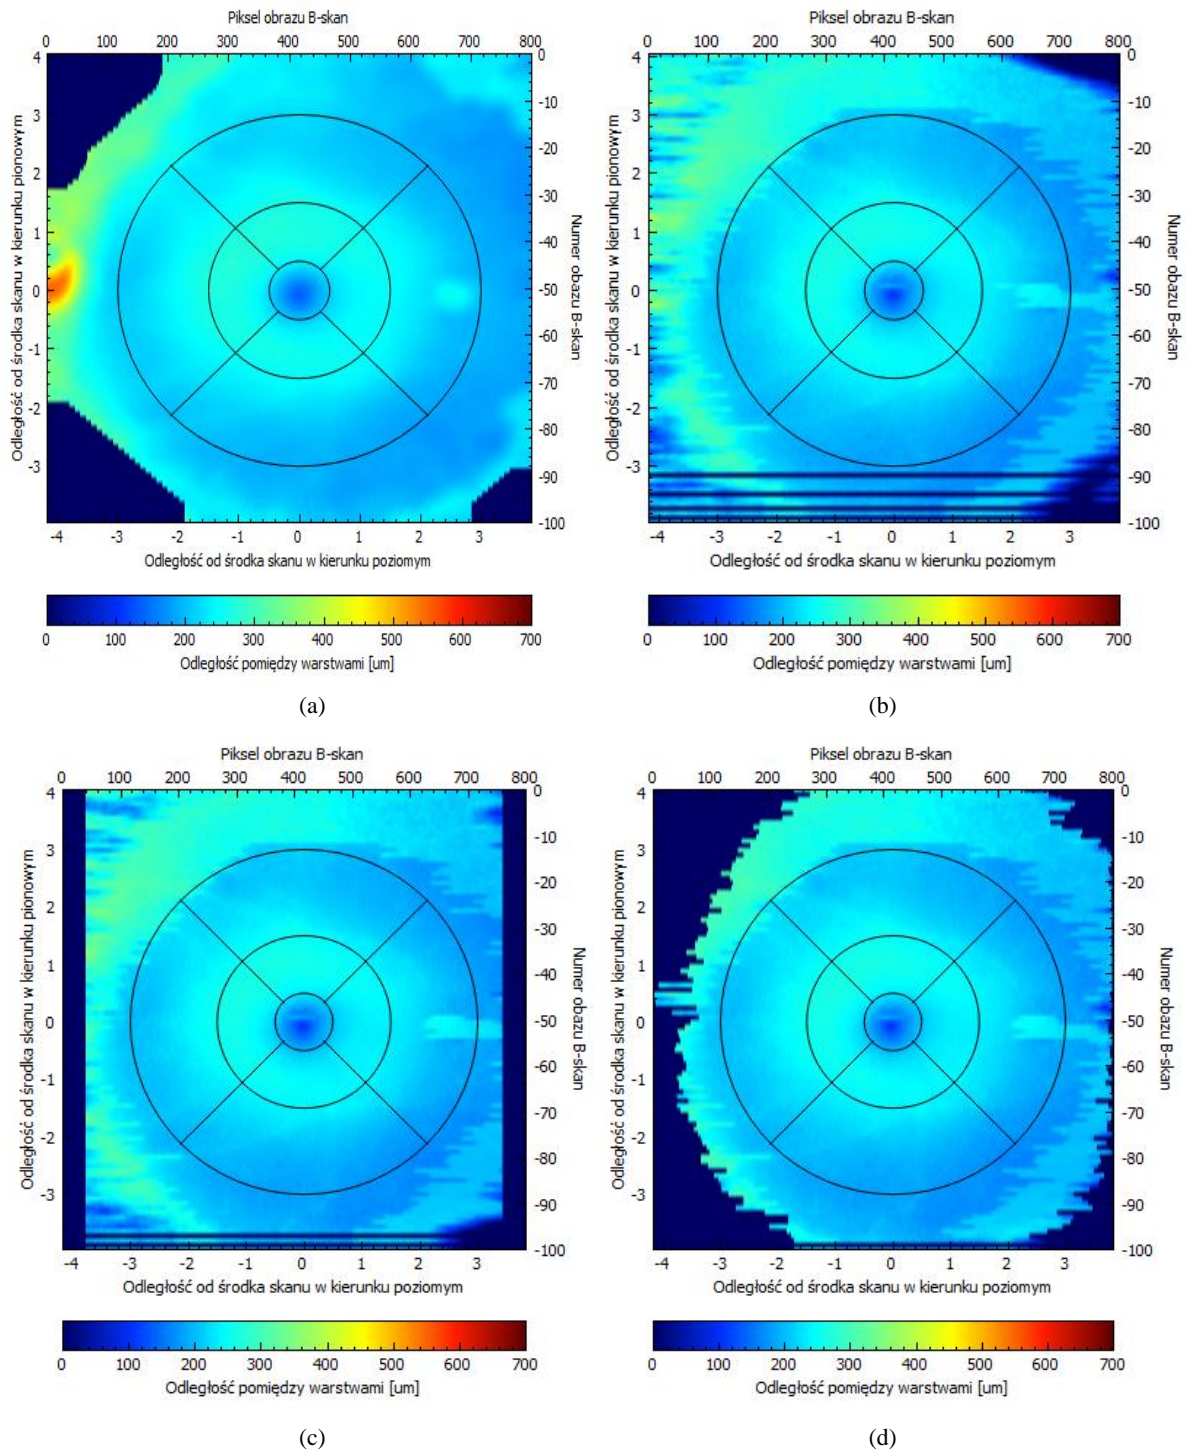
Bliższa analiza wygenerowanych map wykazuje, że słuszne jest wykluczenie obszarów o niskiej jakości sygnału z przetwarzania wybranym algorytmem, ze względu na widoczną poprawę skuteczności. Rysunek 4b ukazuje artefakty w peryferyjnych częściach skanu oraz błędy w segmentacji pomiędzy 90-tym a 100-nym przekrojem. Wykluczenie części skanu z analizy znacznie poprawia wyniki, jak można zauważyć na rys. 4c i 4d.

5. PODSUMOWANIE

Zaproponowane rozwiązania poprawiają dokładność procesu segmentacji warstw, który jest etapem wstępnym do dalszych obliczeń związanych z diagnostyką medyczną. W przypadku obrazów OCT 3D analiza warstw odbywa się z wyższą precyzją, jeżeli poszczególne B-skany są analizowane pojedynczo, ale z uwzględnieniem skanów sąsiednich.

Przeprowadzone eksperymenty udowadniają, że możliwa jest skuteczna analiza również obrazów OCT o bardzo niskiej jakości, podczas gdy standardowe metody wykorzystywane w dostarczonym przez producenta oprogramowaniu nie są już w stanie podołać temu zadaniu (jak pokazano na rys. 1).

Jak pokazano w artykule [17] wirtualne mapy pomiędzy trakcją witreoretinalną a warstwą ILM, pozwalają na śledzenie postępowania choroby i wybór odpowiedniej strategii leczenia, zarówno farmakologicznej jak i chirurgicznej. Co więcej, precyzyjnie wygenerowane mapy mogą wspomóc wybór najwłaściwszego pozycjonowania narzędzi chirurgicznych podczas operacji witrektomii.



Rys. 4. Wirtualna mapa pomiędzy warstwami ILM a IS/OS dla: (a) ręcznych oznaczeń, oraz automatycznych oznaczeń wykonanych (b) bez obcinania obszarów o niskim poziomie sygnału, (c) z obcięciem obrazu o stałą wartość szerokości oraz (d) z wykorzystaniem adaptacyjnej techniki usuwania obszarów o niskiej jakości

BIBLIOGRAFIA

- [1] Z. Yaqoob, J. Wu, C. Yang, “Spectral domain optical coherence tomography: a better OCT imaging strategy”, *Biotechniques* 39 (6 Suppl), S6-13. doi: 10.2144/000112090, 2005.
- [2] SOCT Copernicus HR, “User Manual Software Version 4.3.0 User Manual rev. A”, Optopol, 2011.

- [3] RTVue XR 100 Avanti Edition, „Podręcznik użytkownika”, Optovue Inc., 2014.
- [4] T. Fabritius, S. Makita, et al., “Automated segmentation of the macula by optical coherence tomography”, *Opt. Express* 17(18), pp. 15659–15669, 2009.
- [5] A. Yazdanpanah, G. Hamarneh, B. Smith, M. Sarunic, “Intra-retinal Layer Segmentation in Optical Coherence Tomography Using an Active Contour Approach,” in Proceedings of the 12th International Conference on Medical Image Computing and Computer-Assisted Intervention: Part II, Springer-Verlag, vol. 5762, pp. 649–656, 2009.
- [6] V. Kajic, B. Povazay, B. Hermann, B. Hofer, D. Marshall, P. L. Rosin, W. Drexler, “Robust segmentation of intraretinal layers in the normal human fovea using a novel statistical model based on texture and shape analysis”, *Optics Express* 18(14), pp. 14730–14744, 2010.
- [7] M. K. Garvin, M. D. Abramoff, R. Kardon, S. R. Russell, X. Wu, M. Sonka, “Intraretinal Layer Segmentation of Macular Optical Coherence Tomography Images Using Optimal 3-D Graph Search”, *IEEE Transactions on Medical Imaging* 27(10), pp. 1495–1505, 2008.
- [8] S. J. Chiu, X.T. Li, P. Nicholas, C. A. Toth, J. A. Izatt, S. Farsiu, “Automatic segmentation of seven retinal layers in SDOCT images congruent with expert manual segmentation”, *Opt. Express* 18(18), pp. 19413–19428, 2010.
- [9] Y. M. Cha, J.H. Han, “High-Accuracy Retinal Layer Segmentation for Optical Coherence Tomography Using Tracking Kernels Based on Gaussian Mixture Model”, *IEEE Journal of Selected Topics in Quantum Electronics* 20(2), 2014.
- [10] M. Szkulmowski, M. Wojtkowski, B. Sikorski, T. Bajraszewski, V.J. Srinivasan, A. Szkulmowska, J.J. Kaluzny, J.G. Fujimoto, A. Kowalczyk, “Analysis of posterior retinal layers in spectral optical coherence tomography images of the normal retina and retinal pathologies”, *Journal of Biomedical Optics* 12(4), 2007.
- [11] M. Szkulmowski, M. Wojtkowski, “Averaging techniques for OCT imaging”, *OPTICS EXPRESS* 21(8), pp. 9757-9773, 2013.
- [12] H. Ishikawa, D.M. Stein, et al., “Macular segmentation with optical coherence tomography”, *Invest. Ophthalmol. Vis. Sci.* 46(6), pp. 2012–2017, 2005.
- [13] A. Ehnes, Y. Wenner, C. Friedburg, M. N. Preising, W. Bowl, W. Sekundo, E. Meyer zu Bexten, K. Stieger, B. Lorenz, “Optical Coherence Tomography (OCT) Device Independent Intraretinal Layer Segmentation”. *Trans. Vis. Sci. Tech.* 3(1), 2014.
- [14] D. C. Fernández, et al., “Automated detection of retinal layer structures on optical coherence tomography images”, *Opt. Express* 13(25), pp. 10200–10216, 2005.
- [15] D. M. Stein, et al. “A New Quality Assessment Parameter for Optical Coherence Tomography”, *The British Journal of Ophthalmology* 90.2 (2006): pp. 186–190. PMC. Web. 10 Mar. 2015.
- [16] S. J. Chiu, et al., “Automatic segmentation of seven retinal layers in SDOCT images congruent with expert manual segmentation”, *Optics Express* 18(18);pp. 19413-19428, 2010.
- [17] A. Stankiewicz, T. Marciniak, A. Dąbrowski, M. Stopa, E. Marciniak, “A New OCT-based Method to Generate Virtual Maps of Vitreomacular Interface Pathologies”, *Proc. of SPA 2014: Signal Processing Algorithms, Architectures, Arrangements, and Applications Conference Proceedings*, pp. 83-88, 2014.

Praca współfinansowana ze środków Unii Europejskiej w ramach Europejskiego Funduszu Społecznego „Wsparcie stypendialne dla doktorantów na kierunkach uznanych za strategiczne z punktu widzenia rozwoju Wielkopolski”, Poddziałanie 8.2.2 Programu Operacyjnego Kapitał Ludzki.

Analysis of low quality OCT images

Keywords: optical coherence tomography (OCT), image segmentation, graph theory

ABSTRACT

This article presents aspects of the automatic segmentation of retinal layers of the human eye. The paper draws attention to the problems that occur during computer image processing of the images obtained with the use of the spectral domain optical coherence tomography (SD OCT). The accuracy of retinal layers segmentation for a set of 3D scans with low quality was shown. Possible ways to improve the process were pointed out and experimental studies were performed using the so-called B-scans obtained with the OCT Copernicus HR device.

Fig. 1. Sample 3D OCT examination – $100 \times 800 \times 1010$ data points: (a) fundus reconstruction, (b) B-scan No. 53, $QI = 5.29$, (c) B-scan No. 8, $QI = 2.01$

Fig. 2. Illustration of three examined methods of reducing the impact of a low level signal area on the correctness of automatic segmentation algorithm on an example of: (a) reconstructed fundus image and (b) the B-scan image

Fig. 3. Average error graph for each automatic segmentation method

Fig. 4. The virtual maps between ILM and IS/OS segmented layers for: (a) manual, and automated segmentations carried out (b) without cutting areas of low signal levels, (c) with cropping B-scan image of a selected constant width, and (d) with adaptive technique of removing the low quality area

Table 1. The average value of the absolute error for automatic retinal layers segmentation algorithm