

DOI: 10.5604/20830157.1121333

ZASTOSOWANIE METODY HELLWIGA DO REDUKCJI WYMIARU PRZESTRZENI CECH OBRAZÓW USG TARCZYCY

Zbigniew Omiotek¹, Waldemar Wójcik²¹Doktorant na Wydziale Elektrotechniki i Informatyki Politechniki Lubelskiej, ² Politechnika Lubelska, Wydział Elektrotechniki i Informatyki

Streszczenie. W artykule przedstawiono wyniki zastosowania metody Hellwiga do redukcji wymiaru przestrzeni cech obrazów USG tarczycy. Za pomocą tej metody, z wejściowego zbioru 283 cech otrzymano kombinację 3 cech z największą wartością wskaźnika pojemności informacyjnej Hellwiga. Zbiór ten posłużył do budowy i testowania klasyfikatorów. Wyniki klasyfikacji porównano z wynikami uzyskanymi dla 48 cech otrzymanych za pomocą metody korelacji. Okazało się, że dokładność klasyfikatorów zbudowanych ze zbioru liczącego 3 cechy nie jest gorsza od dokładności klasyfikatorów dla 48 cech, a w kilku przypadkach nawet ją przewyższa. Sugeruje to, że metoda Hellwiga może być wykorzystana jako wydajna metoda redukcji wymiaru przestrzeni cech dla potrzeb przyszłej klasyfikacji obrazów USG tarczycy.

Słowa kluczowe: metoda Hellwiga, choroba Hashimoto, przetwarzanie obrazów, klasyfikacja tekstur

THE USE OF HELLWIG'S METHOD FOR DIMENSION REDUCTION IN FEATURE SPACE OF THYROID ULTRASOUND IMAGES

Abstract. This paper presents the use of Hellwig's method for dimension reduction in feature space of thyroid ultrasound images. On the base of this method, the combination of three features with the greatest value of Hellwig's index information capacity from the input set of 283 features was obtained. This set was used to build and test the classifiers. Classification results were compared with the results obtained for a set of 48 features obtained using correlation method. It turned out that the accuracy of classifiers built on the base of 3 features is not worse than the accuracy of classifiers built on the base of 48 features, and in some cases it is even higher. This suggests that the Hellwig's method can be used as an effective method for dimension reduction in feature space for the future thyroid ultrasound images classification.

Keywords: Hellwig's method, Hashimoto's disease, image processing, texture classification

Wstęp

Jedną z chorób tarczycy jest choroba związana z zaburzeniami układu odpornościowego organizmu, zwana chorobą Hashimoto. Podstawową metodą jej diagnozowania jest obecnie metoda ultrasonograficzna. Jednak, wykrycie w ten sposób wczesnego stadium rozwoju choroby jest zadaniem bardzo trudnym. Z punktu widzenia skuteczności terapii, bardzo ważne jest natomiast wykrycie choroby jak najwcześniej. Dlatego też niezwykle istotne jest zwiększenie skuteczności wykrywania wczesnego stadium choroby na podstawie wyników badań ultrasonograficznych. Wydaje się, iż może tutaj znaleźć zastosowanie system komputerowy, który wykorzystując odpowiednią metodę automatycznej klasyfikacji obrazów, wspomagałaby lekarza w procesie diagnozy [15, 16]. Zdjęcia USG tarczycy, w procesie analizy obrazu, są traktowane jako obrazy teksturowe. Niestety, w literaturze można znaleźć niewiele wyników badań tekstur obrazów USG tarczycy ukierunkowanych na diagnozę choroby Hashimoto. Część z nich prezentuje rozwiązania wykorzystujące proste metody analizy i przetwarzania obrazów [5, 12-14, 18, 19, 21]. Inne badania oparte są na bardziej zaawansowanych metodach analizy tekstur [9, 10]. Natomiast część publikacji opisuje wpływ metody pomiaru cech obrazu oraz ustawień aparatury pomiarowej na dokładność otrzymywanych wyników [7, 8, 22, 23].

Aktualne badania, których przedmiotem są obrazy USG tarczycy, koncentrują się najczęściej na dwóch typowych stanach gruczołu – tarczycy zdrowej oraz dotkniętej chorobą Hashimoto w zaawansowanej postaci. Nie są znane wyniki dotyczące wykrywania wczesnego stadium rozwoju tej choroby. Dlatego też podjęto własne badania, których celem jest znalezienie wskaźników diagnostycznych, w postaci wektora cech obrazów USG tarczycy, charakteryzujących wczesne stadium rozwoju choroby Hashimoto. Wektor ten, zostanie w dalszej części badań wykorzystany do budowy klasyfikatora wspomagającego lekarza w procesie diagnozy. Początkowym etapem, przed rozpoczęciem analizy skupień czy klasyfikacji, jest redukcja wymiaru przestrzeni cech. Można ją zrealizować za pomocą jednej z wielu popularnych metod, np.: analizy składowych głównych, analizy czynnikowej, skalowania wielowymiarowego, odwzorowania Sammon'a, relacyjnych map perspektyw czy map Kohonena. Zadanie to można także wykonać za pomocą metody wskaźników pojemności informacyjnej. Metoda ta wykorzystuje algorytm

Hellwiga, często stosowany w zagadnieniach z obszaru ekonometrii [6].

W niniejszej pracy zaprezentowano wyniki działania algorytmu Hellwiga, za pomocą którego otrzymano 3 cechy z wejściowego zbioru 283 cech charakteryzujących obrazy USG tarczycy. Wyniki te porównano z wynikami uzyskanymi na podstawie metody opartej na korelacji pomiędzy badanymi cechami (zmiennymi objaśniającymi) a zmienną decyzyjną (zmienną objaśnianą). Tą drugą metodą otrzymano zbiór 48 cech. Oba wyjściowe zbiory posłużyły do budowy klasyfikatorów przypisujących analizowane przypadki do jednej z dwóch klas – *chory* lub *zdrowy*. Średnia dokładność klasyfikacji uzyskana z 20-tu prób była podstawą do porównania skuteczności obu metod w redukcji wymiaru przestrzeni cech. Do budowy klasyfikatorów wykorzystano liniową i kwadratową analizę dyskryminacyjną, drzewa klasyfikacyjne, metodę najbliższych sąsiadów oraz lasy losowe. Wspomniane metody zostały dokładnie opisane w wielu pozycjach, m.in. w [1-3, 11, 20].

W rozdziale pierwszym scharakteryzowano metodę bazującą na algorytmie Hellwiga, zwaną także metodą wskaźników pojemności informacyjnej. Przetwarzanie wstępne zdjęć USG scharakteryzowano w rozdziale drugim, natomiast opis i wyniki eksperymentu zamieszczono w rozdziale trzecim. Całość pracy kończy podsumowanie.

1. Metoda Hellwiga

Metoda Hellwiga (metoda wskaźników pojemności informacyjnej) wykorzystuje do obliczeń współczynniki korelacji między zmiennymi, są to: wektor współczynników korelacji R_0 między zmienną objaśnianą Y a zmiennymi objaśniającymi X_1, X_2, \dots, X_n oraz macierz współczynników korelacji R między zmiennymi objaśniającymi X_1, X_2, \dots, X_n :

$$R_0 = \begin{bmatrix} r_1 \\ r_2 \\ \vdots \\ r_n \end{bmatrix}, \quad R = \begin{bmatrix} 1 & r_{12} & \cdots & r_{1n} \\ r_{12} & 1 & \cdots & r_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ r_{1n} & r_{2n} & \cdots & 1 \end{bmatrix}, \quad (1)$$

gdzie n jest liczbą obserwacji. Celem obliczeń jest znalezienie najlepszej kombinacji zmiennych objaśniających, czyli kombinacji o największym integralnym wskaźniku pojemności informacyjnej. Wybierane są zatem zmienne objaśniające silnie skorelowane

ze zmienną objaśnianą oraz słabo skorelowane między sobą. Do wyboru jest $L = 2^n - 1$ kombinacji zmiennych objaśniających X_1, X_2, \dots, X_n . Realizacja obliczeń według metody Hellwiga składa się z trzech zasadniczych etapów:

1. Obliczenie indywidualnych wskaźników pojemności informacyjnej dla wszystkich kombinacji:

$$h_{kj} = \frac{r_j^2}{1 + \sum_{\substack{i=1 \\ i \neq j}}^m |r_{ij}|}, \quad (2)$$

gdzie: k – numer kombinacji ($k = 1, 2, \dots, l$), j – numer zmiennej w kombinacji ($j = 1, 2, \dots, m$).

2. Obliczenie integralnych wskaźników pojemności informacyjnej dla wszystkich kombinacji:

$$H_k = \sum_{j=1}^m h_{kj}, \quad k = 1, 2, \dots, l \quad (3)$$

3. Wybór kombinacji optymalnej, posiadającej największy integralny wskaźnik pojemności informacyjnej H . Zmienne z tej kombinacji powinny zostać wykorzystane do budowy przyszłego modelu.


2. Przetwarzanie wstępne zdjęć USG

Materiał do badań zawierał serie zdjęć należące do 60-ciu pacjentów. Wśród nich było 28 osób zdrowych oraz 32 chore, u których rozpoznano chorobę Hashimoto. Dla niemalże wszystkich pacjentów wykorzystano zdjęcia lewego i prawego płatu tarczycy w przekroju podłużnym. Wyjątek stanowiły dwie osoby zdrowe i jedna chora, w przypadku których wykorzystano zdjęcia tylko lewego lub prawego płatu gruczołu. W efekcie otrzymano 108 próbek dla przypadków rozpoznanych jako zdrowe oraz 126 dla chorych (w sumie 234 przypadki). Zdjęcia USG poddano kadrowaniu w celu wyodrębnienia obszarów zainteresowania (ROI) do dalszego przetwarzania i analizy. Wybór liczby ROI podyktowany był wcześniejszym szacowaniem liczebności próby tak, aby zapewnić osiągnięcie zadowalającego efektu klinicznego (wrażliwość klasyfikacji ponad 80%) oraz zakładanej mocy testu istotności statystycznej osiągniętych wyników (0,8) [17]. Z kolei, rozmiar ROI dobrany był tak, aby maksymalnie wykorzystać powierzchnię teksturowanej potencjalną informację, oferowaną przez obraz gruczołu w przekroju podłużnym. Zastosowano ROI o szerokości 200 i wysokości 150 pikseli, przy czym na podstawie jednego obrazu USG tworzone były 2 ROI (rys. 1). Wyodrębnione fragmenty zdjęć poddano konwersji z trybu RGB do skali szarości oraz normalizacji zakresu jasności z korekcją liniową. W wyniku ekstrakcji cech dyskryminacyjnych, otrzymano zbiór 283 deskryptorów cech obrazu. Wykorzystano do tego celu: wektor histogramu obrazu (9 cech), macierz gradientu obrazu (5 cech), macierz rozkładu długości pasm (5 cech x 4 kierunki), macierz przejść tonalnych (11 cech x 4 kierunki x 5 odległości), model autoregresji (5 cech) oraz dyskretną transformatę falkową (24 cechy) [4].

3. Opis i wyniki eksperymentu

Redukcja wymiaru przestrzeni cech. Wejściowy zbiór 283 cech dyskryminacyjnych został zredukowany dwiema metodami. W pierwszej, wybrano wszystkie cechy, których korelacja ze zmienną decyzyjną była istotna (poziom istotności $\alpha = 0,05$). W efekcie otrzymano zbiór 48 cech. W metodzie drugiej zastosowano algorytm Hellwiga, który uporządkował kombinacje cech pod względem wartości wskaźnika pojemności informacyjnej, zwanego też wskaźnikiem Hellwiga (tab. 1). Maksymalną liczbę cech w analizowanych kombinacjach ustawiono na 10. W wyniku obliczeń okazało się, że najwyższą wartość wskaźnika Hellwiga, równą 0,358, posiada kombinacja

trzech cech. Są to cechy nr 256 – parametr Θ_2 modelu autoregresji zakładającego, że jasność danego piksela jest uzależniona od jasności pikseli z jego otoczenia, 277 – energia współczynnika falkowego dla podpasma LH w piątej skali oraz 279 – energia współczynnika falkowego dla podpasma HH w piątej skali.



Rys. 1. Rozmieszczenie regionów zainteresowania na tle przekroju podłużnego płata tarczycy. Rysunek odzwierciedla rzeczywiste proporcje pomiędzy wymiarami gruczołu na zdjęciu USG a wielkością ROI

Tabela 1. Zestaw pierwszych dziesięciu kombinacji cech z największą wartością wskaźnika Hellwiga

Numer	Kombinacja cech	Wskaźnik Hellwiga
1	256-277-279	0,358
2	256-277-279-283	0,345
3	256-275-277-279	0,332
4	216-256-277-279	0,330
5	227-256-277-279	0,329
6	205-256-277-279	0,328
7	172-256-277-279	0,326
8	256-257-277-279	0,326
9	183-256-277-279	0,326
10	256-275-277-279-283	0,324

Zbiory danych. Oba zbiory danych uzyskane w wyniku redukcji liczby cech zostały następnie wykorzystane do klasyfikacji. Jej celem było przypisanie analizowanych przypadków do jednej z dwóch klas – *chory* lub *zdrowy*. Cały zbiór danych zawierał 234 przypadki, przy czym proporcja przypadków zdrowych do chorych wynosiła 108/126 (46% zdrowych i 54% chorych). Na drodze losowania, dokonano podziału tego zbioru na zbiór treningowy i testowy. Współczynnik podziału – zbiór treningowy / zbiór testowy wyniósł 2/3, czyli 156 przypadków stanowiło zbiór treningowy oraz 78 – zbiór testowy. W obu zbiorach zachowano proporcję pomiędzy liczbą przypadków zdrowych i chorych. W efekcie zbiór treningowy składał się z 72 przypadków zdrowych i 84 chorych a testowy z 36 zdrowych i 42 chorych. Klasyfikacja była realizowana 20-krotnie, dlatego też w sposób losowy przygotowano 20 zbiorów treningowych i 20 testowych. W celu zapewnienia maksymalnej zgodności, zbiory treningowe i testowe dla danych wybranych metodą korelacji oraz metodą Hellwiga zostały zbudowane z tych samych obserwacji (te same indeksy obserwacji).

Metody klasyfikacji. Podczas klasyfikacji wykorzystano liniową analizę dyskryminacyjną, kwadratową analizę dyskryminacyjną, drzewa klasyfikacyjne (algorytm CART z wartością współczynnika kary $cp = 0,00001$), metodę najbliższych sąsiadów (dla $k = 1$) oraz lasy losowe. Dla obu metod redukcji wymiaru przestrzeni cech ustawiono identyczne parametry klasyfikacji. Nie była dokonywana optymalizacja działania klasyfikatorów, a więc otrzymane wyniki dotyczą całego zbioru cech, tj. czterdziestu ośmiu w pierwszym przypadku i trzech w drugim. Do oceny jakości działania klasyfikatorów zastosowano dokładność klasyfikacji, zdefiniowaną jako stosunek liczby wszystkich poprawnych klasyfikacji do liczby klasyfikowanych przypadków. Budowę i testowanie klasyfikatorów przeprowadzono w środowisku R [24].


Wyniki i dyskusja. Dokładność klasyfikacji dla 20-tu prób zestawiono w tab. 2. Z kolei na rys. 2. przedstawiono wartości

średnie dokładności klasyfikacji dla poszczególnych metod. Jedynie dla lasów losowych średnia dokładność klasyfikacji dla metody Hellwiga (72,564%) okazała się nieco mniejsza od metody korelacji (74,038%). Różnica ta wyniosła ok. 1,5%. W przypadku metody najbliższych sąsiadów, dokładność była niemal taka sama w obu przypadkach. Dla metody korelacji wyniosła ona 66,987%, zaś dla metody Hellwiga 66,538%. Dla pozostałych trzech metod klasyfikacji, zastosowanie metody Hellwiga do redukcji wymiaru przestrzeni cech poprawiło dokładność klasyfikacji. W przypadku drzew klasyfikacyjnych, poprawa ta wyniosła 1,6%, dla kwadratowej analizy dyskryminacyjnej 4,4%, a dla liniowej analizy dyskryminacyjnej 3,4%. Widać zatem, że ograniczenie liczby cech z 48 do 3, dla większości

zastosowanych w eksperymencie metod klasyfikacji, nie tylko nie pogorszyło dokładności klasyfikacji ale wręcz ją nieznacznie poprawiło. Należy w tym miejscu przypomnieć, iż nie była dokonywana optymalizacja działania klasyfikatorów, polegająca na odrzuceniu cech mniej istotnych oraz wprowadzających szum. Teoretycznie, mogłaby ona doprowadzić do pewnej poprawy dokładności klasyfikacji w przypadku metody korelacji. Jednak niezależnie od tego, otrzymane wyniki pokazują, iż drastyczne zmniejszenie liczby cech z 48 do 3 nie pogarsza własności wynikowego zbioru danych w kontekście budowy klasyfikatorów. Dlatego też, metoda Hellwiga wydaje się być interesującą alternatywą dla popularnych metod redukcji wymiaru przestrzeni cech.

Tabela 2. Dokładność klasyfikacji (w %) dla 20-tu prób uzyskana dla wymiaru przestrzeni cech zredukowanego metodą korelacji (KOR) oraz metodą Hellwiga (HEL); Oznaczenia: LDA - liniowa analiza dyskryminacyjna, QDA - kwadratowa analiza dyskryminacyjna, CART - drzewa klasyfikacyjne, kNN - metoda najbliższych sąsiadów, RF - lasy losowe

Nr próby	LDA		QDA		CART		kNN		RF	
	KOR	HEL	KOR	HEL	KOR	HEL	KOR	HEL	KOR	HEL
1	75,641	71,795	66,667	70,513	57,692	58,974	67,949	69,231	73,077	70,513
2	71,795	75,641	62,821	74,359	70,513	69,231	69,231	58,974	78,205	71,795
3	82,051	75,641	75,641	75,641	64,103	64,103	65,385	62,821	73,077	64,103
4	70,513	76,923	69,231	73,077	65,385	70,513	69,231	69,231	73,077	74,359
5	70,513	83,333	74,359	79,487	57,692	64,103	58,974	66,667	71,795	69,231
6	73,077	75,641	66,667	78,205	61,538	64,103	61,538	65,385	71,795	70,513
7	75,641	75,641	70,513	74,359	65,385	71,795	65,385	66,667	80,769	74,359
8	74,359	76,923	75,641	73,077	70,513	65,385	66,667	71,795	74,359	69,231
9	76,923	80,769	79,487	76,923	71,795	74,359	76,923	71,795	78,205	76,923
10	66,667	78,205	71,795	74,359	66,667	61,538	64,103	70,513	76,923	74,359
11	84,615	78,205	75,641	76,923	70,513	67,949	69,231	65,385	80,769	69,231
12	78,205	83,333	69,231	78,205	62,821	64,103	66,667	69,231	82,051	78,205
13	71,795	79,487	70,513	78,205	61,538	73,077	71,795	69,231	69,231	74,359
14	71,795	75,641	71,795	73,077	66,667	61,538	60,256	62,821	64,103	65,385
15	71,795	71,795	67,949	71,795	58,974	69,231	67,949	65,385	74,359	74,359
16	73,077	80,769	65,385	79,487	65,385	61,538	70,513	67,949	75,641	74,359
17	70,513	76,923	73,077	71,795	58,974	70,513	61,538	62,821	70,513	74,359
18	79,487	83,333	71,795	76,923	70,513	70,513	69,231	69,231	76,923	82,051
19	65,385	74,359	62,821	73,077	62,821	62,821	62,821	60,256	66,667	70,513
20	84,615	82,051	74,359	74,359	71,795	67,949	74,359	65,385	69,231	73,077
Średnia	74,423	77,821	70,769	75,192	65,064	66,667	66,987	66,538	74,038	72,564



Rys. 2. Średnia dokładność klasyfikacji dla poszczególnych klasyfikatorów oraz wymiaru przestrzeni cech zredukowanego metodą korelacji i metodą Hellwiga

4. Podsumowanie

W artykule porównano wyniki redukcji wymiaru przestrzeni cech uzyskane za pomocą metody korelacji oraz metody Hellwiga. Zbiór wejściowy liczył 283 cechy. Został on ograniczony do czterdziestu ośmiu cech za pomocą pierwszej metody oraz do trzech – za pomocą drugiej. Oba wyjściowe zbiory zostały następnie wykorzystane do budowy i testowania popularnych klasyfikatorów. Otrzymane wyniki pokazały, że dokładność klasyfikatorów zbudowanych ze zbioru liczącego 3 cechy nie jest gorsza od dokładności klasyfikatorów zbudowanych ze zbioru 48 cech, a w kilku przypadkach nawet ją przewyższa. Wyniki te sugerują, że metoda Hellwiga może być stosowana jako wydajna metoda redukcji wymiaru przestrzeni cech dla potrzeb przyszłej klasyfikacji obrazów USG tarczycy. Osiągnięta dokładność klasyfikacji na poziomie ponad 70% stwarza interesujące możliwości wykorzystania cech wyselekcjonowanych za pomocą metody Hellwiga do realizacji procesu grupowania obiektów. Dlatego też, w toku dalszych badań podjęta zostanie próba wyłonienia, w wyniku grupowania, naturalnych skupisk obiektów dających się w sensowny sposób interpretować. Sprawdzona zostanie także możliwość separacji, w grupie przypadków chorych, tych obiektów, które mogą zawierać symptomy wczesnego stadium rozwoju choroby Hashimoto.

Literatura

- [1] Cichosz P.: Systemy uczące się. Wydawnictwa Naukowo-Techniczne, Warszawa, 2007.
- [2] Ćwik J., Koronacki J.: Statystyczne systemy uczące się. Wydawnictwa Naukowo-Techniczne, Warszawa, 2005.
- [3] Ćwik J., Mielniczuk J.: Statystyczne systemy uczące się. Ćwiczenia w oparciu o pakiet R. Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa, 2009.
- [4] Haralick R., Shanmugam K., Dinstein I.: Textural Features for Image Classification. IEEE Transactions on Systems, Man and Cybernetics, Vol. 3, No 6, 610-621, 1973.
- [5] Hayashi N., Tamaki N.: Sonography of Hashimoto's thyroiditis. J. Clin. Ultrasound, Vol. 14, 1986, pp. 123-126.
- [6] Hellwig Z.: On the optimal choice of predictors. Study VI in Z. Gostkowski (ed.): Toward a system of quantitative indicators of components of human resources development; Paris: UNESCO, 1968.
- [7] Koprowski R., Korzyńska A., Wróbel Z., Zieleźnik W., Witkowska A., Małysek J., Wójcik W.: Influence of the measurement method of features in ultrasound images of the thyroid in the diagnosis of Hashimoto's disease. BioMedical Engineering OnLine 2012, 11:91, DOI:10.1186/1475-925X-11-91
- [8] Koprowski R., Wróbel Z., Zieleźnik W.: Automatic ultrasound image analysis in Hashimoto's disease. Lect. Notes in Comput. Sci. – Adv. in Pattern Recognit. Vol. 6256, 2010, pp. 98-106.
- [9] Koprowski R., Wróbel Z., Zieleźnik W.: Analysis of thyroid ultrasonogram in Hashimoto's disease. The 2010 International Congress on Computer Applications and Computational Science. IRAST, Singapore, 2010, pp. 448-451.
- [10] Koprowski R., Zieleźnik W., Wróbel Z., Małysek J., Stępień B., Wójcik W.: Assessment of significance of features acquired from thyroid ultrasonograms in Hashimoto's disease. BioMedical Engineering OnLine 2012, 11:48, DOI:10.1186/1475-925X-11-48
- [11] Krzyżko M., Wołyński W., Górecki T., Skorzybut M.: Systemy uczące się. Rozpoznawanie wzorców analiza skupień i redukcja wymiarowości. Wydawnictwa Naukowo-Techniczne, Warszawa, 2008.
- [12] Loy M., Cianchetti M.E., Cardia F., Melis A., Boi F., Mariotti S.: Correlation of computerized gray-scale sonographic findings with thyroid function and thyroid autoimmune activity in patients with Hashimoto's thyroiditis. J. Clin. Ultrasound, Vol. 32(3), 2004, pp. 136-140.
- [13] Mailloux G., Bertrand M., Stampfler R., Ethier S.: Computer analysis of echographic textures in Hashimoto disease of the thyroid. J. Clin. Ultrasound, Vol. 14(7), 1986, pp. 521-527.
- [14] Mazzotii G., Sorvillo F., Iorio S., Carbone A., Romeo A., Piscopo M., Capuano S., Capuano E., Amato G., Carella C.: Grey-scale analysis allows a quantitative evaluation of thyroid echogenicity in the patients with Hashimoto's thyroiditis. Clin. Endocrinol. Vol. 59, 2003, pp. 223-229.
- [15] Omiotek Z., Burda A., Wójcik W.: Metoda klasyfikacji obrazów USG tarczycy z wykorzystaniem indukcji drzew decyzji. Prace Instytutu Elektrotechniki, Zeszyt 260, 2012 s. 57-68.
- [16] Omiotek Z., Burda A., Wójcik W.: The use of decision tree induction and artificial neural networks for automatic diagnosis of Hashimoto's disease. Expert Systems with Applications (2013), DOI: <http://dx.doi.org/10.1016/j.eswa.2013.03.022>
- [17] Petrie A., Sabin C.: Statystyka medyczna w zarysie. Wydawnictwo Lekarskie PZWL, Warszawa 2006.
- [18] Sara R., Smutek D., Sucharda R., Svacina S.: Systematic Construction of Texture Features for Hashimoto's Lymphocytic Thyroiditis Recognition from Sonographic Images. In 8th Conference on Artificial Intelligence in Medicine in Europe. AIME, Cascais, Portugal, 2001, pp. 339-346.
- [19] Schiemann U., Gellner R., Riemann B., Schierbaum G., Menzel J., Domschke W., Hengst K.: Standardized grey scale ultrasonography in Graves' disease: correlation to autoimmune activity. Eur. J. Endocrinol. Vol. 141(4), 1999, pp. 332-336.
- [20] Stapor K.: Metody klasyfikacji obiektów w wizji komputerowej. Wydawnictwo Naukowe PWN, Warszawa, 2011.
- [21] Uwe S., Avenhaus W., Konturek J., Gellner R., Hengst K., Gross M.: Relationship of clinical features and laboratory parameters to thyroid echogenicity measured by standardized grey scale ultrasonography in patients with Hashimoto's thyroiditis. Med. Sci. Monit. Vol. 9(4), 2003, pp. 49-53.
- [22] Zieleźnik W., Małysek-Tumidajewicz J., Stęchły T., Stępień B., Wójcik W., Owczarek A.: The analysis of thyroid ultrasound echogenicity in the patients with hashimoto's disease. Eur Thyroid J, 5:160, 2011.
- [23] Zieleźnik W., Witkowska A., Małysek-Tumidajewicz J., Koprowski R., Stępień B., Owczarek A., Koprowski R., Wójcik W.: The new method of analysis thyroid echogenicity in the patients with Hashimoto's disease. Sent to Thyroid, 2012.
- [24] Strona domowa środowiska R: <http://www.r-project.org/>

Mgr inż. Zbigniew Omiotek
e-mail: zomiotek@gmail.com

Absolwent Wydziału Elektroniki WAT w Warszawie. W latach 1995-2000 asystent w Instytucie Podstaw Elektroniki WAT. Od 2000 r. asystent w Katedrze Informatyki i Inżynierii Wiedzy WSZiA w Zamościu, a od 2011 r. doktorant na Wydziale Elektrotechniki i Informatyki Politechniki Lubelskiej. Zainteresowania naukowe skupiają się wokół metod analizy i rozpoznawania obrazów medycznych.



Prof. dr hab. inż. Waldemar Wójcik
e-mail: waldemar.wojcik@pollub.pl

Ukończył studia na Politechnice Wrocławskiej - Wydział Elektroniki (1975), doktorat obronił na Politechnice Lubelskiej (1985), a habilitację na Politechnice Lwowskiej (2001). W 2009 otrzymał tytuł profesora nauk technicznych. W swoim dorobku ma ponad 50 monografii, ponad 400 prac naukowych oraz 6 patentów. Jest współautorem ok. 20 opracowań dla przemysłu dotyczących światłowodowych sieci kontrolno-pomiarowych i teleinformatycznych.



otrzymano/received: 01.10.2013

przyjęto do druku/accepted: 24.02.2014