

Algorytm kompresji danych dla interfejsu mózg-komputer

Streszczenie. Przedstawiony algorytm kompresji danych dla interfejsu mózg-komputer (BMI) pozwala na kodowanie sygnałów neuronowych z przepływnością ok. 0.25 bity na próbkę, przy zniekształceniach mniejszych jak 3% rms. Dzięki redukcji transmitowanych danych kompletny, wielokanałowy system BMI wraz z układem telemetrii i anteną magnetyczną może być implantowany w całości pod skórą badanego zwierzęcia. Pełna podskórna implantacja redukuje prawdopodobieństwo rozwoju infekcji i umożliwia obserwację zwierzęcia w jego naturalnym środowisku.

Abstract. Presented data compression algorithm dedicated to Brain-Machine Interface (BMI) system enables encoding of neural signals at data rate of 0.25 bits per sample with distortions below 3% rms. Reduction of transmitted data enables implantation of complete, multichannel BMI system along with telemetry unit and magnetic antenna. Full implantation of BMI system is essential for minimization risk of developing infections and enabling the animal to interact freely with the environment. (**Data compression algorithm for brain-machine interface**).

Słowa kluczowe: interfejs mózg-komputer, kompresja sygnałów neuronowych, transformacja falkowa

Keywords: brain-machine interface, neural signal compression, discrete wavelet transform

Wstęp


Ogromny postęp poczyniony przez mikroelektronikę i inżynierię materiałową umożliwił projektowanie i realizację zaawansowanych, wielokanałowych systemów interfejsu mózg-komputer BMI (ang. brain machine interface systems). Najbardziej zaawansowane z obecnie konstruowanych systemów BMI pozwalają na równoczesną stymulację wielu setek neuronów oraz rejestrację sygnałów elektrycznych pochodzących nawet z kilkuset neuronów równocześnie [1], [2], [3]. W systemach tych wykorzystuje się nowoczesne elektrody wytwarzane na podłożu krzemowym w technologii MEMS (ang. micro-electro-mechanical systems), które oprócz miniaturowych platynowych kontaktów elektrycznych integrują matryce przełączników w postaci tranzystorów MOS wraz z kompletną elektroniką sterującą [4]. Ogromną korzyścią ze zastosowania takich elektrod jest możliwość wyboru do rejestracji tylko tych sygnałów, które pochodzą z neuronów znajdujących się możliwie blisko kontaktów elektrycznych elektrody, a więc gwarantujących odpowiednią jakość sygnału wyrażoną poprzez stosunek sygnał-szum (SNR).

Równoległa rejestracja sygnałów pochodzących z setek elektrod powoduje konieczność bezprzewodowej transmisji ogromnych ilości danych. Przykładowo, system o 100 elektrodach, przy częstotliwości próbkowania 25 kHz i rozdzielczości 8 bitów, generuje strumień danych o przepływności 20 Mbps. By móc w pełni korzystać w praktyce klinicznej z takich systemów muszą być one w pełni implantowalne. Oznacza to konieczność ścisłej integracji elektrod i elektroniki odczytowej, a także układu zasilania bezprzewodowego, nadajnika radiowego, a nawet anteny transmisyjnej. Dopiero tak zaprojektowany SoC (ang. system-on-chip) może być wszczepiony pod skórę, co zapewnia minimalizację prawdopodobieństwa infekcji oraz daje możliwość obserwacji obiektu badań w jego naturalnym środowisku.

Niestety, obecnie dostępne systemy przezskórnej bezprzewodowej telemetrii oferują szybkość transmisji na poziomie ok. 2 Mbps [5]. Ograniczenie to wiąże się ze stosunkowo wysoką przewodnością elektryczną tkanek, a więc wysokim stopniem tłumienia składowej elektrycznej fali elektromagnetycznej. Dlatego w systemach transmisji przezskórnych stosuje się nośną z pasma ISM o możliwie niskiej częstotliwości (433 MHz) oraz anteny typu magnetycznego, które niestety cechują się węższym pasmem, w porównaniu do ich elektrycznych odpowiedników.

Sposobem na ominięcie ograniczeń przezskórnej

telemetrii jest kompresja transmitowanych danych. Stosowane algorytmy bazują na obserwacji, że informacja przesyłana pomiędzy poszczególnymi neuronami ma kształt wąskiej szpilki napięciowej (rys.1), nazywanej przez neurologów potencjałem czynnościowym AP (ang. action potential). Najprostsze algorytmy kompresji stosują metodę progowania celem detekcji chwili wystąpienia AP [6]. Moment wystąpienia danego AP kodowany jest jako odległość, wyrażona poprzez liczbę próbek sygnału znajdujących się pomiędzy kolejnymi AP. Dodatkowo możliwe jest dołączenie informacji o wartości amplitudy wykrytej szpilki. Taka metoda posiada dwie zasadnicze wady: 1) prowadzi do utraty informacji o kształcie AP, który w części eksperymentów neurobiologicznych jest bardzo istotny, oraz 2) jest mało efektywna w przypadku sygnałów o niskiej wartości SNR. Dlatego, w pracy [7] zaproponowano modyfikację tego algorytmu polegającą na wysłaniu krótkiego fragmentu sygnału zlokalizowanego wokół wykrytego AP. Inne podejście, polegające na ekstrakcji specyficznych cech i klasyfikacji wykrytych AP zaproponowano w pracy [8]. Oczywiście wadą takiej metody jest wysoka złożoność obliczeniowa oraz trudności z oceną wartości SNR. Odmianą metody [7] jest metoda, która do ekstrakcji fragmentu sygnału wokół AP wykorzystuje operację progowania, która realizowana jest nie na sygnale w dziedzinie czasu, lecz na współczynnikach jego rozwinięcia falkowego [9] lub względem funkcji Walsh-Hadamard'a WHT [10]. Niestety, metoda ta również jest mało efektywna przy niskich wartościach SNR.



Rys. 1. Sygnał aktywności elektrycznej neuronu.

W niniejszej pracy proponuje się algorytm wykorzystujący rozwinięcie falkowe sygnału celem dekorelacji jego próbek, które następnie poddawane są kwantyzacji i kodowaniu przy pomocy kodera entropijnego uwzględniającego charakter kodowanego sygnału.

Proponowany algorytm pozwala na dobór stopnia kompresji do przepustowości stosowanego układu transmisji oraz pełną rekonstrukcję całego sygnału, nie tylko fragmentów wokół AP. Dzięki temu możliwa jest klasyfikacja sygnałów AP jak i ocena wartości SNR w poszczególnych kanałach systemu BMI. Dodatkowo możliwa jest adaptacja algorytmu do łącznej kompresji sygnałów reprezentujących lokalnych potencjałów polowych (LFP), które obrazują wypadkową aktywność elektryczną większej grupy neuronów, oraz czynnościowych - obrazujących aktywność pojedynczego neuronu w takiej grupie. System wyposażony w taki algorytm umożliwia pozyskanie możliwie kompletnej informacji (LFP+AP) o zachodzących procesach w tkance neuronowej badanego organizmu.

Kryteria oceny działania algorytmu

Celem oceny skuteczności pracy algorytmu przyjęto następujące miary. 1) Wartość *rms-pp* (ang. root-mean-square) błędu rekonstrukcji odniesioną do wartości maksymalnej sygnału potencjału czynnościowego AP

$$(1) \quad rms-pp = \frac{1}{x_{pp}} \sqrt{\frac{1}{N} \sum_i (\hat{x}_i - x_i)^2} \cdot 100\%,$$

gdzie x_i oraz \hat{x}_i są odpowiednio próbkami sygnału oryginalnego i zrekonstruowanego, zaś x_{pp} jest wartością sygnału od szczytu-do-szczytu (ang. peak-to-peak).

2) Wartość entropii współczynników falkowych rozwinięcia sygnału. Entropia Shannona dyskretnego źródła o alfabecie $X=\{x_1, x_2, \dots, x_N\}$ i prawdopodobieństwach wystąpienia symboli $P=\{p_1, p_2, \dots, p_N\}$ określona jest wzorem

$$(2) \quad H(x) = -\sum p(x_i) \log_2 p(x_i),$$

gdzie $\log_2 p(x_i)$ jest liczbą bitów potrzebnych do reprezentacji symbolu x_i . Wartość $H(x)$ może być interpretowana jako średnia długość kodu binarnego potrzebnego do reprezentacji pojedynczego symbolu wysyłanego przez źródło w sposób statystycznie niezależny. Zatem, entropia stanowi dolne ograniczenie na długość kodu. Kod o długości równej wartości entropii źródła, nazywany jest kodem optymalnym.

W przypadku dekompozycji falkowej (lub subpasmowej) możliwa jest niezależna kompresja współczynników reprezentacji sygnału na poszczególnych poziomach dekompozycji. Wtedy można napisać

$$(3) \quad H_{sb}(x) = \sum 2^{-j} H(d_j) + 2^{-K} H(a_K),$$

gdzie $H(d_j)$ jest entropią współczynników reprezentujących detale sygnału na j -tym poziomie dekompozycji, zaś $H(a_K)$ jest entropią współczynników reprezentujących aproksymację sygnału.

3) Zazwyczaj skonstruowanie kodu o średniej długości równej entropii nie jest możliwe. W związku z tym, jakość kodowania entropowego, będąca równocześnie miarą uzyskiwanej kompresji, określono poprzez współczynnik *bps* (ang. bits per sample), tj. średnią liczbę bitów potrzebną do reprezentacji pojedynczej próbki sygnału

$$(4) \quad bps = N_C / N_0.$$

W powyższym wzorze N_C jest liczbą bitów wymaganą do zapisania skompresowanego sygnału, zaś N_0 jest liczbą próbek kompresowanego sygnału.


Transformacja liniowa sygnału

Celem transformacji liniowej sygnału jest uzyskanie możliwie wysokiego stopnia upakowania energii próbek kompresowanego sygnału x . Efektywność pakowania energii dla danej transformacji T określa stosunek średniej

arytmetycznej do średniej geometrycznej wariancji współczynników $y=Tx$ sygnału

$$(5) \quad G_{TC} = 10 \log_{10} \left[\frac{\sum_{n=0}^{N-1} \sigma_n^2 / N}{\left(\prod_{n=0}^{N-1} \sigma_n^2 \right)^{1/N}} \right],$$


gdzie σ_n^2 jest wariancją współczynników y_n wektora y . Z postaci G_{TC} wynika, że kolejnym istotnym czynnikiem mającym wpływ na efektywność danej transformacji jest liczba podpasm N . Niestety wraz ze wzrostem N rośnie złożoność obliczeniowa i pamięciowa procesu transformacji, a także samego kodowania entropowego współczynników. Dlatego, by określić optymalną liczbę poziomów dekompozycji wyznaczono wartości funkcji autokorelacji sygnału AP (rys.2). Funkcja ta przyjmuje istotne wartości dla argumentu nie większego od 8. Dlatego, jako kompromis pomiędzy złożonością obliczeniową algorytmu a stopniem kompresji, do dekompozycji sygnału wybrano transformację subpasmową (falkową) o 3-ch poziomach dekompozycji.



Rys. 2. Unormowana funkcja autokorelacji sygnału aktywności elektrycznej neuronu.

Transformacja interpolacyjna

Każdą transformację falkową [11], ortogonalną bądź biortogonalną, można przedstawić w postaci schematu predykcja - uaktualnienie, który ma formę drabinki. W tym schemacie najprostszą realizację mają transformacje interpolacyjne zbudowane z dwóch filtrów realizujących operacje predykcji P i uaktualnienia U (rys.3). W trakcie badań symulacyjnych stwierdzono, że filtry P i U mające więcej niż 4 współczynniki nie dają istotnego wzrostu stopnia kompresji. Dlatego w dalszej części pracy ograniczono się do transformacji PU z filtrami o dwóch lub czterech współczynnikach.



Rys. 3. Schemat prostej i odwrotnej transformacji falkowej PU.


Transformacja DB-5/3 i DB-9/7

Transformacje DB-5/3 i DB-9/7 należą do klasy biortogonalnych transformacji falkowych. Różnią się one między sobą stopniem gładkości i złożoności obliczeniowej. Cenną własnością tych transformacji, jak też i innych transformacji biortogonalnych, jest symetryczna odpowiedź impulsowa filtrów. W [11] pokazano że transformacje te można przedstawić w wersji predykcyjnej. Realizacja transformacji DB-9/7 w wersji predykcyjnej pokazana jest

na rysunku 4, zaś transformacja DB-5/3 opisana jest równaniami:

$$d(n) = d_0(n) + [0.5(s_0(n+1) + s_0(n))],$$


$$(6) \quad s(n) = s_0(n) + [0.25(d(n) + d(n-1)) + 0.5].$$



Rys. 4. Transformacja DB-9/7 wg schematu predykcja-korekcja, $\alpha = -203/128$, $\beta = -217/4096$, $\gamma = 113/128$, $\kappa = 1817/4096$.


Celem wyboru optymalnej transformacji dla omawianego algorytmu wyznaczono zależność błędu rekonstrukcji (1) w funkcji entropii współczynników transformacji (3) sygnału (rys. 5). Zmianę entropii współczynników wymuszono poprzez ich kwantyzację. W przypadku transformacji PU pod uwagę wzięto transformacje z filtrami P i U mającymi po 4 współczynniki (PU-444) oraz transformacje, gdzie filtry P i U miały po 2 współczynniki na dwóch pierwszych poziomach dekompozycji oraz 4 na poziomie ostatnim (PU-224). Dodatkowo uwzględniono transformację S+P z dwoma wariantami predyktorów [12].

Jak widać, przy transformacji PU osiąga się najniższą wartość błędu rekonstrukcji przy danej wartości entropii (kompresji). Dlatego, proponowany algorytm oparto na transformacji PU-224, która cechuje się znacznie niższym kosztem realizacji jak PU-444.




Rys. 5. Błąd rekonstrukcji (1) sygnału w funkcji entropii (3) współczynników transformacji sub-pasmowej.

Przy ocenie dopuszczalnego poziomu zniekształceń wprowadzanych do rejestrowanego sygnału przez algorytm kompresji, wskutek kwantyzacji współczynników, należy uwzględnić poziom szumów własnych elektroniki układu BMI oraz amplitudę sygnału AP (ok. 100 μ V). Poziom szumów wejściowych wzmacniacza systemu BMI zdefiniowany jest przede wszystkim poziomem szumów termicznych źródła sygnału, tj. elektrody. Ze względu na bardzo małą powierzchnię czynną elektrody, przewodność środowiska, w tym ściany komórkowej neuronu, rezystancja źródła sygnału waha się pomiędzy 100 k Ω , a 1 M Ω . Gęstość widmowa szumów termicznych określona jest zależnością $4kTR$, gdzie k jest stałą Boltzmanna, zaś T temperaturą wyrażoną w Kelwinach. Zatem, przy $R = 1$ M Ω w temperaturze $T=310$ K i szerokości pasma systemu równym 25 kHz otrzymuje się wartość napięcia szumów 20 μ V $_{rms}$, co stanowi ok. 20 % amplitudy AP. Tak więc błąd rekonstrukcji proponowanego algorytmu (rys.6) na poziomie 3% wartości AP jest w pełni akceptowalny.



Rys. 6. Fragment sygnału (oryginal i rekonstrukcja) obejmujący AP. (PU224, entropia = 0.2, błąd $rms=2.5\%$, $bps=0.23$).



Rys. 7. Unormowane histogramy skwantowanych współczynników transformacji reprezentujące detale sygnału AP (3 górne wykresy) oraz jego aproksymacje (ostani wykres).

Kodowanie entropijne współczynników transformacji

Zadaniem kodera entropijnego jest zakodowanie współczynników rozwinięcia falkowego sygnału przy użyciu jak najmniejszej liczby bitów. Analizując histogramy współczynników transformaty sygnału (rys.7) można zauważyć, że ogromna większość współczynników reprezentujących detale sygnału w rozwinięciu falkowym ma wartości równe zero, co oznacza że ich entropia jest bardzo niska. Efektywne kodowanie źródła w warunkach bardzo niskiej entropii wymaga użycia złożonego kodera arytmetycznego, lub uprzedniej transformacji ciągu kodowanych symboli do postaci par liczb (L, ν) , gdzie L oznacza liczbę współczynników zerowych (zer) poprzedzających współczynnik niezerowy (ν). W niniejszej pracy wybrano podejście drugie, znane w literaturze jako kodowanie ciągów RLE (ang. run-length encoding). Wadą metody RLE jest znaczny rozrost alfabetu używanego do reprezentacji wartości pierwszego elementu pary (L). Skutkuje to wzrostem złożoności pamięciowej kodera entropijnego, który używany jest do zapewnienia odpowiednio wysokiego, końcowego współczynnika kompresji. By ograniczyć ten wzrost, w niniejszej pracy, ciągi zer o długości większej jak 255 rozbito na podciągi o długości ograniczonej do 255.

Dalszą redukcję złożoności pamięciowej procesu kodowania entropijnego można osiągnąć poprzez reprezentację interwałową kodowanych współczynników. W praktyce stosuje się dwa typy kodów interwałowych. Pierwszy to kod VLC (ang. Variable Length Code) znany z algorytmu JPEG, drugi to kod MS-VLC [12] (ang. Magintude Set VLC). W kodzie VLC kodowaną liczbę zapisuje się w postaci pary dwóch liczb. Pierwsza z nich określa długość

rozwiązania dwójkowej kodowanej liczby, druga jest jej rozwiązaniem dwójkowym. Zwykle, kodowaniu entropijnemu (np. metodą Huffmana) podlega tylko pierwszy element tej pary. Element drugi zapisywany jest do strumienia wyjściowego wg prostej reguły: jeśli kodowany współczynnik ma wartość x , a zapis binarny jego modułu $itob(|x|)$ ma b cyfr, to dla $x > 0$ emituje się ciąg $itob(|x|)$, w przeciwnym razie emituje się b bitów otrzymanych z ciągu $itob(|x|)$ przez negację wszystkich bitów.

W przypadku reprezentacji MS-VLC [12], kodowaniu entropijnemu podlega tylko numer odpowiednio skonstruowanego przedziału, do którego należy kodowana wartość. Ponadto, do strumienia wynikowego zapisuje się znak kodowanej liczby oraz różnicę pomiędzy modulem kodowanej wartości, a dolnym krańcem przedziału.

Tabela 1. Zależność współczynnika kompresji (4) od stopnia kwantyzacji (Q) współczynników dla różnych koderów entropijnych. HE – koder Huffmana, HE+VLC – koder Huffmana z reprezentacją VLC, HE-MS – koder Huffmana z reprezentacją MS-VLC, GR – koder Goloba-Rice'a.

Lp.	Q	rms-pp [%] (1)	H_{sb} (3)	Współczynnik kompresji (4)			
				HE	HE+VLC	HE+MS	GR
1	4	0,76	1,25	1,27	1,38	1,32	1,34
2	8	1,21	0,67	0,69	0,76	0,73	0,72
3	12	1,55	0,44	0,45	0,51	0,48	0,49
4	16	1,84	0,33	0,34	0,39	0,37	0,36
5	20	2,09	0,27	0,28	0,33	0,32	0,30
6	24	2,30	0,23	0,24	0,29	0,28	0,26
7	28	2,50	0,20	0,22	0,26	0,26	0,23
8	32	2,68	0,17	0,20	0,24	0,24	0,21

Poszczególne metody kodowania entropijnego różnią się od siebie wydajnością i kosztem implementacji. Dlatego, w niniejszej pracy oprócz trzech wariantów kodera opartego o algorytm Huffmana zaimplementowano dodatkowo koder adaptacyjny Golomba-Rice'a. Algorytm Golomba-Rice'a reprezentuje kodowaną liczbę całkowitą $x \geq 0$ w postaci dwóch ciągów bitowych: unarnego prefiksu o długości $\lfloor x/2^k \rfloor$, po którym następuje k najbardziej znaczących bitów liczby x [13]. Przykładowo, kod Golomba-Rice'a o parametrze $k=2$ dla $x=10$ ma postać '11010', w której '110'=2 to prefiks w kodzie unarnym, zaś '10'=2 to dwa najstarsze bity kodowanej liczby x . Długość kodu zależy od parametru k i wynosi $\lfloor x/2^k \rfloor + 1 + k$. Można pokazać [14], że optymalna wartość k dla ciągu współczynników o rozkładzie wykładniczym dwustronnym wynosi:

$$(7) \quad k = (\log_2(\bar{x} + 1)),$$

gdzie \bar{x} jest wartością oczekiwaną zmiennej x . W prezentowanym algorytmie, celem estymacji parametru k , wykorzystano dwa rejestry: rejestr A przechowujący sumę modułów kodowanych współczynników oraz rejestr N , stanowiący licznik kodowanych współczynników. W oparciu o wartości tych rejestrów estymowana jest wartość parametru k dla każdego sub-pasma z osobna:

$$(8) \quad k = \min\{k : 2^k N \geq A\}.$$

Ilekcioć wartość zliczeń w rejestrze N przekroczy próg N_0 , zawartości rejestrów N i A dzielone są przez 2. W ten sposób z jednej strony obniżono złożoność implementacyjną wyrażenia (8), z drugiej zaś zapewniono odpowiednią szybkość adaptacji parametru k do zmian statystyk kodowanych współczynników. W badaniach symulacyjnych stwierdzono, że optymalna wartość progu N_0 to 16. Uzyskane wyniki, dla wszystkich testowanych koderów, zestawiono w Tablicy 1.

Podsumowanie

W artykule przedstawiono algorytm kompresji danych dla systemu BMI. Dzięki zastosowaniu predykcyjnej transformacji falkowej, do dekorrelacji próbek sygnału, uzyskano niższą złożoność obliczeniową proponowanego algorytmu w porównaniu do [9]. Zastąpienie operacji progowania współczynników operacją ich kwantyzacji pozwoliło na użycie opisanego algorytmu do kompresji sygnałów zawierających informację zarówno o potencjałach polowych jak i czynnościowych. Redukcję złożoności pamięciowej operacji kodowania entropijnego współczynników transformacji sygnału osiągnięto poprzez użycie adaptacyjnego kodera Golomba-Rice'a.

Praca wykonana w ramach działalności statutowej.

LITERATURA

- [1] Aziz J.N, Abdelhalim K., Shulyzki R., Genov R., Bardakjian B., Derchansky M., Carlen P., "256-channel neural recording and delta compression microsystem with 3D electrodes," *IEEE Journal of Solid-State Circuits*, 44, (2009), 995-1005.
- [2] P. Kmon, P. Grybos, "Energy Efficient Low-Noise Multichannel Neural Amplifier in Submicron CMOS Process," *IEEE Trans. on Circuits and Systems I: Regular Papers*, 99, (2013), 1-12.
- [3] P. Kmon, "Digitally assisted neural recording and spike detection multichannel integrated circuit designed in 180 nm CMOS technology," *Microelectronics Journal*, 45, 9 spec. Iss., (2014), 1187-1193.
- [4] Torfs, T., Aarts, A. A., Erismis, M. A., Aslam, J., Yazicioglu, R. F., Seidl, K., Herwik S., Ulbert I., Dombovari B., Fiath R., Kerekes B. P., Puers R., Paul O., Ruther P., Hoof C. V., Neves H. P.: "Two-Dimensional Multi-Channel Neural Probes With Electronic Depth Control," *IEEE Trans. Biomed. Circuits and Sys.* 5, (2011), 403-412.
- [5] P. Turcza, "Low power 2 Mbps radio telemetry system for biomedical applications," ECCTD 2013 - European Conference on Circuit Theory and Design : 8-12 September 2013, Dresden.
- [6] R. R. Harrison, P. T. Watkins, R. J. Kier, R. O. Lovejoy, D. J. Black, B. Greger, F. Solzbacher, "A low-power integrated circuit for a wireless 100-electrode neural recording system," *IEEE Journal of Solid-State Circuits*, 42, (2007), 123-133.
- [7] Y. Perelman, R. Ginosar, "An integrated system for multichannel neuronal recording with spike/LFP separation, integrated A/D conversion and threshold detection," *IEEE Trans. on Biomed. Eng.*, 54, (2007), 130-137.
- [8] C. Moo, Y. Zhi, M. R. Yuce, H. Linh, W. Liu, "A 128-channel 6 mW wireless neural recording IC with spike feature extraction and UWB transmitter," *IEEE Trans. Neural Syst. Rehabil. Eng.*, 17, (2009), 312-321.
- [9] F. Zhang, M. Aghagolzadeh, K. Oweiss, "A Fully Implantable, Programmable and Multimodal Neuroprocessor for Wireless, Cortically Controlled Brain-Machine Interface Applications," *J Sign Process Syst* 69, (2012), 351-361.
- [10] H. Hosseini-Nejad, A. Jannesari, A. M. Sodagar, "Data Compression in Brain-Machine/Computer Interfaces Based on the Walsh-Hadamard Transform," *Biomedical Circuits and Systems, IEEE Transactions on*, 8(1), (2014), 129-137.
- [11] I. Daubechies, W. Sweldens, "Factoring wavelet transforms into lifting steps," *J. Fourier Anal. Appl.*, 4 (1998), 245-267.
- [12] Said A., Pearlman W.A.: *An image multiresolution representation for lossy image compression*, IEEE Trans. Image Process., 5(9):1303-1310, 1996.
- [13] Rice R. F.: Some practical universal noiseless coding techniques, Tech. Rep. JPL-79-22, Jet Propulsion Laboratory, Pasadena, CA, Mar. 1979.
- [14] Memon N.: Adaptive coding of DCT coefficients by Golomb-Rice codes, in Proc. ICIP, vol. 1, Chicago, IL, pp. 516-520, 1998.

Autorzy: dr inż. Paweł Turcza, E-mail: turcza@agh.edu.pl, dr inż. Zbigniew Marszałek, E-mail: antic@agh.edu.pl, dr inż. Mirosław Socha, E-mail: socha@agh.edu.pl, AGH w Krakowie, Katedra Metrologii i Elektroniki, al. Mickiewicza 30, 30-059 Kraków.