



## Analiza falkowa potencjałów czynnościowych jednostek ruchowych

ANDRZEJ P. DOBROWOLSKI, KAZIMIERZ TOMCZYKIEWICZ\*

Wojskowa Akademia Techniczna, Wydział Elektroniki, Instytut Systemów Elektronicznych,  
00-908 Warszawa, ul. S. Kaliskiego 2

\*Wojskowy Instytut Medyczny, Klinika Neurologiczna,  
00-909 Warszawa, ul. Szaserów 128

**Streszczenie.** Statystyczne opracowanie parametrów przebiegów czasowych potencjałów czynnościowych jednostek ruchowych zapewnia w większości przypadków prawidłową diagnozę, ale ze względu na niejednoznaczność w określaniu parametrów czasowych oraz ich liczbę, niezbędne jest duże doświadczenie neurologa interpretującego wyniki. W artykule zaprezentowano nową metodę diagnozowania chorób nerwowo-mięśniowych, opartą na liniowej analizie dyskryminacyjnej skalogramów wyznaczonych za pomocą falek *Symlet 4 rzędu*. Z otrzymanych w wyniku transformacji falkowej skalogramów wyekstrahowano sześć parametrów falkowych, które sprowadzono do pojedynczego parametru umożliwiającego dyskryminację przypadków prawidłowych, miogennych i neurogennych. Implementacja programowa proponowanej metody umożliwiła stworzenie komputerowego narzędzia diagnostycznego wspomagającego badanie elektromiograficzne o bardzo wysokim prawdopodobieństwie prawidłowej oceny stanu mięśnia.

**Słowa kluczowe:** elektromiografia ilościowa (QEMG), potencjał czynnościowy jednostki ruchowej (PJR), transformata falkowa, skalogram, diagnostyka medyczna

**Symbole UKD:** 616-07

### 1. Wstęp

*Elektromiografia (EMG)* jest badaniem czynnościowym odgrywającym podstawową rolę w diagnostyce chorób nerwowo-mięśniowych. Pozwala m.in. na odróżnienie zapisu mięśnia zdrowego od chorobowo zmienionego oraz określenie, czy zmiany mają charakter pierwotnie mięśniowy czy neurogenny. Badanie EMG — szerzej opisane w pracach [1, 2] — polega na wprowadzeniu do mięśnia elek-

trody igłowej i rejestracji potencjałów z mięśnia w spoczynku oraz podczas słabego i maksymalnego wysiłku. Zarejestrowane potencjały noszą nazwę *potencjałów czynnościowych jednostek ruchowych* — PJR (ang. *motor unit action potential* — MUAP, MUP). Podczas badania, w celu oceny różnych fragmentów mięśnia, elektroda jest wielokrotnie przemieszczana. PJR przedstawia krzywą ilustrującą depolaryzację i repolaryzację włókna mięśniowego, a charakter tej krzywej świadczy o prawidłowej bądź nieprawidłowej czynności elektrycznej jednostki ruchowej. W trakcie skurczu mięśnia, zależnie od jego siły, angażowana jest mniejsza lub większa liczba jednostek ruchowych. Przy lekkim skurczu mięśnia można wyróżnić pojedyncze potencjały jednostek ruchowych, przy skurczu silniejszym lub maksymalnym poszczególne potencjały nakładają się na siebie, tworząc *zapis interferencyjny*, będący efektem sumowania w czasie i przestrzeni potencjałów różnych jednostek ruchowych. Diagnoza z reguły poprzedzona jest statystyczną analizą kształtu [3, 4], a w szczególności amplitudy i czasu trwania oraz powierzchni PJR — tzw. *elektromiografia ilościowa* (ang. *Quantitative EMG* — QEMG). Aby zapewnić wiarygodność analizy statystycznej, konieczny jest pomiar co najmniej 20 różnych potencjałów, przy czym nie uwzględnia się przebiegów o wartości międzyszczytowej mniejszej od 50  $\mu$ V. Kryterium wyboru potencjałów stanowi co najmniej pięciokrotne wystąpienie w tym samym zapisie potencjałów o zbliżonym kształcie.


W ostatnich latach, w celu zwiększenia wartości diagnostycznej pomiarów elektromiograficznych, stosuje się m.in. parametry statystyczne wyższych rzędów [5], sztuczne sieci neuronowe [6], analizę widmową [1, 2, 7, 8, 9]<sup>1</sup> i falkową [10], filtrację cyfrową [11] oraz techniki modelowania [12]. Główną zaletą zaprezentowanej niżej metody falkowej jest brak konieczności precyzyjnego wyznaczenia początku i końca PJR oraz pozostałych — przedstawionych w kolejnym rozdziale — parametrów definiowanych w dziedzinie czasu. W praktyce wartości podstawowych parametrów czasowych podlegają subiektywnej ocenie diagnosty i często bywają przez niego modyfikowane, przez co trudna jest ich jednoznaczna interpretacja i porównywanie danych pochodzących z różnych ośrodków klinicznych. W niniejszym artykule prezentujemy propozycję pozbawionego powyższych wad efektywnego parametru diagnostycznego wyznaczanego na podstawie skalogramów potencjałów czynnościowych jednostek ruchowych.

---

<sup>1</sup> Neurolog podczas badania z reguły „wysłuchuje się” w brzmieniu potencjałów czynnościowych jednostek ruchowych i uzyskuje tą drogą istotną informację diagnostyczną. Ponieważ ludzkie ucho reaguje na widmo sygnału, a nie na kształt przebiegu czasowego, celowe jest poszukiwanie wartościowych parametrów diagnostycznych właśnie w widmie sygnału.

## 2. Analiza czasowa

Tradycyjna analiza potencjałów czynnościowych jednostek ruchowych realizowana w dziedzinie czasu wymaga wyznaczenia parametrów, uśrednienia ich w całym zbiorze PJR-ów pochodzących z badanego mięśnia oraz porównania wyników z obowiązującymi normami [13]. Definicje parametrów czasowych potencjałów czynnościowych jednostek ruchowych zilustrowane są na rysunku 1, natomiast parametry prawidłowych PJR mięśnia naramiennego (*deltoid*) określone dla populacji zdrowych dorosłych ludzi umieszczone są w tabeli 1 [2, 13].



Rys. 1. Ilustracja parametrów potencjału czynnościowego jednostki ruchowej podczas słabego skurczu:  $A$  — amplituda PJR;  $t_w$  — czas trwania PJR;  $t_i$  — czas trwania impulsu;  $S$  — powierzchnia PJR;  $l_F$  — liczba faz (liczba odchyłeń potencjału od linii podstawy);  $l_Z$  — liczba zwrotów (liczba punktów zmiany kierunku)

TABELA 1

Parametry (wartości średnie  $\pm$  odchylenia standardowe) prawidłowych potencjałów czynnościowych jednostek ruchowych mięśnia naramiennego

$A$ [ $\mu$ V]	$t_w$ [ms]	$t_i$ [ms]	$S$ [ $\mu$ V $\cdot$ ms]	$l_F$
$550 \pm 110$	$10,4 \pm 1,3$	$4,18 \pm 0,75$	$858 \pm 210$	$2,98 \pm 0,28$

Podczas analizy wyników należy mieć świadomość, że w przedziale  $\pm \sigma$  wokół wartości średniej mieści się zaledwie 68% przypadków, dla  $\pm 2 \sigma$  jest to już 95%, a przedział  $\pm 2,5 \sigma$  pokrywa 98,8%, czyli „praktycznie” całą populację. W praktyce medycznej przyjęto jako normę zakres  $\pm 2,0 \sigma$  wokół wartości średniej. Główny problem diagnostyczny pojawiający się niejednokrotnie podczas stosowania analizy czasowej polega na często występującym częściowym pokrywaniu się przedziałów  $\pm 2 \sigma$  w przypadkach fizjologicznych i patologicznych.

Dodatkowym parametrem diagnostycznym jest tzw. *polifazja* definiowana jako procentowy udział potencjałów wielofazowych (polifazowych), tj. potencjałów, dla których liczba faz przekracza normę, w całkowitej liczbie potencjałów zarejestrowanych w badanym mięśniu. Przykładowo, jeśli dla mięśnia naramiennego liczba faz potencjału czynnościowego przekracza 3,54, tzn. jeśli wynosi ona 4 lub więcej, to taki przebieg traktujemy jako tzw. potencjał wielofazowy. Jeśli wśród wszystkich potencjałów zmierzonych w danym mięśniu takich potencjałów jest więcej niż 15% (niektórzy badacze przyjmują 20%), czyli typowo 3-4 potencjały, to mówimy o wystąpieniu zwiększonej polifazji.

Generalnie — w odniesieniu do kształtu przebiegu PJR — można stwierdzić, że w przypadkach uszkodzeń neurogennych pojawia się tzw. *zapis neurogenny* charakteryzujący się wydłużonym czasem trwania i wysokimi amplitudami PJR oraz zwiększoną polifazją, natomiast w przypadkach uszkodzeń pierwotnie mięśniowych mamy do czynienia z tzw. *zapisem miogennym*, charakteryzującym się krótkim czasem trwania i niskimi amplitudami PJR oraz również zwiększoną polifazją.

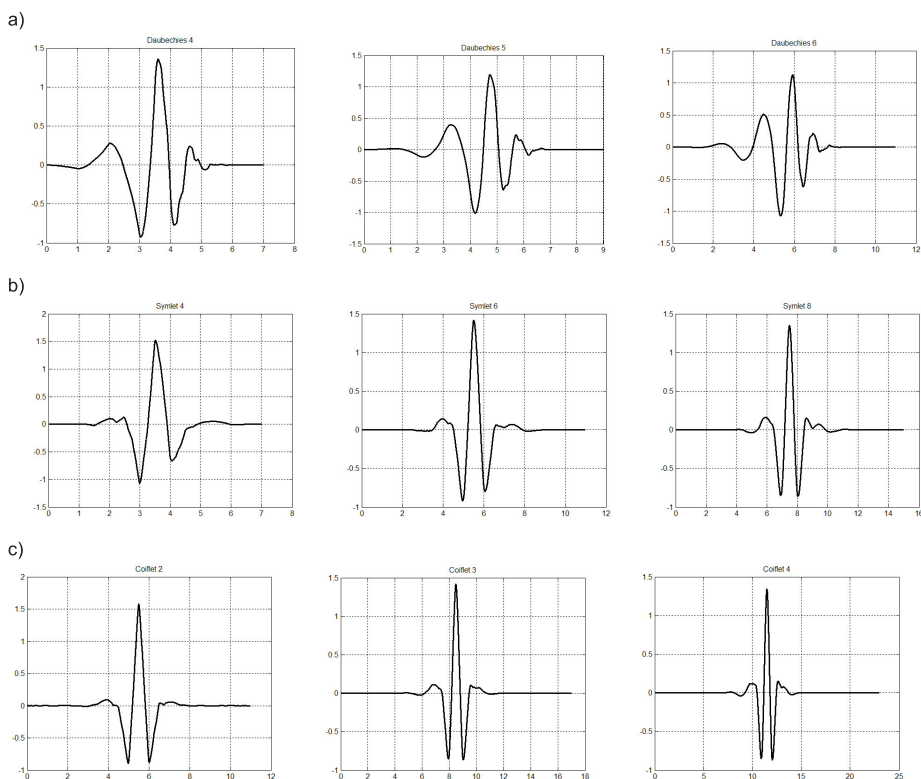
### 3. Wybór rodzaju falki

Ze względu na szybkość wykonywania obliczeń (*algorytm Mallata* [14, 15]) oraz bezproblemową rekonstrukcję sygnału, umożliwiającą bieżącą kontrolę działania algorytmu, zdecydowano się na realizowalne szybkim algorytmem dyskretnej transformaty falkowej (ang. *DWT — Discrete Wavelet Transform*) przekształcenie na bazie falek ortogonalnych o zwartym nośniku. Do wstępnej selekcji wybrano falki *Daubechies* oraz falki z rodzin *Symlet* i *Coiflet* [16].

Falki *Daubechies* stanowią obecnie najpopularniejszą i najczęściej wykorzystywaną rodzinę falek. Ich podstawowe zalety to zwarty nośnik o długości  $2N-1$ , gdzie  $N$  określa rząd falki, dokładna aproksymacja funkcji stałych i liniowych oraz stosunkowo prosta postać. Falka *Daubechies* pierwszego rzędu jest tożsama z falką Haara — pierwszą historycznie i najprostszą funkcją falkową. Falki *Symlets* charakteryzujące się „prawie symetrycznymi” filtrami zostały zaproponowane przez I. Daubechies jako modyfikacja falek *Daubechies* (bez zmiany długości nośnika). Falki *Coiflets* zostały zaprojektowane również przez I. Daubechies na prośbę R. Coifmana w celu linearyzacji charakterystyki fazowej filtrów analizy i syntezy poprzez minimalizację

asymetrii współczynników. Falki te mają stosunkowo małą asymetrię, co osiągnięto kosztem wyraźnego zwiększenia długości nośnika falki (do  $6N-1$ ).

Można zauważyć, że we wszystkich przedstawionych grupach wraz ze wzrostem rzędu wzrasta gładkość falki i jej funkcji skalującej, przy czym falki najniższych rzędów (Daubechies rzędu 1, 2 i 3, Symlet rzędu 2 i 3 oraz Coiflet rzędu 1) charakteryzują się wyjątkowo ostrymi załamaniami. Jednocześnie wraz ze wzrostem rzędu rosną amplitudy skrajnych oscylacji oraz, ze względu na zwiększanie się długości filtrów, istotnie rośnie czas wykonywania obliczeń. Zakładając, że optymalne do analizy będą falki o kształcie zbliżonym do przeciętnego przebiegu PJR, rozważany zbiór falek ograniczono do zestawu przedstawionego na rysunku 2, wykluczając z wyżej przedstawionych powodów falki najniższych i wyższych rzędów. Ponadto w przypadku falek z rodziny Symlet odrzucono falki rzędów nieparzystych ze względu na ich wyraźną asymetrię.



Rys. 2. Falki wyselekcjonowane do dalszej analizy: a) Daubechies rzędu 4, 5 i 6; b) Symlet rzędu 4, 6 i 8; c) Coiflet rzędu 2, 3 i 4

Podobnie jak kształty falek, tak też kształty uśrednionych skalogramów wyznaczonych z ich wykorzystaniem, a w szczególności ich maksima na poszczególnych poziomach są bardzo do siebie zbliżone. O wyborze falki zdecydowała więc głównie jakość dyskryminacji uzyskana za jej pomocą. Ponadto wzięto pod uwagę długości filtrów analizy i syntezy oraz wymaganą liczbę poziomów. Ilościowo jakość dyskryminacji można określić za pomocą parametrów  $\gamma_M$  i  $\gamma_N$ , przedstawionych w kolejnych rozdziałach artykułu.

#### 4. Metodyka badań

Podlegający ocenie diagnostycznej skalogram potencjału jednostki ruchowej obliczany jest za pomocą algorytmu Mallata, na podstawie wycinka sygnału o stałym czasie trwania. Pierwotny sygnał mierzony przez neurologa w systemie *Viking IV D* [1, 2] ma długość 2000 próbek, co przy częstotliwości próbkowania  $f_p = 20$  kHz odpowiada czasowi 100 ms. Ponieważ umowny — ze względu na specyficzny sposób wyzwalania pomiaru — środek impulsu, tzw. *trigger point* wypada w systemie *Viking IV D* w 40 ms ( $n_{tp} = 799$ ), a czasy trwania przebiegów PJR z reguły nie przekraczają znacząco 15 ms, autorzy zdecydowali się na analizę wycinka czasowego o długości 20 ms (401 próbek), zawartego między  $n_{\min} = 599$  i  $n_{\max} = 999$  ( $30 \div 50$  ms). W celu wyizolowania tego fragmentu sygnał oryginalny jest okienkowany za pomocą okna prostokątnego, przy czym po 5 skrajnych próbek sygnału (początkowych i końcowych) poddanych jest dodatkowemu okienkowaniu z wykorzystaniem okna Hanninga. Jest to zabieg kompromisowy pomiędzy zastosowaniem typowego okienkowania za pomocą nieprostokątnej funkcji okna a oknem całkowicie prostokątnym, zapewniający optymalny *preprocessing* sygnału. W ramach wstępnego przetwarzania przebieg PJR jest ponadto synchronizowany z siatką czasowo-częstotliwościową.

Obserwacja wielu różnorodnych przebiegów PJR wskazuje, że istotna informacja diagnostyczna zawarta jest w paśmie od 50 Hz do 1 kHz. Górna granica zakresu została przyjęta doświadczalnie na podstawie obserwacji, wskazującej, że powyżej tej częstotliwości poziom widma zaczyna zbliżać się do poziomu szumów i zakłóceń. Dolna granica  $f_{\min} = 50$  Hz wynika z przyjętego czasu obserwacji ( $1/20$  ms = 50 Hz). Wynika stąd, że już na wstępie można pominąć poziomy pierwszy (pseudoczęstotliwość wszystkich rozważanych falek na poziomie pierwszym  $f_1 \approx 7$  kHz) oraz ósmy ( $f_8 \approx 55$  Hz) i wyższe. Dodatkowymi argumentami za wstępnym odrzuceniem tych poziomów są bliskość częstotliwości Nyquista na poziomie pierwszym oraz bliskość częstotliwości sieci na poziomie ósmym (silny filtr pasmowo-zaporowy). Ponadto pobieżna analiza skalogramów i rekonstrukcji sygnału wskazuje, że składowa na poziomie pierwszym niesie mniej niż 1% energii. Udział składowej z poziomu ósmego bywa znacznie wyższy, ale nie zmienia istotnie kształtu PJR — zmienia się jedynie poziom „pływającej składowej stałej”.

Na podstawie wielu pilotażowych analiz statystycznych, eksperymentów i obliczeń stwierdzono, że istotną informację diagnostyczną niosą wartości maksymalne skalogramu na poszczególnych poziomach. Analiza falkowa przy przyjętych założeniach wstępnych daje więc do dyspozycji sześć cech charakterystycznych, które mogą posłużyć do konstrukcji klasyfikatora. Są to wyrażone w  $[\mu\text{W}]$  wartości maksymalne skalogramu na poziomach od 2 do 7:  $M_2, M_3, M_4, M_5, M_6$  i  $M_7$ .

Analiza statystyczna sześciu cech falkowych ( $M_2, M_3, M_4, M_5, M_6$  i  $M_7$ ) wsparta dużym doświadczeniem autorów doprowadziła do wstępnego przetworzenia tych cech, w wyniku którego otrzymano siedem cech charakterystycznych, które posłużyły do konstrukcji quasi-optimalnego klasyfikatora falkowego. Są to: wartość maksymalna skalogramu (maksimum globalne)  $M_g$  wyrażona w  $[\mu\text{W}]$  oraz maksima na poziomach od 2 do 7 wyrażone w procentach maksimum globalnego:  $m_2, m_3, m_4, m_5, m_6$  i  $m_7$ .

Reasumując, zbiór cech falkowych charakteryzujących pojedynczy potencjał czynnościowy jednostki ruchowej określony jest następującym układem równań:

$$\begin{cases} M_g = \max \{M_2, M_3, M_4, M_5, M_6, M_7\} \\ m_g = \frac{M_g}{\mu \text{ W}} \\ m_i = \frac{M_i}{M_g} \cdot 100, \quad \text{dla } i = 2, 3, 4, 5, 6, 7. \end{cases} \quad (1)$$

Podczas każdego badania rejestruje się  $K$  przebiegów PJR, przy czym  $K$  nie powinno być mniejsze od 20. Dla każdego przebiegu oblicza się przedstawione wyżej cechy i wyznacza się ich wartości średnie dla całego badania, wg zależności

$$\begin{cases} c_1 = \frac{1}{K} \sum_{k=1}^K m_{gk} \\ c_i = \frac{1}{K} \sum_{k=1}^K m_{ik}, \quad \text{dla } i = 2, 3, 4, 5, 6, 7. \end{cases} \quad (2)$$

Klasyfikator falkowy  $F$  służący do różnicowania przypadków miogennych, neurogennych i prawidłowych, określony jest zależnością

$$F = \alpha \log \left( c_1 \sum_{i=2}^7 k_i c_i \right) + \beta. \quad (3)$$

Nieliniowe przetworzenie za pomocą funkcji logarytmicznej zastosowano, biorąc pod uwagę dynamikę zmian w całej populacji badanych pacjentów. Seria eksperymentów z różnymi wariantami zależności (3) potwierdza zdecydowaną poprawę zdolności dyskryminacyjnej po zastosowaniu logarytmowania. Parametry  $\alpha$  i  $\beta$  skalują klasyfikator  $F$  do zakresu wygodnego w praktyce lekarskiej (wartość średnia 50, odchylenie standardowe 5).

## 5. Materiał i wyniki badań

Badania przeprowadzono na 161-osobowej grupie osób dorosłych (w wieku od 16 do 78 lat — średni wiek 35 lat) obojga płci (w tym 89 kobiet i 72 mężczyzn). W grupie tej 114 osób było zdrowych, u 13 stwierdzono miopatię, a u pozostałych 34 neuropatię. W każdym przypadku analizowano po 20 przebiegów PJR pochodzących z mięśnia naramiennego.

Wybór optymalnej falki wymagał wykonania żmudnych obliczeń, polegających na wyznaczeniu dla każdej rozważanej falki zbioru siedmiu współczynników  $k_i$  maksymalizujących określoną niżej funkcję celu oraz wykonaniu serii obliczeń z wykorzystaniem tych współczynników. W trakcie realizacji badań wyznaczono dla każdej falki trzy zestawy współczynników maksymalizujących funkcję celu dla przypadków:

- najlepszego rozróżnienia przebiegów miogennych od prawidłowych,
- najlepszego rozróżnienia przebiegów neurogennych od prawidłowych,
- najlepszego rozróżnienia jednocześnie przebiegów miogennych od prawidłowych i neurogennych od prawidłowych.

Dla każdej z dziewięciu falek wyznaczone zostały trzy pary współczynników określających jakość dyskryminacyjną rozróżniania przypadków zdrowych od miogennych  $\gamma_M$  oraz zdrowych od neurogennych  $\gamma_N$ . Współczynniki te zdefiniowane są jako odległość wartości średnich klasyfikatora  $F$  dla przypadku prawidłowego i chorobowo zmienionego odniesiona do podwojonej wartości sumy odchyłeń standardowych tego klasyfikatora dla obu przypadków

$$\gamma_M = \frac{|\mu_P - \mu_M|}{2(\sigma_P + \sigma_M)}, \quad \gamma_N = \frac{|\mu_P - \mu_N|}{2(\sigma_P + \sigma_N)} \quad (4)$$

gdzie:  $\mu_P, \mu_M, \mu_N, \sigma_P, \sigma_M, \sigma_N$  — wartości średnie i odchylenia standardowe klasyfikatora dla przypadków prawidłowych, miogennych i neurogennych.



Współczynniki  $k_i$  optymalizowano w celu maksymalizacji współczynników  $\gamma_M$  i  $\gamma_N$  oraz ich iloczynu  $\gamma_M \gamma_N$ . Dodatkowo, w celu bezpośredniego porównania zdolności dyskryminacyjnej poszczególnych falek, wprowadzono parametr całościowy sumujący maksymalne wartości parametrów  $\gamma$  dla każdej falki

$$\Sigma = (\gamma_M)_{\max} + (\gamma_N)_{\max} + (\gamma_M \gamma_N)_{\max} \quad (5)$$

Wyniki obliczeń przedstawione w tabeli 2 pokazują, że różnice są wprawdzie niewielkie, ale jednak umożliwiają ograniczenie zbioru rozważanych falek do trzech charakteryzujących się najlepszym wskaźnikiem  $\Sigma$ . Są to falki Daubechies rzędu 4, Symlet rzędu 4 i Coiflet rzędu 2. Najważniejsze z punktu widzenia analizy dyskryminacyjnej cechy wybranych falek zebrano w tabeli 3.

Biorąc pod uwagę zebrane w tabeli 3 cechy, jako optymalną przyjęto falekę **Symlet 4**. Poza najlepszą wartością całościowego wskaźnika  $\Sigma$ , falka Symlet 4, podobnie jak falka Daubechies 4, charakteryzuje się stosunkowo krótkim filtrem, co znacznie przyspiesza obliczenia. Jednocześnie, jedynie w przypadku falki Symlet 4 analiza optymalizacyjna współczynników  $k_i$  wyznaczyła zerową wartość współczynnika związanego z drugim poziomem, co oznacza, że nie wpływa on na zdolności dyskryminacyjne wypadkowego klasyfikatora.

TABELA 2

Parametry określające jakość dyskryminacji uzyskaną przy zastosowaniu rozważanych falek

	Opt. $\lambda_M$	Opt. $\lambda_N$	Opt. $\lambda_M \lambda_N$	Opt. $\lambda_M$	Opt. $\lambda_N$	Opt. $\lambda_M \lambda_N$	Opt. $\lambda_M$	Opt. $\lambda_N$	Opt. $\lambda_M \lambda_N$
Falka	<i>Daubechies 4</i>			<i>Daubechies 5</i>			<i>Daubechies 6</i>		
$\lambda_M$	1,13	0,74	1,11	1,08	0,75	1,05	1,06	0,73	1,02
$\lambda_N$	0,89	1,03	0,93	0,88	1,03	0,93	0,85	0,99	0,92
$\lambda_M \lambda_N$	1,01	0,76	1,03	0,95	0,77	0,98	0,90	0,72	0,94
$\Sigma$	3,19			3,09			2,99		
Falka	<i>Symlet 4</i>			<i>Symlet 6</i>			<i>Symlet 8</i>		
$\lambda_M$	1,14	0,75	1,12	1,10	0,73	1,08	1,09	0,74	1,06
$\lambda_N$	0,90	1,03	0,94	0,88	1,04	0,93	0,86	1,02	0,90
$\lambda_M \lambda_N$	1,03	0,77	1,05	0,97	0,76	1,00	0,94	0,75	0,95
$\Sigma$	3,22			3,14			3,06		
Falka	<i>Coiflet 2</i>			<i>Coiflet 3</i>			<i>Coiflet 4</i>		
$\lambda_M$	1,13	0,66	1,10	1,09	0,91	1,05	1,12	0,93	1,09
$\lambda_N$	0,86	1,05	0,92	0,88	0,94	0,89	0,87	0,93	0,90
$\lambda_M \lambda_N$	0,97	0,69	1,01	0,96	0,86	0,93	0,97	0,86	0,98
$\Sigma$	3,19			2,96			3,03		

TABELA 3

Porównanie wybranych falek

	<i>Daubechies 4</i>	<i>Symlet 4</i>	<i>Coiflet 2</i>
Długość filtra	2N = 8	<b>2N = 8</b>	6N = 12
Długość nośnika	2N-1 = 7	<b>2N-1 = 7</b>	6N-1 = 11
Współczynnik $k_2$	$\neq 0$	<b>= 0</b>	$\neq 0$
Wskaźnik $\Sigma$	3,19	<b>3,22</b>	3,19

Ostatecznie do konstrukcji zestawu trzech klasyfikatorów — optymalizowanych ze względu na najlepsze rozróżnianie przebiegów miogennych od prawidłowych ( $F_M$ ), neurogennych od prawidłowych ( $F_N$ ) oraz jednocześnie miogennych i neurogennych od prawidłowych ( $F_{MN}$ ) — przyjęto poziomy od 3 do 7

$$\begin{cases} F_M = \alpha_M \log \left( c_1 \sum_{i=3}^7 k_{Mi} c_i \right) + \beta_M \\ F_N = \alpha_N \log \left( c_1 \sum_{i=3}^7 k_{Ni} c_i \right) + \beta_N \\ F_{MN} = \alpha_{MN} \log \left( c_1 \sum_{i=3}^7 k_{MNi} c_i \right) + \beta_{MN}, \end{cases} \quad (6)$$

gdzie:  $k_{Mi}$ ,  $k_{Ni}$ ,  $k_{MNi}$ , oznaczają zestawy współczynników zoptymalizowanych pod kątem maksymalizacji parametrów  $\gamma_M$ ,  $\gamma_N$  oraz  $\gamma_M \gamma_N$ .

Po przeliczeniu, dla grupy przypadków prawidłowych, klasyfikatorów  $F_M$ ,  $F_N$  i  $F_{MN}$  przy  $\alpha = \beta = 1$ , wyznaczono wartości  $\alpha$  i  $\beta$  standaryzujące normę do wartości średniej równej 50 z odchyleniem standardowym równym 5. W tabeli 4 zestawiono wartości liczbowe wszystkich współczynników niezbędnych do wyznaczenia klasyfikatorów  $F_M$ ,  $F_N$  i  $F_{MN}$ .

TABELA 4

Zestaw współczynników zastosowanych do wyznaczenia klasyfikatorów  $F_M$ ,  $F_N$  i  $F_{MN}$ 

	$\alpha$	$\beta$	$k_3$	$k_4$	$k_5$	$k_6$	$k_7$
$F_M$	32,71	2,26	0,066	0,675	0,055	0,103	0,101
$F_N$	34,84	1,62	0,245	0,232	0,160	0,001	0,362
$F_{MN}$	33,90	1,34	0,107	0,602	0,073	0,077	0,141

W trakcie kolejnego etapu badań wyznaczono histogramy amplitudy, czasu trwania i powierzchni przebiegu czasowego oraz dyskryminanty widmowej [1, 2, 7, 8] i klasyfikatorów  $F_M$ ,  $F_N$  i  $F_{MN}$ . Założono, że wszystkie te cechy podlegają rozkładowi normalnemu i pozytywnie zweryfikowano tę hipotezę za pomocą testu chi-kwadrat na poziomie istotności 0,01. Następnie dla każdego klasyfikatora wyznaczono wartości średnie i odchylenia standardowe.

Normalne rozkłady prawdopodobieństwa klasyfikatorów  $F_M$ ,  $F_N$  i  $F_{MN}$  umożliwiły dalsze udoskonalenie metody. Mimo że każdy z trzech klasyfikatorów falkowych, a w szczególności  $F_{MN}$ , może być bezpośrednio użyty do klasyfikacji, w programie diagnostycznym zastosowano algorytm wykorzystujący wszystkie trzy klasyfikatory:

- w pierwszym kroku oblicza się klasyfikator  $F_{MN}$ ,
- jeśli jego wartość mieści się w granicach  $\mu_p \pm 1,6 \sigma_p = 50,0 \pm 8,0$ , to przypadek klasyfikowany jest jako prawidłowy,
- jeśli  $F_{MN} \leq \mu_p - 1,6 \sigma_p = 42,0$ , to obliczany jest klasyfikator  $F_M$  i jego wartość decyduje, czy przypadek zostanie zaliczony do grupy prawidłowych czy do miogennych,
- jeśli  $F_{MN} \geq \mu_p + 1,6 \sigma_p = 58,0$ , to decydujący jest klasyfikator  $F_N$ .

W pierwszym przypadku klasyfikator wypadkowy  $F = F_{MN}$ , w drugim  $F = F_M$ , a w trzecim  $F = F_N$ . Wartość klasyfikatora  $F$  wyświetlana jest jako podstawa diagnozy. Ostatecznie progi dyskryminacji określono jako  $\mu_p \pm 2,3 \sigma_p = 50,0 \pm 11,5$ .

## 6. Ocena jakości diagnostycznej klasyfikatorów

W praktyce wynik analizy uzyskany za pomocą określonej metody bądź testu diagnostycznego, nie zawsze jest prawidłowy. Pacjent zdiagnozowany jako chory może być rzeczywiście chory, wówczas wynik testu jest prawdziwie pozytywny ( $TP$  — ang. *True Positive*), bądź może być w rzeczywistości zdrowy, wtedy wynik jest fałszywie pozytywny ( $FP$  — *False Positive*). Podobnie pacjent uznany za osobę zdrową może być w rzeczywistości zdrowy — czyli wynik jest prawdziwie negatywny ( $TN$  — *True Negative*) lub chory — wynik fałszywie negatywny ( $FN$  — *False Negative*). Warto zwrócić uwagę, że wbrew intuicji pacjenta wynik pozytywny oznacza chorobę, a negatywny jej brak.

Oznaczając symbolami  $TP$ ,  $FP$ ,  $TN$  i  $FN$  liczby pacjentów przypisane do wyżej określonych grup, można dokonać oszacowania szczegółowych miar skuteczności diagnostycznej danej metody. Podstawowe ze stosowanych przez środowisko medyczne wskaźników to *czułość* ( $Se$  — ang. *sensitivity*) i *specyficzność* ( $Sp$  — ang. *specificity*). Czuość określa się jako stosunek liczby pacjentów chorych prawidłowo zdiagnozowanych do rzeczywistej liczby pacjentów cierpiących na daną chorobę,

natomiast specyficzność to stosunek liczby pacjentów zdrowych zaklasyfikowanych jako zdrowi do wszystkich pacjentów zdrowych poddanych badaniu testem

$$Se = \frac{TP}{TP + FN} = \frac{\text{poprawnie wykryci chorzy}}{\text{suma wszystkich chorych}}, \quad (7)$$

$$Sp = \frac{TN}{TN + FP} = \frac{\text{poprawnie skalsyfikowani zdrowi}}{\text{suma wszystkich zdrowych}} = 1 - \frac{FP}{TN + FP}. \quad (8)$$

Czułość niesie informację o prawdopodobieństwie wykrycia choroby za pomocą danej metody, czyli jest to *prawdopodobieństwo poprawnego wykrycia choroby* (PPW). Natomiast specyficzność określa prawdopodobieństwo tego, że osoba w rzeczywistości zdrowa zostanie zaklasyfikowana jako zdrowa. Jak można zauważyć analizując zależność (8), wielkość  $(1 - Sp)$  wyraża tzw. *prawdopodobieństwo fałszywego alarmu* (PFA).

Korzystając z estymowanych rozkładów gęstości prawdopodobieństwa rozważanych klasyfikatorów, można dokonać oszacowania ich czułości i specyficzności w funkcji wartości progu decyzyjnego  $F_g$ . Czułość i specyficzność metody dla klasyfikacji przypadków miogennych wyznacza się z zależności

$$\left\{ \begin{array}{l} Se_M = \int_{-\infty}^{F_{gM}} p_M(F) dF \\ Sp_M = \int_{F_{gM}}^{\infty} p_P(F) dF, \end{array} \right. \quad (9)$$

gdzie:  $p_M, p_P$  — funkcje gęstości prawdopodobieństwa dla przypadków miogennych i prawidłowych;  
 $F_{gM}$  — próg decyzyjny dla rozróżnienia przypadków miogennych i prawidłowych.

Analogicznie dla przypadków neurogennych

$$\left\{ \begin{array}{l} Se_N = \int_{F_{gN}}^{\infty} p_N(F) dF \\ Sp_N = \int_{-\infty}^{F_{gN}} p_P(F) dF, \end{array} \right. \quad (10)$$

gdzie:  $p_N, p_P$  — funkcje gęstości prawdopodobieństwa dla przypadków neurogennych i prawidłowych;  
 $F_{gN}$  — próg decyzyjny dla rozróżnienia przypadków neurogennych i prawidłowych.

Ponieważ zmiany położenia progu wpływają na wzajemnie ze sobą powiązane wartości  $Se$  i  $Sp$ , szczegółowy obraz jakości klasyfikatora daje wykres tzw. *charakterystyk operacyjnych odbiornika ROC* — ang. *Receiver Operating Characteristics* (nazwa zaczerpnięta została z teorii odbiorników radiolokacyjnych). Krzywe *ROC* obrazują zależność prawdopodobieństwa poprawnego wykrycia choroby ( $Se$ ) w funkcji prawdopodobieństwa fałszywego alarmu ( $1 - Sp$ ). Wartość pola pod krzywą *ROC* świadczy o jakości testu, im jest ono większe, tym metoda jest lepsza.


Krzywe *ROC* wyznaczone dla wszystkich rozważanych klasyfikatorów zostały przedstawione na rysunkach 3 i 4, odpowiednio dla przypadków miogennych i neurogennych, a w tabeli 5 zebrano czułości klasyfikatorów dla specyficzności ustalonej na poziomie 5%.

TABELA 5


Porównanie czułości klasyfikatorów czasowych z widmowym i falkowym dla  $Sp = 5\%$

Przypadki miogenne				
A	$t_w$	S	$\delta$	F
98,2	69,3	97,5	99,6	100,0
Przypadki neurogenne				
A	$t_w$	S	$\delta$	F
89,7	69,9	94,4	93,3	99,0

Spśród cech czasowych, najczęściej branych pod uwagę przez lekarzy neurologów przy stosowaniu metody QEMG do klasyfikacji PJR, amplituda A zapewnia



Rys. 3. Krzywe ROC dla przypadków miogennych



Rys. 4. Krzywe ROC dla przypadków neurogennych

najlepsze rozróżnianie przypadków miogennych, a powierzchnia S — przypadków neurogennych. Dużo słabsze własności dyskryminacyjne ma czas trwania  $t_w$ . Przy różnicowaniu przypadków miogennych bardzo korzystnie wyróżnia się klasyfi-

kator widmowy  $\delta$  [1, 2, 7, 8], jednocześnie niewiele ustępując powierzchni dla przypadków neurogennych. Najlepszą jakością dyskryminacyjną, szczególnie dla przypadków neurogennych charakteryzuje się zaproponowany w niniejszej pracy klasyfikator falkowy.

## 7. Podsumowanie

Zaprezentowane wyniki pozwalają na stwierdzenie, że dekompozycja falkowa — dzięki zastosowaniu jednego zbiorczego parametru diagnostycznego, zamiast kilku stosowanych w analizie czasowej — poważnie upraszcza proces diagnozowania oraz zwiększa trafność diagnozy stawianej na podstawie zapisów PJR. Podstawową zaletą proponowanego klasyfikatora jest precyzyjna i realizowalna w sposób zalgorytmizowany definicja, pozwalająca na obiektywne porównywanie wyników badań uzyskiwanych przez lekarzy neurologów o różnym doświadczeniu i pochodzących z różnych ośrodków badawczych.

Zaprezentowana metoda diagnostyczna zapewnia zdecydowanie lepszą rozróżnialność przypadków chorobowych od prawidłowych, niż tradycyjne parametry określone w dziedzinie czasu, a także w dziedzinie częstotliwości [1, 2, 7, 8]. Czułość metody falkowej, przy specyficzności 95%, wynosi 100% dla schorzeń miogennych oraz 99% dla schorzeń neurogennych, co jest wynikiem odpowiednio o 0,4% oraz 4,6% korzystniejszym niż w przypadku najlepszej z pozostałych metod. Na zakończenie warto podkreślić, że po wykonanej przez neurologa akwizycji sygnałów z mięśnia, diagnoza dokonywana jest w sposób całkowicie automatyczny i niemal natychmiastowy.

W chwili obecnej autorzy testują przedstawioną metodę w Klinice Neurologicznej Wojskowego Instytutu Medycznego w Warszawie i pracują nad jej dalszym udoskonaleniem z wykorzystaniem liniowej analizy dyskryminacyjnej *LDA* (ang. *Linear Discriminant Analysis*) oraz wywodzącej się z teorii sztucznych sieci neuronowych metody wektorów nośnych *SVM* (ang. *Support Vector Machine*).

Artykuł wpłynął do redakcji 28.02.2008 r. Zweryfikowaną wersję po recenzji otrzymano w kwietniu 2008 r.

### LITERATURA

- [1] A. DOBROWOLSKI, K. TOMCZYKIEWICZ, P. KOMUR, *Fourier analysis of motor unit action potentials*, Electronics and Telecommunications Quarterly, vol. 53, no. 2, 2007, 127-141.
- [2] A. DOBROWOLSKI, P. KOMUR, K. TOMCZYKIEWICZ, *Analiza widmowa potencjałów jednostek ruchowych*, Biul. WAT, 56, 1 (645), 2007, 83-97.
- [3] E. ZALEWSKA, I. HAUSMANOWA-PETRUSEWICZ, *Effectiveness of motor unit potentials classification using various parameters and indexes*, J. Clinical Neurophysiology, 111(8), 2000, 1380-1387.

- [4] E. STALBERG, S. D. NANDEDKAR, D. B. SANDERS, B. FALCK, *Quantitative motor unit potential analysis*, J. Clinical Neurophysiology, 13 (5), 1996, 401-422.
- [5] S. SHAHID, J. WALKER, G. M. LYONS, C. A. BYRNE, A. V. NENE, *Application of higher order statistics techniques to EMG signals to characterize the motor unit action potential*, IEEE Transactions on Biomedical Engineering, 52, 2005, 1195-1209.
- [6] C. I. CHRISTODOULOU, C. S. PATTICHIS, *Unsupervised pattern recognition for the classification of EMG signals*, IEEE Transactions on Biomedical Engineering, 46, 1999, 169-178.
- [7] A. DOBROWOLSKI, K. TOMCZYKIEWICZ, P. KOMUR, *Spectral analysis of motor unit action potentials*, IEEE Transactions on Biomedical Engineering, vol. 54, no. 12, 2007, 2300-2302.
- [8] A. DOBROWOLSKI, P. KOMUR, K. TOMCZYKIEWICZ, *Diagnosis of Muscle Condition on the Basis of MUP Spectral Analysis*, IEEE Instrumentation and Measurement Technology Conference (IMTC'07), Warsaw, 2007.
- [9] C. S. PATTICHIS, A. G. ELIA, *Autoregressive and cepstral analyses of motor unit action potentials*, Medical Engineering & Physics, 21, 1999, 405-419.
- [10] C. S. PATTICHIS, M. S. PATTICHIS, *Time-scale analysis of motor unit action potentials*, IEEE Transactions on Biomedical Engineering, 46, 1999, 1320-1329.
- [11] I. RODRIGUEZ-CARRENO, A. MALANDA-TRIGUEROS, L. GILA-USEROS, J. NAVALLAS-IRUJO, J. RODRIGUEZ-FALCES, *Filter design for cancellation of baseline-fluctuation in needle EMG recordings*, Computer methods and programs in biomedicine, 81, 2006, 79-93.
- [12] E. ZALEWSKA, I. HAUSMANOWA-PETRUSEWICZ, E. STALBERG, *Modeling studies on irregular motor unit potentials*, J. Clinical Neurophysiology, 115 (3), 2004, 543-556.
- [13] CH. BISCHOFF, E. STALBERG, B. FALCK, K. EDEBOL EEG-OLOFSSON, *Reference values of motor unit action potentials obtained with multi-MUAP analysis*, Muscle & Nerve, 17, 1994, 842-851.
- [14] S. G. MALLAT, *A Theory for Multiresolution Signal Decomposition: the Wavelet Representation*, IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 11, no. 7, 1989, 674-693.
- [15] S. G. MALLAT, *A Wavelet Tour of Signal Processing*, Academic Press, 1999.
- [16] I. DAUBECHIES, *Ten Lectures on Wavelets*, CBMS-NSF Lecture Notes, 61, SIAM, 1994.

A. P. DOBROWOLSKI, K. TOMCZYKIEWICZ

### Wavelet analysis of motor unit action potentials

**Abstract.** The paper presents a new approach to the computer aided diagnostic systems for the needs of *quantitative electromyography (QEMG)*. Electromyography is a functional examination which plays a fundamental role in diagnostics of muscles and nerves diseases. The method allows for distinction between records of a healthy muscle and a changed one as well as for determination whether pathological changes are of primary myogenic or neurogenic character.

Statistical processing of electromyography examination performed traditionally in the time domain ensures mostly correct classification of pathology without determination of a disease progression. However, because of an ambiguity of temporal parameters definitions, a diagnosis can include a significant error which depends strongly on physician experience. So far, medical practice imposes, as a consensus, registration of at least 20 different *motor unit action potentials (MUAPs)* belonging to one muscle. Then, selected temporal parameters (presented in the paper) are determined for each run and their mean values are calculated. In the final stage, these mean values are compared with a standard and, including also additional electromyography information, a diagnosis is given.



An inconvenience of this procedure in a clinical practice consists in high time-consumption arising, among others, from the necessity of determination of many parameters, usually between 4 and 7. Additionally, as it was mentioned above, an ambiguity in determination of basic temporal parameters can cause doubts during comparison of parameters found by the physician with standard ones determined in other research center which mostly uses equipment of older generation.

A new approach we presented is based on the analysis of wavelet scalograms of the motor unit action potentials calculated on the basis of Symlet 4. The scalograms provide the vector consisting of five features describing the state of a muscle that can be reduced to one feature. In consequence, the healthy, myogenic and neurogenic cases can be successfully classified with the use of a linear method.

A final effect of the first research stage was development of a definition for single point discriminant directly enabling a unique diagnosis to be made. An essential advantage of the suggested discriminant is a precise and algorithmically realized definition which enables an objective comparison of examination results obtained by physicians with different experience and working in different research centers. So, the definition fulfils a fundamental criterion for the parameter used for standard preparation. A suggestion of the standard for selected muscle is presented in the last part of the paper. The aim of next studies is a definition of standards which could allow a unique classification of myogenic, neurogenic, and physiological cases for a large group of muscles based on a more numerous population. Currently, the authors are working on implementation of suggested procedures into diagnostic software that could be compatible with *Viking IV D* system developed by the *Nicolet BioMedical Inc.*

**Keywords:** quantitative electromyography (QEMG), motor unit action potential (MUAP), wavelet transform, scalogram, medical diagnosis

**Universal Decimal Classification:** 616-07

