

웨이브렛 변환평면에서의 근전도신호 인식에 관한 연구

김종원 · 김성환

=Abstract=

A Study on the Identification of the EMG Signal in the Wavelet Transform Domain

Jong-Weon Kim, Sung-Hwan Kim

All physical data in the real world are nonstationary signals that have the time varying statistical characteristics. Although few algorithms suitable to process the nonstationary signals have ever been suggested, these are treated the nonstationary signals under the assumption that the nonstationary signal is a piece-wise stationary signal. Recently, statistical analysis algorithms for the nonstationary signal have concentrated so much interest. In this paper, nonstationary EMG signals are mapped onto the orthogonal wavelet transform domain so that the eigenvalue spread of its autocorrelation matrix could be more smaller than that in the time domain. Then the model in the wavelet transform domain and an algorithm to estimate the model parameters are suggested. Also, an test signal generated by a white gaussian noise and the EMG signal are identified, and the algorithm performance is considered in the sense of the mean square error and the evaluation parameters.

Key words : Nonstationary EMG Signal, Wavelet transform, Eigenvalue spread

서 론

신호를 해석하는데 있어서 그 신호의 통계적 특성을 안다는 것은 매우 중요하다. 신호의 통계적 특성들은 그 신호에 대한 정보를 제공해주고, 해석을 용이하게 해준다. 그러나 신호의 통계적 특성들이 시간에 종속적으로 변화한다면 한 순간의 데이터에 대한 통계적 특성으로 이 신호 전체를 대표할 수 없다. 특히 신호의 통계적 특성이 시간에 종속적으로 변화하지 않는다고 가정하고 해석하는 알고리즘들로는 이러한 신호에 대한 해석이 불가능하다. 따라서 통계적 특성이 비정상적인 (nonstationary) 신호를 모델링하고, 파라미터를 인식하는 기술에 대한 관심이 높아

지고 있다.

비정상 신호를 모델링하기 위한 적절한 알고리즘이 없었던 과거에는 이러한 신호가 부분적으로 정상(piece-wise stationary)일 것이라고 가정하고, 정상데이터를 위해 제안된 알고리즘들을 이용하여 분석해왔는데, 최근들어 여러가지 비정상신호를 모델링하기 위한 방법들이 제안되었다^{1~6)}.

특히, Kitagawa와 Gersch는 비정상 신호인 지진파를 해석하면서 새로운 비정상 모델링 방법을 제안하였다²⁾. 이 알고리즘은 매 샘플시간마다 AIC (Akaike information criteria)로 적절한 모델 차수를 구해주었고 전체 블록데이터를 이용하여 그 순간의 입력잡음 분산을 구함으로써 신호를 모델링하였다. Moser는 이 알고리즘을 수정하여 실시

간 형태로 바꿔 하반신 마비환자의 보행제어를 위한 근전도(electromyogram)신호 인식에 사용하였다³⁾. Kim은 Moser가 제안한 알고리즘이 매 샘플시간마다 추정오차 분산을 계산하는 것이 필요하므로 실시간 처리에 어려움이 따른다는 것을 지적하고 DSP(digital signal processing) Chip을 이용하여 실시간 구현을 하였다⁷⁾.

위에 언급된 몇몇 연구자들에 의해서 비정상 신호에 대한 해석 알고리즘이 제안되었으나 이러한 알고리즘도 정상신호를 해석하기 위해서 제안된 알고리즘을 시변형태로 해석하는데 불과하다. 특히, 최근들어 장애자를 위한 보철 제어분야에서 근전도신호를 이용하여 장애자의 기능을 전기자극으로 제어하려는 연구가 활발하게 진행되고 있다^{3, 8, 9)}. 이때 사용되는 근전도 신호는 장애자의 자세변화에 따라서 비정상적인 특성을 나타내게 되므로 비정상 근전도 신호를 모델링하고 인식할 수 있는 새로운 알고리즘이 요구된다.

웨이브렛 이론은 다양한 신호처리 응용분야에 대해서 독립적으로 개발되어왔던 많은 기술에 대한 통합된 틀을 제공한다. 예를 들어 최근의 컴퓨터 비전에 사용되는 다해상도(multiresolution) 신호처리, 음성과 영상 압축을 위해서 개발된 서브밴드 코딩(subband coding), 응용수학(applied mathematics)에서 개발된 웨이브렛 series expansion은 단일이론에 대한 서로다른 관점으로 인식되어왔다. 사실 웨이브렛 이론은 매우 넓은 영역을 차지한다. 웨이브렛 이론은 연속시간과 이산시간의 두 경우를 다루고 신호처리에서의 많은 연구에 적용될 수 있는 일반적인 기술을 제공하고, 따라서 여러 분야에 다양한 응용력을 갖는다^{10~13)}.

특히 웨이브렛 변환은 비정상 신호의 해석에 대해서 지금까지 고전적으로 사용되어왔던 short-time Fourier 변환(STFT)이나 Gabor 변환과는 다른 관점을 제공하고 있어서 관심을 끌고있다. STFT와 웨이브렛 변환사이의 기본적인 차이점은 STFT가 하나의 해석 윈도우(window)를 사용하는데 비해서 웨이브렛 변환은 높은주파수에서는 짧은 윈도우를 사용하고 낮은주파수에서는 긴 윈도우를 사용한다는 것이다. 따라서 웨이브렛 변환을 “Constant-Q” 또는 constant relative bandwidth frequency analysis라고 부르기도 한다. 또한 웨이브렛 변환은 Wigner-Ville 분포에 근거한 시간-주파수 해석과도 관계가 있다¹⁴⁾.

본 연구에서는 비정상 근전도신호를 웨이브렛 변환을 통하여 직교변환평면(orthogonal transform domain)으로 이동시키고, 웨이브렛 변환평면 MA(wavelet transform domain moving average: 이하 WTDMA라고 한다.) 모델을 세워 변환평면에서의 파라메터를 인식하였다. 또한 실

제로 습득된 근전도 신호를 이용하여 파라메터를 추출하고 알고리즘의 성능을 평가하였다.

웨이브렛 변환

웨이브렛 변환을 정의하기 전에 admissible function을 정의한다. mother 웨이브렛이 되기 위한 함수는 admissible해야한다. 웨이브렛 또는 mother 웨이브렛이 되기 위한 함수는 진동하고 빠른 시간에 영으로 감소해야 한다. 이러한 조건이 웨이브렛의 적분값이 영(웨이브렛의 직류성분이 영)으로 되는 조건과 합쳐지면, mother 웨이브렛이 되기 위한 함수로서 만족하는 세 가지의 non-rigorous admissibility 조건이 된다. 원칙적으로 admissible function은 대역통과 신호이다. 이들 신호는 직류성분을 가질 수 없고, 감쇠됨으로 무한대의 주파수 성분도 가질 수 없다. 매체나 자유공간을 통해서 전송되는 대부분의 신호들은 유한주기, 대역통과 신호이므로 이러한 조건이 매우 제한적인 것은 아니다.

하나의 $L^2(R)$ 함수(유한에너지 함수-독립적인 변수의 범위에 대해서 square integrable) g 는 다음 조건을 만족하면 admissible function이다.

$$C_g = \int_{-\infty}^{\infty} \frac{|G(w)|^2}{|w|} dw < \infty \quad (1)$$

여기서 $G(w)$ 는 g 의 Fourier변환이다. 대부분의 자연적인 신호는 admissible function으로 분류할 수 있다.

웨이브렛 변환 연산자 W_g 는 실수나 복소수값을 갖는 유한에너지 또는 $L^2(R)$ 신호를 다음과 같이 대응시킨다. $W_g: L^2(R) \rightarrow L^2(R \setminus \{0\} \times R)$. 주어진 admissible mother 웨이브렛 g 에 대해서 임의의 신호 $y(t)$ 의 웨이브렛 변환은 다음과 같이 정의된다.

Wavelet domain coeff at scale a and translation τ

$$\begin{aligned} = & W_g y(a, \tau) = \frac{1}{\sqrt{|a|}} \int y(t) g^*(\frac{t-\tau}{a}) dt \\ = & \langle y, \frac{1}{\sqrt{|a|}} g(\frac{\cdot - \tau}{a}) \rangle \\ = & \langle y, g_{a,\tau} \rangle = \langle y, U(a, \tau)g \rangle \end{aligned} \quad (2)$$

여기서 “*”는 공액복소수를 나타내고, $\langle \cdot, \cdot \rangle$ 는 내적(correlation integral에 대한 약식표기)이다. 웨이브렛 요소 g_a 는 unitary affine mapping $U(a, \tau): g(t) \rightarrow \frac{1}{\sqrt{|a|}} g(\frac{t-\tau}{a})$

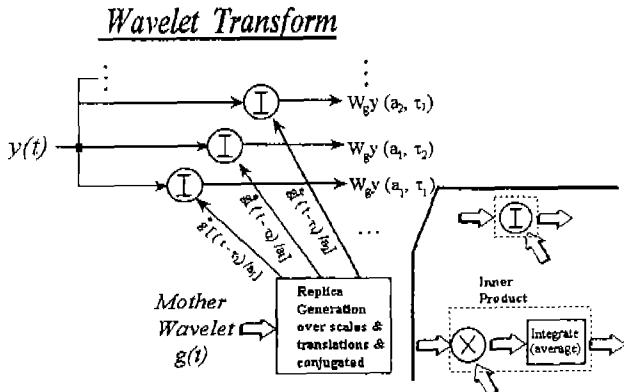


그림 1. 웨이브렛 변화 구조

Fig. 1. Structure of the wavelet transform

$(\frac{t-\tau}{a})$ 로 정의된다. 즉 $g_{a,\tau}$ 는 $g(t)$ 가 스케일 (scale) 파라미터 a 에 의해서 스케일되고 병진 (translation) 파라미터 τ 에 의해서 이동된 형태이다. 스케일은 임의의 영이 아닌 실수, $R \setminus \{0\}$, 가 될 수 있다. “unitary”라는 용어는 스케일된 mother 웨이브렛의 에너지를 원래의 mother 웨이브렛의 에너지와 동일하게 유지되도록 $\frac{1}{\sqrt{|a|}}$ 의 항으로 처리된

에너지 정규화를 의미한다. mother 웨이브렛은 단일의 admissibility 상수 C_g 를 갖도록 정규화될 수 있다. unity admissibility 상수는 등방성의 웨이브렛 변환(에너지가 시간이나 공간평면과 웨이브렛 평면에서 같다.)이 되도록 상수를 허용한다. 이것은 임의의 (a, τ) 에서 웨이브렛 계수가 스케일의 넓은 범위에 대해서 잘 비교되거나 결합되도록 한다. 연속(continuous) 웨이브렛 변환에 대해서 mother 웨이브렛의 선택은 admissibility 조건에 의해서만 제한된다. 이것은 관심있는 특정한 응용분야에서 최적의 동작을 위해서 자유롭게 mother 웨이브렛을 선택할 수 있도록 한다.

웨이브렛의 변형된 집합들이 어떻게 하나의 신호로 근사화되는지를 조사하는 것에 대해서 역변환의 구조가 웨이브렛 변환으로부터 구성될 수 있다. 하나의 특정한 웨이브렛으로부터 발생된 웨이브렛의 집합은 하나의 신호의 근사치(그 신호의 웨이브렛 평면 표현)를 구성하는데 사용될 수 있다. 이 신호는 웨이브렛 집합(스케일되고 이동된 mother 웨이브렛들)에 대한 가중된 합(weighted sum 또는 적분)에 의해서 근사화된다. 각각의 가중된 웨이브렛은 구성블록으로 동작하고 모든 블록이 함께 더해질 때, 하나의 근사치가 형성된다. 웨이브렛 집합의 요소에 대해

서 적당한 가중치를 구하기 위해서 근사화될 신호를 웨이브렛 집합의 각 요소에 투사(projection)한다. 각 투사의 결과는 mother 웨이브렛 g 에 대한 신호 $y(t)$ 의 웨이브렛 계수라고 불리우는 스칼라 값 또는 $W_gy(a, \tau)$ 이다. 이러한 근사화 과정이 웨이브렛 변환으로 그림 1에 나타내었다.

식 (2)에서 정의된 투사 프로세스는 일종의 상관관계 (correlation: 두 신호가 얼마나 잘 정합되는가의 측도)이다. 정합되거나 비교되는 신호는 원신호 $y(t)$ 와 mother 웨이브렛의 스케일되고 이동된 형태인 $g(\frac{t-\tau}{a})$ 이다.

웨이브렛 역변환은 식 (2)에서 설명된 웨이브렛 변환으로부터 유도된다. 어떠한 변환을 적용하여 신호를 합성하는 동작과 역변환은 identity operation이다. 즉 원래의 함수가 구해진다.

$y(t)$ 와 $g(t)$ 가 유한 에너지함수($L^2(R)$ 에서)이고 $g(t)$ 가 $(a, \tau) \in (R \setminus \{0\} \times R)$ 에서 $g_{a,\tau}(t) = \frac{1}{\sqrt{|a|}} g(\frac{t-\tau}{a})$ 를 갖는 admissible mother 웨이브렛이면 웨이브렛 역변환 W_g^{-1} 는 스케일-병진 평면 $H(a, \tau)$ 에서의 병진을 1차원의 시간 또는 공간 평면 ($W_g^{-1} : L^2(R \setminus \{0\} \times R) \rightarrow L^2(R)$)으로 대응시킨다.

$$W_g^{-1} : H(a, \tau) \rightarrow p(t)$$

$$p(x) = \frac{1}{C_g} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} H(a, \tau) \frac{1}{\sqrt{|a|}} g(\frac{t-\tau}{a}) \frac{d\tau da}{a^2} \quad (3)$$

스케일-병진평면이 mother 웨이브렛 g 또는 $H(a, \tau) = W_gy(a, \tau)$ 에 대한 $y(t)$ 의 웨이브렛변환인 경우에 다음과 같이 된다.

$$W_g^{-1} : W_gy(a, \tau) \rightarrow y(t)$$

$$y(t) = \frac{1}{C_g} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} W_gy(a, \tau) \frac{1}{\sqrt{|a|}} g(\frac{t-\tau}{a}) \frac{d\tau da}{a^2} \quad (4)$$

역변환은 스케일되고 이동된 형태의 mother 웨이브렛이 적당히 가중된 합에 의해서 원래의 함수를 생성한다. 가중치는 웨이브렛 계수 $W_gy(a, \tau)$ 이다. 역변환은 2차원 스케일-병진공간에 대한 합이다. 시간과 공간 평면 함수는 웨이브렛 평면 계수 $H(a, \tau)$ 또는 $W_gy(a, \tau)$ 와 mother 웨이브렛 g 로부터 생성된다. 식 (4)의 역변환을 즉시 정의하는 대신에 식 (3)의 보다 일반적인 형태가 mother 웨이브렛에 대한 웨이브렛 변환과의 종속성을 강조하기 위해서 도입되었다.

Inverse Wavelet Transform

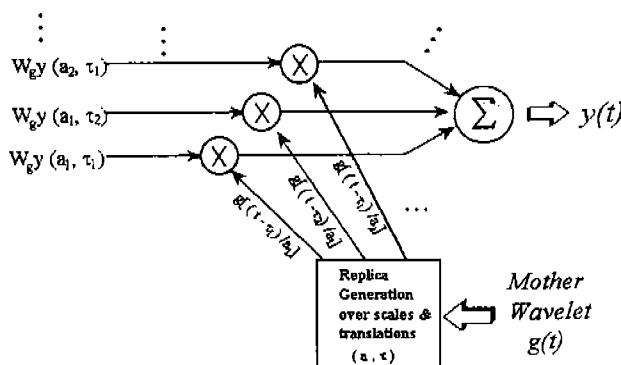


그림 2. 웨이브렛 역변환 구조

Fig. 2. Structure of the inverse wavelet transform

웨이브렛 역변환은 그림 2와 같이 웨이브렛 계수로부터 원래의 신호를 복원한다.

지금까지 유도된 연속 웨이브렛 변환은 이산(discrete) 형태로 각각 다음과 같이 나타낼 수 있다.

$$g_{j,k}(t) = a_0^{-\frac{j}{2}} g(a_0^{-j}t - kT) \quad : \text{discrete wavelet}$$

$$W_{g^{j,k}} = \int y(t) g^*_{j,k}(t) dt \quad : \text{discrete wavelet transform} \quad (5)$$

$$y(t) = C_g \sum_j \sum_k W_{g^{j,k}} g_{j,k}(t) \quad : \text{discrete inverse wavelet transform}$$

웨이브렛 변환평면 비정상 근전도 신호 인식 알고리즘

1. 웨이브렛 변환평면에서의 비정상 근전도 신호모델

시간평면에서 관측된 근전도신호 $y(n)$ 에 대한 웨이브렛 변환평면에서의 표현은 식 (6)과 같이 표현될 수 있다.

$$y(n) = \sum_{j,k} h_{j,k} \sum_i g_{j,k}(n-i-1) y(n-i) \quad (6)$$

콘벌루션 $\sum_i g_{j,k}(n-i-1) y(n-i)$ 과 같은 $z_{j,k}(n)$ 으로 구성된 벡터 $z(n)$ 과 $h_{j,k}$ 로 구성된 벡터 h 로 표기하자. h 의 성분은 $z(n)$ 의 성분에 대해 적당한 순서로 놓여있다고 가정하면 식 (6)을 식 (7)로 나타낼 수 있다.

$$y(n) = h^T z(n) \quad (7)$$

WTDMA 모델을 이용하여 식 (8)과 같이 근전도신호 $y(n)$ 을 추정할 수 있다.

$$\hat{y}(n) = \sum_{j,k} \hat{h}_{j,k} \sum_{i=1}^m g_{j,k}(n-i-1) y(n-i) \quad (8)$$

$z(k)$ 와 h 를 정의했을 때와 비슷하게 두벡터 $z_1(k)$ 와 h 를 도입할 수 있다. 따라서 식 (8)은 식 (9)로 나타낼 수 있다.

$$\hat{y}(n) = \hat{h}^T z_1(n) \quad (9)$$

식 (9)의 벡터들을 식 (7)의 벡터들과 쉽게 관련시키기 위해서 $h^T = [h^T, h^T]$ 이고 $z^T(n) = [z_1^T, z_2^T]$ 이라고 가정하자. h 는 WTDMA 모델의 계수벡터이고 $z_2(n)$ 은 신호 $y(n)$ 을 추정하는데 사용되지 않은 웨이브렛에 대한 콘벌루션 벡터이다. 이러한 일반적인 설정을 통해서 축소된 차수의 모델링(reduced order modeling)의 가능성을 찾을 수 있다.

Bayesian의 관점에서 신호모델링의 궁극적인 목표는 원신호와 추정된 신호사이의 MSE (mean square error)를 최소화 하는 것이다.

$$E[|e(n)|^2] = E[|y(n) - \hat{y}(n)|^2] \quad (10)$$

행렬 $E[z_1^*(n)z_1^T(n)]$, $E[z_1^*(n)z_2^T(n)]$, $E[z_2^*(n)z_2^T(n)]$ 을 각각 R_{11} , R_{12} , R_{22} 로 정의하자. 그러면 식 (10)을 최소화하는 WTDMA 모델의 계수 \hat{h}_0 는

$$\hat{h}_0 = h_1 + R_{11}^{-1} R_{12} h_2 \quad (11)$$

이고 MSE의 최소값은 다음과 같다.

$$J_{\min} = h_2^H (R_{22} - R_{12}^H R_{11}^{-1} R_{12}) h_2 \quad (12)$$

R_{11} 의 고유치(eigenvalue)의 퍼져있는 정도가 작으면 알고리즘의 수치적 특성에 좋은 영향을 줄 수 있다. 시간평면에서 선형예측을 통해 신호를 모델링한다는 것은 현재와 과거의 입력신호와 과거의 출력신호의 선형적 결합으로 나타내는 것이다. 벡터적으로 나타낸다면, 입력신호와 출력신호는 각각 하나의 벡터축을 형성하게 되고 현재의 입력이 각각의 벡터축에 투사된다고 할 수 있다. 이러한 투사를 통한 신호의 모델링에서 일반적으로 각 벡터축들 간의 직교성(orthogonality)이 성립되어 있지 않기 때문에 중첩되어 모델링 되는 부분이 생기게되고, 충분한 차수의

모델링이 이루어지지 않기 때문에 원신호를 정확히 모델링하는데 방해요소가 되며, 모델링 오차를 일으킨다.

이러한 관점에서 볼 때, 근전도신호를 직교투사를 통해서 모델링 할 수 있다면, 중첩되어 모델링되는 부분에 의한 모델링 오차를 줄일 수 있게되어 보다 정확한 모델링이 가능하게 될 것이다. 따라서 본 논문에서 제안되는 웨이브렛 변환평면에서의 근전도신호 모델링은 시간평면에서의 근전도신호 모델링보다 정확한 모델을 제시할 수 있다.

직교투사를 적용할 수 있는 가능성은 입력의 자기상관(autocorrelation)함수의 고유치 분포와 관련이 있으므로 이에대한 해석이 필요하다. 먼저 일반성을 주기 위해서 입력신호의 전력(power) $\circ 1$ 이라고 가정하자.

$$E[y(n)^2] = 1 \quad (13)$$

$Tr(A)$ 는 자승행렬 $Det(A)$ 의 자승행렬 A 의 행렬값이라고 하자. 행렬이론¹⁵⁾으로부터

$$\lambda_{\max} \leq Tr(A) \quad (14)$$

2보다 큰 N에 대해서 일반적으로 다음과 같이 된다.

$$\lambda_{\min} \leq Det(A) \quad (15)$$

그러므로 그 비율 $r(A)$ 는 $\lambda_{\max}/\lambda_{\min}$ 에대한 상한(upper bound)으로 사용될 수 있다.

$$r(A) = \frac{Tr(A)}{Det(A)} \quad (16)$$

$$Det(\Lambda^2 R_{xx}) = Det(\Lambda^2) Det(R_{xx}) \quad (17)$$

$$= Det(\Lambda^2) Det(R_{yy})$$

$$Tr(\Lambda^2 R_{xx}) = Tr(R_{yy}) \\ = N \quad (18)$$

여기서 R_{xx} 는 웨이브렛 변환평면에서의 입력 자기상관 함수, R_{yy} 는 시간평면에서의 입력 자기상관함수, Λ^2 은 (i , j)번째 값이 추정전력(원도우를 이동시켜 평균값을 구한 것)인 $N \times N$ 대각 행렬, N은 입력신호의 갯수이다. 따라서

$$r(\Lambda^2 R_{xx}) = Det(\Lambda^2) r(R_{yy}) \quad (19)$$

$Tr(\Lambda^2) = N \circ 1$ 므로, $Det(\Lambda^2)$ 는 항상 1보다 작거나 같다. 그러므로

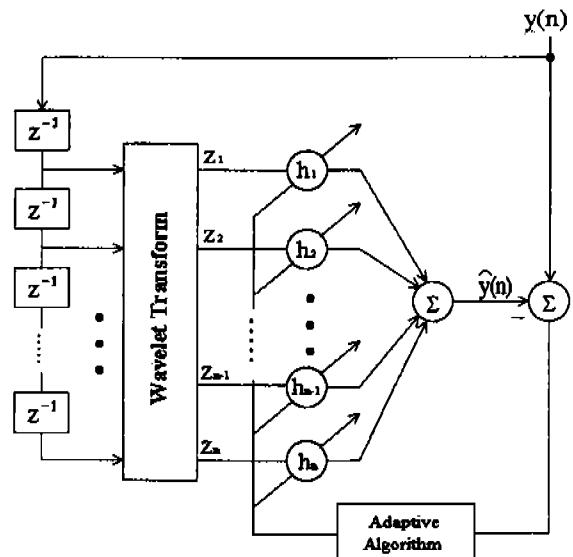


그림 3. 웨이브렛 변환평면에서의 비정상 근전도신호 모델
Fig. 3. Nonstationary EMG signal model in the wavelet transform domain

$$r(\Lambda^2 R_{xx}) \leq r(R_{yy}) \quad (20)$$

즉, 적당히 선택된 직교변환 W_s 에 대해서 고유치가 시간평면보다 퍼져있는 정도가 작을 것이 기대된다. 이 증명의 중요성은 웨이브렛 변환평면으로 이동된 근전도신호를 정확히 모델링 할 수 있는 가능성을 제시한다는 것이다. 본 연구에서는 직교변환으로 웨이브렛 변환을 선택하였으며, mother 웨이브렛으로는 연산량이 적고, 가장 널리 사용되고 있는 Daubechies의 D4 웨이브렛을 사용하였다.

WTDMA 모델에 의한 근전도신호 모델링을 그림 3에 표시하였다.

2. 웨이브렛 변환평면 비정상 근전도신호 인식 알고리즘

웨이브렛 변환평면으로 이동된 비정상 근전도신호는 다음과 같이 나타낼 수 있다.

$$z(n) = W_{sk}y(n) \quad (21)$$

식 (21)로 변환된 비정상 근전도신호는 식 (9)와 같이 현재순간의 근전도신호를 모델링하는데 사용할 수 있다. 따라서 현재 관측된 근전도신호 $y(n)$ 은 식 (22)처럼 나타낸다.

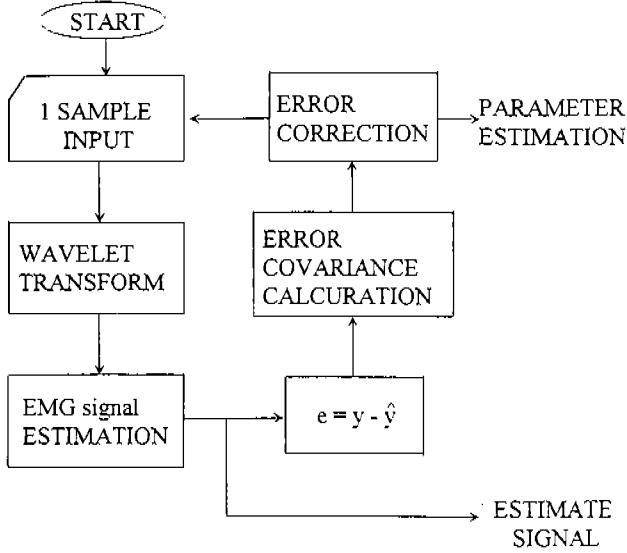


그림 4. 비정상 근전도신호 인식알고리즘의 흐름도
Fig. 4. Flowchart of the identification algorithm for the non-stationary EMG signal

$$y(n) = \sum_{i=1}^m h_i(n)z(n-i) + w(n) \quad (22)$$

$$\hat{y}(n) = \sum_{i=1}^m h_i(n)z(n-i)$$

식(22)의 근전도신호 모델은 다음과 같이 동일한 상태 공간 방정식(state-space equation)으로 변환할 수 있다.

$$x(n+1) = A(n)x(n) + u(n) \quad (23)$$

$$y(n) = C(n)x(n) + w(n) \quad (24)$$

여기서 추정되는 비정상 모델 파라메터는 $x(n)$ 이다.

$$x(n) = \begin{bmatrix} h_1(n) \\ \vdots \\ h_m(n) \end{bmatrix} \quad (25)$$

$$A(n) = I, \quad I: identity matrix \quad (26)$$

$$u(n)^T = [v_1(n+1) v_2(n+1) \dots v_m(n+1)] \quad (27)$$

$$C(n) = [z(1) z(2) \dots z(m)] \quad (28)$$

라하자. $u(n)$ 의 공분산(covariance)은 식(29)로 표현한다.

$$cov[u(n)] = V(n) = \begin{bmatrix} V_1(n+1) & 0 \\ 0 & V_2(n+1) \\ \vdots & \vdots \\ 0 & V_m(n+1) \end{bmatrix} \quad (29)$$

비정상 파라메터 인식 알고리즘은 매 이산샘플시간마다 시스템의 상태, 즉 n 에서의 비정상 모델 파라메터의 추정을 계산하는데 적용할 수 있다. 파라메터의 추정을 위하여 상태공간 방정식을 풀기위한 과정은 식(30)-식(32)와 같다^[16].

$$\hat{x}(n+1/n) = [A(n) - K(n)C(n)] \hat{x}(n/n-1) + K(n)y(n) \quad (30)$$

$$K(n) = A(n)P(n/n-1)C(n)^T \quad (31)$$

$$\cdot [C(n)P(n/n-1)C(n)^T + W(n)]^{-1}$$

$$\begin{aligned} P(n+1/n) &= A(n) \\ &\cdot [P(n/n-1) - P(n/n-1)C(n)^T \\ &\cdot (C(n)P(n/n-1)C(n)^T + W(n))]^{-1} \\ &\cdot C(n)P(n/n-1)A(n)^T + V(n) \quad (32) \\ &= E\{x(n+1) - \hat{x}(n+1/n)\} \\ &\cdot [x(n+1) - \hat{x}(n+1/n)]^T \\ &\cdot \{z(1), \dots, z(n)\} \end{aligned}$$

여기서 $\hat{x}(n+1/n)$ 은 n 번째 구간에서 관측된 데이터로 주어진 $x(n+1)$ 의 추정을 나타내며, $P(n+1/n)$ 은 그 시간의 추정오차 공분산이다.

비정상 근전도신호 인식알고리즘의 흐름도를 그림 4에 나타내었다.

알고리즘의 성능평가 실험 및 결과고찰

1. 실험방법

본 논문에서 제안된 알고리즘의 성능평가를 위해서 백색 가우시안 잡음(white gaussian noise)으로 두 개의 4차 모델을 설정하여 임의의 두 신호를 만들고, 그 신호를 연결시켜 신호의 특성 파라메터가 갑작스럽게 변화하도록 만들었다. 생성된 신호에 대해 웨이브렛 변환평면에서의 인식알고리즘과 시변신호에 대해서 일반적으로 많이 적용되고 있는 GL(gradient lattice)알고리즘을 비교·검토하였다. 또한 적당한 힘을 주고 팔을 움직이면서 이두박근으로부터 근전도 신호를 수집하고, 이 신호의 비정상성을 측정하였으며, 웨이브렛 변환평면에서의 인식알고리즘으로

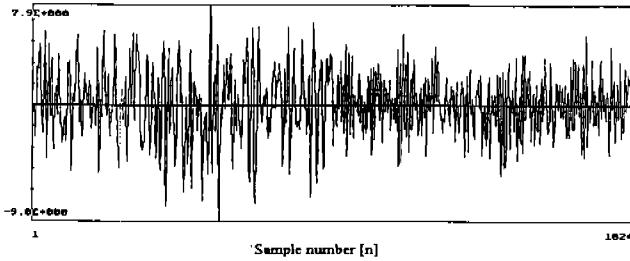


그림 5. 백색 가우시안 잡음으로 생성된 신호

Fig. 5. Signal generated a white gaussian noise

신호를 추정하여 그 결과를 고찰하였다.

정상인의 이두박근에서 가장 근전도신호가 잘 나오는 부분에 표면전극(TECA, NCS 2000)을 부착한뒤 14Kg의 부하를 들어올렸다가 내리는 동작을 수행할 때 근전도 신호를 수집하였다. 팔의 갑작스러운 굴곡운동은 운동의 시작부분에서 근육에 힘이 가해지기 때문에, 근전도 신호가 갑자기 커지면서 불안정한 형태의 신호가 얻어지게 된다. 이때의 샘플링 주파수는 1024Hz, 증폭율은 2000배, 저역 통과 필터는 0.5~500Hz로 하여 1초간 수집하였으며, 비정상성을 검증하기 위해서 Run 테스트를 수행하였다^[17].

2. 실험결과 및 고찰

백색 가우시안 잡음으로 생성된 신호의 구간별 파라미터 값이 표 1에 주어져 있다. 그림 5는 표 1의 파라미터 값으로 생성된 신호이다.

임의로 생성된 신호에 대해서 GL알고리즘과 웨이브렛 변환평면 비정상 신호인식 알고리즘을 이용하여 파라미터를 인식한 결과는 그림 6과 같다. 그림 6에서 GL알고리즘에 의한 파라미터는 시간 평면에서의 값이고, 제안된 알고리즘의 파라미터는 웨이브렛 변환평면에서의 값이다. 두 알고리즘에 의해서 추정되고 있는 파라미터의 수렴특성을 살펴보면, 임의로 생성된 신호의 특성 파라미터가 갑작스럽게 변화하는 부분에서 GL알고리즘이 서서히 수렴되고 있는 반면에 제안된 알고리즘은 급격히 변화된 파라미터를 추정하고 있는 것을 관찰할 수 있다. 두 그림의 첫번째 화살표가 있는 부분이 신호의 특성파라미터가 갑작스럽게 변화되는 부분인데 이곳에서 두번째 화살표가 있는 부분까지 GL 알고리즘은 변화해야 할 파라미터의 46.8%가 변화한 반면에 제안된 알고리즘은 매우 빠른 변화율을 보이고 있어서, 비정상적인 신호특성이 발생했을때 100샘플이내에서 빠르게 기능을 인식할 수 있다. 제안된 알고리즘의

표 1. 구간에 따른 특성 파라미터

Table 1. Feature parameter in each interval

[n]	1-512	513-1024
Para. value		
$\alpha_1(n)$	1.97	1.35
$\alpha_2(n)$	-2.08	-1.52
$\alpha_3(n)$	1.22	0.95
$\alpha_4(n)$	0.40	0.30

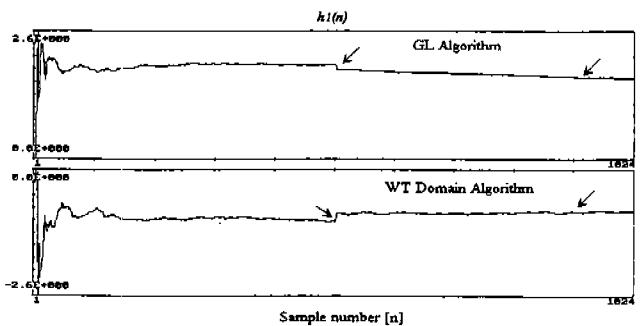


그림 6. 알고리즘의 파라미터 추정특성

Fig. 6. Parameter estimate behavior of the each algorithm

이러한 특징은 신호의 파라미터화를 통해서 기능을 인식하고 분류하는데 커다란 장점이 될 수 있다. 이러한 수렴 특성을 MSE로 관측하면 그림 7과 같다. 그림 7의 MSE의 커브를 보면, 화살표로 지시한 부분에서 제안된 알고리즘이 웨이브렛 변환평면에서의 값이다. 제안된 알고리즘이 GL 알고리즘에 비해서 30~50%정도 MSE가 개선되었음을 알 수 있다.

그림 8은 이두박근으로부터 수집된 근전도 신호를 나타내고 있다. 갑작스런 이두박근의 변화로 근전도신호가 형성되고 있는 것을 알 수 있다. 일반적으로 근육의 상태가 변화가 없을지라도 근육시스템의 생리적인 성질로 인하여 불안정한 성질을 갖는다는 것은 잘 알려져 있다^[18]. 실제 신호인식에 필요한 데이터는 아주 짧은 시간안에 얻어질 수 있으므로 입력신호를 여러구간으로 나누어 통계적인 특성(평균, 분산)을 비교해 볼 수 있다. 신호의 통계적 특성으로써 정상 또는 비정상성을 검증하는 방법은 Bendat와 Piersol에 의해서 제안되었는데, 입력신호 $y(n)$ 을 N개의 등간격으로 나눈 다음 각 간격에서 평균, 표준편차를 각각 구해서 Run 테스트를 이용하여 비교검토한다^[17]. 표 2에 근

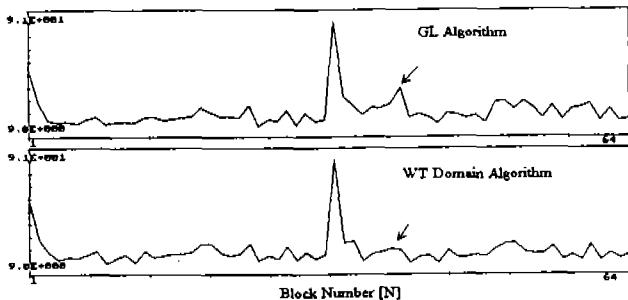


그림 7. 알고리즘의 MSE 비교

Fig. 7. MSE comparison of the each algorithm

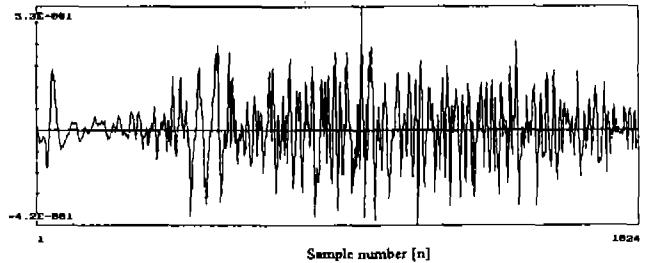


그림 8. 이두박근에서 수집된 근전도신호

Fig. 8. EMG signal from the biceps muscle

표 2. 각 구간의 통계값

Table 2. Stochastic value the each interval

(S.D. : Standard Deviation)

Block	mean	S.D.									
1	0.016	0.123	9	-0.046	0.181	17	-0.034	0.169	25	-0.013	0.134
2	-0.016	0.049	10	0.020	0.188	18	0.061	0.227	26	-0.002	0.164
3	-0.005	0.026	11	0.024	0.119	19	-0.042	0.128	27	0.009	0.124
4	0.015	0.032	12	-0.008	0.092	20	0.039	0.133	28	0.003	0.134
5	0.012	0.033	13	0.002	0.147	21	0.007	0.180	29	0.019	0.095
6	0.002	0.047	14	0.029	0.145	22	0.001	0.148	30	-0.001	0.102
7	0.001	0.059	15	-0.041	0.168	23	0.004	0.140	31	0.013	0.080
8	0.045	0.097	16	0.045	0.164	24	0.018	0.137	32	0.007	0.060

전도 신호에 대한 각 구간의 통계값이 주어져 있다.

비정상성의 검증은 유의수준(level of significance)을 이용하였다. 즉 $n=N/2$ 일 때 실행된 Run수가 $r_{n:1-\alpha/2}$ 와 $r_{n:2}$ 사이에 있으면 정상신호이고, 그렇지 않으면 비정상신호라 할 수 있다. 여기서 N 은 구간의 갯수이고 α 는 유의수준이다.

유의수준 α 를 0.05로 했을 때 Run 분포표에 의해서 $r_{n:1-\alpha/2} = r_{16:0.975} = 11$ 이고, $r_{n:2} = r_{16:0.025} = 22$ 이다. 즉 Run수가 11과 22사이에 존재하지 않으면 비정상 신호라 할 수 있다. 표 2로부터 측정한 결과 Run수가 6개 임으로 수집된 근전도 신호가 비정상신호임을 알 수 있다.

웨이브렛 변환평면 비정상 근전도 신호 인식 알고리즘에서 입력의 자기상관 행렬에서 고유치의 퍼져있는 정도가 작으면 직교투사를 이용하여 신호를 모델링할 수 있고, 보다 정확한 모델링이 가능하다는 것을 증명하였다. 표 3은 시간평면과 웨이브렛 변환평면에서 16개와 4개의 근전도 데이터에 대하여 구한 입력의 자기상관(autocorrela-

tion) 행렬과 그 행렬의 고유치를 나타낸 것이다. 표 4는 관련된 파라메터를 구한 것이다. 이 경우 웨이브렛 변환평면에서의 입력 자기상관 행렬의 고유치가 시간평면보다 16 개의 근전도 데이터에 대해서 8.35배, 4개의 근전도 데이터에 대해서 1.53배 적게 퍼져있다는 것을 알 수 있고, 고유치의 최소치와 최대치의 비로써 나타난 값들이 상한으로 정해진 trace와 행렬값의 비보다 작으므로 제안된 알고리즘이 타당성을 갖는다는 것을 나타낸다. 또한 식(16)에서 정의된 상한에 대한 조건도 만족됨을 알 수 있다.

그림 9는 웨이브렛 변환평면 비정상 근전도신호 인식 알고리즘으로 추정된 근전도 신호를 나타내고 있으며, 그림 10은 근전도신호의 자기상관함수와 추정된 근전도신호와의 상호상관(crosscorrelation)함수를 보여주고 있다. 그림 10에서 자기상관함수와 상호상관함수가 유사한 형태를 갖고 있다는 것과, 상호상관함수에서 두 신호의 상관도가 높다는 것을 알 수 있으며, 알고리즘이 비정상 근전도신호를 정확히 인식할 수 있다는 것을 의미한다.

표 3. 시간평면과 웨이브렛 변환평면의 입력 자기상관 행렬과 고유치**Table 3.** The input autocorrelation matrix and its eigenvalue in the time and the wavelet transform domain

$R_{yy}(k)$				$R_{zz}(k)$			
k	r_k	k	r_k	k	r_k	k	r_k
0	1.000000	8	0.313064	0	1.000000	8	0.064454
1	0.806675	9	0.257713	1	0.209784	9	0.049463
2	0.739484	10	0.197780	2	-0.128629	10	0.022667
3	0.628253	11	0.117234	3	-0.115894	11	-0.068490
4	0.514697	12	0.012993	4	0.141731	12	0.011112
5	0.454161	13	-0.027870	5	0.043899	13	0.193916
6	0.403598	14	-0.052057	6	-0.064702	14	0.218294
7	0.357882	15	-0.077771	7	-0.278809	15	-0.053090

Autocorrelation matrix ($N=16$)

$R_{yy}(k)$				$R_{zz}(k)$			
k	r_k	k	r_k	k	r_k	k	r_k
0	1.000000	2	-0.288650	0	1.000000	2	-0.060516
1	0.233382	3	-0.407204	1	-0.075085	3	-0.363773

Autocorrelation matrix ($N=4$)

$R_{yy}(k)$				$R_{zz}(k)$			
k	r_k	k	r_k	k	r_k	k	r_k
0	0.1747	8	0.1050	0	1.0020	8	0.6120
1	0.1735	9	0.0969	1	0.9892	9	0.5258
2	0.1533	10	0.2396	2	1.0343	10	1.3841
3	0.1527	11	0.5548	3	1.0628	11	0.2722
4	0.1617	12	0.8368	4	0.8680	12	0.2137
5	0.1841	13	1.0839	5	0.8580	13	1.5191
6	0.1950	14	3.6188	6	0.7464	14	2.1280
7	0.2016	15	8.0676	7	0.6541	15	2.1302

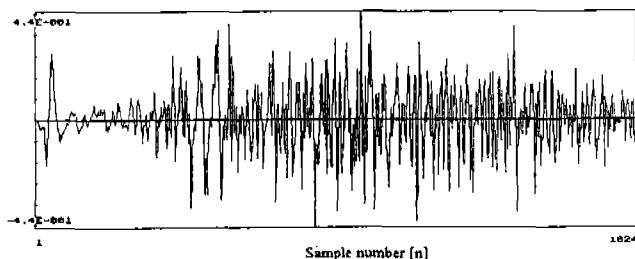
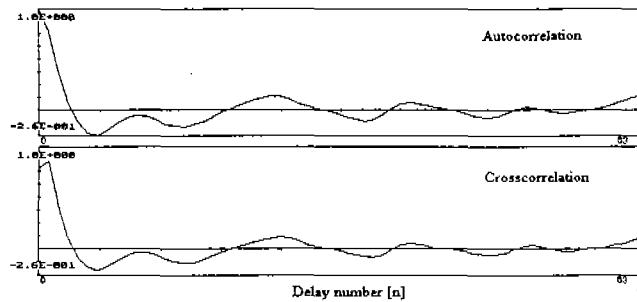
Eignvalue ($N=16$)

$R_{yy}(k)$				$R_{zz}(k)$			
k	r_k	k	r_k	k	r_k	k	r_k
0	1.2381	2	0.5881	0	1.0744	2	1.3645
1	0.4745	3	1.6994	1	0.9786	3	0.5825

Eignevalue ($N=4$)

표 4. 두 평면에 대한 입력 자기상관 행렬의 관련 파라메터**Table 4.** Parameters of the input autocorrelation matrix in the two domain

Parameters	λ_{\min}	λ_{\max}	$\lambda_{\max}/\lambda_{\min}$	$\text{Det}(R)$	$\text{Tr}(R)$	$r(R)$
Time Domain ($N = 16$)	0.0969	8.0676	83.257	2.975E-8	16	5.378E8
Time Domain ($N = 4$)	0.4745	1.6994	3.581	0.5870	4	6.814
Wavelet Domain ($N = 16$)	0.2137	2.1302	9.968	0.0707	16	226.31
Wavelet Domain ($N = 4$)	0.5825	1.3645	2.342	0.8537	4	4.685

**그림 9.** 추정된 근전도 신호**Fig. 9.** Estimated EMG signal**그림 10.** 자기상관 함수와 상호상관 함수**Fig. 10.** Autocorrelation function and crosscorrelation function

결 론

본 논문에서는 웨이브렛 변환평면에서 비정상 근전도신호의 특성 파라메터를 인식할 수 있는 새로운 알고리즘을 제안하였다. 제안된 알고리즘의 타당성은 웨이브렛 변환평면에서의 데이터 구조를 분석하고, 변환평면에서의 신호모델링 방법을 제시하므로써 검증할 수 있었고, 임의로 생성된 데이터를 이용하여 기존의 알고리즘과 비교하여 비정상 신호에 대해서 우수한 알고리즘임을 보였다. 또한 근전도신호를 수집하여 정확하게 신호를 추정하는 것을 보여 알고리즘의 성능도 평가하였다.

16개의 근전도 데이터와 4개의 근전도 데이터에 대해서 고유치의 분포를 계산한 결과 웨이브렛 변환평면에서 각각 8.35배와 1.53배가 적게 펴져 있다는 것은 제안된 모델의 타당성을 나타내며, 임의로 생성된 신호에 대해서 비정상 파라메터를 추정한 결과 시간평면에서보다 일정한 특성을 나타내고 있다는 것을 알 수 있었다. 또한 실제 근전도신호를 낮은 MSE로 추정해내었다. 보통 보철제어를 위해서 근전도신호로부터 기능을 인식하고자 할 때, 장애자가 동작을 취하자마자 기능에 따른 적절한 자극을 가해주어야 한다. 따라서 제안된 알고리즘의 빠른 수렴성은 짧은

시간안에 (100샘플이내에) 기능을 인식할 수 있는 장점을 갖게된다. 이러한 특성은 근전도신호를 파라메터화하여 기능인식에 사용하는데 매우 적합하다.

제안된 알고리즘은 신호가 부분적으로 정상이란 가정하에 제시된 알고리즘들을 대신하여 비정상 신호를 인식하는데 사용할 수 있다. 이것은 실제로 존재하는 모든 물리량이 비정상 신호의 범주에 속하므로 매우 유용한 알고리즘이 될 것이다.

본 논문의 알고리즘은 보철제어를 위한 근전도 신호의 인식 및 분류, 시간에 따라 스펙트럼이 변하는 뇌파신호의 분석이나 지진파의 해석, 원자로의 중성자 잡음측정을 통한 안전진단, 기계고장의 예측, 전력선로의 부하예측등에 유용하게 사용할 수 있으리라고 사료된다.

참 고 문 헌

- D. Graupe, Time Series Analysis, Identification and Adaptive Filtering., Florida, Robert E. Krieger Publishing Co., Inc., 1984.
- G. Kitagawa and W. Gersch, "A Smoothness priors time-var-

- ying AR Coefficient modeling of nonstationary covariance time series," IEEE Trans. Automat. Contr., vol. AC-30, pp. 48-56, Jan. 1985.*
3. A. T. Moser and D. Graupe, "Identification of Nonstationary Models with Application to Myoelectric Signals for Controlling Electrical Stimulation of Paraplegics," IEEE Trans. ASSP, vol. 37, No. 5, pp. 713-719, May, 1989.
 4. M. H. Sherif, R. J. Gregor and J. Lyman, "Effects of Load on Myoelectric Signals: The ARIMA Representation," IEEE Trans., BME, vol. 28, No. 5, pp. 411-416, May, 1981.
 5. E. Shwedyk, R. Balasubramanian, and R. N. Scott, "A Nonstationary Model for the Electromyogram," IEEE Trans., BME, vol. 24, No. 5, pp. 417-424, 1977
 6. R. H. Shumway, Applied Statistical Time Series Analysis. Englewood Cliffs, NJ:Prentice-Hall, 1988.
 7. J. W. Kim and S. H. Kim, "Real-Time Implementation of the Identifier for the Nonstationary Time-Varying Signals and Systems," IEEE IM., Manuscript no. IM-3101, Submitted, 1994.
 8. D. Graupe, "EMG pattern analysis for patient-responsive control of FES in paraplegics for walker-supported walking" IEEE Trans., BME, vol. 36, No. 7, pp. 711-719, July, 1989.
 9. 김근섭, 김종원, 김규학, 홍완희, 김성환, "하반신마비 환자의 보행기능 제어를 위한 FES하드웨어 시스템 설계에 관한 연구," J. of KOSOMBE, vol. 12, No. 1, 1991.
 10. O. Rioul and M. Vetterli, "Wavelets and Signal Processing," IEEE SP Magazine, pp. 14-38, Oct., 1991.
 11. S. G. Mallat, "A Theory for Multiresolution Signal Decomposition: The Wavelet Representation," IEEE Trans., Pattern Ana. and Machine Intel., vol. 11, No. 7, pp. 674-693, July, 1989.
 12. I. Daubechies, "Orthonormal basis of compactly supported wavelets," Comm. Pure Applied Math., vol. 41, pp. 909-996, 1988.
 13. I. Daubechies, "The Wavelet Transform, Time-Frequency Localization and Signal Analysis," IEEE Trans., Infor. Theory, vol. 36, No. 5, pp. 961-1005, Sep., 1990.
 14. Y. Meyer, Wavelets: Algorithms and Applications., Translated by R. D. Ryan, Philadelphia, SIAM, 1993.
 15. G. Strang, Linear Algebra and its Applications, 3rd Ed., Florida, Harcourt Brace Jvanovich, Inc., 1988.
 16. R. E. Kalman, "A new approach to linear filtering and prediction problems," J. Basic Eng. Trans. ASME, vol. 32, pp. 35-45, 1960.
 17. J. S. Bendat and A. G. Piersol, Random Data:Analysis and Measurement Procedures, NewYork, A Wiley-Interscience, 1971.
 18. E. Kwiatny, D. H. Thomas and H. G. Kwiatny, "An application of signal processing technique to the study of myoelectric signals," IEEE Trans., BME., vol. 17, 1970.