

머리 움직임 인식을 위한 근전도 신호의 패턴 인식 기법에 관한 연구

論文

53D-2-5

A Study on the Pattern Recognition of EMG Signals for Head Motion Recognition

李泰雨* · 全昌翼** · 李泳錫*** · 極世根*** · 金成煥§
(Tae-Woo Lee · Chang-Ik Jun · Young-Suk Lee · Se-Keun Yoo · Sung-Hwan Kim)

Abstract - This paper proposes a new method on the EMG AR(autoregressive) modeling in pattern recognition for various head motions. The proper electrode placement in applying AR or cepstral coefficients for EMG signature discrimination is investigated. EMG signals are measured for different 10 motions with two electrode arrangements simultaneously. Electrode pairs are located separately on dominant muscles(S-type arrangement), because the bandwidth of signals obtained from S-type placement is wider than that from C-type(closely in the region between muscles). From the result of EMG pattern recognition test, the proposed mIAR(modified integrated mean autoregressive model) technique improves the recognition rate around 17-21% compared with other the AR and cepstral methods.

Key Words : electromyography(EMG), pattern recognition, mIAR

1. 서 론

머리의 움직임에 의해 발생하는 근전도(electromyography) 신호를 이용하여 여러 가지 기계들의 제어가 수행되고 있다. 이 분야에서는 동작 인식율이 높은 근전도 신호 특징 판별 방법과 전극 배치 방법에 대해서 연구가 수행되어져 왔다. 또한 신경을 다쳐서 사지가 마비된 환자들의 재활을 위한 많은 시도가 이루어져 왔다 [1][2]. 예를 들면 C4 레벨 이하가 마비된 환자가 침대에서 생활할 때 머리와 목의 동작으로 침대를 제어하는 방법의 연구가 있을 수 있다. 이러한 목적을 달성하기 위해서는 근전도 신호를 패턴 인식하여 환자가 침대를 어떻게 움직이려고 하는가를 알아내는 것이 기본요소라 할 수 있다.

머리 움직임 인식을 위한 근전도 분석 방법에는 AR(autoregressive)과 켭스트럼(cepstrum) 파라미터를 이용한 특징 벡터가 사용되어지고 있다. 이와 함께 특징 판별을 위한 전극 배치 방법들이 연구되어져 왔다. Heftner[1]과 Hudgins[2]가 분리된 근육 위에 전극 쌍을 배열했지만, 전극 쌍을 근육사이의 주부적으로 밀접(close)하게 위치를 정한 C-type과 전극 쌍을 주 근육들 위에 분리(separate)해서 위치를 정한 S-type에 대해서는 체계적인 연구가 이루어지지는 못했다. Kang[3]은 C-type 배열보다 S-type 배열방법이 근전도 신호 패턴 인식에 있어서 우수함을 보여주었으나, 근전도 분석 방법으로

AR과 켭스트럼 파라미터를 사용하여 인식율이 낮은 단점이 있다. 이의 단점을 개선한 IAR(integrated mean autoregressive model), ICEP(integrated mean cepstrum model)방법은 전체 분석 프레임(frame)을 작은 부(part) 분석 프레임으로 나누어 AR 계수를 추정하여 인식실험을 수행함으로써 인식율의 향상을 얻을 수 있었으나, 부 분석 프레임 중심점의 이동 편차가 발생하는 취약점을 보여왔다 [4][5].

본 논문에서는 S-type 배열을 사용하여 머리가 움직일 때 근전도 신호를 측정하였다. 인식율을 높이기 위하여 mIAR(modified integrated mean autoregressive model)방법과 mICEP(modified integrated mean cepstrum model)방법을 제안한다.

본 논문에서 제안한 mIAR방법에서 정규화 과정은 IAR 방법의 취약점인 부 분석 프레임의 에너지의 분포의 변화에 대해서 AR 계수의 변화를 보상하는 역할을 수행한다. mIAR 방법에서는 추정된 자기 상관값에 대하여 정규 방정식(normal equation)을 계산하여 안정된 AR 계수를 추출하는 과정을 거친다. AR 방법, 켭스트럼 방법, IAR 방법, ICEP 방법 그리고 mIAR방법과 mICEP방법을 사용하여 머리의 동작시 발생하는 근전도 신호의 인식율을 평가한다.

2. 패턴 인식 알고리듬

2.1 특징 파라미터의 추출

근전도 신호는 동일한 사람에게 취득하더라도 신체 및 심리적인 상태, 동작시의 근육에 가해지는 힘, 동작시의 속도에 따라 심하게 변화하는 특성이 있기 때문에 근전도 신호에서 특징을 정확하게 추출하는 것이 무엇보다 중요하다. 이러한 근전도 신호 패턴의 특징을 추출하는 방법으로서 AR모델링과 켭스트럼 모델링이 널리 사용되고 있다.

* 1) 會員 : 서울市立大學校 電子電氣 工學部 博士課程

** 1) 會員 : 서울市立大學校 電子電氣 工學部 博士修了

*** 1) 會員 : 청운大學校 電子工學科 助教授

§ 1) 會員 : 서울市立大學校 電子電氣 工學部 教授

接受日字 : 2003年 9月 6日

最終完了 : 2003年 11月 26日

2.1.1 자기회귀(AR) 모델링

근전도 신호는 전체적으로 비정상(nonstationary) 신호이지만, 짧은 구간에서는 일정한 통계학적 성질을 지니고 있다고 가정한다 [6][7]. AR 모델을 이용하여 LPC(Linear Predictive Coding)를 추정하여 보면, 파라미터의 시간에 따른 변동범위가 비교적 적으며, 또한 각 신호의 시간 평균으로 계산된 통계적 성질이 각 구간에서 크게 변화하지 않는 비교적 안정된 신호라고 볼 수 있으므로 선형 모델링이 가능하다. 일반적으로 근전도의 분석은 짧은 구간(100ms)내에서 이루어지게 된다 [8][9][10].

근전도 신호를 AR 모델링할 때, 각 샘플 $y(n)$ 은 식 (1)과 같이 과거의 샘플 $y(n - k)$ 에 대한 독립적인 오차 $w(n)$ 을 합한 선형 조합으로 표시된다.

$$\begin{aligned} y(n) &= \hat{y}(n) + w(n) \\ &= - \sum_{i=1}^m a_i y(n-i) + w(n) \\ ; \quad n &= 0, 1, 2, \dots, N-1 \end{aligned} \quad (1)$$

여기서, $y(n)$ 은 AR모델로 표현된 근전도 신호의 샘플, $\hat{y}(n)$ 은 추정 신호, a_i 는 ARC(autoregressive coefficient), m 은 모델의 차수이다. 그리고, $w(n)$ 은 예측오차로서 평균이 0, 분산이 σ^2 인 백색잡음을 나타내며, 식 (2)와 같이 표현할 수 있다.

$$\begin{aligned} w(n) &= y(n) - \hat{y}(n) \\ &= y(n) + \sum_{i=1}^m a_i y(n-i) \\ &= \sum_{i=0}^m a_i y(n-i), \quad a_0 = 1 \end{aligned} \quad (2)$$

자승 예측 오차가 최소로 되도록 자기회귀 파라미터 a_i 를 결정한다면 추정신호 $\hat{y}(n)$ 은 원신호 $y(n)$ 에 가장 가까워지므로 식 (2)의 양변에 자승합의 형태로 수식을 표현하면 식 (3)과 같다.

$$E = \sum_{n=0}^{N-1} w(n)^2 = \sum_{n=0}^{N-1} \left(y(n) + \sum_{i=1}^m a_i y(n-i) \right)^2 \quad (3)$$

자승합 E 의 미분 값이 0이 되도록 식 (3)에서 각각의 AR 파라미터 a_i 로 편미분을 하면 식 (4)와 같다.

$$\frac{\partial E}{\partial a_i} = 0, \quad 1 \leq i \leq m \quad (4)$$

식 (3)과 (4)에 의해 아래와 같은 원신호 $y(n)$ 이 자기상관 함수 $R(i)$ 와 AR 파라미터에 의한 행렬형태의 식 (5)로 나타낼 수 있다.

$$\begin{bmatrix} R(0) & R(1) & \cdots & R(m-1) \\ R(1) & R(0) & \cdots & R(m-2) \\ R(2) & R(1) & \cdots & R(m-3) \\ \vdots & \vdots & & \vdots \\ R(m-1) & R(m-2) & \cdots & R(0) \end{bmatrix} \begin{bmatrix} a_1 \\ a_2 \\ a_3 \\ \vdots \\ a_m \end{bmatrix} = - \begin{bmatrix} R(1) \\ R(2) \\ R(3) \\ \vdots \\ R(m) \end{bmatrix} \quad (5)$$

여기서, 자기상관함수 $R(i)$ 는 식 (6)과 같다.

$$R(i) = \sum_{n=0}^{N-1-i} y(n)y(n+i) \quad (6)$$

이와 같이 입력되는 신호의 정보는 차수 m 에 따른 AR 파라미터 a_i 를 추정함으로써 간단하게 표현할 수 있다. AR 모델의 파라미터를 결정하는 방법에는 여러 가지가 있다. 본 논문에서는 AR 모델의 차수로 4차를 사용하였고, 식 (6)의 결과 식을 효율적으로 계산할 수 있는 Levinson 알고리즘을 이용해 AR 모델 파라미터를 추정한다 [7].

2.1.2 캡스트럼 모델링

두 신호가 선형적으로 결합되어 있을 때는 선형 연산자인 푸리에 변환 등을 사용해서 분리해 낼 수 있다. 그러나, 선형적 결합이 아닌 비선형적 결합으로 이루어진 신호를 분리하기는 어렵다. 캡스트럼은 비선형 신호처리의 한 방식으로 푸리에 변환과 로그변환을 이용하여 컨벌루션(convolution) 형태로 표현된 신호들을 덧셈의 형태로 바꿔서 신호를 분리하는 특성이 있다 [11][12]. 변화가 심한 근전도 신호를 캡스트럼으로 해석하게 되면 각 성분들의 분리가 가능하고 선형 결합된 형태로 나타낼 수 있다.

신경을 통해 근섬유에 전달된 근전도 신호를 모델링하면 식 (7)과 같이 나타낼 수 있다 [13].

$$s(t) = \sum_{n=1}^{\infty} g(n)s_0(t - \tau_n) = s_0(t) * [\sum_{n=1}^{\infty} g(n)\delta(t - \tau_n)] \quad (7)$$

여기서, $s_0(t)$ 는 신경을 통해 근섬유에 전달된 임펄스 응답(impulse response)이고, 검출된 근전도 신호 $s(t)$ 는 $s_0(t)$ 가 τ_n 만큼 지연된 임펄스 응답들의 합으로써 나타낼 수 있다. 시간 영역에서의 컨벌루션은 식 (8)과 같이 푸리에 변환에 의해 주파수 영역에서 곱셈 형태로 나타낼 수 있다.

$$S(w) = S_0(w) \cdot G(w) \quad (8)$$

여기서 $S(w)$ 는 $s(t)$ 의 푸리에 변환, $S_0(w)$ 는 $s_0(t)$ 의 푸리에 변환, $G(w) = \sum_{n=1}^{\infty} g(n)e^{-j\omega \tau_n}$ 이다.

그리고, 이 곱셈에 절대값을 구해서 대수(logarithm)를 취하면 덧셈의 형태로 바뀔 수 있으며, 식 (9)와 같다.

$$\log|S(w)| = \log|S_0(w)| + \log|G(w)| \quad (9)$$

식 (9)는 덧셈의 형태를 가지므로 선형 연산자인 푸리에 연산자를 사용하여 푸리에 역 변환하면 두 스펙트럼을 분리할 수 있다.

근전도 신호 $s(n)$ 의 켭스트럼 $C_s(n)$ 은 식 (10)과 같이 나타나 어진다.

$$C_s(n) = \frac{1}{2\pi} \int_{-\pi}^{\pi} \log|S(\omega)| e^{j\omega n} d\omega \quad (10)$$

이어서, $S(\omega)$ 는 근전도 신호 $s(n)$ 을 푸리에 변환한 결과이다.

식 (10)의 변환 과정은 그림 1과 같이 근전도 신호를 FFT(Fast Fourier Transform)한 후 스펙트럼에 대해 절대값을 구하고, 다시 로그를 취한 후 IFFT(Inverse Fast Fourier Transform) 과정을 수행한 결과와 같아진다.

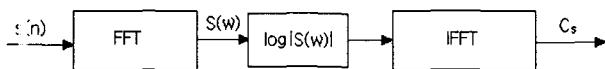


그림 1 켭스트럼 계산

Fig. 1 Calculation of cepstrum

스펙트럼 계수를 구하는 다른 방법으로는 식 (11)과 (12)로 표현된 AR 모델의 역 필터(inverse filter)를 이용하여 구하는 방식이다.

$$J(z) = \frac{Y(z)}{E(z)} = \frac{1}{A(z)} \quad (11)$$

$$A(z) = 1 + \sum_{i=1}^p a_i z^{-i} \quad (12)$$

이어서 $A(z)$ 는 전달함수의 분모이고, a_i 는 AR계수이다. 이 때 $\ln[A(z^{-1})]$ 은 해석적이며, 모든 근(root)은 단위원내에 있다. 식 (12)의 로그(log) 전력스펙트럼을泰일러급수(Taylor series)로 전개하면 식 (13)과 같다.

$$\ln\left[\frac{\sigma^2}{|A(z)|^2}\right] = \sum_{k=-\infty}^{\infty} c_k z^{-k}, \quad (13)$$

$$c_0 = \ln \sigma^2, \quad c_n = c_{-n}$$

이어서 σ^2 은 신호의 스펙트럼을 전극(all pole) 모델화한 함수의 나머지 에너지의 최소치이며, c_k 는 켭스트럼 계수이다.

식 (13)의 양변을 z^{-1} 에 대하여 미분하고, z^{-1} 의 거듭제곱 계수들을 비교 정리하면 식 (14)와 같다.

$$c_k = -a_n - \frac{1}{n} \sum_{k=1}^{n-1} k c_k a_{n-k}, \quad (14)$$

$$n > 0$$

이어서 $a_0=1$ 은 $k>p$ 일 때에 $a_k=0$ 와 같다. 따라서 켭스트럼 계수는 AR 계수로부터 순환적으로 계산되어지며,

식(15)과 (16)과 같이 정리된다.

$$c_0 = -\ln \sigma^2 \quad (15)$$

$$c_i = a_i + \sum_{n=1}^{i-1} \left(\frac{n}{i} \right) c_n a_{i-n}, \quad 1 \leq i \leq p \quad (16)$$

이와 같이 켭스트럼 분석의 특징은 신호의 스펙트럼에 대하여 로그함수를 취함으로써 주파수 영역에서 진폭 레벨이 적은 부분, 즉 전력이 적은 대역에 대하여 더 강조하는 효과를 갖는다.

2.2 새로운 특징 파라미터 추출방법의 제안

2.2.1 일반적인 근전도 신호 패턴인식 과정

근전도 신호로부터 동작 인식은 기본적으로 그림 2와 같은 과정으로 수행된다. 우선 기준 근전도 신호의 입력을 받아 특정 파라미터를 추출한 후 군집의 중심을 결정하는 알고리듬을 통해 기준 패턴을 생성한다. 기준 패턴이 생성된 후에는 임의의 시험 근전도 신호의 입력을 받아 마찬가지로 특정 파라미터를 추출하여 시험패턴을 생성하고 먼저 생성된 기준 패턴과 시험패턴간의 패턴 비교를 한 후 유사도를 결정하여 인식실험을 하게 된다. 이러한 인식실험에서 특정 파라미터의 추출단계는 인식율을 결정하는 아주 중요한 부분이다. 어떠한 특정 파라미터를 사용하는가에 따라 인식율에 있어서 많은 차이를 보일 수 있음을 말한다. 일반적으로 특정 파라미터로는 AR 계수와 켭스트럼 계수를 많이 이용하고 있다. 그리고 인식율을 결정하는 중요한 부분으로 유사도 결정 부분이 있다. 유사도 결정에는 두 개의 패턴간의 거리나 각도를 이용하는 방법이 일반적인 방법으로 사용되며, 이외에도 확률에 의한 방법이 많이 사용되고 있다.

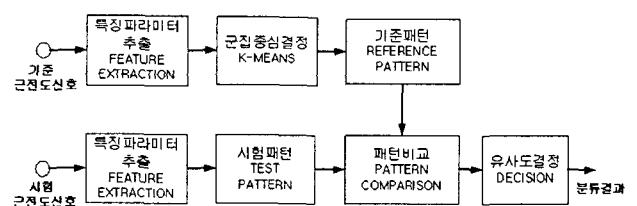


그림 2 근전도 신호를 이용한 패턴 인식 과정

Fig. 2 Process of pattern recognition using EMG Signals

2.2.2 제안된 mIAR 계수와 mICEP 계수 추출방법을 사용한 근전도 신호 패턴인식 과정

그림 3은 인식율의 향상을 위하여 사용된 누적 평균 AR 계수 추출 방법인 IAR 방법을 보여 준다. IAR 계수 추출 방법은 그림 4와 같이 우선 분석 프레임에 대해서 여러 개의 프레임으로 부 분석 프레임을 나누는 단계를 거치게 되며, 각 부 분석 프레임에 대해서 자기 상관값과 정규 방정식을 계산함으로써 프레임 별 AR 계수를 추출하게 된다. 다음으로 평균 추정기를 통해 안정된 IAR 계수를 추출하게 된다. 부 분

석 프레임의 개수를 높일 경우 즉 겹치는 비율(overlapping)을 높일 경우 인식율의 향상을 가져 올 수 있지만, 많은 연산 시간이 필요하므로 적절한 부 분석 프레임의 개수가 결정되어야 한다.

기존의 이러한 IAR 계수 추출방법은 부 분석 프레임에서 추출된 AR 계수는 차수에 해당하는 벡터 공간상의 특정 위치에 놓여진다고 생각 할 수 있으며, 평균 추정기는 이러한 AR 계수의 중심점을 추정하게 된다. 그러나 이러한 방법의 문제는 어떠한 부 분석 프레임의 AR 계수가 다른 부 분석 프레임의 AR 계수와 많은 차이를 보일 때에는 평균 추정기에 의해 추정된 IAR 계수는 중심점의 편차를 가질 수 밖에 없다는 점이다. ICEP 계수 추출방법은 IAR 계수 추출방법에서 추출된 AR 계수로부터 식 (16)과 같이 순환적으로 계산되어진다.

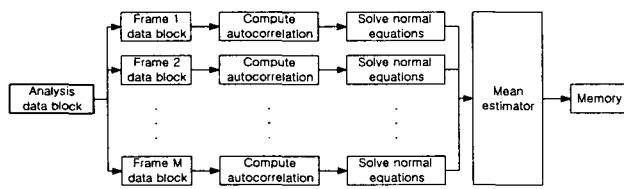


그림 3 기존의 누적 평균 AR 계수 추출 방법

Fig. 3 Existing method for extracting conventional integrated mean AR coefficients

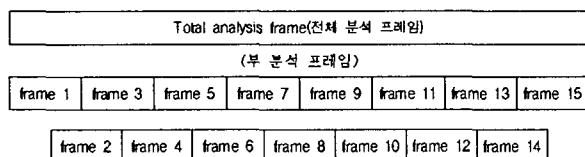


그림 4 IAR 계수 추출시 50% 겹치는 비율의 예

Fig. 4 Example of 50% overlapping in extracting with IAR coefficients

본 논문에서는 기존의 IAR 계수 추출 방법에서 중심점의 이동 편차를 감소시키기 위해서 그림 5와 같이 개선된 mIAR 계수 추출 방법을 제안한다.

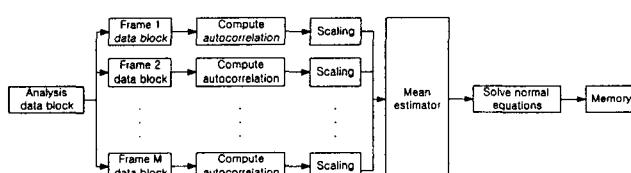


그림 5 제안된 특징 파라미터 추출 방법

Fig. 5 Proposed method for extracting feature parameters

본 논문에서 제안된 방법은 부 분석 프레임별로 자기 상관값을 추출한 후 $\widehat{R}_{yy}(0)$ 값으로 정규화 과정을 거친 후 평균 자기 상관값을 추정하게 된다. 우선 분석 프레임에 대해 여러 개의 프레임으로 부 분석 프레임을 나누는 단계를 거치게

되며, 각 부 분석 프레임에 대해 프레임별로 자기 상관값을 추출한 후 스케일링(scaling) 단계를 거쳐서 평균 추정기를 통과한 후에 정규 방정식을 계산함으로써 프레임별 AR 계수를 추출하게 된다. 기존의 IAR 계수 추출방법에서 추출된 AR 계수는 차수에 해당하는 벡터 공간상의 특정 위치에 놓여진다고 생각 할 수 있으며, 평균 추정기는 이러한 AR 계수의 중심점을 추정하게 된다.

IAR 계수 추출방법에서 단점은 어떠한 부 분석 프레임의 AR 계수가 다른 부 분석 프레임의 AR 계수와 많은 차이를 보일 때에는 평균 추정기에 의해 추정된 IAR 계수는 중심점의 편차를 가질 수 밖에 없다는 점이다. 이러한 단점을 개선하기 위하여 제안된 mIAR 계수 추출 방법에서 $\widehat{R}_{yy}(0)$ 값에 의한 정규화 과정은 부 분석 프레임의 에너지의 분포의 변화에 대해 AR 계수의 변화를 보상하는 역할을 수행한다. 이렇게 추정된 자기 상관값에 대하여 정규 방정식을 계산하여 안정된 AR 계수를 추출하는 과정을 거친다. IAR, mIAR 계수 추출방법에서 겹치는 비율에 의해 부 분석 프레임을 나누어 수행함으로써 연산 시간에 있어서의 단점은 있지만, 인식율의 향상을 위해서는 이와 같은 수행이 유리하다고 할 수 있다.

mICEP 계수 추출방법은 mIAR 계수 추출방법에서 추출된 AR 계수로부터 식 (16)과 같이 순환적으로 계산되어지며, 캡스트럼 분석의 특징은 신호의 스펙트럼에 대하여 로그함수를 취함으로써 주파수 영역에서 진폭 레벨이 적은 부분, 즉 전력이 적은 대역에 대하여 더 강조하는 효과를 갖는다.

2.3 분류 알고리듬

2.3.1 K-means 알고리듬에 의한 군집화

목과 어깨의 각 동작에 따라 발생한 근전도 신호를 분류하기 위하여 AR 계수 또는 캡스트럼 계수가 구해지면, 이를 계수 데이터 집합에서 군집(cluster)의 중심을 결정하여야 한다. 군집의 중심을 결정하는 방법은 최소거리 개념에 기반을 두고 있다. 본 논문에서는 K-means 알고리듬[14][15]을 이용하였다.

K-means 알고리듬의 결과는 군집 중심의 개수(목과 어깨의 동작시 발생하는 근전도 신호별 그룹의 개수), 초기 군집 중심의 선택, 표본의 처리 순서, 그리고 데이터의 기하학적 특성 등에 영향을 받고, 데이터가 서로 비교적 멀리 떨어진 특성을 나타낼 때, 양호한 동작 인식을 위한 근전도 신호 패턴분류 결과를 가져오도록 한다.

2.3.2 유사도 측정법

2.3.1 절에서 군집화 알고리듬에 의해서 기준패턴은 결정될 수 있었다. 다음으로는 이렇게 결정된 기준패턴과 임의의 시험 패턴과의 유사도 측정을 하게된다. 유사도 측정이란 임의의 시험패턴을 선정된 기준패턴들과 비교하여 시험패턴을 형성하고 있는 주파수 및 파형의 성질, 스펙트럼 등의 특징 파라미터가 기준패턴과 일치하는지를 판별하고 일치 여부를 결정 할 수 있는 방법을 말한다. 경우에 따라서는 특정 문턱치를 적용하여 문턱치 이하일 경우 어느 기준패턴에도 속하지 않다고 결정을 내릴 수도 있다. 유사도 측정법은 왜곡 측정

(distortion measure)법, 부동 측정(dissimilarity measure)법, 거리 측정(distance measure)법 등으로 불리워지며[11], 보통 벡터공간에서 거리[16]를 이용하므로 거리 측정법 또는 거리 측도법이라는 용어를 많이 사용한다.

거리 측정법은 기준이 되는 패턴과 비교하고자 하는 패턴을 벡터로 표현하고 벡터공간에서 두 벡터간의 거리를 측정하고 해석하는 것이다. 기준패턴과 시험패턴은 각기 식 (17), (18)과 같이 벡터로 표현할 수 있다.

$$\mathbf{R}_i = [R_{i1}, R_{i2}, \dots, R_{ip}] \quad (17)$$

$$\mathbf{X} = [X_1, X_2, \dots, X_p] \quad (18)$$

여기서 R_i 는 균전도 신호의 종류별 인덱스가 i 인 특징 파라미터 벡터를 나타내며 차수는 p 차임을 말한다. 마찬가지로 임의의 시험패턴도 동일한 형태로 나타낼 수 있다.

도개의 패턴 벡터가 벡터공간에서 특정 지점이나 동일지점을 가리키게 되고 두 패턴 벡터의 크기가 같다면 특정 파라미터가 동일한 경우가 된다. 즉 특징 파라미터가 유사한 값을 가질수록 두 패턴 벡터는 특정지점에 가깝게 되어 시험 패턴이 기준패턴과 동일하게 분류된다. 패턴 벡터의 비교식은 식 (19)와 같다.

$$\begin{aligned} d(R_i, X) &= 0, & R_i &= X \\ d(R_i, X) &> 0, & R_i &\neq X \\ d(R_i, X) &= d(X, R_i), & \text{대칭} \end{aligned} \quad (19)$$

러한 개념을 정량적인 값으로 변환할 수가 있는데 가장 보편적인 방법으로는 유클리디언 거리 측도법(Euclidean distance measure : EDM)을 들 수가 있다. EDM은 식 (20)과 같으나 나타낼 수 있다.

$$d_E(X, R_i) = \|X - R_i\| = \sqrt{(X - R_i)(X - R_i)^T} \quad (20)$$

여기서 $\|\cdot\|$ 는 놈(norm) 연산자를, T 는 전치 행렬을 나타낸다. 그리고 이러한 거리 측정법의 결과 값은 실수 값이 되며 다음 식들과 같이 거리함수 d 와 두 개의 패턴 벡터 x, y 를 사용하여 벡터공간 V 에서의 특징을 정의할 수 있다.

- (i) $0 \leq d(x, y) \leq \infty, \quad x, y \in V$
- (ii) $d(x, y) = d(y, x), \quad x, y \in V$
- (iii) $d(x, y) \leq d(x, z) + d(y, z), \quad x, y, z \in V$
- (iv) $d(x+z, y+z) = d(x, y)$

EDM을 3개의 군집이 있다는 가정 하에 3차원 공간상에서 임의의 패턴과 기하학적 거리는 그림 6처럼 나타낼 수 있다.

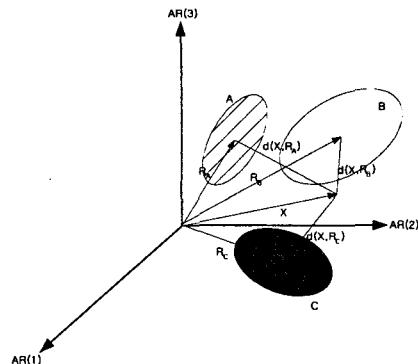


그림 6 공간상에서의 패턴과 기하학적 거리

Fig. 6 Pattern and geometrical distance in vector space

그림 6에서 점을 가리키는 벡터 R_A, R_B, R_C 는 각 군집의 중심을 나타내는 기준 특징 벡터를 나타내며, 이는 다양한 군집화 알고리듬에 의해서 결정될 수 있다. 이렇게 결정된 기준 특징 벡터와 임의의 패턴 벡터 X 는 기하학적으로 볼 때 C 그룹과의 거리 $d(X, R_C)$ 가 가장 작음을 알 수 있다. 따라서 임의의 패턴 벡터 X 는 C 그룹이라고 결정을 내리게 된다.

3. 실험 및 결과 고찰

3.1 측정 시스템 구성과 실험방법

실험 참여인원은 26세-34세 사이 5명의 남자로 하였으며, 피부를 알코올 거즈(gauze)로 닦은 후에 전극을 배치하였다. 전극은 목빗근(sternocleidomastoid muscle)과 상부 등세모근(upper trapezius muscle) 사이 양쪽으로 주 근육들 위에 분리해서 위치를 정한 S-type 형태로 배치시켰는데, S-type 배치에서 두 전극의 각각의 쌍에 대해서, 하나는 목빗근에 다른 하나는 상부 등세모근에 양쪽으로 배치하였다.

피 실험자는 C4 레벨 또는 그 이하에서의 신경이 마비된 사지마비 환자를 위해서 Kang[3]에 의해 제안된 머리와 어깨의 10 가지 동작을 수행하였다. 표 1에서는 실험에서 수행된 10가지 동작들을 보여주고 있다.

표 1 실험에서 수행된 동작들

Table 1 Motions performed in experiment

순서	동작	동작 상세 설명
1	Head flexion(Hf)	머리 앞으로 굽힘
2	Head extension(He)	머리 앞으로 굽힌 상태에서 펴
3	Head right rotation(Hrr)	머리 정면에서 오른쪽으로 회전
4	Head left rotation(Hlr)	머리 정면에서 왼쪽으로 회전
5	Head right sidebending(Hrb)	머리 오른쪽으로 기울임
6	Head left sidebending(Hlb)	머리 왼쪽으로 기울임
7	Right shoulder elevation(Sre)	오른쪽 어깨 올림
8	Right shoulder retraction(Srr)	오른쪽 어깨 뒤로 후퇴
9	Left shoulder elevation(Sle)	왼쪽 어깨 올림
10	Left shoulder retraction(Slr)	왼쪽 어깨 뒤로 후퇴

머리 앞으로 굽힘, 평, 회전, 기울임 등과 같은 동작들에서는 목벗근이 주가 되고, 반면에 상부 등세모근은 어깨울림과 뒤로 후퇴에 이용된다. 이 때 피 실험자는 C4레벨 또는 그 이하의 신경이 마비된 사지마비 환자와 같은 동작을 실현하기 위하여 팔걸이가 없고, 좁은 등받이를 가진 의자에 앉혀졌고, 괄뚝은 어깨의 동작 시에 영향을 받지 않도록 하기 위하여 다리 위에 얹혀 놓도록 하였다.

각각의 동작은 20번 반복 수행하였다. 근전도 센서를 통해 검출된 신호를 증폭기에서 1000배 증폭하고, 20~450Hz 대역 통과 필터링을 수행하였다. 근전도 신호는 2채널로 취득되었으며 2.5kHz의 샘플링 주파수로 2초간 기록되었다.

3.2 결과 고찰

그림 7과 8은 전형적인 목 동작의 취득된 신호의 예를 보여 준다. 그림 7은 Hlr 동작으로 (a)는 채널 1(왼쪽)에서 취득된 신호이며, (b)는 채널 2(오른쪽)에서 취득된 신호이다. 그림 8에서 보듯이 채널 1의 신호가 채널 2의 신호보다 진폭이 훨씬 작음을 알 수 있다. 즉 Hlr 동작 시 오른쪽 목 근육이 왼쪽 목 근육의 사용보다 큼을 알 수 있다. 그리고 500과 1000샘플 구간 사이에서 목 근육의 수축이 시작되어 3000에서 3500구간 사이 샘플 부근에서 동작이 완료되었음을 확인 할 수 있다.

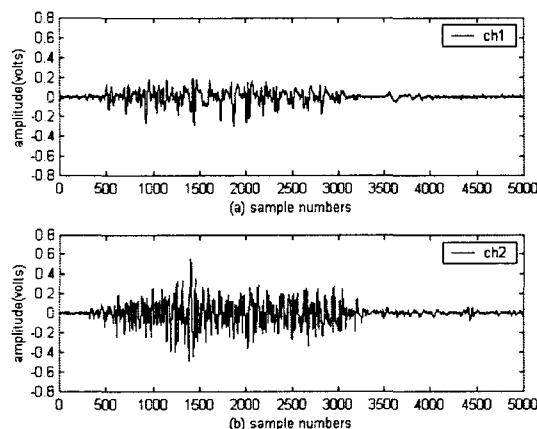


그림 7 Hlr 동작시 취득된 근전도 신호

(a) 채널 1(왼쪽) (b) 채널 2(오른쪽)

Fig. 7 EMG signal obtained in Hlr motion

(a) channel 1(left) (b) channel 2(right)

그림 8은 Hrr 동작으로 (a)는 채널 1(왼쪽)에서 취득된 신호이며, (b)는 채널 2(오른쪽)에서 취득된 신호이다.

Hrr 동작은 Hlr 동작과 상반되는 동작으로 이번에는 채널 1의 신호가 채널 2의 신호보다 진폭이 훨씬 큼을 알 수 있다. 이는 Hrr 동작에서는 왼쪽 목 근육이 오른쪽 목 근육보다 많이 사용된다고 생각할 수 있다. 500에서 1000샘플 구간 사이에서 Hrr 동작이 시작되어 3000에서 3500샘플 구간 사이에서 동작이 완료되었음을 알 수 있다.

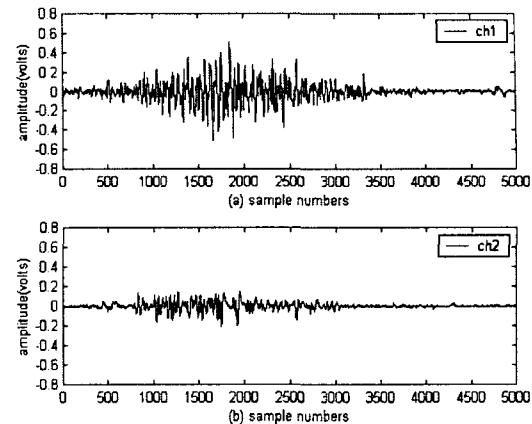


그림 8. Hrr 동작시 취득된 근전도 신호

(a)채널 1(왼쪽) (b) 채널 2(오른쪽)

Fig. 8. EMG signal obtained in Hrr motion

(a)channel 1(left) (b)channel 2(right)

표 2 와 그림 9는 6가지의 인식실험 방법들을 사용하여 10 가지 동작에 대한 인식실험을 수행한 결과를 보여주고 있다. 고전적인 AR/EDM 방법은 73%로 가장 낮으며, IAR/EDM 방법은 고전적인 AR/EDM 방법보다 인식율이 향상됨을 알 수 있다. 이는 겹치는 비율에 의해 부 분석프레임을 나누어 수행함으로써 연산 시간에 있어서의 단점은 있지만 인식율의 향상을 위해서는 이와 같은 수행이 유리하다고 할 수 있다. 본 논문에서 제안한 mIAR/EDM 방법은 90%의 인식율을 보

표 2 인식실험 결과

Table 2 Results of recognition test

(unit : %)

인식 방법	1	2	3	4	5	6
피리미티브 동작	AR /EDM	IAR /EDM	mIAR /EDM	CEP /EDM	ICEP /EDM	mICEP /EDM
Head flexion	75	75	90	80	85	97.5
Head extension	65	75	85	65	90	97.5
Head right rotation	80	85	95	75	85	97.5
Head left rotation	85	85	95	80	80	97.5
Head right sidebending	80	75	90	80	80	95
Head left sidebending	75	80	90	80	80	95
Right shoulder elevation	65	75	90	75	80	90
Right shoulder retraction	80	80	90	80	85	90
Left shoulder elevation	65	75	90	70	80	90
Left shoulder retraction	60	70	85	75	85	90
평균(%)	73	77.5	90	76	82	94

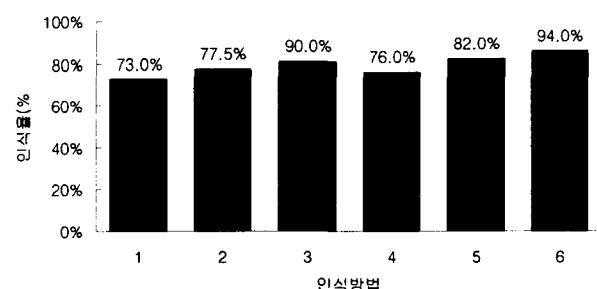


그림 9 인식 실험 결과 (인식방법 1 : Kang[3]의 방법, 인식방법 6 : 본 연구에서 제안한 방법)

Fig. 9 Results of recognition test (method 1 : Kang[3], method 6 : proposed method in this study)

여주었고, 기존의 2가지 방법보다 우수한 결과를 나타내었다. 이는 본 논문에서 제안된 방법이 AR 계수 추정에 있어서 훨씬 정정된 결과를 나타낼 수 있음을 보여준다. CEP(ceps-trum)/EDM 방법은 AR 계수로부터 계산되어진 켭스트럼 계수를 특징 파라미터로 이용한 결과이며, AR/EDM의 방법보다 3%의 인식율의 향상을 보여주고 있다. 이는 기존의 연구에서 AR 계수보다 켭스트럼 계수의 이용이 인식실험에서 우수한 결과를 보여준다는 것과 동일한 결과를 보여준다[3]. ICEP/EDM 방법은 IAR 계수로부터 켭스트럼 계수를 계산한 결과를 이용한 인식 결과이며, IAR/EDM에서의 인식율보다 4.5%의 인식율의 향상을 보여주고 있다. mICEP/EDM 방법은 제안된 mIAR 계수로부터 켭스트럼 계수를 계산한 결과를 이용한 인식 결과이며 mIAR/EDM에서의 인식율보다 4%의 인식율의 향상을 보여주었다. 인식실험 결과에서 보듯이 제안된 mIAR 계수를 이용한 mICEP 계수를 이용하는 방법이 94%로 인식율이 가장 높게 나타났다.

4. 결 론

본 논문에서는 머리가 움직일 때 근전도 신호를 측정하여 동작 인식실험을 수행하였다. 기존의 연구자는 고전적인 AR 계수와 켭스트럼 계수를 사용하여 60%~80%의 인식율을 얻었고, IAR계수와 ICEP계수를 사용하여 70%~85%의 인식율을 얻었다. 본 논문에서는 각 부 분석 프레임에 대하여 자기 상관값을 추정한 후 평균 추정기를 거쳐 정규 방정식의 해를 구하는 mIAR 계수를 사용하여 머리가 움직일 때 동작 인식율이 85%~95%로 우수한 결과를 보였다.

또한 본 논문에서는 AR 계수에 의한 인식실험보다 켭스트럼 계수에 의한 인식실험이 더 우수한 인식율을 보였다. 10가 동작 평균 인식율이 AR, IAR, mIAR 계수 사용시 73%~90%인 반면에 켭스트럼, ICEP, mICEP 계수 사용시 76%~94%로 켭스트럼 계수에 의한 인식율이 AR 계수에 의한 인식율보다 평균 3%~4% 정도 높게 나타났다.

제안된 mIAR 계수로부터 계산되어진 mICEP 계수가 6가지 파라미터를 사용한 인식실험 중에서 가장 높은 인식율을 나타냈다. 고전적인 AR 계수에 의한 방법보다 제안된 mIAR 계수를 이용하는 방법이 인식율에 있어서 17%의 향상을 보였으며 mICEP 계수를 이용하는 방법은 21%의 향상을 보였다. 제안된 부 분석 프레임에서의 AR 계수 추정 방법 및 Cepstrum 계수 추정 방법은 근전도 신호 인식뿐만 아니라 다른 패턴 인식분야에서 쉽게 구현이 가능하며, 폭 넓은 활용이 기대된다.

참 고 문 헌

- [1] G. Hefftner and G. G. Jaros, "The electromyogram (EMG) as a control signal for functional neuromuscular stimulation-Pt. II: Practical Demonstration of the EMG signature discrimination system," IEEE Trans. on Biomed. Eng., vol. 35, pp. 238~242, April. 1988.
- [2] B. Hudgins, P. Parker, and R. N. Scott, "A new strategy for multifunction myoelectric control," IEEE Trans. on Biomed. Eng., vol. 40, pp. 82~94, Jan., 1993.
- [3] W.J. Kang, J.R. Shiu, C.K. Cheng, J.S. Lai, H.W. Tsao, and T.-S. Kuo, "The Effect of Electrode Arrangement on Spectral Distance Measures for Discrimination of EMG Signal," IEEE Trans. on Biomed. Eng., vol. 44, pp. 1020~1023, October 1997.
- [4] J.M. Salavedra, E. Masgrau, A. Moreno, J. Estarellas, "Variable Frame Length Of A Higher Order Speech AR Estimation In A Speech Enhancement System," IEEE Seventh SP Workshop on Statistical Signal and Array Processing , pp 219~222, June 26-29, 1994.
- [5] Wen-Rong Wu, Po-Chen Chen, Hwai-Tsu Chang, Chun-Hung Kuo, "Frame-based subband Kalman filtering for speech enhancement," 1998 Fourth International Conference on Signal Processing Proceedings, vol.1, pp 682~685 , 12-16 Oct. 1998
- [6] W. Gersch, D. R. Sharpe, "Estimation of Power Spectra with Finite-Order Autoregressive Models," IEEE Trans. on Automation Control, vol. 5, pp 367~369, 1973.
- [7] Alan V. Oppenheim, Ronald W. Schafer, Discrete-Time Signal Processing, Prentice-Hall, Inc., 1989.
- [8] C.S. Pattichis and A.G. Elia, "Autoregressive and cepstral analyses of motor unit action potentials," J. Electrogmyogr. Kinesiol. Medical Eng. & Physics, vol. 21, pp. 405-419, 1999.
- [9] S. J. Orfanidis, Optimum Signal Processing, McGraw Hill, New York, 1985.
- [10] Peyton Z., Peebles JR, Probability Random Variables and Random Signal Principles, McGraw-Hill, 1993.
- [11] Lawrence Rabiner, Biing-Hwang Juang, Fundamentals of Speech Recognition, Prentice-Hall Inc., pp. 163~166, 1993.
- [12] X. P. Maldague, Advances in Signal Processing for Nondestructive Evaluation of Materials, Kluwer Academic Publishers, 1993.
- [13] Jingping Xu, Jingzhi Cheng, Yanjun Wu, "A Cepstral Method for Analysis of Acoustic Transmission Characteristics of Respiratory System," IEEE Trans. on Biomedical Eng., vol. 45 5, pp 660~664, May 1998.
- [14] Keinosuke Fukunaga, Introduction to Statistical Pattern Recognition, Academic Press, Inc. Second Edition, 1990.
- [15] Sadaoki Furui, Digital Speech Processing, Synthesis, and Recognition, Marcel Dekker Inc., 1992.
- [16] Agustine H. Gray, JR. and John D. Markel, "Distance Measure for Speech Processing." IEEE Trans. on Biomedical Eng., vol. ASSP-24, No. 5, pp. 380~391, October, 1976.
- [17] McGill, K. C., "Optimal resolution of superimposed action potentials." IEEE Trans. on Biomedical Engineering, vol. 49, pp 640~650, July 2002.
- [18] Lowery, M. M. Stoykov, N.S. Kuiken, T.A., "Independence of myoelectric control signals examined using a surface EMG model." IEEE Trans. on Biomedical Engineering vol. 50, pp 789~793, June 2003.

저자 소개

이태우 (李泰雨)

1967년 12월 15일생. 1992년 2월 성균관대학교 전자공학과 졸업. 2002년 서울시립대 2002년 8월 ~ 현재 : 서울시립대학교 전자전기컴퓨터 공학부 박사과정
e-mail : future21@dreamwiz.com



유세근 (俞世根)

1992년 연세대학교 의용공학과 졸업. 1994년 서울시립대학교 대학원 전자공학과 졸업(공석). 1995년 3월 ~ 현재 : 울산대학교 대학원 전자공학과 박사과정
e-mail : samwoo@markany.com



전창의 (全昌翼)

1971년 3월 9일생. 1996년 서울시립대학교 전자공학과 졸업. 1999년 동 대학원 전자공학과 졸업(공석). 2000년 ~ 현재 서울시립대학교 전자전기공학부 박사과정 수료



김성환 (金成煥)

1952년 6월 12일 생. 1975년 2월 연세대 전기공학과 졸업. 1980년 2월 동 대학원 전기공학과(공박). 1977 ~ 1982년 대전 기계창. 1982년 ~ 현재 서울시립대 전자 · 전기공학부 교수.
Tel : 2210-2449, Fax : 2249-6802
E-mail : shkim1@uoscc.uos.ac.kr



이영석 (李泳錫)

1968년 2월 13일생. 1993년 2월 : 서울시립대학교 전자공학과(공학 학사). 1995년 2월 : 서울시립대학교 대학원 전자공학과 졸업(공업석사). 1998년 2월 : 서울시립대학교 대학원 전자공학과 졸업(공학 박사). 현재 청운대학교 전자공학과 조교수
E-mail : yslee@cwunet.ac.kr

