

論文 91-28B-10-10

신경회로망과 확률모델을 이용한 근전도신호의 패턴분류에 관한 연구

(A Study on the Pattern Classification of the EMG Signals Using Neural Network and Probabilistic Model)

張永健*, 權章禹*, 韓永煥*, 張元碩**, 洪勝弘*

(Young Gun Jang, Jang Woo Kwon, Young Hwan Han, Won Suk Jang, and Seung Hong Hong)

要 約

본 논문은 근전도신호의 패턴분류를 하기 위해 확률모델과 MLP 모델을 합성하여 이용하는 새로운 모델을 제안하였다.

MLP 모델은 오차의 총체적 최소치를 보장하지 못하고 베이지 확률에 대한 근사정도에 문제점이 있으며 확률모델은 모델 파라미터의 추정오차 및 가정의 충실도에 크게 연관된다. 이 두 방식을 적절히 조합하면 각각의 방식의 문제점을 보완해주며 입력변화에 대해서 더욱 견고해질 것이다. MLP 모델을 이용하여 사전확률분포를 적응적으로 추정하므로써 확률 모델에서 최대 사후 확률을 구하는 방식을 제안하였다. 이 방식은 MLP 모델의 구현이 최적인한 확률 모델의 오분류확률을 최소화하며 MLP 모델의 신뢰도를 이용한 결합이다.

모의 실험결과 MLP 모델과 확률모델을 독자적으로 사용하는 것에 비해 제안된 모델의 유용성이 입증되었으며 CPU 클럭이 25MHz인 IBM PC 386기종을 이용시 분류를 위한 계산시간은 합성운동의 경우 평균 50ms가량 소요되었다.

Abstract

A combined model of probabilistic and MLP (multi layer perceptron) model is proposed for the pattern classification of EMG (electromyogram) signals.

The MLP model has a problem of not guaranteeing the global minima of error and different quality of approximations to Bayesian probabilities. The probabilistic model is, however, closely related to the estimation error of model parameters and the fidelity of assumptions. A proper combination of these will reduce the effects of the problems and be robust to input variations.

Proposed model is able to get the MAP (maximum a posteriori probability) in the probabilistic model by estimating a priori probability distribution using the MLP model adaptively. This method minimize the error probability of the probabilistic model as long as the realization of the MLP model is optimal, and this is a good combination of the probabilistic model and the MLP model for the usage of MLP model reliability.

Simulation results show the benefit of the proposed model compared to use the MLP and the probabilistic model separately and the average calculation time for classification is about 50ms in the case of combined motion using an IBM PC 25MHz 386 model.

*正會員, 仁荷大學校 電子工學科

(Dept. of Elec. Eng., Inha Univ.)

**正會員, 建陽大學校 컴퓨터工學科

(Dept. of Comp. Eng., Keongyang Univ.)

接受日字: 1991年 7月 19日

I. 서 론

근전도신호는 근육의 수축시에 발생하는 전기적 신호로서 척수에서 신경임펄스가 발생되어 운동뉴런

을 활성화시키고 이에 따라 운동단위 (motor unit) 내의 근섬유가 활성화되면서 전위차 (motor unit action potential)가 발생하는데 이 현상은 표피전극에 의한 공간적 합으로서 추출이 가능하다. 힘이나 속도에 대한 추정적도로서 표피전극에 의한 EMG (electromyogram)의 측정은 근육내의 운동뉴런에 직접 침투시키는 바늘 형태의 전극에 의한 것보다 좀 더 분명하고 신뢰성이 있다.⁸⁾

EMG 신호처리의 분야는 크게 진단의학이나 스포츠 과학분야와 재활용공학분야의 보철제어 (prosthetic control) 응용³⁻⁶⁾⁷⁾⁹⁻¹⁰⁾으로 나눌 수 있다. 보철제어를 위한 신호처리에 대한 연구로서 아티팩트 (artifact)를 줄이거나 신호대 잡음비를 높이는 방식에 관한 연구,⁴⁾⁶⁾¹¹⁾¹²⁾ 기능분리의 신뢰도 및 정도를 높이는 방식에 관한 연구³⁾⁵⁻⁶⁾⁹⁻¹⁰⁾와 실시간 처리에 관한 연구³⁾¹⁶⁾ 등이 있다. EMG 신호를 신호원으로 사용하는 보철제어에 있어 기능분리는 가장 기본이 되는 기능으로서 이 부분의 신뢰도 및 정도의 확보없이는 그 결과를 이용하는 분해 (decomposition) 및 제어 (control)가 아무런 의미가 없게된다. 따라서 본 논문에서는 근전도 신호의 패턴분류의 오분류확률을 최소화하는 모델을 제안하여 기능분리의 신뢰도를 확보하고자 한다.

기능분리에 대한 연구로서는 Graupe¹³⁾ 등이 ARMA 모델을 적용하여 마이크로 프로세서로 구현하였으며 0.15-0.2초 이내에 완전한 분리를 할 수 있었고 85% 정도의 성공율을 보였다. Saridis^{15,7)} 등은 영교차수와 분산을 이용하여 6개의 기본운동으로 구성된 27가지 운동에 대해 85-90%의 운동이 최대 오분류 확률추정이 10%미만으로 분리될 수 있었다. Willsky¹²⁾ 등은 4개 채널로 다중 모델가정 탐지법 (multiple-model hypothesis detection method)을 적용하여 6개의 팔운동을 분리해 냈고 이것은 신호의 공간적, 시간적 상관성을 처음으로 이용한 방식이다. Triolo¹⁸⁾ 등은 기능분리에 탁월한 병렬필터링 광기능분류기와 신호대잡음비에서 우수한 다중채널 근전도처리를 결합한 완벽하고 견고한 다중채널 시계열 근전도 처리기를 제안하였다. 최근에 와서는 Heftner,¹⁷⁾ Graupe 등에 의해 FNS분야에 EMG 기능분리에 의한 보철제어가 활발히 적용되고 있다.

기능분리에 대한 연구는 방식에 따라 상호 보완적으로 발전하여 왔으며 문헌상에 발표된 것으로 기능분리에 대한 오분류율을 상호 비교한다는 것은 음성이나 화상처리와는 달리 표준화된 데이터 베이스가 없어 큰 의미가 없어 보인다. 근전도 신호처리에 있어 최대의 난점은 신호가 잡음이 많고 시간에 따

라 변하며 일정시간 간격에 대해 준정주성 (quasi-stationary) 밖에 갖고있지 않아 기준 패턴 및 모델의 신뢰성이 제한되며 특히 패턴의 종류가 많고 분류군 (class)의 분리도 (seperability)가 작을 때 오 인식의 확률이 증가한다는 점이다. 따라서 모델의 신뢰성을 고양시키고 견고성 (robustness)을 확보하는 것이 관건이다. 분류를 행하고 결정을 내림에 있어 임의의 클래스에 대한 각 모델의 오분류율에 차이가 발생하며 그 원인은 다양하다. 단일 데이터 전체를 처리하는데 있어 분류모델에 따라 우수한 인식율을 보이는 클래스가 다르다고 가정하면 상호 협조적이고 통합적인 결정을 내림으로써 좀 더 오분류율을 줄이고 견고성을 확보할 수 있을 것이다.

본 논문에선 통계적 분류법인 Saridis등에 의해 제안된 확률모델 (probabilistic model)과 비파라미터 분류기 (nonparametric classifier)의 일종으로 비선형분류에 있어서 탁월한 성능을 보이고 있는 MLP 모델을 합성하여 MAP를 산출하는 방식을 제안한다. (그림1) 확률모델에 의한 분류의 문제점은 근전도 신호를 발생하는 생체시스템이 실제적으로 시변시스템이고 신호가 국부적으로 광의의 정주성 (locally wide-sense stationary)을 갖는 모델에선 신호취득원을 시불변시스템 (time invariant system)이고 신호가 에르고딕 (ergodic) 하다고 가정하므로써 발생한다. 그 결과 모델 파라미터로서의 영교차율이 클래스간 중첩침이 심하여 그 대표값 추정의 신뢰도가 저하되며 이러한 현상은 MLP모델에 있어서도 어느정도 영향을 미친다. MLP모델에 있어서 훈련파라미터의 설정에 있어 설계자에 따라 적응성 및 오분류율의 차이가 발생하며 훈련시 학습 알고리즘의 문제로 기준 패턴과 학습패턴 사이의 오차에 대해 총체적 최소치 (globalminima)를 보장해 주지 못하는 단점이 있다. 훈련이 끝난 MLP의 출력은 베이즈 확률을 근사적

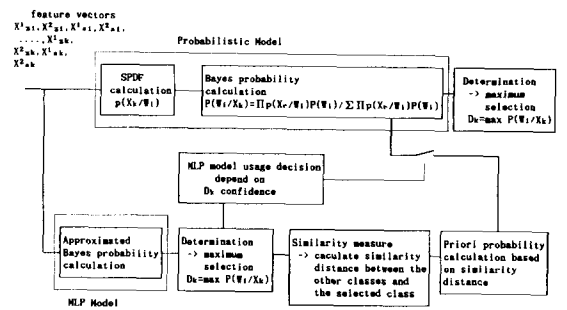


그림 1. 분류기의 구성
Fig. 1. Classifier configuration.

으로 묘사하므로 그 출력의 합이 1인가를 시험하므로서 총체적 최소치에 도달했는지에 대한 시험을 할 수 있다.¹⁵⁾

모델링에 사용된 가정은 다음과 같다.

- 영교차수는 이항분포를 갖는다.
- 근전도신호는 에르고딕하다.
- 피로가 없는 (non fatigue), 등방성, 등장성 (isotropic) 근육 수축
- 분산 (variance)은 절대적분치의 자승에 비례한다.
- 절대적분치는 통계적으로 추정된 기준치 주변에서 가우시안분포를 갖는다.
- 합성운동 (combined motion)은 기본운동 (primitive motion)의 구분적 선형함수 (piecewise linear function)이다.

II. MLP 모델

1958년 Rosenblatt에 의해 Perceptron의 개념이 도입된 이래 수십년에 걸쳐 간헐적으로 패턴인식에 있어 Perceptron의 구조 및 학습 알고리즘에 대한 연구가 진행되어 왔다.¹⁶⁾ 1986년 Rumelhart등에 의해 Perceptron을 효율적으로 학습시킬 수 있는 오차의 역전파알고리즘 (error backpropagation)이란 델타 규칙을 일반화시킨 학습프로시저가 만들어짐에 따라 패턴인식분야에 MLP의 적용이 활발히 이뤄지고 있다.¹⁰⁾¹⁶⁾

잘 훈련된 MLP의 출력에서 특징벡터의 확률이 크다면 MLP가 베이스 최적 판별 함수를 근사적으로 묘사한다는 것¹²⁾과 MLP의 출력이 후회률의 추정¹²⁻¹³⁾이라는 것은 이전의 여러 연구에서 증명되었다. 따라서 MLP의 출력을 $F(W_i/X)$ 라 하면

$$F(W_i/X) \cong P(W_i/X) \tag{1}$$

; X는 feature vector, W_i 는 i번째 class

의 식이 성립한다. 또한 베이스 프로세스에서 MAP는 오분류확률을 최소화하는 최대 판별함수에 대응한다는 것이 밝혀져 있다.¹⁴⁾ Bayes rule에 의해 $P(W_i/X)$ 는

$$P(W_i/X) = P(X/W_i)P(W_i)/P(X) ; P(X) = \sum P(X/W_i)P(W_i) \tag{2}$$

로 주어진다. 주어진 X에 대해 W_i 가 U_j 로 분류되는 결정과 연관된 상대적 risk $R(U_j/X)$ 는

$$R(U_j/X) = \sum \lambda(U_j/W_i)P(W_i/X) ; \text{모든 } j \text{에 대해} \tag{3}$$

의 식으로 나타낼 수 있다. 이때 $X(U_j/W_i)$ 는 최소 오분류율에 대한 대칭적 손실함수이고 W_i 를 U_j 로 분류하는 것은 판별함수를 $G_j(X) = -R(U_j/X)$ 로 정의하면 최대 판별함수가 MAP에 대응되는 $G_j(X) = P(W_j/X)$ 가 존재한다. 따라서 최소 오분류율에 대해 만일

$$P(W_j/X) > P(W_i/X) ; \text{모든 } j \neq i \text{에 대해} \tag{4}$$

이면 U_j 로 결정한다. 그러므로

$$P(U_j) = \max P(W_j/X) ; j=1, 2, \dots, M \tag{5}$$

식이 성립한다. 식(1)과 식(5)의 결과로서 MLP의 최대출력의 선택은 오분류율을 최소화하는 결정이다. 즉

$$P(U_j) \cong \max F(W_j/X) \tag{6}$$

이 성립한다. 그러나 이러한 결과는 국부적 결정에 국한된 것으로 1개의 샘플에 의한 판단으로 신뢰도가 부족할 때 다단결정법 (multi stage decision method)을 사용하는 것이 오분류율을 순차적 샘플링에 의한 다수의 샘플로서 제어할 수 있는 잇점을 갖는다.¹⁹⁾

연속된 EMG 샘플을 서로 독립적이라고 가정하면 k개의 연속된 샘플 (X_1, X_2, \dots, X_k)에서 오분류율을 최소화하는 분류를 행할 확률 $P_k(U_j)$ 는

$$P_k(U_j) = \prod_r^k P_r(U_j) \cong \max_r \prod_r^k F_r(W_j/X_r) \tag{7}$$

로 정의된다.

III. 확률 모델

EMG 신호에 대한 통계적 분석을 통해 EMG 신호는 그의 비정주상 (nonstationary property) 때문에 시계열분석 및 심리적 해석에 대해 신뢰성이 없으나 그 평균값은 패턴분류를 위한 특징 벡터로서 사용될 수 있다는 것이 밝혀졌다.²⁾ 또한 부하 및 속도조건은 근육활동에 시간적 적분에 선형적으로 관련 된다는 것과 영교차수 및 신호분산 같은 특징과 속도와의 관계가 밝혀졌다. 따라서 변화하는 부하와 속도와 무관한 분류 알고리즘의 도출이 가능하다. Saridis등은 영교차수 및 신호분산의 특징벡터를 이용하여 근육활동을 잘 분류할 수 있다는 것을 보여 주었다.⁵⁾⁷⁾

운동종류 및 속도를 규정하는 어떤 임의의 근육명령신호 (m, s)에 대해 측정된 신호에서 어떤 영교차수 및 분산 (X_z, X_p)을 갖을 확률을 $P(X_z, X_p)/(m, s)$ 라 하면

$$P\{X_z, X_v\} = (X_z^1, X_z^2, X_v^1, X_v^2) / (m, s) \} = P\{X_z = (X_z^1, X_z^2) / X_v = (X_v^1, X_v^2), (m, s)\} * P\{X_v = (X_v^1, X_v^2) / (m, s)\} \quad (8)$$

; 1, 2는 서로 다른 EMG신호 취득위치
가 성립한다. 이때 X_z 는 근사적으로 이항분포를 갖고 X_z^1 과 X_z^2 는 서로 독립적이라고 가정하면

$$P\{X_z = (X_z^1, X_z^2)^T / X_v = (X_v^1, X_v^2)^T\} = \begin{bmatrix} N \\ X_z^1 \end{bmatrix} a^{1x_1^z} (1-a)^{N-x_1^z} \begin{bmatrix} N \\ X_z^2 \end{bmatrix} a^{2x_2^z} (1-a)^{N-x_2^z} \quad (9)$$

; a_1, a_2 는 1, 2 패턴의 영교차가 일어날 확률, N 은 프레임당 샘플링 수

의 식이 성립하며 이때 $Na_1[2](1-a_1[2]) \gg 1$ 이면 계산은 단순화를 위해 Demoiivre laplace theorem의 도입이 가능하다. 따라서 식(9)는

$$P\{X_z = (X_z^1, X_z^2)^T / X_v = (X_v^1, X_v^2)^T\} \approx \frac{1}{(2\pi\sqrt{a_1a_2(1-a_1)(1-a_2)})} \exp\{-[(X_z^1 - Na_1)^2 / 2Na_1(1-a_1) + (X_z^2 - Na_2)^2 / 2Na_2(1-a_2)]\} \quad (10)$$

으로 근사화할 수 있다. 또한 EMG 신호가 평균이 0인 가우시안 분포를 갖고 에르고딕(ergodic) 하다고 가정하면

$$X_v = \pi/2 * X_a^2; X_a \text{는 EMG신호의 절대적분치} \quad (11)$$

의 식이 성립하므로 확률계산시 분산 파라미터가 절대적분치 파라미터로의 변환이 가능하여

$$P\{(X_v^1, X_v^2)^T / (m, s)\} = [1/(\pi^2 X_a^1 X_a^2)] * P\{X_a = (2/\pi) (X_v^1, X_v^2)^T / (m, s)\} \quad (12)$$

의 식이 성립한다. 또한 절대적분치는 기준명령 (m, s) 주위에 가우시안 분포를 갖는 랜덤변수로 모델링이 가능하다.^{[21][22]} 합성운동의 기준명령 (m^i, s)에 대한 절대적분치의 SPDF(sample probability density function)는 그 합성운동에 포함된 기본운동 (i, j)의 절대적분치와 분산의 대표값의 함수로서 다음 식으로 정의된다.

$$P\{X_a / (m, s^i)\} = 1/2\pi\sigma_a\sigma_b [L_a/J_a \exp\{-1/2[a^2/\sigma_a^2 + (S_a - s)^2/\sigma_s^2]\} + L_b/J_b \exp\{-1/2[b^2/\sigma_b^2 + (s_b - s)^2/\sigma_s^2]\}] \quad (13)$$

; $a = (X_a^1 X_r^2 - X_a^2 X_r^1) / \{X_a^1 (X_r^2 - X_r^1) - X_a^2 (X_r^1 - X_r^1)\}$,

$$s_a = \{X_a^1 (X_r^1 - X_r^2) - X_a^2 (X_r^1 - X_r^1)\} / (X_r^1 X_r^2 - X_r^2 X_r^1),$$

$$J_a = |X_r^2 (X_r^1 - X_r^1) - X_r^1 (X_r^2 - X_r^2)| s_a, \\ b = (X_a^1 X_r^2 - X_a^2 X_r^1) / \{X_a^1 (X_r^2 - X_r^2) - X_a^2 (X_r^1 - X_r^1)\}, \\ s_b = \{X_a^1 (X_r^2 - X_r^2) - X_a^2 (X_r^1 - X_r^1)\} / (X_r^1 X_r^2 - X_r^2 X_r^1),$$

$$J_b = |X_r^2 (X_r^1 - X_r^1) - X_r^1 (X_r^2 - X_r^2)| s_b$$

식 (13)에서 사용된 L_a 와 L_b 는 (a, s_a) 및 (b, s_b) 에서 (X_a^1, X_a^2)로 맵핑이 존재한다면 각각 1이 되며 아니면 0이 된다. 또한 $X_r^1, X_r^2, X_a^1, X_a^2, \sigma_a, \sigma_b$ 는 훈련을 통해 생성된 근전도신호의 절대적분치들을 처리하는 통계적 방식에 의해 얻어진다. 따라서 두 위치의 EMG신호의 절대적분치와 영교차수를 측정하므로써 뇌의 운동종류 및 속도를 지칭하는 명령의 확률적 추정, 즉 운동명령 m 의 분류군 W_i ($i=1, 2, \dots, M$)의 확률적 추정이 가능하며 이를 이용하여 MLE 기법에 의한 분류가 가능하다. 만일 사전확률분포 $P(W)$ 를 알 수 있다면 MAP의 적용도 가능하다.

순차적 입력신호 X_1, X_2, \dots, X_k 가 서로 독립적이라고 가정하면 그 베이즈 확률 (Bayes probability)은

$$P(W_i / X_1, X_2, \dots, X_k) = \prod_{j=1}^k p(X_j / W_i) P(W_i) / \sum_{l=1}^k \prod_{j=1}^k p(X_j / W_l) P(W_l) \quad (14)$$

식으로 나타낼 수 있다.

IV. 패턴분류를 위한 MLP 및 확률 모델의 합성

1. 사전확률 추정

식(6)에서 보여주는 바와 같이 MLP의 최대출력의 선택은 오분류율을 최소화하는 결정이므로 다단계결정의 경우 식(7)의 관계가 성립한다. 확률모델에 있어 베이즈확률을 산출하기 위한 식(14)의 사전확률 $P(W_i)$ 를

1) MLP 모델에서 식(7)의 관계를 이용하여 설정된 U_j 와 타 클래스 $U_{i \neq j}$ 와의 유사거리(similarity distance)를 도입하여 추정하거나

2) 모든 클래스에 대한 조인트확률을 구하고 그 조인트확률의 상대적 비로서 추정하여 두 모델을 합성하는 방식을 취하였다. 1)의 추정방법을 선택하면 임의의 운동클래스 W_i 의 구성요소, 즉 포함된 기본 운동클래스를 w_{i1}, w_{i2} 라할 때 결정된 운동클래스 W_r 과의 유사거리는 그 구성요소간의 유사거리의 함으로 다음과 같이 정의한다.

$$d(W_r, W_i) = d(W_i, W_r) = d(w_{r1}, w_{i1}) + d(w_{r2}, w_{i2}) \quad (15)$$

구성요소간 유사거리는 비선형적이고 선형적인 판

계에 의해 다음의 식으로 정의한다.

$$\begin{aligned} d(w_i, w_j) &= d(w_j, w_i), \\ d(w_i, w_j) &= 0 \text{ for } w_i = w_j, \\ d(0, +) &= 1, \\ d(0, -) &= 1, \end{aligned} \tag{16}$$

$$d(+, -) = 3$$

; 0, +, -는 해당 구성요소 즉 기본운동의 방향

계산된 유사거리를 이용하여 사전확률 (priori probability)을 다음의 식으로 정의하여 계산한다.

$$P(W_i) = A^{d w_i, w_r} / \sum_i A^{d w_i, w_r} \tag{17}$$

이때 밑은 $0 < A < 1$ 의 범위에서 선정한다.

2)의 추정방법은 식(7)를 이용하면

$$P(U_i) = \prod_r^k P_r(W_i/X_r) \tag{18}$$

으로 표현할 수 있고 사전확률의 총합을 1로 하고 상대적 선택도를 높이기 위해 사전확률을 식(18)로 표현된 $P(U_i)$ 의 전체확률에 대한 상대적 비로서 정의하면

$$P(W_i) = P(U_i) / \sum_i P(U_i) \tag{19}$$

의 식으로 표현된다. 식(18), (19)로 표현되는 2)의 추정 방식은 다단계결정시 결정단계가 증가함에 따라 1)의 방식에서 식(17)의 A를 선택도를 높이기 위해서 작게 변화시켜야하는 번거로움이 없고 계산시간 측면에서 유리하다.

2. 두 모델의 합성

식(17) 또는 식(19)에 의해 추정된 사전 확률분포 $P(W)$ 를 베이지 확률을 계산하는 확률모델의 사전 확률에 대입하여 그 최대치를 선택하면 MLP 모델과 확률모델의 합성된 특성을 갖는 MAP를 구할 수 있다. 즉 결정 D_k 는

$$\begin{aligned} D_k = \max \left[\prod_r^k p(X_r/W_i) P(W_i) / \sum_i \prod_r^k p(X_r/W_i) \right. \\ \left. P(W_i) \right] \end{aligned} \tag{20}$$

의 식으로 정의된다.

3. MLP모델과 확률모델의 합성여부 결정

MLP 모델의 최대출력값으로 사전확률 $P(W_i)$ 를 추정하여 이것을 베이지확률을 산출하는데 이용하고자 할 때 그 효용성은 그 값의 신뢰성에 의해 결정된다. 따라서 최대 출력값과 분류오차율에 대한 통계적 고찰을 통한 오분류가능성을 최소화하는 신뢰구간의 결정이 필요하며 최대출력값이 신뢰구간내에

있지 않을 때에는 확률 모델만을 사용해 MLE 방식에 의해 기능분리를 행하게 하므로써 적응적 분류기를 구현하였다.

MLP 출력값을 서로 독립적이고 배타적인 정분류와 오분류경우와 상관시켜 최대 출력값에 대한 정분류빈도와 오분류빈도를 구하면

$$\begin{aligned} A(x) &= (x \text{에서 일어난 오분류샘플수}) / \text{총분류샘플수} \\ B(x) &= (x \text{에서 일어난 정분류샘플수}) / \text{총분류샘플수} \\ &; x \text{는 MLP 최대출력}, 0 \leq x \leq 1, 0 \leq A(x) \leq 1, \\ &0 \leq B(x) \leq 1, \\ \int_0^1 A(x) dx + \int_0^1 B(x) dx &= 1 \end{aligned} \tag{21}$$

로 정의된다. 임의의 MLP 최대출력값 x 에 대한 누적 오분류빈도 및 정분류빈도는 단조증가함수가 되고 누적정분류빈도가 누적오분류빈도 보다 커지는 최소 a 는 유일하게 존재한다. 즉 임의의 클래스에서

$$F_1(a) = \int_0^a B_1(x) dx - \int_0^a A_1(x) dx > 0 \tag{22}$$

를 만족하는 최소 a 를 구하면 그 값이 그 클래스의 신뢰구간 문턱치가 된다.

$A_1(x)$ 와 $B_1(x)$ 가 이산적이고 여러개의 클래스가 존재할 때 전체클래스에 대한 신뢰구간문턱치는 식(22)의 대수화로서 구해질 수 있다. 즉 m 개의 클래스가 존재한다고 가정하면

$$F(a) = \sum_i F_1(a_i) > 0 \tag{23}$$

를 만족하는 최소 a 가 전체 클래스에 대한 신뢰구간 문턱치가 된다.

V. 실험방법 및 Simulation 결과

1. 실험환경 및 실험방법

제한한 모델의 타당성검증을 위해 모사장애자가 2차원 평면으로 생각할 수 있는 조이스틱을 조종공간으로 운전을 행하고, 운전을 행하는 팔로부터 근전도 신호를 획득하여 제안한 모델 및 비교 모델에 데이터로 입력시켜 시뮬레이션을 행하였다. 시험 시스템은 그림2와 같이 구성하였으며 실험모습은 그림3과 같다. 실험대상자는 실제의 팔 장애자대신에 팔의 불필요한 운동을 못하게 고안된 그림4와 같은 절단모사기 (amputation simulator)를 사용한 정상인 (simulated amputee)을 선택하여 실험하였다. 증폭기의 이득은 500-3000사이에서 가변적으로 변화시켜 A/D 변환기의 입력범위를 충분히 사용할 수 있게 하였으며 대역통과 여과기의 통과주파수는 피부와 전극사이에 움직임으로 유기되는 포텐셜 및 극포

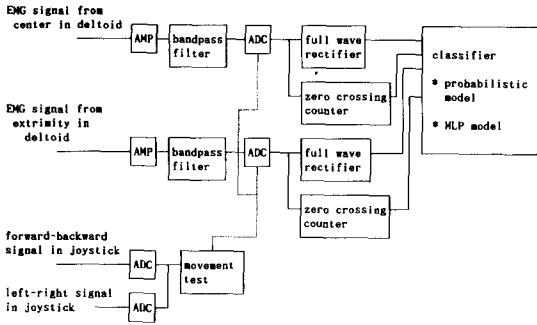


그림 2. 시스템 구성
Fig. 2. System configuration.



그림 3. 실험모습
Fig. 3. Experimental scene.




그림 4. 절단모사기
Fig. 4. Amputee simulator.

텐셜등이 원인인 저주파잡음제거등을 고려하여 10-2000hz로 설정하였다. 실제로 EMG신호의 유효성분을 가진 주파수영역은 참조하는 근육에 따라 다르다.^[2] 획득하는 정보의 길이는 80ms이고 샘플링주파수는 10khz로 하였다.

전극은 일회용 전극을 사용하였으며 어깨의 삼각근의 중심부와 끝부분에 각기 2개씩의 전극(쌍극법)을, 어깨뼈 부분에 접지전극을 부착하여 시험하였다. 전극 부착위치로서 어깨의 삼각근영역을 선택한 것은 2차원 조이스틱을 조정하는 동안 가장 근육활동이 활발한 부분을 찾는 과정에서 선정하였다. 삼각근영역에서의 전극의 위치의 최적선정은 매우 까다로운 문제로서 일반적으로 실험에 의해 결정되며^[17-18] 잡음을 최소화하도록 선정되었다. 전극의 부착위치는 그림5에 표시하였다.




그림 5. 전극 부착위치
Fig. 5. Electrode Allocation

모사장애자가 조이스틱을 움직이기 시작하면 그것을 동기신호로 240ms동안 EMG 신호를 획득하였다. 조이스틱의 운동은 2차원 평면을 45°각도로 나누어 그림7과 같이 8가지 운동형태로 정의하며 각각의 운동에 대해 10회 반복실험을 하였고, 매회마다 획득된 데이터를 CRT화면에 표시하여(그림6) 파형을 보고 잡음이나 아티팩트가 심하게 섞여 있는지를 판단하여 그 신호의 저장여부를 결정했다. 저장된 신호의 특징벡터의 형태로 저장되어 필요로 하는 메모리량을 최소화하였다.

매회의 실험에서 각각의 운동마다 3개 플레임의 데이터가 획득되어 10회 전부를 성공적으로 마치면 30셀(sets)씩의 특징벡터군이 획득된다. 그 중 10셀의 특징벡터군을 설계 샘플로 취해 확률모델을 적용한 분류기의 모델파라미터 및 기준 벡터의 산출에




그림 6. 전우향선회시 획득된 삼각근 중심부 및 끝부분의 근전도 신호 파형

Fig. 6. The EMG signal waveforms acquired from the extremity and center of deltoid muscle in the case of forward-right motion.




그림 7. 조이스틱 좌표계의 클래스 설정

Fig. 7. Class definition in the joystick coordinate.

사용하였으며 MLP의 훈련을 위한 입력값으로 사용하였다.

2. 확률모델의 학습

삼각근의 중심부와 끝부분에서 획득되어 추출된 특징벡터 집단의 표준화 (normalization)된 평균절대적분치와 영교차수의 평균을 구한 다음 그 평균치에 근접한 특징벡터들을 설계샘플로 선택하여 다시 그 설계 샘플들만의 통계적 특성을 구하였다. 통계적 특성으로서 절대적분치는 두개의 취득위치별 평균과 분산 (variance), 두 위치간의 공분산 (covariance) 을 구하였고 영교차수는 각 위치상의 평균값만을 구하였다. 이 통계적 특성들을 이용하여 설계 샘플들을 확률모델에 적용하여 분류하고 그 결과를 분석하여 다시 설계샘플을 선정하는 과정을 반복하였다.

3. MLP 모델의 학습

MLP 모델의 구조는 입력층, 은닉층, 출력층의 3개 층을 사용하였다. 입력층은 삼각근의 두 위치에서 취득된 각각의 절대적분치와 영교차수를 입력으로 사용하여 4개로 정의하였고, 출력층은 조이스틱의 이동방향 종류로서 8개로 정의하였다. 은닉층은 12개의 노드 (node)로 정의하였다. 은닉층의 노드수를 10개 미만으로 잡을 경우는 인식율이 현저히 저하되었다. MLP 모델의 학습시 학습문턱치 (learning threshold)는 0.2, 역전달학습율 (back propagation learning rate)는 0.9, 역전달 스무딩 팩터는 0.6으로 선정하였고 모든 클래스에 대해 학습이 완료되었다. 학습 문턱치의 선정은 너무 엄격한 값을 취하면 학습시 정해진 범위내로 수렴이 어렵고 설계샘플과 다른 시험샘플에 대한 견고성 (robustness)이 손상되는 단점을 갖는다. 훈련데이터의 일관성이 결여되는 정도에 따라 훈련량이 증가하고 정해진 훈련범위내로 수렴이 이뤄지지 못하는 경우가 종종 발생한다.

또한 학습알고리즘의 단점으로서 회로망이 조기포화 (premature) 상태에 빠져 훈련량이 증가하는데 이는 훈련상태를 중간에 확인하여 역전달학습율과 역전달 스무딩팩터 (smoothing factor)를 변화시켜 빠져나올 수 있었다.

4. 시뮬레이션 및 평가

학습이 완료된 MLP 모델을 사용하여 설계샘플, 시험샘플 (validation sample), 혼합샘플에 대해 시뮬레이션을 행한 다음 그 출력을 화일로 만들고, 확률모델에 대해서도 같은 데이터 및 순서로 시뮬레이션을 행해 그 출력과 평가 화일을 만든다. 그 후 합성 모델에 대해 MLP 모델의 출력화일을 참조하여 시뮬레이션을 행해 그 출력을 저장하고 평가를 행해 화일을 만든다.

설계된 분류기의 성능을 평가하는데 있어 최소 오분류확률추정 (lower bound error estimate)에는 재치환법 (resubstitution method)을 사용하였으며 최대 오분류확률추정 (upper bound error estimate)에는 LOOM (leaving one out method)을 사용하였다.^[9]

설계 샘플로서 사용한 영교차수 및 평균 절대적분치는 그림8과 그림9에 표시하였는데 몇개의 클래스는 클래스간 분리도가 매우 낮았다. 설계샘플과 시험샘플을 혼합한 혼합샘플에 대해 확률모델만을 이용해 단계별 결정을 한 결과는 그림10에 표시하였으며 MLP 모델만을 이용해 단계별 결정을 한 결과는 그림11에 표시하였다. 그림12는 '확률모델과 MLP 모델을 합성하여 단계별 결정을 한 결과를 표시한




그림 8. 설계샘플의 영교차수 특징분포
Fig. 8. Zero crossing counts feature space of the design sample.




그림 9. 설계샘플의 절대적분치 특징분포
Fig. 9. Absolute integral values feature space of the design sample.




그림10. 혼합샘플을 사용한 확률모델의 단계별 오분류확률추정
Fig. 10. Error probability estimate of probabilistic model using mixed samples for multi-stage decision.




그림11. 혼합샘플을 사용한 MLP 모델의 단계별 오분류확률추정
Fig. 11. Error probability estimate of MLP model using mixed samples for multi-stage decision.






그림12. 혼합샘플을 사용한 합성모델의 단계별 오분류확률추정
Fig. 12. Error probability estimate of combined model using mixed samples for multi-stage decision.

것이다. 그림13은 3단 결정시 최소 및 최대오분류 확률추정결과로서 (a)는 확률모델 (b)는 MLP 모델 (c)는 확률모델과 MLP모델을 합성한 결과를 표시한 것이다.


그림에서 나타난 바와 같이 확률모델과 MLP모델을 합성한 모델이 독립적으로 사용한 모델보다 우수하며 3단 결정법을 사용하여 인식을 행한 결과 약 98%의 인식율을 보였다. 혼합샘플에 대한 오분류확



(a)



(b)



(c)

그림 13. 3단 결정시 최소 및 최대 오분류확률추정
(a) 확률모델 (b) MLP모델 (c) 합성모델

Fig. 13. Lower/upper bound error probability estimate for 3 stage decision.

- (a) probabilistic model,
- (b) MLP model,
- (c) combined model.

를 추정시 확률모델과 MLP모델에 비해 3단 결정시 전체적으로 각각 1.31, 4.55%의 오분류확률이 줄어듬을 보였다. 최소오분류 확률추정, 최대 오분류확률 추정 및 평균적 오분류확률추정을 MLP 모델, 확률 모델, 합성모델에 대해 단계별로 행한 결과는 표 1에 표시하였다.

표 1. 각 모델의 오분류확률추정결과

Table 1. Error probability estimate of each model.

단위 : %

단계	모델 오분류 추정방식	확률모델	합성모델
		MLP모델	
1	최소추정	5.00	1.25
	최대추정	32.04	25.72
	대표추정	18.08	18.06
2	최소추정	3.33	0.0
	최대추정	18.76	14.29
	대표추정	8.88	6.33
3	최소추정	1.25	0.0
	최대추정	15.25	8.57
	대표추정	5.58	2.02

VI. 결 론

MLP모델로서 오분류확률을 최소화시키는 결정을 행한 다음 그 결정의 신뢰도를 판단하여 신뢰성이 있는 경우 클래스간에 비선형적 유사거리를 도입하고, 유사거리에 의한 사전확률분포를 추정하거나 MLP모델 출력의 조인트확률을 변형시켜 사전 확률 분포를 추정하여 확률모델의 사전확률을 규정하는 방식으로 MAP를 구하고 신뢰성이 없는 경우 확률 모델로서 MLR (maximum likelihood ratio)을 구한 결과 두 모델을 독립적으로 사용한 결과에 비해 오분류확률을 줄일 수 있었고 MLP모델의 신뢰도를 이용하여 데이터에 따라 우수한 모델을 선택하는 적응적 분류기 (adaptive classifier)를 구현할 수 있었다.


기준좌표계를 신체외부에 설정하여 신체내부에 기준좌표계를 설정하였을 때 기능을 분리할 수 없는 해상도의 실현을 가능케 하였으며 이러한 방식은 팔의 신체장애자가 특수한 작업을 하는 응용분야에 적합한 것이다. EMG 신호의 기능분리를 좀 더 신뢰성 있게 하기 위해선 전처리 과정에서 신호 대 잡음비를 최대화하는 기법의 구현과 함께 전극의 미세한 위치변경에 영향을 받지 않는 방식에 대한 연구가

좀 더 진전되어야 할 것이다. 또한 근피로도의 영향에 둔감한 방법에 대한 연구도 실용화를 위해선 필수적이다.

參 考 文 獻

- [1] F. Rosenblatt, "The perceptron: a probabilistic model for information storage and organization in the brain," *Psychological Review* vol 65, pp 386-408, 1958.
- [2] Harry, G. Kwantny et al "An application of signal processing techniques to the study of myoelectric signals," *IEEE Trans on BME* vol. 7, no. 4, pp. 303-312, Oct. 1970.
- [3] Daniel Graupe et al "Functional Separation of EMG signals via ARMA identification methods for prosthesis control purposes," *IEEE Trans on SMC* vol. 5, no. 2, pp. 252-259, March, 1975.
- [4] Neville Hogan et al "Myoelectric signal processing: Optimal estimation applied to electromyography-Part I: derivation of the optimal myoprocessor," *IEEE Trans on BME* vol. 27, no. 7, July 1980.
- [5] George N. Saridis et al "EMG pattern analysis and classification for a prosthetic arm," *IEEE Trans on BME* vol. 29, no. 6, pp. 403-412 June 1982.
- [6] Harry B. Evans et al "Signal processing for proportional myoelectric control," *IEEE Trans on BME* vol. 31, no. 2, Feb. 1984.
- [7] Lee. S.H, Saridis G.N. "The control of a prosthetic arm by EMG pattern recognition," *IEEE Trans on Automatic Control*, vol. 29, no. 4, pp. 290-302, Apr. 1984.
- [8] Lennart Philipson "The electromyographic signal as a measure of muscular force: a comparison of detection and quantification technique," *Electromyogr. Clin. Neurophysiol.* vol. 28, no. 2-3 pp. 141-150, March-April, 1988.
- [9] 박상희 등 "LPC 웨스트럼 계수를 이용한 EMG 신호의 기능인식에 관한 연구" 대한전자공학회논문지 제27권 제 2 호 pp. 126 - pp. 133 2. 1990
- [10] Tony Khoshaba, Kambiz Badie et al "EMG pattern classification based on Back propagation neural network for prosthesis control," Annual International Conference of the *IEEE Engineering in MBS*. vol. 12, no. 3, 1990.
- [11] Edward A. Clancy, Neville Hogan "EMG amplitude estimation from temporally whitened, spacially uncorrelated multiple channel EMG," Annual International Conference of the IEEE engineering in MBS, vol. 12, no. 1, 1990.
- [12] D.W. Ruck, S.K. Rogers et al "The Multilayer Perceptron as an Approximation to a Bayes Optimal Discriminant Function," *IEEE Trans on Neural Networks*, vol. 1, no. 4, pp 296-297, Dec. 1990.
- [13] E.A. Wan "Neural Network Classification: A Bayesian Interpretation," *IEEE Trans on Neural Networks*, vol. 1, no. 4, pp. 303-304, Dec. 1990.
- [14] K.P. Valvanis and G.N. Saridis "Probabilistic modelling of intelligent Robotic systems," *IEEE Trans on Robotics and Automation*, vol. 7, no. 1, pp. 164-170, Feb. 1991.
- [15] H. Bourlard, C.J. Wellenkens "Links Between Markov Models and Multilayer Perceptrons," *IEEE Trans on PAMI*, vol. 12, no. 12, pp. 1167-1178 Dec. 1990.
- [16] D.E. Rumelhart, G.E. Hinton, and R.J. Williams, "Learning Integral Representation by Error Propagation," in D.E. Rumelhart & J.L. Mc Clelland(Eds.), *Parallel Distributed Processing: Explorations in the Microstructure of Cognition*, vol. 1: Foundations. MIT Press, 1986.
- [17] Gisela Hefftner, Walter Zucchini, George G. Jaros "The Electromyogram (EMG) as a control signal for Functional Neuromuscular Stimulation-Part I: Autoregressive Modelling as a Means of EMG Signature Discrimination," *IEEE Trans on BME*, vol. 35, no. 4, April, 1988.
- [18] Ronald J. Triolo, Gorden D. Moskowitz "The Experimental Demonstration of a Multichannel Time-series Myoprocessor: System Testing and Evaluation," *IEEE Trans on BME*, vol. 36, no. 10, pp. 1018-1027, Oct. 1989.
- [19] Fukunaga K.S., *Introduction to statistical Pattern Recognition*, Academic Press, New York, 1972.
- [20] Minsky, M. & S.Papert, *Perceptron: An Introduction to Computational Geometry*, MIT Press, Cambridge, MA, 1969.
- [21] Alan S. Willsky et al, "Upper Extremity Limb Function Discrimination Using EMG Signal Analysis," *IEEE Trans on BME*, vol. 30, no. 1, pp. 18-28, Jan. 1983.

著 者 紹 介




張 永 健(正會員)

1957年 4月 28日生. 1980年 인하대학교 전자공학과 졸업 (공학사). 1991年 8月 인하대학교 대학원 전자공학과 졸업(공학석사) 1978年~1983年 국방과학 연구소 연구원. 1983年~1991年 대우중공업 중앙연구소 선임연구원. 1991年 9月~현재 인하대학교 대학원 전자공학과 박사과정 재학중. 주관심분야는 생체신호처리, 로보틱스, 의용영상처리, 인공지능등임.



張 元 碩(正會員)

1952年 3月 25日生. 1978年 2月 인하대학교 전자공학과 졸업 (공학사). 1980年 8月 인하 대학교 대학원 석사과정 졸업(공학석사) 1988年 8月 인하대학교 대학원 박사과정 졸업(공학박사). 1979年 7月~1991年 2月 국방과학연구소 근무. 1991年 3月~현재 건양대학 컴퓨터공학과 부교수. 주관심분야는 원격측정 및 제어, 신호처리, 의용전자 및 생체공학등임.



權 章 禹(正會員)

1968年 4月 15日生. 1990年 2月 인하대 전자공학과 졸업(공학사) 1990年 3月~현재 인하대학교 전자공학과 대학원 석사과정 재학중. 주관심분야는 디지털 신호처리, 패턴인식, 추정론 등임.



洪 勝 弘(正會員)

1941年 10月 2日生. 1963年 12月 인하대학교 전기공학과(약전) 졸업(학사). 1966年 인하공대 대학원(석사). 1975年 일본동경대 대학원(박사). 1969年~1978年 광운대학교 전자공학과 부교수. 1981年~1982年 일본 동경대 교환교수. 1978年~현재 인하대 공대 전자공학과 교수. 주관심분야는 의용영상처리, 생체정보처리분야, 재활공학, 컴퓨터 응용 등임.



韓 永 煥(正會員)

1965年 5月 20日生. 1989年 2月 인하대학교 전자공학과 졸업. 1991年 2月 인하대학교 대학원 전자공학과 졸업. 1991年 3月~현재 인하대학교 대학원 전자공학과 박사과정 재학중. 주관심분야는 의용 영상처리, 패턴인식, 생체 신호처리 등임.