

실시간 근전도 패턴인식을 위한 특징투영 기법에 관한 연구

A Study on Feature Projection Methods for a Real-Time EMG Pattern Recognition

추준욱, 문인혁*, 김신기, 문무성
(Jun-Uk Chu, Inhyuk Moon, Shin-Ki Kim, and Mu-Seong Mun)

Abstract : EMG pattern recognition is essential for the control of a multifunction myoelectric hand. The main goal of this study is to develop an efficient feature projection method for EMG pattern recognition. To this end, we propose a linear supervised feature projection that utilizes linear discriminant analysis (LDA). We first perform wavelet packet transform (WPT) to extract the feature vector from four channel EMG signals. For dimensionality reduction and clustering of the WPT features, the LDA incorporates class information into the learning procedure, and finds a linear matrix to maximize the class separability for the projected features. Finally, the multilayer perceptron classifies the LDA-reduced features into nine hand motions. To evaluate the performance of LDA for the WPT features, we compare LDA with three other feature projection methods. From a visualization and quantitative comparison, we show that LDA has better performance for the class separability, and the LDA-projected features improve the classification accuracy with a short processing time. We implemented a real-time pattern recognition system for a multifunction myoelectric hand. In experiment, we show that the proposed method achieves 97.2% recognition accuracy, and that all processes, including the generation of control commands for myoelectric hand, are completed within 97 msec. These results confirm that our method is applicable to real-time EMG pattern recognition for myoelectric hand control.

Keywords : EMG, pattern recognition, wavelet packet transform, linear discriminant analysis, myoelectric hand control

I. 서론

근전의수(myoelectric hand)는 상지 절단환자가 잔존근육을 수의수축할 때 발생하는 근전도로부터 사용자의 의도를 인식하고 손동작이 제어되는 의지(prosthesis)이다. 현재 상용화된 근전의수는 잔존근육의 수축강도와 근전도 진폭의 선형적 관계를 바탕으로 2개의 표면전극에서 측정된 근전도의 절대 평균값(mean absolute value, MAV)을 비교함으로써 사용자의 의도를 인식한다[1,2]. 그러나 근전도의 MAV와 같은 정보만을 이용하는 인식방법은 손과 손목의 자유도가 증가하여 동작의 수가 늘어날 경우 충분한 제어명령을 생성하지 못 한다. 최근에는 인간의 손과 같이 다양한 동작을 수행할 수 있는 다기능 근전의수(multifunction myoelectric hand)에 대한 연구가 활발히 진행되고 있다[3-5]. 이러한 다기능 근전의수를 제어하기 위해서는 근전도로부터 더욱 많은 제어명령을 생성해야 한다. 그러나 근전도는 기본적으로 1차원 패턴으로 정보량이 많지 않으며 큰 편차와 비정상적 신호(nonstationary signal) 특성을 보인다. 또한 근전의수 사용자가 시간지연을 느끼지 않고 자연스럽게 근전의수를 사용하기 위해서는 빠른 시간 내에 사용자의 의도를 구분하고 근전의수를 동작시켜야 한다. 따라서 패턴인식 과정에서 특징벡터는 제한된 시간구간으로부터 추출되며, 패턴분류기는 근전의수의 오동작을 방지하기 위해 높은 인식률이 요구된다.

이러한 문제를 해결하기 위해 다양한 근전도 패턴인식 방

법들이 연구되고 있다[6-18]. 다기능 근전의수를 위한 근전도 패턴인식 연구들은 새로운 특징추출(feature extraction) 방법으로 특징벡터를 정의하고 다양한 패턴분류(pattern classification) 방법들을 도입함으로써 인식률을 향상시키고자 노력하였다. 시간 영역 특징벡터로서 진폭(amplitude), 영교차율(zero-crossing rate), 히스토그램(histogram), 자기회귀모델 계수(autoregressive coefficient)가 있으며[6-12], 주파수 영역 특징벡터로서 푸리에 변환 계수(Fourier transform coefficient), 켓스트립 계수(cepstrum coefficient)가 있다[13,14]. 연구자들은 구분하고자 하는 클래스의 수가 증가함에 따라 근전도 채널을 증가시키고 여러 가지 특징벡터를 함께 사용하고 있다. 즉, 특징벡터의 차원을 증가시킴으로써 더욱 많은 정보를 얻고자 노력하고 있다. 최근에는 국소푸리에 변환(short-time Fourier transform), 웨이블렛 변환(wavelet transform, WT), 웨이블렛 패킷 변환(Wavelet Packet Transform, WPT)과 같은 비정상적 신호해석을 위한 시간-주파수 해석방법이 이용되고 있다[15-17]. 이러한 시간-주파수 해석방법은 시간영역과 주파수영역에 대한 정보를 동시에 제공하므로 높은 차원의 특징벡터가 표현가능하며 더욱 많은 정보를 얻을 수 있다. 그리고 이와 같이 높은 차원의 특징벡터로부터 사용자의 의도를 보다 정확하게 구분하기 위하여, 베이지안 분류기(Bayesian classifier) [9,15,16], 가우스 혼합모델(Gaussian mixture model)[10,18], 은닉 마코프 모델(hidden Markov model)[11], 다층신경망(MultiLayer Perceptron, MLP)[6,8, 13,17], 퍼지분류기(fuzzy classifier) [7,12] 등과 같은 다양한 패턴분류 방법들도 인식률 향상을 목적으로 연구되었다. 그러나 기존 연구들은 제안된 패턴분류 방법이 인식률을 향상시키는 이유를 정확하게 설명하지 못하고 다른 패턴분류 방법과의 인식률 비교만을 제시하고 있다. 그 이유는 근전도로부터 정의된 특징벡터의 차원과 분포에 대한 고찰이 부족하였기 때문이다. 일반적으로 높은 차원의 특징벡터

* 책임저자(Corresponding Author)

논문접수 : 2006. 3. 17., 채택확정 : 2006. 7. 1.

추준욱, 김신기, 문무성 : 재활공학연구소

(juchu@iris.korec.re.kr/skkim@iris.korec.re.kr/msmun@iris.korec.re.kr)

문인혁 : 동의대학교 메카트로닉스공학과(ihmoon@deu.ac.kr)

※ 본 연구는 보건복지부 보건의료기술진흥사업의 지원에 의하여 연

구되었음(과제번호: 02-PI3-PG6-EV03-0004).

는 특징투영(feature projection)을 통해 축소된 차원의 특징공간에서 시각화(visualization)할 수 있기 때문에 차원이 축소된 특징벡터의 분포를 관찰함으로써 입력된 원신호에 가장 적절한 패턴분류기를 선택할 수 있다. 이러한 차원 축소(dimensionality reduction)는 패턴인식을 위한 계산시간을 단축함으로써 실시간 구현을 가능케 한다. 또한 학습 목적(learning criterion)에 따라 패턴을 군집화(clustering)함으로써 패턴분류기의 일반화(generalization) 능력을 향상시킬 수 있다.

Huang[8]은 3개 채널의 근전도로부터 시간영역 정보인 자기회귀모델 계수와 히스토그램을 이용하여 특징벡터를 정의하고 특징투영을 위해 SOFM(Self-Organizing Feature Map)을 도입하였다. 그리고 MLP를 이용함으로써 8가지 손동작을 구분하였다. 그러나 SOFM은 특징벡터들의 유사도(similarity)만을 고려하여 연결강도를 조정하는 비교사학습(unsupervised learning) 방법으로 학습과정에서 특징벡터의 클래스 정보를 사용하지 못한다. 따라서 서로 다른 클래스에 속한 특징벡터라 하더라도 유사도가 높을 경우 같은 클래스로 군집화되는 경우가 많다. Engelehart[16]는 4개 채널로부터 얻어진 근전도로부터 WPT계수를 추출하고 PCA(Principal Component Analysis)를 적용하여 특징벡터의 차원을 축소하였다. 그리고 베이지안 분류기를 사용하여 6개의 손동작을 구분하였다. 실험결과에서 PCA에 의해 20 차원내외로 축소된 시간-주파수 특징벡터는 원 근전도 패턴들의 클래스 분포를 잘 표현하였지만 인식률에서 만족할 만한 결과를 보이지 못했다. PCA는 클래스 분리도(class separability)를 고려하지 않고 전체 패턴의 분산이 최대가 되는 직교 좌표계를 구하는 선형변환 방법이기 때문에 클래스간 밀도함수가 정확하게 분리되지 못하는 단점이 있다.

본 연구에서는 LDA를 특징투영으로 이용하는 WPT-LDA-MLP 구조의 근전도 패턴인식 방법을 제안한다. 선형변환-교사학습의 특징투영 방법인 LDA(Linear Discriminant Analysis)는 학습과정에서 클래스 정보를 이용하여 투영된 특징벡터들의 클래스 분리도가 최대가 되는 선형변환 행렬을 찾는다. 그 결과, 패턴분류기는 투영된 특징벡터에 대하여 높은 분할여유(separation margin)를 가진 결정평면(decision surface)을 형성할 수 있으며 인식률을 향상시킬 수 있다. 또한 LDA는 선형변환에 의해 특징벡터의 차원을 축소함으로 처리시간이 빠르며 패턴분류기의 구조와 학습을 간단히 함으로써 실시간 구현을 가능케 한다. 비교실험에서는 WPT 특징벡터에 대한 LDA의 성능을 평가하기 위해 LDA, PCA, NLDA(Nonlinear Discriminant Analysis), 그리고 SOFM을 비교한다. 먼저 4가지 특징투영 방법에 대하여 차원이 축소된 특징벡터를 시각화함으로써 군집화 성향을 조사한다. 정량적 분석을 위해 클래스 분리도, 군집화 능력, MLP의 분류 오차율, 그리고 계산시간을 비교함으로써 LDA특징투영 방법이 가장 우수함을 보인다. 검증실험에서는 다수의 피실험자에 대하여 WPT-LDA-MLP로 구성된 근전도 패턴인식 방법의 성능을 평가한다. 마지막으로 4 자유도를 가진 다기능 근전의수에 대하여 제안한 방법을 이용한 실시간 패턴인식 시스템을 구현한다. 실험결과에서 제안한 방법이 다기능 근전의수를 위한 근전도 패턴인식의 실시간 구현에 적합함을 보인다.

II. 근전도 측정

전완(forearm)에서 가장 자주 사용되는 손목의 굴곡(flexion), 신전(extension), 내전(radial flexion), 외전(ulnar flexion), 내회전(pronation), 외회전(supination), 그리고 손의 움켜쥔(grasp), 펼(open)의 8가지 동작과 휴지(relaxation) 동작을 포함하는 9가지 동작을 인식한다. 8가지 동작은 전완 근육들의 수축으로 이루어진다. 특히 긴 손바닥근(palmaris longus), 손가락 펌근(extensor digitorum), 노쪽 손목 굽힘근(extensor carpi radialis), 그리고 자쪽 손목 굽힘근(flexor carpi ulnaris)은 손과 손목 동작에 관여하는 중요근육으로서 4개의 표면전극(surface electrode)을 부착하여 근전도를 측정한다. 근전도는 근육의 수축에 따라 0~10 mV의 진폭을 가지며 20~500 Hz에 에너지가 집중되어 있다[19]. 따라서 능동형 표면전극(DE-2.1, Delsys[20]), 증폭기 및 필터를 이용하여 80 dB로 증폭되고 20~450 Hz로 대역 제한된 근전도를 획득한다. 다음으로 획득된 근전도는 ADC 보드(6052E, NI[21])를 이용하여 1024 Hz로 샘플링된다.

상지 절단환자가 근전의수를 자연스럽게 사용하기 위해서는 동작의도를 포함한 근전도의 발생으로부터 근전의수의 동작까지 소요되는 시간지연이 300 msec 보다 짧아야 한다[9] 따라서 샘플링된 이산 근전도는 이동 윈도우(moving window)에 의해 분할되며 윈도우의 길이(window length)와 윈도우의 이동증가분(window increment)을 각각 250msec(256 points)와 125 msec(128 points)로 설정한다. 즉, 어떤 시점에서 주어진 사용자 의도는 반드시 250 msec 윈도우에 두 번씩 포함된다. 따라서 근전의수의 제어명령 발생을 포함한 패턴인식이 125 msec 이내에 완료된다면 사용자는 300 msec 이내에 근전의수를 동작시킬 수 있다.

근전도는 피실험자의 성별, 나이, 근육의 상태에 따라 큰 차이를 보인다. 따라서 한명의 대표 피실험자로부터 측정된 근전도를 이용하여 근전도 패턴인식 방법을 제안, 설명하고 검증과정에서 다수의 피실험자를 대상으로 제안한 패턴인식 방법의 성능을 평가한다. 먼저 한명의 정상인 피실험자로부터 근전도를 측정하였다. 피실험자는 휴지동작을 포함하여 8 가지 동작을 순차적으로 10회 반복 수행하였으며 동시에 근전도가 측정되었다. 피실험자의 근 피로도(muscle fatigue)를 고려하여 충분한 휴식을 취한 뒤 같은 방법으로 다시 근전도를 측정하였다. 처음 약 8분 동안 측정된 근전도는 학습패턴으로 사용하였으며, 휴식을 취한 뒤 약 8 분 동안 측정된 근전도는 검증패턴으로 사용하였다. 측정된 근전도는 125 msec 이동증가분을 가진 250 msec의 이동 윈도우로 분할되었고 각각 분류하고자 하는 동작 클래스가 할당되었다.

III. 특징 추출

이동 윈도우에 의해 분할된 근전도로부터 특징벡터를 추출하기 위해 WPT을 수행한다. WPT는 WT의 일반화된 표현법으로 이진트리 구조(binary tree structure)를 가진다. N개의 샘플로 구성된 원신호(original signal)는 서로 다른 시간-주파수 영역을 나타내는 부공간 집합들(subspace sets)이 중복된 형태(overcomplete structure)로 분해된다. $\Omega_{0,0}$ 는 원신호를 나타내는 공간을 의미하며 각 노드의 부공간 $\Omega_{j,k}$ 는 직교 부공간 $\Omega_{j+1,2k}$ 와 $\Omega_{j+1,2k+1}$ 로 분해된다. 여기서 j 는 스케일을, k

는 스케일 내의 부공간을 나타낸다. 각 부공간 $\Omega_{j,k}$ 는 기저 벡터(basis vector) $\mathbf{w}_{j,k,n} = \{w_{j,k,n}\}, n = 0, \dots, 2^{n_0-j}-1, n_0 = \log_2^N$ 로 표현된다. 이와 같은 성질은 각 주파수 대역별 부공간의 선택에 따라 다양한 형태의 완전한(complete) 시간-주파수 공간 표현이 가능하다. 따라서 적절한 분리척도(discriminant measure)를 설정한다면 특징벡터의 클래스 분리도가 최대가 되는 최적기저(beat basis)를 찾을 수 있다. 본 연구에서는 최적기저 탐색방법으로 Saito[22]의 지역 분리 기저(Local Discriminant Basis, LDB) 알고리즘을 이용한다. 클래스 간 분리척도로서 대칭 상대 엔트로피(symmetric relative entropy)

$$D(\mathbf{p}, \mathbf{q}) = \sum_{i=1}^n p_i \log \frac{p_i}{q_i} + \sum_{i=1}^n q_i \log \frac{q_i}{p_i} \quad (1)$$

를 사용한다. 여기서 입력 $\mathbf{p} = \{p_i\}, \mathbf{q} = \{q_i\}, i = 1, \dots, n$ 는 서로 다른 클래스에 포함된 특징벡터들을 나타내는 척도이다. 다음으로 대칭 상대 엔트로피의 입력으로서 각 클래스에 대한 시간-주파수 에너지 맵(time-frequency energy map)으로

$$\Gamma_c(j, k, n) = \sum_{i=1}^{N_c} \left(\mathbf{w}_{j,k,n}^T \mathbf{x}_i^{(c)} \right)^2 / \sum_{i=1}^{N_c} |\mathbf{x}_i^{(c)}|^2 \quad (2)$$

을 정의한다. 여기서 $j = 0, \dots, J, k = 0, \dots, 2^j - 1, n = 0, \dots, 2^{n_0-j}-1$ 이다. 그리고 $\{\mathbf{x}_i^{(c)}\}, i = 1, \dots, N_c$ 는 클래스 c 에 속한 원신호의 집합이며 N_c 는 클래스 c 에 포함된 패턴의 개수이다. 따라서 (1)과 (2)로부터 K 개의 클래스에 대한 부공간 $\Omega_{j,k}$ 의 대칭 상대 엔트로피는 다음과 같이 적을 수 있다.

$$D\left(\{\Gamma_c(j, k, \bullet)\}_{c=1}^K\right) = \sum_{n=0}^{2^{n_0-j}-1} D\left(\Gamma_1(j, k, n), \dots, \Gamma_K(j, k, n)\right). \quad (3)$$

$B_{j,k}$ 를 부공간 $\Omega_{j,k}$ 에 속한 후보 기저벡터 집합이라 하면 $A_{j,k}$ 는 $B_{j,k}$ 에서 선택된 최적기저로서 LDB가 된다. 또한 각 노드(j, k)에서의 분리척도를 $\Delta_{j,k}$ 로 정의한다. LDB 알고리즘은 가지치기 방법(pruning method)을 이용하여 부모노드와 자식노드들의 분리척도를 비교하고 자식노드들을 유지할 것인지 혹은 부모노드 쪽으로 이동할 것인지를 결정한다. 다음에서 LDB 알고리즘을 요약한다.

1. WPT을 위한 웨이블렛 및 스케일 함수를 결정하고 분해 레벨(decomposition level) J 를 설정한다.
2. 각 클래스 $c = 1, \dots, K$ 에 대한 에너지 맵 Γ_c 를 계산한다.
3. 초기화를 위하여 레벨 J 에 대하여 $A_{j,k} = B_{j,k}$, 그리고 $\Delta_{j,k} = D\left(\{\Gamma_c(j, k, \bullet)\}_{c=1}^K\right), k = 0, \dots, 2^J - 1$ 로 설정한다.
4. 다음 과정을 반복하여 LDB $A_{j,k}, j = J-1, \dots, 0, k = 0, \dots, 2^j - 1$ 를 결정한다. $\Delta_{j,k} = D\left(\{\Gamma_c(j, k, \bullet)\}_{c=1}^K\right)$ 로 설정했을 때, $\Delta_{j,k} \geq \Delta_{j+1,2k} + \Delta_{j+1,2k+1}$ 이면 $A_{j,k} = B_{j,k}$ 로 결정하고 그렇지 않으면 $A_{j,k} = A_{j+1,2k} + A_{j+1,2k+1}$ 그리고 $\Delta_{j,k} = \Delta_{j+1,2k} + \Delta_{j+1,2k+1}$ 로 설정한다.

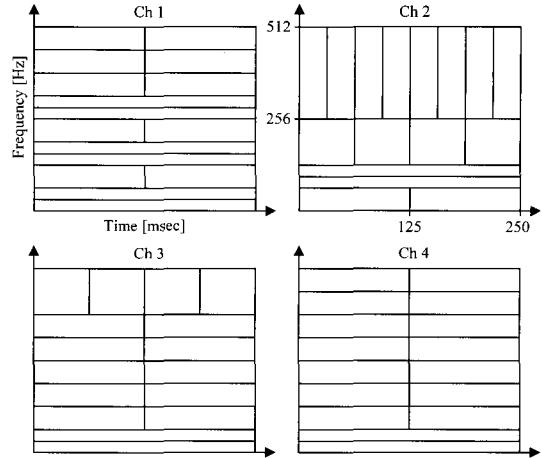


그림 1. 각 채널의 시간-주파수 타일링.

Fig. 1. The tiling of time-frequency plane for each channel.

본 연구에서는 Mallat[23] 알고리즘을 이용하여 이산 웨이블렛 분해를 구현하였다. 웨이블렛 및 스케일링 함수는 Haar 함수가 사용되었으며 4차 스케일 레벨까지 변환이 수행되었다. 특징벡터를 추출하기 위해 피실험자의 학습 패턴에 대하여 LDB 알고리즘을 적용하였다. 클래스 분리도를 증가시키기 위해 4개의 근전도 채널에 대하여 독립적인 LDB를 구성하였다. LDB 알고리즘에 따라 각 노드의 부공간 $\Omega_{j,k}$ 에서는 9개의 클래스에 대한 에너지 맵을 계산하고 다른 노드와 대칭 상대 엔트로피를 비교함으로써 LDB를 선택하였다. 그림 1은 선택된 LDB에 따라 시간-주파수 영역 부공간의 조합을 채널 별로 도시한 결과이다. WT과 달리 채널 별로 서로 다른 형태의 타일링을 가짐을 알 수 있다. 이상의 결과로부터 256 points 이동 윈도우에 의해 분할된 근전도와 LDB를 이용하여 이산 웨이블렛 변환을 수행하고 그 계수의 절대값을 각 채널의 특징벡터로 추출하였다. 따라서 4 채널의 근전도에 대한 특징벡터는 1024차원으로 표현된다.

IV. 특징 투영

특징투영 방법은 변환함수와 학습방법에 따라 선형/비선형 변환 그리고 교사/비교사학습으로 구분할 수 있다. 이 장에서는 WPT 특징벡터에 적절한 특징투영 방법을 찾기 위해 선형변환-교사학습인 LDA, 선형변환-비교사학습인 PCA, 비선형변환-교사학습인 NLDA, 그리고 비선형변환-비교사학습인 SOFM를 비교한다. 먼저 WPT 특징벡터에 대하여 4가지 특징투영 방법을 적용하여 축소된 특징공간에서 패턴분포를 시각화하고 특징투영에 따른 분포의 변화 그리고 클래스 분리도 및 군집화 능력을 조사한다. 다음으로 투영된 특징벡터 분포에 적합한 패턴분류기를 선택하고 각 특징투영에 대하여 패턴분류 오차율과 계산시간을 비교한다.

LDA[24]의 학습과정은 클래스 정보를 이용하여 투영된 특징벡터들의 클래스간 산포도(between-class scatter)가 최대가 되고 클래스내 산포도(within-class scatter)가 최소가 되는 선형 변환 행렬 W 을 찾는다. 즉, 입력 특징벡터의 클래스간 분리도가 최대가 되는 좌표계를 찾는 과정이다. 다음에서 LDA의 학습과정을 요약한다.

1. 전체 n 차원 입력 특징벡터 $\{z_i\}$, $i=1,\dots,m$ 에 대하여 클래스 c 에 대한 클래스내 산포행렬을

$$S_W^{(c)} = \sum_{i=1}^m r_i^{(c)} (z_i - m^{(c)}) (z_i - m^{(c)})^T \quad (4)$$

로 정의한다. 여기서 $z_i \in c$ 이면 $r_i^{(c)} = 1$, 그렇지 않으면 0이다. 또한 $m^{(c)} = \sum_{i=1}^m r_i^{(c)} z_i / \sum_{i=1}^m r_i^{(c)}$ 이다. 따라서 전체 클래스내 산포행렬을 다음과 같이 구성한다.

$$S_W = \sum_{c=1}^K S_W^{(c)} \quad (5)$$

또한 클래스간 산포행렬은 다음과으로 계산된다.

$$S_B = \sum_{c=1}^K N_c (m^{(c)} - m) (m^{(c)} - m)^T \quad (6)$$

여기서 $m = \sum_{c=1}^K m^{(c)} / K$ 이고 $N_c = \sum_{i=1}^m r_i^{(c)}$ 이다. 따라서 전체 산포행렬은 다음과 같다.

$$S_T = S_W + S_B \quad (7)$$

2. $\det(W^T S_T W) / \det(W^T S_W W)$ 이 최대가 되는 $n \times k$ 차

원의 행렬 W 를 구한다. $S_W^{-1} S_T$ 의 가장 큰 고유치를 가지는 k 개의 고유벡터로부터 $n \times k$ 차원의 변환행렬 W 를 계산한다. 여기서 각 행은 k 개의 고유벡터로 구성된다.

3. 입력 특징벡터에 대하여 $y = W^T z$ 를 계산함으로써 k 차원으로 축소된 특징벡터를 얻는다.

PCA[25]의 학습과정은 입력 특징벡터들의 분포를 가장 잘 묘사할 수 있는 직교 좌표계를 찾는 과정으로 볼 수 있으며 선형변환을 이용하여 무의미한 요소의 크기를 줄임으로써 특징벡터의 차원을 축소한다. 추출된 특징벡터를 z 그리고 투영된 특징벡터를 y 라 하면 PCA 학습과정은 다음과 같다.

1. 전체 n 차원 입력 특징벡터 $\{z_i\}$, $i=1,\dots,m$ 에 대하여 공분산 행렬 Σ 를 구성한다.

2. 공분산 행렬 Σ 에 대한 고유치 $\lambda_1 \geq \dots \geq \lambda_n$ 과 고유벡터 u_1, \dots, u_n 을 계산한다.

3. 가장 큰 고유치를 가지는 k 개의 고유벡터로부터 $n \times k$ 차원의 변환행렬 A 를 구한다. 여기서 각 행은 k 개의 고유벡터로 구성된다.

4. 입력 특징벡터에 대하여 $y = A^T z$ 를 계산함으로써 k 차원으로 축소된 특징벡터를 얻는다.

NLDA[26]는 MLP의 비선형변환과 교사학습을 이용하는 특징투영 방법이다. MLP 구조에서 입력층부터 마지막 은닉 층까지의 부신경망(subnetwork)은 오차 역전파 학습을 통해 $\text{Tr}(S_B S_T^+)$ 을 최대화함으로써 출력층에서의 패턴 분류를 용이하게 한다. 따라서 다음과 같은 NLDA 신경망의 구조와 학

습방법으로 특징투영을 수행할 수 있다.

- 특징벡터와 같은 n 차원의 입력층, 충분히 큰 차원의 첫 번째 은닉층, 특징투영을 위한 k 차원의 두 번째 은닉층, 그리고 클래스 K 차원의 출력층으로 MLP를 구성한다. 여기서 은닉층과 출력층은 비선형 활성함수인 양극성 시그모이드 함수를 사용한다.
- 특징벡터와 분류하고자 하는 클래스 정보를 이용하여 MLP에 대한 오차 역전파 학습을 수행한다.
- 학습이 완료된 후, 출력층을 제거하고 마지막 은닉층의 비선형 활성함수를 선형 함수로 대체함으로써 NLDA 신경망을 구성한다.
- NLDA 신경망을 통해 입력 특징벡터를 투영시킴으로써 k 차원으로 축소된 특징벡터를 얻는다.

SOFM[27]은 학습과정에서 입력 특징벡터의 유사도(similarity) 그리고 승리뉴런(winning neuron)과의 기하학적 근접도(topological neighborhood)에 따라 연결강도를 조절한다. 따라서 학습이 완료된 SOFM은 입력 특징벡터와 학습된 연결강도를 비교하여 승리뉴런을 찾고 2차원 격자구조의 출력공간에서 승리뉴런의 좌표값을 출력함으로써 비선형 변환을 수행한다. 본 연구에서 적용된 SOFM의 학습과정은 다음과 같다.

- 연결강도를 위한 초기값을 설정한다. 2차원 출력공간의 격자개수 l 에 대하여 초기 연결강도 벡터 $w_j(0)$, $j = 1, \dots, l$ 는 특징벡터 집합으로부터 무작위로 선택한다.
- 학습을 위한 특징벡터 z 를 샘플링한다. 각 클래스에 속한 특징벡터가 동일한 확률로 선택되도록 한다.
- 반복횟수 n 에 대하여 입력 특징벡터에 대하여 다음의 최소거리 유clidean-노름 조건을 만족하는 승리뉴런 $y(z)$ 를 결정한다.

$$y(z) = \arg \min_j |z(n) - w_j(n)|, \quad j = 1, \dots, l. \quad (8)$$

4. 다음의 학습규칙을 이용하여 모든 뉴런의 연결강도를 조정한다.

$$w_j(n+1) = w_j(n) + \eta(n) h_{j,y(z)}(n) (z(n) - w_j(n)). \quad (9)$$

$$\begin{aligned} \text{여기서 } h_{j,y(z)} &= \exp(-d_{j,y(z)}^2 / 2\sigma^2(n)), \\ \sigma(n) &= \sigma_0 \exp(-n/\tau_1), \\ \eta(n) &= \eta_0 \exp(-n/\tau_2). \end{aligned}$$

$h_{j,y(z)}(n)$ 은 승리뉴런 $y(z)$ 를 중심으로 이웃뉴런과의 거리 $d_{j,y(z)}$ 에 따른 기하학적 근접도를 나타낸다. 반복횟수에 대하여 근접도의 분산 $\sigma(n)$ 과 학습률 $\eta(n)$ 은 지수함수적으로 감소한다.

- 출력공간의 변화가 없을 때까지 단계 2, 3, 4를 반복한다. 괴실험자의 근전도로부터 추출된 WPT 특징벡터에 대하여 선형차원(linear dimensionality)을 조사한 결과 8차원으로 나타났다. 이는 공분산 행렬 Σ 의 가장 큰 8개의 고유치 합이 전체 고유치 합의 97% 이상임을 의미한다. 따라서 WPT 특징벡터는 특징투영 방법들에 대하여 동일하게 8차원으로 축소된다. 하지만 SOFM의 경우 100×100 의 2차원 격자구조로

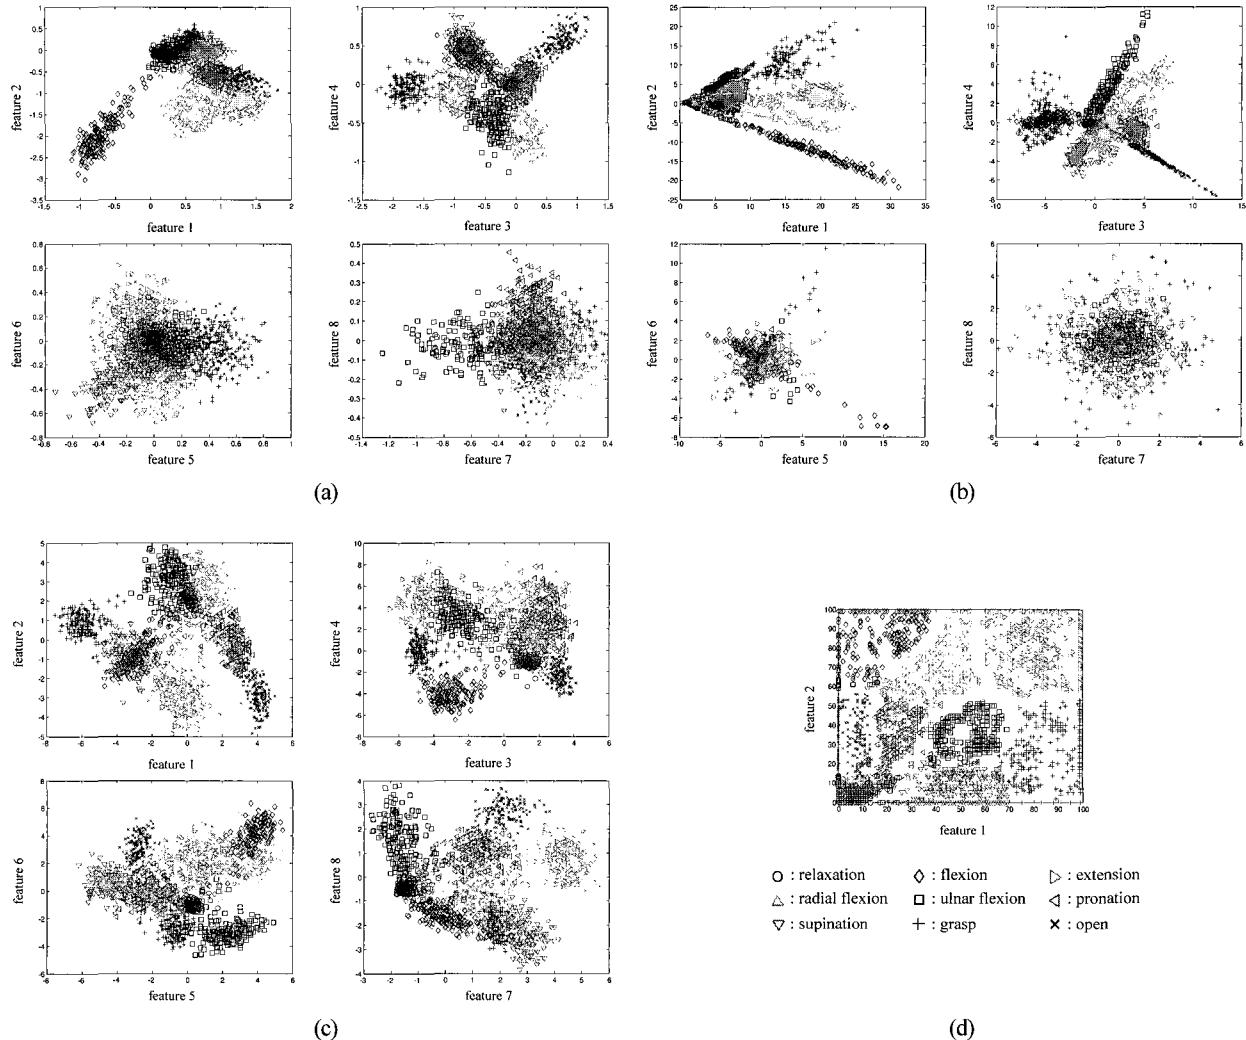


그림 2. (a) LDA, (b) PCA, (c) NLDA, 그리고 (d) SOFM에 의해 차원-축소된 특징공간.

Fig. 2. Dimensionally-reduced feature spaces using (a) LDA, (b) PCA, (c) NLDA, and (d) SOFM.

표 1. LDA, PCA, NLDA, 그리고 SOFM에 대한 Sammon's stress와 Fisher's index의 평균값.

Table 1. The average values of Sammon's stress and Fisher's index for LDA, PCA, NLDA, and SOFM.

	LDA	PCA	NLDA	SOFM
Sammon's stress, E	0.8402	0.2503	0.8475	0.8875
Fisher's index, J	17928.4	0.0032	2997.6	28.0875

표 2. LDA, PCA, NLDA, 그리고 SOFM에 대한 MLP 분류 오차율과 계산시간의 평균값.

Table 2. The average values of the MLP classification error rate and processing time for LDA, PCA, NLDA, and SOFM.

	LDA	PCA	NLDA	SOFM
classification error rate [%]	2.8488	5.1384	2.7458	6.5229
processing time [msec]	2	2	150	300

출력공간을 정의한다. 검증패턴을 학습이 완료된 각 특징투영 방법에 적용하였으며 그림 2에 차원이 축소된 특징벡터를 보인다. 표 1에서는 각 특징투영 방법에 대해 Sammon's stress와 Fisher's index를 비교한다. Sammon's stress[28]는 특징공간의 차원이 축소될 때 특징벡터간 거리변화의 척도로서 군집화 능력을 평가할 수 있으며 다음과 같이 정의된다.

$$E = \sum_{\mu=1}^{m-1} \sum_{\nu=\mu+1}^m \frac{[d^*(\mu, \nu) - d(\mu, \nu)]^2}{d^*(\mu, \nu)} \Bigg/ \sum_{\mu=1}^{m-1} \sum_{\nu=\mu+1}^m d^*(\mu, \nu) \quad (10)$$

여기서 $d^*(\mu, \nu)$ 와 $d(\mu, \nu)$ 는 원 특징공간과 축소된 특징공간에서 μ 와 ν 번째 특징벡터 사이의 거리이다. 차원이 축소된 특징벡터에 대하여 $J = \det(W^T S_T W) / \det(W^T S_W W)$

로 정의되는 Fisher's index를 조사함으로써 클래스 분리도를 평가할 수 있다. Sammon's stress와 Fisher's index는 10회 반복 수행으로 측정된 검증패턴에 대한 평균값이며 정량적 비교를 위하여 각 특징투영의 정규화된 출력공간에서 계산되었다.

LDA는 클래스 분리도를 최대로 하는 학습과정으로 인해

당연히 가장 높은 Fisher's index를 가진다. 또한 선형변환인 LDA가 비선형 변환인 NLDA 그리고 SOFM과 비슷한 Sammon's stress를 가진 것은 클래스 분리도를 향상시키기 위해 특정벡터들 사이의 거리를 크게 변화시켰음을 의미한다. 따라서 그림 2(a)에서와 같이 클래스 밀도함수간 분할여유가 크게 나타났다. PCA는 원 특징공간에서 최대 분산을 가지는 8차원의 직교 좌표계로 특정벡터를 투영하므로 원 특정벡터들의 분포형태가 가장 잘 유지된다. 따라서 가장 낮은 Sammon's stress를 보였다. 그러나 가장 낮은 Fisher's index를 가짐으로써 그림 2(b)에서와 같이 클래스 밀도함수가 중복됨을 확인할 수 있었다. NLDA는 비선형변환-교사학습의 특징 투영 방법이므로 Fisher's index와 Sammon's stress에서 모두 높은 값을 나타냈다. 그림 2(c)와 같이 모든 8차원 특징공간에서 높은 클래스 분리도를 보였다. SOFM은 그림 2(d)와 같이 클래스 별 클러스터를 가장 잘 시각화할 수 있었다. 하지만 SOFM은 클래스 정보를 이용하지 않는 비교교사학습 방법이므로 서로 다른 클래스의 특정 벡터들이 하나의 클러스터에 포함되는 경우가 많았다. 또한 잘못된 클러스터에 속한 특정벡터와 그 특정벡터가 속해야 하는 클러스터 사이의 큰 거리차이를 보였다. 4가지 특정투영에 대한 시각화, 클래스 분리도 및 군집화 능력을 조사한 결과로부터 클래스 정보를 이용하는 LDA와 NLDA 특징투영 방법이 패턴분류를 목적으로 하는 근전도 패턴인식에 적합함을 알 수 있었다.

다음으로 MLP를 패턴분류기로 선택하여 각 특징투영의 분류 오차율을 비교한다. MLP는 정규분포를 포함하여 임의의 패턴 분포를 묘사할 수 있다. 두 개의 은닉층에 각 9개의 뉴런을 가진 MLP를 구성하였으며 활성함수로서 양극성 시그모이드 함수를 사용하였다. 각 특징투영의 출력을 정규화하여 MLP의 입력으로 사용하였으며 자승오차합의 변화가 거의 없을 때까지 오차 역전파 학습을 수행하였다. 표 2에서는 각 특징투영에 대하여 MLP의 분류 오차율과 계산시간을 비교한다. 분류 오차율은 10회 반복수행으로 구성된 검증패턴에 대한 평균값이다. 각 특징투영 방법의 계산시간은 1.8 GHz Pentium IV processor PC에서 수행된 결과이다.

교사학습 방법을 이용하는 LDA와 NLDA는 비교교사학습을 이용하는 PCA와 SOFM에 비해 낮은 오차율을 보였다. 이러한 결과는 앞서 Sammon's stress와 Fisher's index를 통한 비교 결과와 일치함을 알 수 있다. 계산시간에서는 비선형 변환인 NLDA와 SOFM이 많은 시간을 필요로 하였다. NLDA 신경망은 높은 차원의 입력에 대해 비선형 변환을 수행하기 위해 첫 번째 은닉층에 충분히 많은 뉴런을 필요로 한다. 본 연구에서는 256개의 은닉 뉴런을 사용하였으며 이는 실험을 통해 찾은 최소의 뉴런 개수이다. SOFM은 승리뉴런을 찾기 위해 입력과 모든 연결강도와의 유사도를 비교해야 한다. 실시간 근전도 패턴인식을 위해서는 균전의수를 위한 제어명령 발생을 포함하는 모든 과정이 125 msec 내에 이루어져야 한다. 그러므로 NLDA와 SOFM은 실시간 구현이 불가능하다.

지금까지의 비교실험 결과로부터 LDA 특징투영이 군집화 능력과 클래스 분리도를 나타내는 Sammon's stress와 Fisher's index에서 높은 값을 가짐으로써 MLP를 이용한 분류 오차율에서도 우수한 성능을 가짐을 확인할 수 있었다. 또한 LDA

표 3. 검증패턴에 대한 인식결과.

Table 3. Recognition results for test patterns.

motions	subjects					average [%]
	A	B	C	D	E	
relaxation	99.4	99.5	99.6	98.8	97.3	98.2
extension	99.1	100.0	100.0	98.0	98.3	99.0
flexion	97.3	99.4	100.0	99.6	98.6	98.9
radial flexion	98.5	100.0	98.4	97.8	96.2	98.1
ulnar flexion	97.6	100.0	99.7	100.0	97.5	98.9
pronation	96.7	99.5	97.6	97.7	96.4	97.5
supination	97.5	98.6	98.7	99.7	96.1	98.1
grasp	92.3	94.8	95.2	92.7	89.2	92.8
open	93.4	91.2	94.8	93.1	90.4	92.5
average [%]	96.8	98.1	98.2	97.4	95.5	

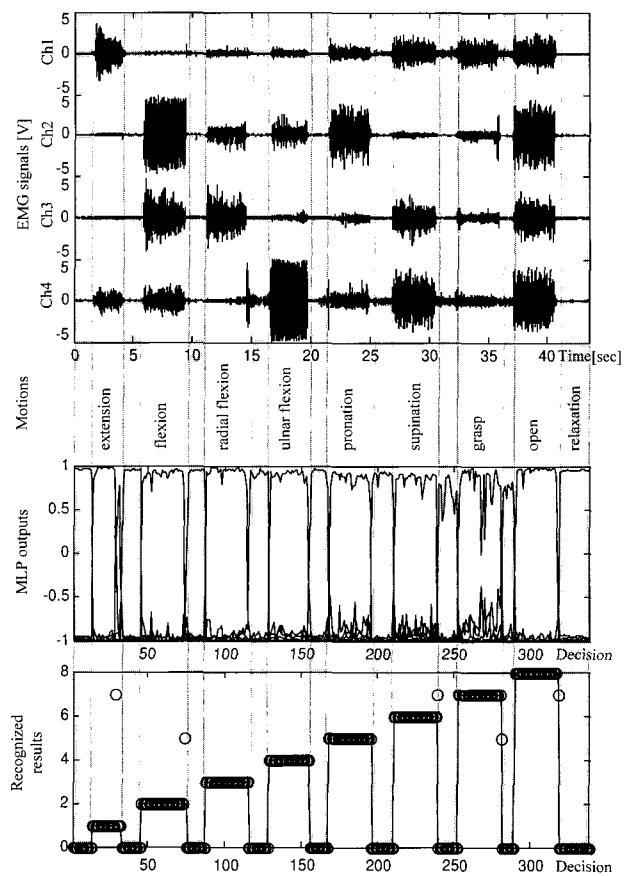


그림 3. 검증패턴과 인식결과의 예.

Fig. 3. Example of test patterns and recognition results.

특징투영의 짧은 계산시간은 근전도 패턴인식의 실시간 구현에 적합함을 알 수 있었다.

V. 제안된 패턴인식 방법의 검증

검증실험에 앞서 WPT-LDA-MLP로 구성된 근전도 패턴인식 과정을 요약한다.

1. 피실험자로부터 측정된 근전도는 선택된 LDB에 따라 이산 웨이블렛 변환을 수행하고 그 절대값으로 WPT 특징 벡터를 추출한다.
2. 다음으로 높은 차원의 WPT 특징벡터는 LDA의 선형변환

행렬에 의해 차원축소와 군집화 과정을 거친다.

3. 마지막으로 투영된 특징벡터는 MLP의 최대 출력값을 가지는 뉴런에 따라 9가지 동작으로 구분된다.

제안된 패턴인식 방법을 검증하기 위하여 5명의 정상인 피실험자를 대상으로 실험을 수행하였다. 2장에서 설명한 방법과 동일하게 근전도를 측정하고 피실험자 별로 WPT-LDA-MLP를 학습시켰다. 표 3은 검증패턴에 대한 인식결과이다. 본 연구에서 근전도가 측정되는 근육들은 주로 손목 동작에 관계되며 피부표면에 가깝게 위치한다. 반면 손가락의 움직임에 관계된 근육들은 전완의 가장 내부에 존재하므로 표면 전극을 통한 근전도 측정이 어렵다. 따라서 동작 별 인식결과에서 보듯이 손의 움켜쥔과 펌 동작에 비해 손목 동작들이 높은 인식률을 보였다. 피실험자에 대한 인식률은 평균 97.2%이며 표준편차 $\pm 1\%$ 로 나타났다. 따라서 제안된 근전도 패턴인식 방법이 모든 피실험자에 적용될 수 있음을 확인하였다. 시간에 따른 패턴인식 결과를 보이기 위해 그림 3에서 검증패턴과 인식결과의 예를 보인다. 검증패턴은 피실험자 C가 8가지 동작을 순차적으로 1회 수행할 때 측정한 4채널 근전도이다. 수행시간 42.5 sec 동안 339 번의 패턴인식이 수행되었다. 그림의 중간 부분에서 -1.0과 1.0 사이의 MLP 출력을 보이며 그림의 아래 부분에서 인식결과를 보인다. 동작 클래스는 '0'에서 '8'의 값으로 표현된다. 실선은 분류하고자 하는 동작 클래스를 의미하며 원 기호는 MLP의 최대 출력값을 가지는 뉴런으로부터 얻은 인식결과이다. 이동 윈도우로 분할된 학습패턴의 대부분은 동작의 정상상태에서의 근전도이다. 따라서 학습된 패턴인식 시스템은 동작의 정상상태에서 안정된 MLP 출력을 가지는 반면 동작의 천이상태

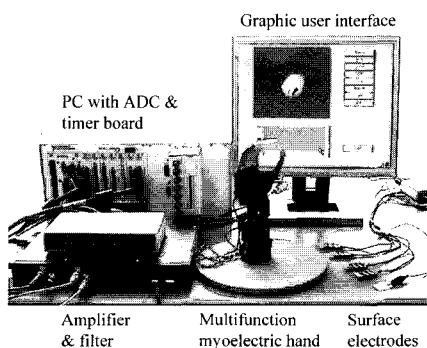


그림 4. 实验装置。

Fig. 4. Experimental setup.

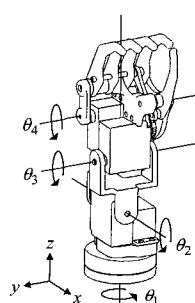


그림 5.4 自由度 다기능 근전의수。

Fig. 5. Multifunction myoelectric hand with four DOFs.

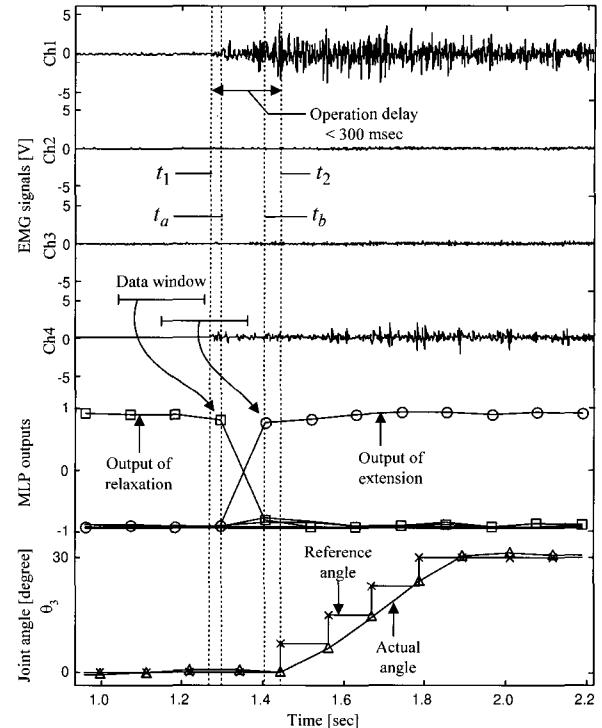


그림 6. 휴지동작에서 신전동작으로의 천이상태。

Fig. 6. Transient state from relaxation to extension.

표 4. 실시간 패턴인식에서 계산시간의 평균값。

Table 4. The average values of processing time in real-time pattern recognition.

processes	processing time [msec]
wavelet packer transform	30
linear discriminant Analysis	2
multilayer perceptron	5
myoelectric hand control	40
others	20
total processes	97

에서 불안정한 출력을 나타냈다. 그 결과 각 동작의 시작과 종료시점에서 오차가 발생하였으며 동작의 정상상태에서는 안정적인 인식결과를 보였다.

VI. 다기능 근전의수의 제어

제안된 방법을 이용하여 다기능 근전의수를 위한 실시간 근전도 패턴인식 시스템을 구현하였다. 그림 4와 같이 4 채널의 표면전극, 필터 및 증폭기, ADC 보드와 타이머 보드를 내장한 PC, 사용자 인터페이스, 그리고 다기능 근전의수로 실험장치를 구성하였다. 본 연구에서 개발된 다기능 근전의수는 그림 5와 같이 내회전/외회전(θ_1), 내전/외전(θ_2), 굴곡/신전(θ_3), 그리고 움켜쥔/펌(θ_4)을 포함하는 4 자유도를 가진다. 전체 길이는 200 mm이며 무게는 0.8 kg이다. 각 관절은 위치제어기가 포함된 RC-서보 모터(HSR-5995TG, HITEC)로 구동된다. 손과 손목동작을 위한 각 관절의 기준각도는 펄스 폭 변조 방식으로 주어지며 타이머 보드(6601, NI[21])를 이용하여 펄스를 발생시켰다.

손목의 신전동작을 인식하는 과정을 예로 들어 설명한다. 피실험자가 신전동작을 취할 때 채널 1과 4의 근전도는 채널 2와 3에 비해 큰 진폭으로 측정된다. 그림 6은 휴지에서 신전으로 동작이 천이될 때 4 채널의 근전도이다. MLP 출력을 그림 6의 중간 부분에서 9개의 실선으로 나타낸다. 휴지동작과 신전동작에 대한 MLP의 출력은 각각 사각 기호와 원 기호로 표시한다. 이러한 출력은 이동 윈도우의 증가분인 125 msec마다 발생한다.

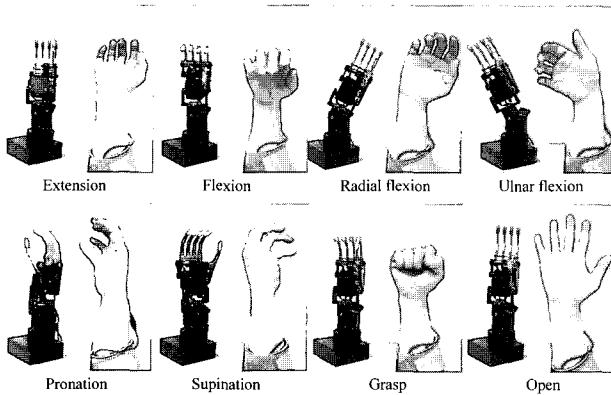


그림 7. 실시간 근전도 패턴인식으로 제어되는 근전의수.

Fig. 7. Myoelectric hand controlled by real-time EMG pattern recognition.

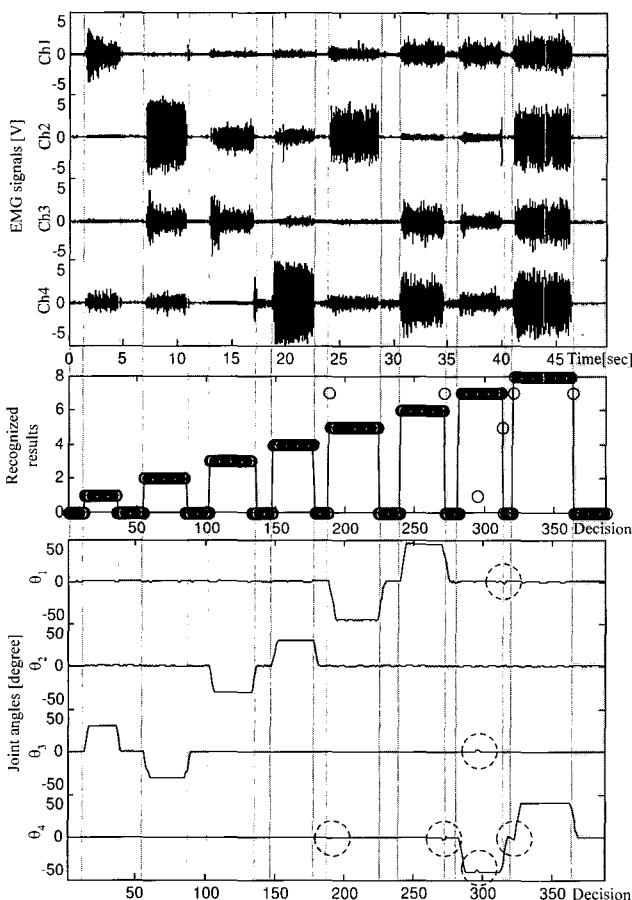


그림 8. 실시간 근전도 패턴인식과 관절각도 제어의 예.

Fig. 8. Example of real-time EMG pattern recognition and joint angle control.

msec마다 발생한다. 먼저 신전동작에 대한 피실험자의 의도는 시간 t_1 에서 발생한다. 그러나 신전동작은 시간 t_a 에서 인식되지 못한다. 그 이유는 시간 t_a 에서의 인식결과는 시간 t_1 을 포함하지 않는 데이터 윈도우를 이용하기 때문이다. 따라서 125 msec 후, 데이터 윈도우가 이동하고 시간 t_b 에서 신전동작이 인식된다. 다음으로 인식 결과에 따라 근전의수를 위한 제어명령 발생 및 사용자 인터페이스가 수행된다. 그림 6의 아래 부분에서 θ_3 에 대한 기준각도와 실제각도를 도시한다. 여기서 기준각도는 패턴인식 시스템이 발생시키는 제어명령을 의미하며 실제각도는 위치제어기를 포함한 RC-서보 모터의 출력이다. 사용자가 취하는 신전동작을 모사하기 위해 최종 기준각도를 30 degree로 설정하였으며 인식결과에 따른 기준각도의 변화분을 7.5 degree로 설정하였다. 사용자 인터페이스는 인식결과에 따라 근전의수와 동일하게 움직이는 3차원 가상 손과 MLP 출력 그래프로 구성되었다. 제어명령 발생 및 사용자 인터페이스 과정은 약 40 msec의 시간이 소요되며 근전의수는 시간 t_2 에서 동작을 시작한다. 표 4에서 보듯이 모든 처리과정이 97 msec 이내에 수행될 수 있었다. 따라서 사용자의 의도가 주어진 시점으로부터 근전의수 동작까지의 시간지연이 300 msec 보다 작았으며 제안된 방법이 다기능 근전의수의 실시간 근전도 패턴인식에 적합함을 확인할 수 있었다.

5명의 피실험자를 대상으로 실시간 근전도 패턴인식을 수행하였으며 검증실험에서와 동일한 97.2%의 인식률을 보였다. 그림 7은 피실험자 C가 제안된 근전도 패턴인식 방법으로 다기능 근전의수를 제어하는 모습이다. 그림에서 근전의수는 각 동작의 정상상태에서의 자세이다. 그림 8에서는 피실험자 C의 4채널 근전도와 실시간 근전도 패턴인식 결과에 따라 제어되는 근전의수의 관절각도를 나타낸다. 주로 동작의 천이상태에서 인식오차가 발생하였으며 이로 인해 그림 8의 점선부분과 같이 사용자가 원하지 않는 동작이 발생하였다. 그러나 앞서 설명한 바와 같이 125 msec마다 발생되는 새로운 인식결과와 기준각도에 의해 관절각도가 보정됨으로써 사용자는 원하는 동작으로 근전의수를 제어할 수 있었다.

VII. 결론

본 논문에서는 다기능 근전의수의 제어를 목적으로 WPT-LDA-MLP로 구성된 근전도 패턴인식 방법을 제안하였다. 먼저 4채널의 근전도로부터 9가지 동작을 구분하기 위해 WPT 특징벡터를 추출하였다. 다음으로 높은 차원의 WPT 특징벡터는 LDA의 선형변환 행렬에 의해 차원이 축소되고 군집화되었다. 마지막으로 투영된 특징벡터는 MLP의 최대 출력값을 가지는 뉴런에 따라 9가지 동작으로 구분되었다. 비교연구를 통해 LDA 특징투영 방법이 시각화, 군집화 능력, 클래스 분리도, 분류 오차율, 계산시간에서 우수함을 확인하였다. 제안된 근전도 패턴인식 방법을 이용하여 다기능 근전의수에 대한 실시간 패턴인식 시스템을 구현하였다. 실험에서 제안된 방법은 97.2%의 높은 인식률을 보였으며, 근전의수 제어명령 발생을 포함하는 모든 처리과정이 97 msec 이내에 완료되었다. 이러한 결과로부터 제안된 방법이 근전의수 제어를 위한 실시간 패턴인식에 적용될 수 있음을 확인하였다.

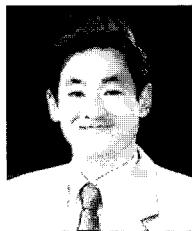
참고문헌

- [1] OttoBock, *MYOBLOCK Arm Components 2005*, 2005.
- [2] S. C. Jacobson, D. F. Knutti, R. T. Johnson, and H. H. Shears, "Development of the Utah artificial arm," *IEEE Trans. Biomed. Eng.*, vol. 29, pp. 249-269, Apr. 1982.
- [3] P. J. Kyberd, O. E. Holland, P. H. Chappel, S. Smith, R. Tregidgoi, P. J. Bagwell, and M. Snaith, "MARCUS: A two degree of freedom hand prosthesis with hierarchical grip control," *IEEE Trans. Rehabil. Eng.*, vol. 3, no. 1, pp. 70-76, 1995.
- [4] C. M. Light and P. H. Chappell, "Development of a lightweight and adaptable multiple-axis hand prosthesis," *Medical Engineering and Physics*, vol. 22, pp. 679-684, 2000.
- [5] J. Butterfab, M. Grebenstein, H. Liu, and G. Hirzinger, "DLR-hand II: Next generation of a dexterous robot hand," *Proc. of IEEE Int'l. Conf. Robotics and Automation*, pp. 109-114, 2001.
- [6] B. Hudgins, P. A. Parker, and R. N. Scott, "A new strategy for multifunction myoelectric control," *IEEE Trans. Biomed. Eng.*, vol. 40, no. 1, pp. 82-94, Jan. 1993.
- [7] F. H. Y. Chan, Y. S. Yang, F. K. Lam, Y. T. Zhang, and P. A. Parker, "Fuzzy EMG classification for prosthesis control," *IEEE Trans. Rehabil. Eng.*, vol. 8, no. 3, pp. 305-311, Sept. 2000.
- [8] H. P. Huang, Y. H. Liu, L. W. Liu, and C. S. Wong, "EMG classification for prehensile posture using cascaded architecture of neural networks with self-organizing maps," *Proc. IEEE Int'l. Conf. Robotics and Automation*, pp. 1497-1502, Sept. 2003.
- [9] K. Englehart and B. Hudgins, "A robust, real-time control scheme for multifunction myoelectric control," *IEEE Trans. Biomed. Eng.*, vol. 50, no. 7, pp. 848-854, July 2003.
- [10] Y. Huang, K. B. Englehart, B. Hudgins, and A. D. C. Chan, "Optimized Gaussian mixture models for upper limb motion classification," *Proc. IEEE Int'l. Conf. EMBS*, pp. 72-75, Sept. 2004.
- [11] A. D. C. Chan and K. B. Englehart, "Continuous myoelectric control for powered prostheses using hidden Markov models," *IEEE Trans. Biomed. Eng.*, vol. 52, no. 1, pp. 121-124, Jan. 2005.
- [12] B. Karlik, M. O. Tokhi, and M. Alci, "A fuzzy clustering neural network architecture for multifunction upper-limb prosthesis," *IEEE Trans. Biomed. Eng.*, vol. 50, no. 11, pp. 1255-1261, Nov. 2003.
- [13] A. Hiraiwa, N. Uchida, N. Sonehara, and K. Shimohara, "EMG pattern recognition by neural networks for prosthetic fingers control - Cyber finger," *Proc. Int'l. Symp. Measurement and control in Robotics*, pp. 535-542, Nov. 1992.
- [14] S. H. Park and S. P. Lee, "EMG pattern recognition based on artificial intelligence techniques," *IEEE Trans. Rehabil. Eng.*, vol. 6, no. 4, pp. 400-405, Dec. 1998.
- [15] K. Englehart, B. Hudgins, P. A. Parker, and M. Stevenson, "Classification of the myoelectric signal using time-frequency based representations," *Medical Engineering and Physics*, vol. 21, pp. 431-438, 1999.
- [16] K. Englehart, B. Hudgins, and P. A. Parker, "A wavelet-based continuous classification scheme for multifunction myoelectric control," *IEEE Trans. Biomed. Eng.*, vol. 48, no. 3, pp. 302-311, Mar. 2001.
- [17] D. Nishikawa, W. Yu, H. Yokoi, and Y. Kakazu, "EMG prosthetic hand controller discriminating ten motions using real-time learning method," *Proc. IEEE/RSJ Int'l. Conf. Intelligent Robots and Systems*, pp. 1592-1597, 1999.
- [18] O. Fukuda, T. Tsuji, M. Kaneko, and A. Otuka, "A human-assisting manipulator teleoperated by EMG signals and arm motions," *IEEE Trans. Robot. Automat.*, vol. 19, no. 2, pp. 210-222, Apr. 2003.
- [19] *Surface Electromyography: Detection and Recording*, Delsys Incorporated, 2002.
- [20] <http://www.delsys.com>
- [21] <http://www.ni.com>
- [22] N. Saito and R. R. Coifman, "Local discriminant bases and their applications," *Journal of Mathematical Imaging and Vision*, vol. 5, no. 4, pp. 337-358, 1995.
- [23] S. G. Mallat, "A theory for multiresolution signal decomposition: The wavelet representation," *IEEE Trans. Pattern Anal. and Machine Intell.*, vol. 11, no. 7, pp. 674-693, July 1989.
- [24] C. Chatterjee and V. P. Roychowdhury, "On self-organizing algorithms and networks for class-separability features," *IEEE Trans. Neural Networks*, vol. 8, no. 3, May 1997.
- [25] R. O. Duda, P. E. Hart, and D. G. Stork, *Pattern classification*. New York: Wiley, 2001.
- [26] D. Lowe and R. Webb, "Optimized feature extraction and bayes decision in feed-forward classifier networks," *IEEE Trans. Pattern Anal. and Machine Intell.*, vol. 13, no. 4, pp. 355-364, Apr. 1991.
- [27] T. Kohonen, "The self-organizing map," *Proc. IEEE*, vol. 78, no. 9, pp. 1464-1480, 1990.
- [28] J. W. Sammon, "A nonlinear mapping for data structure analysis," *IEEE Trans. Comput.*, vol. C-18, pp. 401-409, 1969.



추 준 육

1998년 영남대학교 전기공학과(공학사).
2000년 경북대학교 전자공학과(석사).
2002년 동 대학원 박사과정 수료. 2002
년~현재 재활공학연구소 선임연구원.
관심분야는 생체신호처리 및 패턴인식.



문 인 혁

1992년 경상대학교 전자공학과(공학사).
1994년 동 대학원 석사. 1999년 일본
Osaka 대학 전자제어기계공학과(공학박
사). 1999년~2000년 일본 하마마츠테크
노플리스 추진기구 Post Doc. 연구원.
2000년~2002년 연세대학교 의공학과 연
구교수. 2002년~2005년 재활공학연구소 전자제어팀 책임연구
원. 2005년~현재 동의대학교 메카트로닉스공학과 교수. 관심
분야는 HCI, 바이오메카트로닉스, 이동로봇 및 재활복지로봇.



김 신 기

1988년 경희대학교 기계공학과(공학사).
1990년 동 대학원 석사. 2001년 동 대학
원 박사. 1990년~1995년 엘지정밀연구소
주임연구원. 1995년~현재 재활공학연구
소 기계설계팀 책임연구원. 관심분야는
생체역학 및 재활시스템.



문 무 성

1978년 서울대학교 기계설계학과(공학
사). 1982년 동 대학원 석사. 1992년
University of Minnesota 의공학과(공학박
사). 1981년~1985년 동양공업전문대학
전임강사. 1993년~1994년 경희대학교 의
과대학 연구교수. 1994년~현재 재활공학
연구소 소장. 관심분야는 생체역학 및 재활시스템.