

논문 2005-42SC-2-6

비선형 특징투영 기법을 이용한 웨이블렛 기반 근전도 패턴인식

(A Wavelet-Based EMG Pattern Recognition with Nonlinear Feature Projection)

추 준 욱*, 문 인 혁*

(Jun-Uk Chu and Inhyuk Moon)

요 약

본 논문에서는 다기능 근전의수를 제어하기 위해 전원에서 취득한 4 채널의 근전도로부터 9 가지 동작을 인식하는 새로운 방법을 제안한다. 비정상 신호특성을 가진 근전도를 해석하기 위해서 시간-주파수 영역에서 표현되는 특징벡터를 웨이블렛 패킷변환을 통해 추출한다. 높은 차원을 가지는 시간-주파수 특징벡터에 대하여 차원축소와 비선형변환을 수행하기 위해 PCA와 SOFM으로 구성된 특징투영 방법을 제안한다. PCA를 이용한 차원축소는 패턴분류기의 구조를 단순화하고 패턴인식을 위한 계산시간을 단축할 수 있다. SOFM을 이용한 비선형변환은 PCA에 의해 차원이 축소된 특징벡터를 새로운 공간으로 투영함으로써 클래스 분리도를 향상시킨다. 마지막으로 각 동작은 패턴분류기인 다층 신경회로망에 의해 인식된다. 실험 결과로부터 제안한 방법이 높은 인식률을 보임과 동시에 연속적인 패턴인식을 위한 실시간 구현이 가능함을 보인다.

Abstract

This paper proposes a novel approach to recognize nine kinds of motion for a multifunction myoelectric hand, acquiring four channel EMG signals from electrodes placed on the forearm. To analyze EMG with properties of nonstationary signal, time-frequency features are extracted by wavelet packet transform. For dimensionality reduction and nonlinear mapping of the features, we also propose a feature projection composed of PCA and SOFM. The dimensionality reduction by PCA simplifies the structure of the classifier, and reduces processing time for the pattern recognition. The nonlinear mapping by SOFM transforms the PCA-reduced features to a new feature space with high class separability. Finally a multilayer neural network is employed as the pattern classifier. From experimental results, we show that the proposed method enhances the recognition accuracy, and makes it possible to implement a real-time pattern recognition.

Keywords : EMG, pattern recognition, nonlinear feature projection, wavelet packet transform, PCA, SOFM

I. 서 론

근전의수(myoelectric hand)는 상지절단 장애자가 잔존근육에서 발생하는 근전도를 이용하여 제어할 수 있는 의지(prosthesis)이다. 일반적인 근전의수는 손과 손

목기능을 수행하는 기계장치, 근전도를 측정하기 위한 표면전극, 그리고 근전도로부터 제어명령을 생성하고 각 기능을 제어하는 제어기로 구성된다. 근전도는 기본적으로 1 차원 패턴으로 정보량이 많지 않으며, 큰 편차와 비정상 신호(nonstationary signal) 특성을 보인다. 따라서 현재 상용화된 근전의수는 잔존근육의 수축강도와 근전도 진폭의 선형적 관계를 바탕으로 2 개의 표면전극에서 측정된 근전도의 절대 평균값(mean absolute value, MAV)을 비교함으로써 사용자의 동작을 인식한다^[1,2]. 이러한 근전의수는 주로 4 가지 동작 즉, 손의 움

* 정희원, 재활공학연구소
(Korea Orthopedics & Rehabilitation Engineering Center)

※ 본 연구는 보건복지부 보건의료기술진흥사업의 지원에 의하여 이루어진 것입니다. (과제번호:02-PJ3-PG6-EV03-0004)

접수일자: 2004년12월2일, 수정완료일: 2005년3월10일




그림 1. 근전도 패턴인식의 블록도

Fig. 1. Block diagram for EMG pattern recognition.

켜잡과 펌 기능, 손목의 내회전과 외회전 기능을 수행할 수 있다. 그러나 근전도의 MAV와 같이 적은 양의 정보만을 이용하는 동작인식 방법은 손과 손목의 자유도가 증가하여 동작의 수가 늘어날 경우 충분한 제어명령을 생성하지 못한다.

이러한 문제를 해결하기 위하여 많은 연구자들은 각 동작에 해당되는 근전도로부터 서로 분리가능하며 반복적 재생이 가능한 특징벡터(feature vector)를 정의하고 패턴인식 개념을 도입함으로써 더욱 많은 제어명령을 추출하기 위한 방법들을 제안하였다^[3-9]. 시간 또는 주파수영역에서 추출될 수 있는 근전도 특징벡터는 진폭(amplitude) 및 영교차율(zero-crossing rate)^[3,4], 자기회귀모델 계수 (autoregressive coefficient)^[5], 푸리에변환 계수(fourier transform coefficient)^[6], 켈프스트럼 계수(cepstrum coefficient)^[7] 등이 있다. 그러나 이러한 특징벡터를 이용한 패턴인식 방법들은 근전도가 정상 신호(stationary signal)임을 가정하였기 때문에 높은 인식률을 보이지는 못했다.

최근 들어 국소 푸리에 변환(short-time fourier transform), 웨이블릿 변환(wavelet transform), 웨이블릿 패킷변환(wavelet packet transform)과 같은 시간-주파수 해석방법이 비정상 신호해석에 적용되고 있다. 그 이유는 일반적으로 시간-주파수 해석방법이 특징벡터를 높은 차원으로 묘사함으로써 많은 정보를 제공하기 때문이다. 그러나 특징벡터의 높은 차원은 패턴분류기(classifier)의 학습 파라미터를 증가시키며 학습오차의 수렴성을 저하시킨다. 따라서 시간-주파수 해석에서 추출된 특징벡터를 패턴분류기의 입력으로 적용하기에 앞서 차원축소(dimensionality reduction)를 위한 특징투영(feature projection) 과정이 필요하다. Englehart^[8,9]는 웨이블릿 패킷 변환으로 추출된 특징벡터를 PCA(principal component analysis)에 적용하여 차원을 축소하였다. 그러나 PCA는 클래스 분포의 분리를 고려하지 않고 전체 패턴분포의 분산이 최대가 되는 좌표계를 구하는 선형적 변환방법이기 때문에 패턴 인식률에서

만족할 만한 결과를 보이지 못했다. 일반적으로 근전도 패턴인식에서 PCA에 의해 20 차원내외로 축소된 시간-주파수 특징벡터는 원 패턴들의 클래스 분포를 잘 표현한다고 알려져 있지만^[9], 클래스간 밀도함수가 정확하게 분리되지 못하는 단점이 있다.

본 연구에서는 이러한 단점을 극복하기 위해 '차원축소'와 '비선형변환(nonlinear mapping)' 기능을 가지는 PCA와 SOFM(self-organizing feature map)으로 구성된 새로운 특징투영 방법을 제안한다. PCA를 이용한 차원축소 과정은 패턴분류기의 구조와 학습을 간단히 할 수 있으며, 패턴인식을 위한 계산시간을 단축시킬 수 있다. SOFM을 이용한 비선형변환은 PCA에 의해 차원이 축소된 특징벡터를 새로운 특징공간으로 매핑함으로써 클래스 분리도(class separability)를 향상시킬 수 있으며, 결과적으로 패턴분류기가 향상된 분할여유(separation margin)를 가진 초평면(hyperplane)을 형성할 수 있게 한다. 그 결과, 제안한 특징투영 방법은 PCA만을 이용한 방법보다 높은 인식률을 가짐과 동시에, 높은 차원의 시간-주파수 특징벡터를 직접 투영시키는 SOFM 방법에 비해 적은 계산시간을 소요함으로써 실시간 패턴인식이 가능하다.

본 연구에서는 제안한 특징투영 방법을 이용하여 전원에서 취득한 4 채널의 근전도 신호로부터 9 가지 동작을 인식한다. 먼저 비정상적 신호특성을 가진 근전도 신호를 해석하기 위해 웨이블릿 패킷변환으로 시간-주파수 특징벡터를 추출한다(그림 1 참조). 다음으로 제안한 특징투영 방법에 따라 PCA는 웨이블릿 패킷 특징벡터의 차원을 축소하고, SOFM은 PCA의 출력을 격자공간상의 한 점으로 비선형 변환함으로써 특징벡터 집합의 클러스터를 형성한다. 마지막으로 각 동작은 패턴분류기인 다층 신경회로망에 의해 인식된다. 근전도 패턴인식의 궁극적인 목적은 사용자의 의도를 인식하고 근전도의수 동작을 제어하기 위한 것이다. 일반적으로 300 msec 이내에 사용자의 의도를 인식하고 근전도의수 동작시켜야만 자연스러운 의수사용이 가능하다^[10].

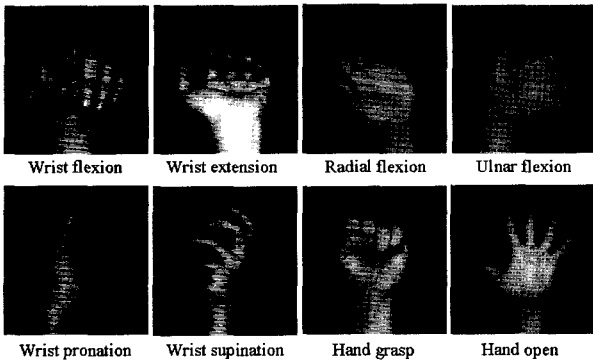


그림 2. 구분되는 8 가지 동작
Fig. 2. Eight kinds of motion to be classified.




그림 3. 4 채널 근전도 측정을 위한 전극 위치
Fig. 3. Electrode placement to acquire the four channel EMG.

따라서 본 연구에서는 패턴인식을 위한 총 처리시간이 125 msec가 넘지 않는 것을 목표로 한다. 본 연구에서 정상인을 대상으로 한 실험결과로부터 제안한 패턴인식 방법이 PCA 혹은 SOFM만을 이용한 결과에 비해 높은 인식률과 동시에 실시간 구현이 가능함을 보인다.

II. 근전도 측정

본 논문에서는 그림 2 와 같이 전완 (forearm)에서 가장 자주 사용되는 손목의 굴곡 (flexion), 신전 (extension), 내전 (radial flexion), 외전 (ulnar flexion), 내회전 (pronation), 외회전 (supination), 그리고 손의 움켜잡(grasp), 펴(open)의 8 가지 동작과 휴지 (relaxation) 동작을 포함하는 9 가지 동작을 인식한다. 8 가지 동작은 그림 3 에서 보이는 전완 근육들의 수축으로 이루어진다^[11]. 특히 긴 손바닥근(palmaris longus), 손가락 펴근 (extensor digitorum), 노쪽 손목 굽힘근 (extensor carpi radialis), 그리고 자쪽 손목 굽힘근 (flexor carpi ulnaris)은 손과 손목 동작에 관여하는 중




그림 4. 이진 트리구조의 부공간
Fig. 4. Binary tree-structured subspaces.

요근육으로서 4 개의 표면전극(surface electrode)을 부착하여 근전도를 측정한다. 근전도는 근육의 수축에 따라 0~10 mV의 진폭을 가지며 20~500 Hz에 에너지가 집중되어 있다^[12]. 따라서 본 논문에서는 Delsys 사의 표면전극, 증폭기 및 필터^[13]를 이용하여 100 dB로 증폭되고 20~450 Hz 대역 제한된 근전도를 획득한다. 다음으로 획득된 근전도는 패턴인식 과정을 위하여 1024 Hz로 샘플링된다. 웨이블릿 패킷변환을 수행하기 위한 데이터 윈도우의 길이(window length)는 250 msec(256 points)로 설정한다. 또한 연속적 패턴인식을 위한 데이터 윈도우의 이동증가분(window increment)은 125 msec(128 points)로 설정한다.

III. 근전도 패턴인식

1. 웨이블릿 패킷변환

근전도로부터 특징벡터를 추출하기 위해 웨이블릿 패킷변환을 수행한다. 웨이블릿 패킷변환은 웨이블릿 변환의 일반화된 표현법이다. 그림 4 에서 이진트리 구조의 웨이블릿 패킷변환을 보인다. N 개의 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 $\Omega_{j,k} \rightarrow \Omega_{j+1,2k}$ 와 $\Omega_{j,k} \rightarrow \Omega_{j+1,2k+1}$ 로 분해된다. 여기서 j 는 스케일을, k 는 스케일 내의 부공간을 나타낸다. 각 부공간 $\Omega_{j,k}$ 는 기저벡터(basis vector) $\{w_{j,k,n}\}$, $n = 0, \dots, 2^{n_0-j} - 1$, $n_0 = \log_2 N$ 로 표현된다. 이와 같은 성질은 각 주파수 대역별 부공간의 선택에 따라 다양한 형태의 완전한(complete) 시간-주

과수 공간 표현이 가능하다. 따라서 적절한 분리척도(discriminant measure)를 설정한다면 특징벡터의 클래스 분리도가 최대가 되는 최적기저(best basis)를 찾을 수 있다.

본 논문에서는 최적기저 탐색방법으로 Saito and Coifman^[14]의 지역 분리 기저(local discriminant basis) 알고리즘을 이용한다. 클래스간 분리척도로서 대칭 상대 엔트로피(symmetric relative entropy) D 는

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

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

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

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 식 (1)과 (2)로부터 K 개의 클래스에 대한 부공간 $\Omega_{j,k}$ 의 대칭 상대 엔트로피는 다음과 같이 적을 수 있다.

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

$B_{j,k}$ 를 부공간 $\Omega_{j,k}$ 에 속하는 후보 기저벡터 집합이라 하면 $A_{j,k}$ 는 $B_{j,k}$ 에서 선택된 최적기저로서 지역 분리 기저가 된다. 또한 각 노드 (j, k) 에서의 분리척도 $\Delta_{j,k}$ 를 정의하면 지역 분리 기저 알고리즘은 다음과 같이 요약된다.

1. 웨이블릿 패킷변환을 위한 웨이블릿 및 스케일 함수를 결정하고 분해레벨(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 $\Delta_{j,k} = D(\{\Gamma_c(j, k, \cdot)\}_{c=1}^K)$, $k = 0,$

$\dots, 2^j - 1$ 로 설정한다.

4. 다음 과정을 반복하여 지역 분리 기저 $A_{j,k}$,

$j = J - 1, \dots, 0$, $k = 0, \dots, 2^j - 1$ 를 결정한다.

$\Delta_{j,k} = D(\{\Gamma_c(j, k, \cdot)\}_{c=1}^K)$ 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.

이상에서 설명한 지역 분리 기저 알고리즘은 가지치기 방법(pruning method)을 이용하여 부모 노드와 자식 노드들의 분리척도를 비교하고, 자식 노드들을 유지할 것인지 혹은 부모 노드 쪽으로 이동할 것인지를 결정한다. 따라서 본 논문에서는 9개의 동작 구분을 위해 각 노드의 부공간 $\Omega_{j,k}$ 에서 9개의 클래스에 대한 에너지 맵을 계산하고 다른 노드와 대칭 상대 엔트로피를 비교함으로써 지역 분리 기저를 선택한다. 더불어 클래스 분리도를 증가시키기 위해 4개의 근전도 채널에 대하여 독립적인 지역 분리 기저 집합을 구성한다. 패턴인식 과정에서는 선택된 지역 분리 기저에 근거하여 웨이블릿 패킷변환을 수행하고 그 계수의 절대값을 특징벡터로 추출한다.

2. 비선형 변환을 이용한 특징 투영

웨이블릿 패킷변환 계수의 절대값으로부터 추출된 특징벡터는 PCA를 통해 차원이 축소된다. 비록 축소된 특징벡터의 차원이 패턴인식 결과에 큰 영향을 미치지 않지만 20 차원 내외의 PCA 출력이 필요하다^[9]. 따라서 본 논문에서는 각 채널별로 5 차원의 PCA 출력공간을 설정한다. PCA의 학습과정은 입력 특징벡터들의 분포를 가장 잘 묘사할 수 있는 좌표계를 찾는 과정으로 볼 수 있으며 선형결합 모델을 이용하여 무의미한 요소의 크기를 줄임으로써 차원축소 과정을 수행한다. 특히, PCA는 닫힌 형태의 해를 제공하며 공분산 행렬의 고유치 크기에 따라 특징벡터 요소들의 중요도를 판별함으로써 새로운 특징공간의 차원을 결정할 수 있다. PCA 과정을 정리하면 다음과 같다^[15].

1. 전체 n 차원 입력 데이터 $\{\mathbf{x}_i\}$, $i = 1, \dots, m$ 에 대하여 공분산 행렬 Σ 를 구성한다.
2. 공분산 행렬 Σ 에 대한 고유치 $\lambda_1 \geq \dots \geq \lambda_n$ 와 고

유벡터 μ_1, \dots, μ_n 를 계산한다.

3. 가장 큰 고유치를 가지는 k 개의 고유벡터로부터 $n \times k$ 차원의 변환행렬 \mathbf{A} 를 구한다. 여기서 각 행은 k 개의 고유벡터로 구성된다.
4. 입력 데이터에 대하여 $\mathbf{y} = \mathbf{A}^T \mathbf{x}$ 를 계산함으로써 k 차원에서의 변환을 수행한다.

SOFM은 PCA에 의해 압축된 특징벡터 공간에 대하여 비선형 변환을 수행함으로써 패턴 분류기가 향상된 분할여유를 가지할 수 있도록 한다. 본 논문에서는 각 채널에 대하여 독립적인 SOFM이 존재한다. SOFM의 입력은 PCA의 출력으로 구성되며 SOFM의 출력공간은 40×40 의 2 차원 격자구조(lattice)로 설계된다. 학습과정에서 SOFM은 입력과의 유사도(similarity) 그리고 승리뉴런(winning neuron)과의 기하학적 근접도(topological neighborhood)에 따라 연결강도를 조절한다. 동일한 클래스에 속한 패턴들이 클러스터를 형성하기 위해서는 연결강도의 초기화와 패턴 샘플링 과정이 매우 중요하다. 연결강도의 초기값은 각 클래스 패턴이 동일한 확률로 분포되어야 하며 패턴 샘플링과정에서도 클래스 간 균등한 기회가 보장되어야 한다. 본 논문에서 적용된 SOFM의 학습과정은 다음과 같다^[6].

1. 연결강도를 위한 초기값을 설정한다. 2 차원 출력공간의 격자개수 l 에 대하여 초기 연결강도 벡터 $\mathbf{w}_j(0)$, $j=1, \dots, l$ 는 입력벡터의 집합으로부터 무작위로 선택한다.
2. 입력벡터 집합으로부터 입력벡터 \mathbf{x} 를 샘플링한다. 각 클래스에 속한 입력벡터가 동일한 확률로 선택되도록 한다.
3. 반복횟수 n 에서의 입력벡터에 대하여 다음의 최소거리 유클리디언-노움 조건을 만족하는 승리뉴런 $i(\mathbf{x})$ 를 결정한다.

$$i(\mathbf{x}) = \arg \min_j |\mathbf{x}(n) - \mathbf{w}_j|, j=1, \dots, l \quad (4)$$

4. 다음의 학습규칙을 이용하여 모든 뉴런의 연결강도를 조정한다.

$$\mathbf{w}_j(n+1) = \mathbf{w}_j(n) + \eta(n)h_{j,i(\mathbf{x})}(n)(\mathbf{x}(n) - \mathbf{w}_j(n)) \quad (5)$$

여기서 $\eta(n)$ 은 학습률 그리고 $h_{j,i(\mathbf{x})}(n)$ 는 승리뉴

런 $i(\mathbf{x})$ 을 중심으로 이웃뉴런과의 기하학적 근접도를 나타낸다. $\eta(n)$ 와 $h_{j,i(\mathbf{x})}(n)$ 는 학습과정에서 동적인 변화를 줌으로써 학습의 수렴성을 향상시킬 수 있다.

5. 출력공간의 변화가 없을 때까지 단계 2에서 4를 반복한다.

단계 4의 기하학적 근접도는 다음과 같으며, 반복횟수에 대하여 시변적 특성을 가진다.

$$h_{j,i(\mathbf{x})}(n) = \exp(-d_{j,i}^2/2\sigma^2(n)) \quad (6)$$

여기서 $d_{j,i}$ 는 승리뉴런과 이웃뉴런과의 거리를 나타낸다. 일반적으로 반복횟수 n 에 대하여 근접도 함수의 분산은 지수 함수적으로 감소하며 다음과 같다.

$$\sigma(n) = \sigma_0 \exp(-n/\tau_1) \quad (7)$$

여기서 σ_0 는 근접도 함수의 초기 분산값이며 τ_1 는 시정수를 나타낸다. 또한 학습률

$$\eta(n) = \eta_0 \exp(-n/\tau_2) \quad (8)$$

도 초기값 η_0 로부터 시정수 τ_2 에 따라 지수 함수적으로 감소한다. 학습이 완료된 SOFM은 패턴인식 과정에서 입력벡터 \mathbf{x} 와 학습된 연결강도를 비교하여 승리뉴런 $i(\mathbf{x})$ 를 찾고 그 좌표값을 출력함으로써 비선형 변환을 수행한다.

3. 패턴 분류

다층 신경회로망은 패턴인식의 마지막 단계인 패턴 분류를 수행한다. 그림 5는 PCA, SOFM, 그리고 다층 신경회로망으로 이루어진 근전도 패턴인식의 구조를 보




그림 5. PCA, SOFM, 그리고 다층 신경회로망으로 구성된 근전도 패턴인식의 구조

Fig. 5. Scheme for EMG pattern recognition composed of PCA, SOFM, and multilayer neural network.

인다. 각 채널의 특징벡터는 PCA와 SOFM의 특징투영 과정을 통해 2 차원 격자점 좌표값으로 변환된다. 따라서 다층 신경회로망은 8 개의 입력과 각 동작에 대응하는 9 개의 출력을 가진다. 본 연구에서는 2 개의 은닉층을 가진 다층 신경회로망이 사용된다. $x_i(n)$ 을 입력층 뉴런, $h_j(n)$ 와 $h_k(n)$ 을 은닉층 뉴런, 그리고 $y_i(n)$ 을 출력층 뉴런이라 하면 은닉층 뉴런과 출력층 뉴런은 다음과 같이 표현된다.

$$h_k(n) = f\left(\sum_{i=1}^L w_{ki}x_i(n) + w_{k0}\right), \quad k = 1, \dots, K \quad (9)$$

$$h_j(n) = f\left(\sum_{k=1}^K w_{jk}h_k(n) + w_{j0}\right), \quad j = 1, \dots, J \quad (10)$$

$$y_i(n) = f\left(\sum_{j=1}^J w_{ij}h_j(n) + w_{i0}\right), \quad i = 1, \dots, I \quad (11)$$

여기서 w_{ij} , w_{jk} , 그리고 w_{kl} 는 뉴런의 연결강도를, w_{i0} , w_{j0} , 그리고 w_{k0} 는 뉴런의 바이어스를 나타낸다. 또한 활성화함수는 $f(v) = 2/(1 + \exp^{-v}) - 1$ 로 표현되는 양극성 시그모이드 함수(bipolar sigmoid function)가 사용된다. 오차 역전과 학습을 위하여 입력벡터 $x_i(n)$ 와 원하는 출력벡터 $d_i(n)$ 을 준비한다. $d_i(n)$ 은 분류하고자 하는 동작에 대응하면 +1, 그렇지 않으면 -1로 설정한다. 출력오차를 $e_i(n) = d_i(n) - y_i(n)$ 로 정의한다면 연결강도는 다음의 오차 역전과 학습법으로 조정된다.

$$w_{ij}(n+1) = w_{ij}(n) + \eta e_i(n) y_i'(n) h_j(n) \quad (12)$$

$$w_{jk}(n+1) = w_{jk}(n) + \eta \sum_{i=1}^I e_i(n) y_i'(n) w_{ij}(n) h_j'(n) h_k(n) \quad (13)$$

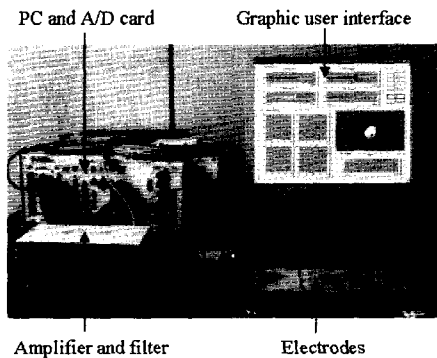


그림 6. 실험 장치
Fig. 6. Experimental setup.

$$w_{kl}(n+1) = w_{kl}(n) + \eta \sum_{i=1}^I \sum_{j=1}^J e_i(n) y_i'(n) w_{ij}(n) h_j'(n) w_{jk}(n) h_k'(n) x_i(n) \quad (14)$$

IV. 실험 결과

근전도 패턴인식의 목적은 사용자의 의도를 인식하고 근전도의 수 동작을 제어하기 위한 것이다. 일반적으로 300 msec 이내에 사용자의 의도를 인식하고 근전도의 수를 동작시켜야만 자연스러운 의수사용이 가능하다¹⁰⁾. 본 연구에서는 이러한 조건을 만족하기 위해서 250 msec 데이터 윈도우가 125 msec 이동증가분을 가지도록 설정하였다. 따라서 어떤 시점에서 주어진 사용자의 의도는 반드시 250 msec 데이터 윈도우에 두 번씩 포함되므로 패턴인식을 위한 처리시간이 125 msec 보다 작다면 사용자의 의도는 300 msec 내에 인식될 수 있다. 실험에서는 본 연구에서 제안한 패턴인식 방법의 오차율과 처리시간을 평가한다.

본 논문에서는 그림 6 과 같이 근전도를 취득하기 위한 4 개의 표면전극, 필터 내장형 증폭기, A/D 카드를 포함한 PC, 그리고 실험결과를 나타내는 사용자 인터페이스로 실험 장치를 구성하였다. 피실험자는 휴지동작을 포함하여 그림 2 의 8 가지 동작을 순차적으로 수행하였으며, 동시에 근전도가 측정되었다. 처음 45056 msec 동안 획득된 근전도는 학습 패턴으로 사용되었으며, 나머지 46848 msec 동안 획득된 근전도는 테스트 패턴으로 사용되었다. 학습과정을 위해 측정된 근전도는 125 msec 이동증가분을 가진 250 msec 데이터 윈도우로 분할되었고, 각각 분류하고자 하는 동작 클래스가 할당되었다. 학습과정에서 구하는 패턴인식 파라미터를

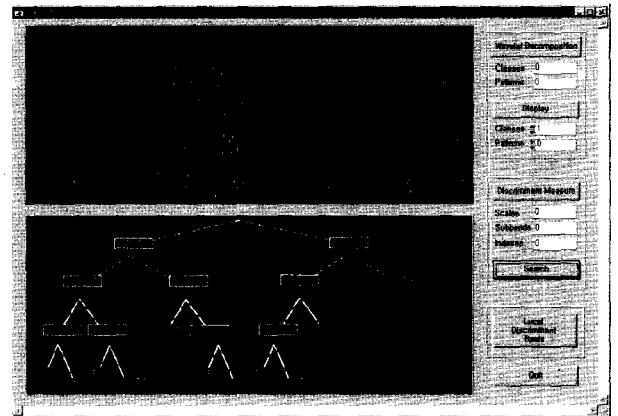


그림 7. 완전분해 결과와 최적 이진트리
Fig. 7. Full decomposition and best binary tree.

정리하면 다음과 같다.

1. 웨이블릿 패킷 변환을 위한 지역 분리 기저
2. PCA를 위한 공분산 행렬의 고유벡터
3. SOFM을 위한 뉴런의 연결강도
4. 다층 신경회로망을 위한 뉴런의 연결강도

지역 분리 기저 알고리즘에서 이산 웨이블릿 분해는 Mallat^[17] 알고리즘으로 구현되었다. 웨이블릿 및 스케일링 함수는 10 개의 계수를 가진 5 차 Symmlet 함수가 사용되었으며, 4 차 스케일 레벨까지 변환이 수행되었다. 컨벌루션 및 다운-샘플링 과정을 거친 후 각 부공간의 기저벡터의 길이는 표 1 과 같다. 그림 7 은 채널 2 에 대한 지역 분리 기저 알고리즘의 결과이다. 상위 원도는 250 msec 원신호가 4 차 스케일 레벨까지 완전분해(full decomposition)된 결과이며, 하위 원도는 부공간의 분리척도를 비교하여 선택된 최적 이진트리(best binary tree)이다. 그림 8 은 선택된 시간-주파수 영역 부공간의 조합을 채널별로 도시한 결과이다. 각 채널은 독립적으로 9 개 클래스의 분리척도를 최대로 하는 시간-주파수 영역을 형성한다. 따라서 웨이블릿 변환과 달리 채널별로 서로 다른 형태의 타일링을 가짐을 알 수 있다. 각 채널의 특징벡터는 선택된 지역 분리

표 1. 각 부공간의 기저벡터 길이
Table 1. The length of basis vector for each subspace.

Subspace	$\Omega_{0,0}$	$\Omega_{1,k}$	$\Omega_{2,k}$	$\Omega_{3,k}$	$\Omega_{4,k}$
Length	256	132	70	39	24

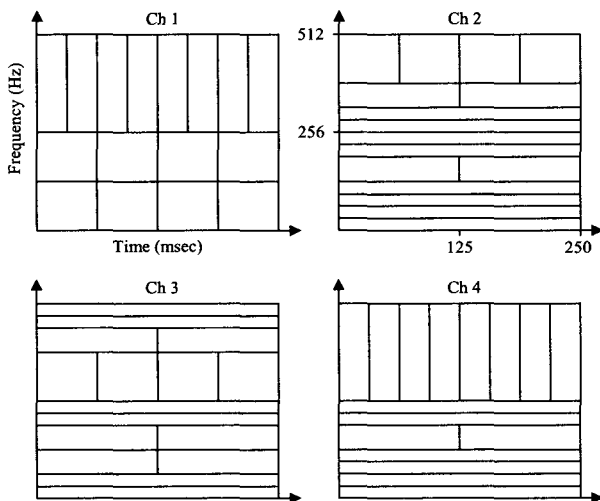


그림 8. 각 채널의 시간-주파수영역 타일링
Fig. 8. The tiling of time-frequency plane for each channel.

기저에 따라 웨이블릿 분해를 수행함으로써 추출되었다.

이상에서 추출된 특징벡터를 이용하여 PCA와 SOFM을 위한 학습을 수행하였다. 먼저 PCA를 위한 공분산 행렬을 웨이블릿 패킷변환 계수의 절대값으로부터 구성하였다. 공분산 행렬의 고유벡터 중 고유치가 가장 큰 5 개의 벡터를 선택하여 변환행렬을 구하였다. 특징벡터는 변환행렬을 통해 5 차원으로 축소되었다. 그림 9 는 5 차원 벡터 중 2 차 주요 성분까지만을 나타낸 결과이다. 앞서 언급한 바와 같이 PCA의 신호압축 효과로 인해 클래스 밀도함수가 중복됨을 확인할 수 있다.

SOFM의 초기 연결강도는 PCA의 출력으로부터 무작위로 선택하였다. 따라서 학습 초기의 모든 뉴런은 동일한 확률로 승리뉴런이 될 수 있다. 근접도 함수의 초기 분산값은 40×40 출력공간을 포함할 수 있도록 $\sigma_0 = 20$ 로 설정하였으며, 시정수는 $\tau_1 = 2000$ 로 설정하였다. 그리고 초기 학습률은 $\eta_0 = 0.9$ 이며 시정수는 $\tau_2 = 2000$ 이다. 그 결과 학습횟수 4000 번에서 SOFM의 연결강도가 수렴함을 보였다. 그림 10 은 SOFM의 출력을 2 차원 격자공간에 도시한 결과이다. 동일한 클래스에 속한 패턴들이 클러스터를 형성하고 있으며 PCA 출력과 비교하여 클래스 분리도가 향상됨을 알 수 있다.

다층 신경회로망의 입력은 SOFM 출력뉴런의 좌표값을 정규화한 값으로 얻어졌다. 2 층으로 이루어진 은

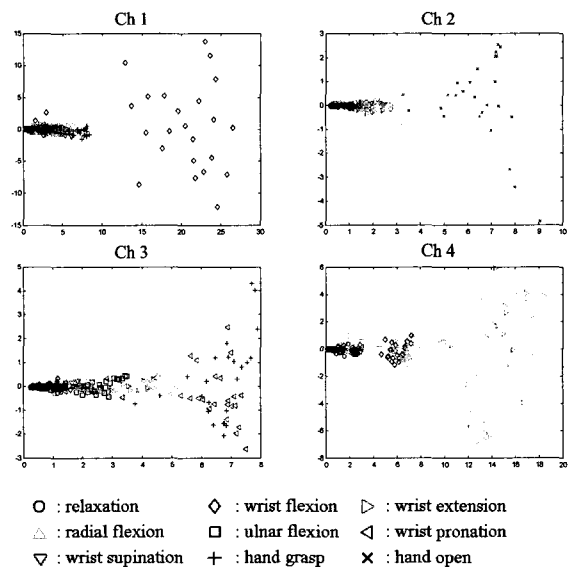


그림 9. 웨이블릿 패킷 특징벡터의 2 차 주요성분
Fig. 9. Two principal components of wavelet packet features.




그림 10. 격자공간의 SOFM 출력
Fig. 10. SOFM outputs in the lattice.




그림 11. 다층 신경회로망의 출력
Fig. 11. Outputs of multilayer neural network.

닉층의 뉴런개수는 각각 9 개로 설정하였으며, 학습횟수 10000 번에서 모든 출력의 오차가 수렴함을 보였다. 학습패턴에 대한 다층 신경회로망의 출력을 그림 11 에 보인다. 45056 msec 동안 351 번의 패턴분류가 이루어졌으며 정상상태에서 각 클래스의 출력이 안정적인임을 확인할 수 있었다.

웨이블릿 패킷변환, PCA, SOFM, 그리고 다층 신경회로망의 학습이 완료된 후, 제안된 방법의 인식률을 검증하였다. 그림 12 에서 테스트 패턴과 인식결과를 보인다. 테스트 패턴은 피실험자로부터 측정된 46848 msec 근전도이다. 원 기호는 인식결과를 나타내며 실선은 분류하고자 하는 클래스이다. 비록 각 동작간의 시작과 종료 시점에서 오차가 발생하지만 전체적인 결과에서 높은 인식률을 보인다.

다음으로 제안된 방법의 우수성을 보이기 위해 PCA만을 사용한 경우 그리고 SOFM만을 사용한 경우와 비교하였다. 그림 13 의 인식 오차율을 보면 SOFM만을

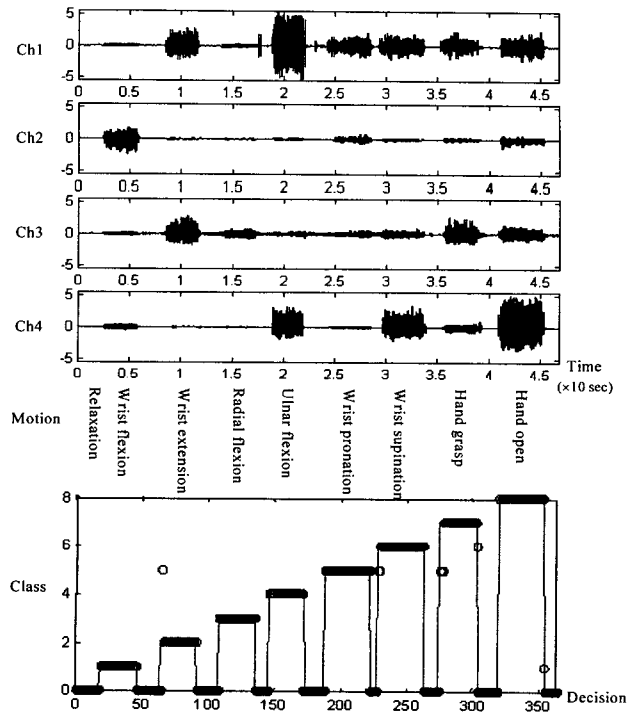


그림 12. 테스트 패턴과 인식결과
Fig. 12. Test patterns and recognition results.




그림 13. 인식 오차율
Fig. 13. Recognition error rate.




그림 14. 처리시간
Fig. 14. Processing time.

사용한 경우가 가장 낮은 오차율을 보였다. 그러나 이 방법은 높은 차원의 시간-주파수영역 특징벡터를 그대로 사용함으로써 그림 14 에 보이는 것과 같이 긴 처리시간을 필요로 하였다. 그림 14 의 처리시간은 1.8 GHz Pentium IV processor PC에서 수행된 결과이다. 실시간 패턴인식을 위해서는 계산과정이 데이터 원도의 이동증가분 125 msec 내에 이루어져야 한다. 따라서 SOFM만을 사용한 방법은 실시간 구현이 불가능하다.

반면 제안된 방법은 SOFM 만을 사용한 방법과 비슷한 인식률을 가지면서 실시간 구현이 가능함을 알 수 있다.

V. 결 론

본 논문에서는 다기능 근전도의 제어를 목적으로 4 채널 근전도로부터 9 가지 동작을 실시간으로 인식하기 위하여 시간-주파수영역의 특징벡터를 효과적으로 다룰 수 있는 비선형 특징투영 방법을 제안하였다. 제안된 방법은 PCA가 차원축소를 위해 단힌 형태의 해를 제공하며, SOFM이 비선형 변환을 통해 특징벡터를 새로운 특징공간으로 매핑함으로써 향상된 클래스 분리도를 가질 수 있다는 점을 이용한 것이다. 각 채널별로 구해진 지역 분리 기저를 바탕으로 웨이블릿 패킷변환이 수행되었으며 추출된 특징벡터는 제안된 특징투영 방법을 통해 새로운 특징공간에서 클러스터를 형성하였다. 이러한 효과는 다층 신경회로망이 향상된 분할여유를 가진 초평면을 형성할 수 있도록 하였다. 실험 결과로부터 본 논문에서 제안된 비선형 특징투영 방법은 차원축소를 위해 PCA만을 사용한 패턴인식 방법보다 높은 인식률을 가졌으며, 또한 짧은 처리시간으로 인해 실시간 패턴인식이 가능함을 보였다. 향후에는 제안된 방법을 현재 제작중인 손목의 3 자유도와 손의 1 자유도를 가진 다기능 근전도의수에 적용하여 유용성을 검증할 예정이다.

참 고 문 헌

- [1] OttoBock HealthCare, *MYOBOCK Arm Components 2004*, 2004.
- [2] S. C. Jacobson, D. F. Knutti, R. T. Johnson, and H. H. Sears, "Development of the Utah artificial arm," *IEEE Trans. Biomed. Eng.*, vol. 29, pp. 249-2697, April 1982.
- [3] 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, January 1993.
- [4] 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. Rehab. Eng.*, vol. 8, no. 3, pp. 305-311, September 2000.
- [5] 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," *IEEE Int'l. Conf. Robotics and Automation*, pp. 1497-1502, September 2003.
- [6] 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, November 1992.
- [7] S. H. Park and S. P. Lee, "EMG Pattern Recognition Based on Artificial Intelligence Techniques," *IEEE Trans. Rehab. Eng.*, vol. 6, no. 4, pp. 400-405, December 1998.
- [8] K. Englehart, B. Hudgins, Philip 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.
- [9] K. Englehart, B. Hudgins, and Philip A. Parker, "A wavelet-based continuous classification scheme for multifunction myoelectric control," *IEEE Trans. Biomed. Eng.*, vol. 48, no. 3, pp. 302-311, March 2001.
- [10] 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.
- [11] Jeffrey R. Cram and Clenn S. Kasman, *Introduction to surface eletromyography*, An Aspen Publication, Maryland, 1998.
- [12] C. J. De Luca, "Surface electromyography: Detection and recording," *Delsys Incorporated*, 2002.
- [13] <http://www.delsys.com>
- [14] N. Saito and R. R. Coifman, "Local discriminant bases and their applications," *J. Mathematical Imaging and Vision*, vol. 5, no. 4, pp. 337-358, 1995.
- [15] Simon Haykin, *Neural Networks: A Comprehensive Foundation*, Prentice-Hall, New Jersey, 1999.
- [16] T. Kohonen, "The self-organizing map," *Proc. IEEE*, vol. 78, no. 9, pp. 1464-1480, 1990
- [17] Stephane G. Mallat, "A theory for multiresolution signal decomposition: The wavelet representation," *IEEE Trans. Pattern Analysis and Machine Intelligence*, vol. 11, no. 7, pp. 674-693, July 1989.

저 자 소 개



추 준 욱(정회원)
 1998년 영남대학교 전기공학과
 학사 졸업.
 2000년 경북대학교 전자공학과
 석사 졸업.
 2002년 경북대학교 전자공학과
 박사 수료

2002년~현재 재활공학연구소 연구원
 <주관심분야 : 생체신호처리, 패턴인식, 학습제어>



문 인 혁(정회원)
 1992년 경상대학교 전자공학과
 학사 졸업.
 1994년 경상대학교 전자공학과
 석사 졸업.
 1999년 일본 Osaka 대학교 전자
 제어기계공학과 박사졸업

1999년~2000년 일본 하마마츠테크노폴리스
 추진기구 Post Doc 연구원
 2000년~2002년 연세대학교 의공학과 연구교수
 2002년~현재 재활공학연구소 전자제어팀
 책임연구원
 <주관심분야 : HCI, 바이오메카트로닉스, 이동로
 봇 및 재활복지로봇>