

의수제어를 위한 인체학습시스템에 관한 연구

장영건* · 홍승홍

=Abstract=

A Study on Human Training System for Prosthetic Arm Control

Young Gun Jang*, Hong Seung Hong

This study is concerned with a method which helps human to generate EMG signals accurately and consistently to make reliable design samples of function discriminator for prosthetic arm control.

We intend to ensure a signal accuracy and consistency by training human as a signal generation source. For the purposes, we construct a human training system using a digital computer, which generates visual graphes to compare real target motion trajectory with the desired one, to observe EMG signals and their features. To evaluate the effect which affects a feature variance and a feature separability between motion classes by the human training system, we select 4 features such as integral absolute value, zero crossing counts, AR coefficients and LPC cepstrum coefficients.

We perform a experiment four times during 2 months. The experimental results show that the human training system is effective for accurate and consistent EMG signal generation and reduction of a feature variance, but is not correlated for a feature separability. The cepstrum coefficient is the most preferable among the used features for reduction of variance, class separability and robustness to a time varying property of EMG signals.

Key words : Human trainer, EMG Signals

서 론

의수를 전기적으로 제어할 때 가장 중요하게 요구되는 것은 인간의 의사를 의수에 전달하는 방법이다. 인간의 의사를 의수에 전달하는 가장 일반적인 방식은 중간경로에 있는 팔을 제어하는 근육의 근전도를 해석하여 제어하는 방식이다. 이러한 방식은 인간의 운동에서 일어나는 근육의 생리활동을 이용하는 것으로써, 뇌에서 근육에 전달되는 명령을 실시간적으로 이용할 수 있는 장점이 있다.

근전도신호를 제어원으로 한 의수제어에 대한 연구는 크게 근전도신호처리와 제어의 영역으로 나누어진다. 신호처리분야에선 1) 아티팩트(artifact)를 줄이거나 신호대 잡

음을 높이는 방식에 관한 연구¹⁾, 2) 기능분리의 신뢰도 및 정도를 높이는 방식에 관한 연구²⁻⁴⁾ 3) 근전도신호의 실시간 처리에 관한 연구¹⁰⁾ 등이 있다. 제어분야에선 1) 근전도신호의 좌표화 2) 임피던스제어 3) 제어구조등이 있다.

이러한 연구들은 거의 모두가 근전도신호가 에르고딕하다는 가정을 전제로 한다. 그러나 이에 대한 검증 및 신호의 충실도에 대한 연구는 매우 부족한 실정이다. 근전도신호의 에르고딕성질에 관해서, 몇가지 응용연구^{9, 10)} 및 기초연구⁸⁾에서 시변시스템으로서의 경향성에 대해 언급하면서도, 이에 대한 보완 및 대응방안을 제시하진 못했다. 이 성질은 신호처리기의 적응성 및 유연성에 대한 요구의 정도를 결정하는 가장 중요한 요인이며, 제어의 정도(accu-

* 인하대학교 전자공학과

* Dept. of Electronics, Inha Univ.

통신저자: 장영건, (402-751) 인천시 남구 용현동 253, Tel. (032) 868-4691, Fax. (032) 868-3654

racy) 및 복잡성을 결정짓는 중요한 요소이다.

근전도신호를 이용하여 근육의 기능을 분리하는 방식으로서 통계적인 방식, 확률적인 방식, 신경회로망이나 퍼지 로직을 이용하는 방식 등 다양한 방법이 있다. 이러한 방식들의 공통점은 설계샘플을 이용한다는 점이고, 설계샘플의 신뢰성은 이 모든 방식의 결과의 신뢰성과 직결되는 측면이 있다. 설계샘플의 신뢰성은 신호발생의 정확도와 신호를 발생시키는 방식에 의해 결정된다. 근전도신호를 발생시키는 주체는 인간이므로, 신뢰성있는 신호발생을 위하여 인간의 학습이 필요하다. 이는 인간이 제어명령을 발생시키는 주체이며, 비교적 정확도 측면에서 기계에 떨어지나, 반복적 훈련에 의해 정확도가 향상된다는 근거에서 타당성을 갖는다. 그러나 기존의 연구에선 인간의 학습 방식에 대한 구체적이고, 체계적인 연구가 부족하였다.

기능분리의 효율을 위해 원신호가 압축된 형태의 특징 추출이 필요하며, 다양한 형태로 제시된 특징들 중에서 상대적으로 학습의 효율이 높은 특징의 선택이 필요하다. 이러한 특징의 선택은 클래스간 분리도 및 분산의 크기가 중요한 결정인자이다. 기존의 연구에선 주로 하나의 특징에 대한 효과적 차수의 결정^{11, 12)}에 대한 것만을 다루었고, 특성이 전혀 다른 특징들에 대한 비교는 발견되지 않고 있다.

본 논문에선 설계샘플의 신뢰성확보를 위하여, 컴퓨터를 이용하여 인간의 제어명령의 정확도와 분류공간으로 매핑하기 위한 특징들을 시각적으로 표시하며, 인간이 스스로 제어명령의 정확성 및 항시성을 어느 한계내에서 유지할 수 있게 훈련할 수 있는 시각채환을 이용한 페루프학습환경을 체계화한 인체학습기를 제안한다.

각 클래스별로 클래스간 분리도가 크며, 클래스내의 평균값에 대한 분산이 비교적 적은 특징을 선택하는 문제와 이 특징후보들의 분산과 분리도에 인체학습시스템이 어떤 영향을 미치는 지 평가할 필요가 있다. 이 특징선택은 클래스간 중첩을 최소화하고, 선택의 신뢰도를 높이는 데 중요한 역할을 담당한다. 이를 평가하기 위해 영교차수, 절대적분치, 자기회귀 모델의 계수 및 이 계수를 이용한 켈스트럼 계수를 특징후보로 하여, 이들의 분리도를 비교하였다. 분리도에 대한 공통적 기준을 적용하기 위해선 분류기에 대한 베이스 오차의 확률을 구하면 되지만, 공통적으로 오확률에 대한 폐형식(closed form)해를 얻을 수 없으므로, 근사적인 오확률의 상위 경계인 바타케리어 거리(Bhattacharyya distance)를 척도로서 선정한다.

인간의 학습

일반적으로 분류하고자 하는 운동이 세분화되고, 근육과 운동의 1:1 맵핑이 어려워지거나, 실험자의 움직임이 다른 운동과 중복될 경우, 각 운동들은 특징 벡터 공간내에서 서로 중복, 중첩되는 경우가 빈번하다. 실험자의 등속 운동이 보장되지 않는 경우에도 이러한 현상이 발생한다. 이러한 문제점들을 해결하기 위하여, 실험자의 시각적 채환을 이용한 페루프학습방법이 제안되었다.

즉, 학습기 화면에 실험자의 운동과 관련된 여러가지 요소들을 그래픽하게 표시함으로써, 실험자는 자신의 운동에 관한 정보를 실제적으로 보며, 스스로가 의도하던 운동에 접근해 나가는 방식을 취했다. 이에 관련된 요소로서는, 실험자의 어깨 2곳에서 획득한 신호의 원래 파형, 그 신호의 특징 벡터 분포, 실험자가 움직인 조이스틱의 위치 프로파일 및 속도성분 등이 있다. 이는 근육운동을 기계적 관점에서 보면, 방향, 속도 및 힘의 함수로 볼 수 있으며, 임의의 방향 및 속도에 대한 인간의 구현은 가우선분포를 갖는다고 가정할 수 있기 때문이다. 따라서 정확한 교시에 대한 충실도는, 조이스틱좌표계에서의 방향과 속도오차에 대한 다음의 식으로 표현된 기준에 따라 판단될 수 있다.

$$E_d = \frac{1}{N} \sqrt{\sum_{i=1}^N \left(X_d - \frac{JY_i - JY_{i-1}}{JX_i - JX_{i-1}} \right)^2} \quad (1)$$

E_d : 방향 오차, X_d : 원하는 방향, N : 조이스틱 샘플의 수
 i : 샘플의 순서, JX, JY : 조이스틱의 X, Y 좌표

$$E_s = \frac{1}{N} \sqrt{\sum_{i=1}^N \left(X_s - \sqrt{(JX_i - JX_{i-1})^2 + (JY_i - JY_{i-1})^2} \right)^2} \quad (2)$$

E_s : 속도 오차, X_s : 원하는 속도,
 N : 조이스틱 샘플의 수, i : 샘플의 순서

절단모사기를 사용하여 조이스틱을 원하는 방향으로 움직여, 조이스틱에서 검출되는 신호 $X_i, Y_i, X_{i-1}, Y_{i-1}$ 로서 E_d, E_s 를 구해 E_d, E_s 가 줄어드는 정도를 관찰함으로써, 훈련에 따른 교시의 충실도의 증가를 판단할 수 있으며, 충실도의 대략적인 한계점으로서 방향 및 속도오차의 임계치들 ϵ_d, ϵ_s 를 규정할 수 있다. ϵ_d, ϵ_s 는 인간의 훈련에 의해 결정되며, 훈련량이 증가함에 따라 일정값으로 수렴한다. 또한 특징 추출 및 선택을 위한 설계샘플의 선정 및 훈련에, 이

입계치들을 식 (3)과 같은 절차에 따라 적용하여, 기계에 의한 객관적 판정기준을 훈련자에게 제시할 수 있게 하였다.

If $E_d < \epsilon_d$ then (3)

If $E_s < \epsilon_s$ then

$X \subseteq X_{DC}$;

사용자에게 현 입력이 훈련이 잘된 샘플이라는 것을 표시;

Else

사용자에게 속도차가 크다는 것을 표시;

Else

사용자에게 방향교시가 정확치 않다는 것을 표시;

X : 관찰된 한 플레임의 입력 시퀀스

X_{DC} : 설계샘플의 후보그룹집합

특징 추출 및 선택

패턴인식에서, 특징 추출 및 선택의 주제는 패턴표현의 차원을 줄이기 위한 수학적 틀에 관련된 것이다. 분류기의 성능적 관점에서 보면, 차원의 축소는 오인식율을 줄이는데도 기여할 수 있다. 즉 불필요한 특징의 추가는 인식의 효율을 저하시키며, 인식율을 저하시키는 데도 기여하기 때문이다. 근전도신호를 인식하는데 있어, 특징 후보로서 절대적분치, 영교차수, 신호의 AR (auto regressive)계수 및 AR계수의 캐스트럼계수를 선정하여, 분리도 및 견고성을 시험한다. 또한 인간의 학습에 의해 이러한 특징들이 어떠한 영향을 받는지를 분리도 및 분산의 관점에서 고찰해 보고자 한다. 각 특징에 대한 정의 및 추출방법에 대해 간략히 기술한다.

1. 영교차수 (zero crossing number)

영교차수 X_z 는 신호의 영교차율을 나타내는 특징으로서, 일정시간 동안에 신호가 0 V를 통과한 횟수이며, 식 (4)와 같이 정의된다.

$$X_z = \sum_{i=0}^{N-1} q[X(i\Delta t)X((i+1)\Delta t)] \quad (4)$$

X : 관찰된 근전도신호, Δt : 샘플링시간 간격,

N : 샘플의 수, i : 샘플의 순서

$q(X) = 1$; if $X < 0$

$q(X) = 0$; o.w

2. 절대적분치 (integral of absolute value)

절대적분치는 신호의 절대적분치를 나타내는 특징으로서, 일정시간 동안의 신호의 절대값을 적분한 것이며, 식 (5)로 정의할 수 있다.

$$X_a = \sum_{i=0}^{N-1} |X(i\Delta t)| \quad (5)$$

X : 관찰된 근전도신호, Δt : 샘플링시간 간격,

N : 샘플의 수, i : 샘플의 순서

3. 자기회기모델계수 (auto regressive model coefficients)

자기회기모델은 Parzen⁶⁾과 Burg⁷⁾에 의해 각각 제안되었으며, Burg는 최대 엔트로피 법칙에 의존하여 발표하였고, Parzen은 모든 정상 시계열은 자기회기모델로 근사화시킬 수 있다는 점에 의존하여 이 방법을 제안하였다. EMG 신호를 AR로서 모델링할 때, EMG 신호의 각 샘플 $X(n)$ 은 다음과 같이 과거의 샘플 $x(n-k)$ 에 독립적인 오차 $e(n)$ 을 합한 선형 조합으로 표시된다.

$$X(n) = -\sum_{k=1}^p a_k X(n-k) + e(n) \quad (6)$$

$X(n)$: AR 모델로 된 EMG 신호의 샘플

a_k : AR 계수, $e(n)$: 오차, p : 모델의 차수

AR모델의 선형 예측계수를 추정에는 자기 상관법을 이용한다. 이 모델의 스펙트랄 밀도함수는 다음과 같다.

$$S(\lambda) = \frac{\sigma^2}{2\pi} \frac{1}{|\sum_{k=0}^p a_k e^{-i\lambda k}|^2}, a_0 = -1 \quad (7)$$

시계열의 자기공분산 함수를 알고 있을 때, 식 (6)은 다음과 같은 울-워커의 방정식을 만족한다.

$$\sigma(l) = a_1 \sigma(l-1) + \dots + a_p \sigma(l-p), l > 0 \quad (8)$$

$$\sigma^2 = \sigma(0) - a_1 \sigma(1) - \dots - a_p \sigma(p) \quad (9)$$

AR계수 $a_{p,1}, \dots, a_{p,p}$ 와 σ_p^2 를 울-워커방정식에 대입하여 정의하면

$$\sigma(l) = \sum_{j=1}^p a_{p,j} \sigma(l-j), l=1, \dots, p \quad (10)$$

$$\sigma_j^2 = \sigma(0) - \sum_{j=1}^p a_{k,j} \sigma(j) \quad (11)$$

$$c_k = -a_n - \frac{1}{n} \sum_{k=1}^{n-1} k c_k a^{n-k} \quad n > 0 \quad (15)$$

$$a_0 = 1, a_k = 0; k > n-1$$

가 되며, 정상성을 갖는 임의의 시계열에 대한 식 (10)을 만족하는 $a_{k,j}$ 를 이 시계열의 p차 부분상관계수라 하고 $\{a_{k,j} | k=0, 1, \dots\}$ 를 부분자기상관함수라 한다. 식 (10)의 해를 구하기 위해 Levison과 Durbin의 알고리즘을 사용하였다.

가 된다. 따라서 cepstrum 계수는 상기의 AR계수를 식 (15)에 순환적으로 대입하여 구할 수 있다.

4. LPC cepstrum 계수(LPC cepstrum coefficients)

5. 분리도

AR계수를 통하여 팔의 동작 기능을 분리하려면 많은 통계적인 작업이 필요하며, 동적 변화가 심한 신호에 적용하는 데에는 인식률이 cepstrum 계수를 이용하는 것보다 떨어진다. 이는 AR계수가 근전도 신호에 대한 에너지 스펙트럼 양상을 압축하고 있는데 반해, cepstrum 계수는 AR계수에 의한 스펙트럼정보와 스펙트럼의 퍼진 정도에 대한 정보를 포함하는 2차 통계특성을 갖으므로, AR계수보다 인식률에 있어 효과적이라 할 수 있다. LPC cepstrum 계수에 의한 거리 계산은 EMG신호의 대수 스펙트럼 상에서의 이 거리 계산과 같은 의미를 주며, 실제 영상 및 음성인식에 있어서 다른 특징 매개 변수들보다 인식률이 높다고 보고되었다.

정규분포에 대해 바타케리아거리의 클래스의 분리도를 평가하는 가장 편리한 척도이다. 바타케리아거리는 식 (16)과 같이 표현된다.

$$\mu(1/2) = \frac{1}{8} (M_2 - M_1)^2 \left\{ \frac{\sum_1 + \sum_2}{2} \right\}^{-1} (M_2 - M_1) + \frac{1}{2} \ln \frac{|\sum_1 + \sum_2|}{\sqrt{|\sum_1| |\sum_2|}} \quad (16)$$

M_1, M_2 : 클래스 1, 2의 평균,

\sum_1, \sum_2 : 클래스 1, 2의 공분산

$||$: 행렬식

식 (6)에서 오차 신호와 EMG신호의 출력 시계열 전달 함수는

이 식의 첫번째 항은 평균의 차에 의한 분리거리이고, 두번째 항은 공분산에 의한 분리거리이다. 이 두 가지 항 중 어떤 항이 전체거리를 좌우하는지를 아는 것은 주어진 분포에 대해 효과적인 분류기를 선택하는데 큰 도움을 준다.

$$H(z) = \frac{Y(z)}{E(z)} = \frac{1}{A(z)} \quad (12)$$

$$A(z) = 1 + \sum_{k=1}^p a_k z^{-k} \quad (13)$$

의 식으로 표현되며, AR모델의 역필터이다. 이때 $\ln|A(z^{-1})|$ 는 해석적이며, 모든 근은 단위원 내에 존재한다. 식 (13)을 로랑 전개(Laurent expansion)로 유도하여 테일러 급수로 전개하면 다음과 같다.

인체학습기

$$\ln\left|\frac{\sigma}{A(z)}\right| = \ln(\sigma) - \ln|A(z)| \quad (14)$$

$$= \ln(\sigma) + \sum_{k=1}^{\infty} c_k z^{-k}$$

이 식에서 σ 는 신호의 스펙트럼을 전극(all pole)모델화한 함수의 나머지에너지의 최소치이며, c_k 를 cepstrum 계수라 한다.

전체 S/W는 데이터 표시부와 데이터처리부로 구성된다. 데이터표시부는 취득된 신호의 파형을 보여주는 원신호표시부, 제어명령발생을 감시하기 위한 조이스틱표시부, 취득된 신호로부터 추출된 특징들을 보여주는 특징벡터표시부로 구성된다. 데이터처리부는 신호를 획득하여, A/D 변환한 후, 메모리에 저장하는 데이터획득모드, 획득된 데이터로부터 영교차수, 절대적분치, AR계수 및 AR계수로부터 얻어진 cepstrum 계수 등의 특징벡터를 추출하며, 특징벡터들의 통계적 성질들을 산출하는 데이터변환모드 및 초기 훈련자를 위해 데이터의 저장없이, 데이터 획득, 변환 및 표시까지 허용하는 초기훈련모드로 구성되었다.

식 (14)의 양변을 z^k 에 대하여 미분하고, z^k 을 곱하여 정리하면

1. 데이터 표시부

원 신호 표시부

그림 2의 훈련기 전체 화면 구성도에서, 우측 하단에 나타나 있는 윈도우가 원 신호 표시부로서, 어깨부분의 두 곳에서 추출한 근전도 신호를 샘플링하여 표시하도록 하였다.

특징벡터 분포 표시부

그림 2의 훈련기 전체 화면 구성도의 상위 부분에 나타나 있는 두개의 윈도우가 특징벡터 표시부로서, 추출된 신호의 절대적분치와 영교차수를 각각의 윈도우에 각 채널별로 표시하도록 하였다.

조이스틱 표시부

그림 2의 훈련기 전체 화면 구성도의 좌측 하단에 나타나 있는 윈도우가 조이스틱 표시부로서, 실험자가 운동에 따라 조이스틱을 움직일때의 운동이 어느 정도의 정확성을 가지고 있는지 표시하여, 실험자가 자신의 운동을 눈으로 확인하며 조절할 수 있는 시각채환을 적용시켰다. 일반적인 환경에서는 실험자가 자신의 운동에 대한 정확성과 신뢰도를 확보할 수가 없으므로, 이를 보완하기 위하여 실험자가 조작하는 조이스틱의 궤적을 구성된 화면의 왼쪽 하단에 표시할 수 있도록 하였다.

또한 실험자의 운동속도를 일정하게 유지하기 위해, 조이스틱의 궤적을 표시할 때 이의 속도 성분을 느낌, 보통, 빠름의 3단계로 구분하고, 각 단계별로 다른 색상을 사용하여 궤적을 나타내도록 하였다. 따라서 실험자의 동작 반복시 최대한의 동일성을 보장하도록 하였다.

2. 데이터 처리부

초기훈련모드

초기훈련모드는 훈련자가 실제데이터를 획득하기 전에, 스스로를 훈련기에 적응시키기 위한 단계로서, 모든 구성 및 기능은 나머지 모드와 동일하나 데이터를 저장하지 않는다는 점에서 구별되게 된다. 초기훈련모드에서, 훈련자는 제시된 움직임들을 동일하게 반복할 수 있도록 반복 훈련을 계속하게 되며, 일정한 정도로 동일 동작을 반복할 수 있으면 실험자는 초기훈련모드에서 타 모드로 넘어가게 된다.

데이터획득 및 변환모드

데이터획득 및 변환모드는 실제 데이터를 저장하고 처리하기 위한 부분으로서, 다음의 단계에 걸쳐 데이터처리가 이루어지게 된다. 훈련자가 조이스틱을 각 운동 방향으로 움직이고, 조이스틱의 출력값이 운동이 없을 때의 3~4




그림 1. 학습훈련기의 전체 S/W 구성도
Fig. 1. Total S/W configuration of human trainer.

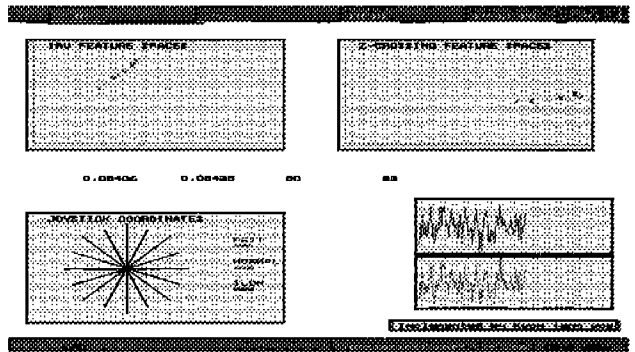


그림 2. 인체학습기의 전체 화면 구성도
Fig. 2. Total display configuration of human trainer.

%를 벗어나게 되면, 데이터 획득을 시작하게 된다. 샘플링된 신호는 화면의 조이스틱 좌표계와 원 근전도 신호를 표시하기 위한 부분에 사용된다. 계산된 절대적분치, 영교차수는 화면에 채널별로 그 분포가 나타나도록 하였다. 특징 분포도에서 x축은 채널 1을, y축은 채널 2를 나타낸다. 데이터획득은 각각의 운동종류에 따라 반복하여 무한루프를 돌도록 되어 있다. 각 운동별로 데이터처리가 시작되면 이 운동은 사용자의 중지 명령이 나올때까지 반복된다. 수집된 EMG 신호파형을 화면에 표시하고 이 신호에 대한 IAV와 영교차수를 화면에 표시하게 된다. 실험자는 동작에 대한 조이스틱 궤적, 속도성분, IAV, 영교차수분포 등을 복합적으로 이용하여 그 동작의 저장여부를 결정하게 된다. 실험자가 데이터의 저장을 승인하면 획득된 두 채널 신호와 조이스틱 출력치가 지정된 화일명. org의 화일 형태로 저장되게 된다. 그리고 이 신호들에서 구해진 영교차수, IAV, 조이스틱값과 조이스틱의 평균 속도비가 지정된 화일명. lan의 화일에 저장된다. 실제적인 EMG 신호 분류를 위한 특징벡터로서는 AR계수로부터 유도된 LPC 캡스트럼계수를 이용하였다. 캡스트럼계수는 4차항까지의 계




그림 3. 시험시스템 구성도
Fig. 3. Test system configuration.




그림 4. 조이스틱 좌표계의 클래스 설정
Fig. 4. Class definition in the joystick coordinate.




그림 6. 인체학습기를 사용하지 않은 훈련종료시의 조이스틱 운동궤적
Fig. 6. Motion trajectory of joystick without human trainer when learning has completed.




그림 7. 인체학습기를 사용한 훈련초기시의 조이스틱 운동궤적
Fig. 7. Motion trajectory of joystick with human trainer when the learning has begun.




그림 5. 인체학습기를 사용하지 않은 초기시의 조이스틱의 운동궤적
Fig. 5. Motion trajectory of joystick without human trainer when learning has begun.




그림 8. 인체학습기를 사용한 훈련종료시의 조이스틱 운동궤적
Fig. 8. Motion trajectory of joystick with human trainer when learning has completed.

수가 사용되어졌으나, 80ms동안의 신호에 대해 40ms의 해밍 윈도우를 씌워서 중첩을 20ms동안 시켰으며, 결과적으로는 80ms동안의 신호에 대해서는 각 채널당 12개 즉, 24개의 웨스트럼 특징벡터가 얻어지게 된다. 이들 특징벡터들은 분류기의 입력 벡터로 다시 구성되게 된다.

실험 및 고찰

1. 신호의 취득 및 특징점 추출

제한한 시스템의 타당성검증을 위해, 모사장애자가 2차

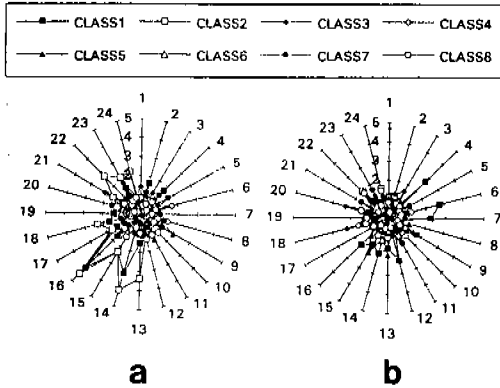


그림 9. AR계수의 클래스별 분산치
(a) 인체학습기 미사용시 (b) 인체학습기 사용시
Fig. 9. Standard deviations of AR coeff. for each class.
(a) without human trainer (b) with human trainer

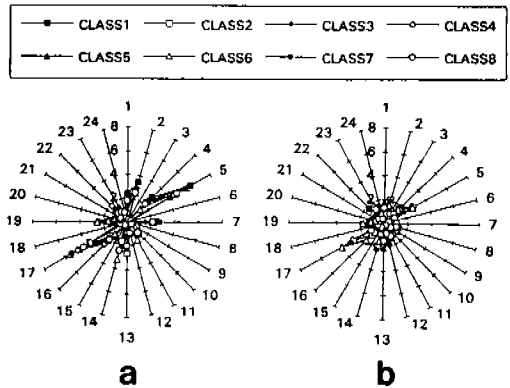


그림 10. LPC 켈스트럼 계수의 클래스별 분산치
(a) 인체학습기 미사용시 (b) 인체학습기 사용시
Fig. 10. Standard deviations of LPC cepstrum coeff. for each class.
(a) without human trainer (b) with human trainer

원 평면으로 생각할 수 있는 조이스틱평면을 조종공간으로 운전을 행하고, 운전을 행하는 팔로부터 근전도신호를 획득하여, 시험을 행하였다. 시험시스템은 그림 3과 같이 구성하였다. 실험대상자는 실제의 팔장애자대신에 팔의 불필요한 운동을 못하게 고안된 절단모사기를 사용한 정상인(simulated amputee)을 선택하여 실험하였다. 증폭기는 Nihon Kohden사의 생체증폭기인 AB-621G를 사용하였으며, 시간상수는 피부와 전극사이에 움직임으로 유기되는 포텐셜 및 극포텐셜 등이 원인인 저주파잡음제거등을 고려하여 0.01초로 하였고, 감도는 0.2mV/Dev를 사용하여 A/D변환기의 입력범위를 충분히 사용할 수 있게 하였다. 획득하는 정보의 한 프레임길이는 80ms이고 샘플링 주파수는 10khz로 하였다.

전극은 일회용 전극을 사용하였으며 어깨의 삼각근의 중심부와 끝부분에 각기 2개씩의 전극(쌍극법)을, 어깨뼈 부분에 접지전극을 부착하여 시험하였다. 모사장애자가 조이스틱을 움직이기 시작하면 그것을 동기신호로 EMG 신호의 획득이 시작되며 240ms동안 지속되고 그 신호를 저장한다. 근전도신호는 시간의 흐름에 따른 변화를 시험하고, 학습에 대한 효과를 검증하기 위해 2개월에 걸쳐 4회 취득하였다. 그 중 2회는 학습기를 사용하지 않고, 임의적 훈련에 의해서 신호를 취득하였으며, 2회는 인체학습기를 사용하여 신호를 취득하였다. 훈련한 방향은 그림 4에 나타난 조이스틱좌표계의 클래스보다 2배가 많은 16개방향에 대해 훈련하였다. 1회당 720개의 샘플들을 채취하였다. 각각의 운동방향에 대해 15회의 반복실험을 하였으며,

각 방향마다 획득된 데이터 및 학습조건을 인체학습기의 화면을 통해 검증하여 저장여부를 결정한다. 각각의 운동방향에 대한 일회의 신호획득마다 3개 프레임의 데이터가 획득되어, 15회 전부를 성공적으로 마치면 45셋(sets)씩의 특징벡터군이 획득된다. 근전도신호의 특징후보로서 절대적분치, 영교차수, AR계수 및 AR계수의 켈스트럼계수를 선정하였다. AR모델의 차수는 4차로 선정하였다. 경험에 의해 훈련한, 조이스틱좌표상의 평균적 이동궤적에 대한 학습초기와 완료시점의 모습을 각각 그림 5와 6에 표시하였다. 이들 그림을 보면 후방에 관련된 운동궤적이 특히 부정확하며, 훈련에 의해 개선되는 효과가 별로 나타나지 않는다. 인체학습기를 통해 훈련한, 조이스틱좌표상의 평균적 이동궤적의 훈련초기와 완료된 시점의 모습을 각각 그림 7과 8에 표시하였다. 그림에서 보는 바와 같이, 인체학습기에 의해 훈련한 궤적이 그림 5, 6에 비해 원하는 궤적에 훨씬 가깝게 접근하고 있음을 확인할 수 있고, 실제식 (1)에서 정의된 방향오차가 그림 5의 데이터에 비해 38% 정도 줄어들었다. 특히 초기방향을 제외한 부분에서 신뢰성 있는 방향벡터가 생성되고 있다. 이 궤적은 실제 조이스틱의 값을 읽어서 표현하였으며, 사용된 조이스틱의 사각방향의 초기부분이 기계적 구조에 의해 간섭을 받으므로 초기데이터는 제외하는 것이 타당하다. 따라서 인체학습기가 인간의 정확한 제어명령발생에 효과가 있음을 알 수 있다.

특징들의 분산에 미치는 인체학습기의 영향을 검증하기 위해, AR계수와 켈스트럼계수에 대해 인체학습기의 사용

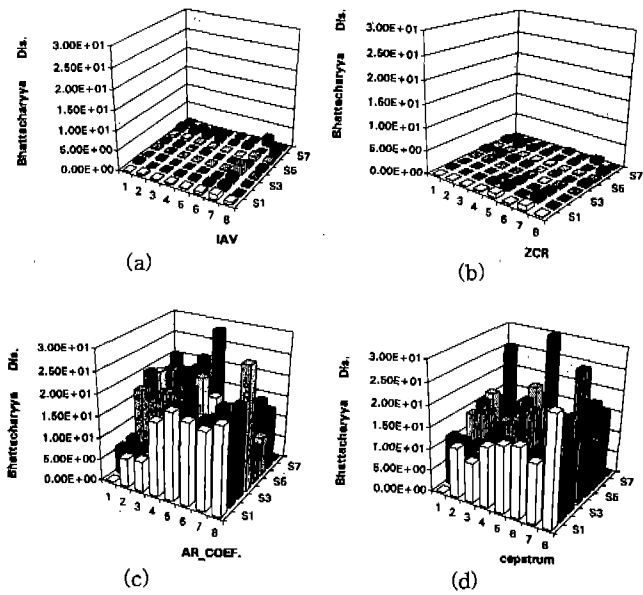


그림 11. 각 특징별 클래스간 바타케리아거리
 (a) 절대적분치 (b) 영교차수 (c) AR계수 (d) LPC 켈스트럼계수
 Fig. 11. Bhattacharyya distance between classes for each feature.
 (a) IAV (b) ZCR (c) AR coef (d) LPC cepstrum coef.

여부에 따른 각 클래스에 대한 분산치를 각각 그림 9와 10에 표시하였다. 그림 9와 10에서 원주위에 표시한 숫자는 두 채널의 3개의 부플레임의 AR계수와 켈스트럼계수에 대한 순서를 표시한 것이다. AR계수와 켈스트럼계수 모두 인체학습기를 적용한 결과 반이하로 분산이 줄어들어, 분산의 감소에 크게 기여하는 것으로 판단되고, 켈스트럼계수의 분산이 더 큰 폭으로 줄어들었다. 더우기 켈스트럼계수의 경우, 형태적인 관점에서 비교적 인체학습기를 사용하지 않았을 때의 형태를 유지하면서 줄어드는 경향을 보였다. 이러한 경향은 비교적 켈스트럼계수가 시변적 성질이 AR계수에 비해 적음을 알 수 있다.

2. 특징점 선택

특징점후보로서 추출된 절대적분치 (IAV), 영교차수, 4차 AR계수 및 AR계수의 켈스트럼 계수에 대하여, 인체학습기를 사용한 경우와 사용하지 않은 경우의 바타케리아거리를 비교하였다. 각 특징별로 인체학습기를 사용하여 훈련이 끝난 클래스간 바타케리아거리를 그림 11에 나타내었다. 그림의 밑면 좌측 및 우측의 숫자는 클래스를 나타낸다. 그림에서 보는 바와 같이 절대적분치와 영교차수

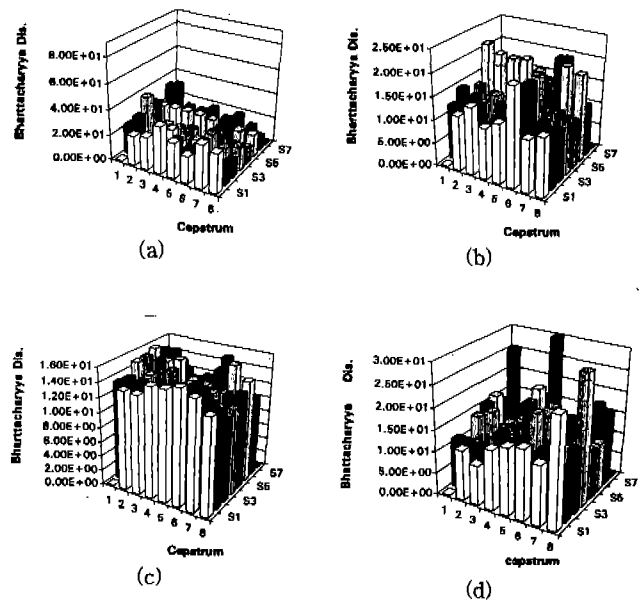


그림 12. 켈스트럼계수의 실험횟수별 바타케리아거리.
 (a) 1회 실험 (b) 2회 실험 (c) 3회 실험 (d) 4회 실험
 Fig. 12. Bhattacharyya distance of LPC cepstrum coef. of each experiment.
 (a) 1st exper. (b) 2nd exper. (c) 3rd exper. (d) 4th exper.

에 비해 AR계수와 켈스트럼계수의 바타케리아거리가 월등히 크며, 따라서 분리도가 큼을 알 수 있다. 켈스트럼계수가 클래스간 거리가 짧은 부분에서 AR계수에 비해 비교적 바타케리아거리가 큼을 알 수 있다. 이러한 현상은 분류의 분류율 측면에서 오분류율을 줄이는 결정적 역할을 한다. 2달 동안 4회에 걸쳐 취득한 켈스트럼계수의 클래스간 바타케리아거리를 실험횟수별로 그림 12에 표시하였다. 특징별로 인체학습기를 사용한 것과 사용하지 않은 것을 비교한 결과 두 경우사이의 분명한 차이가 나타나지 않아, 상관관계가 없는 것으로 보인다. 이는 분산이 크게 줄어드는 결과로 보아, 주로 평균값의 변화에 기인한 것으로 본다. 실험결과마다 큰 차이를 보이고 있어, 경향성을 찾기가 힘들다. 다만 켈스트럼계수의 경우 비교적 가장 실험에 따른 차이가 적었다. 따라서 근전도신호의 시변적 경향에 대해 켈스트럼계수가 가장 큰 견고성을 나타내고 있다고 판단할 수 있다. 따라서 근전도신호에 있어 언급한 절대적분치, 영교차수, AR계수 및 켈스트럼계수중 켈스트럼계수를 특징으로 선택하는 것이 분산, 분리도 및 시변적 성질에 대한 견고성 측면에서 가장 좋다는 결론을 얻을 수 있다.

결 론

의수제어를 위한 제어원으로서 근전도신호를 사용하기 위해 신호발생원인 인간의 신호발생의 정확도 및 항시성 확보를 위한 학습시스템을 제안하였다. 이 시스템은 컴퓨터를 사용해 학습에 필요한 요소를 단계적으로 접근할 수 있도록 하며, 인간의 제어명령의 정확도와 분류공간으로 매핑하기 위한 특징들을 시각적으로 표시하며, 인간이 스스로 제어명령의 정확성 및 항시성을 어느 한계내에서 유지할 수 있게 훈련할 수 있는 시각교환을 이용한 페루프학습환경을 체계적으로 제공한다. 이 시스템은 특히 제어신호발생원인 인간의 기계에 대한 학습방법을 구체화하고, 컴퓨터를 이용하여 객관화시켰으며, 신호처리의 설계데이터의 신뢰도 및 신호처리의 가정에 대한 정량적 데이터를 제시할 수 있다. 인체학습기를 사용하여 훈련한 결과, 인간의 부정확한 운동에 의해 발생하는, 원하는 운동계획과의 방향오차가 38% 정도 줄었으며, 특징인 절대적분치, 영교차수는 표준편차가 평균 40.5%, AR계수와 캡스트럼계수의 경우 각각 평균 52%와 63% 정도 감소되는 효과가 있었다. 따라서 인간의 제어명령의 정확도를 높여주며, 실제샘플의 신뢰도를 제고시킨다. 또한 특징으로서 LPC 캡스트럼계수가 비교한 특징중에서 분리도가 비교적 크며, 근전도신호의 시변적 성질에 가장 견고함을 알 수 있었다.

이 연구는 근전도신호를 제어원이나 신호원으로 사용하는 응용분야에 있어 실제샘플의 신뢰도를 체계적으로 평가하거나 증가시키는데 도움을 줄 수 있을 것으로 기대되며, 근전도신호의 시변적 성질에 대응하기 위한 기초데이터를 제공하였다.

참 고 문 헌

1. Y. G. Jang & S. H. Hong et al, "EMG Pattern Analysis for

Prosthesis Arm Control", RESNA '94 Conference, Neshville, Tennessee, 1994. 6

2. Y. G. Jang & S. H. Hong et al, "Probabilistic Neural Pattern Classifier and Muscle Force Estimation", Proceedings of the 15th Annual Int. Conference of the IEEE EMBS, pp 1045-1046, 1993. 10

3. Y. G. Jang & S. H. Hong, "A Study on the Fuzzy Controller for Prosthesis Arm Control using EMG Signals", Proceedings JTC-CSCC '94, pp 260-263, 1994. 7

4. G. 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

5. Edward A. Clancy and Neville Hogan, "Single Site Electromyograph Amplitude Estimation", IEEE Trans on BME, Vol 41, No 2, pp 168-180, Feb. 1994

6. Burg, J. P., "Maximum Entropy Spectral Analysis", Proceedings of the 37th Meeting of the Society of Exploration Geophysics 1967, Reprinted in Modern Spectral Analysis, D. G. Childers(Eds), 1978, IEEE Press, New York, pp 34-41

7. Parzen, E., "On Consistent Estimates of the Spectrum of a Stationary Time Series", Ann. Math. Statist., pp 329-348

8. Carlo J. De Luca, "Physiology and Mathematics of Myoelectric Signals", IEEE Trans on BME, Vol 26, No. 6, pp 313-325, June 1979

9. 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

10. D. Graupe et al, "Functional Separation of EMG signal via ARMA identification methods for prosthesis control purposes", IEEE Trans on SMC, vol 5, No 2, pp 252-259, March 1975

11. 박상희 등, "LPC 캡스트럼 계수를 이용한 EMG신호의 기능인식에 관한 연구", 대한전자 공학회 논문지, 제27권, 제2호, pp126-133, 2. 1990

12. Gisela Heffner et al, "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