

# 비선형매핑 기반 뇌-기계 인터페이스를 위한 신경신호 spike train 디코딩 방법

論 文

54D-7-9

## Neuronal Spike Train Decoding Methods for the Brain-Machine Interface Using Nonlinear Mapping

金 璞 焕<sup>†</sup> · 金 聖 信<sup>\*</sup> · 金 成 俊<sup>\*\*</sup>

(Kyung Hwan Kim · Sung Shin Kim · Sung June Kim)

**Abstract** – Brain-machine interface (BMI) based on neuronal spike trains is regarded as one of the most promising means to restore basic body functions of severely paralyzed patients. The spike train decoding algorithm, which extracts underlying information of neuronal signals, is essential for the BMI. Previous studies report that a linear filter is effective for this purpose and there is no noteworthy gain from the use of nonlinear mapping algorithms, in spite of the fact that neuronal encoding process is obviously nonlinear. We designed several decoding algorithms based on the linear filter, and two nonlinear mapping algorithms using multilayer perceptron (MLP) and support vector machine regression (SVR), and show that the nonlinear algorithms are superior in general. The MLP often showed unsatisfactory performance especially when it is carelessly trained. The nonlinear SVR showed the highest performance. This may be due to the superiority of the SVR in training and generalization. The advantage of using nonlinear algorithms were more profound for the cases when there are false-positive/negative errors in spike trains.

**Key Words** : Brain-Machine Interface (BMI), Neural Signal, Spike Train Decoding, Support Vector Machine (SVM), Linear Filter

### 1. 서 론

뇌-기계 인터페이스 (brain-machine interface, BMI)는 인간의 중추신경계와, 로봇 팔 및 컴퓨터와 같은 외부장치 간의 직접적인 통신을 가능하게 하여 중증마비환자들의 기본적 의사소통능력을 복원하기 위한 기술이다. 두피에서 측정한 뇌전도 (electroencephalogram, EEG)에 기반한 BMI 기술이 활발하게 연구되고 있으나 [1], 시간적, 공간적 해상도의 제한으로 인하여 근본적 한계를 갖는 것으로 판단된다. 신경과학의 발달과 미세전극제작기술, 집적회로기술, 신호처리 기술 등의 발전으로 인하여 최근에는 매우 많은 수의 단일뉴런들의 전기적 활동을 직접적으로 측정하는 것이 가능해졌으며 이에 따라 다수의 단일뉴런들로부터의 활동전위 (즉, spike train)에 기반한 BMI의 구현이 가시화되고 있다. 이와 관련된 대표적인 연구로는 원숭이의 대뇌 일차운동영역 (primary motor cortex, MI)이나 운동준비영역 (premotor area) 등 움직임을 관찰하는 영역에 삽입된 미세전극으로부터 수십~수백 개의 뉴런으로부터의 신경신호를 기록하여 spike train을 추출하고 이로부터 팔의 움직임 궤적을 복원함으로써 실제의 원숭이의 팔 움직임과 동일한 로봇 팔 혹은

커서의 움직임을 만들어내는 연구를 들 수 있다 [2-5]. 이러한 BMI의 보다 성공적인 구현을 위해서는 관련된 기초신경과학적 연구와 함께, 장기적으로 생체적 합성을 보장할 수 있는 미세전극 및 체내 삽입 가능한 극소형시스템 제작기술이 요구된다 [6]. 또 잡음 및 변동요인이 많은 신경신호로부터 안정적으로 spike train을 추출하는 spike sorting 알고리즘, spike train으로부터 관련된 신경계정보를 추출하는 디코딩 알고리즘 등의 신호처리 기술의 개발이 필요하다 [7,8].

이중 디코딩알고리즘은 출력으로 BMI에서 필요로 하는 정보를 제공하므로 전체시스템의 성능을 좌우할 수 있는 중요한 부분이다. 관련된 대표적 연구그룹들의 결과에서는 선형필터에 의한 spike train의 디코딩에 의해 비교적 성공적으로 신경계정보를 추출할 수 있으며 신경회로망 등의 비선형매핑을 이용한 방법을 사용하는 경우의 장점이 그리 크지 않다고 보고되고 있다 [7,8]. 이러한 결과에는 별다른 부연설명이 제공되지 않고 있으며 신경계의 정보 인코딩 과정이 비선형적이라는 사실을 감안하면 비선형매핑에 의해 더 나은 성능을 얻을 수 있는 가능성이 있는 것으로 판단된다. 본 논문에서는 비선형매핑에 기반한 디코딩알고리즘의 우수성 여부를 확인하기 위하여 비선형매핑 및 선형필터에 기반한 디코딩알고리즘을 개발하고 팔 움직임 및 원숭이의 운동관련 대뇌영역으로부터의 신경신호 측정 실험에 기반한 spike train 모델에 기반하여 이들의 성능평가를 수행하였다.

우리는 관련연구들에서 사용된 비선형 디코딩알고리즘들이 주로 대표적인 신경회로망인 다층퍼셉트론 (multilayer perceptron, MLP)를 활용한 것이라는 것에 주목하였다. 오류역전파에 기반한 MLP의 학습은 많은 경우 최적의 일반화

† 교신저자, 正 會 員 : 延世大 醫工學部 助教授 · 工學博士  
E-mail : khkim@dragon.yonsei.ac.kr

\* 學生會員 : 서울大 電氣工學部 碩士課程

\*\* 正 會 員 : 서울大 電氣工學部 教授 · 工學博士

接受日字 : 2005年 4月 11日

最終完了 : 2005年 6月 15日

성능을 갖도록 학습시키는 것을 어렵게 하는 경우가 많은데, BMI 관련 선행연구들에서는 최적의 MLP 학습을 위해 어떤 노력을 기울였는지에 대한 언급이 없다. 본 논문에서는 MLP 학습의 최적화를 위한 방법인 early stopping을 도입 하였을 경우의 성능개선 정도를 관찰하였다. 또 우수한 일 반화성을 제공하며 최적의 학습이 용이한 것으로 알려진 support vector machine regression (SVR)을 이용한 비선형 디코딩알고리즘을 개발하였다. 선형필터, MLP, SVR에 기반 한 3가지 디코딩 방법들의 비교를 통하여 비선형방법들의 우수성을 확인하였으며 특히 실제 상황에서 중요한 spike train의 오류 상황 하에서 이와 같은 성능차이가 더 현저하게 나타난다는 사실을 보였다. 여러 가지 조건을 변화시켜 가면서 성능평가를 수행한 결과 거의 모든 경우에서 SVR 방법이 가장 우수하였으며 MLP를 이용하는 경우 early stopping의 도입에 의해 성능이 현저히 개선된다는 사실을 확인하였다. 이러한 사실은 과거의 결과들이 비선형매핑의 상대적인 우수성을 충분히 활용하지 못하였기 때문이라는 사실을 보여주고 있으며 특히 SVR에 기반한 디코딩알고리즘을 이용하면 실제 상황에서의 BMI의 특성을 크게 개선할 수 있는 가능성을 제시한다.

## 2. 방법

그림 1은 BMI 및 디코딩알고리즘의 구조를 보여주고 있다. 미세전극에 의해 세포의 방법으로 측정되는 신경신호로부터 활동전위 파형, 즉 spike들이 검출되고 이들은 각각의 단일뉴런들로부터의 신호로 분류되어 spike train들을 구성하게 된다. 디코딩알고리즘은 여러 단일뉴런들로부터의 spike train을 입력으로 받아 시변발화율을 계산한 다음 time-delay들 및 입-출력 매핑 알고리즘에 의하여 신경신호에 담겨 있는 신경계 정보를 추출하게 된다. 이 경우 추출되는 정보는 팔의 움직임 궤적에 해당한다. 본 논문의 시스템의 경우 입-출력 매핑 알고리즘은 선형회귀, MLP, SVR 중 어느 하나가 된다.

선형회귀가 사용되는 경우 디코딩알고리즘은 선형필터에 해당하며 출력  $\hat{v}(i)$  (즉,  $i$ 번째 time bin에서의 팔의 궤적의 예측치)는 다음과 같이 표현된다.

$$\hat{v}(i) = \sum_{p=1}^N \sum_{j=0}^{M-1} r_p(i-j) f_p(j) \quad (1)$$

여기서  $f_p(j)$ 는  $p$ 번째 뉴런이 입력되는 필터의  $j$ 번째 계수,  $r_p(i)$ 는  $p$ 번째 뉴런의 시변발화율이다. Time bin의 길이는 50 ms이다.  $M$ 과  $N$ 은 각각 필터의 텁수, 즉 그림 1 (b)에 서의 각 채널 당 time-delay element들의 개수와 단일뉴런의 총 수에 해당된다. 실제로 디코딩되는 정보는 운동의 변위 혹은 속도에 해당되는 벡터이며 본 논문에서는 2차원 운동을 가정하였으므로 가로방향 정보  $\hat{v}_x(i)$  와 세로방향 정보  $\hat{v}_y(i)$  가 디코딩되게 된다. 필터계수  $f_p(j)$ 는 최소자승방법에 의하여 다음과 같이 구할 수 있다 [9]:

$$\mathbf{f} = (\mathbf{R}^T \mathbf{R})^{-1} \mathbf{R}^T \mathbf{v} \quad (2)$$

여기서  $\mathbf{f} = [f_1(0) \ f_1(1) \ \dots \ f_p(0) \ \dots \ f_p(M-1)]^T$

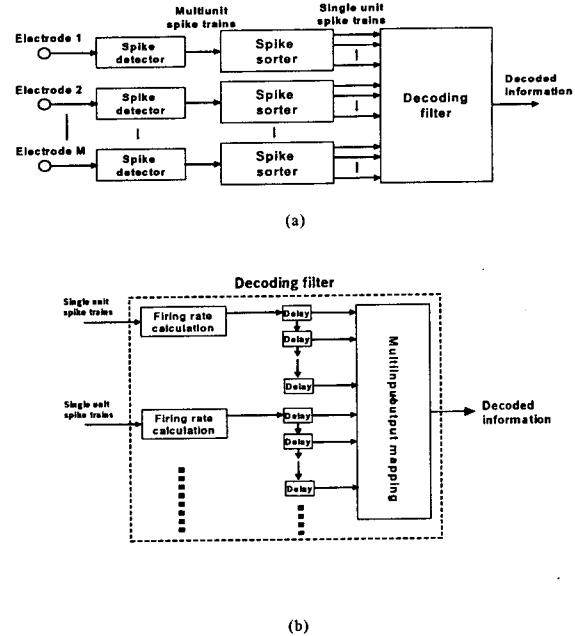


그림 1. 단일뉴런들로부터의 spike train에 기반한 뇌-기계 인터페이스의 디코딩알고리즘의 전체적인 구조. (a) 전체블럭도. (b) (a)의 디코딩 필터 부분의 상세 구조

Fig. 1. The structure of the decoding filter of BMI based on multiple spike trains. (a) Block diagram of the brain-machine interface. (b) Detailed structure of the decoding filter stage of Fig. 1 (a).

$$\mathbf{R} = \begin{bmatrix} 1 & r_1(0) & r_1(1) & \cdots & r_1(M-1) & \cdots & r_N(0) & \cdots & r_N(M-1) \\ 1 & r_1(1) & r_1(2) & \cdots & r_1(M) & \cdots & r_N(1) & \cdots & r_N(M) \\ \vdots & \vdots & \vdots & \ddots & \vdots & \ddots & \vdots & \ddots & \vdots \\ 1 & r_1(L) & r_1(L+1) & \cdots & r_1(L+M-1) & \cdots & r_N(L) & \cdots & r_N(L-M+1) \end{bmatrix}$$

이며  $\mathbf{v} = [v(0) \ v(1) \ \dots \ v(L-1)]^T$ 이다.  $L$ 은 필터계수를 구하기 위해 사용된 데이터 (즉 학습데이터)의 길이이며 행렬  $\mathbf{R}$ 과  $\mathbf{v}$ 는 학습데이터로부터 구성할 수 있다. MLP나 SVR 등 비선형매핑이 사용되는 경우 디코딩 알고리즘의 출력은 다음과 같이 시변발화율  $r_p(i)$ 의 비선형 함수로써 표현된다.

$$\hat{v}(i) = \sum_{p=1}^N \sum_{j=0}^{M-1} \phi(r_p(i-j) f_p(j)) \quad (3)$$

여기서  $\phi(\cdot)$ 은 일반적인 비선형 함수를 나타내며 위의 표현식은 신경계정보 인코딩 과정의 역매핑을 여러 개의 뉴런들의 발화율의 비선형필터링에 의해 수행하는 것에 해당한다. 최적의 디코딩 결과를 얻기 위한 역매핑은 실제로는 SVR이나 MLP등의 비선형매핑 알고리즘에 의해 근사화되게 된다.

MLP를 사용하는 경우 본 논문에서는 임의의 입-출력 매핑을 구현할 수 있는 것으로 알려진 입력층-온닉층-출력층의 3층퍼셉트론을 이용하였다. 입력노드의 수는 필터의 텁수에 해당되며 (식 (3)의  $M$ ), 출력노드는 1개이다. 온닉층 노드의 수는 이후 설명하는 바와 같이 30 ~ 50의 범위를 갖는다. 온닉층, 출력층은 각각 하이퍼볼릭탄젠트 및 선형함수를 전달함수로 갖는다. MLP의 학습은 입-출력 쌍을 알고

있는 데이터, 즉 학습데이터에 기반하여 실제 출력과 예측 출력값 간의 오차를 최소화하도록 구성된 목적함수를 최소화하는 방법에 의하여 이루어지게 된다. 이의 대표적인 방법으로 gradient-descent 방법에 기반한 오류역전파 (Error backpropagation, BP) 알고리즘이 사용된다. BMI를 위한 spike train 디코딩을 위해서도 역시 이 방법이 사용되었다 [7, 9]. 보다 성공적인 MLP의 학습을 위하여 많은 연구가 진행되어 왔으나 [10] 대개 BP에 의한 MLP의 학습을 성공적으로 수행하기 위해서는 많은 경험과 시행착오가 요구되며 많은 경우 MLP의 학습은 최적의 성능을 보인다기보다 적절한 선에서 중단되게 된다. 따라서 학습을 위해 특별한 노력을 기울이지 않은 경우에 있어서 비선형매핑의 상대적인 장점이 최대한으로 활용되고 있지 못할 가능성이 있으며 이 사실은 spike train 디코딩을 위한 연구의 경우에도 해당된다.

본 논문에서는 MLP의 학습을 위해 두 가지 방법을 사용하였다. 첫 번째는 은닉층의 노드 수를 변화시켜 가면서 시행착오 (trial-and-error)에 의해 만족스런 일반화 성능이 얻어질 때까지 반복 학습시키는 방법이다 (MLP1). 두 번째 방법은 early stopping [10, 11]을 사용한 방법이다 (MLP2). 이는 MLP의 학습을 체계적으로 최적화하기 위해 개발된 대표적이며 성공적인 방법으로 학습데이터를 다시 학습데이터와 validation 데이터로 분할하여, 분할된 학습데이터에 대해 학습을 수행하면서 주기적으로 validation 데이터에 대한 오류를 검사하여 이 오류가 감소하는지를 점검한다. 만약 이 오류가 증가하기 시작하면 학습데이터에 대한 오류가 감소하더라도 일반화성능이 떨어지기 시작하는 것이므로 학습을 멈춘다. Early stopping을 도입하는 경우 많은 수의 은닉노드를 사용하여 (본 논문에서는 30~50 개) 알고리즘 자체의 잠재적인 복잡도를 높이면서, 이로 인한 일반화 특성은 early stopping을 막는 방법을 활용한다. 즉 비선형매핑의 장점은 살리면서 단점은 보완하는 것이 어느정도 가능하다. 이에 대한 자세한 설명은 참고문헌 [12]에 제시되어 있다.

Support vector machine (SVM)은 MLP에 비하여 높은 일반화성을 보이는 최적화된 구조 및 파라미터를 찾기 쉬운 장점으로 인하여 패턴분류 및 비선형매핑에 있어서 최근 각광받고 있는 알고리즘이다 [11, 13]. SVM의 학습은 convex optimization 문제를 푸는 것에 해당되기 때문에 항상 최적해를 얻을 수 있음이 입증되어 있다 [13]. 본 논문에서 MLP와 더불어 SVM에 기반한 회귀 (SVM-based regression, SVR)를 이용한 spike train 디코딩 방법을 이용한 이유는 만약 성공적인 학습에 의하여 비선형 매핑방법의 장점이 최대한 활용될 경우, 선형필터를 이용한 경우에 비하여 높은 성능을 얻을 수 있는지 여부를 알아보기 위함이다. 본 논문에서는 Gaussian kernel을 사용하였으며 알고리즘의 세부사항들은 참고문헌 [14]에 자세히 설명되어 있다. MLP와 SVR에 의한 비선형 디코딩알고리즘은 모두 60 s 길이의 학습데이터에 기반하여 학습되었으며, 50개의 60 s 길이의 테스트 데이터에 대하여 성능평가를 수행하였다.

성능평가를 위하여 원숭이 대뇌의 일차운동영역 (primary motor cortex, MI)으로부터의 실험에 기반한 활동전위 발생모델을 구성하여, 실제의 팔 움직임 특성을 고려한 2차원 운동에 따른 다수의 단일뉴런들의 spike train을 생성하였다.

directional tuning (DT) 모델이라고 하는 이 활동전위 발생모델은 MI 뉴런들의 순간발화율이 현재의 운동방향과 개개의 뉴런마다 정해진 최대발화율에 해당하는 특정한 방향 (preferred direction, PD)과의 코사인값 및 현재의 속도의 크기에 비례한다는 특성에 기반하고 있다 [15]. 개개의 뉴런들의 spike 발생시간은 순간발화율에 따른 inhomogeneous Poisson process로부터 구해진다 [15, 16].  $p$ 번째 뉴런의 순간발화율  $r_p(i)$ 는 다음과 같이 표현할 수 있다.

$$\begin{aligned} r_p(i) &= A \mathbf{e}_p \cdot \mathbf{v}(i) + B \\ A &= (\lambda_{\max} - \lambda_{\min})/2, \quad B = (\lambda_{\max} + \lambda_{\min})/2 \end{aligned} \quad (4)$$

여기서  $\mathbf{e}_p$ ,  $\mathbf{v}(i)$ ,  $\lambda_{\max}$  및  $\lambda_{\min}$ 은 각각  $p$ 번째 뉴런의 PD에 해당하는 단위벡터, 현재시간의 속도벡터, 최대발화율 및 최소발화율을 나타낸다. 이 모델로부터 실제의 2차원적 팔움직임 특성을 고려한 움직임 궤적 특성 [17]에 응답하는 뉴런들의 spike train들을 생성하였다.

디코딩 알고리즘들의 성능은 다음과 같이 정의 되는 coding fraction (CF)이라는 수치로서 정량화하였다 [18, 19].

$$CF = 1 - \frac{\frac{\epsilon^2}{\sigma^2}}{\left( \sum_{i=1}^L v(i) - \frac{1}{L} \sum_{i=1}^L v(i) \right)^2} \quad (5)$$

CF는 실제의 신경계의 입력신호에 해당되는 움직임 궤적과, 디코딩 알고리즘에 의해 얻어지는 예측된 움직임 궤적 간의 유사성정도를 수치화하며 유사성이 높을수록 1에 가까운 값을 갖게 된다.

세포의 기록 신경신호에 기반한 BMI에서는 각 단일뉴런들로부터의 spike train을 구성하기 위해 활동전위 파형 검출 및 패턴분류에 의한 파형분류 과정 (spike sorting)을 반드시 거쳐야 하며 [20, 21] 이 과정에서 편연적으로 false positive (FP) 및 false negative (FN) 오류를 포함한다. 따라서 각 디코딩 알고리즘들이 spike train의 FP 및 FN 오류가 존재하는 상황에서 어느 정도의 디코딩 성능을 갖는지 파악할 필요가 있다. 본 논문에서는 활동전위 검출 및 분류 과정에 따라 발생할 수 있는 FP 및 FN 오류율을 정량적으로 변화시켜 가면서 디코딩 성능의 저하를 관찰하였다. 검출에 따른 오류는 단지 오류율에 해당하는 비율만큼 적절한 시간에 spike를 첨가하거나 제거함으로서 쉽게 고려할 수 있다. 그러나 파형분류 오류를 고려하는 경우 주의가 요구된다. 이는 한 단일뉴런의 spike train에 분류오류가 발생할 경우 이 결과로 인해 나머지 뉴런들의 spike train에 오류가 발생할 수도 있고, 그렇지 않을 수도 있기 때문이다. 예를 들면 하나의 전극으로부터 A, B, C 3개의 뉴런들로부터의 신호가 관찰될 경우, 뉴런 A의 spike train의 오류는 1) 뉴런 B 혹은 C로부터의 spike를 뉴런 A의 것으로 오인한 FP 오류, 2) 뉴런 A의 spike를 뉴런 B, C 혹은 잡음에 의한 것으로 오인한 FN 오류 등 두 가지 중 하나에 해당된다. 1)의 경우에는 뉴런 A의 FP 오류가 뉴런 B 혹은 C의 FN 오류를 반드시 야기한다. 그러나 2)의 경우에는 FN 오류가 B 혹은 C에 발생할 수도 있고 아닐 수도 있다. 이러한 세부적인 사실은 spike sorting 과정의 특성에 크게 의존한다. 따라서 동일 전극으로부터 측정되는 여러개의 spike train들을 동시에 고려해야 하며 spike sorting 과정의 성능 특성 수치

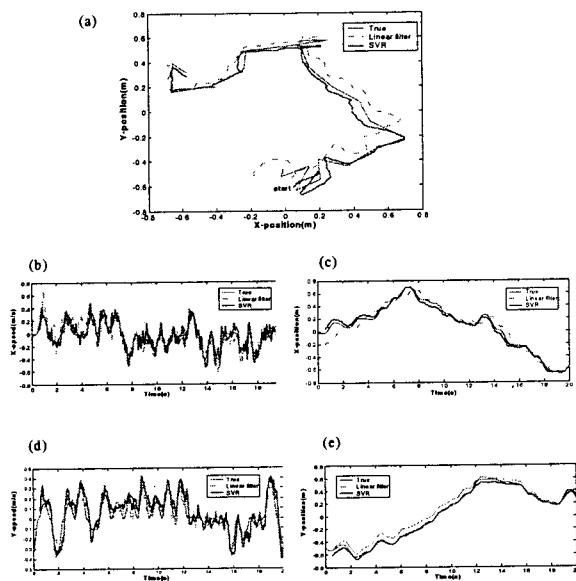


그림 2. MI 뉴런 spike train의 decoding 예. SVR 및 선형필터에 기반한 알고리즘이 사용되었다. (a) 팔 움직임의 2차원 궤적. (b) 가로방향 속력. (c) 가로방향 변위. (d) 세로방향 속력. (e) 세로방향 변위.

Fig. 2. A typical example of spike train decoding obtained from the DT model of MI neurons using the SVR-based, and linear-filter-based decoding filters. (a) Two-dimensional trajectory of arm-movement. (b) Speed in horizontal direction. (c) Displacement in horizontal direction. (d) Speed in vertical direction. (e) Displacement in vertical direction.

가 주어져야 한다.

본 논문에서는 분류오류에 따른 성능저하를 정량적으로 분석하기 위하여 다음과 같은 방법을 사용하였다. 10개의 전극으로부터 2개씩의 단일뉴런들의 활동이 관찰되는 상황을 고려하였다. 실제 상황을 모사하기 위해 최근 보고된 MI 내에서의 PD의 분포에 관한 실험결과 [22]를 참고하여 동일 전극에서 관찰되는 뉴런들의 PD 간 차이를 평균 76.4도, 표준편차 6.6도가 되도록 설정하였다. 위 20개 단일뉴런들로부터의 spike train들을 생성한 후 오류의 종류 및 비율에 맞도록 FP 혹은 FN 오류를 첨부하였다. 한 전극으로부터 두 개의 뉴런 (A, B)만의 활동이 기록되므로 spike sorting의 결과 특정 spike는 A, B, 혹은 잡음으로 인한 것으로 판정된다. 문제를 간단히 하기 위해 spike sorting 과정의 특성 중 정분류율 (correct classification ratio)은 모두 동일하다고 가정하였다. 즉,  $p_{AA} = p_{BB} = p_I$ 로 놓았다. 여기서 두 개의 아랫첨자들은 spike가 속하는 뉴런과 spike sorting의 판정 결과를 나타낸다. 오분류율 (correct classification ratio) 역시 모두 같은 값을 갖도록 하였다 (즉,  $p_{AB} = p_{BA} = p_{BN} = p_{NB} = (1-p_I)/2$ ). 여기서 아래첨자  $N$ 은 잘못된 분류에 의해 어느 spike 과정이 잡음으로 판정된 경우를 의미한다.

### 3. 결 과

그림 2는 선형필터와 SVR을 이용한 디코딩 알고리즘들

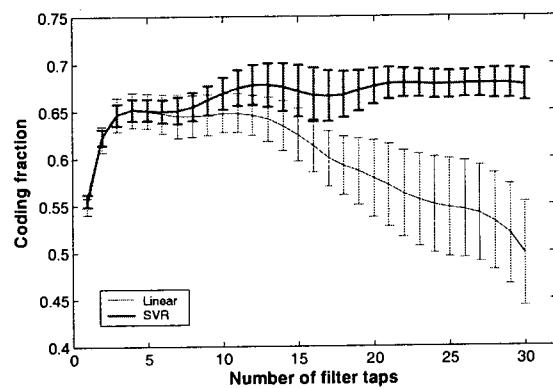


그림 4. 필터 텁 수에 따른 선형 필터 및 SVR기반 디코딩 알고리즘의 성능변화

Fig. 4. Performances of the linear-filter-based and SVR-based decoding algorithms as the length of the filter (the number of taps) varies

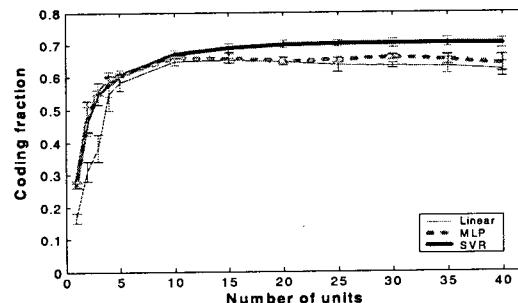


그림 3. 입력 뉴런 수에 따른 선형필터, MLP, SVR에 기반한 디코딩 알고리즘의 성능변화.

Fig. 3. Performances of the linear-filter-based, MLP-based, and SVR-based decoding algorithms quantified by the coding fraction as a function of the number of units.

을 50개의 단일뉴런들의 60초 간의 spike train에 적용하여 얻어진, 2차원 팔움직임 복원결과의 대표적인 예를 보여주고 있다. Time-delay의 수, 즉 필터 텁 수는 10이었다. 선형필터를 이용한 디코딩 방법도 비교적 우수한 움직임 복원결과를 보여주고 있으나, SVR을 이용한 방법이 현저하게 우수한 결과를 보여주고 있다.

성공적인 디코딩을 위해 몇 개의 뉴런들로부터의 입력을 필요로 하는지는 실제로 BMI를 구현할 때 전체구조에 큰 영향을 미친다. 이는 미세전극의 수 및 신호처리기의 채널수를 결정하기 때문이다. 각 디코딩 방법에 따라 요구되는 뉴런의 수를 파악하기 위하여 입력뉴런수를 변화시켜 가면서 디코딩성을 정량적으로 평가하였다. 그림 3에서 보였듯이 약 5개 이상의 단일뉴런들이 입력으로 사용된 경우 SVR이 세가지 방법 중 가장 우수한 결과를 보임을 확인할 수 있었다. MLP에 의한 방법은 몇몇 경우에는 선형필터 방법과 거의 비슷한 수준에 불과한 성능을 보였다. 또한 필터 텁수를 변화시켜 가면서 디코딩 성능을 관찰하였다. 그림 4에서 볼 수 있는 바와 같이 필터 텁수의 변화 시에도 SVR

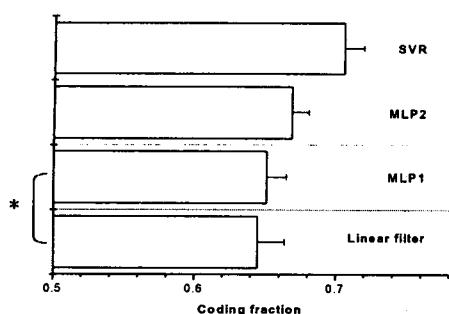


그림 5. 20회 반복실험에 의한 coding fraction의 평균 및 표준편차와, post-hoc t-test 결과. 통계적으로 의미있는 차이를 보이지 않는 경우는 단 한 가지 ('\*'로 표시) 뿐이었다. MLP기반 알고리즘은 2가지를 고려하였으며, MLP2가 early stopping을 도입하여 학습을 수행한 경우이다.

Fig. 5. The mean and standard deviation of coding fractions obtained from 20 experiments and the results of post-hoc t-test. There were only one case where the post-hoc t-test results did not show statistical difference (indicated by '\*'). Note that there are two bars for the MLP-based algorithm MLP2 is for the case when it is trained by the elaborated procedure of early stopping.

의 우수성은 계속 유지되었다.

다음으로 Early stopping을 도입한 경우에 MLP의 성능향상을 관찰하였다. Early stopping을 도입하여 주의깊게 학습을 수행한 MLP2의 경우에도 역시 SVR에는 못 미치는 디코딩 성능을 보였다. 그러나 MLP1에 비교하면 통계적으로 유의미한 성능 향상을 달성할 수 있었다. 이러한 사실은 MLP1, MLP2, SVR 등 3가지 방법을 분산분석 (analysis of variance, ANOVA)에 의해 비교한 결과에 근거한다. 각각의 방법을 60 s 길이의 학습데이터로 학습한 후 60 s 길이의 30개 쪽의 spike train에 기반하여 디코딩 성능을 구한 결과를 ANOVA에 의해 분석하였다. 그림 5에 도시한 바와 같이 SVR에기반한 방법이 가장 우수한 성능을 보였으며 MLP1과 MLP2의 성능 차이는 유의 수준  $p < 0.0001$ 에서 통계적으로 의미있는 결과였다.

디코딩알고리즘 들을 학습시키기 위해 사용한 학습데이터의 길이에 따른 성능변화도 관찰하였다. 기대한 바와 같이 선형필터, MLP, SVR 모두 학습데이터의 길이가 증가함에 따라 CF 값은 증가하였으나 증가추세가 곧 포화되었다. 그러나 SVR의 경우 약 30 s, MLP는 50 s, 선형필터는 60 s에서 성능증가의 포화가 시작되었다. 이 결과는 필요로 하는 학습데이터의 길이 측면에서도 SVR이 가장 우수함을 의미한다.

그림 6은 spike sorting 과정에서 발생할 수 있는 검출 오류로 인한 FP 및 FN 오류율에 따른 디코딩 성능의 저하를 보여주고 있다. 오류율에 따라 CF가 단조감소하는 추세를 보이고 있으며 SVR의 우수함이 일관되게 관찰된다. 그림 6 (a)와 (b)를 비교하면 FN 오류에 의한 영향이 보다 심한 성

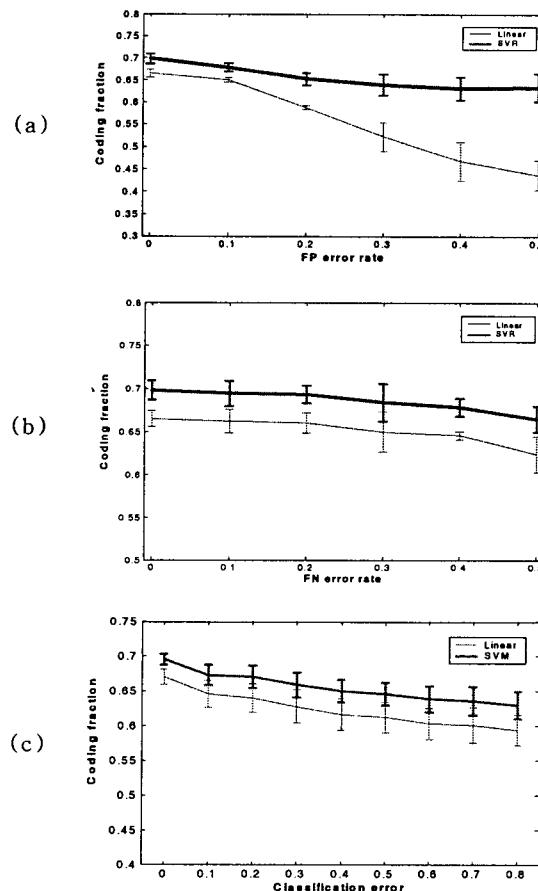


그림 6. spike train 내 오류로 인한 SVR 및 선형필터 기반 디코딩 필터의 성능변화. (a) false-positive 검출오류. (b) false-negative 검출오류. (c) 분류 오류.

Fig. 6. Performances of the SVR-based, and linear-filter-based decoding algorithms as a function of the ratio of spike train errors. (a) For false-positive detection errors. (b) For false-negative detection errors. (c) For classification errors.

능저하를 가져오는 것으로 보인다. 그림 6 (c)에 도시한 총 분류오류율 ( $2 \times p_2$ )에 따른 디코딩 성능 역시 SVR의 경우에 있어서 훨씬 유리함을 확인할 수 있었다.

#### 4. 고찰 및 결론

본 연구의 주요한 목적은 손상된 신경기능의 인위적 회복을 위한 BMI의 핵심요소인 spike train 디코딩에 있어서 비선형매핑을 이용하는 것이 바람직한 지의 여부를 평가하기 위한 것이었다. 많은 선행 연구들이 비선형디코딩을 위해서 활용하고 있는 MLP의 학습을 보다 최적화하고, 나아가 보다 우수한 일반화 성능을 갖는 SVR을 이용할 경우 비선형 매핑을 이용하는 것이 spike train 디코딩 성능을 향상시키는데 유리함을 보였다. 특히 SVR에 기반한 방법은 전처리 과정인 spike 검출 및 분류 오류에 따른 디코딩 성능저하가

상대적으로 작다는 우수함을 보였기 때문에 BMI를 위해 특히 유리할 것이라는 결론을 얻었다.

대부분의 관련연구들에서는 비선형매핑을 이용하는 것이 선형필터를 사용하는데 비하여 그다지 큰 장점을 보이지 않는다고 결론짓고 있다 [5, 8, 9]. 그러나 이에 대한 엄밀한 근거가 제시되고 있지 않으며 신경계의 정보 인코딩 과정이 명백히 비선형적이라는 사실을 고려할 때 좀 더 깊은 고찰이 필요한 것으로 판단하였다. 본 연구에서는 최적의 방법으로 학습되지 못한 MLP를 활용하였기 때문에 비선형매핑 방법들의 잠재적인 성능이 충분히 발휘되지 못했을 수 있다는 사실로부터 MLP의 보다 나은 학습을 시도하였고, 최적화에 있어서의 장점이 입증된 비선형매핑 방법인 SVR을 도입하였다.

Early stopping을 적용하여 MLP의 학습을 향상시킨 결과 통계적으로 유의미한 디코딩 성능 향상을 달성하였다. 또 이렇게 학습된 MLP (MLP2)는 항상 선형필터보다 우수한 디코딩 성능을 보임을 통계적으로 확인하였다. 반면 trial-and-error에 의해 학습한 MLP (MLP1)은 선형필터와 비슷한 성능을 보이는 경우도 많았다. SVR에 기반한 방법은 거의 모든 경우에 가장 우수한 성능을 보였다. SVM의 학습과정이 convex optimization에 해당하여 항상 최적해를 구할 수 있는 문제를 푸는 것에 해당한다는 사실과 학습 시 일반화 성능에 대한 고려가 함께 포함되어 있다는 두 가지 장점이 효과적으로 활용된 것으로 판단된다. 추후 Regularization 방법에 의한 overfitting 문제의 개선, Levenberg-Maquardt 방법에 의한 발전된 학습 등을 도입하여 MLP에 의한 디코딩 성능을 높일 수 있는지의 여부를 관찰해볼 필요가 있을 것이다.

비선형매핑에 기반한 디코딩방법의 우수성은 spike train 내에 검출 및 분류 오류가 포함될 경우에 더욱 현저하게 나타났다. 이러한 사실들을 고려할 때 비선형매핑, 특히 SVR을 이용한 디코딩알고리즘은 실제 BMI의 동작 시 반복히 발생할 수 있는 오류상황에서도 보다 신뢰성있는 동작을 보장할 것으로 판단되어 선형필터에 비해 큰 장점을 지니는 것을 기대된다. spike sorting 과정의 성능향상을 위해서는 매우 복잡한 패턴분류알고리즘이 요구될 수 있으며 이는 BMI의 신호처리기를 매우 복잡하게 만들 수 있다. 만약 디코딩알고리즘이 spike sorting 과정의 오류에 덜 영향을 받도록 한다면 상대적으로 간단한 spike sorting 과정으로도 충분하게 되므로 전체시스템의 구조가 훨씬 간단해 질 수 있을 것으로 기대된다.

### 감사의 글

이 논문은 2004학년도 연세대학교 학술연구비의 부분적인 지원에 의하여 이루어진 것입니다.

### 참 고 문 현

- [1] J. R. Wolpaw, N. Birbaumer, D. J. McFarland, G. Pfurtscheller, T. M. Vaughan, "Brain-computer interfaces for communication and control", Clin.

Neurophys., Vol. 113, pp. 767-791, 2002

- [2] J. D. Donoghue, "Connecting cortex to machines: recent advances in brain interfaces", Nature Neurosci., Vol. 5, pp. 1085 - 1088, 2002
- [3] M. Mojarradi, D. Binkley, B. Blalock, R. Andersen, N. Ulshofer, T. Johnson, L. D. Castillo, "A miniaturized neuroprosthesis suitable for implantation into the brain", IEEE Trans. Neural Sys. Rehab. Eng., Vol. 11, pp. 38-42, 2003
- [4] M. A. L. Nicolelis, "Actions from thoughts", Nature, Vol. 409, pp. 403 - 407, 2001
- [5] J. Wessberg, C. R. Stambaugh, J. D. Kralik, P. D. Beck, M. Laubach, J. K. Chapin, J. Kim, S. J. Biggs, M. A. Srinivasan, M. A. L. Nicolelis, "Real-time prediction of hand trajectory by ensembles of cortical neurons in primates", Nature, Vol. 408, pp. 361-365, 2000
- [6] K. A. Moxon, N. M. Kalkhoran, M. Markert, M. A. Sambito, J. L. McKenzie, J. T. Webster, "Nanostructured surface modification of ceramic-based microelectrodes to enhance biocompatibility for a direct brain-machine interface", IEEE Trans. Biomed. Eng., Vol. 51, pp. 881-889, 2004
- [7] M. Serruya, N. Hatsopoulos, M. Fellows, L. Paninski, J. Donoghue, "Robustness of neuroprosthetic decoding algorithms", Biol. Cybern., Vol. 88, pp. 219-228, 2003
- [8] J. Wessberg, M. A. L. Nicolelis, "Optimizing a linear algorithm for real-time robotic control using chronographic cortical ensemble recordings in monkeys", J. Cogn. Neurosci., Vol. 16, pp. 1022-1035, 2004
- [9] D. K. Warland, P. Reinagel, M. Meister, "Decoding visual information from a population of retinal ganglion cells", J. Neurophysiol., Vol. 78, pp. 2336-2350, 1997
- [10] M. Pardo, G. Sberveglieri, "Remarks on the use of multilayer perceptrons for the analysis of chemical sensor array data", IEEE Sensors J., Vol. 4, pp. 355-363, 2004
- [11] S. Haykin, Neural Networks: A comprehensive foundation, New Jersey: Prentice Hall, 1999
- [12] S. Amari, N. Murata, K. R. Muller, M. Finke, H. Yang, "Statistical theory of overtraining", Adv. Neural. Inf. Proc. Sys., Vol. 8, pp. 176-182, 1996
- [13] A. Smola, B. Schlkopf, "A tutorial on support vector regression", Statistics and Computing, Vol. 14, pp. 199-222, 2004
- [14] L. Hoogaerts, J. A. K. Suykens, J. Vandewalle, B. De Moor, "Subset based least squares subspace regression in RKHS", Neurocomputing, Vol. 63, pp. 293-323, 2005
- [15] A. P. Georgopoulos, A. B. Schwartz, R. E. Kettner,

- "Neuronal Population Coding of Movement Direction", Science , Vol. 233, pp. 1416-1419, 1986
- [16] C. Koch, Biophysics of Computation, New York: Oxford University Press, 1999
- [17] C. Kernere, K. V. Shenoy, T. H. Meng, "Model-based neural decoding of reaching movements: a maximum likelihood approach", IEEE Trans. Biomed. Eng., Vol. 51, pp. 925-932, 2004
- [18] M. Serruya, N. Hatsopoulos, M. Fellows, L. Paninski, J. Donoghue, "Robustness of neuroprosthetic decoding algorithms", Biol. Cybern., Vol. 88, pp. 219-228, 2003
- [19] D. S. Won, P. D. Wolf, "A simulation study of information transmission by multi-unit microelectrode recordings", Network: Comput. Neural. Syst., Vol. 15, pp. 29-44, 2004
- [20] K. H. Kim, S. J. Kim, "A wavelet-based method for action potential detection from extracellular neural signal recording with low signal-to-noise ratio", IEEE Trans. Biomed. Eng., Vol. 50, pp. 999-1011, 2003
- [21] K. H. Kim, S. J. Kim, "Method for unsupervised classification of multiunit neural signal recording under low signal-to-noise ratio", IEEE Trans. Biomed. Eng., Vol. 50, pp. 421-431, 2003
- [22] Y. Ben-Shaul, E. Stark, I. Asher, R. Drori, Z. Nadasdy, M. Abeles, "Dynamical organization of directional tuning in the primate premotor and primary motor cortex", J. Neurophysiol., Vol. 89, pp. 1136-1142, 2003

## 저자 소개

### 김경환 (金 璞煥)



1973년 6월 4일생. 1995년 한국과학기술원 전기 및 전자공학과 졸업. 2001년 서울대학교 전기컴퓨터공학부 졸업(공학박사). 2001년 3월 - 2004년 2월 삼성종합기술원 HCI lab. 책임연구원, 2003년 3월 - 2003년 12월 한국과학기술원 fMRI 연구실 방문연구원, 2004. 3-현재 연세대 의공학과 조교수. 관심분야는 신경시스템, 신경보철, 생체신호처리 등

Tel : 033-760-2364

Fax : 033-760-2197

E-mail : khkim@dragon.yonsei.ac.kr

### 김성신 (金 聖信)



1979년 2월 7일생. 2003년 서울대학교 응용화학부 졸업 (전기컴퓨터공학 복수전공). 2005년 서울대학교 전기컴퓨터공학부 졸업(공학석사). 관심분야는 BMI, 신경보철 등

Tel : 010-4741-9224

E-mail : sunji0807@hanmail.net

### 김성준 (金 成俊)



1954년 9월 24일생. 1978년 서울대학교 전자공학과 졸업. 1983년 美 코넬대 전자공학과 졸업(공학박사). 1983년-1989년 AT&T Bell lab. 1989년-현재 서울대학교 교수. 2000년-현재 초미세생체전자시스템 연구센터 센터장. 관심분야는 신경보철, 생체전자시스템 등.

Tel : 02-880-1812

Fax : 02-882-4658

E-mail : kimsj@snu.ac.kr