

시공간적 계층 메모리 학습 알고리즘을 이용한 근전도 패턴인식

Electromyogram Pattern Recognition by Hierarchical Temporal Memory Learning Algorithm

성무중^{*} · 추준욱^{*} · 이승하^{**} · 이연정^{*}

Moo-Joung Sung*, Jun-Uk Chu*, Seung-ha Lee^{**} and Yun-Jung Lee*

* 경북대학교 전자전기컴퓨터학부

** 단국대학교 의과대학 의공학교실

요약

본 논문에서는 비전 패턴인식 알고리즘인 시공간적 계층 메모리 학습 알고리즘을 이용한 새로운 근전도 패턴인식 방법을 제시한다. 효율적인 근전도 신호의 학습과 분류를 위하여 단순화된 2 레벨의 공간적 집합, 시간적 집합, 그리고 관리 맵퍼를 이용한 수정된 시공간적 계층 메모리 학습 알고리즘을 제안한다. 인식 성능을 향상시키기 위해서 관리 맵퍼 학습뿐만 아니라 시간적 집합 학습에도 카테고리 정보를 사용한다. 실험을 통하여 열 가지 손동작이 성공적으로 인식됨을 검증한다.

키워드 : 근전도, 패턴인식, 시공간적 계층 메모리 학습, 시간적 학습, 공간적 학습.

Abstract

This paper presents a new electromyogram(EMG) pattern recognition method based on the Hierarchical Temporal Memory(HTM) algorithm which is originally devised for image pattern recognition. In the modified HTM algorithm, a simplified two-level structure with spatial pooler, temporal pooler, and supervised mapper is proposed for efficient learning and classification of the EMG signals. To enhance the recognition performance, the category information is utilized not only in the supervised mapper but also in the temporal pooler. The experimental results show that the ten kinds of hand motion are successfully recognized.

Key Words : electromyogram, pattern recognition, hierarchical temporal memory, spatial learning, temporal learning.

1. 서 론

최근들어 근전도(electromyogram, EMG), 뇌전도(electroencephalogram, EEG), 안전도(electrooculogram, EOG)와 같은 생체 신호를 이용한 인간-기계 인터페이스가 많이 연구되고 있으며 그 중 그림 1과 같이 근전도 신호의 패턴인식을 기반으로 한 근전 의수 및 보조기에 관한 연구들이 활발히 진행되고 있다. 그러나 근전도 신호는 같은 동작을 취하더라도 근육의 힘에 따라 진폭이 달라지고 비정상적(non-stationary) 신호특성을 보인다. 또한 대부분 10mV 이하의 신호크기로 잡음에 민감하며, 피부 표면에 부착한 수 채널의 근전도 센서 신호들만으로 다양한 동작을 구별해야하기 때문에 근전도 신호를 이용한 동작패턴의 분류 및 인식은 어려운 문제이다.

근전도 신호의 패턴인식의 난제들을 해결하기 위하여 여러 방법이 연구되어 왔다 [1-4]. 기존 방법들은 근전도로부터 동작의 구분이 용이하고 반복적 재생이 가능한 특징벡터

를 추출하고, 다양한 통계적 패턴분류 방법과 신경회로망 기법을 이용하여 특징벡터를 분류함으로써 동작을 인식하고 있다. 이러한 방법들은 근전도 신호로부터 추출된 특징 벡터가 시불변이라고 가정하고 사용자로부터 단시간에 축정된 근전도 신호를 학습패턴으로 사용했다. 또한 근전도 신호의 개인적 차이에 적응하기 위해 개인별 오프라인 학습 시스템을 사용했다. 이러한 학습시스템의 경우 사용자가 초기에 축정된 학습패턴과 동일한 근전도 신호를 발생시킬 경우에만 높은 인식률을 보장하며 특징벡터를 추출하기 위해서 복잡한 연산과정을 필요로 하는 단점이 있다.

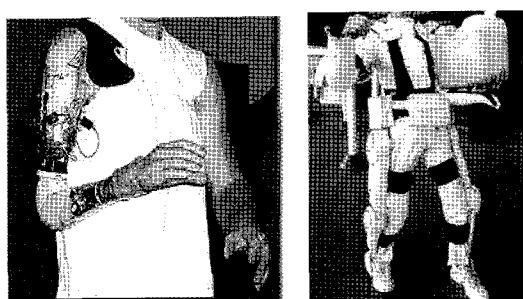


그림 1. 근전도 신호 인터페이스 사용 예

Fig. 1. Examples of EMG-interface applications.

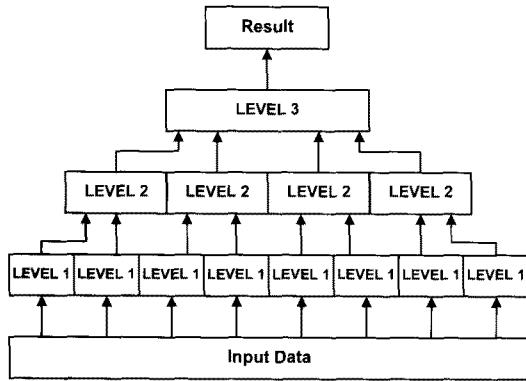


그림 2. HTM 계층구조

Fig. 2. Hierarchical recognition structure of HTM.

본 논문에서는 앞서 언급한 단점을 해결하기 위해서 시공간 계층 메모리 학습 알고리즘(Hierarchical Temporal Memory, HTM) [5]을 이용한 근전도 패턴인식 방법을 제안한다. HTM을 개발한 Hawkins는 사람이 새로운 물체를 학습할 때 많은 뉴런을 이용하여 다양한 특징을 가능한 많이 기억시키고, 반면에 물체를 인식할 때는 기억된 특징에 기반하여 간단한 연산만으로 물체를 판별한다고 보았다. 따라서 물체의 특징이 시간적 그리고 공간적으로 변화하더라도 장인한 인식이 가능하다고 생각하였다. 이와 같은 사람의 물체 인식방식을 모방한 HTM은 물체의 특징을 저장하기 위한 메모리를 계층적으로 배치하고 시공간적 연관성에 따라 메모리간 신뢰도를 조절함으로써 새로운 물체를 학습한다.

공간적 특징 학습에서는 전체 이미지를 아주 작은 부분들로 나누어 저장하며 저장된 몇 개의 부분을 모아서 상위 단계에서 보다 큰 이미지를 구성한다. 이러한 공간적 정보는 많은 메모리를 사용하지만 유사한 이미지들, 예를 들어 강아지와 고양이를 정확하게 구분할 수 있는 장점이 있다. 시간적 특징 학습은 전체 이미지가 시간에 흐름에 따라 부분적으로 보여지더라도 시간 인접성에 따라 하나의 이미지로 인식할 수 있게 한다. 예를 들어 움직이는 강아지를 인식하는 경우, 초기에는 강아지 전체가 화면에 포착되다가 나중에는 강아지의 일부분인 꼬리 만이 보일 수도 있는데, 시간 인접성을 사용하면 꼬리만을 보고도 강아지임을 판별할 수 있게 되는 것이다.

HTM의 시공간적 특징 학습은 근전도 패턴인식 문제에서도 유용하게 적용될 수 있다. 공간적 특징 측면에서 근전도 신호는 하나의 동작에서 일정한 패턴이 유지되지 않으며 서로 다른 동작들에 대해서 유사한 패턴을 가질 수 있다. 또한 시간적 특징으로 연속적인 동작인식을 위해 시간의 흐름에 따른 부분적인 근전도 신호가 인식기의 입력으로 사용될 수 있다. 본 논문에서는 이러한 근전도 패턴의 시공간적 특징을 학습할 수 있는 HTM의 구조를 제안하고 성능을 평가함으로써 인식률을 향상시킬 수 있음을 보인다.

2. 시공간적 계층 메모리 학습 알고리즘

2.1 HTM 구조

HTM은 사람의 물체 인식 체계를 모사한 새로운 비전 학습 알고리즘 중 하나이다. 사람이 뇌에 있는 수많은 뉴런

들이 정보를 저장하는 특징에 착안하여 많은 메모리를 계층적으로 연결하는 구조를 가진다. 그림 2와 같이 HTM 학습 알고리즘은 여러 개의 레벨로 구성되어 있으며 각 레벨마다 그림 3과 같이 공간적 집합(spatial pooler)과 시간적 집합(temporal pooler)을 가진다. 학습과정에서 공간적 집합 특성 벡터인 양자화 중심 행렬(quantization center matrix)과 시간적 집합 특성 벡터인 시간 그룹 행렬(temporal group matrix)을 구성하며 이러한 특성 벡터행렬들은 인식과정에서 공간적 집합 추론과 시간적 집합 추론을 통하여 양자화 중심과 시간 그룹의 신뢰값을 출력한다[5-9]. HTM 알고리즘의 세부 내용은 참고문헌[5-9]에 상세히 기술되어 있으므로 본 논문에서는 주요 부분만을 다음 절들에서 요약하여 설명한다.

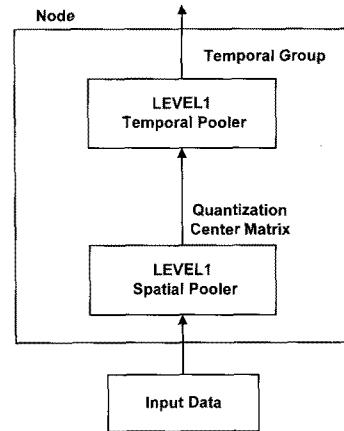


그림 3. 단계 구조

Fig. 3. Level structure.

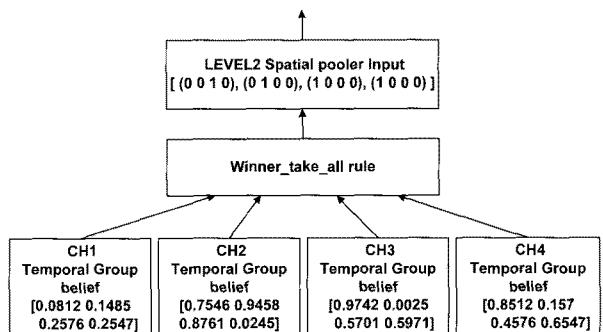


그림 4. 승자가 모든 것을 가지는 방법 예

Fig. 4. Example of winner-take-all rule.

2.2 공간적 집합 학습 및 추론

HTM 알고리즘의 첫 단계에서는 공간적 집합 학습에 의해 양자화 중심 행렬을 생성하고, 공간적 집합 추론으로 양자화 중심의 신뢰값을 계산한다. 최하위 단계인 레벨 1에서는 공간적 집합 학습을 위해서 가우시안 학습(Gaussian learning) 방법을 이용한다. 최초의 입력을 양자화 중심으로 생성하고 새로운 입력에 대하여 다음과 같이 유클리드 거리값(euclidean distance)을 계산한다.

$$d^2(x, w) = \sum_{j=1}^{N_{\text{dim},s}} (x_j - w_j)^2 \quad (1)$$

여기서 N_{dim_s} 는 입력 벡터 및 양자화 중심의 차원이고 x_j 는 입력 벡터의 j 번째 열, w_j 는 양자화 중심 w 의 j 번째 열, $d^2(x, w)$ 는 입력 벡터와 양자화 중심 w 의 유clidean 거리값이다. 계산결과가 디자인 파라미터인 최대거리 보다 작으면 발생빈도 값을 증가시키고 기존의 중심에 포함시킨다. 반면, 최대거리 보다 크다면 새로운 양자화 중심을 생성한다.

이와 같이 구해진 공간적 집합의 특징 벡터인 양자화 중심 행렬을 이용하여 공간적 집합 추론을 수행한다. 입력 데이터의 양자화 중심 신뢰값을 구하기 위해 다음과 같은 가우시안 추론 방법을 이용한다.

$$y_j = e^{-(x - W_j)^2 / 2\sigma^2} \quad (2)$$

여기서 x 는 입력 벡터, σ^2 는 디자인 파라미터인 분산값, y_j 는 j 번째 양자화 중심에 관한 신뢰값 벡터, W_j 는 j 번째 양자화 중심 행렬이다. 계산된 신뢰값은 시간적 집합 추론 입력으로 사용되어 진다.

레벨 1 이상의 상위 단계에서는 공간적 집합 학습에 승자가 모든 것을 가지는 방법(winner-take-all rule)을 사용한다. 승자가 모든 것을 가지는 방법이란 그림 4와 같이 각 하위 단계에서 상위 단계의 공간적 집합 학습의 입력으로 들어온 시간 그룹 신뢰값 중에서 최대값을 가지는 시간 그룹이 승자가 되어 1의 값을 가지며 나머지 시간 그룹은 0의 값을 가지는 방법이다. 이와 같이 업데이트 된 입력으로 양자화 중심 행렬을 학습하며 추론 과정에서는 다음과 같이 양자화 중심 신뢰값을 구한다.

$$y_i = \sum_{j=1}^N \text{Support}(W_i, \text{child}_i) \quad (3)$$

여기서 i 는 양자화 중심 번호, N 은 하위노드 개수, child_i 는 i 번째 양자화 중심에서 j 번째 채널에서 의해 생성된 양자화 중심값, $\text{Support}(W_i, \text{child}_i)$ 는 j 번째 채널에서 i 번째 하위단계 시간 그룹의 신뢰값과 그 채널로부터 승자가 모든 것을 가지는 방법으로 만들어진 양자화 중심 행렬과의 내적 연산이다. 계산된 신뢰값은 시간적 집합이나 관리 맵퍼 학습의 입력으로 사용된다.

2.3 시간적 집합 학습 및 추론

시간적 집합 학습은 각 단계의 공간적 집합 학습 결과로 나온 양자화 중심을 이용하여 시간 인접 행렬(time adjacency matrix)을 생성한다. 이 행렬은 시간 t 에서의 양자화 중심 번호를 시간 인접 행렬의 행으로, 그 전 시간 $t-1$ 에서의 양자화 중심 번호를 시간 인접 행렬의 열로 설정한다. 각 행렬요소에 시간 인접성에 따라 가중치를 부과하여 행렬을 생성한다.

학습으로부터 얻어진 시간 인접 행렬과 공간적 집합 추론 결과 나온 양자화 중심 신뢰값은 다음과 같이 시간 그룹 신뢰값으로 계산된다.

$$z_i = \sum_j \text{weights}_{i,j} \times y_j \quad (4)$$

여기서 y_j 는 공간적 집합 추론에서 연산된 j 번째 양자화 중심의 신뢰값이고, z_i 는 시간적 집합 추론에서 연산된 i 번째 시간 그룹의 신뢰값이며, $\text{weights}_{i,j}$ 는 i 번째 시간 그룹에 대한 j 번째 양자화 중심의 가중치 행렬로서 다음과

같다.

$$\text{weights}_{i,j} = \text{counts}_j \times I_{i,j} / \left(\sum_k (\text{counts}_k \times I_{i,k}) \right) \quad (5)$$

여기서 i 는 시간 그룹 번호, j 는 양자화 중심 번호, counts_j 는 j 번째 양자화 중심의 발생빈도, $I_{i,j}$ 는 다음의 인덱스 행렬이다.

$$I_{i,j} = \begin{cases} 1 & QC_j \in \text{group } i \\ 0 & QC_j \notin \text{group } i \end{cases} \quad (6)$$

여기서 QC_j 는 j 번째 양자화 중심을 뜻한다. 이와 같이 구해진 시간 그룹의 신뢰값은 상위 단계의 공간적 집합 학습 입력으로 사용된다.

2.4 관리 맵퍼 학습 및 추론

HTM의 마지막 단계에서는 시간적 집합 학습 및 추론을 대신하여 관리 맵퍼 학습 및 추론이 사용된다. 관리 맵퍼 학습에서는 양자화 중심과 카테고리 간의 관리 맵퍼 행렬(supervised mapper matrix)을 만든다. 관리 맵퍼 행렬은 시간 t 에서의 카테고리 번호를 행으로, 공간적 집합 추론에 의해 계산된 양자화 중심의 신뢰값 중 최대값을 가지는 양자화 중심의 번호를 열로 하여 각 요소에 가중치를 부과함으로써 구성된다. 관리 맵퍼 추론에서는 각 카테고리의 신뢰값을 다음과 같이 구한다.

$$z_i = \sum_j \text{norm}_{i,j} \times y_j \quad (7)$$

여기서 y_j 는 j 번째 양자화 중심의 신뢰값, z_i 는 관리 맵퍼 추론에서 계산된 카테고리의 신뢰값, $\text{norm}_{i,j}$ 는 i 번째 카테고리에서 j 번째 양자화 중심의 놈 행렬값으로 다음과 같다.

$$\text{norm}_{i,j} = m_{i,j} / \sum_k m_{k,j} \quad (8)$$

여기서 $m_{i,j}$ 는 i 번째 카테고리에서 j 번째 양자화 중심의 관리 맵퍼 가중치 값이다. 이렇게 구해진 카테고리의 신뢰값 중 최대가 되는 값으로부터 인식된 카테고리를 결정한다.

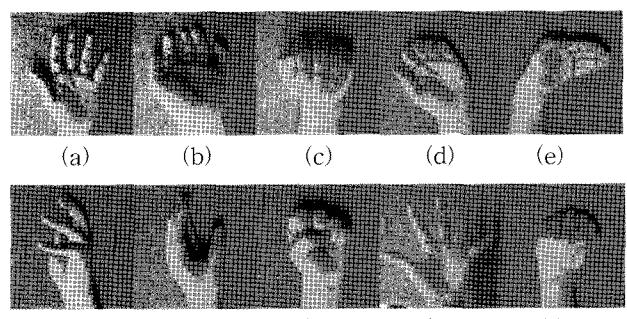


그림 5. 손동작 (a) 휴지 (b) 신전 (c) 굴곡 (d) 내전 (e) 외전 (f) 외회전 (g) 내회전 (h) 원형파지 (i) 폼 (j) 측면파지
Fig. 5. Hand motion. (a) relaxation. (b) extension. (c) flexion. (d) radial flexion. (e) ulnar flexion. (f) supination. (g) pronation. (h) cylindrical grasp. (i) open. (j) lateral grasp.

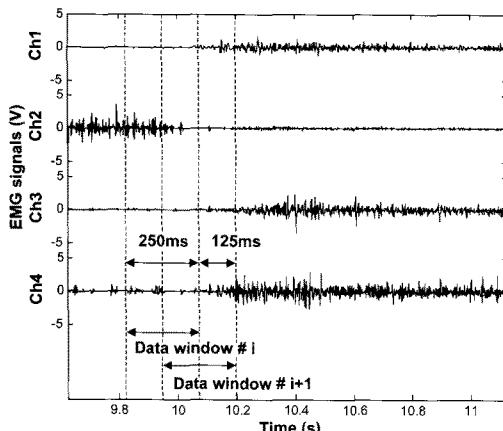


그림 6. 근전도 입력 데이터
Fig. 6. EMG input data.

3. HTM을 이용한 근전도 패턴인식

3.1 입력 근전도 신호

본 논문에서는 그림 5와 같이 전완(forearm)에서 가장 자주 사용되는 손목의 굴곡(flexion), 신전(extension), 내전(radial flexion), 외전(ulnar flexion), 내회전(pronation), 외회전(supination), 그리고 손의 원형파지(cylindrical grasp), 측면파지(lateral grasp), 그리고 펼(open)의 9 가지 동작과 휴지(relaxation) 동작을 포함하는 10 가지 동작을 인식한다. 휴지 이외의 9 가지 동작은 전완 근육들의 수축으로 이루어진다. 특히 긴 손바닥근(palmaris longus), 손가락 펼근(extensor digitorum), 노쪽 손목 굽힘근(extensor carpi radialis), 그리고 자쪽 손목 굽힘근(flexor carpi ulnaris)은 손과 손목 동작에 관여하는 중요 근육으로서 4 개의 표면전극(surface electrode)을 부착하여 근전도를 측정한다. 근전도는 근육의 수축에 따라 0~10 mV의 진폭을 가지며 20~500 Hz에 에너지가 집중되어 있다. 따라서 능동형 표면전극(DE-2.1, Delsys), 60 dB 이득을 갖는 증폭기 및 20~450 Hz의 대역통과필터를 이용하여 근전도 신호를 획득한다. 다음으로 획득된 근전도 신호는 ADC 보드(6052E, NI)를 이용하여 1024 Hz로 샘플링한다.

상지 절단환자가 근전의수를 자연스럽게 사용하기 위해서는 동작의도를 포함한 근전도의 발생으로부터 근전의수의 동작까지 소요되는 시간지연이 300 ms 보다 짧아야 한다. 따라서 그림 6과 같이 샘플링된 이산 근전도는 이동 윈도우(moving window)에 의해 분할되며 윈도우의 길이(window length)와 윈도우의 이동증가분(window increment)을 각각 250 ms (256 points)와 125 ms (128 points)로 설정한다. 즉, 어떤 시점에서 주어진 사용자 의도는 반드시 250 ms 윈도우에 두 번씩 포함된다. 따라서 근전의수의 제어명령 발생을 포함한 패턴인식이 125 ms 이내에 완료된다면 사용자는 300 ms 이내에 근전의수를 동작시킬 수 있다.

3.2 HTM을 이용한 근전도 패턴인식 구조

본 논문에서 제안하는 근전도 패턴인식을 위한 HTM의 구조는 그림 7과 같다. 4 개의 채널에서 들어오는 250 ms의 근전도 신호를 전반부 125 ms 와 후반부 125 ms 로 나

누어 총 8 개의 부분들을 레벨 1 노드의 입력으로 사용한다. 각각의 노드는 가우시안 학습으로 독립적으로 전반부와 후반부의 양자화 중심 행렬을 만든다. 다음으로 만들어진 전반부와 후반부의 양자화 중심들이 중복되지 않게 새로운 양자화 중심 행렬을 구성한다. 만들어진 양자화 중심 행렬과 카테고리 정보로 같은 카테고리에 있는 양자화 중심에 대해서만 시간 그룹을 만든다. 가우시안 추론으로 계산된 양자화 중심의 신뢰값으로 시간 인접 행렬로부터 얻은 시간 그룹의 신뢰값을 계산하여 레벨 2의 입력으로 사용한다.

레벨 2의 공간 집합에서는 레벨 1의 학습 및 추론 결과로부터 나온 전반부와 후반부 시간 그룹의 신뢰값을 승자가 모든 것을 가지는 방법(winner-take-all rule)을 이용하여 업데이트 한다. 이 업데이트된 시간 그룹의 신뢰값으로 양자화 중심을 전반부와 후반부로 나누어 찾은 다음, 전반부와 후반부 양자화 중심이 중복되지 않게 새로운 양자화 중심 행렬을 구성한다. 만들어진 전반부와 후반부의 양자화 중심의 신뢰값과 카테고리 정보로부터 관리 맵퍼 행렬을 만들고 최종적으로 카테고리의 신뢰값을 계산한다.

3.3 기존 HTM과의 차이점

근전도 패턴인식에 적용하기 위해서 제안한 HTM은 기존의 HTM과 몇 가지 다른 점이 있다. 첫 번째 차이점은 계층의 단순화이다. 기존의 HTM은 최소 3 레벨 이상의 계층으로 입력 데이터의 추상화와 그룹화를 통한 패턴인식 방법이다.

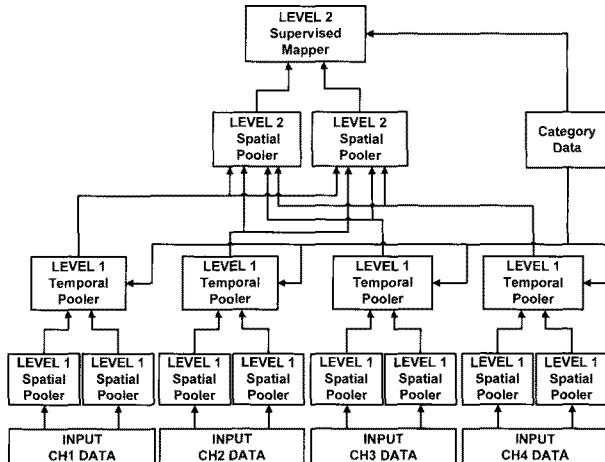


그림 7. 근전도 패턴인식을 위한 HTM 구조
Fig. 7. HTM structure of EMG pattern recognition.

그러나 근전도 신호는 데이터양이 많기 때문에 3 레벨 이상의 경우 계산시간이 많이 요구되고 신호 간에 유사성이 비교적 높아 많은 추상화를 할 경우 인식률이 저하될 수 있으므로 계층을 줄여 2 레벨 구조를 사용한다.

두 번째로 그림 8과 같이 입력 데이터 윈도우를 두 부분으로 나누어 사용하는 것이다. 앞서 언급 하였듯이 사용자의 동작의도를 연속적으로 인식하기 위해 데이터 윈도우를 윈도우 길이의 절반씩 중복하여 사용한다. 이런 경우에는 인접한 두개의 데이터 윈도우 간 유클리드 거리값이 유사함으로 전체 양자화 중심의 개수가 줄어들게 된다. 따라서 특정한 시간 그룹이 전체 시간적 집합 공간을 점유하게 됨으로써 인식률이 저하된다. 이러한 문제를 해결하기 위해서 데이터 윈도우를 전반부와 후반부로 나누어 공간적 집합 학

습을 수행한다. 즉, 전반부를 입력으로 가지는 공간적 집합은 항상 데이터 윈도의 전반부만을 입력 받음으로써 의미 있는 시간 인접 행렬을 구할 수 있다. 또한 두 부분으로 나누어 공간적 집합 학습을 함으로써 더욱 짧은 시간구간의 근전도 특징 변화를 기억시킬 수 있으며 결과적으로 공간적 특징 벡터의 숫자를 증가시킬 수 있다.

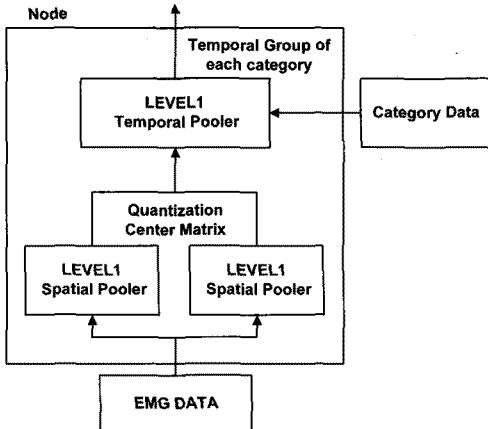


그림 8. 근전도 패턴인식을 위한 단계 구조
Fig. 8. LEVEL structure of EMG pattern recognition.

세 번째 차이점은 그림 8과 같이 카테고리 정보를 관리 맵과 학습뿐만 아니라 시간적 집합 학습에도 사용하는 것이다. 근전도 신호는 유사한 패턴이 연속적으로 발생됨으로 시간적 집합 학습에서 시간 인접성에 따른 그룹핑이 쉽지 않다. 따라서 카테고리 정보를 부가하여 카테고리 별로 시간 그룹을 생성한다.

HTM을 근전도 패턴인식에 적용함에 있어 인식률과 계산속도의 향상을 위하여 제안된 세 가지 학습 및 구조적 특징은 다음 실험들을 통하여 그 유효성을 확인한다.

4. 실험 결과

4.1 손동작에 따른 근전도 측정

제안된 HTM을 이용하여 실제 측정된 근전도 신호의 패턴인식 성능을 검증한다. 실험에서는 앞서 언급한 10 개의 손동작으로부터 발생되는 근전도 신호와 카테고리 정보를 측정하였다. 정상인 피실험자는 휴지동작을 포함하여 10 가지 동작을 순차적으로 각각 5 초간 수행하였으며 동시에 근전도를 측정하였다. 카테고리 입력은 그림 9 와 같이 10 가지 손동작에 대하여 번호를 부여함으로써 저장하였다. 이 카테고리 정보는 모든 데이터 집합에 대하여 동일한 순서로 할당하였다. 하지만 피실험자의 동작전환 시점이 일정하지 않음으로 각각의 동작에 포함되는 데이터 윈도의 개수는 조금씩 차이를 가진다.

실험에서 획득된 10 개의 데이터 집합은 그림 10과 같다. 4 채널의 근전도 신호가 약 50초 동안 측정되었으며 총 405 개의 이동 윈도우 개수를 가진다. 앞서 언급하였듯이 피실험자가 같은 동작을 수행하더라도 각 데이터 집합에 대하여 4 채널의 근전도 패턴이 일정하지 않으며, 서로 다른 동작인 원형파지, 측면파지, 평동작에서는 유사한 근전도 패턴이 발생됨을 확인할 수 있다.

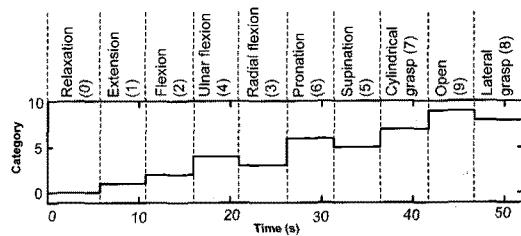
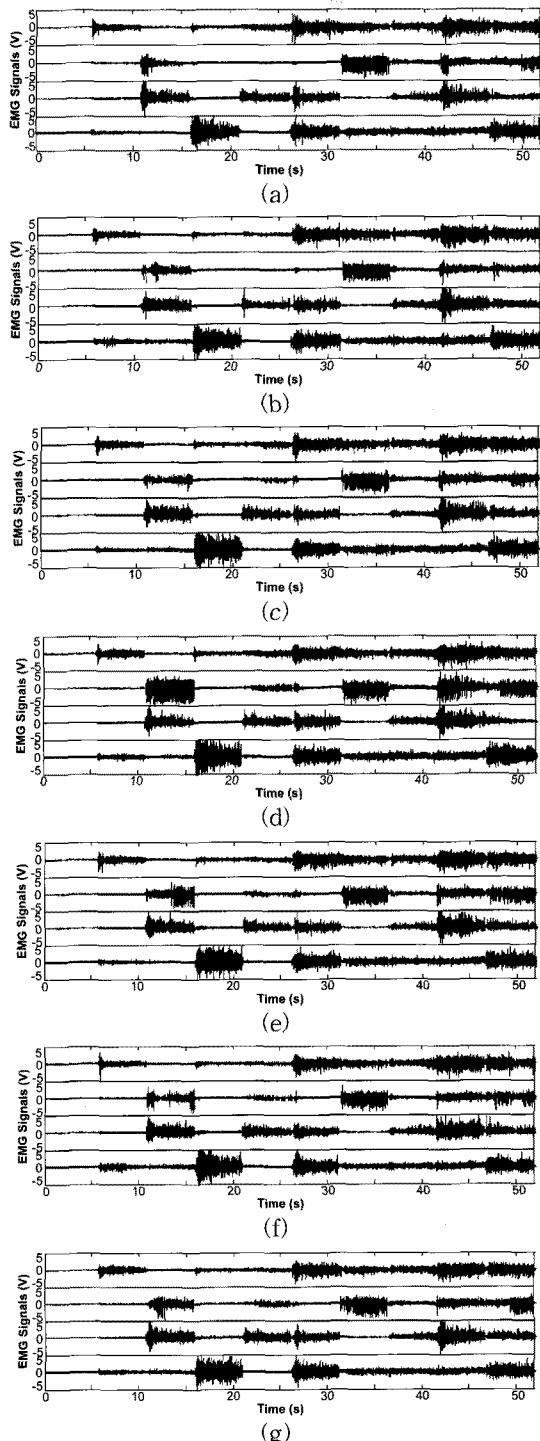


그림 9. 카테고리 입력
Fig. 9. Category inputs.



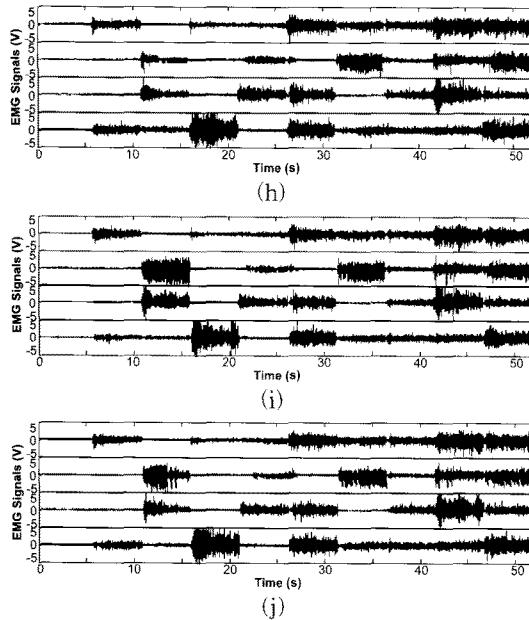


그림 10. 근전도 입력들 (a) 1번 데이터 집합(D1) (b) 2번 데이터 집합(D2) (c) 3번 데이터 집합(D3) (d) 4번 데이터 집합(D4) (e) 5번 데이터 집합(D5) (f) 6번 데이터 집합(D6) (g) 7번 데이터 집합(D7) (h) 8번 데이터 집합(D8) (i) 9번 데이터 집합(D9) (j) 10번 데이터 집합(D10)

Fig. 10. EMG inputs. (a) Data set 1 (D1). (b) Data set 2 (D2). (c) Data set 3 (D3). (d) Data set 4 (D4). (e) Data set 5 (D5). (f) Data set 6 (D6). (g) Data set 7 (D7). (h) Data set 8 (D8). (i) Data set 9 (D9). (j) Data set 10 (D10).

그림 10의 데이터 집합 중 D1~D5까지의 데이터 집합은 학습과정에 사용하였고, D6~D10까지의 데이터 집합은 추론과정에서 인식률을 검증을 위해 사용하였다.

4.2 HTM의 구조에 따른 인식률

근전도 패턴인식을 위해 제안한 HTM의 구조적 특징이 인식률에 미치는 영향을 평가하기 위해 실험을 수행하였다. 이 실험에서는 간단히 데이터 집합 D1을 학습하고 데이터 집합 D7에 대하여 추론을 수행하였다.

먼저, 그림 11(a)에서는 2 장에서 설명한 구조 즉, 기존의 비전 데이터에 적용된 HTM 구조에 대하여 근전도 패턴인식 결과를 보인다. 공간 및 시간적 집합에서 적은 수의 특징벡터만이 생성됨으로써 동작에 따른 근전도 특징을 학습하지 못하였다. 그 결과 모든 동작에 대하여 분류가 실패함을 알 수 있다.

제안한 HTM 구조 즉, 2 단계의 레벨을 가지고, 데이터 윈도우를 전반부와 후반부로 나누어 학습하며, 시간적 집합 학습에 카테고리 정보를 이용한 구조에 대한 패턴인식 결과를 그림 11(b)에서 보인다. 결과에서 보듯이 기존의 HTM 보다 월등한 인식률을 보이며 공간 및 시간적 집합의 특징 벡터 개수가 증가함을 확인할 수 있다.

다음으로 근전도 신호의 데이터 윈도우를 전반부와 후반부로 나누어 학습하는 구조가 인식률에 미치는 영향을 알아보기 위한 실험을 수행하였다. 그림 11(c)에서 데이터 윈도우를 한 부분으로 학습한 결과의 인식률을 보인다. 이 실험 결과로부터 데이터 윈도우를 나누어 학습하지 않으면 중복

된 근전도가 입력으로 사용되어 양자화 중심의 개수가 줄어들게 되고 시간적 집합 공간에서 특정한 그룹이 거의 모든 양자화 중심을 포함하게 되는 현상이 발생하였다. 따라서 데이터 윈도우를 전반부와 후반부로 나누어 학습한 결과인 그림 11(b) 보다 인식률이 낮음을 확인할 수 있다.

그림 11(d)에서는 카테고리 정보를 관리 맵피 학습에만 사용한 경우의 인식결과를 보인다. 즉, 시간적 집합 학습에서 카테고리 별로 양자화 중심의 시간 그룹을 생성하지 않고 모든 양자화 중심을 대상으로 시간 인접성에 따라 그룹을 생성하였다. 그 결과 시간 그룹의 개수가 줄어들었으며, 카테고리 정보를 시간적 집합 학습과 관리 맵피 학습에 동시에 사용한 경우의 실험결과인 그림 11(b)보다 인식률이 낮아짐을 확인할 수 있다.

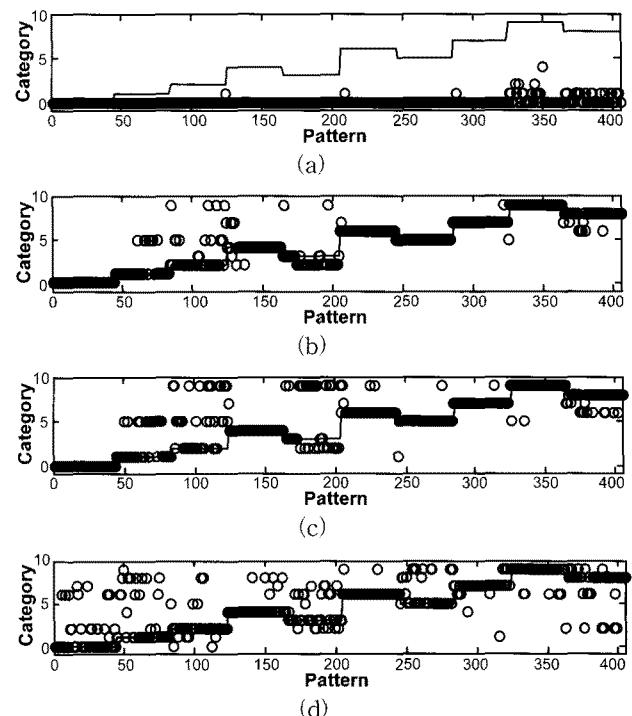


그림 11. HTM 구조에 따른 인식률 변화 (a) 기존의 HTM 구조의 경우 (10.02%) (b) 제안한 HTM 구조의 경우 (82.47%) (c) 제안한 HTM 구조+데이터 윈도우를 한 부분으로 학습한 경우 (77.86%) (d) 제안한 HTM 구조+시간 집합 학습에 카테고리 정보를 사용하지 않은 경우 (70.86%)
Fig. 11. Pattern recognition results according to HTM structure. In case of (a) the conventional HTM (10.02%). (b) the proposed HTM (82.47%). (c) the proposed HTM+single data window (77.86%). (d) the proposed HTM+a temporal pooler without category data inputs (70.86%).

4.3 학습 데이터 양에 따른 인식률

학습 데이터 양에 따른 HTM 근전도 패턴인식 결과를 검증하였다. 데이터 집합의 수를 증가시키면서 학습 하였을 경우 공간 및 시간적 특징 벡터의 개수와 추론 데이터 집합에 대한 패턴 인식 결과를 조사하였다.

그림 12와 같이 학습에 사용된 데이터 집합이 증가할수록 각 레벨의 저장된 공간적, 시간적 특징 벡터의 개수가

증가하는 것을 확인 할 수 있다. 또한, 표 1과 같이 D6에서 D10까지의 데이터 집합에 대한 인식률이 학습 데이터양의 증가에 따라 향상됨을 확인할 수 있다.

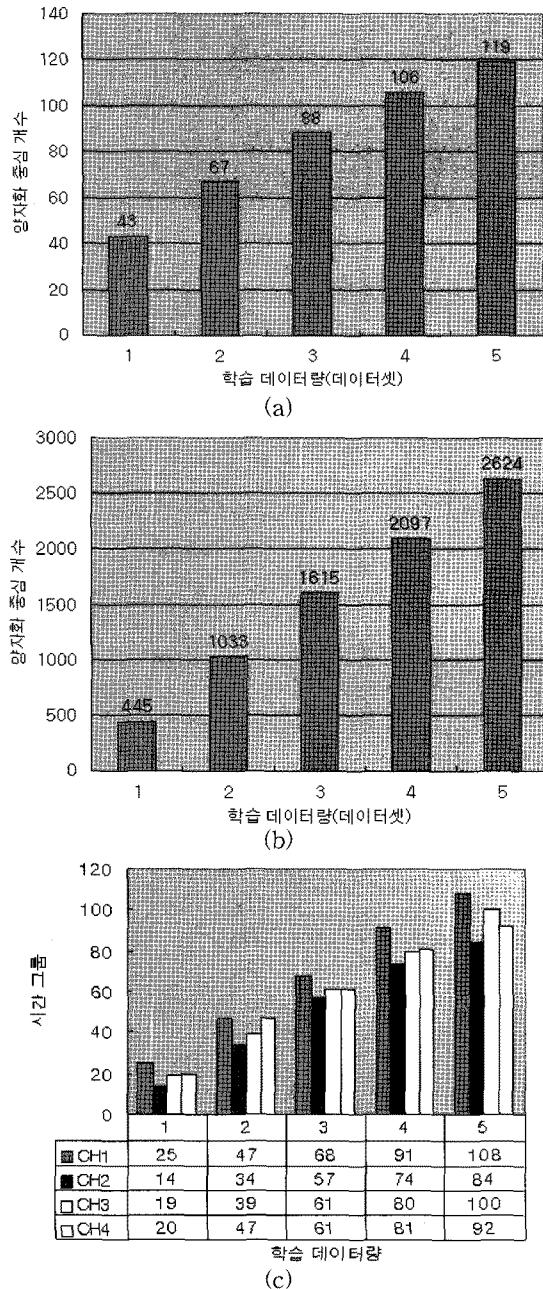


그림 12. 학습량 증가에 따른 특징 벡터 숫자 변화 (a) 레벨 1의 공간적 특징 벡터 숫자 변화 (b) 레벨 2의 공간적 특징 벡터 숫자 변화 (c) 레벨 1의 시간적 특징 벡터 숫자 변화
Fig. 12. Change in the number of feature vectors according to the increase of learning data quantity. (a) the number of feature vectors of spatial pooler in level 1. (b) the number of feature vectors of spatial pooler in level 2. (c) the number of feature vectors of temporal pooler in level 1.

그림 13은 표 1의 D7 추론 데이터 집합에 대하여 학습 데이터 집합을 D1부터 D5까지 증가시켰을 경우의 인식 결

과이다. 이 실험 결과로 학습 데이터양이 증가할수록 저장되는 공간적, 시간적 특징 벡터 개수가 증가하고 이를 바탕으로 인식률이 향상됨을 확인 할 수 있다.

표 1. 학습 데이터양 증가에 따른 균전도 인식률 변화

Table 1. Change in recognition rates according to the increase of learning data quantity. [%]

학습 데이터 추론 데이터	D1	D1 ~ D2	D1 ~ D3	D1 ~ D4	D1 ~ D5
	D6	D7	D8	D9	D10
83.46	91.36	94.32	94.32	94.32	94.32
82.47	94.07	94.32	96.30	98.27	
84.23	84.69	86.91	89.38	90.86	
80.74	93.07	93.82	95.80	97.00	
79.26	82.96	88.64	94.81	94.81	

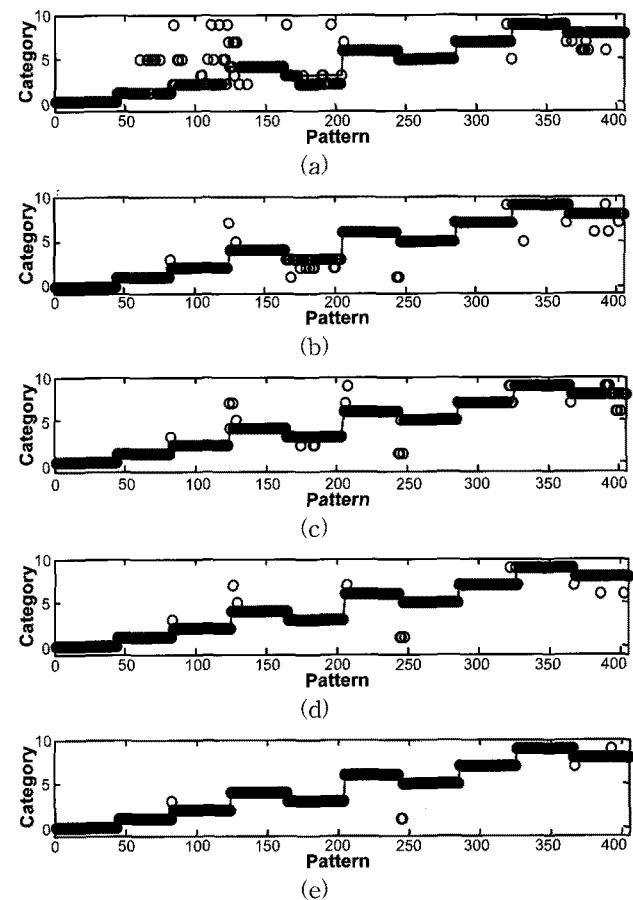


그림 13. 학습 데이터양 증가에 따른 인식 변화 (a) 1개 학습데이터 집합의 경우 (b) 2개 학습데이터 집합의 경우 (c) 3개 학습데이터 집합의 경우 (d) 4개 학습데이터 집합의 경우 (e) 5개 학습데이터 집합의 경우
Fig. 13. Change in recognition results according to the increase of learning data quantity. In case of (a) one learning data set. (b) two learning data sets. (c) three learning data sets. (b) four learning data sets. (b) five learning data sets.

이상의 실험 결과로부터 균전도 패턴인식을 위해서 기준의 HTM과는 다르게 2 단계 계층 구조를 가지며, 데이터

윈도우를 두 부분으로 나누어 학습하고, 시간적 집합 학습에 카테고리 정보를 사용하는 방법이 인식률 향상에 기여함을 확인할 수 있었다.

5. 결 론

HTM을 이용한 근전도 패턴인식 방법의 첫 번째 장점은 복잡한 학습 및 추론 엔진을 이용한 인식률의 향상이 아니라 학습 데이터양의 증가에 따른 인식률 향상이 가능하다는 점이다. 실험을 통하여 학습 데이터양이 증가함에 따라 최대 98%까지 인식률이 증가함을 확인했고 추후 더 많은 학습 데이터를 이용한다면 더 좋은 인식률을 가질 수 있을 것으로 판단된다. 두 번째 장점은 시간적 집합 학습에 의한 인식률의 향상이다. 같은 카테고리 입력 패턴이지만 공간적으로는 다른 특징을 가져 다른 카테고리로 인식될 경우에도 시간 집합 학습을 통하여 올바른 패턴인식이 가능하였다. HTM은 같은 카테고리에서 공간적 특징이 다양한 입력 패턴을 시간의 흐름에 따라 연속적으로 학습함으로써, 기존의 패턴 인식이 초기에 측정된 학습 패턴과 동일한 근전도 신호를 발생시킬 경우에만 높은 인식률을 보장하는 단점을 보완할 수 있었다.

참 고 문 헌

- [1] 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, 2000.
- [2] 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, 2003.
- [3] 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, 2005.
- [4] Jun-Uk Chu, Inhyuk Moon, Yun-Jung Lee, Shin-Ki Kim, and Mu-Seong Mun, "A Supervised Feature-Projection-Based Real-Time EMG Pattern Recognition for Multifunction Myoelectric Hand Control," *IEEE/ASME Trans. Mechatronics*, vol. 12, no. 3, pp. 282-290, 2007.
- [5] Jeff Hawkins and Sandra Blakeslee, *On Intelligence*, Numenta Inc., 2006.
- [6] Jeff Hawkins and Dileep George, *Hierarchical Temporal Memory : Concepts, Theory, and Terminology*, Numenta Inc., 2006.
- [7] Jeff Hawkins, "Why can't a computer be more like a brain?," *IEEE Spectrum*, vol. 44, no. 4, pp. 21-26, 2007.
- [8] *ZetaL Algorithms Reference*, Numenta Inc., 2007.
- [9] Dileep George and Bobby Jaros, *The HTM Learning Algorithms*, Numenta Inc., 2007.

저 자 소 개



성무종(Sung, Moo-Joung)
2006년: 경북대 전자전기컴퓨터학부(학사)
2008년: 경북대 전자전기컴퓨터학부(석사)
2008년~현재: 삼성테크윈 제어기술그룹
연구원

관심분야 : 근전도 패턴인식, 모터 제어
E-mail : moojoung.sung@samsung.com



추준욱(Chu, Jun-Uk)
1998년: 영남대 전기공학과(학사)
2000년: 경북대 전자공학과(석사)
2009년: 경북대 전자공학과(박사)
2002년~2006년: 재활공학연구소
선임연구원

관심분야 : 근전도 패턴인식, 생체신호처리
E-mail : juchu@ee.knu.ac.kr



이승하(Seung-ha Lee)
1988년: 경북대학교 전자공학과(학사)
1990년: 한국과학기술원 전기 및 전자공학과(석사)
1995년: 한국과학기술원 전기 및 전자공학과(박사)
1995년~1996년: 한국과학기술원 전기 및 전자공학과 Post-Doc
1996년~2005년: 경북대학교 전자전기컴퓨터학부 BK21 교수
2005년~현재: 단국대학교 의과대학 의공학교실 교수

관심분야 : 의공학시스템, 지능제어, 임베디드시스템
E-mail : shalee@dankook.ac.kr



이연정(Lee, Yun-Jung)
1984년: 한양대학교 전자공학과(학사)
1986년: 한국과학기술원 전기 및 전자공학과(석사)
1994년: 한국과학기술원 전기 및 전자공학과(박사)
1995년~현재: 경북대학교 전자전기컴퓨터학부 교수

관심분야 : 보행로봇, 서비스로봇, 임베디드 시스템
E-mail : yjlee@ee.knu.ac.kr