

Gaussian Mixture Model 기반 전완 근전도 패턴 분류 알고리즘

A Gaussian Mixture Model Based Pattern Classification Algorithm of Forearm Electromyogram

송영록*, 김서준, 정의철, 이상민

Y. R. Song, S. J. Kim, E. C. Jeong, S. M. Lee

요 약

본 논문에서는 의수환자의 일상생활을 고려한 1-자유도 동작을 손을 쥐고 펴므로 정의하고, 두 동작에 대한 근전도 패턴 분류를 위한 가우시안 혼합 모델 기반의 근전도 패턴 분류 알고리즘을 제안한다. 근전도 패턴 분류 알고리즘의 핵심이 되는 근전도 신호의 특징점 추출을 위하여 근전 신호의 진폭 특성을 고려하는 절대차분평균치(DAMV)와 평균절대값(MAV)을 사용한다. 또한 동작에 대한 근전 신호의 진폭 특성을 보다 명확히 구분하기 위하여 D_DAMV와 D_MAV를 제안한다. 본 논문에서는 4명의 성인남성을 대상으로 실험을 실시하였고, 두 동작에 대한 근전도 패턴의 정확한 분류 여부를 확인하였다.

ABSTRACT

In this paper, we propose the gaussian mixture model based pattern classification algorithm of forearm electromyogram. We define the motion of 1-degree of freedom as holding and unfolding hand considering a daily life for patient with prosthetic hand. For the extraction of precise features from the EMG signals, we use the difference absolute mean value(DAMV) and the mean absolute value(MAV) to consider amplitude characteristic of EMG signals. We also propose the D_DAMV and D_MAV in order to classify the amplitude characteristic of EMG signals more precisely. In this paper, we implemented a test targeting four adult male and identified the accuracy of EMG pattern classification of two motions which are holding and unfolding hand.

Keyword : EMG, Gaussian mixture model, pattern classification, Feature extraction, D_DAMV, D_MAV

1. 서론

접 수 일 : 2011.11.29

심사완료일 : 2011.12.16

게재확정일 : 2011.12.19

* 송영록 : 인하대학교 정보전자공동연구소 연구교수

gateway32@inha.ac.kr (주저자)

김서준 : 인하대학교 전자공학과 학부과정

wodud4435@nate.com (공동저자)

정의철 : 인하대학교 전자공학과 석사과정

kaisergog@naver.com (공동저자)

이상민 : 인하대학교 전자공학과 교수

sanglee@inha.ac.kr (교신저자)

※ 본 연구는 지식경제부 및 정보통신산업진흥원의 IT융합 고급인력과정 지원사업의 연구결과로 수행되었음 (NIPA-2011-C6150-1102-0001)

생체신호 기반 인터페이스 기술은 근전도(EMG) 및 뇌전도(EEG)와 같은 인위적으로 발생 가능한 생체 신호를 이용하여, 노약자나 장애인이 컴퓨터를 이용하는데 있어서의 인터페이스(human computer interface)로 사용하거나 휠체어 등의 재활기기 구동 제어를 위한 명령어를 생성하기 위한 기술을 의미한다[1]. 이러한 인간의 생체신호 중에서 EMG 신호 처리는 진단의학, 스포츠 과학, 재활 공학과 같은 분야에서 인간의 골격근 분석 및 진단, 동작 모방을 위해 연구되어 왔다[2]. 또한 근전도 신호의 패턴 인식을 기반으로 한 근전 의수 및 보조기에 관한 연구들이 진행되고 있다. 최근의 연구에서는 근전도 신호의 패턴 분류를 위한 k-nearest neighbor (k-NN), Quadratic Discriminant Analysis (QDA), Linear Discriminant Analysis(LDA) 알고리즘을 비

교하는 연구[3]와 Support Vector Machine(SVM) 알고리즘을 이용한 근전도 신호의 패턴 인식 기법 [4] 등이 연구되었고, 미국 미시간 대학은 신경 손상된 환자의 재활을 목적으로 다리에 착용하는 형태로 근전도 신호를 이용하여 움직임을 예측하고 모터대신 공기압력을 이용한 인공근육을 움직이게 하여 사람의 보행을 돕는 Powered Lower Limb Orthoses를 개발하였다[5].

본 논문에서는 의수환자의 일상생활을 고려한 손을 쥐고 펴는 동작의 추정을 위한 가우시안 혼합 모델(GMM : Gaussian Mixyure Model)기반 전완 근전도 패턴 분류 알고리즘을 제안한다. 근전도 패턴 분류 알고리즘의 핵심이 되며 사용자 동작 추정의 필수 요소인 근전도 신호의 정확한 특징점 추출을 위하여 근전 신호의 진폭 특성을 고려하는 절대차분평균치(DAMV : Difference Absolute Mean Value)와 평균절대값(MAV : Mean Absolute Value)을 구한다[1][3][4]. 또한, 본 논문에서는 동작에 대한 근전 신호의 진폭 특성을 보다 명확히 구분하기 위하여 D_DAMV(Division_DAMV)와 D_MAV(Division_MAV)를 제안한다. 제안한 근전도 패턴 분류 알고리즘의 성능을 검증하기 위하여 건강한 성인 남성 4명을 대상으로 손을 쥐고 펴는 동작의 근전도 신호를 측정하여 알고리즘에 학습시킨 후, 학습에 참여하지 않은 두 동작에 대한 근전도 신호를 입력하여 동작 추정의 정확한 분류 여부를 확인한다.

2. 근전도 측정

손은 총 16-자유도(DOF : Degree Of Freedom)로 묘사되는 매우 복잡한 시스템이다. 하지만 전동 의수의 경우 자유도가 올라갈수록 의수의 무게가 무거워지며, 의수환자의 경우 물체를 잡을 수 있는 능력이 가장 중요하게 판단되어진다[6]. 이에 본 논문에서는 의수환자 등의 일상생활을 고려한 1-자유도 동작을 손을 쥐고 펴므로 정의한다. 두 가지 동작에 대한 근전도 신호를 측정하기 위하여 그림 1과 같이 피험자의 자측 손목 신근(extensor carpi ulnaris)과 자측 손목 굴근(flexor carpi ulnaris)에 체표면 전극을 부착하여 근전도를 측정한다. 근전도 신호는 movement artifacts와 aliasing을 제거하기 위하여 high-pass 필터링과 low-pass 필터링이 필요하다. 따라서 본 논문에서는 BIONOMADIX사의 MP15WSW와 BN-EMG2 앰프를 이용하여 10~500Hz 대역으로 필터링하여 두 개의 채널로 근

전도를 측정한다.

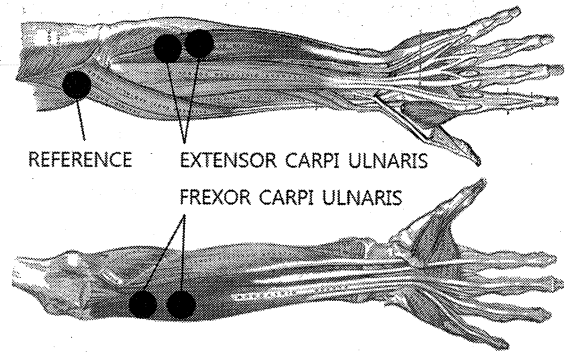


그림 1. 근전도 측정을 위한 전극의 위치

3. 근전도 패턴 분류 알고리즘

본 논문에서는 측정된 근전도 신호에서 손을 쥐고 펴는 동작 패턴을 분류하기 위하여 그림 2와 같이 근전도 패턴 분류 과정을 제안한다. 제안하는 알고리즘은 취득된 근전도 신호를 대역 통과 필터링 및 증폭 등의 전처리 작업을 거친 후, 근전도 특징점 추출을 위하여 근전 신호의 진폭 특성을 고려하는 DAMV와 MAV를 구한다. 또한, 손을 쥐고 펴는 동작의 특징점을 보다 명확히 구분하기 위하여 본 논문에서 제안하는 D_DAMV와 D_MAV를 구하고, 이를 표본 데이터 집합으로 하는 2차원 GMM으로 모델링하여 두 동작에 대한 근전도 신호의 패턴을 분류한다.

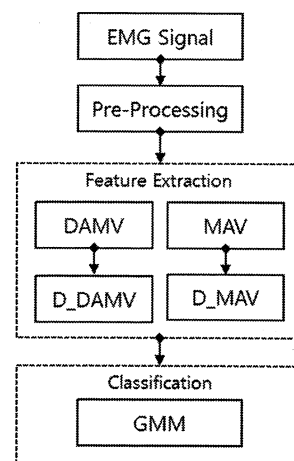


그림 2. 근전도 패턴 분류 과정

3.1 특징점 추출

푸리에 변환(fourier transform)은 생체 신호 안에

담긴 주파수 영역의 정보를 분석할 수 있기 때문에 생체신호 분석에 많이 사용되고 있다. 하지만 푸리에 변환은 기본적으로 분석되는 신호가 안정적이어야 한다는 가정을 만족시켜야 하며, 이는 비안정적인 신호인 생체신호의 분석에 적합하지 않고, 또한 계산량이 많아진다는 단점이 있다[7]. 이에 최근의 연구에서는 신호의 진폭 특성을 고려한 MAV, DAMV, 제곱평균제곱근(RMS) 등의 기법을 적용하여 근전도 신호의 특징을 파악한다. 본 논문에서는 DAMV와 MAV를 구하여 근전도 신호의 특징점을 추출한다.

DAMV는 근전도 신호의 절대차분평균을 나타내는 특징으로 일정시간 동안의 신호의 절대값을 적분한 것이며 식 (1)로 정의된다[1][3].

$$DAMV = \frac{1}{N-1} \sum_{i=2}^N |x(i) - x(i-1)| \quad (1)$$

여기에서 x 는 측정된 근전도 신호이며, i 는 샘플의 순서, N 은 샘플의 수를 나타낸다.

MAV는 근전도 신호의 평균절대값을 나타내는 특징으로 moving 윈도우를 이용하여 계산되며 식 (2)로 정의된다[4].

$$MAV = \frac{1}{S} \sum_1^S |f(s)| \quad (2)$$

여기에서 S 는 윈도우의 길이이며, $f(s)$ 는 윈도우 내의 데이터를 나타낸다.

하지만 DAMV와 MAV를 이용하여 근전도 신호의 패턴을 인식시키면 그림 3과 같이 손을 편 상태의 신근과 손을 쥘 상태의 굴근의 진폭 특성, 손을 편 상태의 굴근과 쥘 상태의 신근의 진폭 특성이 오버랩(overlap)되는 등 두 동작사이의 특징점이 정확하게 구별되지 않을 수 있는 가능성이 존재한다.




그림 3. 동작에 따른 신근과 굴근 진폭 특성의 모호성

이에 본 논문에서는 신근과 굴근의 진폭 특성의 구분을 보다 명확하게 하기 위하여 D_DAMV와 D_MAV를 제안하고 다음과 같이 정의한다.

$$D_DAMV = \frac{DAMV_{Flexor}}{DAMV_{Extensor}} \quad (3)$$

$$D_MAV = \frac{MAV_{Flexor}}{MAV_{Extensor}} \quad (4)$$

식 (3)과 (4)는 일반적으로 손을 쥐는 동작에서는 굴근의 진폭이 신근과 비교하여 우세하고 손을 펴는 동작에서는 반대의 특징이 나타난다는 현상을 이용한다. 손을 쥐고 펴는 두 동작에서 평균적으로 손을 쥘 때, D_DAMV와 D_MAV가 1보다 큰 값으로 결정되고, 펼 때, 두 특징 값이 1보다 작은 값으로 결정되어 두 동작에 대한 근전도 진폭 특성을 명확히 한다.

3.2 GMM을 이용한 패턴 분류

GMM은 주어진 표본 데이터 집합의 분포 밀도를 단 하나의 확률밀도함수로 모델링하는 방법을 개선한 밀도 추정 방법으로 복수 개의 가우시안 확률밀도함수로 데이터의 분포를 모델링하는 방법이다. 이는 화자 인식(speaker recognition) 분야에서 매우 뛰어난 패턴 인식기법으로 최근 몇 년간 검증되어 왔다[8]. 본 논문에서 GMM을 동작에 대한 근전도 분류에 사용한 이유는 GMM이 화자 검증 및 확인 분야에 매우 적합한 장점을 보여 왔고, 화자 검증 및 확인을 위한 패턴 인식기법에서 발생하는 다양한 문제들이 인간의 동작에 대한 근전도 분류에서 발생하는 문제들과 매우 유사하기 때문이다[9]. GMM은 단일한 가우시안 모델로는 도저히 모델링할 수 없는 복수개의 중심점을 가지는 1차원 데이터뿐만 아니라 그림 4와 같이 2차원 데이터에 대하여 견고하게 모델링이 가능하다.




그림 4. 2차원 데이터에 대한 GMM 모델링

최종적인 전체 확률밀도함수는 M개의 가우시안 확률밀도함수의 선형결합으로 식 (5)와 같이 정의된다.

$$p(x|\theta) = \sum_{i=1}^M p(x|\omega_i, \theta_i) P(\omega_i) \quad (5)$$

여기서, $p(x|\omega_i, \theta_i)$ 는 데이터 x 에 대하여 ω_i 번째 성분 파라미터 θ_i 로 이루어진 확률밀도함수를 의미하며, $P(\omega_i)$ 는 혼합 가중치(mixture weight)로 각 확률밀도함수의 상대적인 중요도를 의미한다. 이렇게 모델링된 모델의 보다 나은 패턴 인식 및 분류를 위하여 베이즈(Bayes) 분류를 수행한다.

4. 실험 및 결과

4.1 실험 방법

본 논문에서 제안한 근전도 패턴 분류 알고리즘의 성능을 검증하기 위하여 4명의 건강한 20~30대 남성을 대상으로 실험을 실시하였다. 각 피험자는 자측 손목 신근과 자측 손목 굴근에 체표면 전극을 부착한 후, 3초간 손을 쥐고 2초간 쉬고 3초간 손을 펴고 2초간 쉬는 동작을 2분 동안 반복하였다. 이를 하나의 실험 세트로 하여 각 피험자별 총 5세트를 반복하여 그림 5와 같은 근전도 신호를 취득한 후, 이를 제안한 근전도 패턴 분류 알고리즘에 피험자별 근전도 패턴을 학습시킨다.




그림 5. 취득된 근전도 Raw 데이터

패턴 분류 알고리즘의 동작 추정 성능을 검증하기 위하여 모든 피험자는 24시간이 지난 후, 다시

위의 과정을 반복하여 총 5세트의 실험을 실시하였고, 여기서 취득된 근전도 데이터를 피험자별로 학습된 근전도 패턴 분류기에 입력하여 제안한 알고리즘의 동작 추정의 패턴 분류 성능을 검증하였다.

4.2 실험 결과

본 논문에서는 근전도 신호의 특징점 추출을 위하여, 신호의 진폭 특성을 고려한 DAMV와 MAV 사용하였다. 하지만, 3.1절에서 언급하였듯, 손을 편 상태의 신근과 손을 쥘 상태의 굴근의 진폭 특성, 손을 편 상태의 굴근과 쥘 상태의 신근의 진폭 특성이 오버랩 되는 등 DAMV와 MAV는 두 동작사이의 특징점이 정확하게 구별되지 않을 수 있는 가능성이 존재한다. 이에 본 논문에서는 이를 개선한 D_DAMV와 D_MAV를 사용한다. 그림 6은 임의의 실험 대상자 1인의 손을 편 상태의 신근과 손을 쥘 상태의 굴근의 DAMV를 구하여 진폭 특성이 오버랩 되는 구간을 보인다. 그래프의 x축은 식 (1)에 의해 구해진 DAMV 값이고, y축은 해당되는 DAMV 값의 발현 빈도수이다. 예를 들어 손을 쥘 상태의 굴근의 DAMV 값의 범위가 0.2에서 0.35의 구간에서 총 7번의 손을 쥐는 동작에 대한 DAMV 값이 손을 편 상태와 오버랩 되어 근전도 패턴 분류의 어려움을 높일 수 있음을 보여준다.




그림 6. DAMV에서 진폭 특성의 오버랩 현상

그림 7은 임의의 실험 대상자 1인의 손을 편 상태와 쥘 상태의 근전도 신호의 진폭 특성을 본 논문에서 제안한 D_DAMV와 D_MAV로 구하여 그 값의 분포를 나타낸 그림이다. 그림에서 나타나듯 손을 쥘 상태와 편 상태의 진폭 특성이 명확히 구분되어 두 동작에 대한 근전도 패턴 분류의 정확성을 기대할 수 있다. 또한 한 명의 피험자를 제외한

모든 피험자의 근전 신호 진폭 특성이 그림 7과 같이 100% 명확히 구분되어 본 논문에서 제안한 D_DAMV와 D_MAV의 우수성을 확인하였다.




그림 7. D_DAMV와 D_MAV에서 근전도 신호 특성의 분포

그림 8은 측정된 근전도 데이터에서 본 논문에서 제안한 D_DAMV와 D_MAV를 구한 후, 이를 표본 데이터 집합으로 GMM을 이용하여 두 동작에 대한 패턴의 분포를 학습시킨 결과를 보인다.




그림 8. 동작에 대한 패턴 학습 결과

학습을 통해 구성된 근전도 패턴에 학습에 참여하지 않은 근전도 신호를 입력하여 각 동작에 대한 동작 추정을 위한 패턴 분류의 정확성을 판단하였다. 그림 9는 본 논문에서 제안한 GMM 기반 근전도 패턴 분류 알고리즘에 표본 데이터 집합으로 DAMV와 MAV를 사용한 경우와 D_DAMV와 D_MAV를 사용한 경우 패턴 분류의 정확성을 비교하였다. DAMV와 MAV를 사용하여 GMM에 동작 패턴을 학습시킨 결과 약 76.46%의 정확도로 입력된 근전도 신호에서 동작 패턴을 정확히 분류하였고, D_DAMV와 D_MAV를 이용하여 동작 패턴을 학습시킨 결과 약 99.79%의 정확도로 동작 추정이 가능함을 확인하였다. 그림 10은 각 피험자별 동작 추정을 위한 패턴 분류 결과를 보인다.




그림 9. 패턴 분류 알고리즘의 정확도

본 논문에서 제안한 D_DAMV와 D_MAV를 이용한 GMM기반 근전도 패턴 분류 알고리즘의 경우 기존의 DAMV와 MAV를 이용한 근전도 패턴 분류 결과와 비교하여 동작 추정을 위한 패턴 분류의 정확도가 약 76.46%에서 99.79%로 월등히 향상됨을 알 수 있다. 또한 기존의 연구들과 비교하여 실험 프로토콜 등의 차이로 정확한 비교는 어려우나, DAMV를 이용한 k-NN 알고리즘 기반 근전도 패턴 분류에 관한 연구의 정확도가 약 84.9%[3], MAV를 이용한 SVM 알고리즘 기반 근전도 패턴 분류에 관한 연구의 정확도가 약 99%[4]로 본 논문에서 제안한 근전도 패턴 분류 알고리즘 성능의 신뢰성과 우수성을 확인하였다.

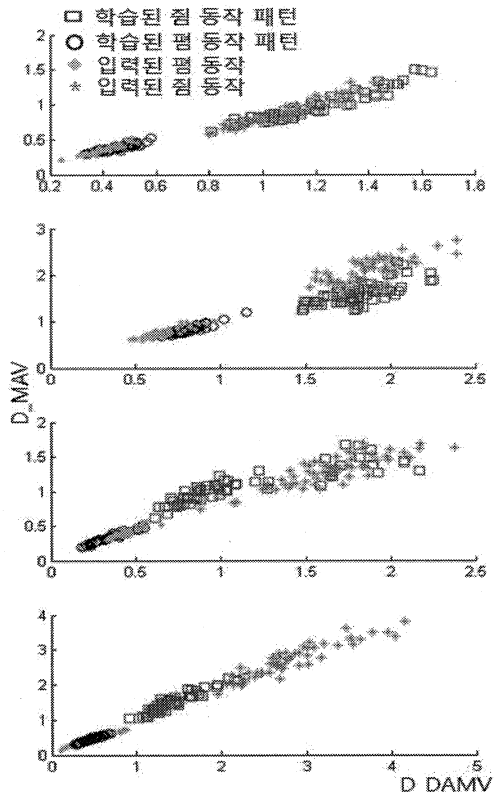


그림 10. 피험자별 동작에 대한 패턴 분류 결과

5. 결론

본 논문에서는 의수환자의 일상생활을 고려한 1-자유도 동작을 손을 쥐고 펴므로 정의하고, 두 동작에 대한 근전도 패턴 분류를 위한 GMM 기반의 근전도 패턴 분류 알고리즘을 제안하였다. 또한, 본 논문에서는 동작에 대한 근전 신호의 진폭 특성을 보다 명확히 구분하기 위하여 기존의 근전도 신호 특징점 추출 기법인 DAMV와 MAV를 개선한 D_DAMV와 D_MAV를 제안하였다. 제안한 근전도 패턴 분류 알고리즘의 성능을 검증하기 위한 실험 결과, 기존의 DAMV와 MAV를 표본 데이터 집합으로 사용하여 GMM에 모델링한 경우 약 76.46%의 정확도로 근전도 패턴 분류에 성공하였고, 본 논문에서 제안한 D_DAMV와 D_MAV를 사용한 결과 약 99.79%의 정확도로 동작에 대한 근전도 패턴 분류에 성공하였다.

향후 연구에서는 보다 다양한 동작을 추정하는 근전도 패턴 분류 알고리즘으로 개선할 예정이며, 실제 전동 의수에 사용자의 의도를 정확히 반영하여 동작 명령을 전달할 수 있는 실시간, 신뢰성 있는 알고리즘으로 개선할 예정이다.

참고 문헌

[1] 김종성, 김흥기, 정혁, 김기홍, 임선희, 손육호, “생체신호 기반 사용자 인터페이스 기술”, 전자통신동향분석, 제20권, 제4호, ETRI, pp.67-81, 2005. 8.

[2] 최영진, 유현재, “표면 근전도 신호처리 기반 인간 팔 동작의 추종 알고리즘”, 제어·자동화·시스템공학 논문지, 제13권, 제8호, pp.769-776, 2007. 8

[3] K.S. Kim, H.H. Choi, C.S. Moon and C.W. Mun, “Comparison of k-nearest neighbor, quadratic discriminant and linear discriminant analysis in classification of electromyogram signals based on the wrist-motion directions”, *Current Applied Physics*, vol.11, issue.3, pp.740-745, 2011. 5.

[4] Ahmet Alkan, and Mucahid Gunay, “Identification of EMG signals using discriminant analysis and SVM classifier”, *Expert System with Applications*, vol.39, issue.1, pp.44-47, 2012. 1.

[5] G.S. Sawicki, K.E. Gordon, and D.P. Ferris,


“Powered Lower Limb Orthoses: Applications in Motor Adaptation and Rehabilitation”, *International Conference on Rehabilitation Robotics*, pp.206-211, 2005. 6.

[6] 구광민, 장평훈, 손민균, 신지현, “뇌졸중 환자의 일상생활 동작 훈련을 위한 1자유도 손 재활 로봇 설계”, 제어-자동화 시스템공학 논문지, 제16권, 제9호, pp.833-839, 2010. 9.

[7] 조영진, 김정룡, “근육 피로도 분석 시 MPF 파라미터 해석의 한계점”, *대한인간공학회, 학술대회 논문지*, pp.67-72, 2008.

[8] D. A. Reynolds, T. F. Quatieri, and R. B. Dunn, “Speaker verification using adapted Gaussian mixture models”, *Digital Signal Process*, vol.10, no.1, pp.19-41, 2000. 1.

[9] Y.H. Huang, K.B. Englehart, B. Hudgins and A.D.C. Chan, “A Gaussian Mixture Model Based Classification Scheme for Myoelectric Control of Powered Upper Limb Prostheses”, *IEEE Transactions on Biomedical Engineering*, vol.52, no.11, pp.1801-1811, 2005.



송영록

2001년 2월 인천대학교 정보통신공학과 졸업 (학사)

2003년 8월 인천대학교 대학원 정보통신공학과 졸업 (석사)

2009년 2월 인천대학교 대학원 정보통신공학과 졸업 (박사)

2009년 7월-현재 인하대학교 정보전자공동연구소 연구교수

관심분야 : Ubiquitous Computing, Semantic Web, Bio-Signal Processing




김서준

2012년 2월 인하대학교 전자공학과 졸업 예정 (학사)

2012년 3월 인하대학교 대학원 전자공학과 입학 예정 (석사)

관심분야 : Bio-Signal Processing, Pattern Classification




정 의 철

2011년 2월 인하대학교 전
자공학과 졸업 (학
사)

2011년 3월 - 인하대학교
대학원 전자공학과
석사과정

관심분야 : Bio-Signal Processing, Neural
Engineering



이 상 민

1987년 2월 인하대학교 전
자공학과 졸업 (학
사)

1989년 2월 인하대학교 대
학원 전자공학과 졸
업 (석사)

2000년 2월 인하대학교 대학원 전자학과 졸업
(박사)

2006년 9월 - 현재 인하대학교 전자공학과 부교
수

관심분야 : Bio-Signal Processing,
Psycho-Acoustic, Brain-Machine
Interface