



저작자표시-비영리-변경금지 2.0 대한민국

이용자는 아래의 조건을 따르는 경우에 한하여 자유롭게

- 이 저작물을 복제, 배포, 전송, 전시, 공연 및 방송할 수 있습니다.

다음과 같은 조건을 따라야 합니다:



저작자표시. 귀하는 원저작자를 표시하여야 합니다.



비영리. 귀하는 이 저작물을 영리 목적으로 이용할 수 없습니다.



변경금지. 귀하는 이 저작물을 개작, 변형 또는 가공할 수 없습니다.

- 귀하는, 이 저작물의 재이용이나 배포의 경우, 이 저작물에 적용된 이용허락조건을 명확하게 나타내어야 합니다.
- 저작권자로부터 별도의 허가를 받으면 이러한 조건들은 적용되지 않습니다.

저작권법에 따른 이용자의 권리는 위의 내용에 의하여 영향을 받지 않습니다.

이것은 [이용허락규약\(Legal Code\)](#)을 이해하기 쉽게 요약한 것입니다.

[Disclaimer](#)

2021년 2월  
석사학위논문

근전도 스펙트로그램 기반 사용자  
인식을 위한 잡음 제거 및 데이터  
생성에 관한 연구

조선대학교 대학원

전자공학과

김재명

# 근전도 스펙트로그램 기반 사용자 인식을 위한 잡음 제거 및 데이터 생성에 관한 연구

A study on noise elimination and data generation for user  
recognition based on EMG spectrogram

2021년 2월 25일

조선대학교 대학원

전자공학과

김 재 명

# 근전도 스펙트로그램 기반 사용자 인식을 위한 잡음 제거 및 데이터 생성에 관한 연구

지도교수 반 성 범

이 논문을 공학석사학위신청 논문으로 제출함.

2020년 10월

조선대학교 대학원

전자공학과

김 재 명

김재명의 공학석사학위논문을 인준함

위원장 조선대학교 교수 김윤태

위원 조선대학교 교수 곽근창

위원 조선대학교 교수 반성범



2020년 11월

조선대학교 대학원

# 목 차

제1장 서론 .....	1
제1절 연구 배경 및 목적 .....	1
제2절 연구 내용 및 방법 .....	3
제2장 기존 근전도 신호를 이용한 기술 분석 .....	6
제1절 동작인식을 위한 행동 패턴 분석 .....	6
제2절 근전도 신호를 이용한 사용자 인식 연구 .....	9
제3장 제안하는 근전도 스펙트로그램 기반 사용자 인식 .....	14
제1절 잡음제거 및 데이터 증가를 위한 전처리 기술 .....	15
제2절 근전도 스펙트로그램을 이용한 사용자 인식 .....	20
제4장 실험 결과 및 분석 .....	25
제1절 실험 방법 .....	25
제2절 근전도 스펙트로그램을 이용한 사용자 인식 성능 분석 .....	27
제3절 사용자 인식 성능 결과 비교 .....	31
제5장 결론 .....	34
참고문헌 .....	36

## 표 목차

표 1. 근전도 신호를 이용한 활용 연구 .....	7
표 2. 근전도 오픈 데이터베이스 .....	10
표 3. 시간 영역 특징 추출 방법에 대한 수식 .....	12
표 4. 근전도 신호 데이터베이스 구성 .....	26
표 5. 한 주기 동작에 대해 생성된 근전도 신호 유사도 .....	26
표 6. 전처리 전·후 사용자 인식 성능 .....	27
표 7. 네트워크별 사용자 인식 성능 .....	30
표 8. 근전도 신호 기반 사용자 인식 성능 비교 .....	31

## 그림 목차

그림 1. 생체정보 사용자 인식 기반 인터넷 서비스 .....	1
그림 2. 다양한 근육을 이용한 근전도 신호 취득 .....	2
그림 3. Matching pursuit을 이용한 신호 생성 .....	4
그림 4. Short Time Fourier Transform 분석 방법 .....	5
그림 5. 근전도 신호 .....	6
그림 6. 근전도 신호 기반 사용자 인식 시스템 .....	9
그림 7. 제안하는 근전도 스펙트로그램 기반 사용자 인식 흐름도 .....	14
그림 8. 잡음 제거 및 데이터 증가 전처리 과정의 흐름도 .....	16
그림 9. 한 동작 주기 신호 분할 .....	16
그림 10. 불규칙한 근전도 신호 .....	17
그림 11. 휴식신호 제거 과정 .....	18
그림 12. 시간 도메인을 이용한 12채널 결합 .....	19
그림 13. 근전도 신호의 스펙트로그램 변환 .....	20
그림 14. STFT의 Overlap 적용 .....	21
그림 15. STFT Window length 변화에 따른 근전도 스펙트로그램 .....	21
그림 16. CNN 네트워크 구조 .....	22
그림 17. Densely Connected 네트워크 구조 .....	23
그림 18. MobileNet-v1과 MobileNet-v2 네트워크 구조 .....	24
그림 19. Ninapro DB2의 7가지 손동작 .....	26
그림 20. 1차원 근전도 신호를 이용한 사용자 인식 .....	28
그림 21. Window length의 변화에 따른 인식 성능 .....	28
그림 22. 잡음 및 휴식 신호 제거 후 사용자 인식 .....	29



그림 23. 학습 데이터 증가 후 사용자 인식 .....30

그림 24. 사용자 인식 성능 .....32

## ABSTRACT

### A study on noise elimination and data generation for user recognition based on EMG spectrogram

Kim, Jae Myung

Advisor : Prof. Pan, Sung Bum, Ph.D.

Department of Electronic Engineering

Graduate School of Chosun University

Recently, user recognition methods have been attracting attention amidst the rise of Internet services that require a high level of security, such as e-commerce using mobile devices. Among existing password input methods, recognition methods that utilize a part of the physical body are being used; however, they are limited in that body information is vulnerable to hacking and cannot be changed. Accordingly, as a next-generation user recognition method, researchers are studying electromyography(EMG) signals, which are electrical signals generated inside a human body that possesses unique individual features. EMG involves measuring an individual's unique muscular strength activated over time as digital signals, thus giving it the

advantage of generating different signal patterns. However, the previously opened EMG database consists of data obtained based on behavior pattern recognition, with a highly insufficient number of people. Moreover, it is difficult to repeatedly obtain consistent signals for each movement and there are not enough repetitions for each movement, thereby limiting the application of EMG signals to user recognition. Therefore, the problems of insufficient EMG data and irregular signals must be solved, and research on multidimensional feature transformation, including frequency features over time, is required.

This thesis proposes a method of removing rest state signals such as noise and generating data. First, the EMG signal are divided into each frame and the average energy of the frame is set as the threshold. If less than the threshold value, then it is determined to be a rest state and the irregular rest signal included in the EMG signal is removed. Next, to supplement the insufficient data, various signals can be generated from a small quantity of data, and EMG signals are generated using matching pursuit, which can quickly generate signals through simple operations. Finally, to verify the user recognition performance, the one-dimensional EMG signals are transformed into spectrograms from which multidimensional features can be extracted, which are then applied to a convolutional neural network. The proposed system consists of a data composition process, data preprocessing and normalization process, spectrogram transformation process, and final classification process. According to the experimental results, the user recognition performance after removing rest signals as proposed in this study was 85.4%, an improvement of over 6% compared to using the original

signals, and the performance after supplementing the insufficient data through data generation was 96.1%, an improvement of over 10%. As opposed to one-dimensional signals, the proposed method uses multidimensional features including time-frequency, supplements the insufficient data, and removes rest signals included in the EMG signals, thereby improving the user recognition performance.

# 제1장 서론

## 제1절 연구 배경 및 목적

최근 IT 발달로 일상생활에서 인터넷 서비스가 보편화됨에 따라 개인 신분을 증명하는 사용자 인식 방법이 주목받고 있다[1]. 기존의 사용자가 지정한 패스워드를 입력하는 방식 또는 특정 장치를 이용한 방법은 망각 또는 분실 및 도난의 문제가 있다. 따라서 사용자의 고유한 정보 또는 행동 특징을 이용하는 생체정보 기반 사용자 인식 기술이 부각되고 있다. 생체정보 기반 사용자 인식 기술은 개인의 고유한 특징을 추출하여 정보화시키는 방식으로 사람마다 다른 특징을 인식시켜 비밀번호 대신 사용자를 인식하는 기술이다[2].

얼굴·지문과 같은 생체정보를 이용한 사용자 인식은 전자 금융, 스마트 의료, 정보통신, 출입 통제, 헬스케어 서비스 등 그림 1과 같이 다양한 분야에서 적용되고 있다[3].

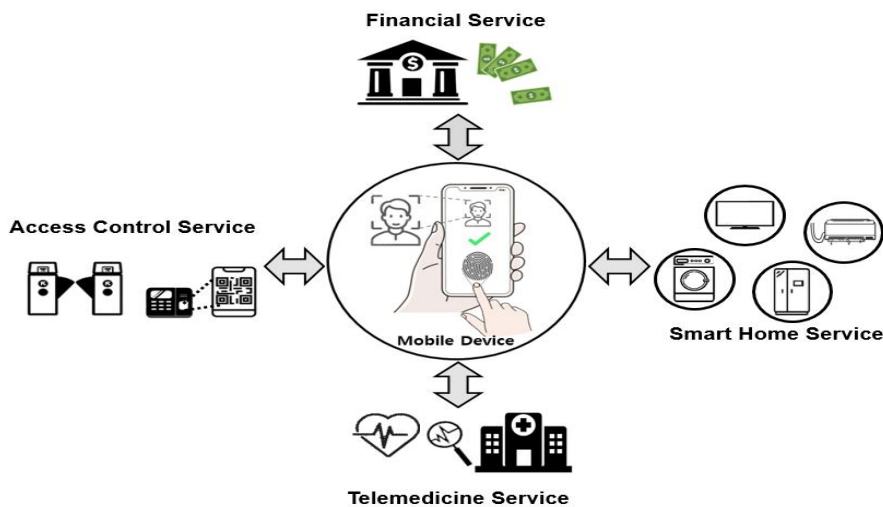


그림 1. 생체정보 사용자 인식 기반 인터넷 서비스

그러나 국내에서 3D 프린터를 이용하여 제작한 실리콘 지문으로 금융 위조사고가 발생하였으며, 사용자를 닮은 가족의 얼굴에 페이스 ID가 풀리는 문제가 발생하였다[4]. 해외에서는 독일 해커단체가 러시아 대통령 사진으로 홍채를 복제하여 해킹한 사고가 발생하였으며 가짜 손을 만들고 그 위에 정맥 인증 정보를 입혀 정맥 인증을 통과하는 사례도 발생하였다. 이러한 생체정보의 문제점을 보완하기 위해 신체 내부에서 발생하는 개인별 고유의 생체신호를 이용한 사용자 인식 기술이 주목받고 있다[5].

생체신호는 신체 내부에서 발생하여 개인의 고유한 특징을 가지는 전기적 신호이며, 대표적인 생체신호로는 근전도, 심전도, 뇌전도 등이 있다[6]. 다양한 생체신호 중 심장의 전기생리학적 요인과 심장의 위치, 크기, 신체적 조건에 의해 개인 고유의 특성을 가지는 심전도 신호를 이용한 사용자 인식 기술은 성능 개선을 위한 연구가 진행되고 있다. 그러나 심전도 신호는 해킹과 같은 문제로 인해 외부에 노출될 경우, 신호 자체를 변경할 수 없는 단점이 있다. 또한, 심전도 신호는 개인의 신체적 활동이나 측정 시간대 또는 정신적 영향에 의해 심박수 및 파형이 변하는 문제점이 있다. 이러한 단점을 보완할 수 있는 근전도 신호는 각 근육의 발달 정도에 따른 활성도와 개인간의 근육 발달 정도 등 행동학적 특징에 의해 근육에서 발생하는 신호로 개인마다 고유하게 발생하는 생체신호이다. 또한, 근전도 신호는 그림 2와 같이 취득하고자 하는 부위의 근육을 피부 표면에서 측정할 수 있어 심전도와 뇌전도보다 신호 취득이 간편하고, 사용하는 근육에 따라 서로 다른 신호 패턴을 생성하는 장점이 있다[7].



그림 2. 다양한 근육을 이용한 근전도 신호 취득

그러나 기존 근전도 신호를 이용한 사용자 인식 연구에 사용되는 데이터베이스는 인원 수 또는 각 동작의 반복 횟수가 충분하지 않다. 근전도 신호는 행동학적 특징에 의해 근육에서 발생하는 신호를 이용하여 사용자를 인식하기 때문에 각 동작을 충분한 반복 횟수로 취득할 경우 사용자 인식에 적용 가능하지만, 반복 횟수가 부족할 경우 각 동작을 인식할 수 없는 문제가 발생하여 사용자 인식에 적용할 수 없다. 예를 들어 데이터가 부족할 때 동일한 취득환경에서 취득된 데이터를 결합하여 데이터 부족 문제를 해결할 수 있다. 그러나 근전도 신호의 취득환경 설정은 취득 장비, 수행 동작, 사용한 근육, 근육 채널 수, 샘플링 속도 등 초기 취득 환경 설정 조건이 많아 동일한 조건으로 구성된 데이터를 찾기 어려워 데이터간의 결합이 불가능하다[8].

또한, 기존 근전도 기반 사용자 인식 연구들은 대부분 1차원 근전도 신호에 시간영역 특징 추출 방법을 이용하여 인식 알고리즘에 적용한 경우가 대부분이다. 그러나 근전도 신호는 시간의 흐름에 따라 특징이 변하는 연속적인 신호이며 시간 변화에 따라 일정한 근력 세기를 유지한 상태에서 반복하기 어려워 명백한 주기성을 찾기 어렵다. 즉 일정한 세기와 시간으로 취득되지 않은 1차원 근전도 신호를 시간 영역에서 분석할 경우 사용자 인식 성능을 저하시킨다[9].

따라서 1차원 근전도 신호를 이용하여 사용자 인식에 적용하기 위해 불규칙한 신호 문제를 해결하고 사용자의 행동학적 특징에 따라 취득된 1차원 근전도 신호에 시간-주파수 정보를 갖는 다차원 특징 추출을 적용하여 높은 사용자 인식 성능을 나타내는 연구가 필요하다.

## 제2절 연구 내용 및 방법

근전도 신호는 시간의 흐름에 따라 특징이 변하는 연속적인 신호이며 동일한 동작을 수행하더라도 일정한 시간과 세기로 반복하기 어려워 명백한 주기성을 찾

기 어렵다. 따라서 일정한 시간 간격으로 동작 데이터가 구성되어야하며, 시간 변화에 따른 주파수 특징을 포함한 다차원 특징 변환 과정을 통해 높은 인식 성능을 나타내야 한다. 본 논문에서는 일정하게 취득되지 않은 근전도 신호의 불규칙한 문제를 해결하기 위해 근전도 신호에 포함되어 있는 휴식상태 신호를 제거하고 신호의 크기를 동일하게 맞춰준다. 또한, 전처리된 근전도 신호는 데이터의 수를 증가시키기 위해 Matching pursuit을 이용한다[10].

Matching pursuit은 그림 3과 같이 임의의 점들을 대략적으로 생성하고 원자를 하나씩 이동시켜 원본 신호와 최소 근사 오차를 찾는 방법이다. 대표적인 데이터 생성 방법으로 뛰어난 성능을 보이는 GAN(Generative Adversarial Network) 신경망을 주로 사용한다. 그러나 기존 근전도 데이터의 수가 너무 부족하기 때문에 직접 취득한 원본 데이터 보다 많은 수의 신호를 생성하지 못하는 문제점이 있다 [11]. 따라서 근사 오차를 줄여가며 원본신호와 유사하게 생성하는 Matching pursuit을 적용하여 데이터의 수를 증가하는 방법을 제안한다.

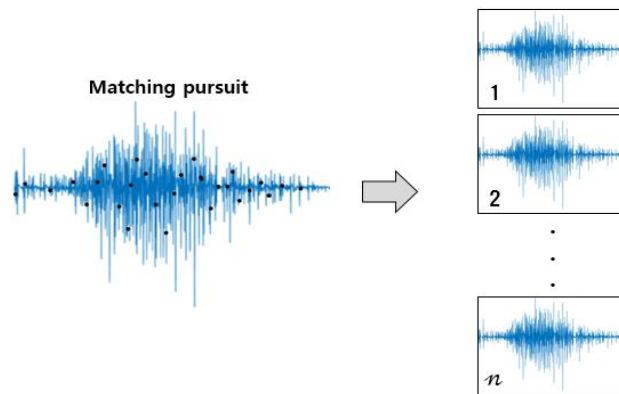


그림 3. Matching pursuit을 이용한 신호 생성

다음으로 동작을 수행할 때 발생하는 근전도 신호 데이터에 시간 및 주파수 특징 추출 방법을 이용한 사용자 인식 방법이 연구되고 있다. 그러나 근전도 신호는 시간에 따라 주파수 특징이 변하는 연속적인 신호로 단차원 특징 추출 방법보다



고차원의 특징 분석 방법으로 효율적인 분석이 필요하다. 따라서 본 논문에서는 시간-주파수 다차원 특징을 이용하여 근전도 신호를 분석한다. 전처리된 1차원 근전도 신호를 시간-주파수 영역의 2차원 특징을 추출하기 위해 STFT(Short Time Fourier Transform)를 적용하여 근전도 스펙트로그램으로 변환한다[12].

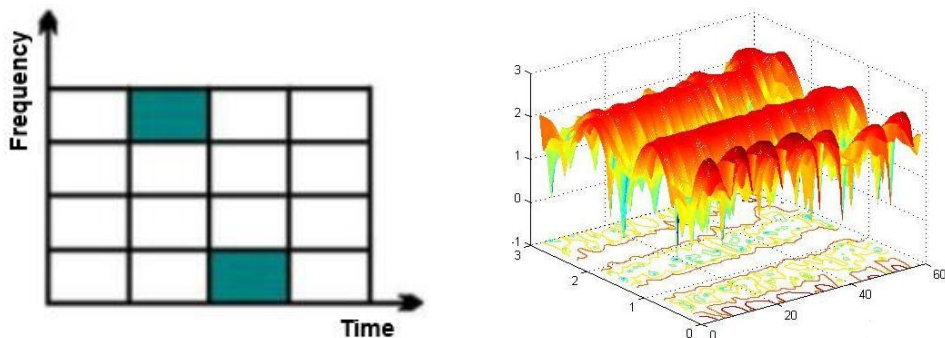


그림 4. Short Time Fourier Transform 분석 방법

STFT는 그림 4와 같이 특정 시간대의 주파수 성분을 분석할 수 있으며 근전도와 같은 연속적인 신호에서 시간-주파수의 다차원 특징을 추출할 수 있는 방법이다. 그러나 STFT의 단점으로 시간 해상도와 주파수 해상도는 동시에 향상시킬 수 없는 문제점이 있다. 따라서 STFT의 Window length 변화에 따른 시간 및 주파수 해상도를 확인하며 사용자를 보다 정확하게 인식하는 파라미터를 찾아 근전도 스펙트로그램으로 생성한다[13].

본 논문의 구성은 다음과 같다. 1장의 서론에 이어 2장에서는 기존 근전도 신호를 이용한 기술에 대해 분석한다. 3장에서는 본 논문에서 제안하는 근전도 스펙트로그램을 이용한 사용자 인식에 관해 설명한다. 4장에서는 제안하는 사용자 인식 시스템에 대한 실험방법 및 결과를 분석하고 5장에서 결론 및 향후 연구에 대해 논한다.

## 제2장 기존 근전도 신호를 이용한 기술 분석

본 장에서는 기존 근전도 신호를 이용한 행동 패턴 인식과 사용자 인식 시스템에 적용된 기술에 대해 분석한다. 근전도는 근육의 수축 정도에 따라 발생하는 전기생리학적 신호로 신체의 움직임에 의해 근 섬유에서 일어나는 전기적 신호를 의미한다. 근전도 신호는 그림 5와 같으며 근 섬유의 발달 정도에 따라 활동 전위의 크기가 비례하며, 근 섬유막에서 발생하는 전기적 신호를 취득할 수 있다.




그림 5. 근전도 신호

### 제1절 동작인식을 위한 행동 패턴 분석

근전도 신호는 표 1과 같이 행동학적 특징을 이용하여 근육 활성화 유무, 동작 제어, 수화 인식, 사용자 인식 등 다양한 분야에서 근전도 신호가 적용되고 있다. 근전도 신호는 초기에 주로 의료 목적으로 근육의 활성화 유무 판별 및 분석하는 정도로 사용되었다[14]. 신호처리와 알고리즘의 개발로 근육에서 발생하는 근전도 신호를 이용하여 수행하는 동작을 인식하기 위한 용도로 사용하였다. 절단 또는

마비 환자를 위해 근육 움직임을 인식하여 의수 및 의족 등을 제어하거나 수화와 지화를 전환근 또는 손목 주변의 근육에서 발생하는 근전도 신호를 이용하여 인식한다. 최근에는 사람마다 근육 발달 정도와 활성도가 다른 특징을 이용하여 사용자 인식 연구가 진행되고 있다.

표 1. 근전도 신호를 이용한 활용 연구

	Signal pre-processing	Feature extraction	Recognition	Performance	Field
Chen et al. [15]	Filter (Band-pass)	Feature : MAV, AR	Analysis : Linear Bayesian Classifier	Hand motion recognition : 95%	Medical field (Hand motion + EMG)
Zhang et al. [16]	Fourier Transform Filter (4th order Butter worth)	Feature : MAV, SSC, WL, RMS, HP	Analysis : ANN	Hand motion recognition : 98.7%	Medical field (Hand motion + EMG)
Haris et al. [17]	Filter (3th order butter worth)	Feature : MAV, RMS, Variance, Mobility, Complexity, ZC, WL	Analysis : KNN, ANN	Finger motion recognition KNN : 86% ANN : 93%	Control field (Finger motion + EMG)
Leon et al. [18]	Filter (Band-pass)	Feature : AR, RMS, DFT	Analysis : SVM	Hand motion recognition : 97.23%	Control field (Hand motion + EMG)
Savur et al. [19]	Filter (Band-pass, Notch)	Feature : MAV, MMAV, SSI, RMS, AAC, MFL, Log Detector, Minimum, Maximum, Standard Deviation	Analysis : SVM	Signature recognition : Offline : 91% Real-Time : 82,3%	Visual language field(sign language + EMG)
Divya et al. [20]	Filter (Band-pass)	Feature : MAV, SSI, STD, RMS, AAC, MAX, MIN, P	Analysis : SVM	Signature recognition : 90%	Visual language field(sign language + EMG)
Shiohi et al. [21]	Fast Fourier Transform Filter (High-pass, Notch)	Feature : CNN	Analysis : CNN	Hand motion recognition : 94.6% Personal authentication : 95%	User Authentication field(Hand motion + EMG)
Lee et al. [22]	Filter (Band-pass, Notch)	Feature : RMS, MAV, DF, IEMG	Analysis : LDA	Recognition using all muscles : 65.8% Recognition using selected muscles : 93%	User Authentication field(Walk motion + EMG)

재활치료는 치료사가 구두 및 시각적 행동으로 환자의 움직임을 보조하고 안내하며 치료한다. 로봇 장치를 이용해 근육 활성화 패턴을 분석하고 치료를 보조하면 편리하고 효율적인 치료가 가능하다. 환자의 상태를 진단하기 위해 인터페이스의 안내에 따라 일정한 속도로 동일한 궤적의 동작을 반복 수행할 때 발생하는 근육 활성화 신호에 대해 공통 패턴을 찾고 유사도를 결정하여 환자의 상태를 진단한다[23].

또한, 근육에서 발생하는 근전도 신호를 이용하여 행동 패턴을 인식하는 연구가 진행되어왔다. 절단 또는 마비 환자 등 신체적 활동에 제약이 있는 사람들을 위하여 행동 패턴을 인식하여 휠체어, 의수 및 의족 등을 제어하기 위해 손목 동작의 데이터를 취득하고 전처리된 데이터는 시간 영역 특징 추출 방법으로 특징 추출 후 LDA 분류기를 사용하여 96%의 성능으로 손목 동작을 분류하였다[24]. 청각 장애가 있는 사람들이 사용하는 의사소통 방법인 수화와 지화를 수행할 때 전완근 또는 손목 주변의 근육에서 발생하는 근전도 신호를 이용하여 수화나 지화를 인식하기 위해 지화를 수행할 때 발생하는 근전도 데이터를 취득하고 전처리된 데이터는 CNN을 통해 특징 추출 후 100%의 정확도로 지화 동작을 인식하였다[25]. 또한, 행동 패턴을 이용하여 전자기기의 인터페이스를 제어하는 연구가 이뤄지고 있어 다양한 응용 분야에서 일반인에게도 활용할 수 있는 연구가 진행되고 있다[26].

최근에는 근육에 따라 서로 다른 신호 패턴을 생성하며 근육 발달 정도와 활성화도의 차이로 개인마다 고유한 특징을 가지는 근전도 신호를 이용한 사용자 인식 연구가 진행 중이다. 보행을 할 때 발생하는 근전도 신호와 보폭, 속도 등의 데이터를 취득하고 전처리된 데이터는 시간 영역 특징을 추출한 후 선형 판별 분석 분류기에 의해 93%의 정확도로 최종 인식하였다[22]. 이 외에도 손동작을 수행할 때 발생하는 근전도 신호와 전완근의 둘레 두 가지 특징을 이용하거나, 근전도 신호와 심전도 신호 등 최소 두 가지 이상의 특징을 인증 요소로 사용하는 멀티팩터

인식 연구가 진행되고 있다[27][28].

## 제2절 근전도 신호를 이용한 사용자 인식 연구

손동작 및 걸음걸이 등 행동학적 특징을 추출하여 사용자를 인식하는 사용자 인식 연구가 활발히 진행 중이다. 근전도 신호를 이용한 사용자 인식 시스템의 기술적 구조는 그림 6과 같다. 1단계는 근전도 신호를 취득 또는 오픈 Dataset을 이용하여 데이터를 구성하는 과정, 2단계는 원 신호에 포함된 잡음을 제거하기 위한 전처리 및 정규화 과정, 3단계는 전처리된 신호에서 특징을 추출하는 과정, 4단계는 분류기를 이용하여 사용자 인식 성능을 평가하는 과정이다.

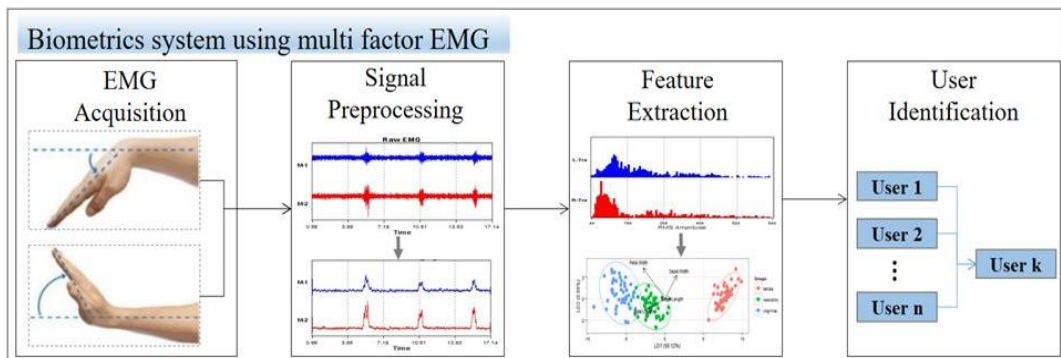


그림 6. 근전도 신호 기반 사용자 인식 시스템

사용자 인식을 위해 가장 먼저 근전도 데이터를 구축한다. 근전도 데이터는 사용하고자 하는 근육, 동작으로 데이터를 구성한다. 공개된 근전도 데이터 DB로는 표 2와 같이 손 또는 손목 동작을 이용한 공용 DB로 Ninapro2와 sEMG for Basic Hand Movements Data Set 등이 있으며, 다리 동작을 이용한 공용 DB로는 EMG Benchmark Datasets for Bilateral Lower-Limb이 있다[29-32].

표 2. 근전도 오픈 데이터베이스

데이터명	채널	인원	동작	비고
sEMG Basic Hand Movements Upatras	2ch	5명	손 움직임 6개	<ul style="list-style-type: none"> <li>• 각 동작 6초 지속</li> <li>• 각 동작 30회 반복</li> </ul>
EMG(Dr. Rami Khushaba)	2ch	8명	손가락 움직임 10개	<ul style="list-style-type: none"> <li>• 각 동작 5초 지속</li> <li>• 각 동작 6회 반복</li> </ul>
Ninapro DB2	12ch	40명	손과 손목 움직임 49개	<ul style="list-style-type: none"> <li>• 각 동작 5초 지속</li> <li>• 각 동작 6회 반복</li> </ul>
Benchmark Datasets for Bilateral Lower-Limb	7ch	10명	다리 동작 3개	<ul style="list-style-type: none"> <li>• 각 동작 3회 반복</li> </ul>

그러나 근전도 DB의 데이터 부족 문제는 꾸준히 제기되었다. 취득된 인원 수가 부족하거나 각 동작을 반복 하는 횟수가 부족한 문제점이 있다. 이러한 문제를 해결하기 위해 여러 DB를 결합하는 방법이 있지만 근전도 DB는 초기 취득 조건으로 동작, 근육 채널, 동작 반복 횟수, 동작 지속 시간 등 취득 조건이 모두 다르므로 여러 근전도 DB를 결합하기에 어려움이 있다. 또한 한 동작 주기의 근전도 신호를 정해진 윈도우로 잘라서 데이터를 증가시킬 경우 동일한 동작이더라도 시간에 따른 주파수 성분이 달라 동일한 동작 신호로 판단하기 어려운 문제가 있다 [8].

다음으로 구축된 근전도 DB는 다양한 환경에서 발생하는 잡음을 포함하고 있어서 전처리 과정을 거쳐야 한다. 제거해야 하는 잡음으로는 측정 장비에서 발생하는 전력선 잡음 60Hz 대역의 변조파와 광대역의 백색 잡음, 일회용 전극의 각 성능과 기능의 차이로 인해 생기는 잡음, 인체 생리학적 간섭에 의한 잡음, 근육 세포조직의 특성에 의한 잡음 등이 있다. 이러한 잡음을 제거하기 위해 전처리 과정이 필요하며 잡음 제거 방법으로 주파수 분석을 통해 잡음을 확인하고 고역통과, 저역통과, 대역통과, 버터워스[33], 노치 필터[34] 등을 사용하여 잡음을 제거한다.

전처리를 마친 근전도 신호는 특징을 추출한다. 특징 추출은 크게 시간 영역과 주파수 영역, 시간-주파수 영역으로 나뉜다. 시간 영역 특징 추출 방법은 MAV(Mean Absolute Value), SSC(Slope Sign Change), RMS(Root Mean Square), WL(Waveform Length), VAR(Variance), IEMG(Integrated EMG), ZC(Zero Crossing) 등이 있으며 각각의 특징에 대한 수식은 다음 표 3과 같다[35].

표 3. 시간 영역 특징 추출 방법에 대한 수식

특징명	수식
MAV	$\frac{1}{N} \sum_{n=1}^N  x_n .$
SSC	$\sum_{n=2}^{N-1} [f[(x_n - x_{n-1}) \times (x_n - x_{n+1})]],$ $f(x) = \begin{cases} 1, & \text{if } x \geq \text{threshold} \\ 0, & \text{otherwise.} \end{cases}$
RMS	$\sqrt{\frac{1}{N} \sum_{n=1}^N x_n^2}$
WL	$\sum_{n=1}^{N-1}  x_{n+1} - x_n $
VAR	$\frac{1}{N-1} \sum_{n=1}^N x_n^2$
IEMG	$\sum_{n=1}^N  x_n $
ZC	$\sum_{n=1}^{N-1} [sgn(x_n \times x_{n+1}) \wedge  x_n - x_{n+1}  \geq \text{threshold}],$ $sgn(x) = \begin{cases} 1, & \text{if } x \geq \text{threshold} \\ 0, & \text{otherwise} \end{cases}$

그러나 근전도 신호는 시간의 흐름에 따라 특징이 변하는 연속적인 신호이며 동일한 동작을 수행하더라도 일정한 시간과 세기로 반복하기 어려워 명백한 주기성을 찾기 어렵다. 주파수 영역의 대표적인 특징 추출 방법으로 FFT(Fast Fourier Transform)가 있다. FFT는 시간 영역의 신호를 주파수 영역으로 변환한다. 그러나 FFT는 시간적인 한계에 대한 단점으로 자신이 알고 싶은 시점에서의 주파수 성분을 파악할 수 없다[36].

시간-주파수 영역의 대표적인 특징 추출 방법으로 STFT(Short Time Fourier Transform)를 사용한다[12]. STFT는 FFT의 시간적인 한계를 보완한 방법으로 원하는 Window length를 정하여 시간에 대해 구간을 짧게 나누고 나누어진 여러 구간을 각각 푸리에 변환한다. 따라서 STFT는 시간 영역에 따른 주파수 성분을 분석하기 때문에 시간의 흐름에 따라 특징이 변하는 근전도 신호를 STFT에 적용하여 시



간-주파수 다차원 특징으로 분석 하는 것이 시간 및 주파수 특징보다 더욱 효율적인 분석 방법으로 입증되었다[9].

근전도 신호의 분류를 위해 사용되는 방법은 머신러닝과 딥러닝이 있다. 머신러닝은 작업을 대신 수행할 기계를 학습시켜 원하는 결과를 얻는 기술이다. 머신러닝은 크게 지도학습과 비 지도학습 두 가지로 나눌 수 있다. 지도학습은 정답이 존재하는 상태에서 학습을 시켜 예측해 나가는 방법으로 대표적인 지도학습 방법에는 SVM이 있다[37]. 비 지도학습은 정답이 존재하지 않고 유사한 패턴을 군집화하여 찾는 방법이다. 대표적인 비 지도학습 방법으로는 클러스터링을 이용한 군집 분석의 k-최근접 이웃 알고리즘이 있다. 이외에도 사용하는 분류기로는 결정 트리 학습법, 랜덤 포레스트, 주성분분석[38], 선형판별분석[39] 등이 있다. 딥러닝은 인공지능망에 기반을 둔 기계학습 기술의 한 종류로 신경망의 계층을 깊게 구성하여 학습이 잘 이루어지지 않는 문제를 해결한 기술이다. 딥러닝의 대표적인 네트워크로 CNN(Convolutional Neural Networks)과 LSTM(Long Short Term Memory) 등이 있다. LSTM은 RNN의 장기 의존성 문제점을 해결한 알고리즘으로 시간적 특성을 갖는 데이터에서 많이 활용하고 있다. CNN은 가장 널리 사용되는 딥러닝 방법으로 이미지에서 패턴을 찾는 데 유용한 알고리즘이다[40].

### 제3장 제안하는 근전도 스펙트로그램 기반 사용자 인식

본 장에서는 근전도 신호의 불규칙한 문제를 해결하기 위해 휴식상태 신호와 잡음을 제거하는 전처리 방법을 제안하고 1차원 근전도 신호에 시간-주파수 다차원 분석 방법을 적용하는 사용자 인식에 대해 설명한다. 그림 7은 본 논문에서 제안하는 근전도 스펙트로그램 기반 사용자 인식에 관한 전체적인 흐름도를 나타낸다.

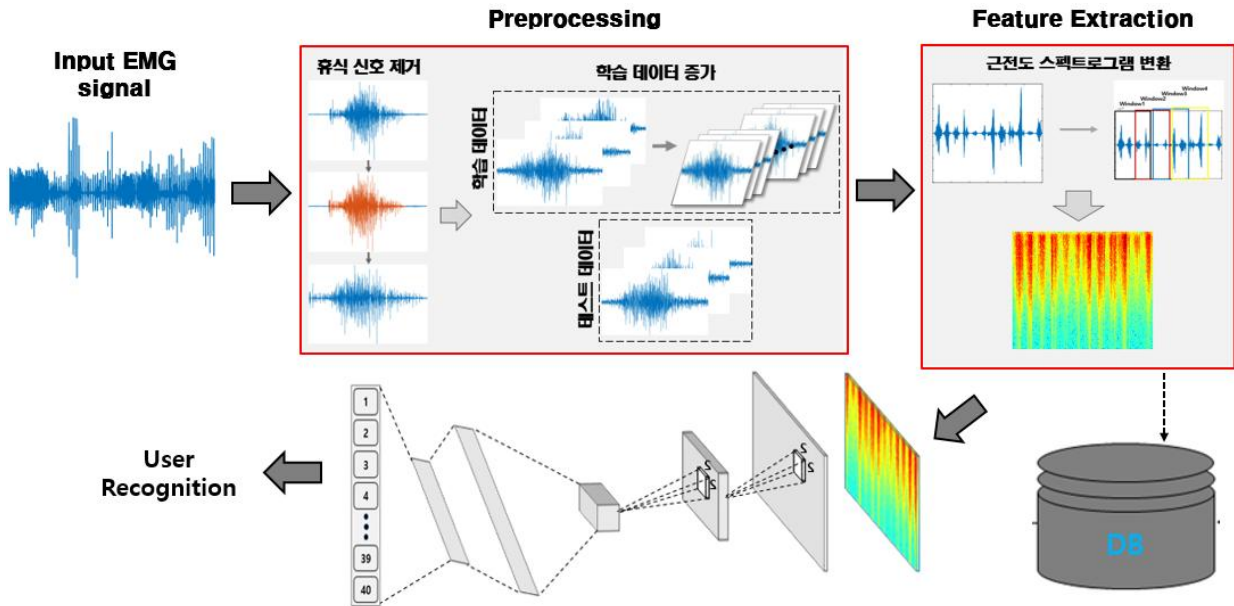


그림 7. 제안하는 근전도 스펙트로그램 기반 사용자 인식 흐름도

먼저, 근전도 신호 데이터는 오픈 데이터베이스 중 Ninapro DB2를 이용하여 데이터 세트를 구성한다. 다음으로 근전도 신호를 한 동작 주기 신호로 분할하고 신호 취득 과정에서 발생하는 잡음 및 불규칙한 휴식신호 제거와 같은 전처리 과정을 진행한다. 근전도 신호에서 발생하는 특정 대역의 주파수를 제거하고 500Hz 미만의 주파수 대역에서 운동정보를 포함하고 있기 때문에 특정 대역 제거 필터, 대역 통과 필터 등과 같은 필터를 이용하여 잡음을 제거한다. 또한 한 동작 주기의

근전도 신호를 겹치지 않는 프레임으로 나누고 각 프레임에 대한 에너지 및 스펙트럼 중심을 계산하여 임계값을 설정한 후 활동 정보를 포함하는 신호만을 추출하여 불규칙한 휴식신호를 제거한다. 전처리 과정의 마지막 단계는 Matching pursuit을 이용하여 근전도 데이터의 수를 증가시키는 과정을 거친다. 다음으로 전처리 과정을 거친 1차원 근전도 신호를 시간-주파수 다차원 특징 추출 방법을 적용하여 2차원 근전도 스펙트로그램 이미지로 변환한다. 그러나 스펙트로그램의 단점으로 시간 해상도와 주파수 해상도는 동시에 향상시킬 수 없는 문제점이 있다. 따라서 STFT의 Window length 변화에 따른 시간 및 주파수 해상도를 확인하며 사용자를 보다 정확하게 인식하는 파라미터를 찾아 근전도 스펙트로그램을 생성한다. 마지막으로 이미지 분류에 가장 대표적으로 사용되는 CNN 네트워크를 통해 사용자 인식 성능을 확인한다.

## 제1절 잡음제거 및 데이터 증가를 위한 전처리 기술

근전도 신호는 동작을 수행할 때 근육에서 발생하는 전기적 신호로 신체활동과 관련된 중요한 정보를 담고 있다. 이러한 근전도 신호는 500Hz 미만의 주파수에서 운동정보를 포함하고 있다. 또한, 근전도 신호에서 발생하는 잡음과 근육 활동 신호가 아닌 불규칙한 휴식상태 신호는 개인 인식을 진행하는 과정에서 불필요하기 때문에 잡음 및 휴식상태 신호 제거가 필수적이다. 그림 8은 본 논문에서 신호 분할부터 잡음제거와 데이터의 수 증가를 포함한 전처리 과정의 흐름도이다.

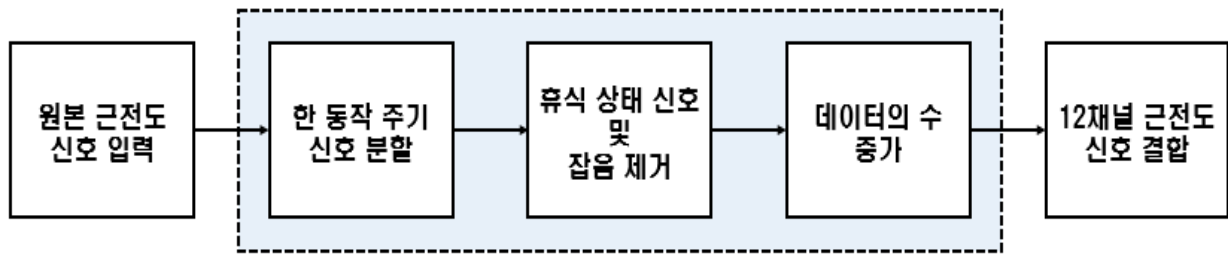


그림 8. 잡음 제거 및 데이터 증가 전처리 과정의 흐름도

Ninapro DB2의 원본 신호는 총 40개의 손 또는 손목 동작을 6번씩 반복하여 취득되었다. 근전도 신호를 각 동작의 한 주기 신호로 분할하기 위해 데이터 자체적으로 각 동작에 부여된 라벨을 이용하여 신호를 분할하면 그림 9와 같다.




그림 9. 한 동작 주기 신호 분할

동작의 한 주기로 분할한 후 근전도 신호에 포함된 잡음을 제거한다. 근전도 신호에 포함된 잡음의 종류에는 취득 장비에 의해 발생하는 전력선 잡음, 일회용 전극의 각 성능과 기능의 차이로 인해 생기는 잡음, 인체 생리학적 간섭에 의한 잡음 등이 있다. 본 논문에서 사용된 대역 통과 필터는 특정한 두 차단주파수 사이에 있는 주파수 대역의 신호는 감쇠없이 통과시키고 그 이외의 모든 주파수에 대해서는 감쇠시키는 필터이다. 대역 통과 필터를 이용하여 운동정보를 가지는

10-500Hz의 주파수 대역은 감쇠없이 통과시키고 그 이외의 주파수 대역은 감쇠시켜 제거한다. 전력선 잡음은 취득 장비의 접지가 부적절하거나 장비 주변의 고압선에 의해 발생하는 잡음으로 일반적으로 60Hz로 나타난다. 이러한 전력선 잡음을 제거하기 위해 특정 대역 제거 필터를 적용하여 60Hz의 주파수 대역을 제거한다.

다음으로 근전도 신호에 포함되어 있는 휴식신호를 제거한다. 본 논문에서 정의하는 휴식신호는 취득 조건으로 설정한 동작 수행 시간 동안 동작을 수행하기 전과 동작이 끝난 후 포함되어 있는 휴식신호이다. 근전도 신호를 취득함에 있어 초기 실험 취득 조건으로 정해진 시간 휴식 후 동작을 수행하여 근전도 신호를 취득한다. 그러나 똑같은 동작을 반복하더라도 정해진 초 단위를 사람이 정확하게 맞출 수 없기 때문에 동작을 지속하는 시간에 힘을 주지 않는 휴식신호가 포함되어 취득된다. 이러한 근전도 신호는 그림 10과 같이 동일한 사람이 동일 동작을 반복 수행하더라도 동작을 수행하기 이전의 휴식시간과 동작을 지속하는 시간이 모두 다르기 때문에 신호가 모두 불규칙하게 취득되는 문제점이 있다.

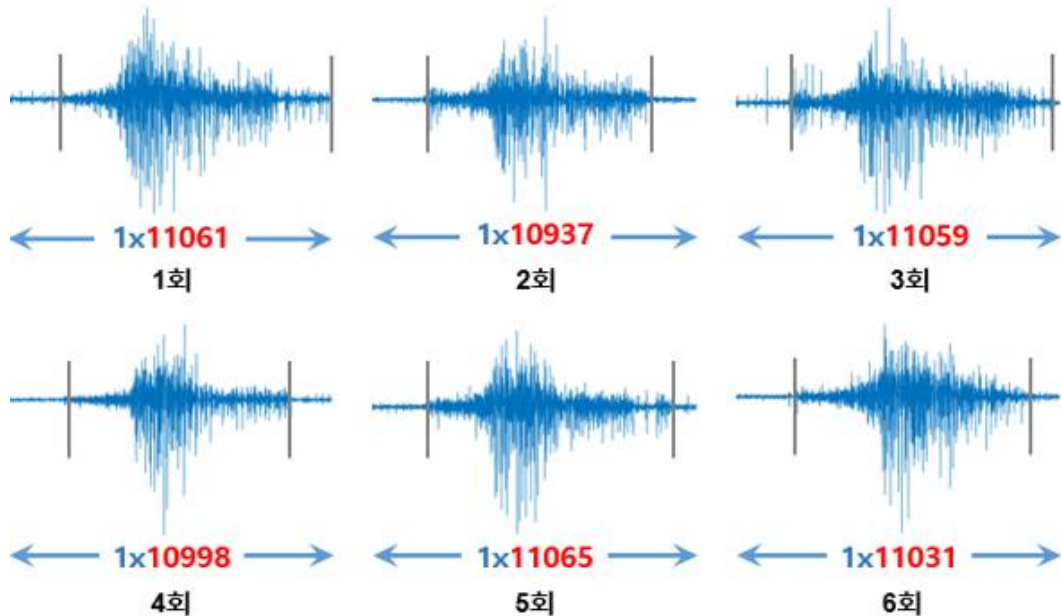


그림 10. 불규칙한 근전도 신호

따라서 휴식신호를 제거하기 위해 한 동작 주기의 근전도 신호를 겹치지 않는 프레임으로 나누고 각 프레임에 대한 에너지 평균을 계산하여 임계값으로 설정한다. 설정된 임계값을 이용하여 임계값보다 클 경우 활동 정보를 포함하는 동작 신호로 판단하여 신호를 추출하고 임계값보다 작을 경우 휴식상태로 판단하여 제거한다. 이때 추출된 근전도 신호 역시 지속시간이 다르므로 리샘플링을 이용하여 신호의 크기를 모두 동일하게 맞춰준다. 그림 11은 한 동작 주기 신호로 분할된 근전도 신호에 휴식신호를 제거한 결과를 나타낸다.




그림 11. 휴식상태 신호 제거

잡음제거 및 휴식상태 신호 제거 과정을 거친 근전도 신호는 부족한 데이터의 수를 증가시키기 위해 근전도 신호를 생성하여 데이터 증가시킨다. 대표적인 데이터 생성기술로 GAN을 사용하고 있다. GAN은 데이터를 만들어내는 Generator와 만들어진 데이터를 평가하는 Discriminator로 구성되어 Generator와 Discriminator가 서로 대립하며 성능을 점차 개선하는 학습 방법으로 진행되며 GAN은 데이터를 생성하기 위해 사전에 많은 데이터가 요구된다[11]. 그러나 근전도 데이터베이스는 적은 반복 횟수로 취득되어 데이터의 수가 매우 부족하기 때문에 근전도 신호 생성을 위해 GAN을 적용하기 어려운 문제가 있다. 따라서 적은 데이터 수로도 신호 생성이 가능하며 다른 생성기술에 비해 비교적 간단한 수식으로 빠르게 데이터

생성이 가능한 장점이 있는 Matching pursuit을 사용하였다. Matching pursuit 알고리즘은 Mallat과 Zhang에 의해 처음 소개되었다[36]. Matching pursuit의 기본 아이디어는 신호를 대략적으로 표현한 후 원소(Atom)들을 하나씩 선택하여 현재 신호와 가장 높은 내적을 가진 원소를 찾아내고, 현재 신호에서 해당 원소만 사용하는 근사값을 빼고 잔여 신호가 분해 될 때까지 반복 수행한다. Matching pursuit의 대략적인 분해는 아래 수식(1)과 같으며  $R^{(m)}$ 은 잔여 신호를 의미하며 반복 횟수( $m$ )에 따라 인덱스  $\gamma_i$ 를 찾고  $\alpha_{\gamma_i}$ 을 계산한다.

$$s = \sum_{i=1}^m \alpha_{\gamma_i} \phi_{r_i} + R^{(m)} \quad (1)$$

따라서 Matching pursuit을 근전도 신호에 적용하여 현재 신호와 유사한 신호를 생성할 수 있으며 반복 횟수에 따라 유사도를 변화시켜가며 신호를 생성할 수 있다. 생성된 신호는 90%~99% 사이의 교차상관관계 유사도를 갖는 신호 생성을 진행하였다. 본 논문에서는 앞서 설명한 대역 통과 필터, 대역 제거 필터를 이용하여 잡음을 제거 및 신호에 포함되어 있는 휴식상태 신호를 제거하고 Matching pursuit을 이용하여 근전도 데이터 신호를 생성하는 전처리 과정을 진행한다. 전처리 과정을 거친 한 동작 주기의 근전도 신호는 12채널의 신호를 모두 이용하기 위해 그림 12와 같이 시간 도메인으로 모두 결합한다.




그림 12. 시간 도메인을 이용한 12채널 결합

## 제2절 근전도 스펙트로그램을 이용한 사용자 인식

본 논문에서는 전처리 및 정규화를 마친 1차원 근전도 신호는 시간-주파수 특징 추출 방법인 STFT를 적용하여 다차원 특징을 추출한다. STFT는 기존의 주파수 영역 특징 추출 방법의 FFT의 단점을 보완한 방법으로 시간의 흐름에 따라 변하는 신호에 대해 자신이 알고 싶은 시점의 주파수 성분을 분석하는 방법으로 시간과 주파수를 포함하는 다차원 특징을 추출할 수 있다[41]. 이때 STFT 적용 식은 수식 (2)와 같다.

$$X(R, \omega) = \int_{-\infty}^{\infty} x(t)w(t-R)e^{-j\omega t} dt = s \quad (2)$$

신호  $x(t)$  입력신호와 윈도우 함수  $w(t)$ 를 이용하여 FFT 길이에 따라 스펙트로그램 변환을 진행하며  $R$ 은 윈도우 길이,  $\omega$ 는 각주파수이며,  $s$ 는 스펙트로그램 값이다. 따라서 수식 (1)을 1차원 근전도 신호에 적용하면 시간에 따라 주파수 정보를 포함하게 되며 시간-주파수 정보를 갖는 다차원 특징을 추출한다. 추출된 다차원 특징을 이용하여 근전도 스펙트로그램으로 변환하면 그림 13과 같다.




그림 13. 근전도 신호의 스펙트로그램 변환

하지만 STFT 특징 추출 방법은 정해진 Window length  $R$ 을 기준으로 FFT를 진행하기 때문에 시간과 주파수 두 가지 분해능은 동시에 향상될 수 없다. 즉



Window length  $R$ 이 작을 경우 시간 해상도가 향상되고 주파수 해상도는 하락하며 반대로 Window length  $R$ 이 커질 경우 시간 해상도가 하락하고 주파수 해상도가 향상된다. 따라서 그림 14와 같이 Overlap을 적용하여 Window가 겹쳐져 적용되고 이에 따라 시간 해상도가 향상된다. Overlap은 대체로 50%~70% 사이를 적용하며 50%의 Overlap을 적용했다.




그림 14. STFT의 Overlap 적용

STFT의 파라미터인 Window length  $R$ 의 변화에 따른 시간-주파수 해상도를 확인하기 위해 Window length  $R$ 을 변화시켜가며 2차원 근전도 스펙트로그램 이미지로 변환한다. 이때 Window length  $R$ 은 가장 낮은 값으로 64를 설정하였으며 두 배씩 늘려나가 가장 높은 값으로 512를 설정하여 구성하였다. 그림 15와 같이 Window length가 변경됨에 따라 시간-주파수 해상도가 변하는 것을 스펙트로그램으로 확인할 수 있다[13].




그림 15. STFT Window length 변화에 따른 근전도 스펙트로그램

최종 인식을 위한 방법은 2차원 이미지 입력을 기반으로 하는 딥러닝 방식의 대표적인 CNN 네트워크를 사용했다. 구성된 CNN 네트워크는 3개의 컨벌루션 층과 2개의 맥스 풀링 층, 2개의 완전연결 층과 활성화함수는 ReLU로 구성하였으며 최종적으로는 소프트맥스에 의해 분류가 진행된다. 전체적인 네트워크 구조는 그림 16과 같이 구성된다. CNN 네트워크의 컨벌루션 층 필터 크기는  $3 \times 3$ 으로 설정하고, 풀링 층의 필터 크기는  $2 \times 2$ 로 스트라이드는 2로 설정했다. 최대 반복 횟수는 150으로 반복 수행하고 각 층의 초기 가중치는 랜덤으로 설정하여 소프트맥스에 의해 출력 층에서 사용자가 최종 인식된다[40].




그림 16. CNN 네트워크 구조

또한 인식 성능 비교를 위해 직접 구성한 CNN 네트워크뿐만 아니라 깊은 신경망으로 설계된 DenseNet201과 고성능 컴퓨터가 아닌 제한적 환경에서도 적용할 수 있는 MobileNet-v2 네트워크를 사용하였다. DenseNet201은 조밀하게 연결된 CNN 구조로 설계되었으며 이는 아래 그림 17과 같이 이전 레이어들의 특징맵을 다음 레이어의 입력과 연결하는 방식으로 레이어 간의 흐름 개선을 개선하였다. 이러한 구조는 네트워크가 깊어짐으로써 입력에 대한 정보가 여러 계층을 통과하면서 정보를 상실할 수 있는 문제를 보완하기 위해 적용되었다. 따라서 DenseNet201은

Vanishing Gradient 개선, Feature Propagation 강화, Feature Reuse, Parameter 수 절약의 이점을 가지고 있다[42].




그림 17. Densely Connected 네트워크 구조

MobileNet은 고성능 컴퓨터가 아닌 제한된 환경에서도 사용이 가능하도록 경량화 네트워크에 대한 연구로 설계된 네트워크이다. 초기 MobileNet은 네트워크를 작게 설계하면 학습이 빠르며 저전력에서 정확도를 향상시키는 조건으로 네트워크를 설계되었다. MobileNet의 핵심 아이디어는 Xception에서 가져온 Depthwise Seperable 컨벌루션으로 입력 데이터를 채널별로 나눈 다음 각 채널에 해당하는 필터에 대해 컨벌루션 연산을 진행한다. 따라서 입력 데이터의 채널수만큼 필터가 존재하며 컨벌루션 연산을 마친 특징 맵은 다시  $1 \times 1$  컨벌루션을 진행하여 최종 1 채널의 결과물로 출력된다[43]. 이러한 MobileNet-v1을 기반으로 MobileNet-v2를 설계하였으며 전체 컨벌루션을 서로 다른 Stride를 가지는 두 개의 개별 레이어로 분할함으로써 정확도를 유지하면서 필요한 작업 및 메모리 수를 줄였다[44]. MobileNet-v1과 MobileNet-v2의 구조는 그림 18과 같다.

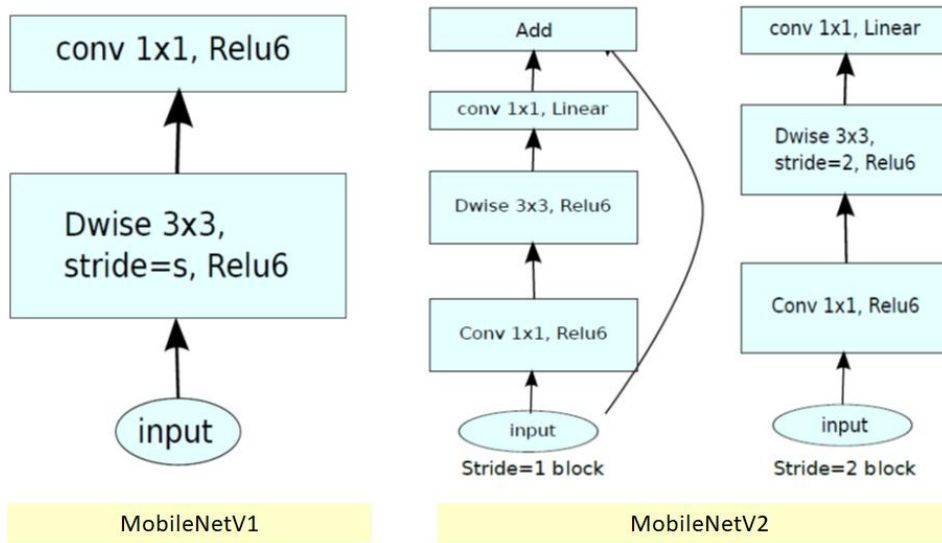


그림 18. MobileNet-v1과 MobileNet-v2 네트워크 구조

## 제4장 실험 결과 및 분석

본 장에서는 제안하는 근전도 스펙트로그램 기반 사용자 인식 성능을 평가하기 위해 1차원 근전도 신호와 근전도 스펙트로그램을 이용하여 사용자 인식 성능을 평가한다. 또한, 휴식상태 제거와 학습 데이터의 수를 포함한 전처리 전과 후로 데이터를 구성하여 사용자 인식 성능을 분석한다.

### 제1절 실험 방법

본 논문에서 제안하는 근전도 스펙트로그램 기반 사용자 인식 성능 재현성을 확인하기 위해 대표적인 오픈 데이터베이스의 Ninapro DB2를 사용하였으며 구체적인 구성은 표 4와 같다. 인원은 총 40명으로 구성하였으며 사용한 손동작은 그림 19와 같다. Ninapro DB2에 포함된 손동작은 팔 전체 또는 손의 움직임으로 구성되어 있다. 그러나 사용자 인식으로써 행동이 큰 동작은 사용자 인식 암호로 사용하기에 적합하지 않아 제외하고 손바닥 범위 안에서 수행 가능한 1번 동작부터 7번 동작까지 사용하여 데이터를 구성했다. 각 동작은 6번씩 반복되었으며 5초 지속 3초 휴식으로 2,000Hz의 샘플링으로 취득되었으며, 채널은 전완근 주변과 이두와 삼두를 포함하여 총 12채널을 사용하였다[30]. 각 동작 반복 횟수가 6회로 데이터의 수가 부족하기 때문에 초기에는 5:5의 비율을 적용하여 데이터를 나누면 각 동작 Training data와 Test data는 각각 3개씩 구성된다. 따라서 피험자 한명에 대한 데이터 수는 Training data 21개, Test data 21개이며 총 40명에 대해 Training data 840개, Test data 840개로 구성된다.

표 4. 근전도 신호 데이터베이스 구성

구분	데이터
인원 (명)	40
손동작 (수)	7
채널 (수)	12
반복 횟수 (수)	6
표본 추출 비율 (Hz)	2,000



그림 19. Ninapro DB2의 7가지 손동작

구성된 근전도 신호는 휴식상태 신호를 포함하여 잡음을 제거한 후 Matching pursuit을 이용하여 학습 데이터 수를 증가시킨다. 이때 Matching pursuit의 정해진 반복 횟수를 통해 생성된 근전도 신호는 교차상관관계를 통해서 실제 신호와 유사도를 측정하여 확인할 수 있다. 실제 근전도 신호와 Matching pursuit을 통해 생성된 근전도 신호의 교차상관관계 유사도는 표 5와 같으며 90%~99% 사이의 유사도로 신호가 생성되는 것을 확인했다. 따라서 초기에 구성한 Training data를 10배 증가시키면 각 동작 데이터는 Training data 33개, Test data 3개로 구성되며 총 40명에 대해 Training data 9,240개, Test data 840개로 데이터 생성을 통해 Training data의 수를 증가시켜 구성 비율이 변화되었다.

표 5. 한 주기 동작에 대해 생성된 근전도 신호 유사도

구분	반복 생성 횟수									
	1회	2회	3회	4회	5회	6회	7회	8회	9회	10회
교차상관 관계 유사도	0.908	0.919	0.927	0.934	0.942	0.955	0.96	0.973	0.985	0.99
	0.903	0.913	0.922	0.932	0.941	0.949	0.956	0.964	0.971	0.981
	0.907	0.918	0.928	0.937	0.944	0.956	0.963	0.971	0.979	0.989
	0.900	0.912	0.923	0.933	0.94	0.952	0.959	0.966	0.972	0.983
	0.904	0.916	0.924	0.934	0.943	0.953	0.961	0.969	0.974	0.986
	0.907	0.917	0.925	0.937	0.949	0.956	0.961	0.968	0.972	0.988
	0.909	0.919	0.927	0.936	0.945	0.955	0.964	0.971	0.977	0.989

## 제2절 근전도 스펙트로그램을 이용한 사용자 인식 성능 분석

본 논문에서 제안하는 근전도 스펙트로그램 기반 사용자 인식과 비교 분석하기 위해 동일한 DB의 1차원 근전도 신호를 CNN 네트워크로 사용자 인식 성능을 확인하였다. 1차원 근전도 신호를 시간 도메인에서 12채널 결합한 뒤 CNN 네트워크의 입력으로 사용하여 특징 추출 후 최종 인식된다. 이때 CNN 네트워크의 인식 성능 신뢰성 확보를 위해 깊은 신경망으로 설계된 GoogleNet과 ResNet-101 네트워크를 사용하여 전이학습을 진행하였다.

각 동작별 1차원 근전도 신호를 이용하여 사용자 인식 성능을 분석한 결과 표 6과 같다. 인식 성능은 모든 동작에서 5번씩 반복하여 성능을 분석하였으며 최종적으로 평균값을 이용하여 사용자 인식 성능을 확인하였다.

표 6. 전처리 전·후 사용자 인식 성능

구분	휴식상태 제거 전						휴식상태 제거 후					
	인식 성능					평균	인식 성능					평균
1	56.7%	56.7%	56.7%	59.2%	55%	56.8%	55%	59.2%	55.8%	56.7%	59.2%	57.2%
2	66.7%	65.8%	66.7%	66.7%	68.3%	66.8%	68.3%	71.7%	68.3%	67.5%	64.2%	68%
3	64.2%	63.3%	66.7%	61.7%	61.7%	63.5%	69.2%	67.5%	67.5%	68.3%	67.5%	68%
4	64.2%	67.5%	63.3%	65%	65.8%	65.2%	69.2%	68.3%	69.2%	67.5%	71.7%	69.2%
5	70.8%	73.3%	65%	65%	70.8%	68.9%	75%	75.8%	74.2%	68.3%	76.7%	74%
6	65.8%	65%	65%	63.3%	66.6%	65.1%	66%	70%	65.8%	65.8%	65%	66.5%
7	22.5%	30%	29.2%	32.5%	29.2%	28.7%	65.8%	63.3%	68.3%	63.3%	65.8%	65.3%

1차원 근전도 신호를 이용하였을 때 그림 20과 같이 40명의 사용자 인식 성능은 휴식상태 신호 제거 전 성능은 59.3%이며, 휴식상태 신호 제거 후 성능은 66.7%의 정확도로 휴식상태 신호 제거 전 보다 7.4% 향상됨을 확인했다.

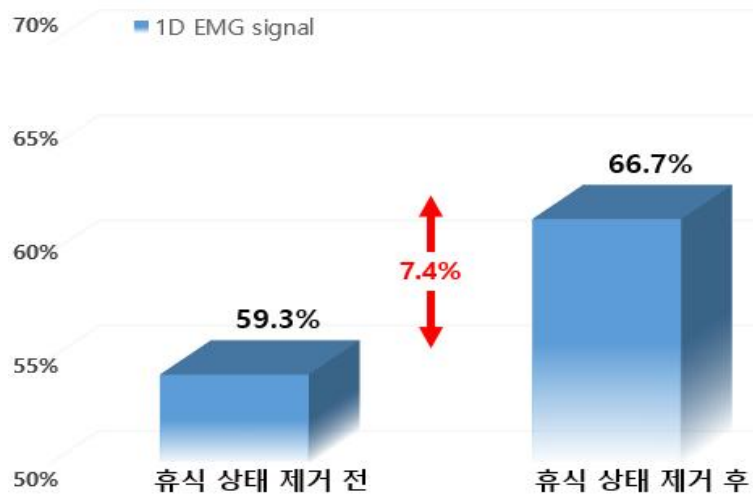


그림 20. 1차원 근전도 신호를 이용한 사용자 인식

근전도 스펙트로그램을 이용해서 사용자 인식 성능을 분석하기 위해 STFT의 파라미터인 Window length는 64, 128, 256, 512로 구성한 후, 시간-주파수 해상도를 변화시켜가며 근전도 스펙트로그램을 생성하였다. 휴식상태 제거 후의 신호를 이용하여 Window length가 256일 때 그림 21과 같이 85.4%로 가장 높은 인식 성능을 보였다.

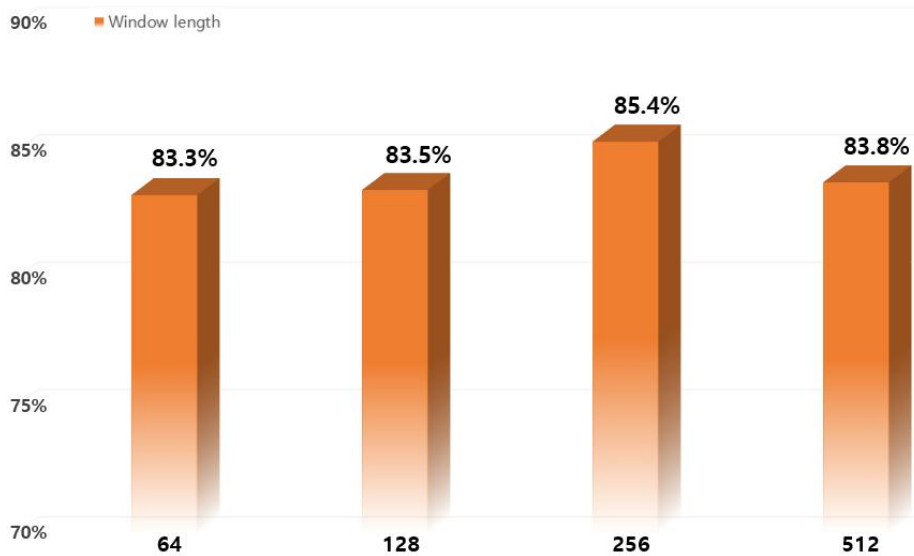


그림 21. Window length의 변화에 따른 인식 성능



따라서 256의 Window length를 이용하여 근전도 스펙트로그램을 생성하였을 때 그림 22와 같이 40명의 사용자 인식 성능은 휴식상태 신호 제거 전 78.7%, 휴식상태 신호 제거 후 85.4%의 정확도로 인식되었다. 근전도 스펙트로그램으로 변환하였을 때 각각 19.4%, 18.7%의 인식 성능이 향상됨을 확인하였으며 휴식상태 전처리 제거 전과 후는 6.7% 사용자 인식 성능이 향상되는 것을 확인했다.

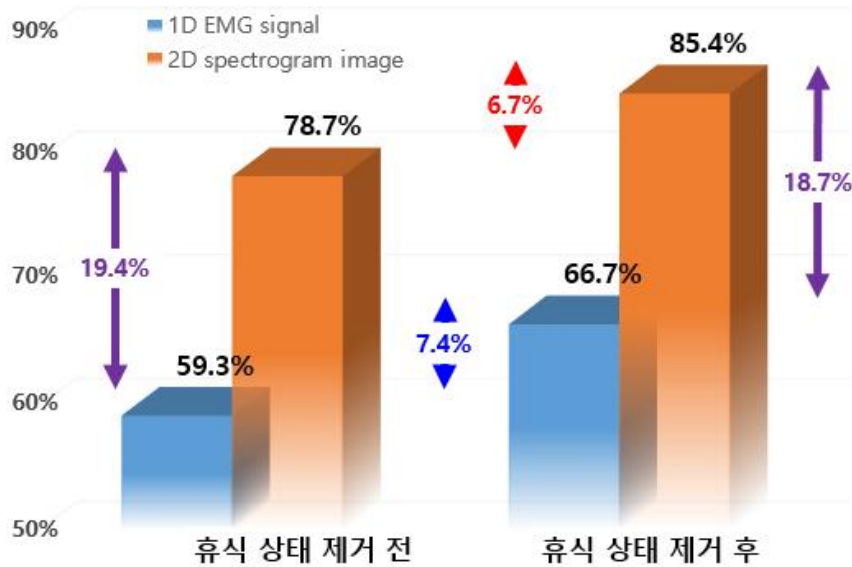


그림 22. 잡음 및 휴식신호 제거 후 사용자 인식

또한 근전도 데이터베이스의 부족한 문제를 해결하기 위해 휴식상태를 제거한 후 Matching pursuit을 이용하여 학습 데이터 수를 증가시켰다. 각 동작 신호 당 90%~99%의 유사율로 근전도 신호를 생성하여 기존의 부족한 학습 데이터에서 10배의 학습 데이터를 증가시킨 후 사용자 인식 성능을 확인하였다. 부족한 학습 데이터의 수를 증가시켰을 때 그림 23과 같이 데이터의 수를 증가시키기 전보다 1차원 근전도 신호에서는 7%의 인식 성능이 향상되었으며, 근전도 스펙트로그램에서는 10% 이상 향상되어 96.1%의 사용자 인식 성능을 보였다.

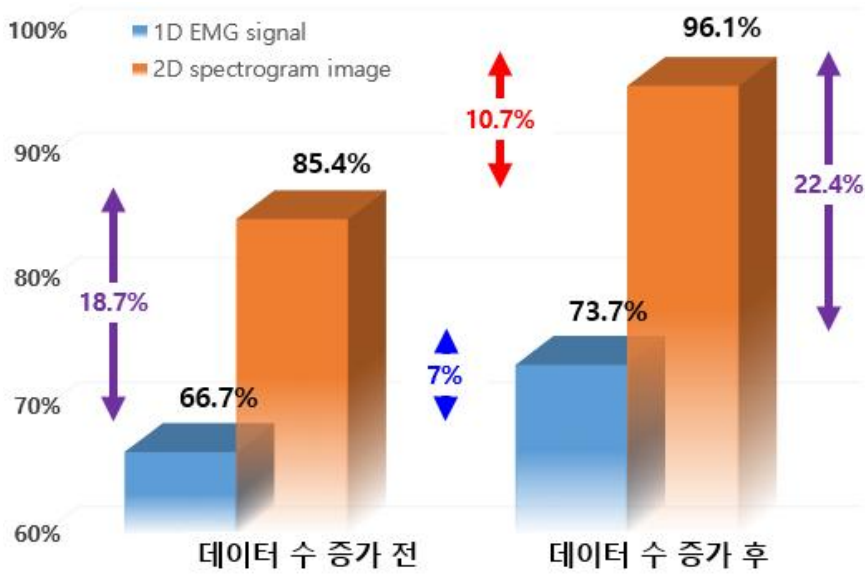


그림 23. 학습 데이터 증가 후 사용자 인식

인식 성능 결과를 비교하기 위해 깊은 신경망으로 구성된 DenseNet201 신경망과 연산량 및 모델 사이즈를 줄여 모바일 환경에서도 적용 가능한 MobileNet-v2 신경망을 사용하여 인식 성능을 비교하였다. 원본신호를 이용한 사용자 인식 성능과 잡음 제거 및 데이터 생성 후 사용자 인식 성능은 표 7과 같다.

표 7. 네트워크별 사용자 인식 성능

(a) 원본 신호를 이용한 사용자 인식

구분	MobileNet-v2	DenseNet201	CNN
1D EMG Signal	X	52.6%	59.3%
2D EMG spectrogram	X	61.8%	78.7%

(b) 잡음 제거 및 데이터 생성 후 사용자 인식

구분	MobileNet-v2	DenseNet201	CNN
1D EMG Signal	55.4%	67.3%	73.7%
2D EMG spectrogram	83%	90.3%	96.1%

직접 구성한 CNN 네트워크를 포함한 총 세 개의 네트워크에서 1차원 근전도 신호를 이용한 결과보다 근전도 스펙트로그램을 이용하였을 때 높은 인식 성능을 보였다. 또한 원본 신호를 이용하였을 때 낮은 인식 성능을 보이는 반면에 본 논문에서 제안하는 잡음 제거 및 데이터의 수 증가를 포함한 전처리를 진행하였을 경우 인식 성능이 크게 향상됨을 확인하였다.

### 제3절 사용자 인식 성능 결과 비교

기존 근전도 기반 사용자 인식 시스템을 이용한 방법과 본 논문의 근전도 스펙트로그램 기반 사용자 인식 성능 결과를 표 8과 같이 비교 분석하였다.

표 8. 기존 근전도 신호 기반 사용자 인식 성능 비교

구분	Pre processing	Feature Extraction	People	Classification	Performance
X. Zhai et al. [9] (2016)	-	Feature : RMS, Spectrogram, PCA	40	Analysis : SVM	RMS : 67.7% Spectrogram : 77.4%
D. Huang et al. [12] (2019)	-	Feature : Spectrogram	40	Analysis : SVM, CNN-LSTM	SVM : 77.2% CNN-LSTM : 79.3%
Proposed Method	Matching pursuit Filter (Band-pass, Notch)	Feature : Spectrogram	40	Analysis : CNN	CNN : 96.1%

X. Zhai 및 D. Huang는 동일한 Ninapro DB2를 이용하여 1차원 근전도 신호를 스펙트로그램으로 변환하여 행동 패턴 인식을 진행했다. X. Zhai는 특징 추출 방법에 따른 성능을 비교 분석하였으며 스펙트로그램 기반 SVM을 사용하여 77.41%의 인식 성능을 확인하였다. 스펙트로그램을 이용함으로써 시간 영역 특징 추출 방법을 사용하였을 때보다 9.7% 높은 인식 성능을 보였다. 따라서 단차원 분석 방법인

시간 영역 특징 추출 방법보다 시간-주파수 정보를 갖는 다차원 특징 추출 방법인 스펙트로그램을 적용하였을 때 근전도 신호를 효율적으로 분석할 수 있다는 것을 증명하였다. 또한 D.Huang은 분류기에 따른 성능을 비교 분석하였으며 스펙트로그램 기반 CNN-LSTM을 사용하여 79.329%의 인식 성능을 확인하였다. 기존의 머신러닝 방식의 SVM보다 딥러닝 방식의 CNN-LSTM 네트워크를 이용하였을 때 2.1% 높은 인식 성능을 보였다. 따라서 머신러닝 방식보다 딥러닝 방식의 네트워크를 이용하였을 때 높은 인식 성능을 보이는 것으로 확인하였다.




그림 24. 사용자 인식 성능 결과

본 논문에서는 그림 24와 같은 사용자 인식 성능을 보였다. 근전도 신호에 적합한 STFT의 시간-주파수 해상도를 조절하여 근전도 스펙트로그램으로 변환하였으

며, 딥러닝 기반의 CNN네트워크를 구성하여 사용자 인식을 진행하였다. 실험 결과 CNN 네트워크 기반 근전도 스펙트로그램을 이용한 사용자 인식에서 85.4%로 기존 연구들에 비해 향상된 성능을 보였다. 또한 전처리 단계에서 휴식상태를 포함하여 불필요한 잡음을 제거하고 부족한 학습 데이터의 수를 증가 시킨 후 근전도 스펙트로그램으로 변환하였을 때 96.1%로 높은 인식 성능을 보이는 것으로 확인하였다. 따라서 본 논문에서 제안하는 잡음제거 및 데이터의 수를 증가시켰을 때 10% 이상 향상되었으며 기존 연구들과 비교하였을 때도 15% 이상 향상됨을 확인하였다.

## 제5장 결론

기존 근전도 신호를 이용한 사용자 인식 연구들은 간단한 필터를 이용하여 잡음이 제거된 근전도 신호로 실험을 진행하였다. 근전도 신호는 시간에 따라 취득되는 시계열 데이터로 동작을 수행할 때 각 근육의 서로 다른 활성화도에 따라 발생한다. 따라서 충분한 양의 데이터를 취득할 경우 사용자 인식에 적용 가능하다. 그러나 대부분의 근전도 데이터베이스는 데이터 수가 매우 부족하며 동작을 반복하여 취득하는 과정에서 조건에 따라 일정하게 취득하기 어려워 신호가 불규칙하게 취득되는 문제가 있다. 또한 시계열 데이터인 근전도 신호는 시간 변화에 따라 일정한 근력 세기를 유지한 상태에서 반복할 수 없기 때문에 명백한 주기성을 찾기 어려워 단차원 특징으로 분석할 경우 사용자 인식 성능이 저하되는 문제점이 있다.

본 논문에서는 행동학적 특징에 따라 취득된 1차원 근전도 신호를 이용하여 사용자 인식 시스템에 적용하기 위해 불규칙한 신호 문제와 부족한 데이터 문제를 해결하기 위한 전처리 방법과 시간-주파수를 포함하는 다차원 특징 근전도 스펙트로그램을 이용한 사용자 인식 방법을 제안하였다. 근전도 신호에 포함된 불규칙한 휴식신호 및 잡음을 제거하고 적은 데이터 수로도 신호 생성이 가능하며 다른 생성 기술에 비해 간단한 수식으로 빠르게 데이터 생성이 가능한 Matching pursuit을 이용하여 근전도 신호를 생성하였다. 생성된 근전도 신호는 교차상관관계 유사도를 통하여 90%~99%의 유사도 결과를 확인하였다. 전처리를 마친 1차원 근전도 신호는 시간-주파수 정보를 포함한 다차원 특징 추출 방법인 STFT에 적용하고 근전도 신호를 효율적으로 분석할 수 있는 해상도를 조절한 뒤 근전도 스펙트로그램으로 변환하여 CNN 네트워크로 최종 사용자를 인식한다. 제안한 시스템은 근전도 데이터 구성 과정, 근전도 데이터 전처리 및 정규화 과정, 1차원 근전도 신호를 근전도 스펙트로그램으로 변환하는 과정, 최종 분류 과정으로 구성된다.

실험결과 1차원 근전도 신호를 이용하였을 때 사용자 인식 성능은 전처리 전 59.3%, 전처리 후 66.7%로 전처리 후 인식 성능이 소폭 향상 되었으나, 여전히 낮은 인식 성능을 보였다. 제안한 방법을 이용하여 40명의 사용자 인식 성능은 12채널에서 256의 Window length를 적용하여 근전도 스펙트로그램으로 변환하였을 때 전처리 전 78.4%, 전처리 후 85.4%로 1차원 근전도 신호를 이용하였을 때보다 각각 19.4%, 18.7% 향상되었다. 또한 부족한 데이터는 Matching pursuit를 적용하여 10배 증가시켰을 때 96.1%의 높은 인식 성능으로 데이터를 증가시키기 전보다 10% 이상 향상되었다. CNN 네트워크 뿐만 아니라 DenseNet201, MobileNet-v2 네트워크를 이용하여 사용자 인식을 진행하였을 때 본 논문에서 제안하는 방법을 적용하여 사용자 인식 성능이 향상되는 것을 확인하였다. 따라서 1차원 근전도 신호에 휴식 상태를 포함한 불필요한 신호를 제거하고 부족한 학습 데이터를 증가시킨 후 STFT를 적용하여 다차원 특징인 근전도 스펙트로그램을 기반으로 사용자 인식 가능성을 확인하였다.

## 참고문헌

- [1] Q. Xiao, "Technology review-biometrics-application, challenge, and computational intelligence solutions," IEEE Computational Intelligence Magazine, vol. 2, no. 2, pp. 5-25, May. 2007.
- [2] J. L. Wayman, "Technical testing and evaluation of biometric identification devioes," Biometrics. Springer, pp. 345-368, Jun. 1996.
- [3] J. Pathuel, "Biometric control systems and associated methods of use," U.S. Patent application, no. 11/159,814, Jun. 2005.
- [4] T. M. Nazmy, H. El-Messiry, and B. Al-Bokhity, "Adaptive neuro-fuzzy inference system for classification of ECG signals", In Informatics and Systems (INFOS), 2010 The 7th International Conference on, pp. 1-6, Mar. 2010.
- [5] D. N. K Hardani, O. Wahyunggoro, H. A. Nugroho, and N. Faisal, "Analysis of emotional condition based on electrocardiogram signals", In Electrical Engineering and Computer Science (ICEECS), 2014 International Conference on, pp. 152-157, Nov. 2014.
- [6] R. D. Luis-Garcia, C. Alberola-Lopez, O. Aghzout and J. Ruiz-Alzola, "Biometric identification systems," Signal processing, vol. 83, no. 12, pp. 2539-2557, Dec. 2003.
- [7] E. Scheme, K. Englehart, "Electromyogram pattern recognition for control of powered upper-limb prostheses: State of the art and challenges for clinical use," The Journal of Rehabilitation Research and Development, vol. 48, no. 6, pp. 643-659, Dec. 2011.
- [8] A. Phinyomark and E. Scheme, "EMG pattern recognition in the era of big data and deep learning," Big Data Cognitive Computing, vol. 2, no.



- 3, pp. 21, Aug. 2018.
- [9] X. Zhai, B. Jelfs, R. H. M. Chan and C. Tin, "Short latency hand movement classification based on surface EMG spectrogram with PCA," 2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), pp. 327-330, Aug. 2016.
- [10] S. G. Mallat and Z. Zhang, "Matching pursuits with time-frequency dictionaries," In IEEE Transactions on Signal Processing, vol. 41, no. 12, pp. 3397-3415, Dec. 1993.
- [11] M. Mehralian and B. Karasfi, "RDCGAN: Unsupervised representation learning with regularized deep convolutional generative adversarial networks," 2018 9th Conference on Artificial Intelligence and Robotics and 2nd Asia-Pacific International Symposium, pp. 31-38, Dec. 2018.
- [12] D. Huang and B. Chen, "Surface EMG decoding for hand gestures based on spectrogram and CNN-LSTM," 2019 2nd China Symposium on Cognitive Computing and Hybrid Intelligence (CCHI), pp. 123-126, Sep. 2019.
- [13] T. N. S. T. Zawawi, A. R. Abdullah, E. F. Shair, I. Halim and O. Rawaida, "Electromyography signal analysis using spectrogram," 2013 IEEE Student Conference on Research and Development, pp. 319-324, Dec. 2013.
- [14] X. Yang, X. Chen, X. Cao, S. Wei and X. Zhang, "Chinese sign language recognition based on an optimized tree-structure framework," In IEEE Journal of Biomedical and Health Informatics, vol. 21, no. 4, pp. 994-1004, Jul. 2017.
- [15] X. Chen, X. Zhang, Z. Zhao, J. Yang, V. Lantz and K. Wang, "Multiple hand gesture recognition based on surface EMG signal," 2007 1st

- International Conference on Bioinformatics and Biomedical Engineering, pp. 506–509, Jul. 2007.
- [16] Z. Zhang, K. Yang, J. Qian and L. Zhang, “Real-time surface EMG pattern recognition for hand gestures based on an artificial neural network,” *Sensors*, vol. 19, no. 14, pp. 3170, Jul. 2019.
- [17] M. Haris, P. Chakraborty and B. V. Rao, “EMG signal based finger movement recognition for prosthetic hand control,” 2015 Communication, Control and Intelligent Systems (CCIS), pp. 194–198, Nov. 2015.
- [18] M. Leon, J. M. Gutierrez, L. Leija and R. Munoz, “EMG pattern recognition using support vector machines classifier for myoelectric control purposes,” 2011 Pan American Health Care Exchanges, pp. 175–178, Apr. 2011.
- [19] C. Savur, and F. Sahin, “Real-time american sign language recognition system using surface EMG signal,” 2015 IEEE 14th International Conference on Machine Learning and Applications (ICMLA), pp. 497–502, Dec. 2015.
- [20] B. Divya, J. Delpha and S. Badrinath, “Public speaking words (Indian sign language) recognition using EMG,” 2017 International Conference On Smart Technologies For Smart Nation (SmartTechCon), pp. 798–800, Aug. 2017.
- [21] R. Shiohi, S. Ito, M. Ito and M. Fukumi, “Personal authentication and hand motion recognition based on wrist EMG analysis by a convolutional neural network,” 2018 IEEE International Conference on Internet of Things and Intelligence System (IOTAIS), pp. 184–188, Dec. 2014.

- [22] M. Lee, J. Ryu and I. Youn, “Biometric personal identification based on gait analysis using surface EMG signals,” 2017 2nd IEEE International Conference On Computational Intelligence and Applications (ICCIA), pp. 318–321, Sep. 2017.
- [23] E. J. Avila–Mireles, F. J. Ruiz–Sanchez and O. Garcia–Salazar, “EMG patterns induced in upper limb by haptic guidance for diagnosis and treatment evaluation,” 2015 12th International Conference on Electrical Engineering, Computing Science and Automatic Control (CCE), pp. 1–6, Oct. 2015.
- [24] A. A. Adewuyi, L. J. Hargrove and T. A. Kuiken, “An analysis of intrinsic and extrinsic hand muscle EMG for improved pattern recognition control,” In IEEE Transactions on Neural Systems and Rehabilitation Engineering, vol. 24, no. 4, pp. 485–494, Apr. 2015.
- [25] C. Savur and F. Sahin, “Real-time american sign language recognition system using surface EMG signal,” 2015 IEEE 14th International Conference on Machine Learning and Applications (ICMLA), pp. 497–502, Dec. 2015.
- [26] J. J. Park and C. K. Kwon, “Study on forearm muscles and electrode placements for CNN based korean finger number gesture recognition using sEMG signals,” Journal of Korea Academia–Industrial cooperation Society, vol. 19, no. 8, pp. 260–267, Aug. 2018.
- [27] J. Cannan and H. Hu, “Automatic user identification by using forearm biometrics,” 2013 IEEE/ASME International Conference on Advanced Intelligent Mechatronics, pp. 710–715, Jul. 2013.
- [28] N. Belgacem, R. Fournier, A. Nait–Ali and F. Bereksi–Reguig, “A novel biometric authentication approach using ECG and EMG signals,”

- Journal of Medical Engineering and Technology, vol. 39, no. 4, pp. 226-238, Jun. 2014.
- [29] R. N. Khushaba, M. Takruri, S. Kodagod and G. Dissanayake, “Toward improved control of prosthetic fingers using surface electromyogram(EMG) signals,” *Expert Systems with Applications*, vol. 39, no. 12, pp. 10731-10738, Sep. 2012.
- [30] M. Atzori, A. Gjisberts, C. Castellini, B. Caputo, A. M. Hager, S. Elsig, G. Gistsidis, F. Bassetto and H. Muller, “Electromyography data for non-invasive naturally-controlled robotic hand prostheses,” *Scientific Data*, no. 140053, Dec. 2014.
- [31] C. Sapsanis, G. Georgoulas and A. Tzes, “EMG based classification of basic hand movements based on time-frequency features,” *21st Mediterranean Conference on Control and Automation*, pp. 716-722, June. 2013.
- [32] H. Blair, R. Elliott, H. Levi, “Benchmark datasets for bilateral lower-limb neuromechanical signals from wearable sensors during unassisted locomotion in able-bodied individuals,” *Frontiers in Robotics and AI*, vol. 5, no. 14, Feb. 2018.
- [33] I. W. Selesnick and C.S. Burrus, “Generalized digital butterworth filter design,” *In IEEE Transactions on Signal Processing*, vol. 46, no. 6, pp. 1688-1694, Jun. 1998.
- [34] A. Nehorai, “A minimal parameter adaptive notch filter with constrained poles and zeros,” *In IEEE Transactions on Acoustics, Speech, and Signal Processing*, vol. 33, no. 4, pp. 983-996, Aug. 1985.
- [35] A. Phinyomark, S. Hirunviriya, C. Limsakul and P. Phukpattaranont, “Evaluation of EMG feature extraction for hand movement recognition

- based on Euclidean distance and standard deviation,” ECTI-CON2010: The 201 ECTI International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology, pp. 856-860, May. 2010.
- [36] D. D. Jayasree, “Classification of power quality disturbance signals using FFT, STFT, wavelet transforms and neural networks - a comparative analysis,” International Conference on Computational Intelligence and Multimedia Applications (ICCIMA 2007), pp. 335-340, Dec. 2007.
- [37] M. A. Oskoei and H. Hu, “Support vector machine-based classification scheme for myoelectric control applied to upper limb,” In IEEE Transactions on Biomedical Engineering, vol. 55, no. 8, pp. 1956-1965, Aug. 2008.
- [38] S. Wold, K. Esbensen and P. Geladi, “Principal component analysis,” chemometrics and intelligent laboratory systems, vol. 2, no. 1-3, pp. 37-52, Aug. 1987.
- [39] S. Mika, G. Ratsch, J. Weston, B. Scholkopf and K.R. Mullers, “Fisher discriminant analysis with kernels,” Neural Networks for Signal Processing IX: Proceedings of the 1999 IEEE Signal Processing Society Workshop, pp. 41-48, Aug. 1999.
- [40] T. Bao, A. Zaidi, S. Xie and Z. Zhang, "Surface-EMG based wrist kinematics estimation using convolutional neural network," 2019 IEEE 16th International Conference on Wearable and Implantable Body Sensor Networks (BSN), pp. 1-4, May. 2019.
- [41] 김재명, 최규호, 김진수, 반성범, "CNN 기반 근전도의 2D 스펙트로그램 이 미지를 이용한 사용자 인식," 한국정보기술학회논문지, 2020. (게재예정)

- [42] G. Huang, Z. Liu, V. D. Maaten and K. Q. Weinberger, "Densely connected convolutional networks," 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 2261–2269, Jul. 2017.
- [43] G. Howard, M. Zhu, B. Chen, D. Kalenichenko, W. Wang, T. Weyand, M. Andreetto and H. Adam, "MobileNets:efficient convolutional neural networks for mobile vision applications," Computer Vision and Pattern Recognition, Apr. 2017.
- [44] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov and L. Chen, "MobileNetV2:inverted residuals and linear bottlenecks," 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, pp. 4510–4520, Jun. 2018.

## 감사의 글

대학원을 진학하여 영상처리 연구실에서 생활하는 동안 도움을 주신 모든 분들에게 이 지면을 빌어 감사의 말씀을 드리고자합니다.

먼저, 학부를 졸업하는 시점에 방향하던 저를 이끌어주시고 지도해주신 반성범 교수님께는 어떠한 말로도 감사의 마음을 표현할 길이 없을 것 같습니다. 교수님의 지도 아래 무사히 석사과정을 마칠 수 있었습니다. 진심으로 감사드립니다. 또한, 진심 어린 마음으로 부족한 점이 많았던 논문이 나아질 수 있도록 도움을 주신 김윤태 교수님, 곽근창 교수님께도 깊은 감사를 드립니다.

함께 연구를 진행하며 서로에게 도움이 되어준 연구실의 선후배님들에게도 고마운 마음을 전합니다. 연구실 선후배들이 있었기에 좋은 연구실 생활을 보낼 수 있었습니다.

마지막으로 학업을 진행하는 동안 아낌없이 뒷바라지 해주시며 믿고 지켜봐 주신 아버지와 어머니께 감사드리며 항상 동생을 걱정해주는 누나들에게도 고마운 마음을 전합니다.