

다채널 근전도 기반 딥러닝 동작 인식을 활용한 손 재활 훈련시스템 개발 및 사용성 평가

안성무¹ · 이건희¹ · 김세진¹ · 배소정² · 이현주² · 오도창^{1*} · 태기식^{1*}

¹건양대학교 의공학과, ²건양대학교 물리치료학과

Development and Usability Evaluation of Hand Rehabilitation Training System Using Multi-Channel EMG-Based Deep Learning Hand Posture Recognition

Sung Moo Ahn¹, Gun Hee Lee¹, Se Jin Kim¹, So Jeong Bae², Hyun Ju Lee²,
Do Chang Oh^{1*} and Ki Sik Tae^{1*}

¹Department of Biomedical Engineering, ²Department of Physical Therapy, Konyang University
(Manuscript received 30 September 2022 ; revised 15 October 2022 ; accepted 21 October 2022)

Abstract: The purpose of this study was to develop a hand rehabilitation training system for hemiplegic patients. We also tried to find out five hand postures (WF: Wrist Flexion, WE: Wrist Extension, BG: Ball Grip, HG: Hook Grip, RE: Rest) in real-time using multi-channel EMG-based deep learning. We performed a pre-processing method that converts to Spider Chart image data for the classification of hand movement from five test subjects (total 1,500 data sets) using Convolution Neural Networks (CNN) deep learning with an 8-channel armband. As a result of this study, the recognition accuracy was 92% for WF, 94% for WE, 76% for BG, 82% for HG, and 88% for RE. Also, ten physical therapists participated for the usability evaluation. The questionnaire consisted of 7 items of acceptance, interest, and satisfaction, and the mean and standard deviation were calculated by dividing each into a 5-point scale. As a result, high scores were obtained in immersion and interest in game (4.6±0.43), convenience of the device (4.9±0.30), and satisfaction after treatment (4.1±0.48). On the other hand, Conformity of intention for treatment (3.90±0.49) was relatively low. This is thought to be because the game play may be difficult depending on the degree of spasticity of the hemiplegic patient, and compensation may occur in patient with weakened target muscles. Therefore, it is necessary to develop a rehabilitation program suitable for the degree of disability of the patient.

Key words: Convolutional Neural Network (CNN), EMG, Hand rehabilitation, Hand posture recognition, Usability evaluation

*Corresponding Author : Do Chang Oh
Dept. of Biomedical Engineering, Konyang University, 158
Gwanjeodong-ro, Seogu, Daejeon, 35365, Republic of Korea
Tel: +82-42-600-8522
E-mail: docoh@konyang.ac.kr
*Corresponding Author : Ki Sik Tae
Dept. of Biomedical Engineering, Konyang University, 158
Gwanjeodong-ro, Seogu, Daejeon, 35365, Republic of Korea
Tel: +82-42-600-8518
E-mail: tae@konyang.ac.kr

본 연구는 2021년도 정부(과학기술정보통신부)의 재원으로 한국연구재단 기초연구사업의 과제의 지원을 받아 수행하였음(No. 2021R111A304391111).

1. 서론

뇌졸중(stroke)은 성인의 3대 사인 중의 하나로 성인병의 증가와 더불어 그 발생빈도가 점차 증가되고 있는 추세이며, 이로 인해 편마비(hemiplegia) 환자의 비율 또한 높아지고 있다[1]. 편마비 환자의 신체적 문제는 우울, 불안, 자존감 저하 등의 심리적인 문제를 발생시킨다[2]. 따라서 편마비 환자의 기능 장애를 최소화하고 건강한 정신 상태를 유지하기 위해서 재활 운동에 대한 동기를 부여하고 실제 일상생활에서 실시할

수 있는 재활 운동의 지침을 주는 것이 무엇보다 중요하다.

재활 치료는 주기적으로 병원 통원 시 의사가 지정해 준 동작을 반복적으로 취하며 정상적인 움직임의 할 수 있도록 유도하는 방법이다. 하지만 이러한 운동 치료의 문제점은 전문가의 지시에 따라 시행되어 환자 스스로 정확한 자세를 취하기 어렵고, 일정한 동작을 반복적으로 수행하므로 환자에게 있어 무료함을 느낄 수 있기 때문에 적극성 및 집중도 부족으로 인해 재활 과정에서 효과를 결정하는 중요 요소인 재활 동기가 떨어질 수 있다[3]. 또한, 동기부여와 재활 결과는 긍정적인 상관관계가 있기 때문에 흥미성과 적극성을 유발하는 기능성 게임은 기존의 재활 운동에 비해 기능적 향상과 환자의 삶의 질 향상으로 이어질 가능성이 높다[4]. 그러나 일반인을 대상으로 상용화된 게임기들은 게임의 난이도 및 속도, 인터페이스 부분에서 환자에게 적용하기 어려움을 보인다. 따라서 환자의 수준에 따른 맞춤형 재활 전용 게임 개발이 요구된다[5].

근전도 신호는 사용자의 움직임 의도를 직접적으로 나타내고 신체의 움직임 시 실제 동작보다 근육의 전기신호가 미리 측정된다는 특성이 있다[6]. 근전도를 활용한 인간-기계 사이의 인터페이스는 전극을 통해 얻게 되는 근전도 신호로 의도를 해석할 수 있기 때문에, 게임을 실행할 때 상용화된 게임기들의 조이스틱이나 리모컨에 비교하면 환자에게 쉬운 인터페이스를 제공할 수 있다. 또한, 실제 신체 움직임이 일어나기 이전에 신호가 선행하므로 모션 카메라나 각속도 센서를 이용한 재활 시스템을 사용하여 움직임의 의도를 추정하는 것 보다 앞서 의도를 해석할 수 있는 장점이 있어 게임에 구동 시 명령에 필요한 생체신호 처리 시간 측면에서 효율적이다[7]. 그러나 근전도 신호는 시간이 지남에 따라 신호 자체의 변화하는 특성, 전극 위치 이동, 근육 피로, 근육 수축 강도의 변화[8-10] 등으로 인해 동작을 분류하기 힘든 특성을 가진다. 또한 편마비 환자는 움직임이 작고 근활성도가 낮아 유도되는 근전도 신호를 통해 동작을 인식하고 예측하는데 어려움이 있다. 편마비 환자를 대상으로 하는 근전도 기반 재활 시스템의 경우 인공지능과 같은 우수한 생체 신호 분석 기능을 가지는 알고리즘을 사용한다면, 사용자의 근전도 신호로부터 진폭(amplitude), 주파수(frequency), 발생 기간(duration) 등의 특징을 추출하여 학습하는 방식으로 사용자의 미세한 움직임으로부터 동작 의도를 인식할 수 있어 유용하다[11].

최근 움직임에 의해 유도되는 근전도 신호를 자동으로 분류하는 패턴 인식 기반 인공지능 알고리즘이 많이 활용되고 있다. 머신러닝(선형 판별 분석(LDA), K-Nearest Neighbor(KNN), 서포트 벡터 머신(SVM), 인공 신경망(ANN)) 기술은 효과적인 근전도 제어를 위한 알고리즘으로써, 근전도를 활용한 재활기기, 인간-컴퓨터 상호 작용의 제어 부분에서 우수한 분류 정확도를 보여주며 시간이 지남에 따라 발전해왔다[12]. 이 중

딥러닝 기술은 다른 머신러닝(ML) 기술의 문제점인 기능 추출과 대규모 데이터 세트를 효율적으로 처리할 수 없는 두 가지 한계를 보완하였다. 최근 대부분의 딥러닝 알고리즘은 동작 분류의 우수성과 머신러닝 알고리즘에 비해 더 낫다는 연구 결과를 보여준다[13]. Park 등은 표면 근전도(sEMG)의 분류를 위해 딥러닝을 사용한 SVM보다 12%~18% 더 성능이 우수하다고 결론지었으며[14], Atzori 등은 기존 머신러닝 기법(KNN, SVM 및 LDA)과 비교하여 딥러닝(CNN)의 우수한 성능을 보여주었다[15]. 합성곱신경망(CNN : Convolution Neural Network)은 컨볼루션 필터와 풀링 작업을 사용하여 입력으로부터 공간 특징을 추출하는 방식을 기반으로 하며, 이미지 분류 문제에서 우수한 성능을 보여주는 아키텍처이다. 선행 연구들에선 높은 분류 성능을 보이는 아키텍처를 탐구하기 위한 방법으로 표면 근전도 신호를 이미지화하는 방식을 제시하였고, CNN으로 학습했을 때 분류 성능이 가장 우수함을 보였다. Allard 등은 근전도용 웨어러블 센서(Myo Armband)를 이용한 실시간 애플리케이션에서 CNN의 성능을 보여주었고 97.8%의 분류 정확도를 달성했다[16]. Ozdemir 등은 4채널 표면 근전도 신호를 측정하여 CNN을 활용하였을 때 95.9%의 분류 정확도를 가지는 손동작 인식 시스템을 개발하였고[17], Nahid 등은 표면 근전도와 CNN-LSTM 신경망 아키텍처를 적용하여 근전도 의수에 적합한 제어 시스템을 연구한 사례를 보였다[18].

따라서 본 연구에서는 표면 근전도와 합성곱신경망(CNN)을 사용하여 손동작 인식 기반 손재활 게임을 개발하고자 하였다. 재활에 필요한 동작 5가지를 선정한 후 각 동작에 대해 다채널 근전도 센서를 활용하여 손동작의 데이터를 수집하였으며, CNN 딥러닝 알고리즘을 적용한 재활 게임을 제작하였다. 또한, 실시간 손동작 인식을 통해 편마비 환자의 효과적인 재활치료를 유도하고 환자의 의도를 반영하는 재활치료용 게임을 개발한 후, 사용성 평가를 통해 검증하고자 하였다.

II. 연구 방법

1. 손 동작 인식 기반 재활 훈련시스템

본 연구에서는 Myo armband 표면 근전도 센서와 합성곱신경망(CNN : Convolution Neural Network)을 이용해 손목의 각도와 손가락 굽힘에 따른 손동작 인식을 통해 손동작 인식 기반 재활 게임을 개발하고자 하였다. 사용자의 아래팔 근전도 데이터를 얻기 위해 Myo armband가 포함된 입력부, 신호처리부, 구현 및 출력부로 나누었다. 그림 1은 본 연구에서의 시스템 설계를 위한 블록도를 나타낸다. Myo armband는 사용자의 근전도 데이터를 컴퓨터와 블루투스 통신을 가능하게 하는 기능만을 제공하기 때문에 실시간 동작 인식을 위해서는 딥러닝을 통한 별도의 학습이 필요하다. 따라서 사용자




그림 1. 전체 시스템 블록도
Fig. 1. Block diagram of system

가 손동작을 취하면 미리 학습된 딥러닝 모델을 통해 실시간으로 동작을 분류하고, 각 동작에 따라 게임상에서 이벤트가 발생하도록 구성하였다. 게임의 경우 규칙적으로 이벤트를 발생시켜야 하는 DDR(Dance Dance Revolution) 게임과 가위바위보 게임으로 선정하였다.

2. 근전도 데이터 수집

(1) 손 재활 동작 선정

본 연구에서는 편마비 환자의 손 재활 훈련을 목적으로 한다. 편마비 환자의 재활은 굽혀진 손가락을 반복적으로 펴주고, 잡기 또는 쥐기 동작 훈련을 통해 일상생활에서 환자가 원하는 동작을 독립적으로 수행 가능하도록 해야 한다. 그러나 편마비 환자의 손은 굽힘 공동운동(flexor synergy)이 강하게 발달되어 있어 환측의 손을 굽힌 상태로 유지하여 펴 동작 수행에 어려움이 있기 때문에 원활한 게임 진행이 불가능할 수 있고 재활 훈련의 효과 또한 미비할 수 있다.

따라서 본 연구 개발을 위해 적용 가능한 편마비 환자의 기준을 명확히 하는 것이 필요했다. 대부분의 편마비 환자는 브룬스트롬(Brunnstrom) 5단계(표 1)를 기준으로 강직 정도를 분류하는데, 브룬스트롬 1단계는 이완성 단계로 능동적인 손의 기능을 전혀 할 수 없고, 2단계는 손 전체로 잡기(gross grip)가 시작되며 약간의 능동적인 손가락 굽힘이 가능하다. 3단계는 손 전체로 잡기와 훅모양 잡기(hook grip)가 가능하며, 4단계는 가쪽 쥐기(lateral prehension)가 발달하면서 약간의 손가락 펴(finger extension)와 엄지손가락을 움직일 수 있다. 5단계는 볼 잡기(ball grip)와 원통 잡기(cylindrical grip) 등의 물건을 잡는 듯한 동작이 가능하며, 6단계는 모든 형태의 손 움직임이 가능하다. 본 연구의 재활 대상으로써 손

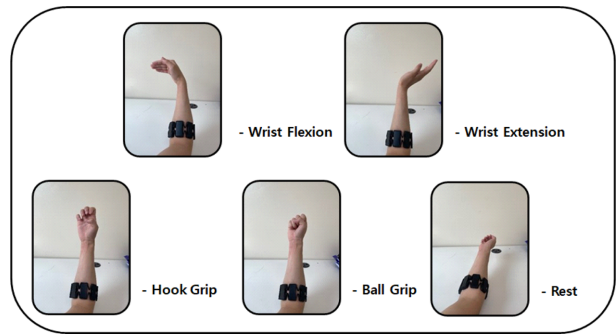


그림 2. 데이터 수집을 위해 선정한 손 동작
Fig 2. Selected hand gestures for data collection

의 움직임을 저해하는 관절가동범위의 제한이 없고, 정상보다 낮은 수준이지만 꾸준한 훈련을 통해 손 재활이 가능한 브룬스트롬 5단계의 환자로 선정하였다.

기본적인 손 재활운동은 주로 손과 손목에 해당하는 각 관절 부위를 중심으로 매우 약한 힘을 가해 스트레칭하거나 잡기 또는 쥐기 등의 반복적인 손 동작을 통해 이루어진다. 본 연구에서는 여러 손 재활 동작[19] 중에서, 4가지 (WF: Wrist Flexion, WE: Wrist Extension, BG: Ball Grip, HG: Hook Grip) 동작에 기반을 두어 재활 운동을 구성하였다. RE(Rest) 동작은 추후 게임 구동을 위한 자세이며, 재활 동작에 포함되지 않았다(그림 2).

(2) 근전도 데이터 측정

실험에 사용한 근전도 데이터는 탈믹랩스(Thalmic Labs)에서 제조한 Myo armband를 통해 획득하였다. Myo armband는 8개의 건식 전극이 압밴드 형태로 구성되어 있으며, 9축 IMU (Inertial Measurement Unit) 센서를 포함한다. 최대 표면 근전도 샘플링 주파수는 200 Hz, IMU 샘플링 주파수는 50 Hz로 원시 데이터(raw data) 출력이 가능하다. 또한 Myo armband는 신호의 잡음 제거를 위해서 20~200 Hz의 Band Pass Filter를 내장하여 사용하였다. 표면 근전도 및 IMU 데이터는 Bluetooth (BLE4.0)를 이용하여 무선으로 PC와 통신하였다. 연구에서는 근전도 센서만 사용하였다. 딥러닝 학습에 필요한 데이터는 건

표 1. 브룬스트롬 손 회복 단계

Table 1. Brunnstrom stages for hand recovery hand recovery stage

Stage	Characteristic
Stage 1	There is no hand function at all.
Stage 2	The gross grip begin and can bend your fingers a little bit
Stage 3	It is possible to gross grip and hook grip.
Stage 4	As lateral grip develops, some finger stretching and thumb movement are possible.
Stage 5	It is possible to ball grip, cylindrical grip, and put things.
Stage 6	All types of grip are possible, and individual finger movements are possible.




그림 3. Myo armband 착용 위치
Fig. 3. Myo armband wearing position

강한 성인 남성 5명을 대상으로 수집하였다. 실험 대상자들은 그림 3과 같이 Myo Armband의 상단의 LED 표시기가 손을 향하게 오른쪽 아래팔에 착용하고, 의자에 앉아 책상에 오른팔을 올린 후 선정된 5가지 동작(WF, WE, BG, HG, RE)을 취하였다.

데이터는 각 동작 당 2초 동안 1회씩 취하는 것을 기준으로 하였다. 데이터 취득 프로그램의 동작 신호와 휴식 신호에 맞추어 2초 동안 동작을 1회 수행한 후, 2초 휴식을 하였다. 한 동작을 취할 시 Myo armband의 8개 채널에서 각각 200 Hz의 주파수로 샘플을 취득하여 1개의 데이터를 만들었으며, 5명으로부터 5가지 동작을 각각 60번씩 취하여, 1,500개의 데이터를 수집하였다. 각 동작 당 60개의 데이터 중 54개는 훈련 데이터(Train data) 6개는 검증 데이터(Test data)로 분류하여, 1,350개의 데이터로 구성된 훈련 데이터 세트(Train data set)와, 150개의 데이터로 구성된 검증 데이터 세트(Test data set)를 제작하였다. 제작한 데이터 세트는 전처리(pre-processing) 과정을 진행하여 최종적으로 8각형 Spider Chart의 이미지 형태 데이터로 변환하였다.

3. 전처리 및 CNN모델 설계

(1) Spider Chart와 그래프 생성

Spider Chart란 동심원 위에 점을 찍어 그 도형의 모양으로 변수 분포를 확인하는 데 쓰이는 Chart이며, 전처리로 사용된 Spider Chart는 각 변수에 대해 가질 수 있는 값의 범위

가 모두 같다. 또한 둘 이상의 Spider Chart를 비교하는 데 있어 변수 및 특성을 직관적으로 확인할 수 있어 데이터 분류에 용이하다.

전처리 과정은 다음과 같이 진행하였다. 하나의 근전도 샘플은 8개의 채널로 구성되어 있으며, 각 채널당 데이터의 값은 -125부터 +125 사이의 값이 측정된다. 측정된 ±125의 데이터 값들에 절댓값을 취해준 뒤, 각 채널의 데이터 값의 특징점은 MAV 기법으로 추출해 주었다. 근전도 데이터는 측정 시 피험자의 자세 또는 근피로도 등 생리학적 변화에 많은 영향을 받는다. 따라서 기존 근전도 데이터를 분석하는 데 사용되던 푸리에 변환이 아닌, 불안정한 데이터를 분석하는데 용이한 MAV 기법을 사용해 주었다. MAV 기법이란 근전도 신호의 특징을 분류하는 데 있어 자주 사용하는 기법으로, 근전도 샘플의 절댓값의 평균을 말한다. 식 (1)은 MAV를 보여준다.

$$MAV = \frac{1}{N} \sum_{k=1}^N |X_k| \quad (1)$$

분류된 특징들은 정규화 과정을 통해 일정한 범위 안의 값들로 만들어 주었다. 이후 채널별로 평균값의 크기가 작은 하위 4개의 값은 0으로 변경하고, 상위 4개의 값으로 팔각형 Spider Chart에 나타내 주었다. 그림 4는 전처리 과정을 거친 데이터의 형태이다.

(2) 합성곱신경망(CNN) 적용 및 평가

CNN(Convolutional Neural Network)은 근전도 패턴 인식에서 가장 널리 사용되는 딥러닝 방법이며, 앞선 연구들에서 성능이 입증되었다. CNN은 기능에 따라 4개의 영역 입력 계층, 컨볼루션 계층(convolution layer), 풀링 계층(pooling layer) 및 완전 연결 계층(fullconnected layer)으로 나눌 수 있다. 입력 계층은 많은 인공 신경망에서 볼 수 있는 가장 일반적인 계층이다. 컨볼루션 레이어는 가중치와 입력 볼륨에 연결된 영역 간의 스칼라 곱 계산 통해 입력의 로컬 영역에 연결된 뉴런의 출력을 결정한다. 풀링 레이어는 네트워크에서 학습해야 하는 매개 변수 수를 줄여서 출력을 간소화한다. 풀링 계층 이후에는 완전 연결 계층을 사용하여 일반적인 인공




그림 4. 최종 데이터 형태
Fig. 4. Final data form

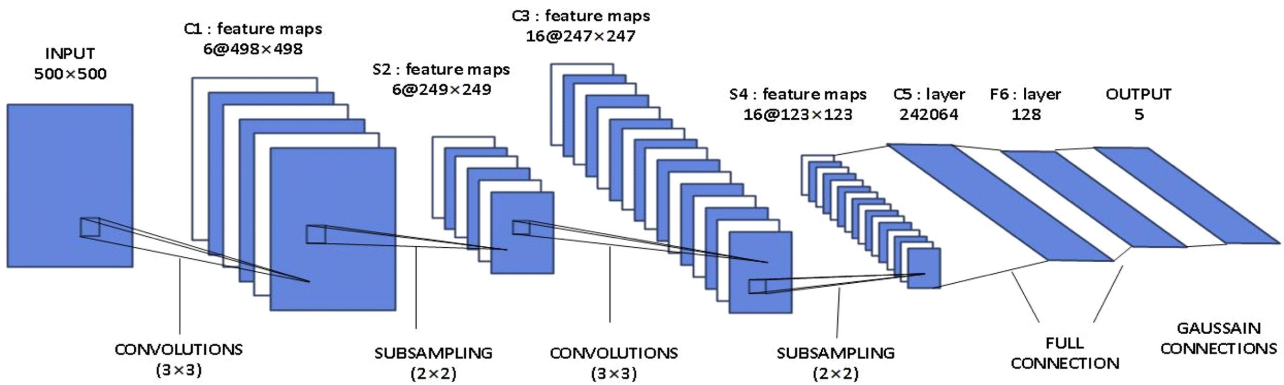


그림 5. CNN 모델 구조
Fig. 5. CNN model structure

신경망 절차를 수행한다[20].

본 연구에서 사용한 CNN의 구조는 그림 5와 같이 컨볼루션 레이어(C1, C3)에는 기울기 소실 문제를 방지하는 Relu (rectified linear unit) 함수를 적용하였고, C5는 다중 클래스 분류 시 적합한 softmax 함수를 적용하였다. F6은 128개의 뉴런을 가진 피드포워드 신경망이며, 아웃풋 레이어는 최종적으로 이미지가 속한 클래스를 분류하도록 손동작 수와 일치하는 7개의 뉴런을 가지도록 설정하였다(표 2). 모델의 overfitting 문제를 해결해 주기 위해 dropout을 0.75로 설정했으며, 손실 함수(loss function)는 출력층인 softmax 함수에 맞추어 categorical_crossentropy를 적용하였고, optimizer는 덤퍼닝 최적화 기법 중 하나로써 Momentum과 RMSProp의 장점을 결합한 Adam(Adaptive Moment Estimation)을 적용했다. 모델의 학습은 python 모듈을 이용하였으며, 전처리된 손동작 데이터를 라벨링(labeling) 된 훈련 세트(training set) 90%(1350개)와 평가 세트(test set) 10%(150개) 나누어 300epoch의 지도학습 형태로 진행하였다.

표 2. 모델 레이어 정의 및 구조
Table 2. Definition and structure of model layer

Layer (type)	Output Shape
conv2d (Conv2D)	(498, 498, 6)
max_pooling2d (MaxPooling2D)	(249, 249, 6)
conv2d_1 (Conv2D)	(247, 247, 16)
max_pooling2d_1 (MaxPooling2D)	(123, 123, 16)
dropout (Dropout)	(123, 123, 16)
flatten (Flatten)	(242064)
dense (Dense)	(128)
dropout_1 (Dropout)	(128)
dense_1 (Dense)	(5)

4. 재활게임 콘텐츠 개발

(1) 게임 개요

본 연구에서는 개발된 손동작 인식 재활 훈련 시스템은 재활치료를 위한 게임 콘텐츠의 구현을 목표로 하였다. 게임은 Python 모듈의 Pygame을 통해 개발하였으며, Myo Armband를 착용하여 실시간으로 Pygame과 연동하여 진행하였다. 게임은 기본적으로 편마비 환자의 손 재활을 위한 운동 중 ‘쥐기, 펴기, 굽히기’ 운동을 통해 얻어지는 아래팔의 표면 근전도 신호를 측정하여 그 센서 값들을 게임 요소로 사용하였다. 이는 제작한 손동작 인식 기반 재활 훈련 시스템의 Myo Armband 근전도로 측정하였고, 이를 통해 얻어진 데이터들은 Myo Armband의 자체 기능인 블루투스를 사용하여 실시간으로 게임과 연동되도록 제작하였다. 그리고 손목과 근육의 유연성 향상 및 굽힘과 펴를 반복적으로 수행할 수 있도록 게임 콘텐츠를 설계하였다. 게임은 2가지 모드로 나누어 구성되었다. 4가지 재활 동작(WF, WE, BG, HG)으로 이벤트가 발생하여 게임이 동작되는 DDR 게임과, 3가지 재활 동작(WF, WE, BG)으로 게임이 동작되는 가위바위보 게임으로 설계하였다.

(2) 게임 방식 구성

두 게임은 모두 손의 움직임을 인식하고 게임상에서의 이벤트가 발생할 시, 사용자가 지각할 수 있는 적절한 시간이 300 msec 정도임을 참고해 동작 분류의 시간을 200 msec로 설정했다.

DDR 게임은 손가락 DDR 게임의 형태로(그림 6), 게임 오브젝트(상하좌우 화살표)가 위에서 아래쪽으로 랜덤으로 떨어지는 형태로 제작하였고, 게임 오브젝트가 빨간색 클리어 존 안에 위치했을 때 오브젝트를 사라지게 해 점수를 올리는 방식으로 진행되었다. 이에 따라 사용자가 Myo Armband를 착용하고 손동작으로부터 얻어지는 센서 값들을 인식하여 빨간색 클리어 존 안에서 오브젝트를 사라지게 할 수 있도록 설

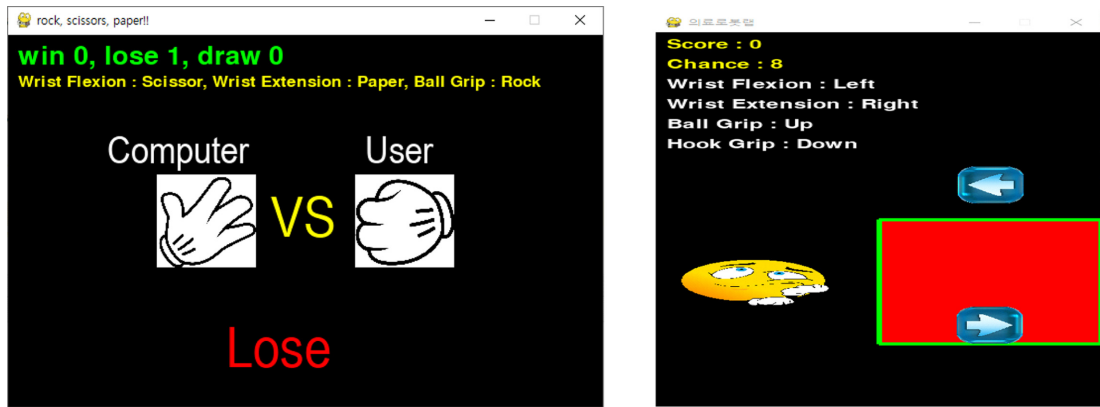


그림 6. 재활 게임 구동(좌측 : 가위바위보 게임, 우측 : DDR 게임)
 Fig. 6. Driving a rehabilitation game(Left : rock-paper-scissors, right: DDR)

계하였다. 게임 화면 좌측 상단에 Score와 Chance를 표시해 두었으며, 환자가 타이밍에 맞춰 정확한 손동작을 취하게 되면 Score가 오르고 타이밍이 틀리거나 동작이 올바르지 않으면 Chance가 감소하게 된다. 손동작의 모양은 Rest 동작을 기준으로 시작하여 WF 동작을 취하면 왼쪽 화살표, WE 동작을 취하면 오른쪽 화살표, BG 동작을 취하면 위쪽 화살표, HG 동작을 취하면 아래쪽 화살표가 인식되도록 하였다.

가위바위보 게임은 컴퓨터와 가위바위보를 겨루는 형태로 제작하였다(그림 6). DDR 게임과 마찬가지로 Myo Armband를 착용하고 센서 값들을 인식하여 이벤트가 발생하도록 설계하였으며, 사용자가 재활 동작을 취하면 User 란에 가위, 바위, 보가 출력되며 그와 동시에 PC화면 아래에도 가위, 바위, 보가 랜덤으로 출력돼 승부를 가린다. 손동작의 모양은 Rest 동작을 기준으로 시작하여 WF 동작을 취하면 가위를 내고, WE 동작을 취하면 보를 내며 BG 동작을 취하면 바위를 내도록 하여 가위바위보 대결을 하는 게임으로 설계하였다. 승패 문의 결과는 왼쪽 상단 위에 스코어로 표시되게 설정했으며, 승부 결과는 하단 가운데 부분에 표시되도록 하였다. 한번의 게임이 끝난 후 Rest 동작을 취해야 다음 승부로 넘어갈 수 있게 하였다.

5. 사용 만족도 평가

본 연구의 참여 대상은 대전지역에 위치한 의료기관의 물리치료사 10명이었다. 사용 평가 진행 전, 모든 참여자는 본 연구에 대한 목적, 방법 그리고 절차에 대한 설명을 듣고 연구 참여에 동의하였다.

만족도 조사 결과는 7개의 항목에 대해 각각 5점 척도(1점: 매우 만족하지 않는다, 2점: 만족하지 않는다, 3점: 보통이다, 4점: 만족한다, 5점: 매우 만족한다)로 구분하여 평균과 표준편차를 산출하였다. 질문의 유형은 수용 정도, 흥

미도, 만족도를 묻는 문항으로 구성하였으며 수용 정도 파트는 치료 목적 의도에 적합한지, 게임 콘텐츠는 적절한지, 치료의 사용성이 기대되는지를 평가하였다. 흥미도 파트는 게임의 디자인이 친근하게 다가왔는지 정도를 평가하였다. 만족도 파트는 기기 탈부착이 편리한지, 장비의 조작이 안정성을 가지는지, 사용을 진행한 후 사용에 대한 만족감으로서 총 7가지 문항을 평가하였다.

III. 연구 결과

1. 학습모델 및 손동작 인식 정확도 평가

개발한 CNN 모델의 학습은 python 모듈을 이용하였으며, 전처리 된 손동작 데이터 샘플(1,500개) 중 90%(1,350개)는 훈련 세트(training set), 10%(150개)는 평가 세트(test set)로 나누어 300epoch(300회 학습)의 지도학습을 진행했다. 학습 결과 모델의 정확도는 95%를 보였다.

손동작 정확도 평가는 건강한 성인 5명을 대상으로 앞서 훈련된 CNN 모델을 기반으로 진행하였으며, 동작 인식 성능을 테스트하기 위해 게임에서의 동작 인식 속도인 200msec와 동일하게 모션 분류 시간을 설정하였다. 표면 근전도 데이터 수집 때와 마찬가지로 Myo Armband의 상단의 LED 표시기가 손을 향하게 오른쪽 아래팔에 착용하고 의자에 앉아 책상에 오른팔을 올린 후 테스트를 진행했다. 1명의 실험자로부터 한 동작 당 200회의 분류 결과를 얻고자 했으며, 한 동작 당 5초 측정, 5초 휴식을 1 사이클로 8회 반복하여 측정하였다(40 sec/200 msec=200). 5명의 실험자들로부터 5가지 동작의 분류 결과를 취득했으며, 표 3은 손동작 별 인식 정확도를 보여준다. WF 동작은 93%, WE 동작은 94%, BG 동작은 90%, HG 동작은 92%, RE 동작은 97%의 정확도를 각각 나타내었다(표 3).

표 3. 5개 손동작 인식 정확도

Table 3. Prediction accuracy of 5 hand postures

Motion	No.	1	2	3	4	5	Sum (number)	Accuracy (%)
		Success/Fail						
WF		187/13	183/17	189/11	195/5	180/20	934/66	93
WE		190/10	185/15	191/9	193/7	188/12	947/53	94
BG		181/19	177/23	185/15	183/17	177/23	903/97	90
HG		182/18	180/20	189/11	183/17	186/14	920/80	92
RE		194/6	192/8	197/3	192/8	198/2	973/27	97

표 4. 사용성 평가 결과

Table 4. The result of usability evaluation

Questions (n=10)	Min	Max	Mean±SD
Conformity of intention for treatment	3	5	3.9±0.49
Difficulty level of game manipulation	2	5	3.7±0.88
Expectations of treatment effectiveness	3	5	3.8±0.45
Interest in gaming design	3	5	4.6±0.43
Convenience of the device	4	5	4.9±0.30
Stability of system operation	3	5	4.3±0.78
Satisfaction after treatment	3	5	4.1±0.48

2. 사용 만족도 평가

다음은 물리치료사 10명을 대상으로 게임 수행 후 만족도 평가를 실시한 결과를 나타낸다(표 4).

실험에 참여한 대다수가 병원에서 진행되는 일반적인 손 재활치료 방식보다 게임을 활용한 재활치료 과정이 몰입감과 흥미가 느껴졌다고 하였다. 개발 시스템의 편리성은 4.9점, 흥미도는 평균 4.6점으로 앰밴드를 사용해 게임을 조작하면서 인공지능을 통한 정확한 동작 운동을 유도한다는 점에서 시스템이 간단하고 흥미롭다고 평가하였다. 하지만 게임 조작 편리함 정도는 가장 낮은 결과(3.7점)가 도출되었는데 이는 환자의 특성에 따른 다양한 콘텐츠가 필요하며 환자의 상태에 따라 차후 이를 자동 진행하는 체크박스 이벤트를 추가하여 편리성을 제공하고 환자 스스로 속도 등의 난이도를 쉽게 수정할 수 있는 다이얼 방식의 모드 개선이 필요할 것으로 보인다.

치료 목적 의도의 적합성은 평균 3.9점의 평가를 받았는데, 편마비 환자의 강직(spasticity) 때문에 게임의 원활한 수행에 어려움이 있을 수 있고 목표 근육의 약화가 있는 환자의 경우 보상작용이 발생할 수 있으므로 이에 대한 보완이 필요하다고 응답하였다. 또한 환자의 장애 수준에 맞는 맞춤형 재활 프로그램이 요구된다.

IV. 고찰 및 결론

본 연구에서는 근전도 센서가 내장되어 있는 웨어러블 모

듈인 Myo armband를 사용하여, CNN을 활용한 실시간 동작 인식의 정확도 개선을 통해 좀 더 정확하고 효과적인 재활치료를 유도하고자 하였다. 또한 환자의 의도를 반영하는 재활치료용 게임을 개발하고 본 시스템에 대한 사용 만족도 평가를 통해 검증하였다. Ozdemir 등은 4채널 표면 근전도 신호를 측정해 CNN을 활용해 손동작 인식 시스템을 개발하였고[17], Nahid 등은 표면 근전도와 CNN-LSTM 신경망 아키텍처를 적용하여 근전도 의수에 적합한 제어 시스템을 연구하였다[18]. Asif 등은 18명의 대상자의 표면 근전도 데이터에서 10개의 손 제스처를 결정하고 분류하기 위해 CNN을 딥러닝 방법으로 사용하여 close hand 83.7%, flex hand 71.2%, extend hand 82.6% 및 fine grip 74.6%의 손동작 인식률을 보였다[21].

본 연구에서도 앞선 연구들에서 효과가 검증된 표면 근전도를 활용해 손동작의 데이터를 수집하여 WF 동작은 93%, WE 동작은 94%, BG 동작은 90%, HG 동작은 92%, RE 동작은 97%의 정확도를 나타내었다. WF 동작과 WE 동작은, 동작을 취하는 데 있어 손과 손목에 움직임이 차이가 크기 때문에 Myo Armband를 착용한 아래팔 근육의 근전도 데이터의 특징을 분류하기 용이해 정확도가 비교적 높게 측정되었다. BG와 HG의 경우 상대적으로 낮은 정확도를 보였다. 이는 두 동작의 유사성으로 인한 문제로 보인다. 근전도를 사용한 제스처 인식이 어려운 이유중 하나는, 근전도 데이터가 피험자의 팔의 두께나 측정 자세 등의 생리학적 변화에 많은 영향을 받는 것이다[10-12]. 본 연구의 데이터 측정 시에도 동

작이 유사한 BG과 HG의 경우 정확한 동작 및 자세를 취하지 않을 경우 동작별로 정형화된 Spider Chart가 아닌, 서로 유사한 Spider Chart가 생성되는 현상을 확인 할 수 있었다. 이러한 현상은 그림 4의 Spider Chart 데이터 세트로 학습된 모델을 기반으로 하는 동작 분류 평가 시, 피험자의 상태(동작, 자세)에 따라 BG은 HG으로, HG은 BG으로 인식하는 결과로 이어질 수 있다. 이러한 이유로 BG와 HG의 경우 상대적으로 낮은 정확도를 보였다 사료된다. RE 동작의 경우 가장 높은 정확도가 측정되었다.

개발한 시스템은 물리치료를 대상으로 사용성 평가를 진행하였는데, 그 결과 대다수로부터 게임을 활용한 재활치료 과정이 몰입감과 흥미가 느껴졌다는 긍정적인 평가를 얻었으며, 환자의 흥미를 유발하기에도 적합하다는 응답을 얻었다. 더하여, Myo armband 하나로 게임을 구동할 수 있어 간편하고 효율성이 좋다는 응답을 얻었다. 하지만 환자의 흥미를 유발하는 게임 내의 요소들이 부족하다는 응답과 편마비 환자의 특성상 편마비 정도에 따라 다양한 편마비 환자에게 적용이 어려울 것이라는 응답이 있었다. 또한 게임 진행에 대한 설명 부족으로 인해 치료를 마친 후 만족감이 낮다는 평가를 받았다.

추후 흥미를 유발하는 요소(배경음, 효과음)를 추가하고, 편마비 단계에 따른 게임의 난이도 조절 모드를 개발할 필요가 있다. 또한, 원활한 게임 플레이를 위해 직관적인 UI 개선이 필요할 것으로 보인다. 아직 본 연구에서 개발한 재활시스템은 병원이나 가정 등에서 사용되기에는 부족한 부분이 많은 것으로 판단되나, 사용성 평가 결과를 바탕으로 시스템을 개선한다면 제품의 사용성 및 만족도는 더욱 높아질 것으로 기대된다. 또한, 차후 문제점을 보완하여 실제 편마비 환자를 대상으로 사용성 평가 및 임상실험을 통한 검증이 필요하다.

본 연구에서 개발한 인공지능을 이용한 손동작 인식 기반의 손 재활 훈련 시스템의 사용성 평가에서 대부분 긍정적인 평가와 치료 시 사용 의사를 보였다는 점에서 계획했던 목표와 부합한 것으로 판단된다. 또한, 손동작 이외 다른 근육에도 적용이 가능한 치료 보조 수단으로써 임상뿐만 아니라 가정에서도 쉽게 적용 가능할 것으로 사료된다.

References

- [1] Roh GH. The Effect of Aerobic Walking Exercise Program on Walking, Balancing, Performance of Daily Activities, and Depression in Stroke Patients. *The Korean Journal of Rehabilitation Nursing*. 2002;5(3):193-204.
- [2] Lee KH. Correlation among the stroke patient familie's health status, burden and of life. *J Korean Acad Nurs*. 2001; 31(4):669-80.
- [3] Park SJ, Song KS, Lee HJ, Tae KS. Development and Usability Evaluation of a Functional Game Based on Inertial Sensor for Knee Rehabilitation in Total Knee Arthroplasty Patient. *Journal of Rehabilitation Welfare Engineering & Assistive Technology*. 2019;13(2):127-33.
- [4] Lee CJ. A Serious Game for Language/Cognitive Rehabilitation Therapy of Stroke Patients. *Journal of Koen*. 2011; 5(1):73-80.
- [5] Aenderson F, Annett M, Bischof WF. Lean on wii: physical rehabilitation with virtualreality wii peripherals. *Studies in healthtechnology and informatics*. 2010;154:229-234.
- [6] Tagliapietra L, Vivian M, Sartori M, Farina D, Reggiani M. Estimating EMG signals to drive neuromusculoskeletal models in cyclic rehabilitation movements. 2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). 2015;3611-3614.
- [7] Kim KS, Choi HH, Mun CW. Comparison of k-nearest neighbor, quadraticdiscriminant and linear discriminant analysisin classification of electromyogram signalsbased on the wrist-motion directions. *Current applied physics*. 2011;11(3): 740-745.
- [8] Scheme E, Englehart K. Training Strategies for Mitigating the Effect of Proportional Control on Classification in Pattern Recognition-Based Myoelectric Control. *JP O Journal of Prosthetics and Orthotics*. 2013;25(2):76-83.
- [9] Phinyomark A, Quaine F, Charbonnier S, Serviere C, Tarpin-Bernard F, Laurillau Y. EMG Feature Evaluation for Improving Myoelectric Pattern Recognition Robustness. *Expert Syst*. 2013;40(12):4832-40.
- [10] Tkach D, Huang H, Kuiken TA. Study of Stability of Time-Domain Features for Electromyographic Pattern Recognition. *Journal of neuroengineering and rehabilitation*, 2010;7(1):21.
- [11] Ren JL, Chien YH, Chia EY, Fu LC, Lai JS. Deep Learning based Motion Prediction for Exoskeleton Robot Control in Upper Limb Rehabilitation. 2019 International Conference on Robotics and Automation (ICRA). 2019;5076-5082.
- [12] Yousefi, Hamilton-Wright J. Characterizing EMG data using machine-learning tool. *Computers in biology and medicine*. 2014;51:1-13.
- [13] Schmidhuber J. Deep learning in neural networks: An overview. *Neural Networks*. 2015;61:85-117.
- [14] Park KH, Lee SW. Movement intention decoding based on deep learning for multiuser myoelectric interfaces. In *Proceedings of the 2016 4th International Winter Conference on Brain-Computer Interface(BCI)*. 2016.
- [15] Atzori M, Cognolato M, Muller H. Deep learning with convolutional neural networks applied to electromyography data. A resource for the classification of movements for prosthetic hands. 2016.
- [16] Cote-Allard U, Fall CL, Campeau-Lecours A, Gosselin C, Laviolette F, Gosselin B. Transfer learning for sEMG hand gestures recognition using convolutional neural networks. In *Proceedings of the 2017 IEEE International Conference on Systems*. 2017;1663-1668.
- [17] Ozdemir MA, Kisa DH, Guren O, Onan A. EMG based Hand Gesture Recognition using Deep Learning. 2020 *Medical Technologies Congress*. 2020.
- [18] Nahid N, Rahman A, Ahad MAR. Deep Learning Based Surface EMG Hand Gesture Classification for Low-Cost Myoelectric Prosthetic Hand. 2020 *Joint 9th International Conference on Informatics, Electronics & Vision (ICIEV)*. 2020.
- [19] <http://www.relayhealth.com>, accessed on Oct. 10, 2022.
- [20] R. Laezza, "Deep Neural Networks for Myoelectric Pattern Recognition An Implementation for Multifunctional Control," 2018.
- [21] Asif AR. Performance Evaluation of Convolutional Neural Network for Hand Gesture Recognition Using EMG Sensors. 2020;20(6):1642.