

손 위치와 손동작 개별 인식을 통한 딥러닝 기반 통증행동 모니터링 시스템의 설계 및 개발

조용훈*, 이현욱*, 백윤주^o

Design and Development of a Deep Learning-Based Pain Behavior Monitoring System through Individual Recognition of Hand Positions and Hand Gestures

Yonghun Cho*, Hyunwook Lee*, Yunju Back^o

요약

급격한 딥러닝 기술의 발전으로 헬스케어 분야에 딥러닝을 접목시켜 환자의 생체정보나 복합적인 상태를 인식하는 연구가 활발히 수행되고 있다. 특히 통증의 효과적인 관리는 환자의 건강상태 개선 및 의료 만족도의 상승으로 이어진다. 본 논문은 손목 밴드 디바이스를 통해 수집된 IMU 센서 데이터를 입력으로 하는 딥러닝 기반 통증행동 모니터링 시스템을 제안한다. 통증행동의 정밀한 인식을 위해 손 위치와 손동작을 개별 인식하는 2개의 CNN 모델과 통증행동을 일상행동으로 인식하는 오인식을 줄이는 HMM 모델을 결합한 모델을 설계했다. IMU 센서 데이터를 수집하는 손목 밴드 디바이스는 저전력 설계를 위해 nRF5240 기반의 MDBT50Q 모듈을 기반으로 설계되었다. 제안하는 시스템은 부산대학교병원의 자문을 받아 선정된 28가지 통증행동을 평균 87.06%의 정확도로 인식한다.

Key Words : Pain-behavior monitoring, deep learning, healthcare, embedded, wristband device

ABSTRACT

With the rapid development of deep learning technology, research on recognizing patients' biometric information or complex conditions by incorporating deep learning into the healthcare field is being actively conducted. In particular, effective management of pain leads to an improvement in the patient's health condition and an increase in medical satisfaction. This paper proposes a deep learning-based pain behavior monitoring system with IMU sensor data collected through wristband devices as input. For precise recognition of pain behavior, we designed a combination of two CNN models that individually recognize hand positions and hand movements and an HMM model that reduces misrecognition of pain behavior as daily behavior. The wristband device, which collects IMU sensor data, is designed based on an nRF5240, based MDBT50Q module for low-power design. The proposed system recognizes 28 pain behaviors selected with advice from Pusan National University Hospital with an average accuracy of 87.06%

※ 이 논문은 부산대학교 기본연구지원사업(2년)에 의하여 연구되었음

• First Author : Pusan National University Department of Information Convergence Engineering, kchoyh95@pusan.ac.kr 학생회원

◦ Corresponding Author : Pusan National University Department of Computer Science and Engineering, yunju@pusan.ac.kr, 종신회원

* Pusan National University, Department of Computer Science and Engineering, gjh2525@gmail.com

논문번호 : 202210-243-C-RN, Received October 11, 2022; Revised December 8, 2022; Accepted December 8, 2022

I. 서 론

최근 몇 년 간 급격한 발전을 이룬 딥러닝 기술은 의료를 비롯한 다양한 분야에 적용되고 있다. 그 중 헬스케어 분야에 딥러닝을 접목시켜 환자의 생체정보 뿐만 아니라 환자의 복합적인 상태를 인식하는 연구가 활발히 수행되고 있다^{1,2)}. 특히 통증은 의료 서비스를 제공받고자 병원을 찾는 주요 원인이며 많은 질병과 관련이 있다³⁾. 통증의 효과적인 관리는 환자의 건강상태 개선 및 의료 만족도의 상승으로 이어진다⁴⁾. 즉, 통증의 효과적인 관리를 위해 행동, 표정, 음성 등의 동작이 복합적으로 수행되는 통증을 인식하고 통증 정보를 수집, 모니터링 할 수 있는 시스템의 개발이 필요하다.

환자 본인이 통증 발생 시 수시로 통증 위치와 통증행동을 기록하거나 전문 의료진의 검진을 통해 통증 위치를 기록해야한다. HS Kim 등¹²⁾의 연구에 따르면 통증은 주관적인 경험이며 암환자의 자발적인 통증보고가 중요하며 통증의 발생부위, 정도, 지속시간에 대한 환자의 보고가 필요하다. 하지만 매 통증 시 환자가 이를 자각하고 기록하는 것은 비현실적인 방법이다. 결국 통증 발생 시 이를 자동으로 인식하고 기록할 수 있는 딥러닝 기반 통증행동 모니터링 시스템의 도입이 필수적이다.

통증행동 모니터링 시스템은 일반적으로 이미지나 모션 센서를 활용하여 구현된다. 이미지 기반 통증행동 모니터링 시스템은 카메라로 환자의 행동과 표정을 인식하여 통증행동의 유무를 판별한다. G. Bargshady 등⁵⁾은 RGB 이미지인 환자의 표정을 입력으로 통증 강도를 인식하는 연구를 수행했다. R. Irani 등⁶⁾은 RGB 이미지와 깊이, 열화상 이미지를 결합해 통증 감지 및 통증 강도를 인식하는 연구를 수행했다. 하지만 카메라의 설치 위치 및 카메라 시야 내 장애물에 민감하고 환자의 프라이버시를 침해할 우려가 있다.

모션 센서를 활용한 통증행동 모니터링 시스템은 환자의 신체에 IMU(inertial measure unit) 센서를 부착하여 통증행동을 비롯한 다양한 움직임을 인식한다. 신체에 부착되는 IMU 센서는 그 수에 따라 인식할 수 있는 행동의 종류와 정확도가 나뉜다. 단일 IMU 기반 통증행동 인식은 주로 척추 자세 및 간단한 척추 움직임 모니터링을 위해 연구되었⁷⁾. JF. Payen 등⁸⁾은 양 손목에 웨어러블 디바이스를 착용한 Dual-IMU 기반의 시스템을 제안했으며, 환자가 습진이나 아토피 등으로 인해 가려움을 느낄 때 수행하는 행동을 모니터링하고 긁는 행동을 인식한다. 하지만 단일 통증행

동만을 인식하기에 실용성을 위해 보다 다양한 통증행동을 인식할 필요가 있다. Multi-IMU 기반의 통증행동 인식 연구는 다수의 IMU가 장착된 모션 수트를 착용한 환경에서 수행된다⁹⁾. R. Qin 등¹⁰⁾은 18개의 IMU 센서가 탑재된 모션 수트를 활용해 통증행동 인식 연구를 수행했다. 통증으로 인해 발생하는 망설임, 갑작스러운 경직, 절뚝거리기, 문지르기 등의 통증행동을 56.50%의 정확도로 인식한다. 하지만 모션 수트의 낮은 착용성과 낮은 정확도를 개선할 추가적인 연구가 필요하다. 즉, 적은 수의 IMU 센서를 활용하면서 다양한 통증행동을 정밀하게 인식할 수 있는 모니터링 시스템의 개발이 필요하다.

본 논문은 손목 밴드 형태의 웨어러블 디바이스를 활용해 환자의 프라이버시와 착용성을 고려한 딥러닝 기반의 통증행동 모니터링 시스템을 제안한다. 제안하는 모델은 손 위치와 손동작을 인식하는 2개의 CNN 모델과 일상행동을 인식하는 HMM(hidden markov model)로 구성된다. 손 위치와 손동작을 인식한 뒤 이를 종합해 통증행동을 추론하는 구조로 기존 방식 대비 정밀한 통증행동 인식이 가능하다. 또한 일상생활에서 수행하는 동작을 통증행동으로 잘못 인식하는 오인식을 줄이고자 HMM을 결합했다.

II. 통증행동 모니터링 시스템 구현

본 장에서는 제안하는 통증행동 모니터링 시스템의 구현에 필요한 항목들을 구체적으로 서술한다. 인식할 통증행동에 대해 정의하고, 개발한 손목 밴드 형태의 웨어러블 디바이스와 딥러닝 기반 통증행동 인식 기법에 대해 설명한다.

2.1 전체 시스템 개요

본 논문에서 제안하는 통증행동 모니터링 시스템은 환자의 양 손목에 착용하는 손목 밴드 형태의 웨어러블 디바이스로 일상생활 중 발생하는 28가지 통증행동과 일상행동을 인식한다. 환자의 착용성을 고려하여

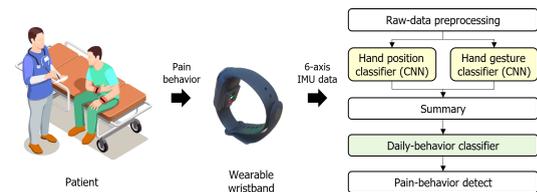


그림 1. 제안하는 통증행동 모니터링 시스템의 개요
Fig. 1. Overview of the proposed pain behavior monitoring system

각 1개의 IMU 센서를 밴드 내 탑재한다. 통증행동 인식을 위한 6축 IMU 데이터는 BLE(blueetooth low energy) 통신을 통해 외부 게이트웨이로 전송된다. 1차원 IMU 데이터를 기반으로 윈도우 크기만큼 2차원 IMU 데이터를 생성하여 딥러닝 모델의 입력으로 사용한다. 디바이스는 저전력 MCU를 탑재하여 긴 착용시간을 보장한다. 제안하는 시스템 개요는 그림 1과 같다.

2.2 통증행동 정의

본 논문에서 정의하는 통증행동은 통증 발생 시 통증에 반응하기 위한 환자의 손 위치와 환자가 취하는 손동작을 종합적으로 고려하여 정의한다. 인식할 통증행동의 종류를 정의하는 것은 본 논문에서 제안하는 통증행동 모니터링 시스템에서 가장 핵심적인 부분으로 전문가의 자문이 필수적이다. 전문가인 의료종사자의 의견을 반영하고자 부산대학교병원과의 회의를 통해 손 위치와 손동작, 통증행동의 종류를 선정하였다.

제안하는 통증행동 모니터링 시스템은 10가지 손 위치와 4가지 손동작을 구분하여 인식한다. 그림 1은 인식하는 10가지 손 위치이다. 손 위치는 머리, 목, 왼쪽 어깨, 오른쪽 어깨, 왼쪽 팔, 오른쪽 팔, 가슴, 배, 다리, 허리가 있다. 손동작의 경우 통증 발생 시 가장 빈번하게 수행하는 동작을 선정하고자 하였다. 4가지 손동작을 인식하며 두드리기, 부축하기, 긁기, 마사지가 있다. 통증행동을 인식하기 위해선 통증 위치와 손동작을 종합적으로 고려해야한다. 예를 들어 환자의 허리에 통증 발생 시 손을 뒤로 돌려 허리에 손이 위치하고 두드리는 손동작을 조합한 행동이 나타난다. 표 1은 손 위치와 손동작을 종합하여 결과적으로 인

표 1. 28가지 통증행동 인식 종류
Table 1. 28가지 통증행동 인식 종류

Position \ Gesture	Gesture			
	Tapping	Guarding	Scratching	Massaging
Head		✓	✓	
Neck	✓		✓	✓
Left-Shoulder	✓			✓
Right-shoulder	✓			✓
Left-arm	✓	✓	✓	✓
Right-arm	✓	✓	✓	✓
Chest	✓	✓	✓	✓
Stomach		✓	✓	✓
Legs	✓			✓
Low-back	✓	✓		

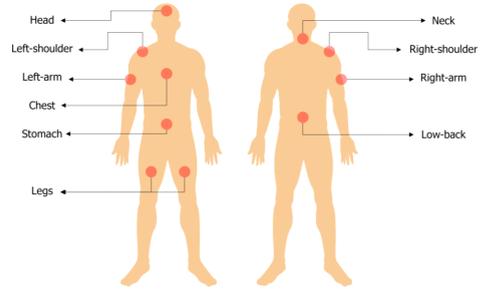


그림 2. 10가지 손 위치 인식 부위
Fig. 2. 10 hand position recognition areas

식하는 통증행동이다. 조합 가능한 40가지의 통증행동 중 일반적으로 수행되지 않는 비정상적인 조합을 제외하여 28가지 통증행동을 인식한다. 비정상적인 조합은 복부를 두드리는 등 일반적이지 않은 통증행동을 예로 들 수 있다.

2.3 손목 밴드 디바이스 설계

통증행동 모니터링 시스템에서 사용하는 손목 밴드 형태의 웨어러블 디바이스는 MCU, 센서부, 전원부로 구성된다. 긴 착용시간을 보장하기 위해 저전력 MCU인 Nordic 사의 nRF52840 SoC를 탑재한 MDBT50Q 모듈을 사용한다. nRF52840 SoC는 64MHz Cortex-M4 CPU를 기반으로 구축되었으며, 1MB의 Flash와 256KB의 RAM을 탑재하고 있다. nRF5240 기반의 MDBT50Q 모듈은 BLE 5.0 통신모듈이 탑재되어 별도의 외부 안테나가 불필요하며 10.5 mm x 15.5 mm x 2.2 mm 크기의 모듈로 손목 밴드 디바이스에 적합한 초소형 모듈이다. MDBT50Q 모듈은 SPI와 I2C 고속통신을 지원하여 높은 수집 주기를 갖는 센서 데이터와 모듈 간 원활한 데이터 전송이 가능하다.

센서부의 IMU 센서는 9축 IMU인 ICM-20948로 가속도 센서, 각속도 센서, 지자기 센서 데이터를 수집한다. 센서의 수집 주기는 약 80Hz에서 100Hz의 주기로 최소 40Hz의 수집 주기를 요구하는 행동인식 분야¹¹⁾의 최소치를 충족한다. 통증행동 모니터링 시스템은 가속도와 각속도 센서 데이터를 사용하여 환자의 행동을 인식하므로 지자기 센서 데이터를 제외한 6축 센서 데이터를 딥러닝 게이트웨이로 전송한다.

병원환경에서 손목 밴드 디바이스의 활용도를 높이기 위해 센서부에 생체센서를 추가할 수 있다. 개발된 손목 밴드 디바이스는 PPG 센서와 IR 센서를 추가해 환자의 심박수, 체온을 인식한다. 추가된 생체센서가 IMU 센서의 데이터 수집 주기에 영향을 끼칠 수 있으므로 약 10초에 한 번씩 생체센서 정보를 전달한다.

기본 데이터 수집 주기와 비교했을 때 3Hz에서 5Hz의 손실이 발생한 것을 확인했다. 하지만 생체정보의 유용성을 고려했을 때 감수할 수 있을 정도의 손실로 보인다.

2.4 딥러닝 기반 통증행동 인식

본 논문에서 제안하는 통증행동 모니터링 시스템의 딥러닝 모델은 환자의 통증행동을 인식하기 위해 손 위치와 손동작을 인식하는 2개의 CNN 모델과 통증행동과 일상행동을 구분하기 위한 HMM 모델로 구성된다.

2.4.1 CNN 기반 통증행동 인식 모델

CNN은 딥러닝 분야에서 가장 일반적으로 사용되는 모델로써 이미지 분석, 센서 데이터 기반 추론 등 다양한 분야에 사용되고 있다. CNN은 구형 편이성이 뛰어나고 하이퍼파라미터를 손쉽게 조절할 수 있어 다양한 모델들을 생성하고 비교할 수 있다는 장점이

있다. 본 논문에서 제안하는 손 위치와 손동작 인식을 위한 딥러닝 모델에 CNN을 사용한다.

통증행동 인식을 위한 최적의 모델을 선정하고자 다양한 모델을 구성하여 성능을 비교한다. 손 위치와 손동작을 인식하는 최적의 CNN 모델의 구조가 서로 다를 수 있으므로 hidden layer의 구조를 바꿔가며 다양한 모델의 정확도를 비교하고자 했다. 5가지 모델을 생성하여 비교했으며 각 모델 구조는 표2와 같다. CNN 모델의 입력 데이터는 윈도우 사이즈 150으로 2개의 손목 밴드 디바이스로부터 수집한 센서 데이터를 분할하여 사용한다. 입력 데이터는 전처리 과정을 거쳐 (150, 12, 1) 형태를 갖는다. 3개의 pooling layer, convolution layer, 1개의 global average pooling layer, dense layer로 구성된 기본 CNN 모델에서 k개의 pooling layer와 convolution layer를 추가한 서로 다른 CNN 모델을 생성한다. 학습된 모델의 과적합을 방지하고자 dropout은 0.5로 설정하며, 학습의 최적화 알고리즘으로 Adam optimizer를 사용했다. Convolution layer의 활성화 함수는 ReLU이며 dense layer의 활성화 함수는 ReLU와 softmax이다.

손 위치 인식 모델과 손동작 인식 모델, 제안하는 통증행동 인식 모델과 비교를 위한 단일 CNN 모델 총 3가지 추론 모델을 선정한다. 각 모델들은 통증행동과 일상행동을 구분하여 인식한다. 때문에 10가지 손 위치와 4가지 손동작, 28가지 통증행동에 일상행동을 추가해 모델의 출력은 11, 5, 29가지 행동이다.

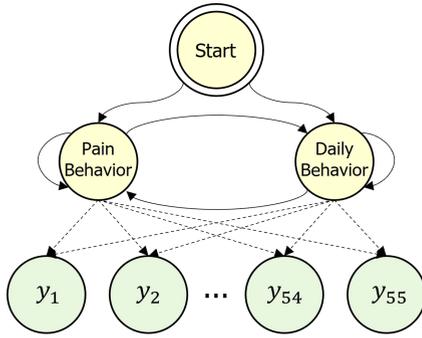
2.4.2 HMM 기반 일상행동 인식 모델

본 논문에서 제안하는 통증행동 모니터링 시스템은 일상행동과 통증행동을 구분하여 인식한다. 두 행동을 구분하는 것으로 실사용 중 발생할 수 있는 오인식을 줄일 수 있다. 일상행동과 통증행동을 구분하기 위해선 손 위치와 손동작의 패턴을 분석해야한다. 이를 위한 딥러닝 모델로 손 위치와 손동작의 변화에 따라 생성되는 시계열 데이터를 입력으로 하는 HMM 모델을 제안한다.

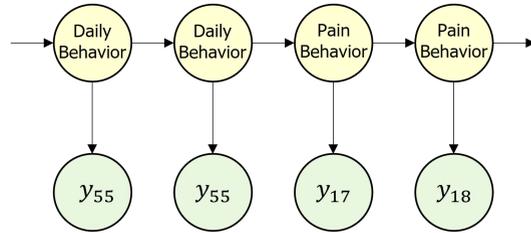
HMM 모델은 시계열 분석에서 널리 사용되는 모델이다. HMM은 관측값 이후의 상태를 추론하기 위한 모델로 기본적으로 markov chain을 기반으로 변형된 모델이다. 본 논문에서 제안하는 HMM 모델은 손 위치와 손동작을 관측값으로, 일상행동과 통증행동을 상태로 설정하여 행동을 구분한다. HMM 모델은 $\langle Q, Y, \pi, T, E \rangle$ 집합으로 구성되며, 학습 데이터를 기반으로 π, T, E 를 학습한다. 집합에서 표기된 Q 는 상태를 의미하며, 일상행동과 통증행동 2개의 조합으

표 2. 성능 비교를 위한 모델들의 구조
Table 2. Structure of models to compare

Model	#1	#2	#3	#4	#5	
Input	Input (150, 12, 1)					
Hidden layer	Conv					
	Max-Pooling	Max-Pooling	Max-Pooling	Max-Pooling	Max-Pooling	
	Conv	Conv	Conv	Conv	Conv	
	Max-Pooling	Max-Pooling	Max-Pooling	Max-Pooling	Max-Pooling	
	Conv	Conv	Conv	Conv	Conv	
		Max-Pooling	Max-Pooling	Max-Pooling	Max-Pooling	Max-Pooling
		Conv	Conv	Conv	Conv	Conv
			Max-Pooling	Max-Pooling	Max-Pooling	Max-Pooling
			Conv	Conv	Conv	Conv
			Max-Pooling	Max-Pooling	Max-Pooling	Max-Pooling
			Conv	Conv	Conv	Conv
	GAP (global average pooling)					
	Dense					
	Output	11 (10 Hand position + daily-behavior) or 5 (4 Hand gesture + daily-behavior) or 29 (28 pain behavior + daily-behavior)				



상태 전이에 따른 HMM 구조



시계열 관측치에 따른 HMM 구조

그림 3. 제안하는 HMM 모델 구조
Fig. 3. Proposed HMM model structure

로 구성된다. Y 는 관측값을 의미하며 5가지 손동작과 11가지 손위치를 고려한 55개의 조합으로 구성된다. π 는 초기 상태의 확률 집합을, T 는 상태가 전이할 확률 집합을 의미하며 E 는 각 상태에서 특정 관측치가 발생할 확률 집합이다.

제안하는 HMM 모델은 통증행동의 유무를 출력한다. 이 때 관측값과 상태 간의 조합으로 네 가지 상황이 발생할 수 있다. 첫 번째로 관측값이 일상행동이면서 상태가 통증행동으로 인식될 경우, 두 번째로 관측값이 통증행동이면서 상태가 일상행동으로 인식될 경우, 세 번째와 네 번째로 관측값과 상태의 추론 결과가 동일한 경우이다. 발생할 수 있는 4가지 상황에서

일상행동인지 통증행동인지 최종적으로 인식하는 후 처리를 통해 통증행동과 일상행동 인식 간 발생할 수 있는 오인식을 개선한다. 상태 전이에 따른 HMM 구조와 시계열 관측치에 따른 HMM 구조의 예시는 그림 3과 같다.

III. 실험

3.1 통증행동 데이터셋 수집

본 논문에서 제안하는 통증행동 모니터링 시스템의 학습 및 평가를 위해 통증행동 데이터셋을 수집했다. 앞서 부산대학교병원의 자문을 통해 선정한 28가지 통증행동과 일상행동을 포함해 총 29가지 동작을 각각 30초씩 수집했다. 양 손목에 손목 밴드 디바이스를 착용한 실험자가 30초 간 통증행동이나 일상행동을 수행한 후, 각 행동 사이에 10초의 휴식시간을 가지도록 데이터를 수집했다. 데이터는 3축 가속도와 3축 각속도 데이터로 80Hz에서 100Hz의 주기로 수집한다. 수집 대상은 만 23세에서 29세 사이의 성인 남성 5명으로, 병원 환경을 고려해 연구실 내 빈 공간에 침대를 설치한 환경에서 데이터를 수집했다.

데이터 수집 시 환자가 침대에 완전히 누워있는 상태에서 통증행동을 수행하는 것이 아닌, 침대에 앉아 있거나 서있는 상황에서 통증행동을 수행한다고 가정하고 데이터를 수집했다. 제안하는 통증행동 모니터링 시스템은 통증행동과 일상행동을 구분해서 인식하므로 일상행동을 추론하기 위해 걷기, 일어서기, 눕기 3개의 행동을 추가로 수집했다. 수집된 데이터셋은 28가지 통증행동과 3가지 일상행동을 포함한 약 405분 가량 분량이다. RGB 카메라를 통해 이미지 데이터를

표 3. 수집된 데이터셋의 분포
Table 3. Distribution of collected data sets

Position \ Gesture	Gesture			
	Tapping	Guarding	Scratching	Massaging
Head		2.70%	2.73%	
Neck	3.00%		2.92%	2.79%
Left-shoulder	1.43%			1.53%
Right-shoulder	1.39%			1.31%
Left-arm	1.50%	1.43%	1.46%	1.35%
Right-arm	1.36%	1.45%	1.36%	1.47%
Chest	2.73%	3.02%	2.97%	2.96%
Stomach		2.97%	2.82%	2.93%
Legs	2.93%			2.89%
Low-back	2.72%	2.70%		
Daily-behavior	37.19%			

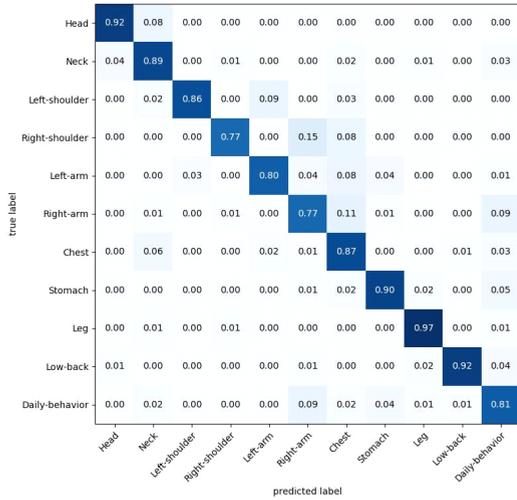


그림 4. 손 위치 인식 모델의 confusion matrix
Fig. 4. Confusion matrix of hand position recognition model

함께 수집하여 ground truth를 위한 labeling을 수행했다. 수집된 데이터의 비율은 표 3과 같다.

3.2 통증행동 인식 모델 실험

본 논문에서 제안하는 통증행동 모니터링 시스템은 딥러닝을 통해 인식한 손 위치와 손동작을 종합하여 통증행동을 인식한다. 손 위치와 손동작을 인식하는 모델은 LOOCV(leave one out cross validation)을 통해 가장 높은 정확도를 보이는 모델을 선택하여 통증행동 인식에 사용한다. 실험에 사용된 데이터셋은 7:2:1 비율로 학습과 검증, 평가에 사용한다. 딥러닝 모델은 고성능의 GPU가 장착된 외부 서버에서 학습하였으며, 제안하는 통증행동 모니터링 시스템의 평가는 NVIDIA Jetson TX2 상에서 구동되는 Linux 환경에서 진행했다.

3.2.1 손 위치 인식 모델 실험결과

손 위치 인식 모델은 5개의 CNN 모델 중 2개의 pooling layer와 convolution layer를 추가한 모델이 가장 높은 정확도인 85.59%의 정확도를 보였다. 수집한 동작 간 데이터 불균형 문제를 고려하여 F1-score를 측정하였으나 F1-score도 정확도와 유사한 결과를 보였다.

손 위치 인식 모델의 confusion matrix는 그림4와 같다. Confusion matrix를 통해 부위별 인식 정확도를 비교했을 때 팔에서 수행한 통증행동을 가슴으로 오인식하는 경우가 많았다. 이는 팔과 가슴으로 손이 갈 때 손이 움직이는 거리에 작은 차이가 있다는 점을 제

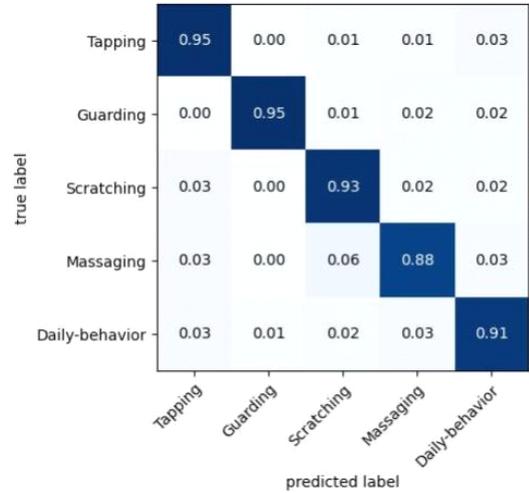


그림 5. 손동작 인식 모델의 confusion matrix
Fig. 5. Confusion matrix of hand gesture recognition model

외하고 상당히 유사한 동작을 보이기 때문이다.

3.2.2 손동작 인식 모델 실험결과

손동작 인식 모델도 손 위치 인식 모델과 동일하게 2개의 pooling layer와 convolution layer가 추가한 모델이 89.22%로 가장 높은 정확도를 보였다.

손동작 인식 모델의 confusion matrix는 그림 5와 같다. 손동작 인식 모델의 경우 tapping, guarding, scratching, massaging, daily behavior 5가지 손동작

표 4. 28가지 통증행동의 약어
Table 4. Abbreviations of pain behavior

Gesture Position	Tapping	Guarding	Scratching	Massaging
Head		HG	HS	
Neck	NT		NS	NM
Left-shoulder	LsT			LsM
Right-shoulder	RsT			RsM
Left-arm	LT	LG	LS	LM
Right-arm	RT	RG	RS	RM
Chest	CT	CG	CS	CM
Stomach		SG	SS	SM
Legs	LegT			LegM
Low-back	LowT	LowG		
Daily-behavior	Daily			

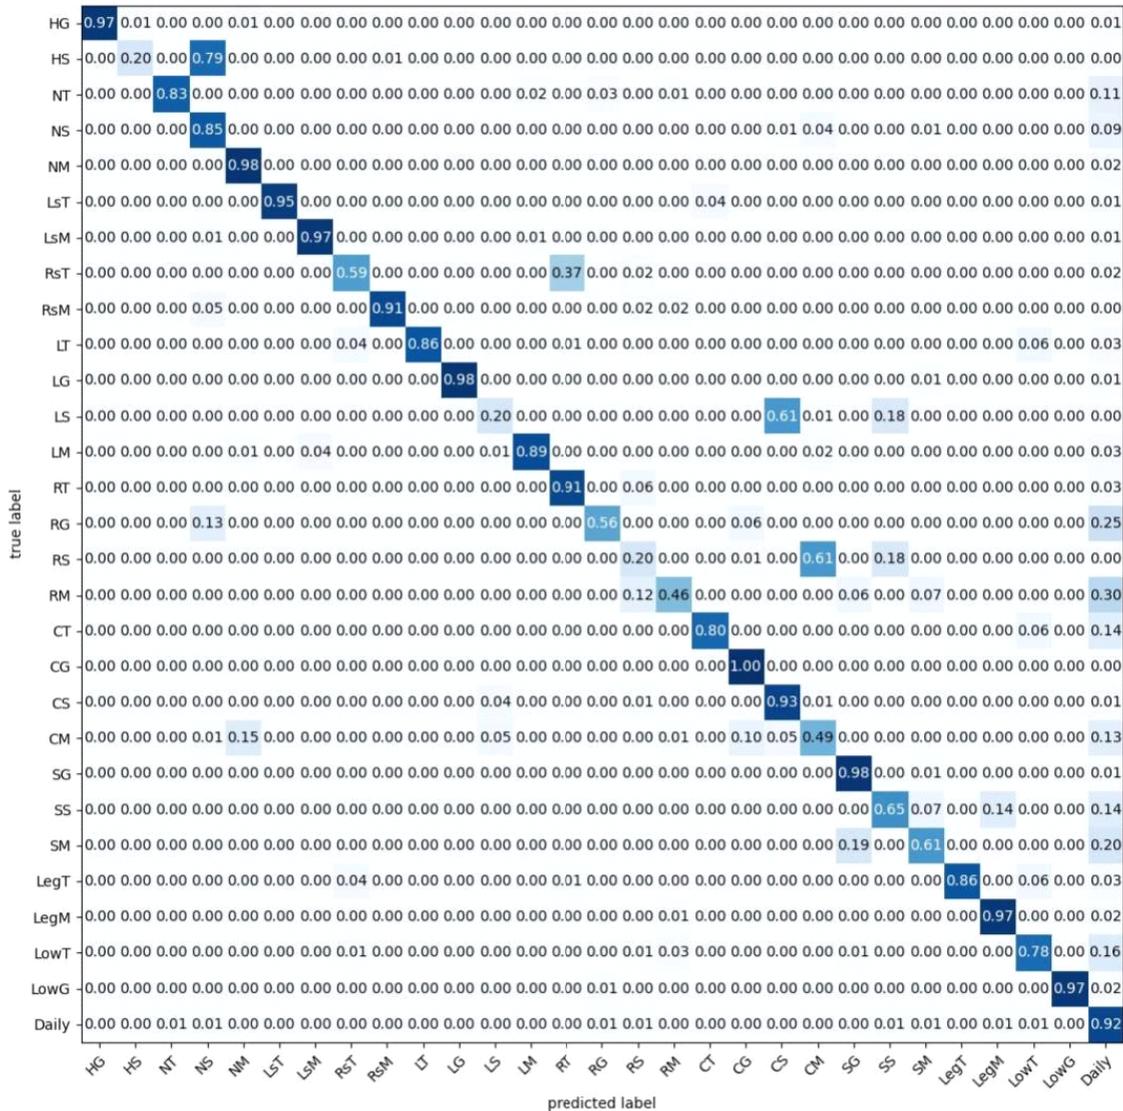


그림 6. 단일 CNN 모델에서 29가지 통증행동 및 일상행동 인식 정확도 confusion matrix
 Fig. 6. Confusion matrix of recognition of 29 pain behaviors and daily behaviors in a single CNN model

에 대해 전반적으로 높은 정확도를 보였으나 scratching을 massaging으로 오인식하는 경우가 발생했다. 이는 tapping, guarding에 비해 scratching과 massaging 동작이 유사하기 때문이다.

3.2.3 통증행동 인식 모델 실험결과

CNN 기반 손 위치 인식 모델과 손동작 인식 모델을 선정한 후 HMM을 결합하여 본 논문에서 제안하는 통증행동 인식 모델을 구성하고 평가했다. 손 위치와 손동작을 구분하는 방식을 평가하고자 단순히 28가지 통증행동을 인식하는 단일 CNN 모델을 추가로

생성하고 정확도를 비교했다. 이 때 생성한 단일 CNN 모델은 손 위치 인식 모델과 손동작 인식 모델과 동일한 2개의 pooling layer와 convolution layer가 추가된 모델이다.

본 논문에서 제안하는 CNN과 HMM을 결합해 생성한 통증행동 인식 모델의 정확도는 87.06%로 비교를 위해 생성한 단일 CNN 모델의 정확도인 82.68% 대비 4.38% 높은 정확도를 보였다. 그림 6은 단일 CNN 모델의 confusion matrix이며 그림 7은 제안하는 CNN과 HMM을 결합해 생성한 통증행동 인식 모

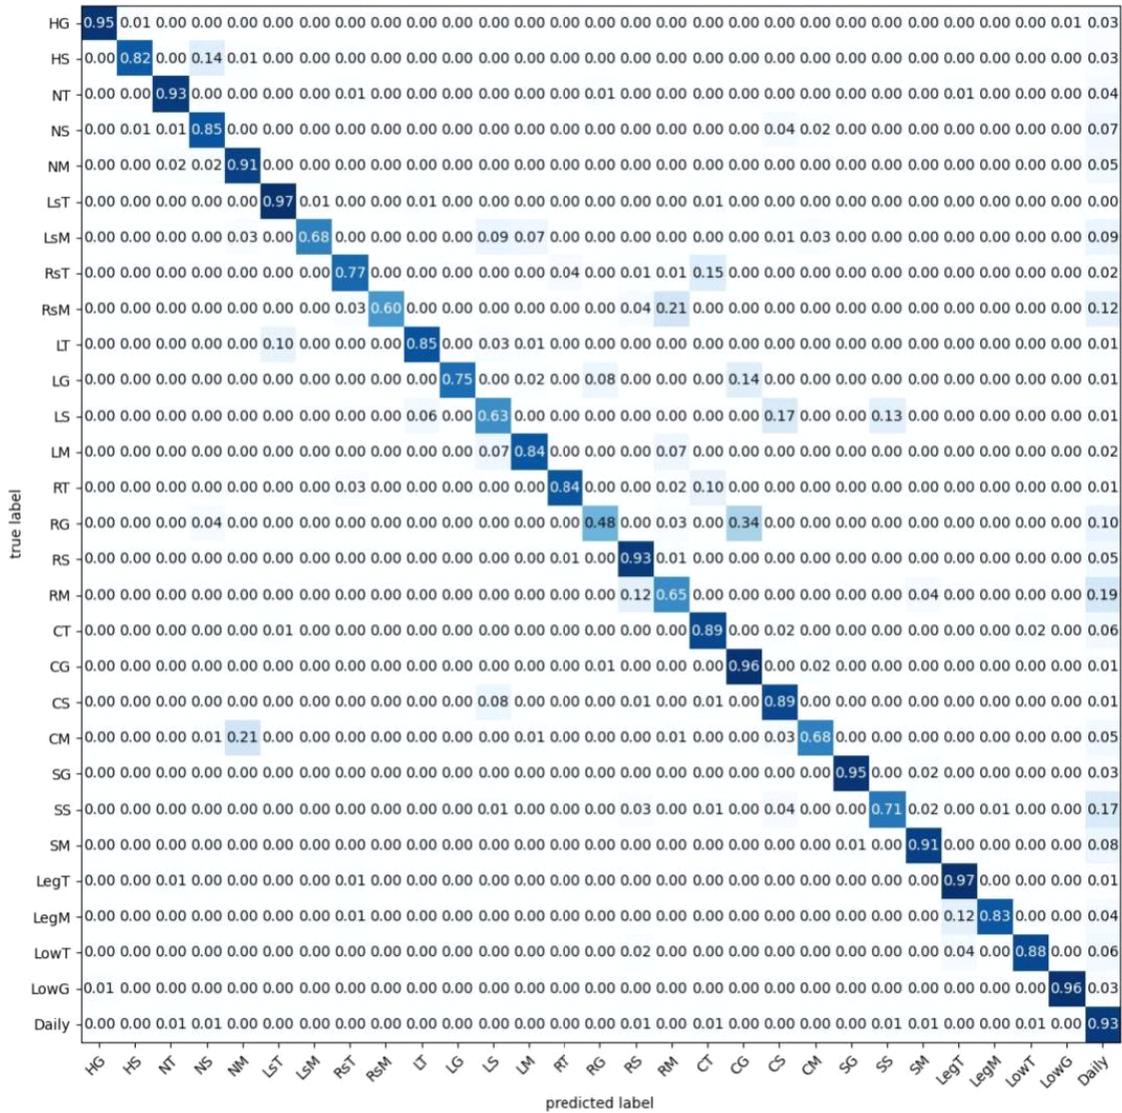


그림 7. 제안하는 모델에서 29가지 통증행동 및 일상행동 인식 정확도 confusion matrix
 Fig. 7. Confusion matrix of recognition of 29 pain behaviors and daily behaviors in a proposed model

델의 confusion matrix다. 각 모델의 confusion matrix를 분석했을 때, head guarding이나 leg guarding 등 단순한 동작이나 다른 동작과 구분되는 명확한 패턴이 있는 통증행동은 두 모델 간 정확도의 차이가 크지 않았다. 그에 비해 단일 CNN 모델로 구성된 통증행동 인식 모델의 경우 head scratching 등 손 위치가 혼동될 가능성이 있거나 손동작이 복잡한 통증행동의 오인식률이 제안하는 통증행동 인식 모델에 비해 큰 폭으로 차이는 것을 확인할 수 있다.

IV. 결론

본 논문은 일상생활 중 비주기적으로 발생하는 환자의 통증행동을 인식하기 위한 통증행동 모니터링 시스템을 제안한다. 제안하는 시스템은 손목 밴드 디바이스를 통해 부산대학교병원과의 회의로 선정된 28가지 통증행동과 일상행동을 인식한다.

정밀한 통증행동 인식을 위해 손 위치와 손동작을 구분하여 인식하는 CNN 모델 구조를 제안했다. 통증행동과 일상행동을 구분하기 위해 HMM 모델을 추가

하여 일상생활 중 발생할 수 있는 오인식을 줄였다. 제안하는 모델 구조는 단일 CNN 모델 대비 4.38% 높은 정확도로 통증행동과 일상행동을 인식할 수 있다. 또한, 손 위치가 유사하거나 손동작이 복잡한 통증행동을 인식하는데 효과적임을 확인할 수 있다.

향후 계획으로 손 위치와 손동작을 인식하는 CNN 모델을 고도화해서 정확도를 향상시키고 부산대학교 병원과의 협업을 통해 실제 환자를 대상으로 통증행동 데이터를 수집하여 병원 환경에 최적화하는 연구를 수행할 예정이다.

References

[1] P. Rajan Jeyaraj, "Smart-monitor: Patient monitoring system for IoT-based healthcare system using deep learning," *IETE J. Res.*, vol. 68, no. 2, pp. 1435-1442, 2022. (<https://doi.org/10.1080/03772063.2019.1649215>)

[2] I. Ahmed, et al., "A deep learning-based smart healthcare system for patient's discomfort detection at the edge of internet of things," *IEEE Internet of Things J.*, vol. 8, no. 13, pp. 10318-10326, Jul. 2021. (<https://doi.org/10.1109/JIOT.2021.3052067>)

[3] E. K. Naeini, et al., "An edge-assisted and smart system for real-time pain monitoring," *IEEE/ACM Int. Conf. Connected Health: Appl., Syst. and Eng. Technol. (CHASE)*, pp. 47-52, Sep. 2019. (<https://doi.org/10.1109/CHASE48038.2019.00023>)

[4] D. Glowacki. "Effective pain management and improvements in patients' outcomes and satisfaction," *Critical care nurse*, vol. 35, no. 3, pp. 33-41, 2015. (<https://doi.org/10.4037/ccn2015440>)

[5] G. Bargshady, et al., "Enhanced deep learning algorithm development to detect pain intensity from facial expression images," *Expert Syst. with Appl.*, vol. 149, 2020. (<https://doi.org/10.1016/j.eswa.2020.113305>)

[6] R. Irani, et al., "Spatiotemporal analysis of RGB-DT facial images for multimodal pain level recognition," *IEEE Conf. CVPR*, pp. 88-95, 2015.

(<https://doi.org/10.1109/CVPRW.2015.7301341>)

[7] Y. Zhang, et al., "On-device lumbar-pelvic movement detection using Dual-IMU: A DNN-Based approach," *IEEE Access*, vol. 9, pp. 62241-62254, 2019. (<https://doi.org/10.1109/ACCESS.2021.3074755>)

[8] J. Lee, et al., "Itchector: A wearable-based mobile system for managing itching conditions," *CHI Conf. Human Factors in Comput. Syst.*, pp. 893-905, 2017. (<https://doi.org/10.1145/3025453.3025569>)

[9] D. Roetenberg, et al., "Xsens MVN: Full 6DOF human motion tracking using miniature inertial sensors," *Xsens Motion Technol. BV, Tech.*, Rep. 1, pp. 1-7, 2009.

[10] R. Qin, et al., "Continuous pain related behavior recognition from muscle activity and body movements," *12th ICNC-FSKD IEEE*, pp. 1710-1715, 2016. (<https://doi.org/10.1109/FSKD.2016.7603435>)

[11] C. V. C. Bouten, et al., "A triaxial accelerometer and portable data processing unit for the assessment of daily physical activity," *IEEE Trans. Biomed. Eng.*, vol. 44, no. 3, pp. 136-147, 1997. (<https://doi.org/10.1109/10.554760>)

[12] H. S. Kim and M. J. Suh, "A study on patients' concerns about management of cancer pain and related factors," *The Korean J. Rehabilitation Nursing.*, vol. 3, no. 1, pp. 43-58, 2000.

조 용 훈 (Yonghun Cho)



2020년 2월 : 동의대학교 컴퓨터 공학과 공학학사

2020년 9월~현재 : 부산대학교 정보융합공학과 석박사통합 과정

<관심분야> 임베디드 시스템, 임베디드 AI

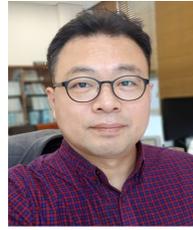
[ORCID:0000-0002-5838-2959]

이 현 옥 (Hyunwook Lee)



2019년 2월 : 창원대학교 컴퓨터
공학과 공학학사
2021년 2월 : 부산대학교 컴퓨터
공학과 공학석사
<관심분야> 임베디드 시스템, 웨
어러블 디바이스
[ORCID:0000-0002-1556-8219]

백 윤 주 (Yunju Baek)



1990년 2월 : 한국과학기술원 전
산학과 공학학사
1992년 2월 : 한국과학기술원 전
산학과 공학석사
1997년 2월 : 한국과학기술원 전
산학과 공학박사
1999년~2002년 : 네이버 CTO
2003년~현재 : 부산대학교 정보컴퓨터공학과 교수
<관심분야> 임베디드 시스템, 임베디드 AI
[ORCID:0000-0002-3873-2624]