

논문 2021-16-09

산업용 로봇 원격제어를 위한 CNN기반 손 제스처 인식 방법 (CNN-based Hand Gesture Recognition Method for Teleoperation Control of Industrial Robot)

전 세 윤, 김 은 수, 박 범 용*

(Se-Yun Jeon, Eun-Su Kim, Bum Yong Park)

Abstract : This paper introduces a teleoperation control system of an industrial robot based on hand gestures using the convolutional neural network (CNN). The proposed system employs the gesture data obtained from an EMG sensor and considers a CNN-based deep learning method. Using the proposed CNN model, we develop a real-time teleoperation control system for the industrial robot. Finally, it is confirmed that the proposed system is reliable in real system since it can be applied to the teleoperation control of a real industrial robot.

Keywords : Industrial robot, ROS, EMG, Teleoperation, CNN

I. 서 론

최근 다양한 공학 기술이 발전하면서 로봇 공학 분야의 기술이 폭넓게 발전되고 있으며 여러 분야에서 로봇이 활용되고 있다. 특히 제조업 분야는 공장 자동화와 무인화 등이 진행되면서 산업용 로봇의 수요가 증가하는 추세이고 관련 기술 또한 많은 연구가 진행되고 있다 [1]. 제조 현장에서 자동화와 무인화 등이 이루어지기 위해 산업용 로봇을 활용하면서 인간-로봇 상호작용 (Human-Robot Interaction, HRI) 기술에 대한 필요성이 증가하고 있다 [2]. 현재 인공지능 기술이 점점 발전하고 있지만, 아직 로봇이 특정 조건이나 환경에서 인간의 지각 능력을 대체할 수는 없는 상황이다. 따라서 현재 활발하게 연구되고 있는 기술은 인간이 다양한 환경에서 실시간으로 판단하고 로봇을 원격으로 제어할 수 있는 원격조작 (teleoperation) 기술이다.

인간이 하기에 위험하거나 어려운 작업 환경의 경우 원격조작 기술을 이용하면 직접 수행할 필요 없이 원격지에서 로봇을 조작하여 안전하고 효과적으로 작업할 수 있다. 이러한 기술을 활용하여 의사가 원격으로 로봇을 조작하여 수술을 진행하는 수술 로봇 [3], 재난 현장에서 활용되는 재난 구조 로봇 [4], 광산 내부를 탐사하는 탐사로봇 [5] 등 다양한 산업 분야에서 원격조작 기술을 사용하는 로봇들이 많이 개발되고 있다. 키보드, 마우스, 조이스틱 등 여러 가지 조

작 도구가 로봇을 원격조작하기 위해 개발되었지만, 인간이 이러한 도구들을 조작하기 위해서는 높은 숙련도가 필요하고 많은 시간과 비용이 든다. 따라서 최근 인간의 움직임을 직접 전달하는 방법이 다양하게 연구되고 있다. HMD를 활용하여 휴머노이드 로봇 원격조작 연구 [6], 외골격 로봇을 이용해 인간의 행동을 파악하여 로봇을 제어하는 연구 [7, 8], 영상과 깊이를 인식하는 센서를 이용하는 로봇 원격조작 연구 [9], Leap motion을 이용하여 제어하는 연구 [10] 등이 있다.

최근에는 이러한 조작 방법 중 인간의 생체 신호를 이용하여 원격조작에 사용하는 연구가 수행되고 있다. 근전도 센서와 햅틱 센서를 이용하는 로봇 조작 연구 [11], 근전도 센서와 키넥트 (kinect) 기기를 통해 영상 데이터를 결합하여 로봇을 원격제어하는 연구 [12] 등이 있다. 이와 같이 사람의 팔 동작을 인식하여 로봇을 원격조작하는 다양한 연구가 있으나 대부분의 연구에 사용되는 로봇은 연구용 다관절 로봇이며, 실제 산업현장에서 사용하고 있는 산업용 다관절 로봇에게 적용한 연구는 많지 않다. 연구용 로봇은 산업용 로봇과 비교하면 연구 환경 구축이나 통신의 호환성은 좋지만, 연구결과를 실제환경에 적용하기 어려울 수 있다. 그에 비해 산업용 로봇 기반의 연구는 다양한 산업환경에서 사용되고 있는 로봇을 대상으로 시스템을 개발하기 때문에 연구 결과의 활용가능성이 높다. 따라서 본 논문에서 제안하는 시스템에서는 산업용 로봇을 활용한다. 또한, 제안 시스템에서는 근전도 신호를 다루는 CNN (Convolutional Neural Network) 구조를 적용하여 인간의 손 제스처를 추정하고

*Corresponding Author (bumyong.park@kumoh.ac.kr)

Received: Jan. 27, 2021, Revised: Mar. 8, 2021, Accepted: Apr. 13, 2021.
S.Y. Jeon: Kumoh National Institute of Technology (M.S.)

E.S. Kim: Kumoh National Institute of Technology (M.S.)

B.Y. Park: Kumoh National Institute of Technology (Assist. Prof.)

※ 이 연구는 금오공과대학교 학술연구비로 지원되었음 (202001710001).

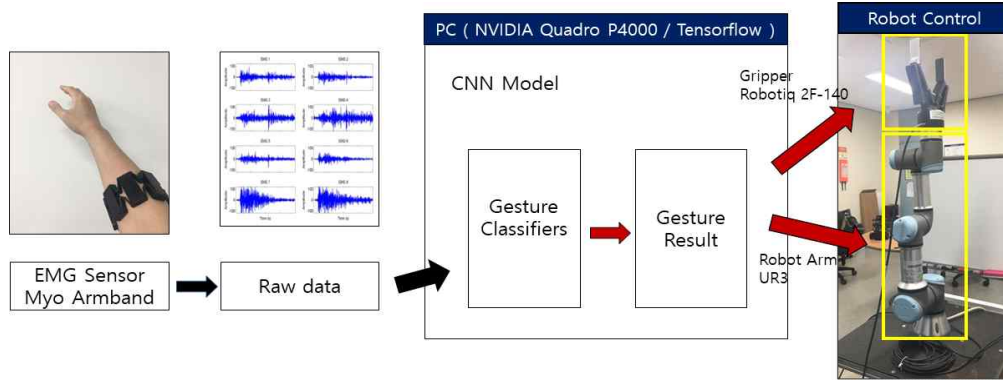


그림 1. EMG기반 산업용 로봇 원격제어 시스템 구성도

Fig 1. EMG-based industrial robot remote control system configuration diagram

이를 원격제어에 사용한다. 이러한 CNN 기반의 로봇 제어 연구는 다양하게 진행되고 있으며 로봇 제어 목적에 따라서 일상 생활에서 주로 쓰는 손 제스처를 선정하고 학습하여 능동요소를 제어하는 연구 [13], 손 제스처를 영상처리하여 학습하고 로봇의 방향 지시를 제어하는 연구 [14] 등이 있다.

본 논문에서는 다양한 환경에서 활용할 수 있고 조작 장치에 대한 비숙련자도 로봇을 원격제어할 수 있는 근전도 기반의 원격제어 시스템을 제안한다. 제안 시스템은 근전도 센서를 활용하여 인간의 손 동작을 인식하여 다관절 로봇을 원격으로 제어하는 시스템이다. 근전도 신호를 측정하기 위해 IMU (Inertial Measurement Unit) 센서, EMG (Electromyogram, EMG) 센서, 블루투스 (Bluetooth) 기능을 내장하고 있는 Thalmic Labs의 Myo armband를 사용하였으며 원격조작의 대상이 되는 로봇은 현재 산업현장에서 활발하게 활용되고 있는 산업용 로봇인 Universal Robots사의 UR3와 Robotiq사의 그리퍼를 이용하였다. Myo armband에서 근전도 신호를 전달받아 로봇을 제어하기 위해 UR3 로봇 자체 제어 소프트웨어를 사용하지 않고 ROS (Robot Operating System)를 이용하였다. ROS는 로봇 시스템의 제어, 감지, 판단 등 다양한 기능별 모듈화를 가능하게 하는 미들웨어로, 세계적으로 많은 로봇 연구자들이 사용하는 로봇 플랫폼이다 [15]. 이러한 ROS를 기반으로 근전도 센서 모듈, 센서 신호처리 모듈, 로봇 제어 모듈 등 기능별로 모듈을 개발하여 시스템을 구성하였다. 모든 모듈은 Ubuntu 18.04 버전 운영체제 상에 ROS Melodic 버전을 설치한 Intel i7 Xeon 기반의 컴퓨터에서 구현하였다. 제안 시스템은 Myo armband에서 수집한 근전도 신호를 이용해 CNN 모델을 학습하고 이 모델을 이용하여 UR3 로봇과 그리퍼를 제어하는 시스템이다. UR3 로봇과 그리퍼를 제어하

기 위한 손 제스처를 선정하고 해당 데이터를 수집하여 학습한다. 근전도 신호는 2차원 데이터이므로 이미지 데이터를 학습할 때 주로 사용하는 CNN 모델을 이용하여 학습하였다.

본 논문은 CNN을 이용한 EMG 기반의 산업용 로봇 원격제어 시스템을 제안한다. 내용은 다음과 같이 구성되어 있다. 2장에는 제안 시스템의 전체 구성을 설명한다. 3장에는 제안 시스템 구현에 적용한 CNN 구조 및 자료수집과 학습에 관한내용을 설명한다. 4장은 제안 시스템의 성능을 보여주는 실험에 대해 논한다. 마지막 장에는 전체 내용에 대한 결론과 향후 연구 방향에 관한 내용을 담고 있다.

II. 제안 시스템의 구성

1. 제안하는 시스템의 구현

본 논문에서 제안하는 시스템은 근전도 센서를 이용하여 손 제스처 데이터를 얻고, 이 데이터로 학습시킨 분류기의 손 제스처 분류에 따라 로봇 팔과 그리퍼를 제어하는 시스템이다. 우선, 로봇 제어를 위한 5가지의 손 제스처를 정하고, 근전도 센서를 이용해 각 제스처에 대해 데이터를 수집한 후 정규화하여 CNN 구조를 적용한다. 5가지의 손 제스처로 학습된 분류기를 생성하고 근전도 센서로부터 실시간으로 얻는 데이터를 분류기에 적용하여 결과를 얻는다. 결과값에 따라서 로봇 팔과 그리퍼를 제어한다. 그림 1은 제안하는 시스템 구성도이다. 제안 시스템은 PC의 Linux Ubuntu 18.04 환경에서 ROS (melodic 버전)를 활용하여 구현되었으며, 제스처 분류기는 별도로 구현한 가상환경 (Python 버전-3.6)의 Tensorflow-GPU-2.3.0을 기반으로 하여 생성하였다. 시스템에서 사용한 산업용 로봇은 그림 1의 오른쪽 사진과 같이 로봇 팔과 그리퍼를 결합한 형태이다.

산업용 로봇 중 로봇 팔은 Universal Robots사에서 개발한 산업용 로봇인 UR3 로봇이다. UR3를 PC와 연동하기 위해 랜 케이블을 연결하고, DHCP (Dynamic Host




그림 2. 각 제스처에 해당하는 산업용 로봇 제어
Fig 2. Industrial robot control corresponding to each gesture

Configuration Protocol)방식을 통해서 할당된 UR3의 IP주소에 접속하여 신호를 수신할 수 있는 상태로 설정한다. 그리퍼는 Robotiq 사의 그리퍼 (2F-140 버전)를 사용하였다. 이 그리퍼는 2개의 finger가 있고, finger 사이의 폭은 최대 140mm이다.

2. 시스템 개발 환경

Ubuntu18.04 환경의 ROS를 기반으로 제안 시스템을 그림 1과 같이 구현하여 실험한다. CNN 모델을 이용해 만든 제스처 분류기를 통해 사용자의 손 제스처에 대한 데이터를 실시간으로 판별하여 추정하고 그 결과로 UR3와 그리퍼를 제어한다. 실험에서는 관절 'base'의 각만 조절하여 제어하고 그 이외의 관절들은 고정된 상태로 설정하였다. 실시간으로 전송되는 EMG 데이터를 통해 50샘플 간격으로 제스처를 추정한다. 'Rest'는 어떤 제스처도 취하지 않은 상태를 유지한다. 'Rest'를 제외한 제스처 중 'Close'와 'Open'은 그리퍼를 제어하고 'Right'와 'Left'는 UR3를 제어한다. 그림 2는 각 제스처의 로봇 제어이다. 'Close'에는 그림 2와 같이 그리퍼가 닫힌 상태가 되고, 'Open'에는 그리퍼가 열린 상태가 된다. 또한, 'Right'에서는 그림 2의 반시계방향으로 UR3의 관절 'base'가 90°의 위치로 이동하고 'Left'에서는 시계방향으로 UR3의 관절 'base'가 0°의 위치로 이동한다.

3. ROS 기반 시스템 구현

제안하는 시스템의 전반적인 구성은 ROS를 이용하여 개발하였다. ROS는 다양한 운영체제에서 설치되어 사용될 수

있으며, 인터넷 연결이 된 이기종 컴퓨터의 프로세스들 사이에서 TCP/IP 메시지 통신을 통하여 다양한 로봇개발을 쉽고 빠르게 할 수 있다. 또한, 로봇 구성에 필요한 다양한 패키지를 사용자가 직접 개발하고 공유할 수 있고, 반대로 하드웨어 모듈들의 작동 제어에 필요한 응용프로그램 패키지들을 받을 수도 있다. 제안하는 시스템에서 근전도 센서와 산업용 로봇을 제어하기 위해서 해당 로봇의 기능을 제어할 수 있는 패키지를 사용하였다.

ROS에서 활용하는 패키지는 최소 단위의 실행 프로그램인 노드 형태로 개발된다. 노드는 또 다른 노드와 메시지를 통해 데이터를 주고받으며 하나의 커다란 프로그램이 되고, 노드 간의 통신이 가능하다. 제안 시스템에서 또한 ROS의 큰 장점인 통신을 활용하여 전반적인 구성을 구축한다. Myo Armband 센서와 로봇과의 통신을 위한 패키지 'ros_myo', 그리퍼를 구동하기 위한 패키지 'robotiq_2f_gripper_control', UR3를 구동하기 위한 패키지 'ur_robot_driver'를 이용한다 [16-18].

그림 3은 ROS의 시각화 도구인 rqt graph를 이용하여 요약한 것이다. 'Data_listener' 노드는 'Myo_armband' 노드로부터 손 제스처에 대한 데이터인 토픽 'Myo_emg'를 실시간으로 받아 제스처 분류기에 전달하여 손 제스처를 구분하고, 동작제어를 위해 결괏값을 'Gripper' 노드와 'UR3' 노드에 각각 전달한다. 단, 제스처 분류기는 ROS환경이 아닌 별도의 가상환경에서 실행하고, TCP/IP 통신을 이용하여 Myo Armband로 부터 데이터를 받고, 제스처 분류 결과를 그리퍼와 UR3에 전송한다.

4. 근전도 센서 (Myo armband)

Myo armband (그림 4)는 Thalmic Labs에서 개발한 착용 장치이다. 작업자가 팔에 Myo armband를 착용하면 블루투스 어댑터를 이용한 블루투스 기능을 통해 시스템과 통신할 수 있다. 또한, 8개의 EMG 센서와 9개의 축이 있는 1개의 IMU 센서가 내장되어 있다. 근육은 신경의 지배를 받고, 근육 자체에도 미세한 전류가 항상 흐른다. 신경 자극에 따라 근육이 반응하고 근육의 반응은 근육 내 전류




그림 3. 제안 시스템 구성의 노드 연결 구조
Fig 3. Node connection structure of proposed system




그림 4. Myo armband의 채널 위치와 사용 모습
Fig 4. Channel location and usage of Myo armband




그림 5. UR3의 각 관절 명칭
Fig 5. Name of each joint of UR3

의 변화를 가져오게 된다. 제안한 시스템에서는 손 제스처를 추정하기 위해 근전도 변화를 얻을 수 있는 근전도 센서를 사용하였다. Myo armband는 두 가지 종류의 데이터 값에 의해서 작동한다. 첫 번째는 방향 데이터 값이다. 3차원의 x, y, z 축에 대한 Pitch, Yaw, Roll 의 값이다. 두 번째는 8개의 EMG 센서에 의해서 측정된 데이터 값이다. 그림 4에서 장치 착용 및 센서의 인식 방향에 대해서 확인할 수 있다.

5. UR3 로봇

제안하는 시스템에서 사용된 로봇팔은 Universal Robots 사에서 개발한 CB-series 중 가장 작은 UR3 로봇을 이용하였다. 최대 작업 반경이 500mm이고, 최대 페이로드는 3kg이다. UR3 로봇은 그림 5와 같이 6개의 회전 관절을 가진 6자유도 로봇이다. wrist3을 제외한 모든 관절의 작업 범위는 $\pm 360^\circ$ 이며 wrist3의 작업 범위는 제한 없이 무한하다. 또한, 철저한 안전보호 기능을 탑재하고 있으므로 작업자의 부상에 대한 위험성이 거의 없다.

III. 근전도 센서를 이용한 CNN기반의 제스처 분류기 구현

본 논문에서 제스처 분류기를 구현하기 위해 근전도 센서인 Myo armband를 사용한다. 작업자가 팔에 Myo armband를 착용하면 블루투스를 이용해 시스템과 통신 할




그림 6. 산업용 로봇 제어를 위해 선택한 5가지 손 제스처
Fig 6. Five hand gestures chosen for controlling an industrial robot

표 1. Myo armband를 이용하여 수집한 손 제스처 'Close' 1set data
Table 1. Hand gesture 'Close' 1set data collected using Myo armband

	ch.1	ch.2	ch.3	ch.4	ch.5	ch.6	ch.7	ch.8
1	0.00996	0.00996	0.07597	0.03238	0.01308	0.00685	0.0056	0.00623
2	0.01557	0.13574	0.06476	0.02428	0.01619	0.01308	0.04608	0.03674
3	0.01494	0.18991	0.06538	0.02304	0.01557	0.01059	0.04483	0.02491
4	0.01557	0.18493	0.06227	0.01806	0.0137	0.00996	0.04359	0.01681
~								
48	0.02242	0.16065	0.08219	0.02491	0.01059	0.00934	0.01121	0.01121
49	0.01743	0.16999	0.08468	0.02242	0.00996	0.00809	0.00934	0.00872
50	0.01681	0.17933	0.09278	0.0193	0.00934	0.00809	0.00747	0.00809

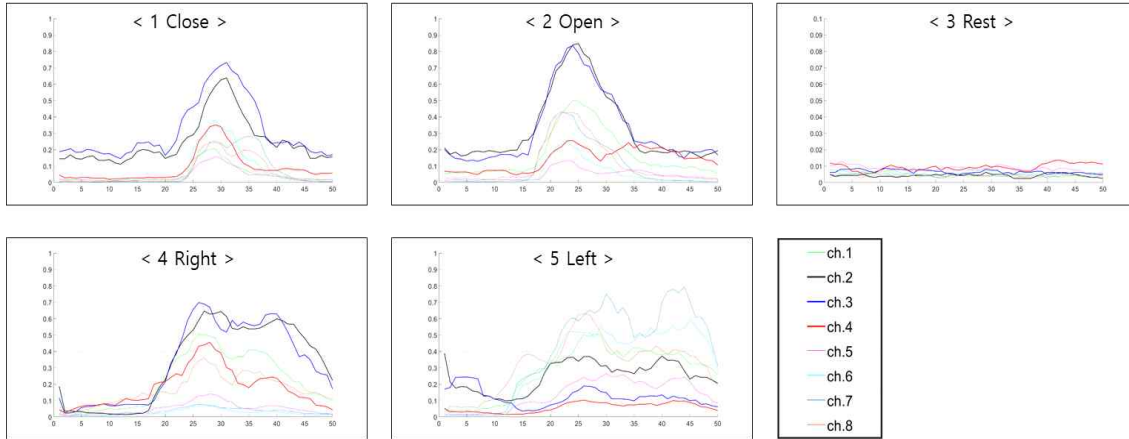


그림 7. 각 손 제스처 데이터의 특징
Fig 7. Characteristics of each hand gesture data

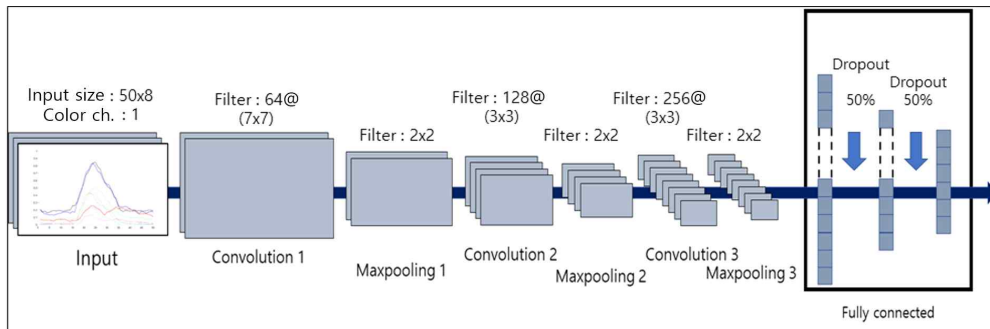


그림 8. 제안 시스템의 CNN 구조
Fig 8. CNN structure of the proposed system

수 있다. 그림 4와 같이 8개의 EMG센서로 구성되어 있고, EMG 데이터에 대한 샘플링 주파수는 50Hz이다. Myo armband에서 수집한 데이터를 활용하여 제스처 분류기를 생성하기 위해 CNN 모델을 이용한다. CNN모델은 주로 이미지와 같이 2차원 데이터의 특성을 추출하여 학습할 때 사용한다. 제안 시스템에서 제스처 분류기 생성을 위해 사용하는 Myo armband의 EMG 데이터는 시간의 흐름에 따라 신호의 크기를 나타내는 2차원 데이터이기 때문에 CNN 모델을 이용하였다.

1. 데이터 수집과 학습

그림 6와 같이 산업용 로봇 제어를 위한 5개의 제스처를 선정하고, 데이터를 수집한다. 데이터 수집에 있어서 손동작 1회는 8개의 채널에 50샘플로 구성되어 있으며, 1회에 소모되는 시간은 1초이다. 표 1은 손 제스처 'Close'에 대한 1set 데이터이다. 이미지 데이터와 같이 2차원 데이터의 형태임을 알 수 있다. 그림 7은 표 1과 같은 각 제스처의 데이터 형태를 시각화한 것이다. 각 제스처마다 서로 다른 특징을 확인할 수 있다.

2. 제스처 분류기 구현을 위해 적용한 CNN 구조

적용한 제안 시스템의 CNN 구조는 그림 8과 같다. 입력 데이터인 손 제스처 데이터는 Myo Armband를 통하여 얻은 데이터이다. 8개 채널의 50샘플의 데이터가 1set 데이터가 된다. 첫 번째 층은 64개의 필터 (7x7)를 사용하고 스트라이드는 1로 설정한다. 여러 번 시행을 통해 성능이 가장 우수하게 나온 필터를 적용하였다. 입력 픽셀의 크기는 50x8이고, 컬러채널은 1이다. 두 번째 층은 풀링의 크기를 2로 설정한 최대 풀링을 추가하여 공간 방향 차원을 반으로 줄인다. 이와 같은 과정을 두 번 더 추가한다. 이 구조는 2차원 입력 데이터의 크기에 따라서 적절한 반복횟수를 설정하는 것이 일반적이고, 크기가 클수록 늘어날 수 있다. 필터의 개수는 첫 번째 층의 64개에 이어 128, 256개로 늘어난다. 풀링 층에서 공간 방향 차원을 반으로 줄이므로 다음 층에서 메모리 사용량, 파라미터 개수, 계산비용을 크게 늘리지 않고 특성 맵 개수를 두 배로 늘릴 수 있다. 다음으로 완전 연결 계층은 두 개의 은닉층과 출력층으로 구성된다. 또한, 과대적합 현상을 방지하기 위해 드롭아웃 비율을 50%로 설정하였다.

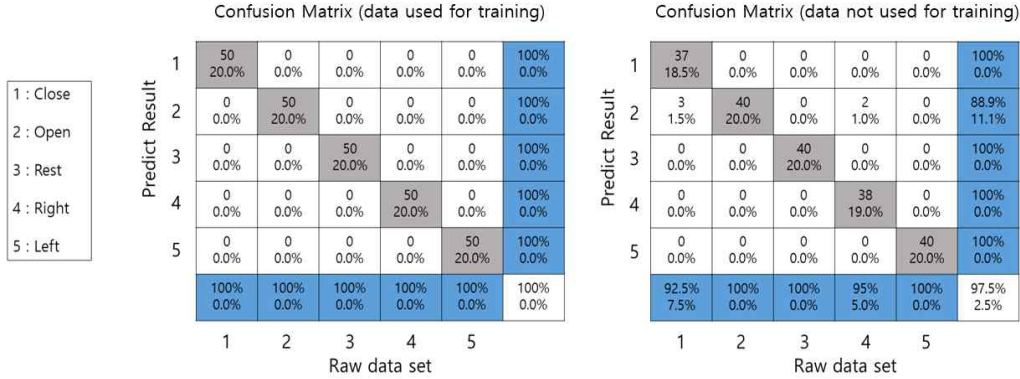


그림 9. 학습에 사용된 데이터와 학습에 사용되지 않은 데이터를 테스트 데이터로 적용한 모델의 Confusion Matrix
 Fig 9. Confusion Matrix of model applying data used for training data and not used for training as test data

표 2. 제안 시스템의 실시간 작동 정확도
 Fig 2. Real-time operation accuracy of the proposed system

Gesture	Success/Fail	Accuracy
Close(1)	43/7	86%
Open(2)	39/11	78%
Rest(3)	49/1	98%
Right(4)	43/7	86%
Left(5)	46/4	92%
Total	220/30	88%

IV. 실험

1. 학습 모델 평가

학습에 사용된 데이터 중 각 제스처의 50set씩을 테스트 데이터로 적용하여 모델의 정확도를 확인한 결과와 학습에 사용되지 않은 새로운 데이터 (각 제스처 40set씩)를 테스트 데이터로 적용하여 모델의 정확도를 확인하였다. 그림 9에서 확인한 것과 같이 학습에 사용된 데이터를 테스트 데이터로 적용한 경우 100%의 정확도를 보여준다. 학습에 사용되지 않은 데이터를 테스트 데이터로 적용한 경우 제스처 'Open'은 'Close'와 유사하고 제스처 특징이 시작되는 부분이 'Right'와도 유사하므로 그림 9의 테스트 데이터를 적용한 Confusion Matrix의 결과에서 제스처 'Close'와 'Right'가 'Open'으로 인식되는 경우도 있는 것을 알 수 있다.

2. 제안 시스템 로봇 제어

제안 시스템의 로봇 제어 성공률 (제스처 분류기의 정확도)은 표 2와 같다. 각 제스처 당 50회의 실험을 통해 실제 로봇이 제스처를 추정한 결과대로 작동하는지 실험하였다. 모든 제스처에 대한 동작 정확도는 88%로 CNN 모델을 테스트 할 때보다 정확도가 낮은 것을 볼 수 있다. 이는 연속적으로 전송되는 데이터를 임의의 50샘플로 나누어 제스처 분류기에 적용하면서 모델 (제스처 분류기)평가 정확도보다

낮아진 것이다. 정확도를 올리기 위해서는 실시간으로 전송되는 데이터 처리방식을 개선하고, 실시간 정확도를 높이기 위한 CNN 모델 개선, 그리고 제스처의 더 확실한 구분을 위한 데이터 정규화 방법에 관한 연구가 필요할 것으로 생각하고 있다.

V. 결론 및 향후 연구

본 논문에서는 장착용 근전도 센서로 수집한 데이터를 토대로 제스처 분류기를 생성하고, 출력값을 산업용 로봇 UR3와 그리퍼에 통신하여 제어하는 ROS 기반 시스템을 제안하였다. CNN 기반의 산업용 로봇 원격제어 시스템은 사용자의 필요에 맞게 원하는 제스처를 설정해서 학습하고 로봇 제어에 사용할 수 있으므로 자유로운 제어가 가능하고, CNN 모델 개선에 따라서 더 많은 손 제스처와 높은 정확도를 가진 제어가 가능하다. 본 논문에서는 실시간 작동에 의한 정확도가 88%로 측정되었다. 12%의 오차를 손 제스처 데이터의 특성과 테스트 데이터의 Confusion Matrix를 토대로 파악했을 때 특성이 비슷한 제스처의 데이터를 분류기가 정확히 판별하지 못했던 것으로 생각된다. 이것은 적용한 CNN 모델 구조를 개선하고, 근전도 센서의 수를 늘려 확실한 특성을 가진 데이터를 수집하거나 다른 학습 데이터의 정규화 방법을 고려해서 해결할 수 있을 것으로 생각하고 있다.

References

[1] V. Villani, F. Pini, F. Leali, C. Secchi, "Survey on Human-robot Collaboration in Industrial Settings: Safety, Intuitive Interfaces and Applications," Mechatronics, Vol. 55, pp. 248-266, 2018.
 [2] T.B. Sheridan, "Human-Robot Interaction," Human Factors, Vol. 58, No. 4, pp. 525-532, 2016.
 [3] M.H Kim, S.R. Jin, "Study on Direct Teaching Algorithm

for Remote Center Motion of Surgical Assistant Robot using Force/Torque Sensor,” Journal of Korea Robotics Society, Vol. 15, No. 4, pp. 309-315, 2020 (in Korean).

[4] S.G. Hong, G.H. Park, Y.W. Lee, W.S. Lee, B.H. Choi, S.C. Kang, “Development of a Tele-Operated Rescue Robot with High Weight Lifting Capacity,” Journal of Institute of Control, Robotics and Systems, Vol. 23, No. 12, pp. 1077-1085, Dec 2017 (in Korean).

[5] S.S. Heo, W.H. Lee, H.C. Sim, J.H. No, “Research on Forced Feedback method and Autonomous Driving for Remote Operation of an Unmanned Exploration and Mining Robot,” Institute of Control, Robotics and Systems, pp. 532-536, May 2010 (in Korean).

[6] B. Yoon, J. Sa, K. Choi, “Humanoid Robot Teleoperation System using Head Mounted Display,” Journal of the Institute of Electronics and Information Engineers, Vol. 56, No. 9, pp. 77-84, 2019 (in Korean).

[7] B.K. Lee, J.Y. Lee, M.C. Moon, S.G. Hwang, J.K. No, C.S. Han, “A Study of HRI Control for 7-DOF Telerobotic Controller,” Proceedings of KSPE 2017 Autumn Conference, pp. 858-859, 2017 (in Korean).

[8] Moon, H. G., Han, C. S., Lee, H. D., Kim, W. S., Lee, B. K., & Han, J. S. “Performance Verification of the HRI Control Algorithm of the Upper Limb Exoskeleton Robot,” Proceedings of KSPE 2013 Spring Conference, pp. 59-60, May 2013 (in Korean).

[9] S. Wang et al. “A Generative Human-robot Motion Retargeting Approach Using a Single Depth Sensor,” IEEE International Conference on Robotics and Automation, July 2017.

[10] G. Du, P. Zhang, X. Liu. “Markerless Human-manipulator Interface Using Leap Motion with Interval Kalman Filter and Improved Particle Filter,” IEEE Transactions on Industrial Informatics, Vol. 12, No. 2, 2016.

[11] C. Yang, S. Chang, P. Liang, Z. Li, C.Y. Su, “Teleoperated Robot Writing Using EMG Signals,” IEEE International Conference on Information and Automation, 2015

[12] Li, C., Yang, C., Wan, J., Annamalai, A. S. K., Cangelosi, A. “Teleoperation control of Baxter robot using Kalman filter-based sensor fusion,” An Open Access Journal, Vol. 5, No. 1, pp. 156-167, 2017.

[13] Y.U. Jo, D.C. Oh, “Study on the EMG-based Grasp Gesture Classification Using Deep Learning and Application to Active Prosthetics,” Journal of Institute of Control, Robotics and Systems, Vol. 25, No. 3, pp. 229-234, March 2019 (in Korean).

[14] Javier O. Pinzón Arenas, Robinson Jiménez Moreno and Ruben Darío Hernández Beleño, “Convolutional Neural Network with a DAG Architecture for Control of a Robotic Arm by Means of Hand Gestures,” Contemporary Engineering Sciences, Vol. 11, No. 12, pp. 547-557, 2018.

[15] Quigley, Morgan, et al. “ROS: an open-source Robot Operating System,” In ICRA workshop on open source software, Vol. 3, No. 3.2, pp. 5, 2009.

[16] https://github.com/uts-magic-lab/ros_myo

[17] <https://github.com/ros-industrial/robotiq>

[18] https://github.com/ros-industrial/ur_robot_driver

Se-yun Jeon (전 세 윤)



2019 School of Electronic Engineering from Kumoh National Institute of Technology (B.S.)
 2021 School of Electronic Engineering from Kumoh National Institute of Technology (M.S.)

Career:

2019~2021 Kumoh National Institute of Technology, Master Student

Field of Interests: Embedded System, Robot Manipulator System

Email : fkdzjdn@kumoh.ac.kr

Eun-su Kim (김 은 수)



2020 School of Electronic Engineering from Kumoh National Institute of Technology (B.S.)
 2020~School of Kumoh National Institute of Technology, Master Student

Field of Interests: Embedded System, Robot Manipulator System

Email : 20206010@kumoh.ac.kr

Bum Yong Park (박 범 용)

2009 School of Electrical Engineering and
Computer Science from Kyungpook
National University (B.S.)

2011 Electrical Engineering from
POSTECH (M.S.)

2015 Electrical Engineering from
POSTECH (Ph.D.)

2017~School of Electronic Engineering and Department of IT
Convergence Engineering at Kumoh National Institute of
Technology (Assistant Professor)

Career:

2015~2017 Senior Engineer, Samsung Electronics

Field of Interest: Robust Control, Signal Processing, Embedded
Control Systems, Robot Manipulator System

Email : bumyong.park@kumoh.ac.kr