

적외선 센서의 시간 지연 딥러닝 학습

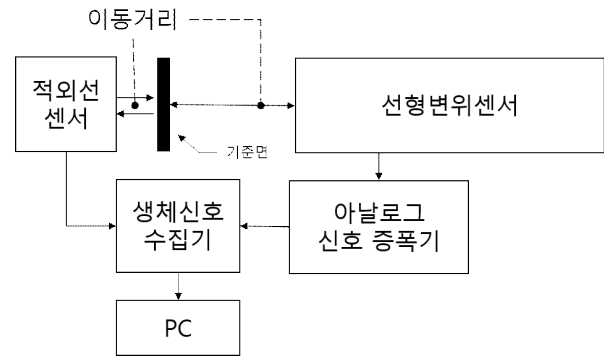
박재성*, 피진우*, 손호선**, 차은종*, 김경아*
 충북대학교 의과대학 의공학교실*, 충북대학교 의학연구소**

Time delay deep learning of infrared light sensor

Jae Sung Park*, Pi Jin Woo*, Ho Sun Shon**, Eun Jong Cha*, Kyung Ah Kim*
 Chungbuk National University, Department of Biomedical Engineering*
 Chungbuk National University, Medical Research Institute**

Abstract - 적외선 센서는 범용성과 안전성으로 다양한 분야에서 사용되고 있으나, 출력신호에 포함된 노이즈로 인해 평균 제곱 오차 또는 평균 절대 오차 등과 같은 필터를 사용하게 된다. 이때 신호에 변형이 발생하게 되어 정확도가 떨어지는 문제점이 발생하게 된다. 따라서 본 연구에서는 시간 지연 신경망을 이용하여 적외선 센서의 노이즈를 제거하고 기준 거리 데이터와 유사하게 출력할 수 있음을 확인하였다.

다. 생체신호 수집기(IDAQ-400, PhysioLab, Korea)로 적외선 센서와 선형변위센서의 출력신호를 동시에 수집하였다.



〈그림 1〉 실험장치 모식도

1. 서 론

전자기와 스펙트럼에서 적외선은 0.78 μ m에서 1,000 μ m의 파장 영역에 해당하며 적외선의 응용 목적에 따라 근적외선, 단적외선, 중적외선, 원적외선, 극적외선의 5개 영역으로 구분할 수 있다[1]. 산업계에서는 근적외선 방식에 비해 긴 가지거리와 우수한 노이즈 특성을 가진 8.0~14 μ m 대역의 원적외선 방식을 사용하고 있지만, 원적외선 방식은 가격이 높아 고가의 장비에만 채용이 확대되고 있어 비교적 저렴한 0.75~1.4 μ m 대역의 근적외선 센서를 사용하기도 한다[2].

물체에 반사되어 돌아오는 적외선을 검출하는 능동형 근적외선 방식은 금속, 나무 그리고 피부까지 측정 가능한 범용성과 안전성으로 다양한 분야에서 사용된다. 하지만 근적외선 센서 신호에는 노이즈가 많아 평균 제곱 오차(mean squared error, MSE) 또는 평균 절대 오차(mean absolute error, MAE) 방법으로 필터링하여 사용되고 있다[3-4]. MSE나 MAE 등을 이용하여 필터링한 근적외선 센서의 신호는 신호에 변형이 있어 정확도가 떨어지는 문제점이 있다[4].

신경회로망(neural network)은 사람의 뇌 구조를 모방한 기계 학습 방법으로, 계층적 접근을 통해 결정 경계를 찾는다. 사람의 뇌에는 10¹¹개의 뉴런이 있고 이 뉴런들 사이에 10¹⁵개의 시냅스 연결이 존재한다. 신경회로망은 XOR과 같이 선형으로 분리되지 않는 문제를 해결하기 위해 다층 신경회로망(multi-layer neural network)으로 발전하여 패턴 인식 문제 또는 특징점 학습을 위해 많은 수의 신경층을 가지도록 모델을 구성하는 기계학습으로 발전하였다[5]. 시간 지연 딥러닝(time-delay neural network, TDNN)은 이차원 분류에 적용되어 좌표 공간에서 시프트 불변성(scale-invariant feature transform)으로 학습할 수 있으며, 데이터의 시간적 관계를 수용할 수 있는 구조로서 음성과 같은 동적인 데이터의 처리 및 동적인 특성을 반영하여 정보를 추출하기 위한 방법으로 활용되고 있다[6]. 따라서 본 연구에서는 TDNN을 이용하여 적외선 센서의 노이즈를 제거하고 거리 신호로 변환하여 거리 측정에 적용 가능한지 확인하고자 하였다.

2. 본 론

2.1 시스템 구성

적외선 센서(GP2Y0A41SK0F, Sharp, Japan)와 선형변위센서(LTM-550, Gefran, Italy)가 동일한 변위를 측정하도록 <그림 1>과 같이 실험 장치를 구성하였다. 적외선 센서와 선형변위센서 사이에는 이동 가능한 기준면(반사면)을 두었다. 적외선 센서의 측정 범위를 고려하여 이동 범위를 40~300mm로 설정하였

2.2 데이터 획득


적외선 센서와 선형변위센서로부터 위치 데이터를 얻기 위해서 40~300mm 범위 안에서 기준면을 좌우로 일정한 속도로 수동 왕복 운동하였다. 총 10분 10초 동안 125번 왕복 운동을 시행하였으며, 형태가 다른 데이터에 대한 처리 성능을 확인하기 위해 7분 30초 이후에는 최초의 이동 속도보다 조금 더 느린 속도로 움직였다.

2.3 전처리와 시간 지연 신경망

적외선 센서와 선형변위센서로부터 획득한 데이터를 TDNN에 적용하기 위해 MATLAB(MathWorks, USA)에서 제공하는 함수를 사용하여 전처리를 수행하였다. 먼저 table2array를 사용하여 배열로 변환하였다. 이후 reshape 함수를 사용하여 크기를 조절하였으며, 표준 뉴런 네트워크 셀(cell) 어레이(array)로 변환하기 위해 tonndata를 사용해 데이터를 셀 형태로 만들었다. TDNN은 MATLAB의 nts 툴박스를 사용하였고, 입력층과 출력층의 크기는 100으로 동일하게 설정하였다. Training은 전체 데이터에서 80%, validation과 testing 데이터는 각각 10%로 설정하였다. 지연 시간의 비율은 1:2로 하였으며, 은닉층의 수는 20개로 설정하였다. Training 함수는 베이시안 정규화(Bayesian regularization)를 사용하였다. 1000 에포크(epochs)까지 학습을 진행하였고, MSE와 시계열 응답(time-series response)을 이용하여 성능을 평가하였다.

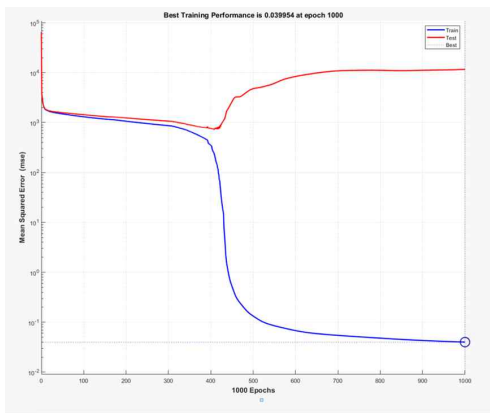
3. 결 과

기준면을 왕복 운동하여 적외선 센서와 선형변위센서로부터 각각 61,000개의 데이터를 획득하였으며, 최초 시작부터 100초까지의 신호를 <그림 2>에 제시하였다.



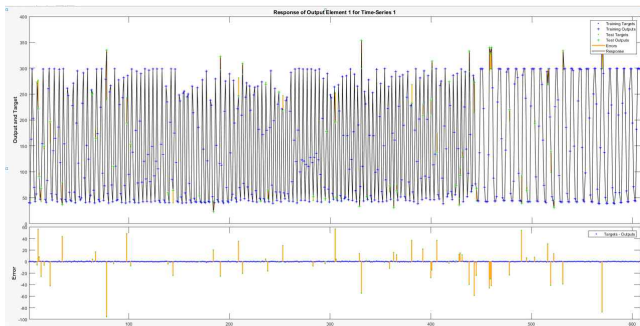
<그림 2> 적외선 센서와 선형변위센서 데이터

MATLAB을 이용하여 테이블 형태의 61,000개 데이터를 전처리한 후 100x610 형태의 배열로 변경하고, 표준 뉴럴 네트워크 셀 어레이로 변환하여 1x610의 셀 형태로 만들었다. TDNN을 학습하기 위한 입력으로 적외선 센서 데이터를 사용하고 target 데이터는 선형변위센서 데이터로 하였다. 학습이 종료된 후 train 데이터의 MSE가 0.039954인 것을 확인하였다. 반면 test 데이터의 MSE는 약 10^4 이었다. <그림 3>은 에포크에 따른 train 데이터와 test 데이터의 MSE를 나타낸 그래프이다.



<그림 3> 에포크에 따른 MSE

시계열 응답의 결과는 training outputs 데이터가 training targets 데이터와 유사하게 나온 것을 확인하였다. 반면 test outputs 데이터는 test targets 데이터와 비교하여 대부분 유사하게 나타났지만 일부 구간에서는 두 수치의 차이가 높게 나왔다. <그림 4>에 시계열 데이터에 대한 출력 요소 응답을 제시하였으며, train과 test의 target에 대한 outputs의 정확도를 나타내고 있다.



<그림 4> 시계열 데이터에 대한 출력 요소 응답

4. 결 론

본 논문에서는 TDNN을 이용해 적외선 센서의 노이즈를 필터링하고 거리 데이터로 출력됨을 확인하였다. 시계열 데이터에

대한 출력 요소 응답에서 target 데이터와 output 데이터의 차이가 일부 구간에서만 높게 나왔으나 대부분의 test 데이터가 target 데이터에 근접하여 출력하는 것을 확인하였다. 본 연구 결과를 통해 TDNN을 이용하여 적외선 센서의 노이즈를 제거하고 기준 거리 데이터와 유사하게 출력할 수 있음을 확인하였다.

[참 고 문 헌]

- [1] 정용택, “적외선 센서의 최신 기술 동향”, 정보통신기획평가원, 2019
- [2] 김연희, 김태현, “적외선 센서 소재 및 응용현황”, CERAMIST, 제17권 제4호, 61-17, 2014
- [3] Witold Pedrycz, “An Identification Algorithm in Fuzzy Relational Systems”, Fuzzy Sets and Systems, Vol. 13, pp. 153-167, 1984
- [4] Vincent Le Guen, Nicolas Thome, “Shape and time distortion loss for training deep time series forecasting models”, Proceedings of the 33rd International Conference on Neural Information Processing Systems, No. 377, pp.4189-4201, 2019
- [5] Bambang Parmanto, Lee G. Deneault, André Y Denault, “Detection of hemodynamic changes in clinical monitoring by time-delay neural networks”, International Journal of Medical Informatics, Vol. 63, No. 1-2, pp.91-99, 2001
- [6] 문성은, 장수범, 이정혁, 이종석, “기계학습 및 딥러닝 기술동향”, Information & communication magazine, 제33권, 제10호, 49-56, 2016