연구논문

Journal of Drive and Control, Vol.20 No.4 pp.133-139 Dec. 2023
ISSN 2671-7972(print) ISSN 2671-7980(online)
http://dx.doi.org/10.7839/ksfc.2023.20.4.133

CNN기반 굴삭기용 부하 측정 시스템 구현을 위한 연구
A Study of Weighing System to Apply into Hydraulic Excavator with CNN

정황훈[1*] · 신영일[1] · 이진호[1] · 조기용[1]
Hwang Hun Jeong, Young Il Shin, Jin Ho Lee and Ki Yong Cho

Received: 15 Nov. 2023, Accepted: 28 Nov. 2023

Key Words : Weighing System(부하 측정 시스템), Linear Regression(선형 회귀), CNN(합성곱 신경망)

Abstract: A weighing system calculates the bucket's excavation amount of an excavator. Usually, the excavation amount is computed by the excavator's motion equations with sensing data. But these motion equations have computing errors that are induced by assumptions to the linear systems and identification of the equation's parameters. To reduce computing errors, some commercial weighing system incorporates particular motion into the excavation process.

This study introduces a linear regression model on an artificial neural network that has fewer predicted errors and doesn't need a particular pose during an excavation. Time serial data were gathered from a 30tons excavator's loading test. Then these data were preprocessed to be adjusted by MPL (Multi Layer Perceptron) or CNN (Convolutional Neural Network) based linear regression models. Each model was trained by changing hyperparameter such as layer or node numbers, drop-out rate, and kernel size. Finally ID-CNN-based linear regression model was selected.

1. 서 론

굴삭기에 있어 부하 측정 시스템은 굴착 또는 이송 작업을 수행하는 버킷 내 부하의 양을 측정하는 시스템을 의미한다. 이 부하 측정 시스템은 굴삭기의 작업량 계산, 운전기사의 작업 효율 측정 및 타 건설 기계와의 협업 등에 사용되어, 건설 작업의 보조 및 건설 자동화의 효율을 향상시키는데 필요한 기술이다.[1,2,3,4,5)]

현재 상용화 된 부하 측정 시스템에는 붐 링크 및 암 링크, 스윙 모터의 각변위, 붐 실린더의 차압을 운동방정식에 적용하여 부하를 계산하는 방법[6)]과 특정 자세에서 부하를 측정하는 방법[7)]이 있다. 전자의 경우 비선형 시스템을 선형으로 가정하고, 저차원화하면서 발생하는 모델링 오차와 실험을 통해 운동방정식 내 관성항을 동정하면서 발생하는 오차를 필연적으로 가지며, 후자의 경우 굴착 및 이송 작업 시 특정 자세를 취하여 관성항의 영향을 0으로 만들어 부하를 측정하여야만 하기 때문에 작업 속도가 떨어지는 단점을 가지고 있다.[8)]

본 연구의 목적은 비선형 특성이 강한 굴착기의 부하 측정 시스템을 비선형 모델인 인공신경망을 활용하여 모사함으로써 부하 측정을 위한 특정 자세를 취하지 않으면서도 선형으로 가정한 부하 측정 시스템보다 오차가 적은 모델을 제안하는 것이다. 목적을 달성하기 위해 본 연구에서는 먼저 30톤 굴삭기의 상차 실험을 통해 인공신경망의 학습을 위한 데이터를 취득하였으며, 저장된 시계열 데이터를 학습하고자 하는 인공신경망의 입력에 맞게 정형하였다. 다음으로, 학습된 인공신경망의 결과를 비교하기 위하여 동일한 데이터 셋에 대하여 다항 회귀를 위한 머신

* Corresponding author: hwanghun@koceti.re.kr
1 Intelligent Control Lab., Korea Construction Equipment Technology Institute, Gunsan 54004, Korea
Copyright Ⓒ 2023, KSFC
This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License(http://creativecommons.org/licenses/by-nc/3.0) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

러닝 모델을 학습하였다. 정형된 데이터 셋에 대하여 다층 퍼셉트론/합성곱 신경망(MLP/CNN) 기반 선형 회귀 모델의 구조, 커널 크기, Drop out 비율 등을 변경하며 학습하였고, 학습된 모델 중 손실함수의 크기가 가장 작은 모델들을 선정하였다. 선정한 모델들은 전체 데이터 셋을 대표하는 시험 데이터 셋의 예측값을 통해 평가하였고, 이를 통해 선정한 모델의 타당성을 확인하였다.

2. 데이터 셋의 생성

본 연구에서 사용하는 선형 회귀 모델은 지도학습이 필요한 모델로 인공신경망의 하중행렬과 편향행렬의 값을 구하기 위해 학습 데이터 셋이 필요하다. 상용 부하 측정 시스템을 바탕으로 굴삭기의 부하를 계산하기 위해 필요한 신호는 붐 링크 및 암 링크, 스윙 모터의 각변위, 붐 실린더의 차압이며,[9,10,11] 본 연구에서는 실차 실험을 통해 습득한다.

2.1 실험 데이터 취득

실험에 사용된 30톤 굴삭기(DX 300LC)의 버킷 용량은 1.27m^{3}이며, 일반적인 흙의 밀도(사질토 1.8~2.2t/m^3, 점성토 1.6~2.0t/m^3, 연석 2.0t/m^{3}미만, 경석 2.5t/m^{3}이상)를 고려할 때, 버킷의 부하는 2.3t에서 3.2t의 값을 가진다. 따라서 실험을 위한 무게추는 Fig.1과 같이 개당 10kg의 모래주머니를 4.5t만큼 준비한다. Table 1은 굴삭기 상태를 측정한 센서 모델을 나타낸 표이며, Fig. 2는 부하가 각각 0kg, 1000kg, 2000kg, 3000kg, 4000kg일 때, 가상의 트럭에 적재하는 것을 가정한 동작을 2회 수행하는 동안 센서를 통해 측정한 시계열 데이터를 나타낸 그래프이다. 그래프로부터 각 부하에 따른 굴삭기의 동작시간이나, 상차 작업에 따른 버킷의 위치, 붐 실린더 차압 등이 일정하지 않음을 알 수 있다.

Fig. 1 Sandbag for test's payload

Table 1 Sensor specification

sensor model	measured state
IMU(MV5-AR)	boom/arm link angle
Encoder(E68S)	swing motor angle
ATM.ECO	boom cylinder's pressure

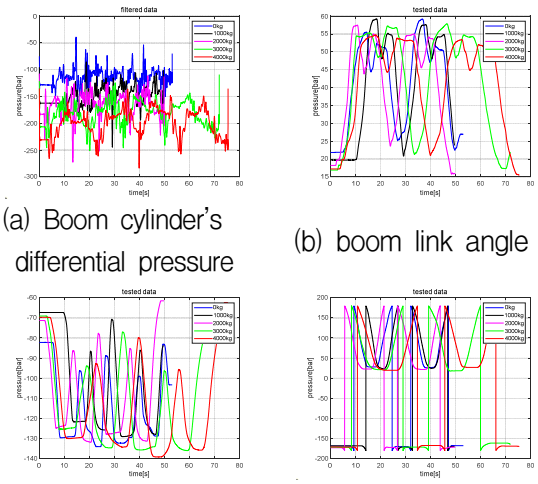

(a) Boom cylinder's differential pressure (b) boom link angle

(c) arm link angle (d) swing angle

Fig. 2 Test data on a dumping process with payload variation

2.2 데이터 전처리

본 연구에서는 다층 퍼셉트론 기반 선형 회귀 모델과 1차원/2차원 합성곱 신경망(1D/2D CNN) 선형 회귀 모델을 사용하고자 한다. 다층 퍼셉트론 기반 선형 회귀 모델의 경우 랜덤으로 선정한 샘플링 시간에서 해당 상태값(붐 실린더 포트 압력, 붐 링크/암 링크/스윙 모터 각변위, 각속도, 각가속도)을 입력으로 사용한다. 각속도와 각가속도를 사용하는 이유는 샘플링 시간 사이 데이터에 대한 상관관계를 학습에 고려하기 위함이다. 2차원 합성곱 신경망(2D CNN) 선형 회귀 모델의 경우 랜덤으로 선정한 샘플링 시간에서 시작하는 해당 상태값(붐 실린더 포트 압력, 붐 링크/암 링크/스윙 모터 각변위)에 대한 196개의 데이터를 순차적으로 14x14 행렬로 정렬하여 흑백이미지처럼 입력으로 활용한다.[12] 시계열 데이터를 이미지로 변환할 경우 기존 이미지 처리에 활용했던 기법들을 응용할 수 있다. 1차원 합성곱 신경망(1D CNN)

Table 2 A specification of dataset's shape

Linear Regression Model	Dataset	
	shape	numbers
MLP	1 x 11	3000
2D CNN	14 x 14	200
1D CNN	1 x 100	200

선형 회귀 모델의 경우 랜덤으로 선정한 샘플링 시간에서 시작하는 해당 상태값(붐 실린더 포트 압력, 붐 링크/암 링크/스윙 모터 각변위)에 대한 196개의 데이터를 1x100 행렬로 정렬하여 입력으로 활용한다.[13)]

각 선형 회귀 모델의 입력으로 사용되는 데이터는 0에서 1사이의 값을 가지도록 정규화 하였다. 이 때 데이터 셋은 학습을 위한 데이터와 검증을 위한 데이터, 시험을 위한 데이터 3부류로 나눈다. 이는 신경망의 학습 시 검증 데이터가 학습 종료를 위해 활용되기 때문이며, 시험 데이터는 학습이 완료된 모델이 비학습 데이터에 대하여 충분한 정확도를 가지는지 판별할 때 활용된다. 0kg에서부터 50kg간격으로 총 91번의 실험을 통해 데이터를 취득하였으며, 이 중 학습 데이터는 40개, 검증 데이터는 15개, 시험 데이터는 13개가 활용되며, 학습 결과로부터 선정된 부하 예측 모델의 성능을 평가하기 위하여 전체 91개의 전체 실험으로부터 평가 데이터 셋을 만들었다.

3. 인공신경망의 학습

본 연구에서는 전처리된 실험 데이터를 활용하여 머신러닝 기반의 다항 선형 회귀 모델을 학습하고, 이를 딥러닝 모델의 학습 결과를 비교할 수 있는 근거로 활용한다. 딥러닝 모델의 학습을 위한 하이퍼 파라미터는 특정 범위의 값이 가질 수 있는 경우의 수에 대하여 모두 수행하고, 이 중 손실함수를 최소로하는 모델을 선정하였다.

3.1 다항 회귀

일반적으로 모델로부터 계산된 결과를 평가하기 위해서는 비교를 위한 기준이 필요하다. 본 연구에서는 딥러닝을 활용하여 학습된 부하 예측 시스템의 정확도를 평가하기 위하여 머신 러닝 기법 중의 하나인 다항 회귀 기법을 사용한다.

다항 회귀는 머신 러닝 중 선형 회귀 방식이 가지는 단순 선형 모델의 한계를 극복할 수 있는 방법으로 가설에 해당하는 선형식의 독립변수 차수를 높여 구현한다.[14)] 다항 회귀에 사용되는 데이터 셋은 다층 퍼셉트론 기반 선형회귀 모델을 위해 작성된 데이터 셋과 동일하며, 다항 회귀 모델의 차수를 증가시켜가며 학습데이터와의 평균 제곱 오차가 최소가 되는 모델을 선정한다.

Fig. 3은 선형 회귀 모델 및 다항 회귀 모델의 학습 결과를 나타낸 그래프이다. 차수가 올라갈수록 모

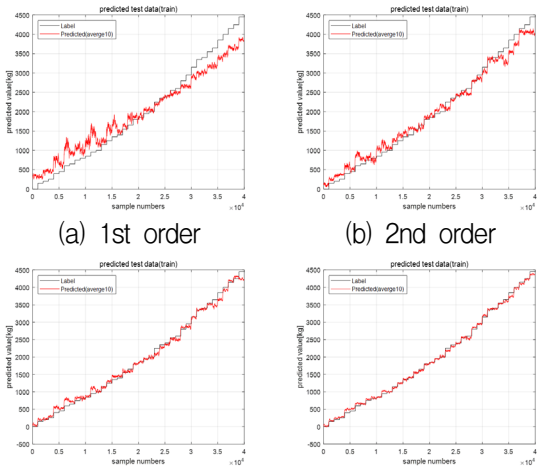

(a) 1st order (b) 2nd order

(c) 3rd order (d) 4th order

Fig. 3 Learning results for linear and polynomial regression

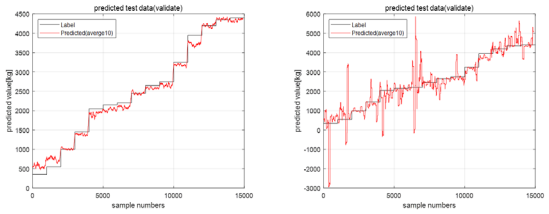

(a) 3rd order (b) 4th order

Fig. 4 Predicted results on validation dataset

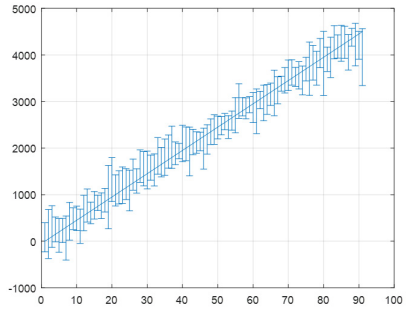

(a) Predicted error

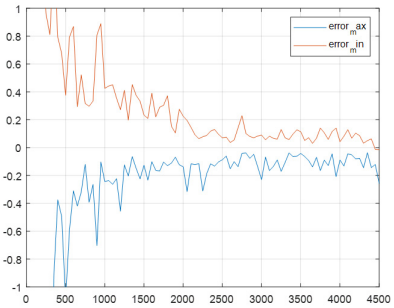

(b) Predicted error rate

Fig. 5 Predicted result's error on test dataset (polynomial regression)

델의 손실함수가 줄어드는 것을 알 수 있다. Fig. 4는 검증 데이터 셋에 대한 3차 및 4차 다항 회귀 모델의 예측값을 나타난 그래프이다. 4차 다항 회귀 모델의 경우 학습되지 않은 데이터에 대하여 큰 오차를 나타내고 있으며, 이는 과적합(over fitting)상태임을 알 수 있다. 따라서 학습 데이터에 대한 다항 회귀 모델은 3차일 때 최소의 평균 제곱 오차를 가진다고 판단된다. Fig. 5(a)는 선정된 다항 회귀 모델에 대한 시험 데이터의 예측값을 나타낸 그래프로 x축은 실험 데이터의 0에서 91까지의 순서를 y축은 예측된 무게의 최대/최소값을 나타낸다. Fig. 5(b)는 실험된 무게추의 라벨값과 예측된 무게 사이의 오차비율을 나타낸 그래프로 x축은 예측된 무게, y축은 오차비율(%)을 나타낸다.

3.2 선형 회귀 모델의 학습

본 연구에서는 굴착량을 예측하는 선형 회귀 모델의 후보로 다층 퍼셉트론 기반 모델 및 1차원/2차원 합성곱 신경망 기반 모델을 선정하였다. 다층 퍼셉트론 기반 모델의 경우 완전 연결된 층(dense layer)를 쌓아 생성하였으며, 선형 회귀 모델이기 때문에 출력층의 활성화 함수는 Relu를 사용하였다.[15] 1차원/2차원 합성곱 신경망 기반 모델의 경우 두 개의 합성곱층과 최대 풀링(max pooling)층으로 구성된 블록을 2개 쌓아 특징을 추출하였으며, 드랍 아웃(Drop out)을 수행하여 학습의 속도를 조절하였다.

3.2.1 하이퍼 파라미터의 선정 방법

최적의 선형 회귀 모델을 학습하기 위해서는 각 모델의 하이퍼 파라미터를 선정할 필요가 있다. Table 3은 각 선형 회귀 모델의 하이퍼 파라미터를 정의한 것이며, 각 조건에 따라 학습된 모델의 검증 데이터에 대한 손실함수를 바탕으로 선형 회귀 모델을 선정하였다.

모든 신형 회귀 모델의 손실 함수는 평균 제곱 오차를 사용하였으며, 탐색 알고리즘(optimizer)은 아담(Adam)을 사용하였으며, 출력층의 노드(node)는 1개로 활성화 함수는 Relu를 사용하였다.

다층 퍼셉트론 기반 모델의 경우 완전 연결된 dense layer로 구성되어 있으며, 1차원/2차원 합성곱 신경망 기반 모델의 경우 특징 추출기(feature extractor)와 선형 회귀 모델로 구성되었다. 특징 추출기는 2개의 1/2차원 합성곱층과 최대 풀링층으로 이루어진 블록을 2개 직렬 연결하였으며, 선형 회귀 모델은 완전 연결된 dense layer로 구성되었다. 합성곱층의 출력은 입력데이터와 동일한 크기가 되도록 패딩(padding)에 대하여 'same' 옵션을 사용하였으며, 특징 추출기와 선형 회귀 모델 사이의 연결 은 flatten층을 추가하여 수행하였다.

Table 3 A specification of hyperparameter

Linear Regression Model/ Hyperparameter		Hyperparameter set
MLP	hidden layer	4, 5, 6, 7
	node	16, 32, 64, 128, 256, 512
2D CNN	convolutional layer node	32, 64, 128, 256, 512
	kernel size	3x3, 4x4
	drop out rate	0.1. 0.2, 0.3, 0.4, 0.5
1D CNN	convolutional layer node	32, 64, 128, 256
	kernel size	2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12
	drop out rate	0.1. 0.2, 0.3, 0.4, 0.5

3.2.2 선형 회귀 모델의 선정

Table 4는 하이퍼 파라미터를 변경하며, 주어진 데이터 셋에 대하여 학습하고, 검증 데이터 셋에 대한 평균 제곱 오차가 최소가 되는 모델을 선정한 결과를 나타낸 것이며, 검증 데이터 셋에 대한 예측 결과는 Fig. 6과 같다. Table 4에서 D는 dense layer, C2d는 2D 합성곱층, M은 max pooling layer, F는 flatten layer, Dr은 Drop out, C1d는 1D 합성곱층을 의미하며, 각 층에 적힌 숫자는 노드 수를 의미한다. Fig. 6에서 x축은 실험데이터로부터 생성된 데이터 셋의 순서를 나타내며, y축은 실험 부하와 예측치를 나타낸다.

Table 4 Simulation results of weighing system

Model	Structure	MSE	
		train	validate
MLP	D256-D256-D128 -D128-D64-D32-D1	28057.1	58466.1
2D CNN	C2d(64)-C2d(64)-M-C2d(64)-C2d(64)-M-F-D256-Dr-D1	15424.3	33650.6
1D CNN	C1d(256)-C1d(128)-M-C1d(64)-C1d(32)-M-F-D256-Dr-D1	25984.4	47287.4

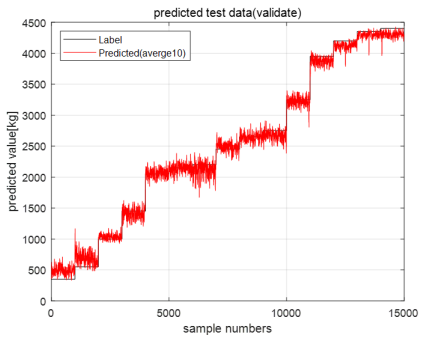

(a) MLP LR

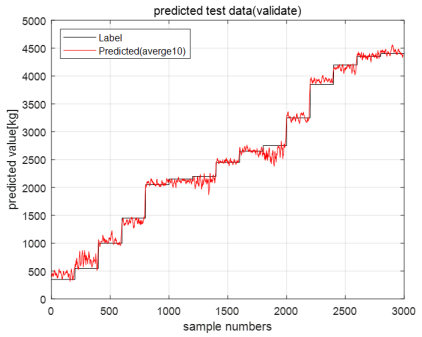

(b) 2D CNN LR

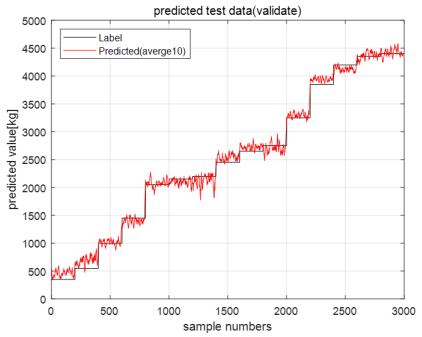

(c) 1D CNN LR

Fig. 6 Predicted results error on validation dataset

3.2.3 선정된 모델의 검증

선정된 각 모델에 대하여 전체 실험데이터를 대표하는 시험 데이터 셋에 대한 예측값을 구하고 라벨값과의 오차값 및 오차비율을 각각 Fig. 7과 Fig. 8과 같이 Fig. 5와 동일한 방법으로 나타내었다.

다층 퍼셉트론 기반 선형 회귀 모델의 경우 평가기준이 되는 머신러닝 다항 회귀 모델에 비하여 시험 데이터 셋의 오차값과 오차 비율이 줄어들었으나, 부하 측정의 정확도 제한을 10% 이하라 가정할 때, 사용 가능한 범위의 시작이 2050kg으로 실차 실험에 적용하기에는 부족하다.

2차원 합성곱 기반 선형 회귀 모델의 경우 머신러닝 다항 회귀 모델이나, 다층 퍼셉트론 선형 회귀 모델에 비하여 오차값과 오차 비율이 상당히 줄어들었다. 다층 퍼셉트론 선형 회귀 모델에서처럼 부하 측정의 정확도를 제한할 때, 사용 가능한 범위는 600kg 이상으로 버킷의 최대 paylaod가 4400kg임을 감안할 때, 실차 실험에 적합하다. 하지만, 선정된 1차원 합성곱 신경망 기반 선형 회귀 모델과 비슷한 성능을 가지면서도 예측에 필요한 데이터 수가 더 많으며(1차원 합성곱 신경망 100개, 2차원 합성곱 신경망 196개), 인공신경망의 크기가 상대적으로 커(학습 가능한 변수 개수 1차원 합성곱 신경망 373,217개, 2차원 합성곱 신경망 412,033개) 본 연구에서는 선택하지 않았다. 1차원 합성곱 신경망 기반 선형 회귀 모델의 경우 2차원 합성곱 신경망 기반 선형 회귀 모델과 동일하게 사용 가능한 범위가 600kg 이상으로 부하 측정 시스템의 선형 회귀 모델로 선정하였다.

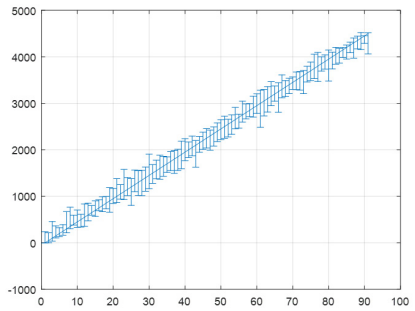

(a) MLP LR

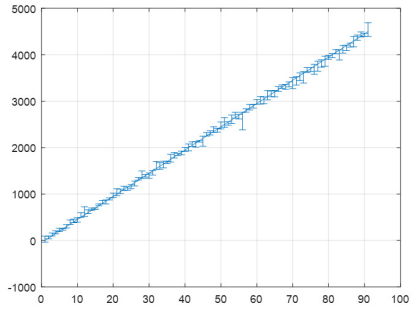

(b) 2D CNN LR

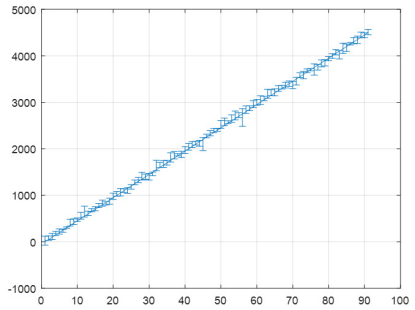

(c) 1D CNN LR

Fig. 7 Predicted result's error on test dataset (min. and max. error)

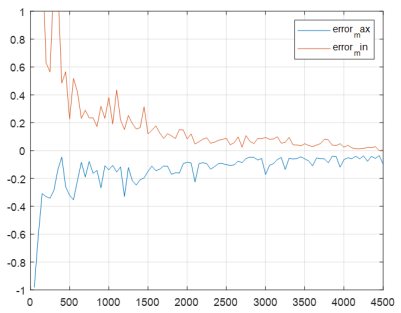

(a) MLP LR

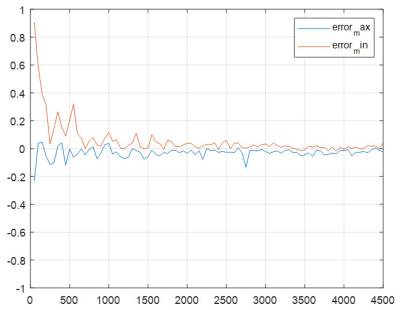

(b) 2D CNN LR

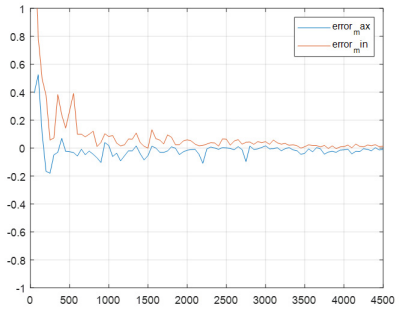

(c) 1D CNN LR

Fig. 8 Predicted result's error on test dataset (min. and max. error rate)

4. 결 론

굴삭기를 이용한 작업을 수행할 때, 부하 측정 시스템이 있을 경우 작업의 효율을 향상시킬 수 있으며, 다른 이송 장비와의 협업 시 정확한 굴삭량을 전달함으로써 명확한 이송 작업의 종료 시점을 알 수 있다. 하지만 상용 부하 측정 시스템의 경우 모델링 오차에서 오는 근본적인 오차와 이를 보상하기 위해 추가되는 특정 동작 때문에 전체 작업효율이 떨어지는 문제가 있다. 이를 보완하기 위해 다음과 같은 연구를 수행하였다.

1) 0kg에서 4500kg까지의 부하에 대하여 30톤 굴착기의 붐, 암 링크, 스윙 모터의 각변위와 붐 실린더의 압력을 측정하였다.

2) 실험을 통해 측정한 데이터를 다항 회귀 모델 및 다층 퍼셉트론, 합성곱 기반 선형 회귀 모델의 입력에 맞는 데이터 셋을 정형하였다.

3) 다항 회귀 모델의 학습 결과를 기준으로 다층 퍼셉트론, 합성곱 기반 선형 회귀 모델의 학습 결과를 평가하였으며, 이를 통해 부하 측정 시스템에 적용하기 위한 선형 회귀 모델을 선정하였다.

4) 선정된 모델의 타당성은 전체 실험 데이터를 대표하는 평가 데이터 셋을 통해 검증하였으며, 그 결과 600kg이상의 무게에 대하여 -2.1%이상 3.9%이하의 오차를 가지는 결과를 얻을 수 있었다.

후 기

이 연구는 국토교통부/국토교통과학기술진흥원이 시행하고 한국도로공사가 총괄하는 "스마트건설기술 개발 국가R&D사업(연구개발과제번호 21SMIP-A157130-2)"의 지원으로 수행하였습니다.

이해관계(CONFLICT OF INTEREST)

저자는 이 논문과 관련하여 이해관계 충돌의 여지가 없음을 명시합니다.

References

1) K. W. Park, Y. J. Park and G. B. Jang, "Deep Learning-based Excavation Weighing System with Mitigated Driver Bias", KSAE Spring Conference Proceedings, pp.1210-1215, 2023
2) M. S. Lee, Y. I. Shin, S. J. Choi, J. W. Kwon and K. Y. Choi, "Development of Load Weighing Algorithm for Excavator", KSAE Annual Conference Proceedings, pp.123-456, 2011.
3) M. K. Seo, H. Y. Shin, H. Y. Lee, J. I. Ko and E. Tumrnjargal, "Development of Onboard Scales to Measure the Weight of Trucks", J. of Drive and Control, Vol.18, No.1, pp.9-16, 2021.
4) D. Y. Shin, "A Study on Excavation Path Design of Excavator Considering Motion Limits", J. of Drive and Control, Vol.18, No.2, pp.20-31, 2021.
5) J. Cho, S. Na, M. Kim and M. Park, "Development of a Workload Index for Monitoring Durability Test

of an Excavator", J. of Drive and Control, Vol.19, No.4, pp.29-35, 2022.

6) Caterpillar, Cat Payload for Excavator, https://www.cat.com/en_US/by-industry/construction-industry-resources/technology/payload.html, 2023.
7) Trimble, Trimble LOADRITE Payload Management for Trimble Earthworks Grade Control Platform Datasheet-English, https://heavyindustry.trible.com/resources/datasheet-brochures-english/trimble-loadrite-payload-management-for-trimble-earthworks-grade-control-platform-english, 2023.
8) H. H. Jeong, M. S. Lee and Y. I. Shin, "A Study of a Hydraulic Excavator's Test to Verify of Payload Estimation by Bucket's Motion Equation", J. of Drive and Control, Vol.19, No.2, pp.11-16, 2022.
9) N. Bennett, A. Walawalkar and C. Schindler, "Payload Estimation in Excavators : Model- Based Evaluation and Comparison of Current Payload Estimation Systems" CVT 2014 3rd Commercial Vehicle Technology Symposium, Vol.3, pp.1-14, 2014.
10) A. Bewley, R. Shekhar, S. Leonard, B. Upcroft and P. Lever, "Real-time volume estimation of a dragline payload", 2011 IEEE International Conference on Robotics and Automation (ICRA), Vol.3, pp. 1571-1576, 2011.
11) A. Gawlik and P. Kucybala, "Dynamic Weighing System used in Excavator," J. of KONES Powertrain and Transport, Vol.24, No.4, pp.31-38, 2017.
12) Q. Liu and C. Huang, "A Fault Diagnosis Method Based on Transfer Convolutional Neural Networks," in IEEE Access, vol. 7, pp. 171423-171430, 2019.
13) D. Li, J. Zhang, Q. Zhang and X. Wei, "Classification of ECG signals based on 1D convolution neural network," 2017 IEEE 19th International Conference on e-Health Networking, Applications and Services (Healthcom), pp. 1-6, 2017.
14) E. Ostertagova, "Modelling using Polynomial Regression", Procedia Engineering, Vol. 48, pp. 500-506, 2012.
15) J. Hindman, R. Burton and G. Schoenau, "An Artificial Neural Network Approach to Payload Estimation in Four Wheel Drive Loaders," 2007 ASME International Mechanical Engineering Congress and Exposition, pp.1-5, 2007.