

벌크 트레일러의 순간 및 누적 분말 배출량 추정을 위한 신경망 모델 성능 비교

이창준¹ · 이정근^{2,+}

Performance Comparison of Neural Network Models for the Estimation of Instantaneous and Accumulated Powder Exhausts of a Bulk Trailer

Chang June Lee¹ and Jung Keun Lee^{2,+}

Abstract

Bulk trailers, used for the transportation of powdered materials, such as cement and fly ash, are crucial in the construction industry. The speedy exhaustion of powdered materials stored in the tank of bulk trailers is relevant to improving transportation efficiency and reducing transportation costs. The exhaust time can be reduced by developing an automatic control system to replace the manual exhaust operation. The instantaneous or accumulated exhausts of powdered materials must be measured for automatic control of the bulk trailer exhaust system. Accordingly, we previously proposed a recurrent neural network (RNN) model that estimated the instantaneous exhaust based on low-cost pressure sensor signals without an expensive flowmeter for powders. Although our previous study utilized only an RNN model, models such as multilayer perceptron (MLP) and convolutional neural network (CNN) are also widely utilized for time-series estimation. This study compares the performance of three neural network models (MLP, CNN, and RNN) in estimating instantaneous and accumulated exhausts. In terms of the instantaneous exhaust estimation, the difference in the performance of neural network models was insignificant (that is, 8.64, 8.62, and 8.56% for the MLP, CNN, and RNN, respectively, in terms of the normalized root mean squared error). However, in the case of the accumulated exhaust, the performance was excellent in the order of CNN (1.67%), MLP (2.03%), and RNN (2.20%).

Keywords: Bulk trailer, Instantaneous exhaust, Accumulated exhaust, Neural network, Exhaust system, Pressure signal

1. 서 론

벌크 트레일러 (bulk trailer)는 시멘트와 석탄재, 건축용 파우더 등 건축에 필요한 분말 형태의 자재를 저장 탱크 내에 적재하여 운송하는 차량이다[1,2]. 특히 콘크리트나 모르타르를 구성하는데 사용되는 주원료인 시멘트는 주요 건설자재로 사용되기 때문에, 이를 운송하기 위한 수단인 벌크 트레일러의 역할은 중요하다[3,4]. 또한 한국교통연구원의 2021년 화물운송시장 동향

연간보고서에 따르면, 일반화물차주의 차종별 차량구입형태에서 컨테이너, 벌크 시멘트 트레일러, 탱크로리, 카고형, 기타 트레일러 중 벌크 시멘트 트레일러 BCT의 신차 구매비율이 72.7%로 가장 높은 것으로 조사되었다[5].

최근 화물운송시장에서는 운임인상을 포함한 물류비 상승 문제가 대두되고 있는데[6], 이는 한번의 운행을 통해 공급할 수 있는 제품의 양이 한정된다는 점과 연관된다. 국내 도로법에 따르면 총중량이 40톤을 초과하는 차량은 운행이 제한되어 있는 반면, 제품의 공급량은 트레일러 운전자들의 운송수입에 직결되는 요소이기 때문이다. 이러한 문제를 해결하기 위한 방안으로 참고문헌[7,8]에서는 제품의 최대 적재량을 증가시킬 수 있도록 벌크 트레일러를 경량화 시키기 위한 연구를 진행한 바 있다. 그러나 탱크 내에 적재된 제품을 배출하는 작업 중 과도한 대기시간이 소요될 경우, 하루에 제품을 운송할 수 있는 횟수가 줄어들게 된다. 따라서 벌크 트레일러 탱크 내의 분말 제품을 짧은 시간 내에 배출하는 것 또한 중요하다.

벌크 트레일러의 저장 탱크 하부에는 배출관과 연결되는 다수 개의 호퍼(hopper)가 있으며, 배출관은 운송된 제품을 저장

¹한경국립대학교 융합시스템공학부(Department of Integrated Systems Engineering, Hankyong National University)

327 Jungang-ro, Anseong, Gyeonggi 456-749, Korea

²한경국립대학교 ICT로봇기계공학부(School of ICT, Robotics and Mechanical Engineering, Hankyong National University)

327 Jungang-ro, Anseong, Gyeonggi 456-749, Korea

⁺Corresponding author: jklee@hknu.ac.kr

(Received: Apr. 10, 2023, Revised: May. 3, 2023, Accepted: May. 4, 2023)

This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License(<https://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.

하기 위한 사일로(silo)로 연결된다. 따라서 호퍼 밸브가 열리면 저장 탱크 내에 적재된 분말 제품이 배출관으로 방출되며, 배출관에서 공기압축기(air compressor)로부터 압축 공기를 공급받아 분말 제품이 사일로로 이송된다. 이때 작업자가 각 호퍼의 밸브와 배출구의 압축 공기 공급량을 제어하기 위한 밸브를 수동으로 조작한다. 하지만, 배출 작업 절차는 명확하게 정해져 있지 않으므로, 배출 시간은 오직 작업자의 숙련도에 의존된다는 문제를 갖는다. 이러한 문제를 해결하기 위한 방안으로는 자동 제어 시스템을 통해 수동으로 이뤄지는 기존의 배출 작업 방식을 대체하는 것이다.

벌크 트레일러의 자동제어 시스템을 개발함에 있어, 분말의 순간배출량과 누적배출량은 유용한 정보로 사용 가능하다. 예로, 분말의 순간배출량을 되먹임하여 밸브를 제어하는 형태의 제어 알고리즘을 개발함으로써 순간배출량을 최대한으로 지속시킬 수 있는 자동제어 시스템을 적용할 수 있다. 분말의 순간배출량은 분말용 유량계를 통해 측정할 수 있지만, 현재 시중에서 구할 수 있는 장비들은 고가에 해당한다. 이러한 고가의 분말용 유량계를 자동제어 시스템에 적용할 경우 오히려 더 높은 비용의 발생을 초래할 것이다. 또한 분말용 유량계는 정밀 계측 장비이기 때문에, 장시간 및 장거리 운행을 하는 벌크 트레일러에 장착할 경우에 운송 중 파손되는 등의 문제가 발생할 수 있다.

이를 위한 해결책으로 저자의 최근 연구인 참고문헌 [9]에서는 분말용 유량계 없이 저가의 압력센서신호만을 사용하여 분말 순간배출량을 추정하는 신경망(neural network) 모델이 제안된 바 있다. 신경망은 사용자에 의한 수학적 모델링 없이 데이터를 기반으로 모델을 구축하는 기계학습(machine learning) 기법들 중 하나이다. 순간배출량 추정과 같은 비선형 회귀 문제에 있어서 많이 활용되는 신경망으로는 다층 퍼셉트론(multi-layer perceptron, MLP), 합성곱신경망(convolutional neural network, CNN), 그리고 순환신경망(recurrent neural network, RNN) 등이 있으며, 참고문헌 [9]에서는 이 중 RNN을 활용하였다. RNN은 현재와 이전 시간의 정보를 입력으로 받는 형태의 신경망으로, 시계열 데이터의 추정 문제에 효과적으로 활용된다[10,11]. 그럼에도 MLP와 CNN 또한 시계열 데이터를 포함한 회귀 문제에 활발하게 활용되고 있다[12-14]. 따라서 순간배출량 추정에 있어 최적의 성능을 나타낼 수 있는 모델을 구축하기 위해서는 신경망 모델별로 성능을 비교하는 과정이 필요하다.

이에 본 논문에서는 압력신호를 기반으로 분말 순간배출량을 추정하는 신경망에 있어서, 신경망 모델별로 추정 성능의 비교 분석을 수행한다. 이때 신경망 모델로는 시계열 데이터의 추정에 많이 활용되는 MLP, CNN, 그리고 RNN이 활용되었다. 이에 더하여 압력신호로부터 분말 누적배출량을 추정하는 신경망 모델을 함께 구현하고 동일한 방식으로 성능을 비교하고자 한다. 또한 각각의 신경망 모델마다 입력 파라미터의 선정이 추정 성능에 미치는 영향을 함께 고찰하고자 한다.




Fig. 1. Exhaust system of a bulk trailer.

2. 방 법

2.1 분말 순간배출량 추정용 신경망 모델

Fig. 1은 참고문헌 [9]에서 사용된 벌크 트레일러 배출 시스템의 개략도에 해당한다. 벌크 트레일러의 분말 배출 작업은 저장 탱크 내에 적재된 분말 제품을 탱크 하부에 위치한 다수의 호퍼를 통해 배출관으로 방출시킨 후에, 배출관에서 사일로로 이송하는 방식으로 이뤄진다. 이때 배출관 내부의 압력은 분말의 배출 상태 정보를 나타내며, 서스펜션 압력은 탱크 내 제품의 적재량 또는 잔량 정보를 나타낸다. 이러한 압력신호는 배출 시스템의 자동제어 기술 개발에 있어 유용하게 사용할 수 있으므로, 배출관과 2개의 후륜 차축 서스펜션에 압력센서를 장착하여 각 부분의 압력신호를 측정한다.

본 논문에서는 순간배출량을 추정하기 위한 기법으로 시계열 데이터의 추정에 많이 활용되는 MLP, CNN, 그리고 RNN을 활용하여 모델을 구현하고 성능 비교하는 것을 목표로 한다. 참고문헌 [9]에서 제안한 신경망 모델은 벌크 트레일러의 압력신호를 입력으로 받아 순간배출량을 출력하는 구조이다. 이때 신경망 모델의 입력 파라미터로 배출관의 압력신호와 2개의 후륜 차축 서스펜션 압력신호의 미분치가 사용되었다. 배출관 압력의 경우, 배출작업 중 순간배출량과 유사한 양상을 나타냈으며, 서스펜션 압력의 경우에는 배출작업이 진행됨에 따라서 점점 감소되는 모습을 보였다. 두 가지 신호 모두 순간배출량과 연관되는 것으로 가정하였으나, 각 입력 파라미터별 성능 비교가 이뤄진 적은 없다. 따라서, 추가적으로 배출관 압력만 사용하는 경우(Input1)와 서스펜션 압력의 미분치만 사용하는 경우(Input2), 그리고 두 가지 신호 모두 사용하는 경우(Input3)로 나누어 성능을 비교한다.

MLP는 비선형 회귀 문제에 사용되는 가장 기초적인 형태의 신경망으로, 입력층과 2개 이상의 은닉층, 그리고 출력층으로 구성된다. 여기서 입력층과 출력층의 노드 수는 각각 입력과 출력 값의 차원 수이며, 은닉층은 이전 층의 모든 노드와 완전 연결되어 있는 밀집층(dense layer)에 해당한다. 또한 모델의 비선형

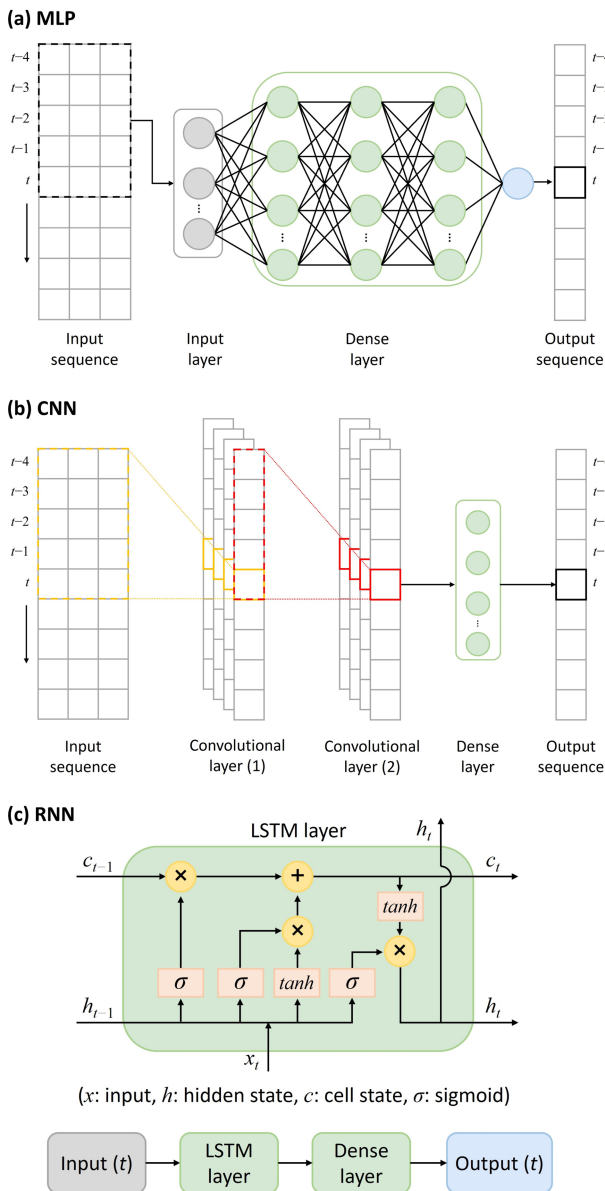


Fig. 2. Structures of (a) multi-layer perceptron, (b) convolutional neural network, (c) recurrent neural network models

성을 추가하기 위하여 각 은닉층 사이에는 활성화 함수가 적용된다. 참고문헌 [9]의 RNN 모델에서는 현재 시간의 압력신호를 입력으로 사용하였으나, MLP는 RNN과 다르게 시간에 따른 데이터의 변화를 고려하지 못하므로 현재 시간의 압력신호만을 사용하면 부정확한 추정이 이뤄질 수 있다. 따라서 현재 시간의 압력신호만을 사용하는 대신, 이전 시간의 데이터를 함께 사용하고자 한다. 본 연구에서는 현재와 이전 시간 4개의 압력신호를 입력 파라미터로 사용하였다. 은닉층은 각각 20개의 노드를 갖는 3개의 밀집층으로 구성하였으며, 활성화 함수로는 ReLU(rectified linear unit)를 적용하였다. Fig. 2(a)는 MLP 모델의 구조를 보여준다.

CNN은 주로 이미지나 영상 데이터 상의 특징 또는 패턴을

추출하는데 유용하게 사용되는 신경망으로, 입력된 데이터에 커널(kernel)을 이동시키면서 합성곱 연산을 하는 합성곱 층으로 구성된다. 시계열 데이터의 경우, 1차원 합성곱 층을 사용하여 시간의 방향으로 커널을 이동시킴으로써 시간의 흐름에 따른 데이터의 특징을 추출 가능하다. 이때 커널 너비는 입력 파라미터의 차원수에, 높이는 커널을 적용하고자 하는 데이터의 시간 크기에 해당한다(Fig. 2(b) 참조). 본 논문에서 구현하는 CNN 모델은 입력층과 크기가 5인 커널 20개를 갖는 2개의 1차원 합성곱 층, 20개의 노드를 갖는 밀집층, 그리고 출력층으로 구성된다. 여기서 첫번째와 두번째 합성곱 층 사이의 활성화 함수로 ReLU를 적용하였다. Fig. 2(b)는 CNN 모델의 구조를 보여준다.

RNN은 이전 시간과 현재 시간의 정보를 입력으로 받는 신경망으로, 시간 흐름에 따라 변화하는 시계열 데이터에 효과적이다. 다만 기본적인 RNN은 장기 의존성 문제를 가지며, 이를 보완하기 위하여 기존의 RNN 셀을 변형시킨 장단기 메모리(long short-term memory, LSTM)가 많이 사용된다. LSTM은 현재 시간의 입력과 이전 시간의 은닉/셀 상태를 입력으로 받아 셀 내부의 연산을 거쳐서 구해진 은닉/셀 상태를 출력하는 구조이며, 여기서 은닉 상태가 다음 층의 입력값으로 사용된다. 본 연구에서 구현하는 RNN 모델은 입력층, 20차원의 은닉/셀 상태를 갖는 1개의 LSTM 층, 20개의 노드를 갖는 밀집층, 그리고 출력층으로 구성된다. Fig. 2(c)는 LSTM층의 구조와 RNN 모델의 구조를 보여준다.

2.2 분말 누적배출량 추정용 신경망 모델

분말 누적배출량은 벌크 트레일러의 저장 탱크로부터 배출된 제품의 양으로, 순간배출량을 시간에 대해 적분함으로써 계산된다. 참고문헌 [9]에서는 배출관의 압력이 순간배출량과 높은 상관관계를 갖는다는 가정하에 순간배출량을 추정하는 입력 신호로 사용하였다. 이를 토대로 하였을 때, 배출관 압력의 적분치가 누적배출량과 연관될 것으로 예측 가능하다. 또한 서스펜션 압력은 저장 탱크 내 분말 제품의 잔량 정보를 간접적으로 포함하며, 배출 시작 전의 서스펜션 압력은 적재된 제품의 총중량 정보를 나타낸다. 누적배출량은 분말의 총중량에서 잔량을 차감한 것에 해당하므로, 배출 시작 전의 초기 압력신호와 배출 작업 중의 압력신호를 함께 사용할 경우, 누적배출량 정보를 추정 가능할 것으로 예측된다. 이에 따라서 누적배출량의 추정에 있어 다음의 세 가지 경우로 나누어 비교하고자 한다: 배출관 압력의 적분치를 사용하는 경우(Input1), 배출 시작 전과 배출 작업 중의 서스펜션 압력신호를 사용하는 경우(Input2), 두 가지 신호 모두 사용하는 경우(Input3). 신경망 모델은 순간배출량 추정과 동일하게 MLP, CNN, 그리고 RNN을 활용하여 구현한다.

2.3 데이터 수집 및 모델 학습

순간배출량 추정을 위한 신경망 모델의 성능 비교를 위하여

참고문헌 [9]의 배출 작업 데이터를 이용하였다. 벌크 트레일러의 배출 시스템에는 압력 센서 (EDN.302, Daho Tronic Ltd., Korea)와 분말용 유량계 (DYNAmas, DYNA Instruments GmbH, Germany)가 Fig. 1과 같이 장착되었으며, 모든 센서신호는 20Hz의 샘플링률로 수집되었다. 분말 배출 작업은 벌크 트레일러 작업자가 수동으로 진행하였고, 총 9번의 배출 작업이 진행되었다. 수집된 데이터의 샘플 수는 총 400,849개이다.

본 연구에서 신경망 모델은 딥러닝 오픈소스 프레임워크 중 하나인 PyTorch 기반의 Fastai를 이용하여 구현되었다. 순간배출량 추정의 경우, 각 신경망마다 입력 파라미터별(Input1~3)로 3가지 모델이 구현되었다. 순간배출량 추정용 신경망 모델의 입력층에서는 입력 파라미터를 평균이 0, 표준편차가 1이 되도록 표준화를 시킨 후에 입력되도록 하였다. 또한 학습 데이터에서 출력값의 범위가 0에서 1사이가 되도록 최대-최소 정규화를 시킨 후에 모델을 학습하였으며, 학습 이후에 모델이 원래의 범위로 출력되도록 설정하였다. 신경망의 손실함수로 평균제곱오차(mean squared error)를 사용되었으며, 최적화 기법으로는 Lookahead에 Radam (Rectified Adaptive Moment Estimation)이 결합된 Ranger가 적용되었다. 모델의 학습률은 0.001로, 에포크 수는 150번으로 설정하였다.

신경망 모델의 검증 방법으로, 각 데이터를 검증 데이터로 사용하는 경우 해당 데이터를 제외한 나머지 데이터 모두를 모델의 학습 데이터로 사용하는 leave-one-out 교차 검증을 수행하였다. 예로, 첫번째 데이터를 모델의 검증에 사용하는 경우, 나머지 8개 데이터를 이용하여 모델을 학습하는 방식이다. 따라서 검증 데이터별로 9개의 모델을 구현하는데, 이때 학습 과정의 임의성을 고려하기 위하여 각 조건마다 동일한 과정으로 3번씩 학습을 진행하였다. 따라서 순간배출량과 누적배출량 각각에 대해서 총 243개(신경망 3가지×입력 3가지×데이터 9개×시행 3번)의 모델이 생성되었다. 신경망의 추정 성능은 순간 및 누적배출량의 평균제곱근오차(root mean squared error, RMSE)와 최대-최소값으로 정규화 된 RMSE(NRMSE)를 이용하여 평가되었다.

3. 결 과

Table 1은 분말 순간배출량 추정 RMSE와 NRMSE, 그리고 표준편차 결과를 보여준다. 여기서 각 모델의 결과는 9개 데이터 평균 결과에 해당한다. 입력 파라미터별로 비교하였을 때, 세 가지 모델에서 모두 배출관 압력신호(Input1)가 서스펜션 압력신호(Input2)에 비해 우수한 정확도를 나타냈다. 예로, MLP의 경우에 Input 2의 RMSE는 258.05kg/min인 반면에 Input 1은 115.84kg/min으로, Input2 대비 200kg/min 이상의 성능 우세를 보였다. 두 가지 신호를 모두 사용하는 Input3의 경우, 작은 수준이지만 Input1에 비해 향상된 정확도를 나타냈다. Input3을 기준으로 세 가지 모델을 비교하였을 때, RNN이 가장 우수한 성

Table 1. RMSE and NRMSE (with standard deviations) results of instantaneous exhausts.

		RMSE [kg/min]	NRMSE [%]
MLP	Input1	115.84 (52.26)	8.72 (3.56)
	Input2	258.05 (28.10)	19.62 (2.15)
	Input3	114.47 (53.72)	8.64 (3.75)
CNN	Input1	117.03 (54.05)	8.82 (3.73)
	Input2	254.83 (24.32)	19.38 (2.01)
	Input3	114.13 (53.28)	8.62 (3.73)
RNN	Input1	116.05 (46.52)	8.75 (3.17)
	Input2	245.93 (29.77)	18.69 (2.3)
	Input3	113.38 (48.44)	8.56 (3.37)

Table 2. RMSE and NRMSE (with standard deviation) results of accumulated exhausts.

		RMSE [ton]	NRMSE [%]
MLP	Input1	0.70 (0.52)	2.85 (2.36)
	Input2	0.79 (0.67)	3.27 (3.26)
	Input3	0.51 (0.26)	2.03 (1.00)
CNN	Input1	0.62 (0.52)	2.54 (2.36)
	Input2	0.73 (0.87)	3.12 (4.26)
	Input3	0.42 (0.24)	1.67 (0.94)
RNN	Input1	0.78 (0.56)	3.15 (2.48)
	Input2	0.78 (0.69)	3.27 (3.41)
	Input3	0.56 (0.24)	2.20 (0.93)

Table 3. RMSE and NRMSE (with standard deviation) results of instantaneous exhausts determined from accumulated exhaust estimation results.

		RMSE [kg/min]	NRMSE [%]
MLP		812.42 (139.07)	61.79 (11.7)
CNN		834.76 (154.94)	62.99 (9.20)
RNN		898.57 (147.03)	67.98 (9.66)

능을 보였으나, 모델간 성능의 차이가 근소한 수준으로 나타났다.

Table 2는 누적배출량의 RMSE와 NRMSE 결과를 보여준다. 입력 파라미터에 대해서 비교하였을 때, 배출관 압력신호(Input1)가 서스펜션 압력신호(Input2)에 비해 우수한 성능을 보였으며, 세 가지 입력 파라미터 중에서는 두 가지 신호를 사용하는 Input3의 성능이 가장 우수하였다. Input3을 기준으로 모델간 성능을 비교하였을 때, CNN(1.67%), MLP(2.03%), RNN(2.20%) 순으로 우수한 성능을 나타냈다.

Table 3과 4는 각각 누적배출량 추정 결과로부터 산출된 순간배출량의 성능과 순간배출량 추정 결과로부터 산출된 누적배출량의 성능을 보여준다. 여기서는 Input3에 대한 순간/누적배출량 모델의 결과만 나타난다. 우선, 누적배출량으로부터 결정된 순간배출량의 경우, 세 가지 신경망 모델의 NRMSE가 모두 60%

Table 4. RMSE and NRMSE (with standard deviation) results of accumulated exhausts determined from instantaneous exhaust estimation results.

	RMSE [ton]	NRMSE [%]
MLP	0.71 (0.59)	2.91 (2.76)
CNN	0.80 (0.74)	3.26 (3.21)
RNN	0.75 (0.68)	3.06 (2.99)

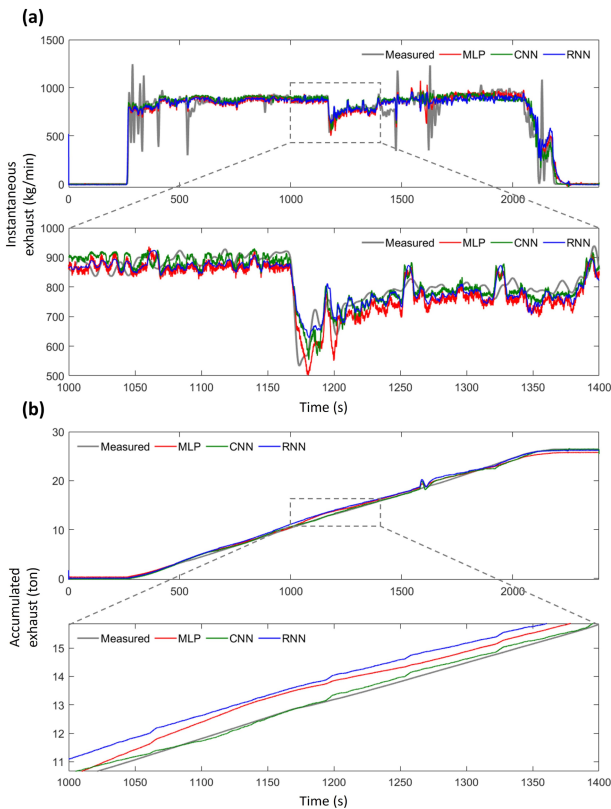


Fig. 3. Estimation results of (a) instantaneous exhausts and (b) accumulated exhausts.

이상으로 사용하기 어려운 수준의 성능이 확인되었다. 반면에 순간배출량으로부터 결정된 누적배출량의 NRMSE는 2.9~3.3%로, 일부 누적배출량 모델과 유사한 성능을 나타냈다. 이 중 RNN이 가장 우수하였지만, 모델간 성능 차이가 크지 않은 것으로 확인되었다.

Fig. 3은 배출작업 데이터 하나에 대한 순간배출량과 누적배출량의 추정 결과를 보여준다. 이때 두 가지 모델 모두 Input3의 결과에 해당한다. Fig. 3(a)에서는 세 가지 모델의 결과 모두 유량계 신호에 근접하게 추종하는 모습을 보였다. 유량계 신호가 급격히 변동되는 부분은 반영하지 못하였지만, 1000~1400초 사이에서 갑자기 저하되는 부분 또한 따르는 모습을 볼 수 있다. 여기서 MLP의 결과는 다른 두 모델에 비해 비교적 잡음 성분이 크게 나타났다. Fig. 3(b)에서도 세 가지 모델 모두 유량계 신호로부터 산출된 누적배출량 신호를 잘 추종하는 모습을 보

였다. 1000~1400초 구간의 결과에서는 CNN의 추정 결과가 MLP와 RNN에 비해 측정값에 근접한 모습을 나타냈다.

4. 고찰 및 결론

본 연구에서는 압력신호로부터 분말 순간배출량 및 누적배출량을 추정하는 신경망 모델을 구현하고, 모델에 따른 성능 비교를 수행하였다. 또한 각 모델마다 입력 파라미터별로 추정 성능을 함께 비교하였다.

순간배출량 추정에 있어서는 모델에 따른 성능의 차이가 작은 수준으로 나타났다. 예로, Input1에 대한 세 가지 모델의 NRMSE 범위가 8.62~8.72%, Input3에 대해서는 8.56~8.64%로, 모델간 성능 차이가 최대 0.1%로 나타났다. 즉, 순간배출량을 추정함에 있어서 신경망 모델의 선정이 매우 큰 효과를 갖지는 못하는 것으로 판단된다. 이러한 경우, 세 가지 모델 중 가장 적은 수의 가중치를 갖는 MLP 모델을 사용하는 것이 연산량의 측면에서 효율적일 것으로 볼 수 있다.

입력 파라미터의 경우에는, 배출관 압력신호가 서스펜션 압력신호에 비해 현저히 우수한 정확도를 나타냈다. 이 결과는 순간배출량을 추정함에 있어 배출관의 압력이 큰 효과를 갖는다는 것을 보여준다. 참고문헌 [9]에서 확인되었듯, 배출관 압력이 순간배출량과 높은 상관관계를 갖는 것으로 볼 수 있다. 반면에 서스펜션 압력신호는 큰 효과를 보이지 못하였다. 서스펜션 압력은 배출관 압력과 다르게 급격하게 변하지 않고 탱크 내의 분말이 배출됨에 따라서 서서히 감소된다. 이와 동시에 센서신호 내의 잡음 성분이 압력의 변화량 대비 큰 수준으로 나타나기 때문에, 분말 배출에 따른 순수한 압력의 변화량의 정보를 추출하기는 어렵다.

누적배출량 추정의 경우, CNN 모델이 가장 우수한 성능을 나타냈으며, 그 다음으로는 MLP가 우세하였다. 두 모델은 현재의 입력 신호와 이전의 상태 정보를 사용하는 RNN과 다르게, 커널(또는 윈도우) 크기만큼의 현재와 이전 시간의 입력값들을 사용하는 구조라는 점에서 과거 정보들을 직접적으로 사용한다고 볼 수 있다. 특히 CNN은 2개의 합성곱 층으로 구성되어 MLP에 비해 더 많은 과거 정보를 사용한다. CNN의 성능 우세는 이러한 CNN의 특성에 기인한 것으로 추측된다.

입력 파라미터별로 비교한 경우, 배출관 압력신호를 사용한 경우가 서스펜션 압력신호에 비해 우세한 성능을 나타냈다. 이는 누적배출량 추정함에 있어서, 서서히 변동되는 서스펜션 압력에 비해 배출관 압력의 적분치가 비교적 더 효과적이라는 것을 보여준다. 그럼에도 서스펜션 압력신호 또한 누적배출량 추정에 효과를 나타내고 있으며, 두 가지 신호 모두 사용하는 경우가 가장 우수한 정확도를 보였다.

본 연구의 결과는 벌크 트레일러 배출을 상사하는 축소모델 기반 데이터가 아닌 실제 벌크 트레일러의 실제 배출작업과정

중에 수집된 데이터를 기반으로 분석이 이루어졌다는 점에서 결과의 현실성에 의미를 부여할 수 있을 것이다. 하지만 9개의 배출 작업 데이터에 대해서만 성능 평가가 이뤄졌기 때문에, 각 모델의 성능을 일반화하기는 어렵다. 그럼에도 시계열 추정 문제에 많이 활용되는 3가지의 신경망 모델과 입력 파라미터별로 순간/누적 배출량의 추정 성능을 비교하고 분석하였다는 점에서 중요성이 있다.

본 연구의 결과는 벌크 트레일러의 자동 배출을 위한 자동제어 시스템을 개발함에 있어 기초 자료로 활용될 수 있을 것으로 기대된다.

감사의 글

본 연구는 2022년도 과학기술정보통신부 ICT R&D혁신바우처지원사업 (No.2022-0-00408)의 지원을 받아 수행되었다. 벌크 트레일러 배출 시스템 구축 관련하여 아이씨피(주)와 벽우(주)에게 감사드린다.

REFERENCES

- [1] J. S. Hahn, H. M. Sung, M. C. Park, S. Y. Kho, and D. K. Kim, "Empirical evaluation on the efficiency of the trucking industry in Korea", *KSCE J. Civ. Eng.*, Vol. 19, No. 4, pp. 1088-1096, 2015.
- [2] S. Lee, Y. J. Kim, K. T. Kim, Y. J. Kwon, and S. M. Kim, "Analysis of bulk freight transportation", *Proc. of KSR Conf.*, pp. 3278-3288, 2011.
- [3] V. Augiseau and S. Barles, "Studying construction materials flows and stock: A review", *Resour. Conserv. Recycl.*, Vol. 123, pp. 153-164, 2017.
- [4] C. R. Gagg, "Cement and concrete as an engineering material: An historic appraisal and case study analysis", *Eng. Fail. Anal.*, Vol. 40, pp. 114-140, 2014.
- [5] The Korea Transport Institute, "2021 annual report of freight transport market trend", 2021.
- [6] J. S. Lim, "A study on the mechanism and influencing factors for truck safety rates", *Korea Logist. Rev.*, Vol. 28, No. 2, pp. 9-20, 2018.
- [7] J. G. Kim and J. G. Lee, "Static and dynamic finite element analyses of a bulk-cement trailer", *Trans. Korean Soc. Mech. Eng. A*, Vol. 36, No. 8, pp. 945-951, 2012.
- [8] J. Kim, H. S. Roh, Y. Min, S. H. Hur, S. Shin, and I. G. Jang, "Lightweight design of a bulk trailer using topology optimization", *Trans. Korean Soc. Automot. Eng.*, Vol. 25, No. 5, pp. 548-554, 2017.
- [9] C. J. Lee and J. K. Lee, "Pressure signal-based instantaneous exhaust estimation of a bulk trailer by using a recurrent neural network", *J. Inst. Control. Robot. Syst.*, Vol. 29, No. 4, pp. 360-365, 2023.
- [10] J. S. Choi and J. K. Lee, "Recurrent neural network for nine-axis IMU-based orientation estimation: 3D orientation estimation performance in disturbed conditions", *J. Inst. Control. Robot. Syst.*, Vol. 28, No. 12, pp. 1216-1223, 2022.
- [11] D. Weber, C. Gühmann, and T. Seel, "RIANN-a robust neural network outperforms attitude estimation filters", *AI*, Vol. 2, No. 3, pp. 444-463, 2021.
- [12] R. Velo, P. López, and F. Maseda, "Wind speed estimation using multilayer perceptron", *Energy Convers. Manag.*, Vol. 81, pp. 1-9, 2014.
- [13] E. Dorschky, M. Nitschke, C. F. Martindale, A. J. Van den Bogert, A. D. Koelewijn, and B. M. Eskofier, "CNN-based estimation of sagittal plane walking and running biomechanics from measured and simulated inertial sensor data", *Front. Bioeng. Biotechnol.*, Vol. 8, 604(1)-604(14), 2020.
- [14] M. Mundt, W. R. Johnson, W. Potthast, B. Markert, A. Mian, and J. Alderson, "A comparison of three neural network approaches for estimating joint angles and moments from inertial measurement units", *Sens.*, Vol. 21, No. 13, pp. 1-14, 2021.