

컨테이너 터미널 내 반출입 차량 체류시간 예측 모형

김영일* · † 신재영

*국립한국해양대학교 KMI-KMOU 학연협동과정, † 국립한국해양대학교 물류시스템학과 교수

Prediction Model for External Truck Turnaround Time in Container Terminal

Yeong-Il Kim* · † Jae-Young Shin

*KMI-KMOU Cooperation Course, National Korea Maritime and Ocean University, Busan 606-791, Korea

† Professor, Department of Logistics Engineering, National Korea Maritime and Ocean University, Busan 606-791, Korea

요약 : 코로나 팬데믹 이후 컨테이너 터미널 내 혼잡도 증가에 따라 반출입 차량 작업 대기 및 체류시간이 급증하여 반출입 작업 비효율이 극심한 실정이다. 이에 항만 당국은 반출입예약시스템(Vehicle Booking System; VBS)을 구축하여 시범운영 중에 있으나 이해관계자 간 정보 공유 문제 및 컨테이너 운송 주체의 미온적 참여 등으로 인해 개선효과가 뚜렷하지 않다. 따라서 본 연구에서는 반출입 차량의 작업 대기 및 체류시간 문제의 해결을 위한 기초자료로써, 딥러닝 기반의 반출입 차량 체류시간 예측 모형을 제시하였다. 실제 컨테이너 터미널의 반출입 운영 데이터를 통해 제시한 예측 모형을 실험하고 실제 데이터와 비교하여 예측 정확도를 검증한 결과 제시한 예측 모형이 높은 예측 정확도를 보이는 것을 확인하였다.

핵심용어 : 컨테이너 터미널, 반출입 차량, 체류시간, 예측 모형, 딥러닝, 부산신항

Abstract : Following the COVID-19 pandemic, congestion within container terminals has led to a significant increase in waiting time and turnaround time for external trucks, resulting in a severe inefficiency in gate-in and gate-out operations. In response, port authorities have implemented a Vehicle Booking System (VBS) for external trucks. It is currently in a pilot operation. However, due to issues such as information sharing among stakeholders and lukewarm participation from container transport entities, its improvement effects are not pronounced. Therefore, this study proposed a deep learning-based predictive model for external trucks turnaround time as a foundational dataset for addressing problems of waiting time for external trucks' turnaround time. We experimented with the presented predictive model using actual operational data from a container terminal, verifying its predictive accuracy by comparing it with real data. Results confirmed that the proposed predictive model exhibited a high level of accuracy in its predictions.

Key words : container terminal, external truck, Turnaround Time(TAT), prediction model, deep learning, Busan new port

1. 서 론

세계적인 수출입 물동량의 급증에 따라 대부분의 수출입 화물을 처리하는 항만은 선박 대기시간 증가 및 정시성 하락, 제한된 장치장 공간에 많은 컨테이너를 적재하여 발생하는 장치장 포화 현상 등 운영상의 어려움을 겪고 있다. 특히, 코로나 팬데믹 기간 중 물동량 증가 폭이 큰 부산신항의 경우 일부 부두 내 야드 장치율이 90% 수준까지 상승하는 등 극심한 항만 혼잡을 보였다. 이러한 혼잡으로 부산항은 상·하역서비스 품질 및 생산성 저하가 우려되는 상황에 직면하였다. Kim(2022)은 부산신항 컨테이너 터미널의 향후 야드 장치율이 70% 이상의 수준을 유지할 것으로 예측하였으며, 이는 터미널 운영상의 비효율의 원인이 될 것이라고 지적하고 있다.

항만의 생산성 저하가 우려되는 상황에서 양적하 작업을 수행하는 본선 작업 생산성은 지속적인 연구와 운영 방식 개

선을 통해 적정 수준까지 향상되었다. 그러나 반출입 작업은 본선 양적하 작업에 우선순위가 밀려 작업 대기가 빈번히 발생하고 있다. 본선 작업 마감시간과 야드 공컨테이너 반입 마감 시간대에 반출입 차량 진출입이 집중되는 등 부산신항의 운영 문제점에서 발생한 특정 시간대의 처리 물량 집중, 높은 야드 장치율에 따른 다수의 컨테이너 리핸들링 작업 소요 등은 반출입 차량의 대기 및 체류시간을 큰 폭으로 증가시켰다(KMI, 2023). 심각한 혼잡 상황에서는 반출입 차량 체류시간이 1시간 이상 소요되는 등 터미널 혼잡에 따른 반출입 작업 생산성 저하가 뚜렷하게 나타나고 있다.

장시간의 반출입 차량 체류시간은 터미널 내 혼잡을 더욱 증폭시키며 야드 내 작업계획 및 장비운용 등 운영 프로세스에 혼란을 초래하고 이는 전반적인 항만 효율성의 저하로 이어지기 때문에 이를 최소화하는 방안이 필요하다. 부산항만공사와 각 터미널 운영사는 반출입 작업의 대기 문제를 해결하

† Corresponding author : 중신회원, shinjy@kmou.ac.kr 051)410-4335

* 정회원, yik9264@g.kmou.ac.kr 051)410-4931

고자 반출입예약시스템(Vehicle Booking System; VBS)을 구축하였다. 그러나 이해관계자 간의 정보공유 및 운영 여건상의 문제, 트럭 운송사 및 운송기사의 미온적 참여 등으로 개선 효과가 뚜렷하게 나타나지 않고 있다.

반출입 작업의 운영적 개선을 위해서는 터미널 운영사와 트럭 운송사가 상호 협력하여 효율적이고 탄력적인 반출입 작업을 계획하고 운영할 필요가 있다. 이를 위한 선행조건으로 터미널 도착 차량의 터미널 내 체류시간의 추정은 필수불가결한 요인이다.

본 연구에서는 부산신항의 반출입 차량 체류시간 예측을 위해 딥러닝 기반의 반출입 차량 체류시간 예측 모형을 제시하였다. 그리고 실제 부산신항 컨테이너 터미널의 반출입 운영 데이터를 통해 검증하였다.

본 연구는 2장에서 반출입 작업에 관한 선행연구를 고찰하고 기존 연구들과의 차별성을 제시하였다. 3장에서는 실증 분석 대상 터미널의 반출입 운영 프로세스 및 문제점을 소개하였다. 4장에서는 딥러닝 기반 반출입 차량 체류시간 예측 모형을 제시하고 예측 결과를 바탕으로 예측 모형의 객관적 성능에 대해 논하였다. 마지막으로 5장에서는 본 연구를 요약 및 정리하고 연구의 시사점과 한계점을 제시하였다.

2. 선행연구 고찰

반출입 작업의 생산성 향상을 위해 터미널 내 반출입 차량의 진출입 및 작업 흐름 등을 실제 터미널 운영 데이터를 활용하여 분석하고자 하는 연구가 다수 수행되었다. 이들 연구의 대부분은 반출입 차량의 대기나 통행량, 체류시간 등의 예측에 관해 다루고 있다.

반출입 차량의 통행량 또는 체류시간을 예측하는 연구는 초기 Al-Deek et al.(2000), Al-Deek(2001), Al-Deek(2002) 및 Xie and Huynh(2010)의 연구와 같이 반출입 시간대, 반출입 요일 및 이전 수행 작업 등 반출입 작업에 영향을 미치는 여러 변수를 선정하고 선형 회귀분석(Linear Regression), 서포트 벡터 머신(Support Vector Machine; SVM), 인공신경망(Artificial Neural Network; ANN) 및 MLFNN(Multilayer Feed Forward Neural Network) 등을 활용하여 항만에 도착하는 반출입 차량의 통행량을 예측하는 등 기계학습의 관점에서 접근한 바 있다.

이후 Kim et al.(2019), Kim et al.(2019), Kim et al.(2020) 및 Li et al.(2023)은 반출입 차량 통행량 예측을 위해 터미널 운영 데이터를 활용하여 랜덤 포레스트(Random Forest), Gaussian Naive Bayes 모형 등의 기계학습 모형과 LSTM(Long Short-Term Memory) 및 GRU-FCNN 모형 등의 딥러닝 모형을 활용하여 예측 모형을 구축하고 각 모형의 성능을 비교 분석하였다.

Cho et al.(2022)은 반출입 차량 정보, 시간, 적재 및 하역 정보 등 반출입 운영 데이터를 활용하여 LSTM 모형 기반의

반출입 차량 턴타임 예측 알고리즘을 구축하고 데이터를 시간, 일, 주 단위의 중·장기적 시점으로 구분하여 예측 모형을 검증하였다.

Kim et al.(2022)은 반출입 차량의 시간대별 평균 대기 및 체류시간을 예측하고자 부산신항 특정 컨테이너 터미널을 대상으로 시계열 기반 딥러닝 예측 모형인 순환 신경망(Recurrent Neural Network; RNN), LSTM 및 GRU(Gated Recurrent Unit) 모형을 구축하고 각 모형의 성능을 비교 분석한 바 있다.

반출입 작업에 관한 이전 연구들의 대다수는 차량의 통행량 예측에 초점이 맞추어져 있다. 이에 반해 반출입 차량의 대기 및 체류시간을 예측한 연구는 그 수가 적으며, 이 또한 중·장기적인 예측만 다루고 있다. 중·장기 시점의 평균 체류시간 예측 모형은 터미널 운영 및 자원 활용을 위해서 필요하다. 하지만 작업 개선을 위한 반출입 계획 수립을 위해서는 시간대별 평균 체류시간이 아니라 도착 차량별로 도착 시점의 터미널 작업 상황과 반출입 작업 내용을 고려한 보다 구체적인 체류시간 예측이 이루어져야 한다.

본 연구에서는 반출입 차량이 게이트에 도착한 시점의 정보에 따라 체류시간을 예측하는 단기 시점의 컨테이너 터미널 내 반출입 차량 체류시간 예측 모형을 제시한다.

3. 반출입 작업 운영 프로세스

3.1 반출입 작업 프로세스

반출입 작업은 컨테이너 검사(Inspection) 및 번호 확인, 반출입 요청, 사전정보 대조, 인수도증(Equipment Interchange Receipt; EIR) 발행 등의 업무를 수행하는 게이트 업무와 반출입 차량이 컨테이너 장치 위치까지 이동하여 야드 블록 내에서 발생하는 컨테이너 상·하차 업무로 구분된다.

게이트 업무는 트럭 운송사가 반출입 전 사전반출입 예정 정보(COPINO)를 EDI를 통해 터미널 운영 시스템(Terminal Operation System; TOS)에 전송하고 OCR 및 RFID 등 반출입 차량 인식장비를 통해 사전정보와 대조한 후, 컨테이너 장치 위치를 할당받게 된다.

반출입 차량은 인수도증에 기재된 야드 내 장치위치로 이동하며 만약 해당 야드 블록에 작업 대기가 있을 경우, 차량은 대기하게 된다. 같은 시점에서 TOS는 반출입 정보를 저장 후 야드 내 트랜스퍼크레인(Transfer Crane; T/C)에 작업을 할당한다. 이후 해당 T/C는 컨테이너를 상·하차하고 작업이 종료된 반출입 차량은 야드에서 게이트로 이동해 반출입 작업이 종료된다.

반입 작업과 반출 작업은 일부 통관 및 정산 등의 프로세스에서 차이가 있으나 대부분의 프로세스가 유사하다. 다만 반출 작업의 경우 야드 내 컨테이너 리핸들링 소요가 많다. 반입작업의 경우 야드 장치계획에 따라 미리 정해진 위치에 반

입하는 것에 반해 반출 작업은 선박 양하 작업 시 장치 가능한 위치에 우선 장치된 컨테이너를 나중에 반출하게 된다. 이는 반출 컨테이너 위에 다른 컨테이너가 적재되어 있을 가능성이 높아지며 결국 다수의 리핸들링 작업이 수반된다.

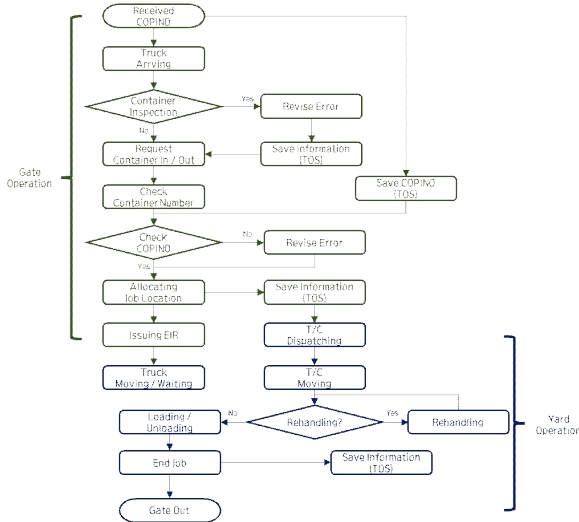


Fig. 1 External truck work flow(Lee, 2011)

3.2 반출입 차량 체류시간

반출입 차량 체류시간을 예측하기 이전에 본 연구의 예측 대상이 될 반출입 차량 체류시간 적용 개념에 대해 검토할 필요가 있다.

일반적인 체류시간의 개념을 적용해 볼 때, 컨테이너 터미널에서 반출입 차량의 체류시간은 차량이 게이트를 통과한 시점에서부터 야드 블록에서 컨테이너 상·하차 작업 완료 후 게이트를 통과해 터미널 외부로 빠져나간 시점까지라고 할 수 있다. 그러나 컨테이너 터미널 실무 담당자에 따르면 반출입 차량이 야드 블록에서 상·하차 작업 완료 이후 게이트를 통과해 나간 시점까지는 터미널 내 혼잡 및 반출입 작업의 정체에 큰 영향을 미치지 않는다고 한다. 반출입 차량이 터미널 내에서 소요하는 시간 중 터미널 혼잡과 반출입 작업에 직접적으로 영향을 미치는 시간은 차량이 게이트를 통과하여 할당된 장치위치로 이동 및 대기 후 컨테이너 상·하차 작업 완료까지라고 할 수 있다.

컨테이너 터미널의 서비스 품질 지표로써 사용되는 반출입 차량 체류시간은 실제로 국내 터미널의 경우 차량의 게이트 진입 시점부터 컨테이너 상·하차 종료 시점까지를 반출입 차량의 체류시간으로 관리하고 있다.

따라서, 본 연구에서 반출입 차량 체류시간은 반출입 차량의 게이트 진입 시점부터 야드 내 컨테이너 상·하차 작업 종료 시점으로 정의한다.

4. 반출입 차량 체류시간 예측 모형

이전 연구인 Kim et al.(2022)에서는 중·장기적 반출입 차량 체류시간 예측을 위해 시간대 별 반출입 차량의 평균 체류시간을 예측하는 시계열 기반 딥러닝 모형을 수립하고 실험하였다. 시간대 별 평균 체류시간은 해당 시간대의 평균 반출입 수요를 반영하지만, 실제 야드에서는 터미널 내 여러 작업 영역 간의 상호작용에 따라 각 개별 차량의 체류시간은 평균 체류시간을 기준으로 큰 폭의 편차를 보일 수 있다.

Fig. 2는 실증 분석 대상 터미널의 1일 간 시간대 별 평균 체류시간과 각 개별 반출입 차량의 체류시간 편차를 분포화한 그래프로, 개별 반출입 차량의 체류시간 분포는 시간대 별 평균 체류시간의 증감 추세를 따라 변화하고 있지만, 각 시간대에서 개별 반출입 차량 체류시간은 평균값과 큰 편차를 보이는 것을 확인할 수 있다.

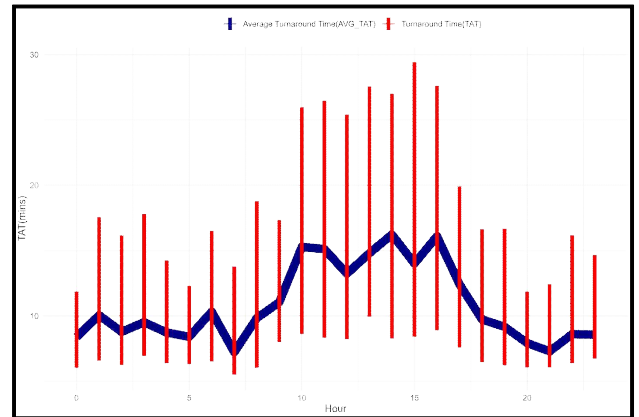


Fig. 2 Distribution of differences in turnaround time of external truck per hour

따라서 본 연구에서는 단기 시점(반출입 차량 게이트 도착 당시)의 반출입 차량 체류시간을 예측하기 위해 반출입 작업에 영향을 미치는 특성 요인을 입력 변수로 하는 예측 모형을 제시한다. 모형의 입력 변수가 될 특성 요인은 선행연구에서 유의성이 검증된 변수와 대상 터미널 실무 전문가 자문에 따라 도출된 변수를 사용한다. 최종적으로 예측에 활용될 입력 변수와 출력 변수는 Table 1과 같다.

4.1 분석 자료

본 연구는 부산신항 내 특정 컨테이너 터미널을 실증 분석 대상으로 하며 해당 컨테이너 터미널의 2022년 반출입 운영 데이터를 기반으로 분석 및 예측을 수행한다.

반출입 차량 체류시간 예측 모형을 설계하기 이전에 반출입 운영 데이터를 컨테이너 운송 유형(반입/반출)에 따라 분리하며 데이터의 결측치 및 이상치를 제거하여 예측에 활용될 데이터를 전처리하였다.

Table 1 Variables(input and output) of predictive models

Source	Input Variables		Output Variable
Al-Deek(2001) Cho et al.(2022) KMI(2023) Li et al.(2023)	Gate in and out hour (0 ~ 23 Hour)		External truck turnaround time
KMI(2023) Li et al.(2023)	Gate in and out day during the week (Monday ~ Sunday)		
Li et al.(2023)	(Gate In)	Cargo shipping closing time (External truck gate in before ship CCT = 0 else 1)	
	(Gate Out)	Container yard(CY) freetime (External truck gate out before CY freetime = 0 else 1)	
Interview	Number of external trucks (including working and waiting) within the operating yard block		
Al-Deek(2001) Al-Deek(2002)	Tturnaround times for the last three external trucks before the entry of external truck within the operating yard block		

Fig. 3, 4는 각각 반입 차량과 반출 차량의 체류시간 분포를 나타낸다. 반출 차량의 체류시간 분포에 비해 반입 차량의 체류시간 분포가 높은 첨도를 보이고 반입 차량의 평균 체류시간은 약 10분 정도 소요된다. 반입 작업 시 30분 이상 소요되는 작업의 빈도는 낮는데 비해 반출 차량의 평균 체류시간은 약 20분 가까이 소요되고 30분 이상 소요되는 작업의 빈도도 높은 것으로 보아 반입 작업보다 반출 작업 시 많은 체류시간이 소요되는 것을 확인할 수 있다. 이는 반출 작업 시 다량의 컨테이너 리핸들링 작업이 수반되어야 하기 때문으로 보이며, 반대로 리핸들링 작업의 소요가 적은 반입 작업의 대기는 상대적으로 짧다고 할 수 있다.




Fig. 3 Distribution of external trucks turnaround time(gate-in)

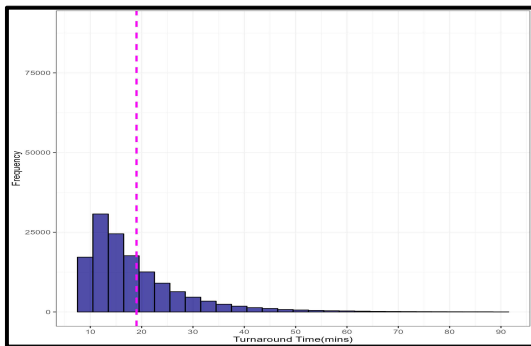


Fig. 4 Distribution of external trucks turnaround time(gate-out)

4.2 적용 모형 검토 및 예측모형 설계

반출입 차량 체류시간 예측 모형은 Table 1의 반출입 차량이 게이트에 도착한 시점에 주어진 정보인 입력 변수에 따라 출력 변수인 반출입 차량 체류시간이 얼마나 소요될지를 예측하여 출력하는 형태로 수립된다.

이에 본 연구에서는 입력 변수와 출력 변수 간의 복잡한 상호작용 및 비선형 관계를 학습할 수 있는 딥러닝 기반 예측 모형인 심층신경망(Deep Neural Network; DNN) 모형을 적용하여 반출입 차량의 체류시간을 예측하고자 한다.

예측 모형은 Table 1에서 도출된 입력 변수를 기반으로 입력층(Input Layer)으로 구성하고 각 변수 간의 복잡한 관계를 학습하고 패턴화할 수 있는 가중치를 가진 은닉층(Hidden Layer), 출력 변수인 반출입 차량 체류시간을 출력하기 위한 출력층(Output Layer)으로 구성하여 설계하였다(Fig. 5).

변수 간의 관계성을 입증하기 어려운 각 입력 변수의 비선형적 패턴을 DNN 모형이 적절히 반영하여 반출입 차량의 체류시간을 예측할 수 있을 것으로 기대되며, 다량의 반출입 운영 데이터를 활용하여 예측 모형이 데이터의 패턴을 학습할 수 있도록 하였다.

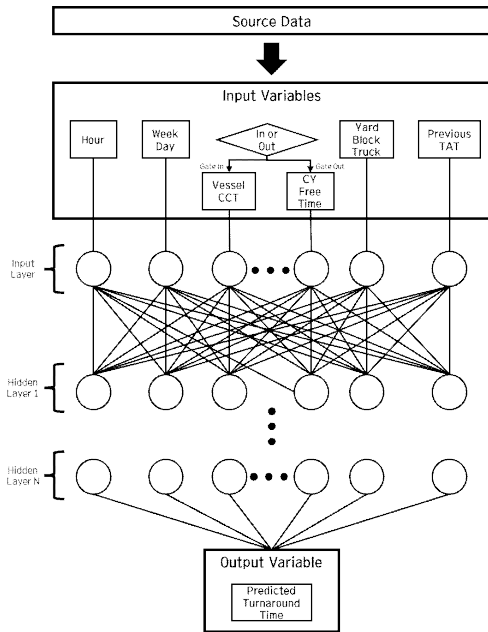


Fig. 5 Architecture of the predictive model

5. 모형의 학습 및 분석

5.1 모형 학습을 위한 하이퍼 파라미터 설정

예측 모형의 학습에 앞서 모형에 적합한 하이퍼 파라미터 (Hyper-Parameter)를 설정할 필요가 있다. 하이퍼 파라미터는 딥러닝 모형을 학습할 때 조정해야 하는 모형의 설정값으로, 최적의 하이퍼 파라미터를 선택하고 설정하는 것은 모형의 성능에 큰 영향을 미칠 수 있다. 또한, 하이퍼 파라미터는 일반적으로 제시된 설정 기준이 없으며 모형의 특성 및 복잡도에 따라 적합한 파라미터를 탐색하는 과정을 반복해야만 한다(Reimers and Gurevych, 2017).

본 연구에서는 예측 모형의 최적 하이퍼 파라미터 설정을 위해 특정 범위 내에서 일정 간격으로 파라미터를 변경하며 최적값을 탐색하는 그리드 서치(Grid Search) 방법을 적용하여 하이퍼 파라미터를 설정하였다.

최적 하이퍼 파라미터 설정을 위한 탐색 범위는 Table 2와 같으며, 탐색 후 도출된 최적 하이퍼 파라미터 값은 Table 3과 같다.

Table 2 Grid search range of hyper parameters

Parameters	Search Range
Epoch	500 / 1,000
Batch Size	256 ~ 1,024
Num Layers	4 ~ 7
Num Neurons	256 ~ 1,024
Learning Rate	0.0001 ~ 0.0025
Dropout Rate	0 ~ 0.4
L2 Regularization	0 ~ 0.2
Batch Normalization	O or X

Table 3 Optimal hyper parameters of models

Network	DNN	
	In	Out
Gate In / Out	In	Out
Epoch	500	1,000
Batch Size	512	1,024
Num Layers	5	5
Num Neurons	1,024, 1,024, 1,024, 1,024, 1,024	512, 512, 512, 512, 512
Optimizer	Adam	Adam
Learning Rate	0.0005	0.001
Dropout Rate	0.4	0.4
Activation Function	swish	swish
L2 Regularization Lambda	0.1331	0.1331
Batch Normalization	O	O

5.2 예측 모형의 학습 및 결과 분석

본 예측 모형은 Python 기반의 Tensorflow 2.4.0 환경에서 구현하고 4개의 Nvidia GeForce RTX 3090을 활용하여 모형의 학습을 수행하였다.

반출입 차량 체류시간 예측 모형의 객관적 성능을 검증하기 위해 전체 데이터 중 80%를 학습 데이터로 구축하고, 학습 데이터 중 20%를 모형 학습과정 검증을 위한 검증 데이터로 분리한 후 나머지 20%의 데이터를 테스트 데이터로 활용하였다.

각 입력 데이터의 특성에 따라 연속형 변수는 데이터의 값을 0 ~ 1 사이로 매핑하는 최소-최대 정규화를 적용하였으며 범주형 변수의 경우 범주형 데이터를 수치형 데이터로 변환하는 방법인 One-Hot Encoding을 통해 범주형 데이터를 예측 모형이 이해할 수 있는 데이터로 변환하였다.

예측 모형의 손실 지표인 Loss값은 평균 제곱 오차(Mean Squared Error; MSE)를 사용하고, 결과 분석을 위한 성능 지표인 Metrics값은 절대 평균 오차비율(Mean Absolute Percentage Error; MAPE)과 평균 제곱근 오차(Root Mean Squared Error; RMSE)를 사용하였다.

모형의 학습은 반출입 차량의 운송유형에 따라 구분된 DNN-반입, DNN-반출 모형에 대해 Table 3의 최적 하이퍼 파라미터 값을 적용하여 학습 및 예측을 수행하였으며 각 모형의 학습과정을 모니터링하였다. 반입과 반출 모형 모두 학습 초기에 빠른 속도로 수렴하여 각 모형이 학습 데이터와 검증 데이터의 패턴을 파악하여 Loss값을 최소화하였으며 에포크의 증가에 따라 안정화된 학습을 하며 일반화된 예측 모형으로 학습되었음을 확인하였다(Fig. 6).

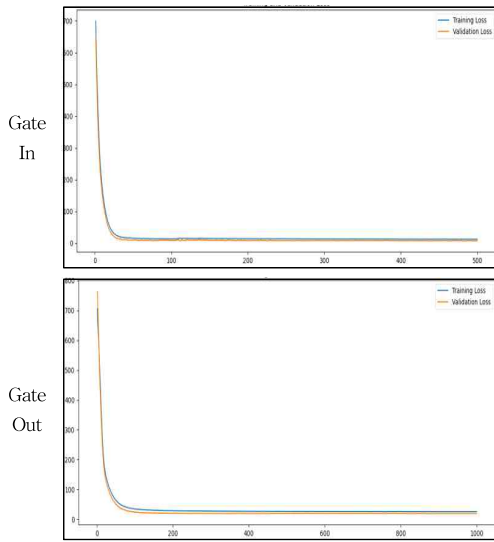


Fig. 6 Learning curve(loss) by gate in and out models

반입 및 반출 예측 모형의 학습이 끝난 뒤 성능 검증을 위해 반출입 차량 체류시간 테스트 데이터의 실측치와 모형을 통해 예측된 예측치를 비교하여 MAPE 및 RMSE 기준으로 각 모형의 성능을 분석하였다.

Table 3 Prediction result of models

Model	DNN-In	DNN-Out
MAPE (%)	14.95	14.47
RMSE (mins)	2.83	4.36

Table 4는 각 모형의 예측 오차율 및 예측 오차로 반입, 반출 두 모형 모두 MAPE 15% 이하의 예측 정확도를 보이는 것을 확인하였고 두 모형은 비슷한 수준의 예측 정확도를 나타내었다. 반출입 차량의 체류시간 예측에 본 DNN 모형이 적합하다고 판단된다.

반입 및 반출 모형의 MAPE는 각각 15% 수준으로 비슷한 수치를 보이는 반면 각 모형의 RMSE는 2.83분과 4.36분으로 약 2분 가까이 차이를 보인다. 이는 반입 작업에 비해 반출 작업 시 차량의 체류시간이 더 오래 걸리기 때문이라고 볼 수 있으며 각 모형의 RMSE는 반입, 반출 체류시간 평균치와 비교하였을 때 수용 가능한 오차로 판단된다(Fig 3).

Fig. 7, 8은 각 모형의 테스트 데이터와 학습을 통해 도출된 예측치의 체류시간 차이인 예측 오차를 분포화한 그래프로, 반입 및 반출 모형 모두 대부분의 예측 오차는 0에 가깝게 분포한다. 본 연구에서 제시한 반출입 차량 체류시간 예측 모형이 유의미한 수준의 예측 정확도를 보이는 것을 확인할 수 있다.

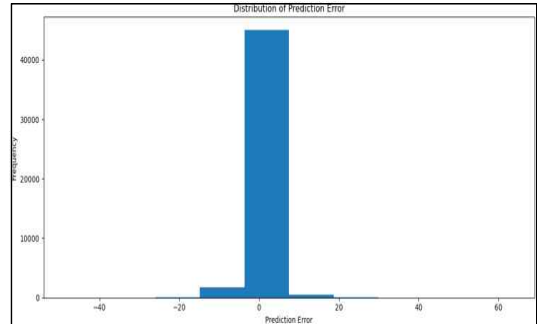


Fig. 7 Distribution of prediction error by gate-in model

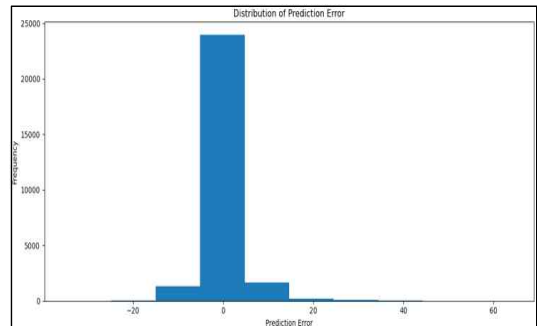


Fig. 8 Distribution of prediction error by gate-out model

6. 결 론

코로나 팬데믹 발생 이후 세계적인 수출입 물동량 증가는 항만의 생산성에도 큰 영향을 미쳤다. 항만 내 혼잡도는 심각한 수준으로 상승하였고 컨테이너 반출입 작업 또한 생산성 저하가 뚜렷하게 나타나고 있다.

반출입 작업의 대기 및 차량의 장시간 체류시간 문제의 현실적 해결을 위해서는 터미널 내 반출입 차량 체류시간을 미리 예측하여 터미널 운영사 및 트럭 운송사가 탄력적으로 반출입 운영에 대처할 수 있도록 해야 한다.

본 연구에서는 효율적인 반출입 작업 계획 수립을 위해 필요한 반출입 차량 체류시간 예측 모형을 제시하였다. 딥러닝 기반의 DNN 예측 모형을 수립하고 실제 부산신항 컨테이너 터미널의 반출입 운영 데이터를 통해 학습시켰다. 또한 실제 데이터와 예측치의 비교를 통해 모형의 성능을 검증하였다. 제시한 예측 모형은 과소 또는 과대 적합 없이 안정적으로 학습되었으며, MAPE 15% 이하의 예측 정확도로 유의미한 수준의 성능을 보여준다.

다만 부산항 전체가 아니라 부산신항 내 특정 컨테이너 터미널의 1년 간 자료를 대상으로 분석 및 실험을 수행하였다는 점이 본 연구의 한계성이라 하겠다. 부산신항의 경우 각 컨테

이너 터미널 간 컨테이너 처리 물량이 집중되는 시간대나 반출입 패턴이 일부 유사하지만, 북항의 경우 이러한 패턴이 부산신항과 상이할 수 있기 때문이다.

또한, 예측에 반출입 차량의 복화운송(Dual Cycle)을 고려하지 않았다는 점도 연구의 한계점이라 하겠다. 복화운송은 컨테이너를 적재한 차량이 터미널 내에 진입하여 컨테이너 반출입 작업을 완료한 후 다른 컨테이너를 반출하는 운송유형으로 반출입 운송 효율성을 제고할 수 있다.

따라서 향후 연구에서는 북항을 포함한 다수의 부산항 컨테이너 터미널의 반출입 체류시간 예측 모형을 수립하고 결과를 터미널 별로 비교 분석하여 부산항의 실질적인 반출입 체류시간 감소 방안에 대해 논할 필요가 있다. 또한 본 연구에서 고려하지 못한 복화운송을 반영한 반출입 차량 체류시간 예측 모형도 개발할 필요가 있겠다.

후 기

본 논문은 2023년도 교육부의 재원으로 한국연구재단의 지원을 받아 수행된 지자체-대학 협력기반 지역혁신 사업의 결과입니다.(2023RIS-007)

References

- [1] Al-Deek, H.(2001), "Which Method Is Better for Developing Freight Planning Models at Seaports - Neural Networks or Multiple Regression", In Transportation Research Record: Journal of the Transportation Research Board, No. 1763, pp. 90-97.
- [2] Al-Deek, H.(2002), "Use of Vessel Freight Data to Forecast Heavy Truck Movements at Seaports", In Transportation Research Record: Journal of the Transportation Research Board, No. 1804, pp. 217-224.
- [3] Al-Deek, H., Johnson, G., Mohamed, A. and El-Maghraby, A.(2000), "Truck Trip Generation Models for Seaports with Container and Trailer Operation", In Transportation Research Record: Journal of the Transportation Research Board, No. 1719, pp. 1-9.
- [4] Cho, M. W., Kim, T. Y. and Lee, B. W.(2022), "Turn-time Prediction System Implementation of Container Trucks at the Port Terminal", Korea Logistics Review, Vol. 32, No. 4, pp. 105-114.
- [5] Kim, G. S.(2021), "Estimation on Storage Yard Occupancy Ratio of Container Terminal : A Case of Busan New Port Container Terminal", Journal of Korean Navigation and Port Research, Vol. 45, No. 3, pp. 148-154.
- [6] Kim, J. H., Kim, J. S. and Lee, G. W.(2019), "A Study on Predicting Truck Arrivals at Busan Container Terminals in Korea", Journal of Maritime Business, Vol. 44, pp. 97-111.
- [7] Kim, J. S., Kim, J. H, Shin, H. J and Lee, G. W.(2020), "Prediction of Truck Arrivals at Container Terminals based on LSTM Network", Korean Society of Transportation, Proceedings of the KOR-KST Conference, pp. 240-241.
- [8] Kim, S. H., Kim, J. R., Cho, H. J. and Lim, C. H.(2019), "A Study on the Prediction of Traffic Volume by Time of Vehicles Entering and Exiting Port Container Terminal Using Machine Learning", Korean Institute of Industrial Engineers, 2019 Fall Conference of Korean Institute of Industrial Engineers, pp. 1412-1417.
- [9] Kim, Y. I., Shin, J. Y and Park, H. J.(2022), "A Study on the Prediction of Gate In-Out Truck Waiting Time in the Container Terminal", Journal of Korean Navigation and Port Research, Vol. 46, No. 4, pp. 344-350.
- [10] Korea Maritime Institute(KMI)(2023), "Pricing Model for Vehicle Booking Systems in Container Terminals", p. 167.
- [11] Lee, S. J.(2011), "A Study on the Improvement of the Gate In-out Operation in the Container Terminals", Master Thesis of Korea Maritime and Ocean University.
- [12] Li, N., Sheng, H., Wang, P., Jia, Y., Yang, Z. and Jin, Z.(2023), "Modeling Categorized Truck Arrivals at Ports: Big Data for Traffic Prediction", IEEE Transactions on Intelligent Transportation Systems, Vol.24, No.3, pp. 2772-2778.
- [13] Ramachandran, P., Zoph, B. and V.Le, Q.(2017), "Swish - A Self-Gated Activation Function", arXiv preprint arXiv:1710.05941
- [14] Reimers, N. and Gurevych, I.(2017), "Optimal Hyper-Parameters for Deep Lstm-Networks for Sequence Labeling Tasks", arXiv preprint arXiv:1707.06799.
- [15] Xie, Y. and Huynh, N.(2010), "Kernel-Based Machine Learning Models for Predicting Daily Truck Volume at Seaport Terminals", Journal of Transportation Engineering, Vol. 136, No. 12, pp. 1145-1152.

Received 08 January 2024

Revised 03 February 2024

Accepted 13 February 2024