

항만 터미널 혼잡도 예측을 위한 Temporal Fusion Transformer 기반 접근

조성현, 김지연, 김기환, 강영진, 정석찬*

동의대학교 인공지능학과,

인공지능그랜드ICT연구센터,

*동의대학교 e비즈니스학과, 인공지능그랜드ICT연구센터

thch989@naver.com, *scjeong@deu.ac.kr

Temporal Fusion Transformer-based Approach for Predicting Port Terminal Congestion

Jo Seong Hyeon, Ji-Yeon Kim, Ki-Hwan Kim, Young-Jin Kang, Seok Chan Jeon*

Dept of Artificial Intelligence, Dong-Eui University,

AI Grand ICT Research Center, Dong-Eui University,

*Dept. of e-Business, AI Grand ICT Research Center, Dong-Eui University

요약

항만 터미널 혼잡도는 운영 효율성과 직결되어있지 않으며, 이를 사전에 파악하고 예측하는 작업은 중요하게 여겨지고 있다. 본 연구에서는 항만 터미널 내부를 이동하는 화물 운송 차량의 수를 터미널 내부의 혼잡도를 나타내는 핵심 지표로 판단하였고, 이를 바탕으로 TFT(Temporal Fusion Transformer) 모델을 활용하여 단기 예측의 타당성을 검증하였다. 또한, 평일과 주말, 공휴일 등 시간대별 패턴을 고려한 분석도 진행하였으며, 그 결과 본 연구에서 제안한 방법론이 실제 현장에서 혼잡 상황을 사전에 인지하고 이에 대한 대책 방안을 마련하는데 실질적으로 기여할 수 있음을 확인하였다.

I. 서론

전 세계 항만 물류는 컨테이너 운송 수요가 꾸준히 증가하면서 항만 내부의 복잡성도 점차 높아지고 있다. 그 결과 터미널 혼잡 문제는 여전히 중요한 과제로 자리 잡고 있다[1]. 특히 게이트와 야드 구간에서 발생하는 화물 차량의 대기과 체류 현상은 터미널 전체 운영 효율에 큰 영향을 주며, 이를 제대로 관리하지 못할 경우 선박 작업 지연, 장비 가동률 저하, 물류비용의 증가와 같은 문제로 이어질 수 있다[2].

기존 연구들은 주로 회귀 분석이나 단순한 통계 모델을 활용해 혼잡도를 예측하고자 했지만[3], 시간대별 비선형적 변화, 주말과 공휴일의 특수성, 계절적 요인과 같은 다양한 패턴을 충분히 반영하는 데 한계가 있었다[4, 5]. 최근에는 심층학습 기반 시계열 분석 기법이 이러한 한계를 극복할 수 있는 유망한 방법으로 주목받고 있으며, 그중에서도 TFT(Temporal Fusion Transformer)는 여러 변수를 동시에 입력받아 시간적 의존성을 효과적으로 처리하고, 변수별 중요도를 해석할 수 있다는 점에서 현장 적용 가능성이 높다[6].

이에 본 연구에서는 터미널 내 화물 운송 차량의 대수를, 혼잡도를 나타내는 핵심 지표로 설정하고, TFT 기반 예측 모델을 구축하였다. 또한 2024년 데이터를 학습에 활용하고 2025년 데이터를 검증에 사용하는 것으로 본 연구에서 제안한 모델의 범용성과 활용 가능성을 검증하고자 한다.

II. 데이터 및 방법

본 연구에서는 부산항의 특정 터미널에서 수집된 시계열 데이터를 활용하였다. 데이터는 2024년 1월부터 12월까지 5분 간격으로 기록된 약 11만

2천여 건(112,474행)으로 하루 평균 288개의 데이터가 기록되는 1년 치 자료이다. 예측 모델 개발에서는 2024년 자료를 학습에 사용하였고, 2025년 자료는 검증용으로 분리하여 모델의 성능을 확인하였다.

예측 대상인 종속 변수는 터미널 내 화물 운반 트럭 수(inout_status)로 지정하였다. 이 값은 최소 0대에서 최대 120대까지 분포하며, 터미널 혼잡도를 가장 직접적으로 보여줄 수 있는 지표로 판단된다. 설명 변수로는 선박의 상태를 나타내는 vessel_status, 차량 흐름과 관련된 inout_status, 그리고 연, 월, 일, 시, 분으로 세분화한 시간 변수를 포함하였다. 이에 더해 달력 효과를 반영하기 위해 주말 여부와 공휴일 여부를 추가하였다. 특히 평일, 주말, 공휴일마다 시간대별 차량 흐름이 일정한 패턴을 보인다는 점을 고려해, 이러한 시간적·달력적 속성을 모델에 반영하였다.

표 1 모델 학습에 사용된 주요 변수 정의

변수명	설명	타입
vessel_status	선박 상태를 나타내는 수치형 변수	int
inout_status	터미널 내부 화물 운반 트럭 수	int
reg_year	기록 연도	int
reg_month	기록 월	int
reg_day	기록 일	int
reg_hour	기록 시	int
reg_minute	기록 분	int
reg_dayofweek	요일	int
reg_week	연중 주차	int
is_holiday	공휴일 여부	int

is_weekend	주말 여부	int
------------	-------	-----

예측 모델은 TFT 구조를 기반으로 설계하였다. 하루 동안의 데이터 흐름을 입력으로 활용하기 위해 Encoder 구간은 288개(24시간)로 설정하였고, 향후 3시간의 inout_status를 예측할 수 있도록 Prediction 구간은 36개로 구성하였다. 학습 과정에서는 MAE(평균 절대 오차)를 손실 함수로 사용했으며, 과적합을 방지하고 모델의 일반화 성능을 확보하기 위해 Early Stopping 기법을 적용하였다.

III. 실험 및 결과

모델 검증 결과, 제안한 TFT 기반 예측 모델은 MAE의 경우 4.5034, RMSE(평균 제곱근 오차)는 5.8057을 기록하였다. 데이터값이 0대에서 120대 사이에 분포한다는 점을 고려하였을 때 이는 약 5대 수준의 오차로, 실제 현장에서 혼잡도를 파악하고 사전에 대응 방안을 마련하는 데 충분히 활용할 수 있는 정확도라 할 수 있다. 특히 혼잡이 집중되는 오후 시간대(13시~15시)에서도 화물 트럭 수의 급격한 변화를 비교적 안정적으로 반영하였다. 일부 구간에서는 실제 관측값보다 다소 낮거나 높게 예측되는 경우가 있었으나, 전체적인 흐름과 혼잡 정점 발생 시점은 유사하게 예측되었다.

그림 1은 2025년 검증 데이터 중 일부 구간에서 실제값과 예측값을 시각화한 그래프이다. 예측 곡선은 실제 곡선과 유사한 형태를 보였으며, 특히 혼잡이 집중되는 정점 구간의 특성을 안정적으로 재현되었다. 이를 통해 본 연구에서 제안된 모델이 단기 혼잡도 예측에 실질적으로 적용될 가능성을 확인할 수 있다.




그림 1 2025년 데이터에서 관측값과 TFT 예측값의 비교

IV. 결론

본 연구에서는 항만 터미널 내 화물 운송 차량 대수를 기반으로 TFT를 적용하여 혼잡도를 단기적으로 예측하고 그 성능을 검증하였다. 결과적으로 해당 모델은 평균적으로 5대 수준의 오차를 보였으며, 실제 차량 흐름의 전반적인 패턴과 혼잡이 집중되는 시간대를 유사하게 예측하였다. 이러한 결과는 터미널 관리자가 혼잡 상황을 사전에 인지하고 적절한 대응 전략을 수립하는 데 효과적임을 보인다.

향후 연구에서는 예측 범위를 3시간에서 더 넓은 범위로 확장하면서도 정확도를 유지하거나 개선할 방법을 탐색할 계획이다. 또한 기상 조건, 교통 상황, 선박 입출항 일정 등 외부 요인을 추가로 반영하여 모델의 설명

력을 높이고, 다양한 터미널 환경에서도 범용적으로 적용할 수 있는 예측 시스템으로 발전시키는 것을 목표로 한다.

ACKNOWLEDGMENT

이 성과는 정부(과학기술정보통신부)의 재원으로 정보통신산업진흥원의 지원을 받아 수행된 연구임(S2201-24-1003, 부산 혁신거점 인공지능 데이터 융합과제).

참 고 문 헌

- [1] B. Li, B. Sun, W. Yao, Y. He, and G. Song, "Container Terminal Oriented Logistics Generalized Computational Complexity," IEEE Access, vol. 7, pp. 94737 - 94756
- [2] A. Ramirez-Nafarrate, R. G. González-Ramírez, N. R. Smith, R. Guerra-Olivares, S. Voß, and S. Voß, "Impact on yard efficiency of a truck appointment system for a port terminal," Annals of Operations Research, vol. 258, no. 2, pp. 195 - 216
- [3] W. Peng, X. Bai, D. Yang, K. F. Yuen, and J. Wu, "A deep learning approach for port congestion estimation and prediction," pp. 1 - 26
- [4] C. S. Fişkin and A. G. Cerit, "Which Forecasting Models Are Employed in The Shipping Industry? Identifying Key Themes and Future Directions Through an Integrative Review," International Journal of Maritime Engineering, vol. 163, no. A4
- [5] X.-L. Ge, Z. Yin, Y. Zou, and B. Wang, "Negative Effect Prediction and Refueling Traffic Flow Equilibrium of Urban Energy Supply Network during Weekends and Holidays," Applied Sciences, vol. 13, no. 4, p. 2498
- [6] B. Lim, S. O. Arik, N. Loeff, and T. Pfister, "Temporal Fusion Transformers for Interpretable Multi-horizon Time Series Forecasting," arXiv: Machine Learning, Dec. 2019