

Naive Bayes-LSTM 기반 예지정비 플랫폼 적용을 통한 화물 상차 시스템의 운영 안전성 및 신뢰성 확보 연구

황 선 우* · 김 진 오** · 최 준 우*** · 김 영 민*

*이주대학교 시스템공학과 · ** (주)코어디아아이티 · *** (주)노바 기업부설연구소

On the Parcel Loading System of Naive Bayes-LSTM Model Based Predictive Maintenance Platform for Operational Safety and Reliability

Sunwoo Hwang* · Jinoh Kim** · Junwoo Choi*** · Youngmin Kim*

*Department of Systems Engineering, Ajou University · **CORE DIT

***Research Institute Global Nova

Abstract

Recently, due to the expansion of the logistics industry, demand for logistics automation equipment is increasing. The modern logistics industry is a high-tech industry that combines various technologies. In general, as various technologies are grafted, the complexity of the system increases, and the occurrence rate of defects and failures also increases. As such, it is time for a predictive maintenance model specialized for logistics automation equipment. In this paper, in order to secure the operational safety and reliability of the parcel loading system, a predictive maintenance platform was implemented based on the Naive Bayes-LSTM(Long Short Term Memory) model. The predictive maintenance platform presented in this paper works by collecting data and receiving data based on a RabbitMQ, loading data in an InMemory method using a Redis, and managing snapshot DB in real time. Also, in this paper, as a verification of the Naive Bayes-LSTM predictive maintenance platform, the function of measuring the time for data collection/storage/processing and determining outliers/normal values was confirmed. The predictive maintenance platform can contribute to securing reliability and safety by identifying potential failures and defects that may occur in the operation of the parcel loading system in the future.

Keywords : Cargo Loading System, Predictive Maintenance, Long Short-Term Memory, Safety System

1. 서론

근래에는 맞벌이, 고령화, 1인 가구의 증가 등 사회구조의 급격한 변화로 인해 비대면 배송 서비스 시장이 폭발적으로 성장하고 있는 시점이다. 또한, 스마트폰 등 모바일 기기의 보급으로 급격한 생활 방식의 변화로 인하여, 지속적으로 온라인 커머스 산업이 성장하고 있다. 이에 따라, 소비 트렌드 변화가 지속되고 있으며, 새벽 배송 등 다중, 소화물 택배 화물 처리 수요가 지속적으로 증가하고 있는

시점이다. 이러한 물류 산업의 과도한 팽창은 택배기사들의 장시간 노동으로 인한 서비스 질 저하와 삶의 질 저하로 이어질 수 있다. 또한, 인력 중심의 다중, 소화물 물품 상차 시, 배송 거리나 크기에 따라 효율적인 물품 배치기 어려워지며, 상차작업 특성상 새벽과 야간에 화물 작업이 집중되기 때문에, 작업 생산성 저하 및 안전사고의 위험이 증대될 수 있다. 이를 해소하기 위해서 다양한 연구 기관에서는 택배 산업의 열악한 환경 개선과 산업 경쟁력 강화를 위해 화물 상차 자동화 기술 연구를 진행하고 있는 시점이다. 본 논문의 연구 대상인 물류 상차 시스템은 물류

†본 논문은 산업통상자원부의 지원을 받아 수행되었음.(20015047)

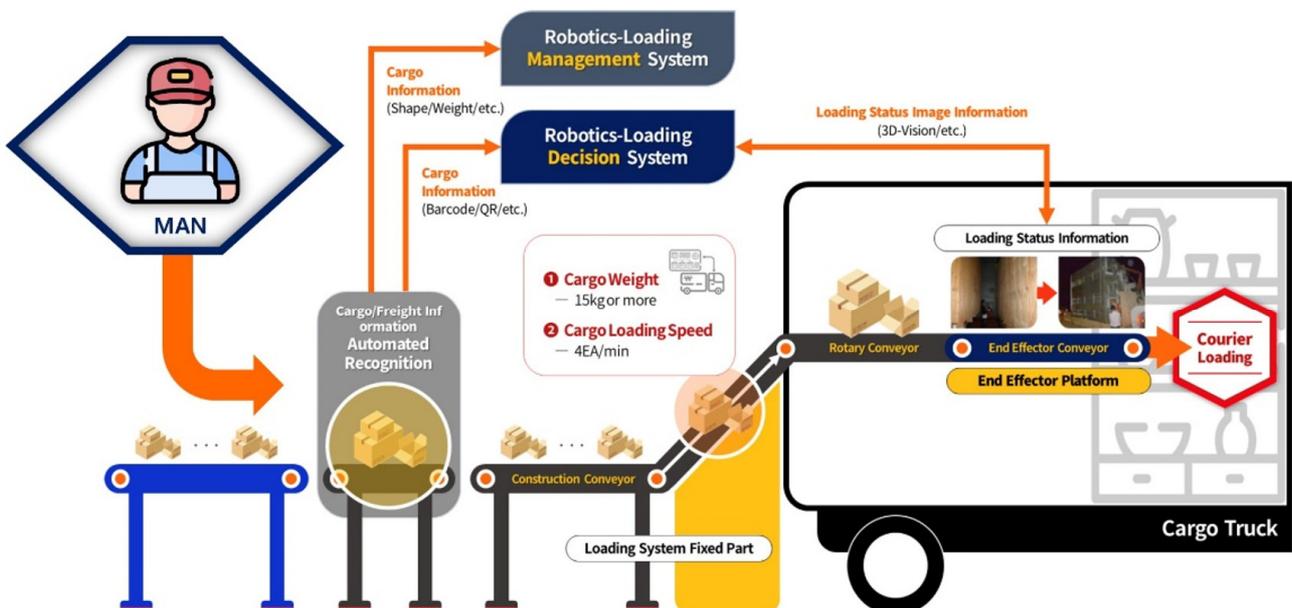
†Corresponding Author : Youngmin Kim, Department of Systems Engineering, Ajou University, 206, World cup-ro, Yeongtong-gu, Suwon-si, Gyeonggi-do, Republic of Korea, E-mail: pretty0m@ajou.ac.kr

Received November 20, 2023; Revision December 14, 2023; Accepted December 14, 2023

서버터미널에서 2.5t 이하 소규모 탑차 형태 물류 배송차량에 화물을 상차할 수 있는 로봇 기반의 상차 시스템이다. 이러한 화물 상차 시스템은 화물 이송용 텔레스코픽 컨베이어, 화물 상차를 위한 엔드 이펙터, 적재 공간 및 적재 상태 확인을 위한 영상 기반 인식기, 화물 순서 및 상차 관리를 위한 분리기, 고장 및 결함을 예측하고, 화물 끼임 등을 감지하기 위한 예지정비 시스템으로 구성된다. 또한, 상차 작업 관리 소프트웨어를 통해 화물정보 확인 및 불량 화물을 인식한 후 처리하고, 적재 의사결정 소프트웨어를 통해 화물정보 기반 상차 순서 및 배치를 수행할 수 있는 시스템이다. 화물 상차 시스템은 비정형 화물 등 다양한 형태의 화물을 분당 4개씩 자동으로 상차할 수 있는 기능과 반자율 기반 차량 내부 화물칸 진입 및 방향 조정 가능, 화물의 크기, 형태, 무게에 따라 효율적인 적재 자동화를 목적으로 연구되고 있는 시점이다. <그림 1>은 화물 상차 시스템의 개념도를 보여준다. 이러한 화물 상차 시스템은 작업자를 대체하는 물류 자동화 시스템이니 만큼, 화물 작업의 효율성 증가 및 운영 신뢰성 확보를 위한 방안과 기술 적용이 중요하다. 따라서, 본 논문에서는 화물 상차 시스템의 고장 및 결함을 사전에 예측을 위한 기반 데이터인 정상/비정상 데이터 수집 및 분석, 처리를 위한 플랫폼을 구축하였다. 또한, 이를 통해 화물 상차 시스템의 운영 안전성 및 신뢰성을 확보하기 위하여, Naive Bayes 연계 LSTM(Long Short-Term Memory) 모델을 기반으로, 사전에 학습된 빅데이터로 고장 및 결함을 사전에 예측할 수 있는 예지정비 시스템을 구현하였다.

2. 예지정비 관련 선행연구 분석

본 절에서는 화물 상차 시스템의 운영 안전성 및 신뢰성을 확보하기 위한 예지정비 플랫폼의 핵심 요소와 관련되어, 선행적으로 수행된 예지정비 관련 연구를 분석하였다. 운영 안전성을 확보하기 위한 목적으로, 고장 및 결함을 예측하기 위해서는 다양한 방면으로의 노력이 필요하다. 기존에는 신뢰성 분석 연구 분야에서 MTTF(Mean Time To Failure) 방법론을 활용하여, 시스템이나 구성품의 수명주기를 예측하는 연구가 수행되었다. 현재는 기술의 발달로 MTTF와 접목하거나, 인공지능 기반의 예지정비 연구가 진행되고 있는 시점이다. 황태민 등은 선박 예지정비 모델 개발을 위한 선박 도크 수리 항목의 텍스트 분석 연구를 수행한 바 있다[1]. 해당 연구는 텍스트 분석을 통해 기기들이 서로 다른 파트에 포함되어 따로 작동하고 있지만 동시에 상호연관성을 가질 수 있다는 결과를 도출하였다. 윤익현 등은 선박 운항 특성을 반영한 예지정비 모델 개념을 제안하였으며, MPdM(Maritime Predictive Maintenance)의 개발을 통해 이상 징후 판단을 기반으로 예지 정비를 수행 기술이 구현되면 선박의 운항 효율성 향상으로 사고 예방 및 비용 절감에 기여할 수 있을 것으로 판단하였다[2]. 홍창우는 NASA(National Aeronautics and Space Administration) 데이터 셋을 기반으로 인공지능과 빅데이터를 활용한 예지정비 적용 방안에 대한 연구를 수행하였다[3]. 해당 연구는 마할라노비스 거리와 주성분 분석을 활용할 경우, 고장 발생 이전에 이상치 감지가 가능할 뿐 아니라 고장 전 발생하는 전조증상까지 감지할 수 있다는 결론을 도출하였다. 천강민 등은 설명 가능한 인공지능을



[Figure 1] Concept of parcel loading system

적용한 기계 예지정비 방법을 연구하였으며, 고압압축기의 과거 고장 이력을 수집하여 고장 위험 및 고장 상황을 위한 머신러닝 모델을 제시하였다[4]. 이경호 등은 용인 경전철 차량부품 정비 데이터 분석 및 상태기반 예지정비 방안 연구를 수행하였다[5]. 신뢰성 기반 정비 시스템 구축을 위해 타겟 부품에 설치된 센서들을 통해 수집된 상태의 정보를 분석하여 부품의 결함 여부를 자동으로 판단하고 수명을 예지하는 기술 및 소프트웨어 개발이 필요하다는 결론을 도출하였다. 이계동 등은 머신러닝 기반의 진동 이상신호 분석을 통한 스마트공장 예측정비에 관한 연구를 수행하였다[6]. 박철순 등은 회전기 설비에 부착된 진동센서로부터 수집되는 진동신호를 이용하여 회전기 설비의 이상신호를 탐지하고 결함을 분류하는 모델을 제안하였으며, 대형 항공부품용 5축 가공기의 예측정비를 위하여, 센서 기반 스피들 모터에 인가되는 전류에 대한 실시간 모니터링을 수행하였다[7]. 또한, 수집된 전류 신호에 대해 머신러닝 기반의 비정상 탐지 알고리즘을 이용해서 공구에 대한 이상 상태를 판단하여 예지정비를 수행할 수 있는 방안을 제시하였다. 이계동 등은 기어박스의 예지정비를 위한 인공지능 기반의 이상탐지 및 결함분류에 관한 연구를 수행하였다[8]. 설비별 결함에 대한 정보를 잘 나타내는 특정 주파수(결함주파수, 고조파 등)를 따로 추출하여 적지만 유의미한 변수를 이용해 모델을 구축하는 기법에 대한 연구가 필요하다는 결론을 도출하였다. 김정태 등은 머신러닝을 활용한 터보팬 엔진의 잔여 유효 수명 예측 모델을 제안하였다[9]. 해당 연구의 방법론은 센서만 부착되어 있다면, 머신러닝을 기반으로 터보팬 엔진뿐 아니라 다른 장비들에서도 일반적으로 적용할 수 있으며, 인과관계 파악도 가능하다는 결론을 도출하였다. 김제동 등은 기계학습 기반의 대공장비 수리부속 수요예측모형 연구를 수행하였다[10]. 해당 연구에서는 지난 5개년의 육군 대공장비 수리부속 수요 데이터를 수집하고 정비내역과 같은 비정형 데이터를 포함한 다양한 정형 데이터 항목을 추출하여 데이터 마이닝 기반의 수요예측 모형을 제안하였다. Chi Nguyen 등은 네트워크 데이터 속도, 대기 시간 및 요구 사항을 보완할 필요성을 인식하고 CNN (Convolutional Neural Network)-LSTM을 결합한 융합 알고리즘을 사용한 바 있다[11]. Xu Gao는 5G 네트워크의 효율적인 자원 성능을 달성하기 위해 GCN (Graph Convolution Network)-LSTM 모델을 사용했다[12]. 해당 연구 결과는 제안된 모델이 스펙트럼 데이터 처리량을 효과적으로 개선한다는 것을 보여주었다. Xianyun Wen은 Attention-incorporated LSTM을 사용하여 시퀀스 데이터 간의 상호 관계를 효과적으로 계산한 바 있다[13]. 해당 연구는 데이터 예측의 정확도를 향상시키는 데 효과적으로 적용될 수 있다고 판단하였다. 이러한 방식으로 LSTM이 파생되어 다양한 분야의 방법론으로

활용될 수 있다. 황선우 등은 화물 보관장치를 연구 대상으로 선정하여, 운영 신뢰성 확보를 위한 예지정비 연계 방안을 제시한 바 있지만, 예지정비를 통한 실제 검증에 대한 한계가 존재하였다[14]. 이처럼 예지정비 분야는 국방, 항공 등 산업별로 다양한 접근을 통해 수행되고 있는 시점이지만, 물류 산업에 활용되는 로봇 및 시스템을 대상으로 예지정비를 수행한 사례는 미미하였다.

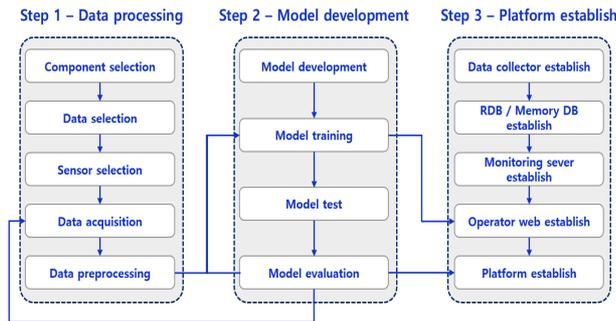
2.1 선행연구 고찰을 통한 문제 정의

기존에 수행된 예지정비 연구들은 일반적으로, 국방이나 항공 등 산업 분야에 적용되었으며, 현재까지 물류 자동화 장비에 대한 연구는 미미한 실정이다. 그러나, 물류 산업의 팽창으로 인하여, 물류 자동화 장비에 대한 수요는 증가하고 있다. 현대의 물류 산업은 다양한 기술들이 접목된 첨단 산업 분야이다. 일반적으로, 다양한 기술들이 접목될수록 시스템의 복잡도는 증가하고, 결함 및 고장 발생률도 증가한다. 이러한 물류 자동화 장비 증가 수요에 맞게, 물류 자동화 장비에 특화된 예지정비 모델이 필요한 시점이다. 본 논문의 연구 대상인 화물 상차 시스템은 전통적인 방식의 물류 시스템이 아닌, 새로운 개념이 융합된 물류 시스템이므로, 설계 혹은 운영 단계에서 식별하지 못한 잠재적인 고장 및 결함이 발생할 수 있다. 최근에는 우리나라 물류 산업의 팽창에 따라, 다양한 산·학계 인공지능 연구 기관에서 물류 장치를 대상으로 예지정비를 연계하는 연구가 진행될 바 있다. 하지만, 해당 연구들의 경우, 예지정비 연계에 대한 개념 단계에 머물러있기에 실제 적용을 위해서는 한계가 존재한다. 또한, 예지정비 플랫폼에 활용되는 LSTM 모델은 예측의 기간이 길어질수록, 예측 성능이 낮아질 수 있는 한계가 존재한다. 따라서, 본 논문은 화물 상차 시스템의 고장 및 결함을 예측하고, 운영 안전성 및 신뢰성을 높이기 위하여, 화물 상차 시스템에 특화된 예지정비 플랫폼 구축을 목표로 수행되었으며, 추가로, 예지정비 성능의 고도화를 위한 Naive Bayes 방법론을 연계하여, LSTM 모델의 보정 모델을 추가로 제시하였다.

2.2 연구 절차

본 논문은 화물 상차 시스템의 운영 안전성 및 신뢰성 확보를 위하여, 고장 및 결함 예측 기반 예지정비 플랫폼 구축과 LSTM 모델 보정을 위한 Naive Bayes 방법의 연계 제시를 목표로 수행되었다. 먼저, 본 논문의 1장에서는 물류 산업에 대한 배경을 논의하고, 물류 산업 팽창으로 인한 물류 자동화 장비의 수요 증가를 기술하였다. 또한, 화물 상차 시스템이 필요한 배경과 본 연구의 대상 시스템

이 가지는 핵심 기능 및 구성에 대한 논의를 진행하였다. 2장에서는 일반적인 예지정비 모델에 대한 논의를 진행하였다. 일반적으로, 예지정비는 머신러닝, 딥러닝 등을 활용한다는 점을 파악하였으며, 머신러닝 모델은 다양하게 활용되었으나, 딥러닝 모델의 경우, LSTM 등의 시계열 예측 모델을 활용한다는 점의 파악하였다. 그리고, 물류 자동화 장비에 특화된 예지정비 모델 구축의 한계와 필요성을 논의하였다. 또한, 현재 예지정비에 활용된 LSTM 모델의 보정 필요성을 고찰하여, 본 연구의 목적 및 개선방안에 대한 의의를 논의하였다. 3장에서는 화물 상차 시스템에 특화된 예지정비 모델 구축에 대한 방법과 프로세스에 대해 논의하였다. 본 논문에서는 메인 컨베이어 모터를 대상으로 선정하여, LSTM 기반의 시계열 예측 모델을 적용하였으며, LSTM 모델의 예지정비 성능 보정을 위한 방안으로, Naive Bayes 방법론의 연계를 제시하였다. 4장에서는 LSTM을 활용한 예지정비 플랫폼의 기능 정의 및 기능 흐름 등 구축에 대한 구체적인 논의를 수행하였고, Naive Bayes 방법론 연계를 통한 LSTM 기반 예지정비 플랫폼의 구축 결과 논의 및 성능 검증을 수행하였다. 5장에서는 본 논문이 포함하고 있는 의미와 기대효과 및 추후 연계성을 논의하였다. <그림 2>는 본 논문의 3장 내용인 화물 상차 시스템에 특화된 예지정비 플랫폼 구축을 위한 절차를 보여준다.



[Figure 2] Development step of predictive maintenance platform

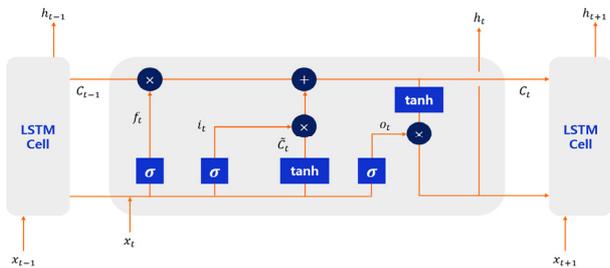
3. 화물 상차 시스템의 운영 안정성/신뢰성 확보를 위한 예지정비 플랫폼 구축

3.1 Long Short-Term Memory 모델

기존 시계열 분석 연구에서 범용적으로 활용되어왔던 딥러닝 모델인 RNN(Recurrent Neural Network)은 길이가 긴 시계열 데이터를 학습할 경우, 신경망의 깊이가

깊어 지게 되어 기울기가 소실되거나, 기울기가 무한대로 발산하는 장기 의존성 문제를 갖고 있다. 즉, 초기 입력값으로 들어온 데이터가 연산 과정을 거치면서 점차 데이터의 출력값이 오염산되는 단점을 갖고 있다. 이러한 문제는 길이가 짧은 시계열 데이터 예측엔 문제를 발생시키지 않지만, 길이가 긴 시계열 데이터 예측엔 문제를 발생시킬 수 있다. 예측 대상과 경우에 따라 범위가 다를 수 있지만, 일반적으로, 예지정비는 최소 수십 여일 이상의 정상/비정상 데이터를 학습해야 한다. 즉, RNN은 기울기 소실 및 발산 문제로 인하여 예지정비 모델에 적합하지 않다. 따라서, 본 논문의 예지정비 플랫폼의 분석 모델은 LSTM을 활용하였다. LSTM은 이러한 RNN의 단점을 해결하기 위해 고안된 기술이다[15]. <그림 3>은 LSTM의 구조를 나타낸다. <그림 3>의 C, t, x, h 는 각각 Cell state, time step, 입력값, 출력값을 의미하며, f, i, o 는 각각 망각 게이트, 입력 게이트, 출력 게이트를 의미한다. RNN에서 발생하던 장기 의존성 문제는 LSTM이 포함하고 있는 3가지 게이트와 Cell state를 통해 해결될 수 있다. 여기서, LSTM의 Cell state는 다음 LSTM Cell로 정보를 그대로 전달하는 역할을 수행한다. 수식 1, 2, 3, 4의 W 와 b 는 각각 가중치 행렬과 편향 벡터를 나타낸다. 수식 1은 망각 게이트 연산을 의미하며, 이전 시점으로부터 전달받은 Cell state의 정보 중에서 삭제할 정보를 정하는 역할을 수행한다. 망각 게이트는 이전 시점의 은닉 상태인 h_{t-1} 과 현재 시점의 입력인 x_t 를 입력으로 받아 활성화 함수를 적용한 값을 출력으로 갖게 된다. 이러한 망각 게이트의 출력은 활성화 함수가 적용되었기 때문에 0과 1사이의 값을 가지며, 이 값이 클수록 Cell state의 정보가 오래 유지되고 이 값이 작을수록 정보가 빠르게 삭제된다. 수식 2는 입력 게이트 연산을 의미하며, 전달받은 이전 시점의 Cell state 중, 사용할 정보를 결정하는 역할을 수행한다. 수식 4의 \tilde{C}_t 가 Cell state에 더해질 새로운 후보값들에 해당하고, 입력 게이트의 출력은 수식 5에서 \tilde{C}_t 와 곱해서 사용할 정보가 결정된다. 수식 3은 출력 게이트 연산을 의미하며, 업데이트된 Cell state에서 출력값을 결정하는 역할을 수행한다. 최종적으로 수식 5에서 망각 게이트의 출력값과 이전 시점의 Cell state에 Element-wise-product가 수행되어 이전 시점의 Cell state에서 사용할 정보가 결정되고 입력 게이트의 출력값과 Cell state에 더해질 후보값들에 Element-wise-product가 수행되어 후보값들 중 사용할 정보가 결정된다. 이러한 두 개의 값으로 업데이트된 Cell state에 Hyperbolic Tangent 함수가 적용된값과 출력 게이트의 출력값에 Element-wise-product가 수행되기에, 현재 시점의 출력값이 계산되어 다음 시점으로 전달된다. 이와

같은 데이터 계산이 매 시점마다 수행되며, 마지막 시점에서 수행된 계산의 결과가 예측값에 해당한다. 그러나, 이러한 LSTM 모델 자체도 예측 기간이 길어짐에 따라, 완벽하지 않는 성능을 보이기에, 이를 보정하기 위한 모델이 필요하다. 따라서, 본 논문에서는 화물 상차 시스템의 고장 및 결함 예측에 LSTM 모델을 활용하고, 이를 보정하기 위한 방안으로 Naive Bayes 방법론을 적용하였다.



[Figure 3] Conceptual diagram of LSTM model

$$f_t = \sigma[W_f \cdot (h_{t-1}, x_t) + b_f] \quad (1)$$

$$i_t = \sigma[W_i \cdot (h_{t-1}, x_t) + b_i] \quad (2)$$

$$o_t = \sigma[W_o \cdot (h_{t-1}, x_t) + b_o] \quad (3)$$

$$\tilde{C}_t = \tanh[W_C \cdot (h_{t-1}, x_t) + b_c] \quad (4)$$

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t \quad (5)$$

3.2 Naive Bayes 보정 모델

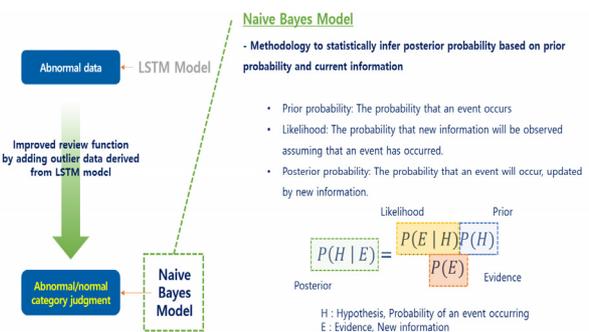
앞서 언급한 바와 같이, 본 연구에서 제시하고자 하는 예지정비의 핵심인 LSTM 모델은 예측 기간이 길어짐에 따라, 예지정비 성능이 감소할 수 있는 가능성이 존재한다. 따라서, LSTM 모델 성능을 보완해줄 수 있는 추가적인 보정 모델과의 연계가 필요하다. 본 논문에서는 LSTM의 보정 모델로써, Naive Bayes 모델의 연계 방안을 제시하였다. 머신러닝 기법 중 하나인 Naive Bayes 모델은 범용적으로, 데이터의 분류를 위한 목적으로 활용된다. 이러한 Naive Bayes의 기본 원리는 조건부 확률에 Baye's 정리를 적용하고, 이를 구성하는 정보의 각각의 요소들이 등장할 확률에 대한 독립성을 가정하여, 입력 벡터를 확률적으로 분류할 수 있다[16]. 즉, 특정 새로운 데이터를 기준에 설정한 기준을 바탕으로, 어떠한 분류 그룹에 속할지를 확률적으로 계산하는 방안이다. 정하림 등은 교통사고가 인적요인, 차량요인, 환경요인 등이 복합적으로 작용하

며, 렌터카 교통사고에 대한 발생 가능성과 심각도가 다르다는 점을 인지하였다 [17]. 따라서, 해당 연구는 교통사고 발생 가능성과 심각도를 분류하기 위한 목적으로, Naive Bayes 빅데이터 분류기를 이용한 렌터카 교통사고의 심각도 예측 연구를 수행한 바 있다. 또한, 본 연구와 비슷한 사례로써, 강성관 등은 Naive Bayes 분류기를 이용한 돌발상황 검지 알고리즘 개발 연구를 수행하였다. 해당 연구는 교통 분야에서 돌발상황에 영향을 줄 수 있는 변수의 여러 가지 조합을 통해 시나리오를 설정하여, 가상의 돌발상황 데이터를 수집하였다. 수집된 돌발상황 데이터를 활용하여, 교통 시뮬레이션의 돌발상황 검지를 수행한 결과, Naive Bayes 분류 모델이 돌발상황 검지에 적합하다는 결론을 도출하였다. 이렇듯 Naive Bayes 모델은 다양한 산업 분야에서 데이터 분류를 위한 방안으로 활용되고 있는 시점이다[19 - 20].

본 논문에서는 사전 확률과 현재의 데이터를 토대로 사후 확률을 통계적으로 추론하는 Naive Bayes의 원리를 LSTM이 판별한 이상값 데이터의 정상/비정상 범주를 재 판단하는 기능에 활용하였다. 수식 6은 Naive Bayes 적용 방정식을 의미한다.

$$P(H | E) = \frac{P(E | H)P(H)}{P(E)} \quad (6)$$

여기서, P(H)는 사전 확률을 의미하고, P(E|H)는 가 능도, P(H|E)는 사후 확률을 의미한다. 사전 확률이란 어떠한 사건이 발생한 확률을 의미하며, 가능도란 사건이 발생했다는 가정하에 새로운 정보가 관측될 확률을 의미한다. 마지막으로, 사후 확률은 새로운 정보에 의해 갱신된 사건이 발생할 확률을 의미한다. 본 연구에서는 이러한 Naive Bayes의 원리를 적용하여, 예지정비 핵심 요소인 LSTM 모델을 보완하는 보정 모델을 연계하였다.

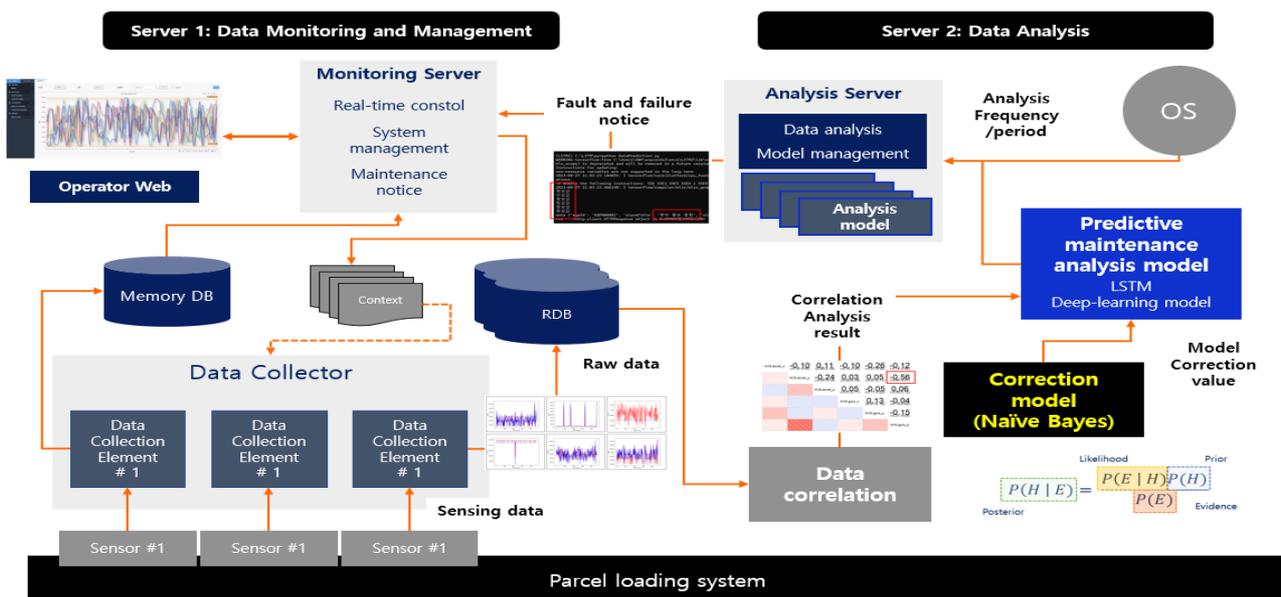


[Figure 4] Naive Bayes-LSTM concept for enhancing predictive maintenance performance

3.3 화물 상차 시스템 예지정비 플랫폼 구축

<그림 5>는 화물 상차 시스템의 예지정비 플랫폼을 보여준다. 예지정비 플랫폼 구축의 첫 번째 단계는 정상/비정상 데이터의 수집이다. 먼저, 데이터 수집은 데이터를 분석하거나, 의사결정을 내리는데 활용하기 위해서 데이터를 모으는 작업이다. 데이터 수집은 데이터의 가공과 저장을 포함하기도 한다. 데이터를 수집하기 위해서는 수집할 데이터의 빈도, 저장 형태 등을 고려해야 한다. 예지정비를 수행하기 위해서는 고장 및 결함에 해당하는 Raw 데이터 수집이 필요하다. 본 연구에서는 화물 상차 시스템의 핵심 요소인 컨베이어 메인 모터를 대상으로, 3축 가속도 및 Gyro 데이터를 수집하였다. 본 연구에서는 수집 및 모니터링 등 데이터 관리를 위한 서버와 데이터 기반 고장 및 결함 분석을 통해 모니터링 서버로 알람을 주는 분석 서버를 별도로 구분하였다. 먼저, Raw 데이터를 수집하기 위하여, json 형태의 Context 포맷 기반 데이터 Collection element를 활용하였다. Json 형태의 Context는 메타 데이터 등 수집되는 데이터의 기본적인 정보를 제공할 수 있다. 수집된 Raw 데이터는 데이터 Collector의 세부 요소인 데이터 Collection element를 거쳐, 각각 RDB (Relational Database)와 Memory DB (Database)로 전달된다. RDB로 전달하는 프레임워크는 별도의 java 프레임워크를 활용하였다. Memory DB는 실시간 데이터 수집 상황 등 데이터 모니터링 및 관리를 위한 용도로 활용하였고, RDB는 고장 및 결함 예측 등 예지정비 데이터 분석을 위한 용도로 활용하였다. 고장 및 결함 등 예지정비 분석을 위해서 RDB에 저장된 Raw 데

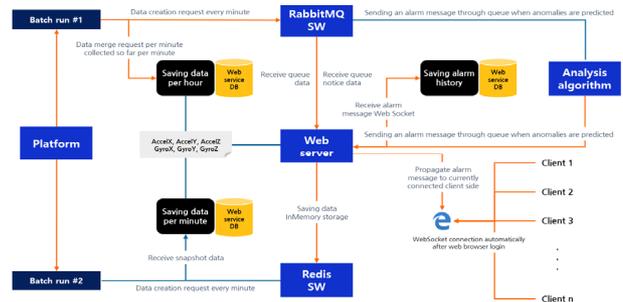
이터를 통해 데이터 Correlation을 수행하였고, 이를 통해, 각각의 데이터 간의 상관관계를 검토하였다. 실시간으로 수집되는 Raw 데이터는 LSTM 모델로 전달되며, 특정 분석 횟수 및 기간에 따라, 시계열 기반의 데이터 분석을 수행한다. 또한, LSTM의 고장 및 결함 예측 성능을 높이기 위하여, Naive Bayes 모델을 기반으로 LSTM 모델을 보정하는 별도의 Correction 모델을 활용하였다. 실시간으로 RDB에 전달되는 데이터 분석을 통해, 분석 서버는 고장 및 결함 발생 시, 모니터링 서버에 알람을 주는 기능을 수행한다. 마지막으로, 모니터링 서버는 운영상 효율을 위해 웹으로 구성하였다. 예지정비 플랫폼을 구현하기 위해서는 각각에 해당하는 기능들을 정의해야 한다. 먼저, 기능은 장비 데이터 생성과 알람 데이터 생성으로 분류할 수 있다. 장비 데이터 생성은 배치 스케줄러를 통한 장비 데이터를 생성하는 분당 장비 데이터 요청 기능 (RabbitMQ로 데이터 요청), Rabbit MQ로 데이터를 송신하는 데이터 송신 기능 (InMemory 방식으로 Redis에 데이터 저장), 배치 스케줄러를 통한 장비 Snapshot 요청을 수행하는 분당 데이터 저장 기능 (요청한 Snapshot 데이터를 DB에 저장), DB에 저장된 장비별 분당 데이터를 요청하는 시간당 데이터 통합 기능 (분당 데이터를 시간당 데이터로 변환 후 DB에 저장)을 포함한다. 알람 데이터 생성은 알고리즘 서버에서 API (Application Programming Interface)를 통한 알람을 요청하는 알람 데이터 요청 기능 (RabbitMQ를 통한 알람 요청), Web socket을 통한 알람을 수신하는 알람 데이터 수신 기능 (알람 수신 후 알람 이력 DB에 저장), 웹 Socket을 통한 알람 메시지를 수신하는 수신된 알람 웹 서비스 기능 (수신된 알람 메시지를 웹 메인 화면에 표시)을 포함한다.



[Figure 5] Platform architecture of predictive maintenance for parcel loading system

<표 1>은 화물 상차 시스템의 예지정비 플랫폼을 구현하기 위한 메인 기능을 보여준다. 메인 기능 외에도 각각의 DB들은 하위 기능들을 포함하고 있다. 각각의 DB는 사용자 정보를 저장하고, 일반 사용자, 시스템 관리자를 구분하여 관리하는 사용자 테이블, 알람 정보를 저장할 수 있다. 또한, 장비 기준으로 발생한 알람을 관리하는 알람 테이블, 장비 정보를 저장하고 장비 스펙에 따라 테이블 구조 변경 기능을 제공하는 장비 테이블, 분당 장비 데이터 정보를 저장하고, 데이터 수집 정보에 따라, 테이블 구조 변경 기능을 제공하는 분당 장비 데이터 테이블 등으로 구성된다. 웹 서비스 기능은 사이트 관리 및 장비 매핑 관리를 수행하는 사이트 관리 기능, 카테고리 관리 및 그룹 관리를 수행하는 시스템 관리 기능, 분 단위 및 시간 단위 모니터링 현황을 차트 형식으로 제공하는 모니터링 관리 기능이 포함된다. 본 연구의 화물 상차 시스템 예지정비 프로세스는 먼저, 플랫폼 서버에서 두 가지의 배치 실행으로 시작된다. 첫 번째 배치 실행은 RabbitMQ에 1분마다 장비 데이터를 생성하도록 요청하는 배치 실행이며, 1분마다 수집된 장비 데이터를 통합 요청하고 웹 서비스 DB에 저장한다. 두 번째 배치 실행은 Redis에 1분마다 장비 Snapshot 데이터를 요청하고 웹 서비스 DB에 수신한다. 분석 알고리즘 서버는 화물 상차 시스템의 이상 징후 예측 시, Queue를 통한 알람 메시지를 RabbitMQ와 웹 서버에 송신한다. 이 과정에서 알람 메시지 웹 Socket은 웹 서비스 DB에 알람 이력으로 저장된다. 또한, RabbitMQ는 Queue 장비 및 알람 데이터를 다시 웹 서버에 수신하고, 웹 서버는 Redis에 장비 데이터 InMemory 저장을 요청한다. 이 과정에서 웹 서버는 실시간으로 연결된 Client측으로 알람 메시지를 전파하고, Client는 해당 메시지를 수신할 수 있다. <그림 6>는 화물 상차 시스템의 예지정비를

운영자 관점에서 활용이 용이하도록 구축한 웹의 기능 흐름도를 보여준다.



[Figure 6] Main function flow diagram of predictive maintenance platform

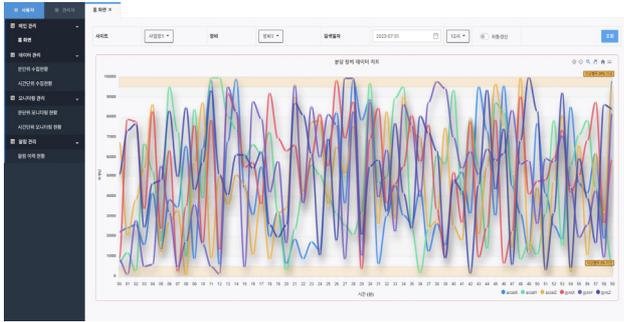
4. 화물 상차 시스템의 예지정비 플랫폼 구축 및 검증 결과

4.1 예지정비 플랫폼 웹 구축 결과 평가

<그림 7>은 화물 상차 시스템의 예지정비 플랫폼의 데이터 수집 및 모니터링 화면을 통해 고장 및 결함에 대한 알람 서비스를 제공할 수 있는 웹 구성을 보여준다. 예지정비 플랫폼은 RabbitMQ 기반의 정상/비정상 데이터를 수집 및 수신을 통해, Redis 활용 InMemory 방식으로 데이터를 적재하고, Snapshot 데이터 DB를 실시간으로 운용하며 작동한다. 먼저, 해당 DB는 검색일자 기준으로 선택된 장비에 수신된 데이터를 차트 형식으로 표현하는 기능을 구현하였다.

<Table 1> Main function of predictive maintenance platform for logistics loading system

Classification	Function	Contents
Generate equipment data	Data request per minute	- Equipment data generation through batch scheduler - Data request with RabbitMQ
	Receive Data	- Receive data with RabbitMQ SW - Storing data in Redis SW (InMemory)
	Save data per minute	- Equipment Snapshot request via Batch Scheduler - Save requested Snapshot data to DB
	Data merge per hour	- Data requests per minute per equipment stored in DB - Data per minute → Save to DB after converting hour data
Generate notice data	Request notice data	- notice request through API from algorithm server - notice request through RabbitMQ SW
	Receive notice data	- Receiving notices via Web Socket - After receiving an notice, it is stored in the notice history DB
	Received notice web service	- Receive notice message via Web Socket - Received notice message displayed on the web main screen



[Figure 7] Fault and defect detection web for parcel loading system

데이터 항목은 가속도 및 Gyro 3축에 해당하는 6개의 포인트를 기준으로 각각 차트에 표시되며, 화면 표시 내용 중 이상값이라고 판단된 경우, 해당 포인트에 빨간색으로 강조 표시된다. 이상값 표시 기준은 높은 구간 (높은 구간 (95%) : 측정값 > 최대값 - (중간값 * 5%))과 낮은 구간 (낮은 구간(5% 미만) : 측정값 < 최소값 + (중간값 * 5%)) 2가지 경우를 산정하였다. 데이터는 1분 단위를 기준으로 새로운 데이터를 요청하여 기본적으로 자동 갱신을 통해 화면에 표시된다. 본 논문의 연구 대상인 화물 상차 시스템은 여러 곳의 물류센터에 배치될 예정이기에, 각각 관리가 필요하다. 따라서, <그림 7>의 데이터 수집 및 알림 웹 외에도, 시스템별 DB 이력 현황, 관리 및 제어 등을 수행할 수 있는 기능들을 포함하여 예지정비 플랫폼을 구축하였다. <그림 8>은 수집된 데이터 로그 중 이상 데이터의 강조 알림을 나타낸다. 수집된 데이터는 수집 범위를 판단하여, 초당 데이터, 분당 데이터, 시간당 데이터 등 다양한 관점에서 모니터링이 가능하다. 또한, 특정 포인트를 기준으로 범위를 지정하거나, 특정 값에 강조할 수 있는 기능을 추가하였다. 또한, 3개 이상의 포인트를 동시에 표시하여, 해당 포인트간 어떠한 관계가 있는지 확인할 수 있는 기능을 추가하였다.

시작하기				데이터				분석				설정				로그아웃			
No	시작시간	종료시간	상태	No	시작시간	종료시간	상태	No	시작시간	종료시간	상태	No	시작시간	종료시간	상태	No	시작시간	종료시간	상태
1	2023-07-01 00:00:00	2023-07-01 01:00:00	정상	1	2023-07-01 00:00:00	2023-07-01 01:00:00	정상	1	2023-07-01 00:00:00	2023-07-01 01:00:00	정상	1	2023-07-01 00:00:00	2023-07-01 01:00:00	정상	1	2023-07-01 00:00:00	2023-07-01 01:00:00	정상
2	2023-07-01 01:00:00	2023-07-01 02:00:00	이상	2	2023-07-01 01:00:00	2023-07-01 02:00:00	이상	2	2023-07-01 01:00:00	2023-07-01 02:00:00	이상	2	2023-07-01 01:00:00	2023-07-01 02:00:00	이상	2	2023-07-01 01:00:00	2023-07-01 02:00:00	이상
3	2023-07-01 02:00:00	2023-07-01 03:00:00	정상	3	2023-07-01 02:00:00	2023-07-01 03:00:00	정상	3	2023-07-01 02:00:00	2023-07-01 03:00:00	정상	3	2023-07-01 02:00:00	2023-07-01 03:00:00	정상	3	2023-07-01 02:00:00	2023-07-01 03:00:00	정상
4	2023-07-01 03:00:00	2023-07-01 04:00:00	이상	4	2023-07-01 03:00:00	2023-07-01 04:00:00	이상	4	2023-07-01 03:00:00	2023-07-01 04:00:00	이상	4	2023-07-01 03:00:00	2023-07-01 04:00:00	이상	4	2023-07-01 03:00:00	2023-07-01 04:00:00	이상
5	2023-07-01 04:00:00	2023-07-01 05:00:00	정상	5	2023-07-01 04:00:00	2023-07-01 05:00:00	정상	5	2023-07-01 04:00:00	2023-07-01 05:00:00	정상	5	2023-07-01 04:00:00	2023-07-01 05:00:00	정상	5	2023-07-01 04:00:00	2023-07-01 05:00:00	정상
6	2023-07-01 05:00:00	2023-07-01 06:00:00	이상	6	2023-07-01 05:00:00	2023-07-01 06:00:00	이상	6	2023-07-01 05:00:00	2023-07-01 06:00:00	이상	6	2023-07-01 05:00:00	2023-07-01 06:00:00	이상	6	2023-07-01 05:00:00	2023-07-01 06:00:00	이상
7	2023-07-01 06:00:00	2023-07-01 07:00:00	정상	7	2023-07-01 06:00:00	2023-07-01 07:00:00	정상	7	2023-07-01 06:00:00	2023-07-01 07:00:00	정상	7	2023-07-01 06:00:00	2023-07-01 07:00:00	정상	7	2023-07-01 06:00:00	2023-07-01 07:00:00	정상
8	2023-07-01 07:00:00	2023-07-01 08:00:00	이상	8	2023-07-01 07:00:00	2023-07-01 08:00:00	이상	8	2023-07-01 07:00:00	2023-07-01 08:00:00	이상	8	2023-07-01 07:00:00	2023-07-01 08:00:00	이상	8	2023-07-01 07:00:00	2023-07-01 08:00:00	이상
9	2023-07-01 08:00:00	2023-07-01 09:00:00	정상	9	2023-07-01 08:00:00	2023-07-01 09:00:00	정상	9	2023-07-01 08:00:00	2023-07-01 09:00:00	정상	9	2023-07-01 08:00:00	2023-07-01 09:00:00	정상	9	2023-07-01 08:00:00	2023-07-01 09:00:00	정상
10	2023-07-01 09:00:00	2023-07-01 10:00:00	이상	10	2023-07-01 09:00:00	2023-07-01 10:00:00	이상	10	2023-07-01 09:00:00	2023-07-01 10:00:00	이상	10	2023-07-01 09:00:00	2023-07-01 10:00:00	이상	10	2023-07-01 09:00:00	2023-07-01 10:00:00	이상
11	2023-07-01 10:00:00	2023-07-01 11:00:00	정상	11	2023-07-01 10:00:00	2023-07-01 11:00:00	정상	11	2023-07-01 10:00:00	2023-07-01 11:00:00	정상	11	2023-07-01 10:00:00	2023-07-01 11:00:00	정상	11	2023-07-01 10:00:00	2023-07-01 11:00:00	정상
12	2023-07-01 11:00:00	2023-07-01 12:00:00	이상	12	2023-07-01 11:00:00	2023-07-01 12:00:00	이상	12	2023-07-01 11:00:00	2023-07-01 12:00:00	이상	12	2023-07-01 11:00:00	2023-07-01 12:00:00	이상	12	2023-07-01 11:00:00	2023-07-01 12:00:00	이상
13	2023-07-01 12:00:00	2023-07-01 13:00:00	정상	13	2023-07-01 12:00:00	2023-07-01 13:00:00	정상	13	2023-07-01 12:00:00	2023-07-01 13:00:00	정상	13	2023-07-01 12:00:00	2023-07-01 13:00:00	정상	13	2023-07-01 12:00:00	2023-07-01 13:00:00	정상
14	2023-07-01 13:00:00	2023-07-01 14:00:00	이상	14	2023-07-01 13:00:00	2023-07-01 14:00:00	이상	14	2023-07-01 13:00:00	2023-07-01 14:00:00	이상	14	2023-07-01 13:00:00	2023-07-01 14:00:00	이상	14	2023-07-01 13:00:00	2023-07-01 14:00:00	이상
15	2023-07-01 14:00:00	2023-07-01 15:00:00	정상	15	2023-07-01 14:00:00	2023-07-01 15:00:00	정상	15	2023-07-01 14:00:00	2023-07-01 15:00:00	정상	15	2023-07-01 14:00:00	2023-07-01 15:00:00	정상	15	2023-07-01 14:00:00	2023-07-01 15:00:00	정상

[Figure 8] Abnormal data occurrence log

4.2 Naive Bayes-LSTM 연계 예지정비의 성능 검증

예지정비 플랫폼은 Naive Bayes-LSTM 모델을 활용하며, 빅데이터를 취급하기 때문에, 하드웨어 구축 환경 조성도 중요한 요소이다. 또한, 화물 상차 로봇 시스템은 고객의 요구에 따라서, 인도 및 설치되어 운영되는 환경이 제각기 다를 수 있기 때문에, 하드웨어 및 통신 성능이 중요한 요소이다. 즉, 운영 도중 고장 및 결함 등의 부정적인 요소 때문에 발생할 수 있는 비정상 상황을 신속히 식별해야 한다. 따라서, 본 연구에서는 비교적 고성능 컴퓨팅 성능을 활용하여 예지정비 플랫폼을 구축하였다. 예지정비 플랫폼 구축에 활용한 프로세서는 13th Gen Intel(R) Core(TM) i5-13400F(2.5GHz), RAM은 32.0GB, 운영 시스템은 Windows 11 Pro 64비트 운영 체제를 활용하였다. LSTM 모델 개발 환경은 pycharm Community 버전 및 Anaconda3를 활용하였으며, 개발 언어는 Python 3.8.16 버전과 Tensorflow2를 활용하였다. 모델 개발과 관련된 라이브러리는 pymysql, numpy, tf_slim, pandas, matplotlib 등을 활용하였다. 본 연구에서는 화물 상차 로봇 시스템의 시장성 확장을 위한 방안으로, 제시한 예지정비 플랫폼 구축 결과의 검증을 수행하였다. 검증 방안으로는 정상값/이상값을 판단하는 예지정비 플랫폼의 기능 수행 완료 유무를 확인하였으며, 기존의 모델과는 다르게 Naive Bayes 방법론 연계를 통하여, LSTM에서 도출된 정상값/이상값을 재판별하는 보정 모델의 기능 수행 완료 유무로 확인하였다. 데이터 수집/저장/처리 관점에서는 1,000건 기준 1초 이내 데이터 수집/저장/처리가 가능한 성능을 만족하였다. 또한, 분석 관점에서는 데이터 상관관계 분석 시 0.5초 이내에 결과를 도출할 수 있는 성능을 만족하였다. <그림 9>는 예지정비 플랫폼의 수행 결과를 보여준다.

```
(LSTM2) C:\LSTM\py>python DataPrediction.py
WARNING:tensorflow:From C:\Users\SWH\anaconda3\envs\LSTM2\lib\site-packages\tensorflow\python\tensor_util.py:110: tf.nn.conv2d (with no nested structure) is deprecated and will be removed in a future version.
Instructions for updating:
non-resource variables are not supported in the long term
2023-09-27 21:03:23.184054: I tensorflow/core/platform/cpu_feature_guard.cc:182] Please set GPU options.
2023-09-27 21:03:23.1846148: I tensorflow/compiler/mlir/mlir_graph_optimization_settings.cc:104] MlirOptimizationSettings are not supported in this mode.
정상값
이상값
정상값
정상값
정상값
정상값
data {'eqpId': 'EQP000001', 'alarmTitle': '정비 필요 알림', 'alarmContent': '정비 필요 알림'}
res = http.client.HTTPResponse object at 0x00000323498FA260>
```

[Figure 9] Verification of predictive maintenance

5. 결론

근래에는 맞벌이, 고령화, 1인 가구의 증가 등 사회구조의 급격한 변화로 인해 비대면 배송 서비스 시장이 폭발적으로 성장하고 있는 시점이다. 또한, 스마트폰 등 모바일 기기의 보급으로 급격한 생활 방식의 변화로 인하여, 지속적으로 온라인 커머스 산업이 성장하고 있다. 이에 따라, 소비 트렌드 변화가 지속되고 있으며, 새벽 배송 등 다중, 소화물 택배 화물 처리 수요가 지속적으로 증가하고 있는 시점이다. 이렇듯, 물류 산업의 팽창으로 인하여, 물류 자동화 장비에 대한 수요는 증가하고 있다. 현대의 물류 산업은 다양한 기술들이 접목된 첨단 산업 분야이다. 일반적으로, 다양한 기술들이 접목될수록 시스템의 복잡도는 증가하고, 결함 및 고장 발생률도 증가한다. 이러한 물류 자동화 장비 증가 수요에 맞게, 물류 자동화 장비에 특화된 예지정비 모델이 필요한 시점이다. 본 논문에서는 화물 상차 시스템의 고장 및 결함을 사전에 예측을 위한 기반 데이터인 정상/비정상 데이터 수집 및 분석, 처리를 위한 플랫폼을 구축하였다. 또한, 이를 통해 화물 상차 시스템의 운영 안전성 및 신뢰성을 확보하기 위하여, LSTM 모델을 기반으로, 사전에 학습된 빅데이터로 고장 및 결함을 사전에 예측할 수 있는 예지정비 시스템을 구현하였다. 예지정비를 위한 세부 사항으로는 화물 상차 시스템의 핵심 요소인 컨베이어 Main motor를 대상으로, 3축 가속도 및 Gyro 데이터를 수집하였다. 수집 본 논문에서는 수집 및 모니터링 등 데이터 관리를 위한 서버와 데이터 기반 고장 및 결함 분석을 통해 모니터링로 알람을 주는 분석 서버를 별도로 구분하였다. 본 논문에서 제시한 예지정비 플랫폼은 화물 상차 시스템을 대상으로, RabbitMQ 기반의 정상/비정상 데이터를 수집 및 수신을 통해, Redis 활용 InMemory 방식으로 데이터를 적재하고, Snapshot 데이터 DB를 실시간으로 운용하며 작동한다. 본 논문은 물류 장비에 활용된 예지정비 플랫폼이 부족한 현 시점에, 물류 장비 대상 예지정비 플랫폼을 구축했다는 점에서 의의가 있다. 다만, 일반적으로 예지정비에 활용되는 LSTM 모델만을 활용했다는 점에서 모델 성능 비교에 대한 한계가 존재하며, 메모리 장기의존성 문제로 기존 RNN 모델을 활용하지 않았다. 이에 대한 보완 사항으로, Naive Bayes 모델을 연계하여, LSTM 모델을 보정하는 모델을 추가하여 플랫폼을 구축하였다. 본 연구에서는 화물 상차 운영 안전성 및 신뢰성 확보를 위한 방안으로, 데이터 수집/저장/처리 성능 등을 활용하여, 제시한 예지정비 플랫폼 구축 결과의 검증을 수행하였다. 본 연구의 한계점으로써는 예지정비 플랫폼의 입력 데이터로 가속도 및 Gyro 데이터를 활용하였으나, 추후, 수집 데이터의 종류를 확장하여,

진동외에, 전류, 소음 등을 추가로 수집하여, 이에 대한 연관성을 분석하고 성능을 고도화할 계획이다. 또한, 본 연구의 추후, 후속 연구로 본 논문의 연구 결과로 제시된 플랫폼의 성능 비교를 위한 연구를 진행할 예정이다. 본 논문의 연구 결과로 제시된 LSTM 기반 예지정비 플랫폼은 화물 상차 시스템의 운영상 발생할 수 있는 잠재적인 고장 및 결함을 식별함으로써, 신뢰성 및 안전성 확보에 기여될 수 있다.

6. References

- [1] T. M. Hwang, I. H. Youn, J. M. Oh(2021), "Study on text analysis of the liquefied natural gas carriers dock specification for development of the ship predictive maintenance model." *Journal of the Korean Society of Marine Environment & Safety*, 27(1):60-66.
- [2] I. H. Youn, J. K. Park, J. M. Oh(2021), "A study on the concept of a ship predictive maintenance model reflection ship operation characteristics." *Journal of the Korean Society of Marine Environment & Safety*, 27(1):53-59.
- [3] C. W. Hong(2022), "A study on the application of predictive maintenance using artificial intelligence and big data." *The Quarterly Journal of Defense Policy Studies*, 38(2):197-228.
- [4] K. M. Cheon, J. K. Yang(2021), "Explainable AI application for machine predictive maintenance." *Journal of Korean Society of Industrial and Systems Engineering*, 44(4):227-233.
- [5] K. H. Lee, J. Y. Lee, Y. M. Kim(2022), "A study on the maintenance data analysis of vehicle parts of Yongin light rail and condition-based prediction maintenance." *Journal of the Korea Society of Systems Engineering*, 18(1):1-13.
- [6] J. D. Lee, G. B. Kim, I. H. Song(2021), "A study on the predictive maintenance of smart factory through ML-Based analysis of vibration abnormal signal." *Journal of The Korea Society of Information Technology Policy & Management (ITPM)*, 13(6): 2723-2728.
- [7] C. S. Park, S. M. Bae(2020), "A study on the predictive maintenance of 5 Axis CNC machine tools for cutting of large aircraft parts." *Journal of Korean*

- Society of Industrial and Systems Engineering, 43(4):161-167.
- [8] J. D. Lee, H. S. Kim, J. H. Kim(2019), "A study on AI-based anomaly detection and defect classification for predictive maintenance of Gearb." Journal of The Korea Society of Information Technology Policy & Management (ITPM), 11(6): 1497-1502.
- [9] J. T. Kim, Y. W. Seo, S. S. Lee, S. J. Kim, Y. G. Kim(2021), "A proposal of remaining useful life prediction model for turbofan engine based on k-nearest neighbor." Journal of Korea Academia-Industrial Cooperation Society (JKAIS), 22(4):611-620.
- [10] J. D. Kim, H. J. Lee(2019), "A study on predictive model for forecasting anti-aircraft missile spare parts demand based on machine learning." Journal of the Korean Data And Information Science Society, 30(3):587-596.
- [11] C. Nguyen, T. M. Hoang, A. A. Cheema(2023), "Channel estimation using CNN-LSTM in RIS-NOMA assisted 6G network." IEEE Transactions on Machine Learning in Communications and Networking, 1:43-60.
- [12] X. Gao, J. Wang, M. Zhou(2023), "The Research of resource allocation method based on GCN-LSTM in 5G network." IEEE Communications Letters, 27(3):926-930.
- [13] X. Wen, W. Li(2023), "Time series prediction based on LSTM-attention-LSTM model." IEEE Access, 11:48322-48331.
- [14] S. W. Hwang, Y. M. Kim(2023), "On the establishment of LSTM-based predictive maintenance platform to secure the operational reliability of ICT/cold-chain unmanned storage." International Journal of Advanced Smart Convergence, 12(3):207-218.
- [15] S. Hochreiter, J. Schmidhuber(1997), "Long short-term memory." Neural Computation, 9:1735-1780.
- [16] B. Thomas, R. Price(1763), Philosophical transactions of the royal society of London. 53:370-418.
- [17] H. R. Jeong, H. H. Kim, S. M. Park, E. Han, K. H. Kim, I. S. Yun(2017), "Prediction of severities of rental car traffic accidents using naive bayes big data classifier." The Journal of the Korea Institute of Intelligent Transportation Systems, 16(4):1-12.
- [18] S. K. Kang, B. K. Kwon, C. W. Kwon, S. M. Park, I. S. Yun(2018), "Development of incident detection algorithm using naive bayes classification." The Journal of The Korea Institute of Intelligent Transportation Systems, 17(6):25-39.
- [19] H. J. Kim, J. Y. Jang(2008), "Improving naive bayes text classifiers with incremental feature weighting." KIPS Transactions on Software and Data Engineering, 15(5):457-464.
- [20] J. I. Kim, S. J. Park, H. G. Kim, J. H. Choi, H. I. Kim, P. K. Kim(2020), "Sensitivity identification method for new words of social media based on naive bayes classification." Smart Media Journal, 9(1):51-59.

저자 소개



황 선 우

현 아주대학교 일반대학원 시스템공학과 박사 과정.

관심분야: 첨단 융합 시스템, 시스템 예지정비, 모델기반 시스템공학, 안전성 분석 등.

주소: 경기도 수원시 영통구 월드컵로 206 아주대학교 성호관.



최 준 우

현 (주)노바 기업부설연구소 책임 연구원.

관심분야: AGV 개발, 스마트 물류, 스택 검사장비, 진동저감기술, 스마트팜, 수소연료전지 등.

주소: 경기 안성시 보개면 보개원삼로 548.



김 진 오

현 (주)코어데이터티 대표이사.

관심분야: 정형 데이터분석, AI 알고리즘 응용, 시스템통합(SI) SW 아키텍처 등.

주소: 서울특별시 금천구 가산디지털2로 166, 에이스K1타워.



김 영 민

현 아주대학교 일반대학원 시스템공학과 교수.

관심분야: 스마트 물류 체계 구축, 첨단 자율운송 시스템, 첨단 교통시스템 및 스마트시티 등.

주소: 경기도 수원시 영통구 월드컵로 206 아주대학교 성호관.