

유도무기 야전 데이터를 활용한 머신 러닝 기반의 정비예측 모델 연구

이동균*, 박장원, 조산희, 이종신
LIG넥스원 PGM IPS연구소

Maintainability Prediction of Guided Missile based on Machine Learning using Field Data

Dong-Kyoon Lee*, Jang-Won Park, San-Hee Cho, Jong-Sin Lee
Intergrated Product Support R&D, LIGNex1

요약 유도무기에 있어 정확한 정비예측은 불필요한 유지보수 활동을 감소시키고 가용도를 높임으로써 총수명주기비용을 절감시키고 전투준비태세를 강화시키는 효과를 가져온다. 본 연구에서는 머신 러닝기법을 활용하여 운용 중인 특정 유도탄이 정비가 언제 발생하는지, 정비요원이 현재 확보해야 할 수리부속은 무엇인지 예측이 가능한 모델을 연구하였다. 머신 러닝으로 분석할 데이터는 정비이력, 점검데이터, 수리부속사용 실적 등 10년 간 수집된 야전데이터를 사용하였다. 머신 러닝에 적합한 데이터 형태를 갖추기 위하여 데이터 결측값, 이상치 처리 등 데이터 전처리를 수행하였고, 알고리즘 모델에서 쉽게 접근할 수 있도록 데이터를 통합하였다. 정비예측에 사용하는 머신 러닝 분류 알고리즘으로는 XGBoost, LightGBM, Catboost를 선정하였고, 3가지 모델을 적용하여 학습하고, 그 결과를 비교했을 때, 알고리즘의 성능은 정확도 90%, 재현율 70% 이상으로 나타났다. 예측된 정비 데이터를 활용하여 12개월까지 정비 발생 예측과 수리부속소요를 산출하였고 일정표 형태로 시각화하였다. 다음 연구 주제로 회기 알고리즘을 활용한 수리부속소요 예측 모델을 개발하여 소요량까지 예측하도록 발전시킬 예정이다. 향후 이 시스템이 정비요원에게 제공됨으로써 정비 및 보급 소요를 사전에 대비할 수 있게 되어 비가동시간이 단축될 것으로 기대한다.

Abstract Accurate maintainability predictions for guided weapons reduce unnecessary maintenance activities and increase availability. In effect, the maintainability predictions reduce Total Life Cycle Costs and enhance Combat Readiness. This study uses Machine Learning (ML) techniques to present a model that predicts when a specific missile in operation will be repaired and when repair parts should be procured. The data analyzed by ML were more than ten years of field operation data such as maintenance, inspection, and repair parts consumption data. First, to have a data form suitable for ML, the data was integrated so that it can be easily accessed from the preprocessing processes such as data missing and outlier processing and algorithm model. Then, we used XGboost, LightGBM, and Catboost models as classification algorithms for ML used in the maintenance prediction. As a result of applying the best algorithms, the maintenance prediction achieved 90% accuracy and 70% recall rate or more. Next, the maintenance prediction and the need for specific repair parts were calculated for the next 12 months using the processed data. The predicted results were then used to visualize the monthly schedule. As the next topic, we plan to develop a repair parts prediction model using a regression algorithm to predict the quantity of repair parts required. In conclusion, providing this maintainability prediction system to the owner makes it possible to prepare for maintenance and supply requirements in advance and reduce downtime.

Keywords : Machine Learning, XGBoost, LightGBM, Catboost, Maintainability Prediction, Guided Missile, Field Data

*Corresponding Author : Dong-Kyoon Lee(LIGNex1)

email: dongkyoon.lee@lignex1.com

Received October 20, 2021

Revised November 12, 2021

Accepted February 4, 2022

Published February 28, 2022

1. 서론

유도무기를 비롯한 현대 무기체계는 복합 시스템(system of system)으로 불리는 만큼 매우 복잡한 장비로 진화됨에 따라 높은 신뢰성, 가용성, 안전성을 요구하고 있다. 이러한 시스템은 운용하는 과정에서 발생하는 마모, 균열 등과 같은 결함(fault)이나 성능저하(degradation)로 인한 손상(damage) 등을 적절히 관리하지 않으면 중대한 사고나 불가동 상태 등을 야기하고, 막대한 전투력 손실을 초래한다. 따라서 무기체계 가용도 향상과 전투력 손실을 방지하기 위해서는 적절한 점검과 정비가 수반되어야 한다.

이러한 흐름에 따라 예방정비 중심의 현 군의 기본 정비 개념 또한 점차 장비의 상태기반의 예측 정비로 변화될 것으로 전망된다[1]. 이는 장비 상태를 모니터링 하여 정비의 최적 시점을 사전에 예측 및 결정하고, 불필요한 정비는 제거하는 등 유지비용 절감과 가용도 향상을 도모할 수 있다는 장점이 있다[2].

과거 국내 무기체계에서는 가용도 향상을 위해 다가를 정비 시점을 정확히 예측한다는 것이 상당히 어려웠다. 왜냐하면 신규 개발되는 무기체계는 정확한 정비성 분석을 위한 기초 자료가 부족하고 유사 무기체계의 운용 및 정비 실적 자료수집 체계가 미흡하기 때문이다. 현재까지는 무기체계의 관리 평가로 사용되는 주요 지표인 RAM(Reliability, Availability, Maintainability) 향상을 위해, 은닉된 결함을 제거하기 위한 자체점검(BIT: Built In Test, 이하 BIT) 기능 강화 연구 또는 최적의 BIT 주기 산출 등의 주제로 연구가 이루어졌다[3,4].

최근 제4차 산업혁명으로 빅 데이터 활용에 대한 관심이 높아지면서, 무기체계 RAM 향상을 위한 목적으로 연구가 활발히 진행되고 있다[5,6]. 초기 단계인 현재, 데이터 확보에 대한 관심이 많은데, 야전 데이터(field data), 센서 데이터 등 가용한 데이터를 수집하지만, 여전히 데이터의 부족과 무기체계 특성 상 데이터 접근의 어려움이 난제로 남아있다. 본 연구 또한 데이터 부족을 겪었으며, 머신 러닝(machine learning) 기법으로 정비에 대한 기초 자료 부족을 완화하려고 노력하였다. 머신 러닝 기법으로 비정형화된 데이터로부터 패턴을 학습하고, 새로운 데이터에 적절한 작업을 수행하여 데이터의 정확성을 높여서 예측 분석 등에 활용하였다.

머신 러닝은 데이터 처리 뿐 아니라 데이터와 적합한 알고리즘을 이용하여 학습된 알고리즘으로 새로운 데이터를 예측할 수 있기 때문에 최적의 예측평가를 수행할

과 동시에 이를 자동적으로 처리하는 장점이 있다고 할 수 있다. 이러한 머신 러닝을 정비예측에 적용하기 위해서는 정비예측에 필요한 변수의 특징을 분석하고 머신 러닝에 용이하도록 데이터를 처리하며, 적합한 머신 러닝 모델을 찾는 과정이 필요하다. 본 연구과제에서는 10년 이상의 유도탄 정비이력을 분석하여 정비예측 머신 러닝기반의 정비예측 모델을 개발하고 군이 정비예측 소요를 사전에 인지하도록 시각화 단계까지 진행하여 머신 러닝을 이용한 정비예측 가능성을 제시하였다.

2. 본론

2.1 머신 러닝 적용 프로세스

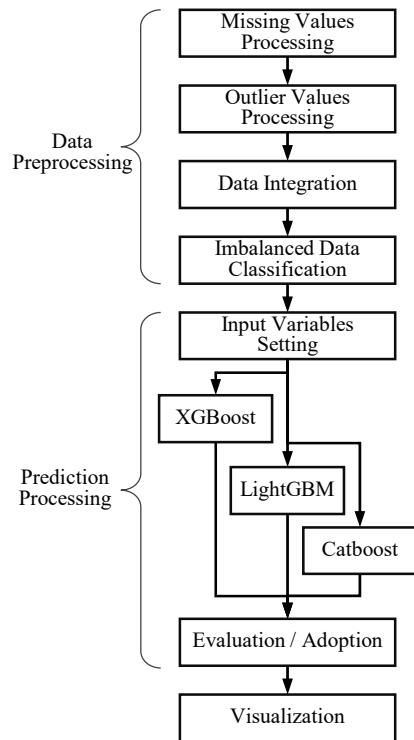


Fig. 1. A Schematic diagram of maintenance prediction procedure through machine learning

머신 러닝을 위한 단계별 적용 방안은 총 4단계로 이루어진다. 먼저 1단계는 데이터의 현황 및 요구 사항 분석을 통해 분석 목표를 설정한다. 2단계는 데이터 전처리 단계로 데이터를 수집 및 정제하고 분석에 의미 있는 변수를 정의한다. 3단계는 모델학습에서 보유했던 데이터와 분석 목표에 맞는 알고리즘 사용하여 모델을 구축하

고, 평가를 통해 가장 최적화된 모델을 선택한다. 마지막 4단계는 최종적으로 선택 한 모델을 적용하여 예측하고, 시각화하여 예측 결과의 활용한다. Fig. 1은 본 논문에서 다루고자하는 2~4단계의 과정을 나타낸다.

2.2 분석 도구 및 운영 환경

Fig. 2는 본 연구의 운영 환경과 관련 분석 도구를 나타낸 것이다. 야전장비의 보안 특성상 독립망 구조의 시스템에서 운영이 된다. 유도무기는 점검장비세트를 통해 구성품 단위로 점검이 이루어지고 측정 데이터는 정비 데이터베이스(DB: Database, 이하 DB)로 수집된다. 정비 DB는 검측데이터, 구성품 교체 및 운용 실적 데이터를 포함한다. 수집된 데이터는 ETL(Extract, Transform, Load) 도구인 TOS(TOS: Talend Open Studio)를 통해 머신러닝에 사용 가능한 데이터 형태로 변환한다. 변환된 데이터는 머신러닝과 딥러닝 개발에 적합한 언어인 파이썬(python)을 활용하여 정비예측 모델을 구성한다. 각 구성품별 모델이 구축되고 예측 결과는 통합DB내에 저장되고 데이터 시각화 도구인 WISE Intelligence를 통해 시각화 한다.

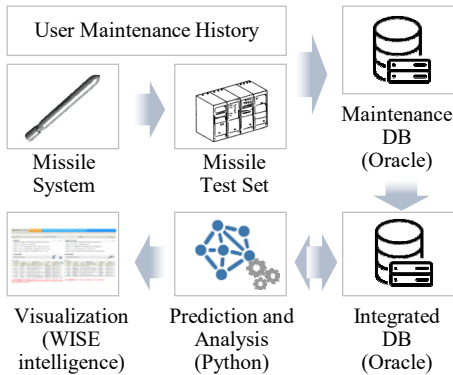


Fig. 2. Operating environment and analysis tools

2.3 데이터 전처리 방법

2.3.1 결측값 처리

점검 데이터의 경우 점검 중단, 미 실시 등의 다양한 이유로 결측치가 발생된다. 이를 처리하기 위해 Fig. 3의 절차를 따라 결측치 처리를 수행하였다. 결측치 처리 방법은 제거하거나 보간하는 방법이 있는데, 유도무기 정비 특성상 주기가 길고 데이터양이 적은 특징이 있어서, 데이터 손실을 최소화 하는 방법이 유리하다. 따라서 데이터를 제거하기보다 데이터를 보존하는 보간법을 선택

하였다.

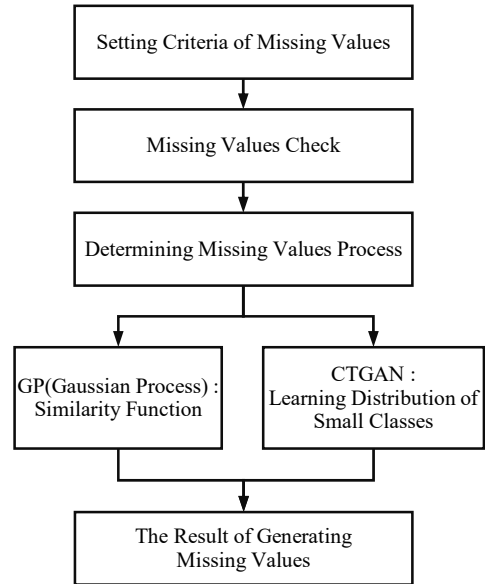


Fig. 3. Interpolation of missing values

보간 방법 중 GP(Gaussian Process) 모델은 훈련 데이터가 부족한 경우 유사성 측정을 통해 데이터를 생성하는 특징을 가지고 있고, CTGAN(Conditional-Tabular Generative Adversarial Networks)은 딥러닝 기반의 비지도 학습 알고리즘으로 기존 GAN(Generative Adversarial Networks)에 비해 구조화된 데이터를 생성하는데 적합한 알고리즘이며, 기존 데이터의 확률 분포를 학습하여 유사한 데이터를 생성하는 특징을 지니고 있다. 본 연구에서는 두 모델을 적합한 모델로 판단하여 결측치 처리 방법으로 활용하였다.

2.3.2 이상치 처리

데이터 점검데이터 중 비정상적인 값은 전체 점검 데이터 패턴에서 동떨어져 있으며 예측 시 알고리즘에 부정적인 영향을 미치는 값이기 때문에, 이상치를 적절하게 처리하는 과정이 필요하다. 이상치 처리방법으로는 삭제, 다른 값으로 변경하는 대치, 스케일링, 정규화 방법이 있는데, 유도무기의 경우 검측 항목의 이상치는 발생 빈도가 매우 낮으며 발생하면 이격이 큰 경향을 확인했다. 따라서 데이터 변경을 최소화 하는 방법인 삭제처리가 적합하다고 판단하였다. 엔진 센서에 대한 처리결과를 Fig. 4에 나타내었다.




Fig. 4. Processing result about engine sensor
 (a) The graph showing the concept of outlier data
 (b) Outlier Data Detection and Removal from actual data

2.3.3 정비 데이터 통합마트 구현

전처리된 야전 데이터는 분류 알고리즘에서 접근이 용이하도록 Fig. 5에 제시한 형태로 데이터 통합 마트를 구성한다. 기존 테이블 생성을 위해 예측 시계열 단위는 월 단위로 설정하고 유도탄, 수리부속품의 정비실적 등 정보를 분류하였다. 점검 데이터는 유도탄 점검 장비를 이용하여 유도탄을 점검하고 결과로 출력되는 성적서를 분석하여 입수된 데이터이다. 이 데이터는 관련 구성품에 대한 성능저하 특성을 확인할 수 있는 수치로서 전원출력, 주파수, 전기 저항 등이 해당된다.

부품 정비이력 데이터는 야전 데이터 수집기간동안 발생한 정비 중 장비성능개선, 오염, 사용자 의도에 의한 교환 등 장비의 고유한 특성과 무관한 데이터를 식별하여 제외하였고 고장에 의한 데이터만 포함되도록 선별하였다. 기존테이블과 업무영역별로 분리된 테이블은 최종 예측 마트를 구성하기 위해 년, 월, 날짜 정보와 부품 정보를 기준으로 통합하였다.

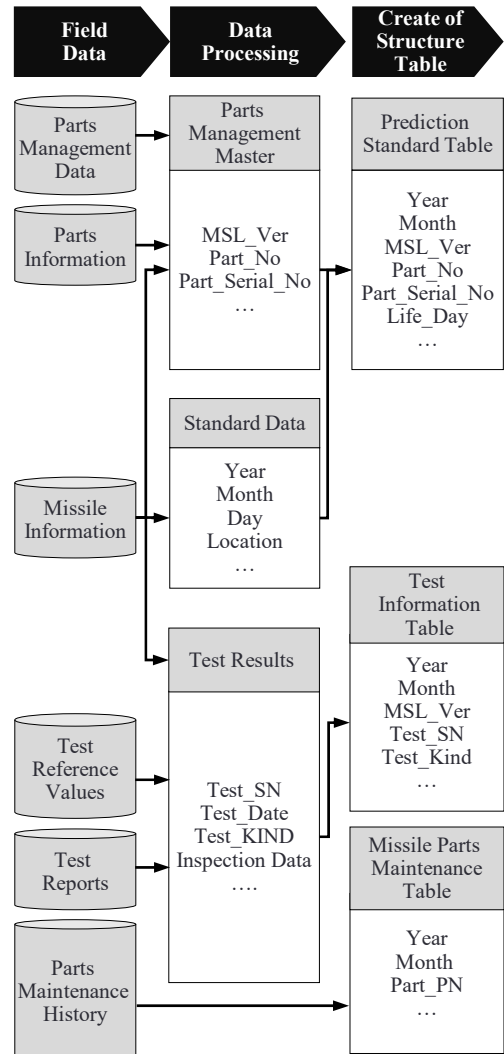


Fig. 5. Data Integration Process

2.3.4 데이터 불균형 처리

클래스의 불균형은 학습 모델의 성능에 영향을 미치기 때문에 이에 대한 적절한 처리가 필요하다. 불균형 문제를 처리하는 것을 샘플링(sampling)이라고 하는데 대표적인 방법에는 오버 샘플링(over sampling), 언더 샘플링(under sampling)이 있다.

유도무기의 특성상 정비가 발생하는 수가 드물기 때문에 정비 여부를 학습하기 위한 클래스의 불균형이 심하다. 이에 대한 해결을 위해 오버 샘플링을 수행하고 그 방법으로 SMOTE(Synthetic Minority Over-Sampling Technique, 이하 SMOTE) 알고리즘을 적용하였다.

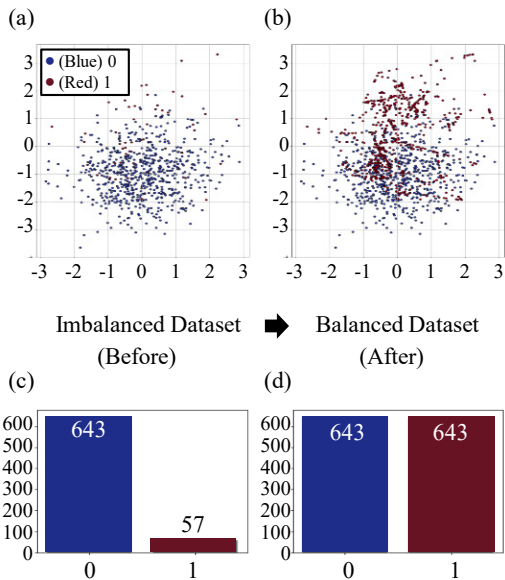


Fig. 6. Scatter plots of imbalanced dataset (a) and balance dataset (b) applying SMOTE. Bar graphs of (a) and (b) are shown as (c) and (d), respectively.

SMOTE 알고리즘은 합성 소수 샘플링 기술로 다수 클래스를 샘플링하고 기존 소수 샘플을 보정하여 새로운 소수 인스턴스를 합성하는 방식으로 합성 데이터를 생성한다. Fig. 6은 SMOTE를 적용한 결과로 57건의 정비결과를 643건으로 오버 샘플링 결과를 나타낸다.

2.4 머신 러닝을 이용한 예측

2.4.1 적용 알고리즘

본 연구에서는 분석할 데이터에 최적화된 특정 머신러닝 알고리즘을 채택하는 전략보다는 여러 알고리즘을 동시에 적용하여, 장치별 데이터 마다, 또는 데이터 유형 마다 높은 성능을 나타내는 알고리즘 적용결과를 비교 평가하여 채택하는 전략을 사용하였다.

2.4.1.1 XGBoost 알고리즘

XGBoost는 여러 트리를 조합해서 사용하는 앙상블 학습 알고리즘으로 분류와 회귀 모델 개발에 좋은 성능을 지닌 알고리즘이다. 앙상블 모형은 여러 개의 단일 모형을 학습하고 이를 조합하여 예측 결과를 추출하는 방식이다. 기존의 그레디언트 부스트보다 빠른 속도를 보여주며 과적합을 규제하는 기능을 지니고 있어 효율성이

높은 알고리즘이다. 또한 조기 종료(early stopping) 기능이 있어 모델의 성능 평가 시간을 단축시키는 효과가 있다.

2.4.1.2 LightGBM 알고리즘

2017년 Microsoft사에서 데이터의 일부만으로 빠르게 정보이득을 계산하여 모델링에 소요되는 시간을 줄이면서도 성능을 유지하는 알고리즘인 LightGBM이 소개되었다. 기존의 부스팅 알고리즘이 사용된 다른 모델들의 단점인 데이터 처리시간을 단축하였으며, 이를 통해 속도측면에서 좋은 성과를 보여준다. LightGBM의 트리는 수직적으로 확장되는 leaf-wise이며 최대 손실 값을 가지는 리프 노드를 반복할수록 균형 트리 분할방식에 비해 예측 오류 손실을 최소화 한다.

2.4.1.3 Catboost 알고리즘

XGBoost, LightGBM 알고리즘은 무기체계에 적용된 사례가 있으나[7], Catboost는 최근에 등장한 부스팅 모델로, 범주형 변수가 많은 데이터 세트(data set)에서 예측 성능이 우수한 것으로 알려져 있다[8]. 기존의 그라디언트 부스팅 방식에서 범주형 변수를 One-Hot Encoding을 통해 범주형 변수로 바꿔줘야 하는 반면 Catboost는 범주형 변수를 자동으로 전처리하는 기능을 통해 모델 훈련과 동시에 전처리를 진행해 시간을 단축시킨다. 또한 그라디언트 부스팅 모델에서 생기는 문제인 목표 변수 누수 문제를 개선하기 위해 순서형 부스팅(ordered boosting) 방식을 사용하였다. 이 방식을 사용함으로써 기존 부스팅 방식의 문제로 지적된 계산 프로세스 마다 이전에 사용한 데이터를 반복해서 쓰는 문제를 피해갈 수 있다.

2.4.2 분석대상

학습과 검증이 가능한 수준으로 정비 발생 건수가 존재하는 구성품에 대하여 적용하며, 대표 4개 구성품과 하부 구성품에 대한 예측을 수행하였다. 4개의 구성품(unit)은 관성항법장치(INS: Inertial Navigation Unit, 이하 INU), 탐색기(SK: Seeker, 이하 SKR), 유도전자장치(GCU: Guidance and Control Unit, 이하 GCU), 전력변환장치(PCU: Power Converter Unit, 이하 PCU)이며, 적용 대상 데이터 현황은 Table 1과 같다.

Table 1. Data types and data by Parts(units)

Parts(Unit)	INS	SKR	GCU	PCU
No. of Parts	59	60	56	47
No. of Inspection data type	21	35	27	14
No. of total inspection	6656	2746	6373	10567
No. of maintenance occurrences	92	53	37	51

2.4.3 사용 변수

수리 예상 장비 예측을 위해 사용한 변수는 Table 2 와 같다.

Table 2. Simplified Input Variables of Machine Learning

No	Variables Name	Description	Note
1	Year	Year of Maintenance	
2	Month	Month of Maintenance	
3	Part_No	Part Number	Allocated of Model for each PART_PN
4	Part_Serial_No	Serial Number of Part	
5	Test_YN	Year of Test	Correction and Preventive Maintenance Events
6	Location	Location of Missile	Deployment or Shop
7	MSL_Ver	Configuration Number of Missiles	BLK1, BLK2
8	Life_Day	Comulative Operating Time from Deployment to Censored	
9	Inspection Data	Measurement Data using Missile Test Set	Radio Frequency (dB), Power(W)

2.4.4 모델 평가 방법

머신 러닝 분류 기반 알고리즘의 성능평가를 위한 지표에는 정확도(accuracy), 재현율(recall)을 사용하였다. 이 지표는 혼동행렬을 통해서 계산이 가능하며, 정비 발생, 미 발생을 실측결과와 예측결과를 혼동행렬로 표현하면 Fig. 7과 같이 표현된다.

		Actual Data	
		Maintenance	No Maintenance
Prediction Values	Maintenance	TP True Positive	FP False Positive
	No Maintenance	TN True Negative	FN False Negative

Fig. 7. Confusion Matrix Definition

성능평가 지표 중 정확도의 계산방법은 전체 이벤트 수에서 예측과 실제 결과가 일치하는 TP, TN의 비율로 정의되며 식으로 표현하면 Eq. (1)과 같다.

$$Accuracy = \frac{TP + TN}{TP + FN + FP + TN} \quad (1)$$

재현율은 실제 값이 Positive인 대상 중에 예측과 실제 값이 Positive로 일치한 데이터의 비율을 나타내며 식으로 표현하면 Eq. (2)와 같다.

$$Recall = \frac{TP}{TP + FN} \quad (2)$$

2.4.5 예측결과

XGBoost, Catboost, LightGBM 알고리즘을 통해 대표 4개의 구성품 정비예측을 수행할 때, 성능평가 지표는 각각 Table 3~5와 같이 나타났다.

Table 3. Accuracy and Recall values using XGBoost

Parts(Unit)	Accuracy	Recall	High score
INU	0.90	0.71	○
SKR	0.84	0.91	
GCU	0.88	0.64	
PCU	0.95	0.78	○

Table 4. Accuracy and Recall values using Catboost

Parts(Unit)	Accuracy	Recall	High score
INU	0.91	0.68	
SKR	0.99	0.91	○
GCU	0.89	0.71	
PCU	0.94	0.78	

Table 5. Accuracy and Recall values using LightGBM

Parts(Unit)	Accuracy	Recall	High score
INU	0.90	0.68	
SKR	0.99	0.91	
GCU	0.88	0.79	○
PCU	0.94	0.78	

예측 결과는 정확도, 재현율로 측정하였으며, 모델 성능 평가를 위해 전체 데이터를 학습 데이터와 검증 데이터 7:3 비율로 나누어 설정하였다. 실제 데이터와 예측 결과를 클래스별 확률 예측 정보 결과와 비교하였으며, 파트별로 우수한 성능지표를 보여준 알고리즘으로 채택하였다. 선정된 예측 결과에 대한 혼동 행렬(confusion matrix)을 도식화하면 Fig. 8과 같다.




Fig. 8. Diagonal Values of Confusion Matric with (a) Inertial Navigation Units (b) Seekers (c) Guidance and Control Units (d) Power Converter Units

2.5 정비 및 보급예측 시각화

2.5.1 정비소요 예측결과

정비소요 예측결과는 Fig. 9와 같이 각 구성품에 대한 최대 12개월까지 범위를 예측하여 시각화 되도록 구성하였다. 구성품 정비예측은 앞서 언급된 3개의 알고리즘을 통해서 산출된 결과 중, Table 6과 같이 성능평가 점수가 가장 높은 알고리즘이 채택되도록 하였으며, 채택 알고리즘의 정비확률이 시각화 되도록 하였다. 시각화 화면은 표와 막대그래프로 구성하였는데, 표의 행 Fig. 9(b)(1)은 예측 날짜를 나타내며, 예측기간은 월 단위로 표기하였다. Fig. 9(b)(2)는 구성품별 정비발생 여부를 나타내는데, '확률' 열에 예측 알고리즘이 정비 발생 여부를 구분할 때 계산되는 확률 값을 전시하고 확률이 0.5 이상일 때는 '정비여부' 열에 '1', 그 이하는 '0'으로 표시하였다. 해당 월에 정비가 발생한다고 예측할 경우, 빨

간색 하이라이트를 통해 사용자가 쉽게 확인할 수 있도록 하였다.

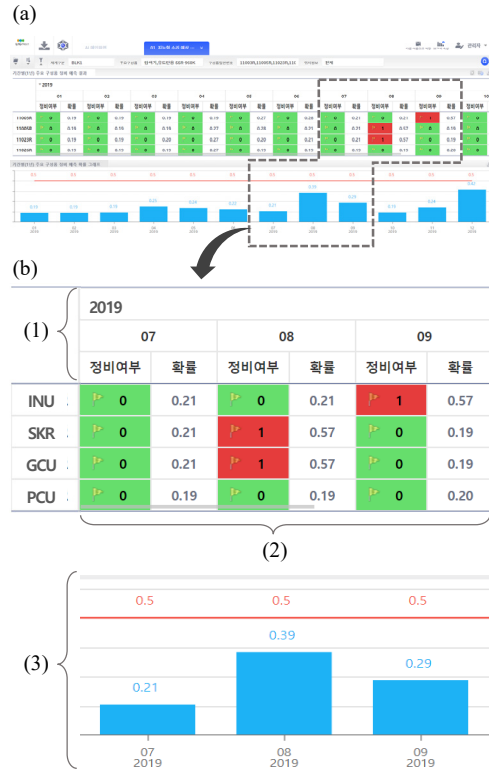


Fig. 9. (a) Overall Visualization of Maintenance Prediction Results on Screen (above) (b) Enlarged Visualization Results from July to September, 2019 (below)

Table 6. High Scored algorithm by parts

Parts(Unit)	Best Algorithm	Maintenance Prediction
INU	XGBoost	September, 2019.
SKR	Catboost	August, 2019.
GCU	LightGBM	August, 2019.
PCU	XGBoost	none

Fig. 9(b)(3)은 특정 구성품을 선택하면 기간에 대한 정비확률을 막대 그래프로 전시한 결과로써 탐색기를 선택했을 때, 7월에서 9월까지의 정비확률을 나타낸다. 정비요원은 구성품 별 정비예측 추이를 확인하여 어떤 구성품이 고장예측소요가 많은지 판단할 수 있다.

2.5.2 보급소요 산출

정비소요 예측을 통해 구성품 단위별로 예측된 결과를 바탕으로 미래 보급소요를 산출하였다. 보급소요는 분기 단위로 계산하였으며 Fig. 10과 같이 과거 실제 소요발생 이력 3년간을 함께 시각화로 보여줌으로써 해당 구성품의 보급소요 추이를 함께 확인할 수 있도록 하였다. 보급소요 결과 화면은 표와 선 그래프로 구성하였으며, 상단의 표는 특정 구성품의 과거 3년간 실제 보급수량과 예측된 1년간의 보급수량을 보여준다. 행은 기간을 분기별로 보여주고 열은 구성품을 나타낸다. 하단의 선 그래프는 특정 구성품선택 시 시간별 추이를 나타낸다.

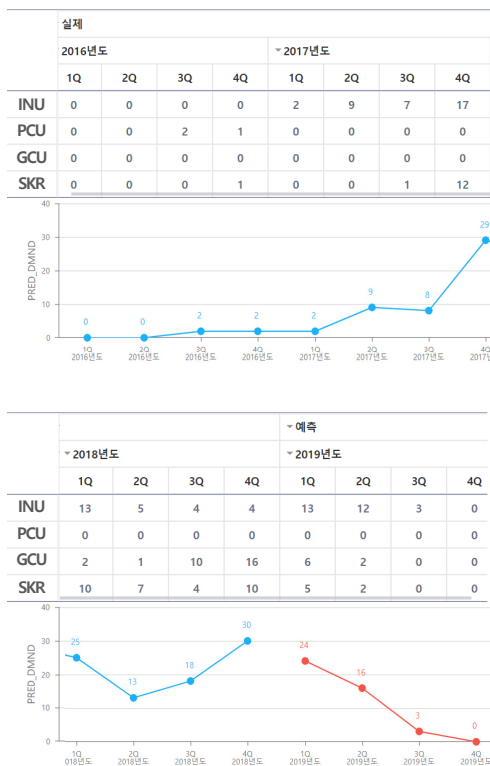


Fig. 10. Prediction Results of Repair Parts Required. Shows Actual Consumption from 2016 to 2018 (blue), and 2019 Represents Predicted Results (Red)

3. 결론

본 연구를 통해 유도무기 야전 데이터를 활용하여 데이터를 전처리하고 머신 러닝 알고리즘 기반 정비예측 모델을 개발하였다. 현재까지 유도무기 정비개념은 개발

간 획득한 RAM 데이터에 크게 의존해왔으나 정비이력과 점검결과를 활용한 장비상태 데이터를 활용하여 미래 시점의 정비를 예측하는 연구를 진행하였다는 것에 본 연구에 의미가 있다.

머신 러닝 기법을 활용하여 예측하여 다음과 같은 결론을 도출하였다. 유도무기가 비교적 온화한 조건에서 저장 상태로 운용되는 특성상 점검이력과 정비가 발생한 이력이 드물기 때문에, 머신 러닝 적용에 충분한 데이터 세트를 구성하기 위한 데이터 전처리가 필요하다. 데이터 전처리 과정을 통해서 이상치 값을 판별하고 처리하며, 데이터를 처리하는 알고리즘을 활용하여 결측값을 보간 하였다. 통합된 데이터는 구성품별로 XGboost, LightGBM, Catboost 알고리즘을 통해 학습을 시키고 성능이 우수한 알고리즘을 채택하였다. 분석결과, 알고리즘별 성능은 정확도 90%, 재현율 70% 이상의 성능을 나타내는 결과를 보여주었다. 예측결과는 시각화 화면을 통해서 정비요원이 구성품의 정비 필요 여부를 쉽게 파악할 수 있게 개발하였다. 수리부속 예측은 정비예측결과에 해당하는 수리부속 소요를 종합하여 제시하였다, 현재 회귀 알고리즘을 사용한 수리부속 소요량 예측 연구를 진행하고 있어 개선된 예측 성능을 기대하고 있다.

마지막으로, 머신 러닝 예측모델이 학습을 통해 고도화되기 위해서는 데이터 부족현상을 극복해야한다. 데이터 부족은 데이터 불균형에 따른 과적합 문제를 발생할 여지가 있으므로, 데이터 신뢰도를 향상시키기 위한 데이터 축적과 학습이 반드시 필요하다. 유관기관의 많은 관심과 후속 데이터 지원이 이루어져 예측성능의 고도화가 이루어지고, 효과적이고 활용성 높은 정비예측 시스템으로 발전하길 기대한다.

References

- [1] Sang-Hun Kim, Seung-Woo Chey, Sung-pyo Hong, "Development Direction of Defense Weapon System for the 4th Industrial Revolution", *Journal of the Korean Society of Industry Convergence*, Volume 22, Issue 2, pp.71-79, 2019.
DOI : <https://doi.org/10.21289/KSIC.2019.22.2.71>
- [2] Chulsoon Park, Sungmoon Bae, "A Study on the Predictive Maintenance of 5 Axis CNC Machine Tools for Cutting of Large Aircraft Parts", *Journal of the Society of Korea Industrial and Systems Engineering*, Volume 43, Issue 4, pp.161-167,2020.
DOI : <https://doi.org/10.11627/ikise.2020.43.4.161>
- [3] Boram Jo, Jangkeun Ahn, Storage Reliability Prediction

Model for Missile subjected to Non-periodic Test and Periodic Inspection excluding Overlapped Failures, *Journal of the Korea Academia-Industrial cooperation Society*, Volume 19, Issue 5, pp.599-604, 2018.
DOI : <https://doi.org/10.5762/KAIS.2018.19.5.599>

- [4] Shin-Ju Hwan, Sang-Boo Kim, Won-Young Yun, On the Maintenance Time Prediction of an Underwater Military System, *IE Interfaces*, vol.11 no.1, pp.175-182 1998.
- [5] Chanyong Choi, Hunki Kim, Young Cheul Kim, Sang-su Kim, Prediction of Track Quality Index (TQI) Using Vehicle Acceleration Data based on Machine Learning, *Journal of the Korean Geosynthetics Society*, Volume 19, Issue 1, pp. 45-53, 2020.
DOI : <https://doi.org/10.12814/jkgss.2020.19.1.045>
- [6] Jinseop Kim, Jaesung Hwang, Jaewoo Chung, A New LSTM Method Using Data Decomposition of Time Series for Forecasting the Demand of Aircraft Spare Parts, *Korean Management Science Review*, Vol 37(2), pp.1-18, 2020.
DOI : <http://doi.org/10.7737/kmsr.2020.37.2.001>
- [7] Min-Gyu Song, Jung-Mok Ma, A study on predictive model for forecasting Airforce F-15K spare parts Using Data Mining, *Journal of the Korea Academia-Industrial*, Vol. 22, No. 8, pp. 279-286, 2021.
DOI : <https://doi.org/10.5762/KAIS.2020.21.7.428>
- [8] Min Jong Cheon, Hye Jin Choi, Ji Woong Park, HaYoung Choi, Dong Hee Lee, Ook Lee, A Study on the traffic flow prediction through Catboost algorithm, *Journal of the Korea Academia-Industrial cooperation Society*, Vol. 22, No. 3, pp. 58-64, 2021.
DOI : <https://doi.org/10.5762/KAIS.2021.22.3.58>

이 동 균(Dong-Kyoon Lee)

[정회원]



- 2007년 8월 : 홍익대학교 재료공학부 (공학사)
- 2009년 8월 : 홍익대학교 신소재공학과 (공학석사)
- 2010년 1월 ~ 현재 : LIG넥스원 선임연구원

<관심분야>

신뢰성공학, 유도무기, 빅데이터, AI, 머신 러닝

박 장 원(Jang-Won Park)

[정회원]



- 2013년 2월 : 숭실대학교 공과대학 산업정보시스템공학과 (공학사)
- 2013년 3월 ~ 현재 : LIG넥스원 선임연구원

<관심분야>

신뢰성, 정보통신, 인간공학

조 산 희(San-Hee Cho)

[정회원]



- 1999년 2월 : 한국항공대학교 컴퓨터공학과 (공학사)
- 2015년 2월 : 경북대학교 전자공학과 (공학석사)
- 2002년 7월 ~ 현재 : LIG넥스원 수석연구원

<관심분야>

빅데이터, AI, 머신 러닝

이 중 신(Jong-Sin Lee)

[정회원]



- 2000년 2월 : 인하대학교 공과대학 산업공학과 (공학사)
- 2000년 12월 ~ 현재 : LIG넥스원 수석연구원

<관심분야>

국방/과학, 빅데이터, 군수보급분야