

# 앙상블 학습 기반의 동시조달수리부속 예측모형 연구

황지환<sup>1</sup>, 박흥석<sup>2</sup>, 김재동<sup>3\*</sup>

<sup>1</sup>국방기술품질원, <sup>2</sup>금오공과대학교, <sup>3</sup>한국국방연구원

## A Study on Forecasting Initial Provisioning Based on Ensemble Learning

Ji-Hwan Hwang<sup>1</sup>, Hong-Suk Park<sup>2</sup>, Jae-Dong Kim<sup>3\*</sup>

<sup>1</sup>Defence Agency for Technology and Quality(DTaQ)

<sup>2</sup>Kumoh National Institute of Technology

<sup>3</sup>Korea Institute for Defense Analyses

**요약** 초기 무기체계 전력화 시 일정기간 재보급 없이 주어진 운용임무를 수행하기 위해 필요한 필수 수리부속을 동시 조달수리부속이라고 한다. 본 수리부속은 보통 총사업비 3%에 해당하며 전투준비태세를 보장하고 원활한 장비운용을 위해 전력화와 동시에 산정되는 수리부속을 뜻한다. 본 연구는 동시조달수리부속의 소요산정에 대한 중요성을 고려하여 기존의 방법론에 대한 정확도를 높이기 위해 랜덤포레스트(RF), 아다부스트(ABC), 지지기반머신(SVM) 등 머신러닝 기반의 모형을 제시하였다. 동시조달수리부속 예측을 위해 일반분해목록(GBL) 등과 같은 획득데이터와 수리부속의 보급 및 정비체계인 장비정비정보체계(DELIIS)의 운영데이터를 활용하였다. 기존의 육군에서 주로 사용한 고장간 평균시간(MTBF) 기반의 기법은 획득데이터만 활용한 반면 본 연구에서의 머신러닝 기법은 운영데이터도 함께 활용하였다는데 의의를 가진다. 결과적인 측면에서도 MTBF 기반의 기법의 정확도는 83%인 반면 머신러닝 기법의 정확도는 DT, RF, ABC, SVM, KNN, VOTE이 각각 85.1, 92.5%, 94.7%, 95.1%, 92.6%, 95.5%로 우수함을 보였다. 기타 Recall, Precision, F1-Score 부분에서도 머신러닝 기법이 우수한 것으로 나타났으며 특히, 머신러닝 기법 중 VOTE 기법이 가장 우수한 결과를 보였다. 본 연구는 기존의 방법론 대비 운영데이터를 추가적으로 활용하였고 앙상블 기법을 적용하여 결과의 개선을 보였다는데 큰 의의를 가진다.

**Abstract** A weapon system's concurrent spare part (CSP) is a spare part that meets the essential requirements for the system to perform tasks without requiring resupply for an initial operating time. In addition, generally, It is critical to maintaining combat readiness and the efficient operation of weapon systems. Hence, this research studied machine learning-based models, such as Random Forest(RF), AdaBoost(ABC), and SVM, to increase the accuracy of existing methodologies for the estimation of the requirements of a CSP, considering the importance of the estimation. In particular, this study used the acquired and operational data of DELIIS, a supply and maintenance system of spare parts, pertaining to the CSP. Also, the MTBF-based techniques, mainly used by the Army, used only acquired data. On the other hand, the machine learning-based models used operational data together with the acquired data. Hence, the accuracy of the MTBF-based techniques was 83%, while the machine learning-based models, DT, RF, ABC, SVM, KNN, and VOTE had an accuracy of 85.1, 92.5, 94.7, 95.1, 92.6, and 95.5%, respectively. In addition, machine learning-based models were also shown to be superior to the MTBF-based techniques, in terms of recall, precision, and F1-score, in the study. In particular, the VOTE model showed the best performance among the ensemble learning models. Hence, this study has great significance in using additional operational data compared to existing methodologies and showing improvements in outcomes using ensemble learning models for the estimation of the requirements of a CSP.

**Keywords** : Ensemble Learning, Concurrent Spare Parts, Initial Provisioning, Data Mining, Logistics

\*Corresponding Author : Jae-Dong Kim(Korea Institute for Defense Analyses)

email: soobahkin@gmail.com

Received May 24, 2022

Revised July 11, 2022

Accepted August 3, 2022

Published August 31, 2022

## 1. 서론

초기 무기체계 전력화 시 일정기간 동안 수리부속의 재보급 없이 주어진 임무운용을 수행하기 위해 필수소요를 충족시키기 위한 수리부속을 동시조달수리부속(CSP: Concurrent Spare Parts 이하 CSP)이라고 한다. 초기 전력화된 획득 무기체계는 일정기간동안 전투준비태세를 위한 목표가동률을 유지해야 한다. 이때 CSP 수량이 과소 재고 보유 시 재고고갈로 이어져 목표가동률을 유지할 수 없으며, 반대로 CSP 수량이 과다 재고 보유 시 저장시설의 부담뿐 아니라 비효율적인 예산 낭비를 초래한다. 따라서 가용예산 범위 안에서 목표가동률을 유지하고 효율적인 예산 활용 및 무기체계의 원활한 운용유지를 위해 적절한 CSP 소요산정이 필요하다.

CSP 확보는 장비 전력화 시점보다 1년 전에 CSP의 품목을 선정하고 수량을 결정한다. 결정된 CSP는 전력화 장비와 동시에 보급된다. 전력화된 장비는 X년 기준으로 수리부속 정비소요를 결정하며, X+2년에는 수리부속 분석을 통해 2년 후 장비운영유지를 위한 예산으로 제기된다. X+3년에는 예산이 편성된 후 장비 운영단계에 필요한 수리부속 소요의 조달이 이루어진다. 동시에 기존에 운용 중인 CSP도 운영단계부터 운영자산으로 전환되어 관리된다. 따라서 안정적인 수리부속 조달이 유지될 수 있도록 최소 3년의 CSP가 필요하다.

일반적으로 6단계 과정을 거쳐 CSP 소요산정이 이루어진다. 1단계는 유사장비 품목제원을 CSP 산정모델인 OASIS(Optimal Allocation of Spares for Initial Support 이하 OASIS)에 기초자료를 개발업체 보유자료 기반으로 입력한다. 2단계는 방위산업청 자체적으로 개발한 OASIS 모델을 활용하여 소요결과를 분석한다. 3단계는 소요결과 자료를 해당군에 제공하여 전력화 장비 대수 등을 방사사업청 소요결과와 비교분석하여 적절하게 조정한다. 4단계는 OASIS 산출결과를 기반으로 소요군에서 제시한 조정소요 의견을 군수사에서 제시한다. 5단계는 군수사 의견을 소요군에서 검토하여 최종 의견을 방위사업청에 제출한다. 6단계는 통합사업관리팀(IPT: Integrated Project Team 이하 IPT)과 무기체계 제작사와 조율하여 최종적인 CSP 소요를 결정한다. OASIS 모델은 입력 단계와 산출 단계로 나누어서 적용된다. 입력 단계는 제작사에서 작성 및 기존 데이터를 활용하며, 산출 단계에서 적용하는 다단계 재고관리 모형은 최소한의 예산을 가지고 목표 가동률을 최대화하는데 목적을 둔 무기체계 중심의 접근방법 모형이다. 그러나 이러한

방법론은 Table 1과 같이 저조한 적중률이 발생하는데 목표 장비가동률 달성에 어려움이 발생된다[1].

따라서 본 연구는 CSP 소요산정의 중요성을 고려하여 품목 정확도 제고를 목적으로 한다. 특히, 최근 다양한 분야에서 적용되고 있는 앙상블 기반의 모형을 제시하고자 한다. 본 논문의 구성은 2장에서는 머신러닝의 수요 예측에 활용된 기존문헌을 살펴보고 CSP 소요산정에 대한 활용 가능성을 확인한다. 3장에서는 데이터 추출 및 변수와 모델을 설명하며 4장에서는 기법별 결과에 대한 비교 및 분석 결과를 제시한다. 마지막 5장에서는 논문 결과와 향후 연구 방향을 제시한다.

Table 1. CSP Accuracy by Equipment Example

equipment	Acquisition			Accuracy(%)		CSP Introduction
	item	count	cost	item	Quantity	
A	312	1,749	1,728	2.6	8	'15year~ '16year
B	95	307	2,165	100	90	'13year~ '16year
C	124	3,434	72	62.1	71	'13year~ '16year
D	39	7,030	50	27.3	3	'13year~ '16year

## 2. 이론적 배경

### 2.1 머신러닝 선행연구

머신러닝은 다양한 연구 분야에서 예측력 및 속도가 뛰어나 활용되고 있다. 특히, 머신러닝은 시계열 기법에 비해 다변수 데이터를 적용될 시 비약적인 성능 향상을 보여주며, 정부 정책 측면에도 활발히 활용되고 있다. 의료정보, 생활여건 등의 변수를 활용하여 보건복지 정책에 대한 영향 분석을 머신러닝을 활용하였다[2]. 기업의 재무정보, 경제지표, 주식정보 등의 데이터로 기업의 부도를 머신러닝으로 예측하였다[3]. 공시지가 등의 데이터로 부동산 가격을 머신러닝으로 예측하였으며, 다양한 변수를 생성하여 제조업에 대한 성과를 머신러닝으로 예측하였다[4,5]. 매출액, R&D투자, 고용 지표 등의 데이터로 딥러닝을 활용하여 정부의 R&D 예산 지원 효과성을 예측 정확도를 제시하였다[6].

### 2.2 수요예측 선행연구

F-15K 전투기에 대한 2014 ~ 2019년까지의 6년치

소모 데이터를 수집하여 7가지(Random forest, GBM, XGBoost, LightGBM, Ridge, Lasso, lastic Net regression)의 머신러닝 모델을 기반으로 시계열과 정확도를 비교분석하였다[7]. 수요 발생율, 폐기율, 소요개수, 소터 수 등의 데이터를 활용하여 DT(Decision Tree), BN(Bayesian Network), ANN(Artificial Neural Network), CVR(Core Vector Regression) 4가지의 데이터마이닝 기법을 적용하여 정확도를 제고하였다[8]. 수리부속 가격, 정비 시간, 전자 운용시간, 전자 운용거리 등의 정보를 활용하여 정형 데이터와 비정형 데이터를 활용하여 데이터마이닝 모델을 수립하였다. 대다수의 논문은 정형 데이터만을 활용하여 예측 정확도를 제고시켰으나 비정형 데이터까지 포함한 정확도가 높았다[9]. 한국항공우주산업(KAI)에서 정비시간, 항공기 운용시간, 소터 수, 운영한 항공기 대수, 항공기 가동율 등을 활용하여 3가지(Simple Moving Average, Weighted Moving Average, Exponential Smoothing) 시계열 기법과 4가지(Random Forest, Support Vector Regression, Linear Regression, Neural Network) 데이터마이닝 기법을 적용하여 정확도를 제고하였다[10].

### 2.3 동시조달 수리부속 수요예측 선행연구

머신러닝이나 수요예측 연구는 지속적으로 연구되었으나 CSP에 대한 사례연구는 많은 연구가 이뤄지지 않았다. 한국군의 운용개념에 맞도록 수리/교체 업무분포 외 SMR코드 추가, 최적해에 대한 정비계단별/대상품목별 분류 산출 등의 데이터 추가로 비용 제한사항을 고려한 확장된 CSP 소요산출 모형을 제시하였다[11]. 시물레이션과 다중 회귀모형을 활용하여 CSP의 최적 소요산출 모형을 제시하였다. 시물레이션 모델링을 위해 장비 품목과 보급 및 정비 체계의 자료를 활용하였으며, 시물레이션 모델을 기반으로 장비수리를 표현하기 위해 다중 회귀모형을 사용하였다. 이때 다중 회귀모형은 비용 제약 하에서 각 품목별 동시조달수리부속 수량의 최적 조합을 도출하였다. 이러한 방법은 연구 개발 중 계속 변화하는 단가에 효율적이며, 대응이 빠른 특징이 있다[12]. 초도 운용기간에 발생하는 휴먼에러 고장에 의한 무기체계의 신속한 복구를 위해 필요한 추가 CSP의 산정 방안을 제안하였다. 이러한 산정 방안은 초도 운용기간에 무기체계의 운용가용도를 높이고 양산간 실제 소요가 예측되는 CSP를 예측하여 필요한 수리부속 확보가 가능한 방안이다[13].

## 3. 동시조달수리부속 예측모형 제안

### 3.1 데이터 수집 및 변수 추출

이전에 도입된 신규 장비 및 유사 장비의 동일한 수리부속에 대한 패턴을 학습하고 이를 신규 수리부속에 적용한다. 즉, 신규장비 수리부속 품목과 기존 장비 수리부속 품목이 일치하는 신규 장비 및 유사 장비 수리부속 품목의 패턴을 학습하여 불일치 품목의 수리부속을 예측하는 방법이다.

Fig. 1과 같이 획득 데이터와 운영 데이터를 적용하였다. 먼저 획득 데이터는 종합군수지원(ILS: Integrated Logistics Support 이하 ILS)을 통하여 도출되는 결과물 중의 하나인 Table 2와 같이 일반분해목록(GBL: General Breakdown List 이하 GBL) 자료를 활용하였다. 운영 데이터는 수리부속의 보급 및 정비체계인 장비정비정보체계(DELIIS: Defense Logistic Integrated Information System 이하 DELIIS)를 활용하였다. 추출한 자료는 육군 DELIIS কে도장비 중심의 12개 항목이 포함된 데이터를 수집하였다. 데이터 기간은 CSP가 3년이 기준이므로 소모 데이터도 동일한 기간의 데이터만을 Table 3과 같이 추출하였다. 이 때 추출 방법은 신규장비 품목 중 기존 도입된 장비의 일치하는 수리부속만을 추출하는 방식을 적용하였다. 데이터 분석대상 장비는 육군에서 운영 중인 장갑차 K-XX이다. 대상 장비는 2009년 DELIIS 운영 후 CSP 운영기간인 3년이 종료된 장비 기준으로 선정하였으며, 데이터 기간은 2009년 1월부터 2015년 12월까지의 데이터를 사용하였다.

K-XX 장갑차 분석을 위해 총 2,846개 수리부속 중 공통품목인 1,067개 품목을 추출했다.

Table 2. GBL Table Example

LCN	Part Number	NSN	Part Name	English Name	SMR	exchange quantity
HAGA01	674-01-1	12345	감지기 홀더	PROBE HOLDER	PAFZZ	10
HAGA02	674-01-2	12345	전압계	VOLT	PAFZZ	20
...	...	...	...	...	...	...
Unit	Failure Rate	MTBF	Unit Failure Rate	Unit MTBF	EC CODE	maintenance time
EA	0.1	10	0.1	1	1	50Hour
EA	0.2	20	0.1	2	7	20Hour
...	...	...	...	...	...	...

Table 3. Army DELIIS Table Example

Equipment Name	Equipment NSN	Equipment registration Number	maintenance date	NSN	troops
Equipment C	C0001	2001C1	20130514	C54321	X LSC*
Equipment D	D0001	2001D1	20140320	D54321	X battalion
...	...	...	...	...	...
Request Unit	consumption Unit	consumption	worker	number of workers	recoverability
EA	EA	8	0 0 0	5	N
EA	EA	9	0 0 0	2	N
...	...	...	...	...	...

### 3.2 모델 구축 및 학습 방법

모델 구축 대상 장비로는 2013년 에 도입한 K-XX 장갑차를 선정하였으며, CSP 예측 모델은 일반적인 머신러닝 학습모델과 동일하다. 그러나 획득 데이터와 운용 데이터를 모두 활용한다는 점에서 다른 머신 러닝 모델과 다르다. 선정된 장비는 2013년부터 도입 되었기 때문에 시점을 기준으로 훈련 데이터와 테스트 데이터에 따라 별도로 적용하였다. 학습 데이터는 주로 획득 데이터와 운용 데이터가 일치하는 1,067개 항목으로 구성되며 테스트 데이터는 Fig. 1과 같다. 이와 관련된 자료는 GBL의 전체 1,779품목을 적용하였다[1].




Fig. 1. Machine Learning Algorithms

학습 데이터는 2010년부터 2012년까지 3년간 발생 또는 미발생 정보를 포함하는 Y train set의 운영 데이터와 X train set의 획득 데이터로 구성된다. 위에서 언급한 바와 같이 11개의 획득 및 운영 데이터에 각 알고리즘의 학습 패턴을 적용하였다. 학습 데이터에 적용된 각 알고리즘에서 학습 패턴을 도출한 후 이를 검증 데이터에 적용하여 최종 결과값을 산출하게 된다[1].

검증 데이터는 2013년부터 2015년까지 3년간 발생 또는 미발생 정보가 포함된 Y test set의 운영 데이터와 전체 품목이 포함된 X test set의 획득 데이터로 구성된

다. 위에서 언급한 바와 같이 학습 데이터를 활용하여 각 알고리즘의 학습 패턴을 적용하여 예측을 산출한다.

마지막으로는 2013년부터 2015년까지 3년 동안의 발생 또는 미발생 정보를 Y test set에 적용하고 모든 품목에 대하여 예측 방법론별로 성능을 비교 분석하였다[1].

획득 데이터는 ILS의 산출물의 하나인 GBL 데이터를 적용하여 복구성 부호, 제고번호 등의 12개 변수를 학습하여 발생 및 미발생 여부를 예측한다. 운용 데이터는 획득 데이터와 DELIIS 데이터가 일치하는 품목을 기준으로 3년 동안 발생 및 미발생 여부에 대한 정보를 반영한다. 위와 같은 방법으로 선택한 변수는 Table 4, 5과 같이 기본적인 통계치 및 변수 설명도 하였다[1].

이와 같은 과정에서 7개년의 품목별, 연도별 소모 개수를 2009년부터 2015년까지 변수로 추출하였다.

마지막으로 적용한 변수는 수리부속별 발생 및 미발생 여부에 대한 데이터를 적용하였다. 위와 같은 방법으로 산출된 변수들을 적용하여 목표변수인 2013년에서 2015년까지 발생 및 미발생 여부의 예측을 비교 분석하였다.

데이터마이닝은 DT, RF, ABC, SVM, KNN 및 VOTE 예측 방법론 적용하였다. 방법론 간의 정확도 비교는 Accuracy, Precision, Recall, F1-Score 척도 기준으로 비교 분석하였다. 프로그램은 Python 3.6.1을 활용한 Sklearn, Keras, Pytorch를 적용하였다.

본 연구는 시계열 기반인 MTBF 예측 기반의 결과와 머신러닝을 적용한 결과를 비교 분석했다. 머신러닝의 공정한 성능 비교를 위해 다양한 방법론을 적용하였다. 적용 방법은 Fig. 2와 같이 학습 데이터와 검증 데이터로 나누어 적용하였다.

The table displays two data sets: 'Common Item (1,067)' and 'All Items (1,776)'. Each set is divided into 'Acquisition data (GBL, RAM Data)' and 'Operation data (DELIIS)'. The acquisition data includes columns for NSN, QPA, LRU/SRU, Muc/Elec, SMM Code, MTBF, Imp-Importance cost, Page, Exc-Failure, Unit, Quantity, and Unit MTBF. The operation data includes columns for Y - Train Set (YES/NO) and Y - Test Set (YES/NO), with a specific example for '09 year January - 11 year December'.

Fig. 2. Training data set and test data set

Table 4. Army DELIIS Table example

Feature	Min	Max	Mean	Standard Deviation
QPA	0.0	423.0	1.61568	8.937497
LRU/SRU	0.0	11.0	6.025098	1.213168

Mechanical Components	0.0	1.0	0.084451	0.278074
Electronic Components	0.0	1.0	0.676177	0.467952
SMR Code	0.0	34.0	5.222531	8.521416
Importance Code	0.0	10.0	1.757276	2.766206
Unit Price	0.0	2.53E+09	3.09E+05	2.30E+07
Exchange Quantity	0.7	423.0	3.624317	10.122783
Unit failure Rate	0.0	13702.446	4.696663	137.36934
Quantity Failure Rate	0.0	13702.446	5.273576	137.65326
Unit MTBF	0.0	2.18E+09	3.89E+07	1.13E+08
MTBF	0.0	1.66E+09	7.47E+06	3.87E+07
consumption (Binary)	0.0	1.0	0.036707	0.188049

#### 4. 실험 분석 및 결과

실험 결과는 시계열 방법론인 MTBF와 머신러닝 방법론을 적용한 결과를 비교분석하였다. 정확도 측정방법은 Table 6과 같이 오차행렬(Confusion Matrix)을 활용하여 4가지 척도인 Accuracy, Recall, Precision, F1-Score를 산출하였다.

Table 5. Variable Descriptions

	Feature	Means
independent variable	QPA	Quantity Per Application
	LRU/SRU (Line/Sub Replaceable Unit)	Equipment WBS (Work Breakdown Structure)
	Mechanical components	Binary [0,1] data
	Electronic components	Binary [0,1] data
	Spare parts specific character code	SMR code, Maintenance code, Recoverability code
	Importance code	A sign that distinguishes whether an item is important or not
	Unit price	latest price
	Exchange quantity	Minimum exchange quantity in case of failure
	Unit failure rate	failure rate / exchange quantity
	Quantity failure rate	failure rate
dependent variable	Unit MTBF	MTBF * exchange quantity
	MTBF	Mean Time Between Failure
	Consumption Number	consumption from 2009 year ~ 2016 year (Binary)

머신러닝의 경우 시계열성을 고려하지 않고 예측 변수의 패턴을 파악하여 이를 예측하는 방법으로 학습이 진행된다. 머신러닝 방법인 DT, RF, ABC, SVM, KNN, VOTE 간 비교를 통해 성능을 평가하였다.

여섯 가지 모델별 성능은 Table 7과 Fig. 5에서 보는 바와 같다. 정확도는 모든 머신러닝이 MTBF의 기준 방

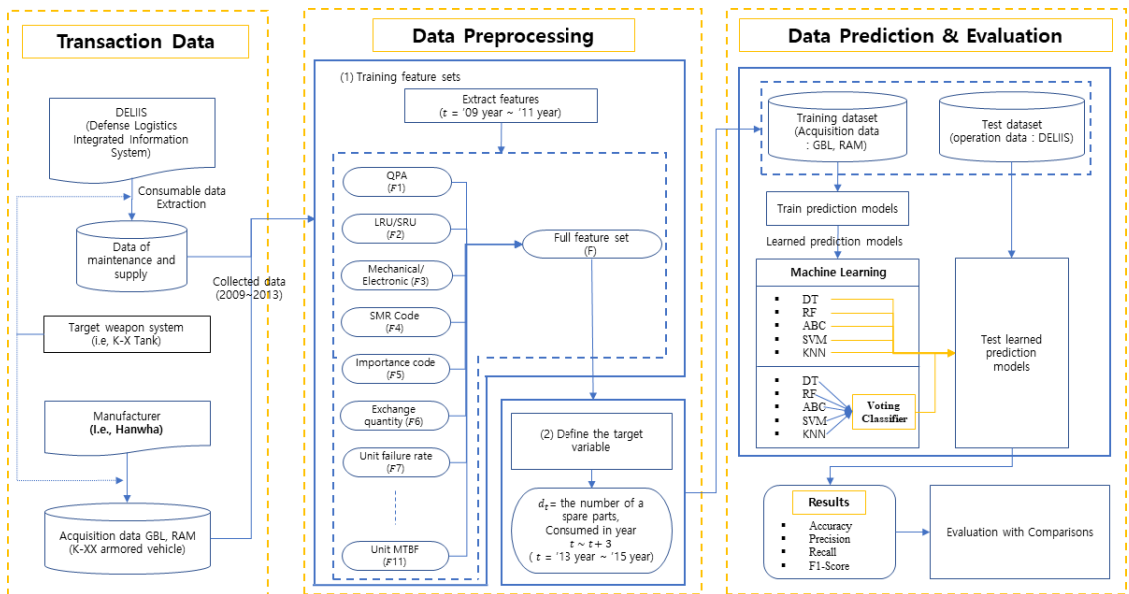


Fig. 3. Feature selection and predictive model evaluation process

법론 보다 좋았다. 단일 머신러닝 기법에서는 SVM 기법 좋았으며, 모든 Accuracy, Recall, Precision, F1-Score 정확도 측면에서 우수하였다. 이는 SVM 방법 특성인 초평면을 활용한 두 개의 범주로 학습 패턴이 그대로 데이터에 적합하게 적용된 결과라고 볼 수 있다. 기존 방법인 MTBF에 비해 SVM 방법은 Accuracy, Recall, Precision, F1-Score의 정확도가 12.1%, 7.8%, 1.2%, 4.6%의 제고 효과가 있었다.

VOTE 분류기는 Fig. 4와 같이 여러 방법론 결과들을 집계하여 가장 많은 표를 얻은 클래스를 최종 예측값을 예측하는 방법론이다.

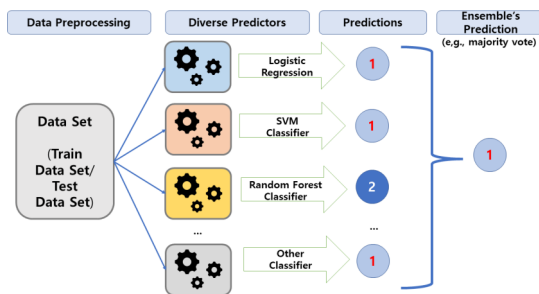


Fig. 4. Voting Classifier Learning Method

Table 6. Confusion matrix

		Predicted	
		Y (Positive)	N (Negative)
Actual	Y(Positive)	A (True Positive)	B (False Negative)
	N (Negative)	C (False Positive)	D (True Negative)
Accuracy = $\frac{A+D}{A+B+C+D}$		Recall = $\frac{A}{A+B}$	
Precision = $\frac{A}{A+C}$		F1-Score = $\frac{2(Precision \cdot Recall)}{(Precision + Recall)}$	

Table 7. Machine Learning Results

	Accuracy	Recall	Precision	F1-Score
MTBF	83.00%	87.20%	93.80%	90.40%
DT	85.10%	79.00%	85.00%	81.00%
RF	92.50%	91.00%	93.00%	92.00%
ABC	94.70%	95.00%	95.00%	95.00%
SVM	95.10%	95.00%	95.00%	95.00%
KNN	92.60%	92.00%	93.00%	92.00%
VOTE	95.50%	97.00%	95.50%	96.00%

클래스의 품목정확도는 Table 6과 같이 Training을 통한 예측 성능을 측정하기 위해 예측값과 실제값을 비교하기 위한 기준이다. 전체 머신러닝 기법 중에서는 Fig. 5와 같이 VOTE 분류기 학습이 다른 방법들 보다 모든 Accuracy, Recall, Precision, F1-Score 정확도 측면에서 우수하였다. 이는 VOTE 방법론의 특성인 각 분류기의 결과들을 집계하여 가장 많은 표를 얻은 클래스를 최종 예측값으로 분류하는 방식이다. 이는 기존 방법인 MTBF에 비해 VOTE 방법은 Accuracy, Recall, Precision, F1-Score의 정확도가 12.5%, 9.8%, 1.7%, 5.6%의 제고 효과가 있었다.




Fig. 5. Comparison of Machine Learning Results

## 5. 결론

본 연구에서는 CSP 예측을 위해 기존 기법과 여러 가지 제안한 기법을 비교 분석한 결과를 살펴보고 이에 따른 이상불 적용 방안을 제시하고자 한다.

획득 데이터와 운영 데이터를 기반으로 예측모형을 구성하였다. 본 연구에서 제안하였듯이 획득 데이터의 MTBF자료만을 활용하여 예측하는 모형이 아닌 운영 데이터도 함께 활용하여 정확도를 제고시킬 수 있었다. 이와 같은 결과는 장기 비수요 품목을 감소시키는 예산적 효과뿐만 아니라 장비 가동률도 높일 수 있는 효율적인 방법이다.

두 번째, 기존 시계열 기법 보다는 제안한 머신러닝 기법이 우수한 결과가 도출됨을 확인하였다. 시계열 기법인 MTBF 정확도는 83.0%이며, 제안한 DT, RF, ABC, SVM, KNN, VOTE 머신러닝 기법의 정확도는 각각 85.1, 92.5%, 94.7%, 95.1%, 92.6%, 95.5%를 보였다. 제시한 머신러닝 기법은 기존 MTBF 기법보다 평균 정확도 측면에서 모두 척도에서 우수함을 보였으며 특히, 제안한 기법 중 VOTE 기법이 가장 우수함을 확인할 수 있었다.

세 번째, 기존 품목 결정 방법 보다 본 연구 방법은 다양한 기법 및 변수를 적용하였다. 따라서 기존 CSP 적용 방법 보다 다양한 기법 및 변수 적용을 통해 비교분석이 가능하며, 발생 수요와 관련된 변수를 다양하게 고려할 수 있다. 본 연구에서는 획득 데이터와 운영 데이터의 정형 데이터만을 고려하였다. 추후 운영 데이터의 비정형 데이터를 추가된다면 현재 제시된 정확도 보다 신뢰성 높은 결과를 기대할 수 있을 것이다.

## References

- [1] J. D. Kim, B. H. Oh, H. R. Lee, R. J. Hong, S. B. Choi, "The development direction of the Concurrent Spare Parts requirement judgment system", Research Report, Korea Institute for Defense Analyses, Korea, 2017.
- [2] M. A. Oh, H. S. Choi, S. H. Kim, J. H. Jang, J. J. Jin, M. G. Chun, "A Study on Social security Big Data Analysis and Prediction Model based on Machine Learning", Research Report, Korea Institute for Health and Social Affairs, Korea.  
<http://repository.kihasa.re.kr/handle/201002/29093>
- [3] J. W. Choi, S. Y. Oh, J. W. Jang, "Using Big Data and Artificial Intelligence Techniques Corporate Default Prediction Research", *Korean Finance Association*, pp.396-435, 2017.  
<https://www.earticle.net/Article/A312198>
- [4] S. W. Bae, J. S. Yu, "Estimating the Real Estate Price Index Based on Sample House Price: Focusing on the Use of Machine Learning Method", *Korea Association For Housing Policy Studies*, vol. 26, no.4, pp.53-74, 2018.  
<https://www.kci.go.kr/kciportal/ci/sereArticleSearch/ciSereArtiView.kci?sereArticleSearchBean.artid=ARTO02407361>
- [5] J. J. Hwang, J. Y. Kim, J. M. M. Park, "Forecasting Innovation Performance via Deep Learning Algorithm : A Case of Korean Manufacturing Industry", *Journal of Korea Technology Innovation Society*, vol.21, No.2, pp.818-837, 2018.  
<https://www.kci.go.kr/kciportal/ci/sereArticleSearch/ciSereArtiView.kci?sereArticleSearchBean.artid=ARTO02367188>
- [6] P. S. Jang, J. Y. Yoo, S. H. Oh, "Predictive Analysis of the Impact of Corporate R&D Support Using Deep Learning", *Journal of Korea Technology Innovation Society*, vol.23, No.1, pp.20-41, 2020.  
<https://www.kci.go.kr/kciportal/ci/sereArticleSearch/ciSereArtiView.kci?sereArticleSearchBean.artid=ARTO02562219>
- [7] M. G. Song, J. M. Ma, "A study on predictive model for forecasting Airforce F-15K spare parts Using Data Mining", *Journal of the Korea Academia-Industrial cooperation Society*, Vol.22, No.8, pp.276-286, Aug. 2021.  
<https://www.kci.go.kr/kciportal/ci/sereArticleSearch/ciSereArtiView.kci?sereArticleSearchBean.artid=ARTO02748523>
- [8] J. D. Kim, H. J. Lee, "A Study on Forecasting Spare Parts Demand based on Data-Mining", *Journal of Internet Computing and Services*, Vol.18, pp.121-129, Feb. 2017.  
DOI: <https://doi.org/10.7472/jksii.2017.18.1.121>
- [9] J. D. Kim, "Text Mining-based Approach for Forecasting Spare Parts Demand of K-X Tanks", *In Proceedings of the 2018 IEEE Intefnational Conference on Industrial Engineering and Engineering Management (IEEM)*, pp.1652-1656, 2018.  
<https://ieeexplore.ieee.org/document/8607632>
- [10] B. Choi, J. H. Suh, "Forecasting Spare Parts Demand of Military Aircraft: Comparisons of Data Mining Techniques and Managerial Features from the Case of South Korea", *Sustainability*, Vol.12, pp.6045, 2020.  
DOI: <https://doi.org/10.3390/su12156045>
- [11] I. S. Na, K. K. Lee, M. K. Park, "The Computing Model of Demand Quantity for Optimal Current Spare Parts considering the Operational Availability under Budget", *Journal of the Korea safety management & science*, Vol.8, pp.167-180, 2006.
- [12] K. R. Kim, H. Y. Yong, K. S. Kwon, "Optimization for Concurrent Spare Part with Simulation", *Journal of the Korea Society for Simulation*, Vol.21, pp.79-88, 2012.  
DOI: <https://doi.org/10.9709/JKSS.2012.21.3.079>
- [13] S. I. Baek., Y. C. Ha, "Additional CSP calculation method considering Human Error", *Journal of the Korea Academia-Industrial cooperation Society*, Vol.22, pp.759-767, 2021.  
DOI: <https://doi.org/10.5762/KAIS.2021.22.1.75>

### 황 지 환(Ji-Hwan Hwang)

[정회원]



- 1997년 2월 : 해군사관학교 전자공학과 (공학사)
- 2001년 2월 : 연세대학교 전기전자공학과 (공학석사)
- 2011년 2월 : 고려대학교 전기전자공학과 (공학박사)
- 2018년 1월 ~ 현재 : 국방기술품절원 선임연구원

<관심분야>

신호처리, 인공지능, 시스템제어

박 흥 석(Hong-Suk Park)

[정회원]



- 1996년 2월 : 육군사관학교 병기 공학과 (공학사)
- 2005년 2월 : 서울대학교 기술정책학과 (공학석사)
- 2011년 7월 : Texas A&M 대학교 산업공학과 (공학박사)
- 2022년 3월 ~ 현재 : 금오공과대학교 조교수

<관심분야>

국방과학기술, 획득정책, 로봇, 인공지능, 스마트공장

---

김 재 동(Jae-Dong Kim)

[정회원]



- 2005년 2월 : 한양대학교 산업공학과 (공학사)
- 2007년 2월 : 한양대학교 산업공학과 (공학석사)
- 2020년 2월 : 고려대학교 산업경영공학과 (박사수료)
- 2007년 5월 ~ 현재 : 한국국방연구원 연구위원

<관심분야>

데이터마이닝, 수요예측, 재고관리, 최적화, 시뮬레이션