

# 머신러닝을 이용한 구축함 수리부속 예측 연구

정연오, 김재동  
한국국방연구원

yono5083@gmail.com, soobahkin@gmail.com

## A study on Destroyer Spare Parts Demand Forecasting using Machine Learning

Yeonoh Jeong, Jae-Dong Kim  
Korea Institute for Defense Analyses

### 요 약

국방분야에서 전력 운영유지를 위한 군수분야 운영 효율화는 매우 중요한 이슈이다. 군수분야의 효율성을 위해 적정한 수리부속 확보는 장비의 가동률과 예산 절감 차원에서 중요성이 크다. 이에 군은 다양한 기법을 활용하여 수리부속 수요예측에 대한 노력을 계속해 왔으나, 여전히 예측 정확도 향상을 위한 지속적인 노력이 요구된다. 이에 본 연구에서는 지난 9개년의 수리부속 수요데이터를 분석하고 다양한 머신러닝을 활용하여 예측정확도를 비교·분석하고, 가장 적합한 수리부속 수요예측 모델을 제안한다.

### 1. 서론

국방분야에서 전력을 운영하는 측면에서의 효율화는 큰 이슈 중 하나이다. 전력의 운영유지를 위한 군수분야 운영 효율화는 무기체계 총수명주기 관점에서 매우 중요하다. 이러한 군수 측면의 효율화는 미래 첨단 무기체계의 전력화로 인한 장비의 다양화로 인해 그 필요성이 더욱 커지고 있다[1].

이러한 군수분야의 효율적인 운영을 위해 적정한 수리부속 확보는 장비의 가동률을 보장하고, 예산을 절감하는 차원에서 중요성이 크다. 이에 정확한 수리부속의 수요를 예측하기 위한 많은 연구들이 진행되어왔다[2]. 대표적인 방법은 기존에 많이 사용되어 오던 시계열과 머신러닝이 있다.

먼저 시계열은 일정기간 동안 변화하는 변수를 분류하여 움직임을 예측하는 기법으로, 시계열 자료의 변동형태를 파악하고 이를 통해 자기 상관성과 이동평균과정 요인의 차분 변수의 다양한 조합을 통해 시계열 속성을 분석하는 ARIMA(Auto Regressive Integrated Moving Average) 모델에 대한 연구가 진행되어 왔으며, 시계열을 이용하여 특정 분야의 수요를 예측하고, 예측정확도를 비교하는 형태의 연구가 활발히 진행되어왔다[3][4]. 하지만 수리부속의 비선형적 특징을 땀에 따라 기존에 많이 사용되어

오던 시계열은 정확한 수요를 예측하는데 제한적이다[5].

이를 보완하기 위해, 최근에는 머신러닝을 수요예측 분야에 적용하기 위한 연구가 활발하게 진행되고 있다[6]. 머신러닝은 대규모 데이터에서 유용한 정보의 관계를 탐색하고 분석 및 모델화하여 지식을 식별하는 일련의 과정으로 정의할 수 있다. 머신러닝은 기존의 시계열이 갖는 비선형 형태의 수요(Non-Linear Demand) 예측에 대한 제한사항을 극복하기 위해, 시계열 속성과 불규칙적 수요특성에 대한 패턴을 학습시켜, 일정한 패턴의 수요를 보다 정확하게 예측할 수 있도록 한다. 특히 인공 신경망을 기반으로 설계된 딥러닝은 하드웨어의 발전과 빅데이터, 다양한 알고리즘의 개발로 수요예측 분야에서도 최근 활발하게 연구되고 있다[7].

본 논문에서는 구축함정인 000 체계를 분석 대상으로 한다. 000 체계는 수리부속에 대한 많은 양의 데이터를 활용할 수 있어 분석의 정확도를 기대할 수 있다. 이에 수년간의 대규모 데이터를 기존에 많이 사용되었던 시계열과 최신의 다양한 머신러닝 및 딥러닝을 활용하여 각 기법별 예측정확도를 비교·분석하고, 이를 통해 최적의 수리부속 수요예측 모델을 제안하고자 한다.

## 2. 관련 연구

시계열은 전통적으로 수리부속의 불규칙한 수요를 예측하기 위해 사용되어 온 기법으로, 일정기간 동안 과거 수요의 평균과 추세, 계절 요인 등을 이용하여 수요를 예측한다. 대표적인 시계열로는 산술평균법과 이동평균법 등이 있다. 산술평균법은 수요예측의 가장 단순한 형태로 과거기간 중 발생한 수요를 모두 평균하여 수요를 예측하는 것으로, 과거 자료가 충분히 많고, 균등하게 형성될 경우 활용되는 방법이다[8]. 이동평균법은 일정기간의 시계열 자료를 대상으로 산술평균 또는 가중평균을 구하여 계절적 및 불규칙 요인을 제거하는 방법으로 기간을 이동하면서 예측값을 산출하는 방법이다[8].

머신러닝은 경험적 데이터를 기반으로 학습을 하고 예측을 수행하며, 스스로 성능을 향상시키는 기법을 의미한다. 대표적인 머신러닝으로는 의사결정나무 알고리즘, 서포트 벡터 머신(SVM) 등이 있다. 의사결정 나무 알고리즘은 의사결정 규칙을 나무 구조로 나타내어 전체 자료를 몇 개의 소집단으로 분류하거나 예측을 수행하는 분석방법으로, 분류를 위한 목표변수에 영향을 줄 수 있는 입력 변수들을 이용해 최적의 분류를 위한 의사결정 규칙을 트리 구조로 나타내어 준다[9]. 서포트 벡터 머신은 다차원 공간에 표시되는 점들 사이에 의사결정 초평면을 사용하여 유사한 클래스의 값들을 그룹으로 나누는 알고리즘이다[10].

딥러닝은 머신러닝의 한 종류로서 인공 신경망을 기반으로 발전된 것으로, 우수한 학습과 분류 성능을 보여준다. 대표적인 딥러닝으로는 순환신경망(RNN), LSTM(Long Short-Term Memory) 등이 있다. RNN은 각 은닉층에 저장된 특정 시점의 데이터 정보를 다음 시점으로 전달하도록 개발된 모델로써, 데이터 간의 비선형적 관계뿐 아니라, 시간 정보까지도 고려할 수 있다[11]. LSTM은 현재 가장 많이 사용되는 순환신경망 구조의 기법으로, 전통적인 순환신경망 구조에서 은닉 계층의 유닛들을 LSTM 블록(Block)으로 대체시킨 형태를 갖는다[12].

이러한 다양한 기법들이 다양한 분야의 수요예측 정확도를 향상시키기 위한 방법으로 활용되어왔다.

## 3. 수리부속 수요예측 모델 제안

본 연구의 분석 대상인 000 체계는 주력 구축함정으로서, 전시 해양우세 확보와 평시 해상침투 대응

등 핵심 임무를 수행하는 대표적인 구축함이다. 또한 해군의 가장 큰 비중을 차지하는 체계로써, 분석 대상으로 적합하다고 판단하였다.

실험과정은 [그림 1]과 같이 5단계 프로세스를 통해 진행하였다.



[그림 1] 실험 절차

먼저 대상 체계에 대한 데이터 수집은 군에서 2009년부터 운영 중인 장비정비정보체계(Defense Logistics Integrated Information System)를 이용하였다. 장비정비정보체계는 무기체계의 주 장비 중심으로 수리부속의 보급 및 정비 관련 사항을 최신 정보 기술을 이용하여 개발한 정보체계로써, 육·해·공군의 편성 부대로부터 국방부에 이르기까지 정비 관련 부서에서 사용하는 통합정보지원 시스템이다.

해군 장비정비정보체계에서 수집된 데이터에는 정비날짜, 정비당일 소모된 수리부속품목의 개수, 대당 구성수 등 00개 항목이 포함되어 있다. 이 데이터에서 수리부속별 수요예측을 위해 데이터를 품목별로 재정리하였으며, 수리부속 품목 수는 총

16,236개이다. 또한, 수리부속별로 2010년부터 2018년까지 9년간의 연도별 소모개수 데이터를 추출하여, 아래 <표 1>과 같이 총 9개의 변수를 사용하였다.

&lt;표 1&gt; 변수 설명

변 수	의 미
'10년 소모개수	'10~'18년 수리부속 품목별 연도별 소모 개수 합
'11년 소모개수	
'12년 소모개수	
'13년 소모개수	
'14년 소모개수	
'15년 소모개수	
'16년 소모개수	
'17년 소모개수	
'18년 소모개수	

실험방법은 2018년의 품목 발생 기준으로 16,236개 품목 중 8,118개의 발생 품목과 8,118개의 미발생 품목으로 분류하였으며, <표 2>와 같이 모델 성능측정은 분류결과표(Confusion Matrix)의 정확도로 측정하였다.

&lt;표 2&gt; 변수 설명

구분	예측 발생	예측 미발생
실제 발생	A	B
실제 미발생	C	D
Accuracy	$\frac{A + D}{A + B + C + D}$	

본 연구에서는 전통적인 시계열 중 산술평균법, 단순이동평균법, 가중이동평균법, 선형이동평균법, 최소자승법 등 5가지 모델을 사용하였다. 머신러닝은 DT(Decision Tree), NB(Naive Bayesian), SVM(Support Vector Machine), LR(Logistic Regression) 등 4가지 모델을, 딥러닝은 MLP(Multi Layer Perceptron), RNN(Recurrent Neural Network), GRU(Gated Recurrent Units), LSTM(Long Short Term Memory), Attention RNN, Attention GRU, Attention LSTM 등 7가지 모델을 사용하였다. 분석 도구는 Python을 사용하였다.

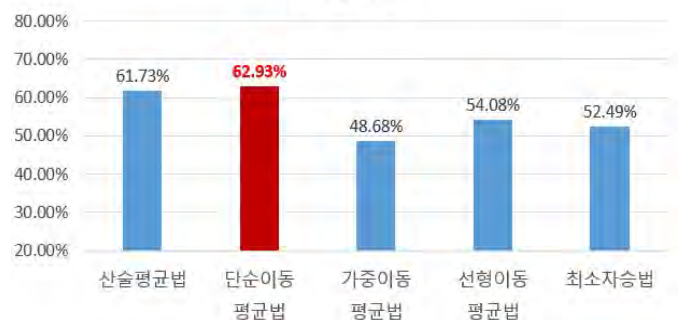
#### 4. 실험 결과

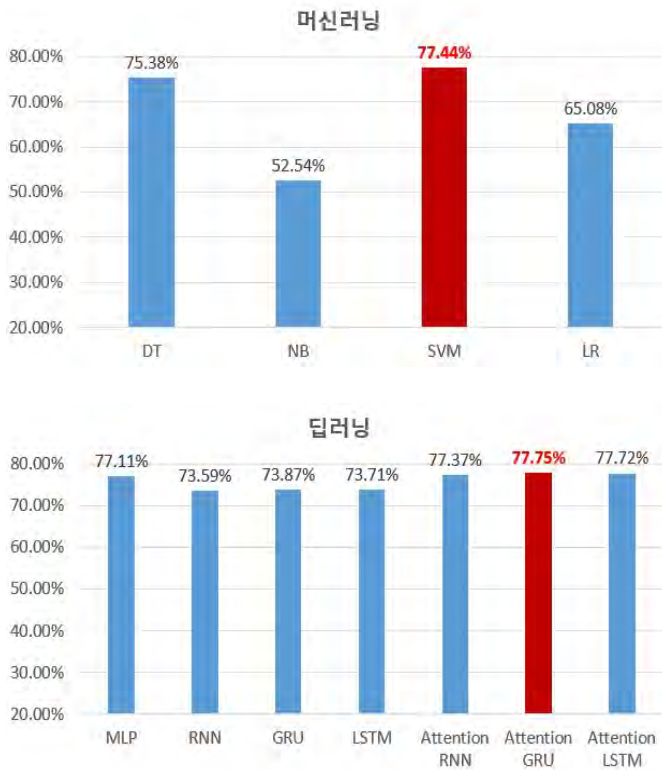
본 연구에서는 시계열과 머신러닝, 그리고 머신러닝의 한 분야인 딥러닝을 적용하여 각각의 예측정확도를 비교하였다. 실험방법은 훈련셋(training set)과 테스트셋(test set)을 7:3의 비율로 나누어 10겹 교차검증(10-fold cross validation) 방식을 사용하였다. 예측정확도를 기준으로 모델의 성능을 평가한 결과, <표 3>에서 보는 바와 같이, 시계열에서 가장 좋은 정확도를 보인 모델은 단순이동평균법으로 62.93%, 머신러닝에서 가장 좋은 정확도를 보인 모델은 SVM으로 77.44%, 딥러닝에는 Attention GRU 모델이 77.75%로 가장 좋은 정확도를 보였다. 본 실험을 토대로 기존의 시계열에 비해 머신러닝, 딥러닝이 보다 높은 예측 정확도를 보임을 확인하였다.

&lt;표 3&gt; 모델별 예측 정확도

방 법		정확도
시계열	산술평균법	61.73%
	단순이동평균법	62.93%
	가중이동평균법	48.68%
	선형이동평균법	54.08%
	최소자승법	52.49%
머신러닝	DT(Decision Tree)	75.38%
	NB(Naive Bayesian)	52.54%
	SVM(Support Vector Machine)	77.44%
	LR(Logistic Regression)	65.08%
딥러닝	MLP(Multi Layer Perceptron)	77.11%
	RNN(Recurrent Neural Network)	73.59%
	GRU(Gated Recurrent Units)	73.87%
	LSTM(Long Short-Term Memory)	73.71%
	Attention RNN	77.37%
	Attention GRU	77.75%
	Attention LSTM	77.72%

시계열 기법





## 5. 결론

본 논문에서는 해군의 대표적인 구축함정인 000 체계의 수리부속 수요예측 정확도 제고를 위하여 지난 9년간의 수리부속 수요데이터를 분석하고, 시계열, 머신러닝 및 딥러닝의 다양한 모델을 활용하여 수리부속 수요예측 결과를 비교 분석하고, 최적의 모델을 제안하였다. 제안한 머신러닝 및 딥러닝 모델이 기존의 수요예측 기법들에 비해 향상된 정확도를 나타냈다는 점에서 의미를 갖는다. 본 연구에서는 수리부속 소모이력의 정형 데이터만을 분석에 활용하였으나, 향후 장비의 운용 관련 변수 등을 추가하고, 텍스트 마이닝 기법을 활용한 비정형 데이터 분석 기법을 추가한다면, 보다 정확한 수요예측 결과를 얻을 수 있을 것으로 기대된다.

## 참고문헌

- [1] Pinzariu, S., Minea, C.D., "The Military Units' Logistic Support Principles," Land Forces Academy Review Vol. XXIV, No 1(93), 2019.
- [2] Regatteri, A., Gamberi, M., Gamberini, R., and Manzini, R., "Managing lumpy demand for aircraft spare parts," Journal of Air Transport Management, 11, 426-431., 2005.
- [3] Shadra, R., and Patil, R., "Connectionist

approach to time series prediction: An empirical test," J. Intell. Manuf., 3, 317-323.

[4] Syntetos, A.A., and Boylan, J.E., "On the bias of intermittent demand estimates," Int. J. Production Economics, 71, 457-466., 2001.

[5] Hill, T., O'Conner, M., and Remus, W., "Artificial neural network models for times forecasts," Management Science, 42, 1082-1092., 1996.

[6] Gutierrez. R.S., Solis, A.O., and Mukhopadhyay, S., "Lumpy demand forecasting using neural networks," Int. J. Production Economics, 111, 409-420., 2008.

[7] Liao, S., Zhou, L., Di, X., Yuan, B., and Xiong J., "Large-scale short-term urban taxi demand forecasting using deep learning," In Proceedings of the 23<sup>rd</sup> Asia and South Pacific Design Automation Conference, Jeju, Korea, 22-25 January 2018; pp. 428-433.

[8] Laptev, Nikolay, et al. "Time-series extreme event forecasting with neural networks at uber." International Conference on Machine Learning. 2017.

[9] Tanizaki, T., Hoshino, T., Shimmura, T., and Takenaka, T., "Demand forecasting in restaurants using machine learning and statistical analysis," 12<sup>th</sup> CIRP Confernece on Intelligent Computation in Manufacturing Engineering, 679-682.

[10] Candelieri, A., Giordani, I., Archetti, F., Barkalov, K., Meyerov I., Polovinkin A., Sysoyev, A., Zolotykh N., "Tuning hyperparameters of a SVM-based water demand forecasting system through parallel global optimization," Computers & Operations Research, Volume 106, 202-209., 2019.

[11] Shi, H., Xu, M. Li, R., "Deep Learning for Household Load Forecasting-A Novel Pooling Deep RNN," IEEE Transactions on Smart Grid, 5271-5280., 2017.

[12] Kong, W., Dong, Z.Y., Jia, Y., David J.H., Xu, Y., Zhang, Y., "Short-Term Residential Load Forecasting Based on LSTM Recurrent Neural Network," IEEE Transactions on Smart Grid, 841-851., 2017.