

# 데이터 마이닝을 이용한 패트리엇 수리부속의 간헐적 수요 예측에 관한 연구

박천규<sup>1</sup>, 마정목<sup>2\*</sup>

<sup>1</sup>공군 제2방공유도탄여단, <sup>2</sup>국방대학교 국방과학학과

## A Study on Intermittent Demand Forecasting of Patriot Spare Parts Using Data Mining

Cheonkyu Park<sup>1</sup>, Jungmok Ma<sup>2\*</sup>

<sup>1</sup>2nd Air Defense Missile Brigade, Airforce

<sup>2</sup>Department of Defense Science, Korea National Defense University

**요약** 군에서는 수요예측에 대한 중요성을 인식하여 수리부속에 대해 예측 정확도 향상을 위한 많은 연구가 이루어지고 있다. 수리부속 수요예측은 예산 운영과 장비 가동률 측면에서 매우 중요한 요소가 되고 있다. 그러나 현재 군에서 적용 중인 시계열 모형으로는 수요량의 변동과 발생주기가 일정하지 않은 간헐적 수요에 대해서는 예측에 한계가 있는 실정이다. 따라서, 본 연구는 공군 패트리엇 수리부속의 간헐적 수요에 대한 예측 정확도를 제고하는 방법을 제시하고자 하였다. 이를 위해서 2013년부터 2019년까지의 701개의 수리부속 소모개수를 토대로 수요 유형을 구분하여 수리부속의 간헐적 수요 자료를 수집하였다. 또한, 장비 고장에 영향을 줄 수 있는 외부 요인으로는 기온, 장비운영시간을 식별하여 입력변수로 선정하였다. 그 후, 소모개수와 외부 요인을 통해 군에서 적용하는 시계열 모형과 제안하는 데이터 마이닝 모형으로 예측을 실시하여 모형별 예측 정확도를 판단했다. 예측 결과로 기존의 시계열 모형과 비교하여 데이터 마이닝 모형의 예측 정확도가 높았으며, 그 중 다층 퍼셉트론 모형이 가장 우수한 성능을 보였다.

**Abstract** By recognizing the importance of demand forecasting, the military is conducting many studies to improve the prediction accuracy for repair parts. Demand forecasting for repair parts is becoming a very important factor in budgeting and equipment availability. On the other hand, the demand for intermittent repair parts that have not constant sizes and intervals with the time series model currently used in the military is difficult to predict. This paper proposes a method to improve the prediction accuracy for intermittent repair parts of the Patriot. The authors collected intermittent repair parts data by classifying the demand types of 701 repair parts from 2013 to 2019. The temperature and operating time identified as external factors that can affect the failure were selected as input variables. The prediction accuracy was measured using both time series models and data mining models. As a result, the prediction accuracy of the data mining models was higher than that of the time series models, and the multilayer perceptron model showed the best performance.

**Keywords** : Data Mining, Intermittent Spare Parts, Demand Forecasting, MultiLayer Perceptron, Patriot

---

\*Corresponding Author : Jungmok Ma(Korea National Defense Univ.)

email: jxm1023@gmail.com

Received December 11, 2020

Accepted March 5, 2021

Revised January 29, 2021

Published March 31, 2021

## 1. 서론

국방과학기술용어사전에서는 수요예측을 과거의 수요 실적에 입각하여 장차의 수요량을 예측하는 것으로 정의하고 있다[1]. 수요예측의 중요성은 점차 강조되고 있는데, 그 이유는 수요예측을 통해 다가 수요에 빠르게 대처하여 조직의 목표를 달성할 수 있기 때문이다. 이에 따라 민간분야에서는 수요예측을 기업의 정책이나 경영에 있어서 핵심적인 요소로 인식하고 있다.

최근에는 민간분야 뿐만 아니라 군에서도 수요예측에 대한 중요성을 인식하여 이에 대한 연구가 활발히 이루어지고 있다. 특히, 군에서의 수요예측은 수리부속에 대하여 많은 연구가 수행되고 있다. 수리부속 수요예측은 효율적인 예산 운영과 장비의 가동률을 유지하는 측면에서 매우 중요하다고 할 수 있다. 만약 수리부속 수요예측의 정확성이 낮다면 수리부속 보유량의 과부족분이 발생할 수 있으며, 수리부속을 과도하게 많이 보유한다면 예산이 불필요하게 사용될 수 있다. 반대로, 수리부속의 보유량이 부족하다면 수리부속 조달 문제로 장비의 가동률이 저하될 수 있다. 해당사례를 살펴보면, 군에서는 2018년도에 보다 정확한 수리부속 수요예측을 위해 한국국방연구원(KIDA: Korea Institute for Defence Analyses)에서 개발한 예측 모델을 사용하였다. 이를 통해 예측 정확도를 70%에서 79%로 향상시켰으며, 약 129억 원의 예산 절감 효과를 거뒀다[2]. 또한, 2012년도에 한 패트리엇 포대가 특정 수리부속의 재고가 없는 문제로 132일 동안 가동이 중단되어 가동률이 현저히 저하된 사례가 있었다[3]. 두 사례를 통해 알 수 있듯이 효율적인 예산 운영과 장비의 가동률 유지를 위해서는 보다 정확한 수리부속 수요예측이 필수적이라 할 수 있다.

공군에서는 공군규정 5-23 “수리부속 관리”에 따라 과거 5년간의 분기별 소모실적을 통해 시계열 기법으로 수요를 예측하고 있다[4]. 예측을 위한 방법으로는 시계열 기법 중 가중이동평균법, 선형이동평균법, 추세분석법, 지수평활법, 선형지수평활법을 적용한다. 구체적으로는 과거 17개 분기의 소모실적 자료를 사용하여 5가지 기법으로 최근 3개 분기의 수요를 예측한다. 그 후에는, 3개 분기별로 각 기법의 예측치와 실제 소모량과의 차이가 가장 작은 기법으로 미래 분기의 수요를 예측하는 방법이며, 이를 도식화하면 Fig. 1과 같다. 그러나, 현재의 방법은 과거 소모실적의 경향성만을 토대로 한다는 한계점이 있다.

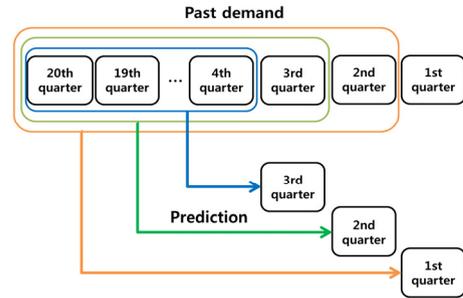


Fig. 1. Demand forecasting process in airforce

한편, 공군은 항공기와 탄도탄을 방어하기 위해 2008년부터 지대공 유도탄인 패트리엇를 도입하여 현재 0개 포대를 운용중이다. 패트리엇는 현재 국내에서 탄도탄을 방어할 수 있는 유일한 무기체계로서, 최근 증가하고 있는 탄도탄 위협을 고려한다면 그 임무의 중요성은 점차 증대되고 있다. 이에 따라, 패트리엇 장비의 가동률을 보장하기 위해 보다 정확한 수리부속 수요예측의 필요성이 강조되고 있다. 2013년부터 2019년까지 소모된 패트리엇의 수리부속은 701개이며, 이 중 약 98.6%(691개)가 간헐적 수요로 분류된다. 공군에서는 간헐적 수요를 5년간 연간수요가 평균 1회 미만인 수요로 정의하고 있으며, 현재 적용중인 방법으로 간헐적 수요를 예측했을 때 주기성을 갖는 수요에 비해 예측 정확도가 40% 이상 낮은 것으로 분석했다[5]. 따라서, 패트리엇 수리부속의 대부분인 간헐적 수요를 예측하기 위해서는 공군에서 적용중인 방법이 갖는 한계점을 보완할 필요가 있을 것이다.

군 분야에서 이루어진 수리부속 수요예측에 대한 선행 연구는 다음과 같다. H. T. Kim은 육군의 ATCMS, K-9 자주포, ARTHUR-K에 대해 수리부속 소모개수와 표준 단가를 설명변수로 선정하여 데이터 마이닝으로 수요예측을 수행하였다. 이 때, 지도학습과 비지도학습을 병행하여 예측 정확도를 더욱 높이는 방안을 제안했다[6]. J. D. Kim은 공군 F-XX 항공기의 수리부속 수요예측을 위해 수리부속의 소모율, 소모개수 등을 변수로 하여 데이터 마이닝을 활용하였다[7]. J. S. Kim은 공군 B 항공기의 수리부속 수요를 장단기 기억 메모리(LSTM: Long-Short Term Memory)를 활용하여 예측하였다[8]. 그러나, 위의 연구들은 수리부속의 수요 유형을 고려하지 않은 채 모든 수리부속에 대해 일괄적으로 수행한 연구라는 한계가 있다.

간헐적 수요를 예측하기 위한 연구는 J. D. Croston이 변형된 지수평활법을 제시하면서 시작됐다[9]. 이 후,

J. D. Croston의 모형을 수정한 간헐적 수요예측 방법을 여러 연구에서 제안하였지만, 수요의 크기와 간격을 각각 정규분포와 기하분포로 가정했다는 점에서 한계가 있다 [10]. 최근 연구에서는 M. K. Park이 공군 KF-16C의 수리부속을 주기성을 갖는 수리부속과 간헐적 수요를 갖는 수리부속으로 구분하여 수요예측 방법을 제안하였다. 이 때, 공군에서 사용하는 5가지 시계열 기법을 활용하는 다수결 투표 및 hybrid 방법을 제시하였다[11]. B. H. Oh는 합성 수리부속의 간헐적 수요예측을 위해 LSTM, 다층 퍼셉트론(MLP: MultiLayer Perceptron), 순환 신경망(RNN: Recurrent Neural Network), 게이트된 순환 뉴트(GRU: Gated Recurrent Unit)과 같은 딥러닝을 활용하였다[12]. 그러나, M. K. Park과 B. H. Oh의 연구는 수리부속의 소모실적만을 변수로 삼았으며, 기상과 같은 외부 요인은 고려하지 않았다.

T. G. Kim은 공군 E-737 수리부속 중 간헐적 수요를 갖는 수리부속에 대해 수리부속 소모개수와 더불어 비행 시간/횡수당 소모율, 분기별 온도/습도의 외부 요인을 고려하여 데이터 마이닝으로 수요예측을 수행하였다. 또한, 4년간의 자료를 1년부터 4년까지의 기간으로 세분화하여 시계열 모형과 데이터 마이닝 모형의 예측 정확도를 비교하여 제시하였다[13]. 그러나, 군에서는 수리부속의 수요를 예측하기 위해 5년간의 자료를 사용하므로, T. G. Kim이 제안한 모형을 군에서 적용하는 모형과 비교하는 것은 적절하지 않을 수 있다.

본 연구와 선행연구의 차이점은 패트리엇을 대상 장비로 하여 간헐적 수요에 대한 연구를 수행했다는 점이다. 패트리엇은 국내에서 유일하게 항공기뿐만 아니라 탄도탄까지 방어가 가능한 대공방어에 핵심역할을 수행하고 있는 무기체계이다. 그러나, Table 1과 같이 공군의 KF-16, E-737 등과 같은 항공기에 대한 연구는 활발히 이루어지고 있지만, 패트리엇에 대한 연구는 수행되지 않았다. 또한, 본 연구는 패트리엇 수리부속의 간헐적 수요에 대한 예측 정확도를 높이기 위해 수리부속 수요에 영향을 미치는 외부 요인을 고려하였다. 외부 요인은 패트리엇의 정비 주무부서에서 분석한 자료에 근거하여 기온과 장비운영시간을 식별하였으며, 이를 예측모형에 반영하였다[13]. 더불어, T. G. Kim의 연구에서는 제한되었으나, 수리부속 수요를 예측하기 위해 군에서 적용하는 모형과 본 연구에서 제안하는 모형의 성능을 비교하였다. 이를 위해 각 모형의 자료기간을 군에서 적용하는 기간과 동일하게 5년으로 설정하였다.

Table 1. Relevant prior research

	Subject	Data Type	Techniques	Comparison with the military method (Data period)
H. T. Kim [6]	ATCMS, K-9, ATHUR-K (Army)	Not classified	Data Mining	yes (6 years)
J. D. Kim [7]	F-XX (Airforce)	Not classified	Data Mining	no (5 years)
J. S. Kim [8]	B aircraft (Airforce)	Not classified	LSTM	no (6 years)
M. K. Park [11]	KF-16C (Airforce)	Intermittent demand	SARIMA	yes (5 years)
B. H. Oh [12]	Vessels (Navy)	Intermittent demand	Deep Learning	no (7 years)
T. G. Kim [13]	E-737 (Airforce)	Intermittent demand	Data Mining	yes (4 years)
This paper	Patriot (Airforce)	Intermittent demand	Data Mining	yes (7 years)

## 2. 본론

### 2.1 연구수행 방법

패트리엇 수리부속의 간헐적 수요 예측을 위해 Fig. 2의 순서로 연구수행 방법을 제시한다. 먼저 패트리엇 수리부속의 소모실적을 수집하여 그 중 간헐적 수요 유형을 분류하였다. 그 후, 입력변수를 선정하여 시계열 모형과 데이터 마이닝 모형으로 수요 예측을 진행하였으며, 최종적으로 모형별 예측 정확도를 비교하는 절차를 수행하였다.

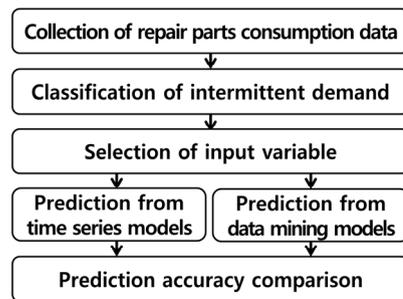


Fig. 2. Proposed Study Process

### 2.2 자료수집 및 입력변수 선정

#### 2.2.1 수리부속 소모실적 수집 및 분류

본 연구에서는 공군 패트리엇의 수리부속을 연구 대

상으로 하였다. 연구를 위해 공군 장비정보체계(DELIS/F: Defense Logistics Integrated Information System/airForce)를 이용하여 2013년부터 2019년까지 28개 분기의 수리부속 소모개수를 수집하였다.

그 후, 수요 유형별로 수리부속을 분류하기 위해 Ghobbar의 연구[14]에 따라 평균발생주기(ADI: Average Demand Interval)와 변동계수(CV: Coefficient of Variation)를 이용하였다. ADI는 수요발생 간 평균 간격을 의미하며, CV는 수요의 표준편차를 평균으로 나눈 값으로 각각 Eq. (1),(2)와 같이 산출된다.

$$ADI = \frac{\sum_{i=1}^N t_i}{N} \quad (1)$$

Where, N denotes number of periods having non-zero demand,  $t_i$  denotes the time period between two consecutive demand periods

$$CV = \frac{\sqrt{\frac{\sum_{i=1}^N (\epsilon_i - \epsilon)^2}{N}}}{\epsilon} \quad (2)$$

Where,  $\epsilon_i$  denotes the average demand in period,  $\epsilon$  denotes the average demand

산출된 ADI와 CV로 수리부속별 수요 발생 유형을 Fig. 3과 같이 구분하였으며, smooth 수요 1개, erratic 수요 9개, lumpy와 intermittent 수요는 691개로 분류되었다. 이 때, smooth와 erratic 수요를 제외하고, 전체 중 98.6%를 차지하는 간헐적 수요의 lumpy와 intermittent 수요를 연구대상으로 선정하였다.

ADI=1.32	
Erratic	Lumpy
Smooth	Intermittent

CV=0.49

Fig. 3. Demand Classification

### 2.2.2 입력변수 선정

패트리어트 수리부속 수요에 영향을 미치는 외부 요인을 식별하기 위해 2009년부터 2019년까지 패트리어트 정비 주무부서의 분석 자료를 수집했다. 먼저, 장비 고장 건수는 총 000건 이었으며, 이를 분기별 비율로 구분하여 Fig. 4와 같이 나타냈다.

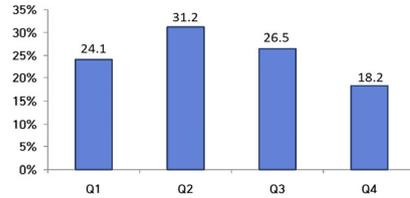


Fig. 4. Statistics by failure time

분석 자료에 따르면 수리부속 중 회로카드, 케이블 등은 고온다습한 기후에 취약한 것으로 분석됐다. 또한, 수리부속별로 혹서기 및 혹한기 등의 계절적 취약요인과 장비운영시간이 고장에 영향을 미친다고 분석했다[15]. 이를 토대로 701개 수리부속의 소모개수와 함께 2013년부터 2019년까지 28개 분기의 기온과 장비운영시간을 변수로 선정하였다. 여기에 장비운영시간과 수리부속 소모개수를 가공하여 장비운영시간당 수리부속 소모율(소모개수/장비운영시간)을 변수로 추가하였다. 이는 분기별 시계열 유형의 자료로서 2012년 이전 자료의 수집이 제한되어 특정 기간의 자료만을 활용했다는 한계점이 있었다.

입력변수 중 기온은 공군 기상정보체계와 기상청 기상자료개방포털의 자료를 이용하여 평균값을 수집하였다. 장비운영시간은 패트리어트를 구성하는 교전통제소(ECS: Engagement Control Station), 레이더(RS: Radar Set), 발사대(LS: Launching Station)로 구분하여 각각의 운영시간을 DELIS/F에서 수집하였으며, 총 112개의 변수를 선정하여 Table 2와 같이 나타냈다.

Table 2. Variable description

Variable	Meaning
$d_i$	Quarterly number of demand
$t_i$	Quarterly average temperatures
$ot_i$	Quarterly average operating time
$r_i$	Quarterly consumption rate
$i$	Quarter : 131, 132, 133, ..., 194 (e.g. 131 means the first quarter of 2013)

### 2.3 모형 구축

수요예측을 위한 모형은 현재 공군에서 적용중인 5가지의 시계열 모형과 본 연구에서 제안하는 데이터 마이닝 모형으로 구축하였다. 또한, 두 모형의 비교를 위해 수집한 7년간의 전체자료를 공군에서 적용하는 기간인 5년씩 2013년~2017년, 2014년~2018년, 2015~2019년으로 3개의 데이터 세트로 구분하였다.

데이터 마이닝이란 방대한 데이터를 이용하여 유의미한 연관성과, 추세를 발견하는 과정으로 정의된다. 데이터 마이닝은 분류, 예측, 데이터 군집화의 기능이 있으며, 최근에는 금융, 산업, 의학뿐만 아니라 군의 수요예측 분야에도 활용되고 있다[16]. 본 연구에서 데이터 마이닝을 사용한 이유는 현재 공군에서 적용중인 방법은 자기상관만을 고려한 예측 방법이지만, 데이터 마이닝은 자기상관 외에 여러 외부 요인을 포함하여 예측을 수행하기에 용이하기 때문이다. 본 연구는 예측하고자 하는 분기의 소모개수를 종속변수로 하는 자료이므로, 데이터 마이닝의 지도학습 모형을 활용하였다. 그 중 예측 정확성과 유용성이 높은 것으로 평가된 선형회귀 모형, 서포트 벡터 머신(SVM: Support Vector Machine, 이하 SVM) 모형, 다층 퍼셉트론(MLP: MultiLayer Perceptron, 이하 MLP) 모형을 선정하여 예측을 수행하였다.

### 2.3.1 시계열 모형

가중이동평균법은 일정기간의 자료에 가중치를 주는 방법이며, Eq. (3)과 같이 정의된다. 가중치의 합은 1이 되도록 설정하며, 공군의 적용방법과 같이 예측시점 직전 분기부터 차례로 0.5, 0.3, 0.2를 부여했다.

$$F_{t+i} = A_t \times w_1 + A_{t-1} \times w_2 + \dots + A_{t-i+1} \times w_i \quad (3)$$

Where,  $F_{t+i}$  denotes predicted value at t+i,  $A_t$  denotes real value at t,  $w_i$  denotes weight at i

선형이동평균법은 1차 이동평균 값과 이를 다시 이동평균한 2차 이동평균 값을 활용하는 방법이다. 이 방법은 추세요인에 따라 발생가능한 과대 또는 과소 추정분을 감소시킬 수 있으며, Eq. (4)와 같이 정의된다.

$$F_{t+i} = MA + (MA - MA') = 2MA - MA' \quad (4)$$

Where,  $F_{t+i}$  denotes predicted value at t+i, MA denotes first moving average value,  $MA'$  denotes second moving average value

추세분석법은 Eq. (5)와 같이 정의되며, 관측치와 예측치의 편차 제곱 합이 최소가 되는 추세를 찾아 이를 통해 예측을 수행한다.

$$Y = \beta_0 + \beta_1 X \quad (5)$$

Where,  $\beta_0$  denotes y intercept,  $\beta_1$  denotes slope

지수평활법은 0부터 1사이의 평활상수를 적용하여 예측오차가 가장 작은 평활상수로 예측하는 방법이다. 이

방법은 Eq. (6)과 같이 정의되며, 공군의 적용방법과 같이 0.1 간격으로 평활상수를 적용하였다.

$$F_{t+i} = \alpha A_t + (1-\alpha)F_t, 0 \leq \alpha \leq 1 \quad (6)$$

Where,  $F_{t+i}$  denotes predicted value at t+i,  $A_t$  denotes real value at t,  $\alpha$  denotes smoothing constant

선형지수평활법은 1차 지수평활 값과 2차 지수평활 값을 활용하는 방법이다. 이 때, 1차에 선정된 평활상수를 2차 지수평활에도 동일하게 적용하며, Eq. (7)과 같이 정의된다.

$$F_{t+i} = F_t + (F_t - F_t') = 2F_t - F_t' \quad (7)$$

Where,  $F_{t+i}$  denotes predicted value at t+i,  $F_t$  denotes exponential smoothing value,  $F_t'$  denotes double exponential smoothing value

### 2.3.2 데이터 마이닝 모형

선형회귀 모형은 변수간의 인과성을 분석하고 여러 변수를 포함하여 분석하기에 용이한 모형이다. 이 모형은 종속변수 Y와 입력변수  $X_1, X_2, \dots, X_p$  사이의 선형관계를 적합시키기 위해 사용되며, 모집단에 대하여 Eq. (8)과 같은 관계를 가정하여 분석을 진행한다.

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_p X_p + \epsilon \quad (8)$$

Where,  $\beta_i$  denotes regression coefficient,  $\epsilon$  denotes noise

모형 구축을 위해서는 단계적 변수선택방법과 변수간의 상관성 확인을 통해 변수 중 통계적으로 유의미한 속성만을 선택하였다.

SVM 모형은 입력공간에서 두 그룹을 최대한 멀리 분류하는 고차원의 초평면을 이용하여 분류 또는 예측을 수행하며, 인공신경망 모형에 비해 과적합 문제를 최소화할 수 있는 모형으로 평가받는다. 본 연구에서는 비선형 문제를 예측하기에 유용한 다항식 커널(polynomial kernel) 함수를 이용하였으며, 과적합을 방지하기 위해 이상치를 허용하는 매개변수 c는 1로 설정하였다.

MLP 모형은 인공신경망을 기반으로 하며, 퍼셉트론으로 이루어진 여러 개의 층을 연결한 모형으로, 입력변수와 종속변수 사이의 복잡한 관계를 파악하는데 매우 유연하여 선형 및 비선형적인 문제에 적용이 가능하다. 이 모형에서는 활성함수가 도출한 결과의 오차가 최소가 되도록 입력층에서의 가중치를 결정한다. MLP 모형은 입출력변수가

0에서 1사이의 값일 때 가장 좋은 결과를 나타내기 때문에 입력변수들을 0에서 1사이의 정규화된 값으로 변형하였으며, 은닉층과 은닉노드 수에 따라라도 예측값이 달라지므로 이를 변화시켜가며 모형을 구축하였다[16].

### 2.4 모형별 예측 결과

모형별 예측 결과를 확인하기 위해 3개 데이터 세트에서 각각 2017년~2019년의 4분기 소모개수를 예측대상으로 설정하였으며, 이를 도식화하면 Fig. 5와 같다.

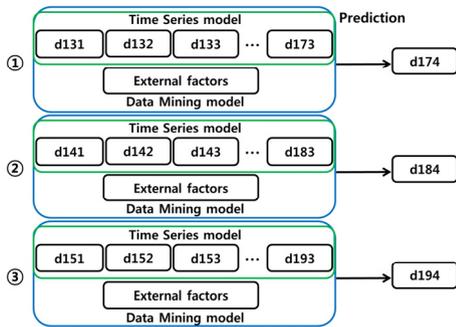


Fig. 5. Data set composition and prediction target

데이터 마이닝 모형으로 예측시 과적합을 방지하기 위해 10 Folds Cross Validation을 적용하였으며, 모형의 정확도를 평가하는 척도는 현재 공군에서 사용중인 척도와 동일하게 평균제곱오차(MSE: Mean Squared Error, 이하 MSE)를 사용하였다.

#### 2.4.1 시계열 모형 예측 결과

먼저, 현재 공군에서 적용중인 방법과 동일하게 5가지의 시계열 모형으로 예측을 수행하였으며, 그 결과는 Table 3과 같다. 특히, 17년 4분기의 MSE가 다른 시기보다 높았는데, 이는 다른 시기에 비하여 수요량의 변동이 매우 큰 특징이 반영된 것으로 보인다. 5가지 모형 중에서는 MSE가 6.4716인 지수평활법이 가장 우수한 결과를 보여 간헐적 수요예측에 가장 적합함을 나타냈다. 또한, 각 데이터 세트에서 사용된 평활상수가 0.2, 0.1, 0.1인 점을 고려하면 평활상수는 1에 가까울수록 최근 관측치에 보다 큰 비중을 주는 것이므로, 최근보다는 과거의 소모실적이 예측에 유리한 것으로 해석할 수 있다. 선형이동평균법은 MSE가 9.1697로 가장 높았는데, 이 방법은 수요량이 주기적이고 안정적인 추세를 갖는 경우에 적합한 방법이므로 다른 시계열 모형에 비해 예측 정확도가 낮은 것으로 판단했다.

Table 3. Prediction results of time series models

Time Series Model	MSE			
	① d174	② d184	③ d194	Average
Weighted Moving Average	18.0150	1.3876	1.2504	6.8843
Linear Weighed Moving Average	21.7416	3.7753	1.9922	9.1697
Trend Analysis	17.5609	2.1058	1.3701	7.0123
Exponential Smoothing	16.9350	1.3650	1.1147	<b>6.4716</b>
Linear Exponential Smoothing	17.1640	1.7729	1.2280	6.7216

#### 2.4.2 데이터 마이닝 모형 예측 결과

데이터 마이닝으로 수리부속 수요 예측을 수행한 운영 환경은 Table 4와 같다.

Table 4. Operating environment in the case study

Category	Value
CPU	intel celeron b820 1.70GHz
MEMORY	6.00GB
OS	window 7 64bit
SW	Weka 3.8.4

본 연구에서 제안하는 수리부속 소모개수, 기온, 장비 운영시간, 장비운영시간당 수리부속 소모율을 입력변수로 반영하여 데이터 마이닝으로 수요를 예측한 결과는 Table 5와 같다. 이 중 두 번째 데이터 세트에서는 기온과 장비운영시간 변수가 유의하지 않은 것으로 분석되어 이를 제거한 후 예측을 수행하였다. 각 모형별 예측 정확도는 현재 공군에서 적용중인 방법과 비교하여 우수한 성능을 보였으며, 이 중 MLP 모형의 MSE가 0.6395로 가장 낮아 세가지 모형 중 가장 우수한 성능을 보였다.

Table 5. Prediction results of data mining models

Data Mining Model	MSE			
	① d174	② d184	③ d194	Average
Linear Regression	1.6241	1.3292	0.3350	1.0961
SVM	1.4354	0.4767	0.3576	0.7567
MLP	1.4280	0.3914	0.0992	<b>0.6395</b>

선형회귀 모형으로 19년 4분기의 소모개수를 예측할 때의 결과를 요약하면 Fig. 6과 같다. 해당 모형의 유의 확률(P값)은 2.2e-16으로 유의하다고 할 수 있으며, Adjusted R<sup>2</sup>은 0.8004로 해당 모형이 약 80%의 설명력을 가지는 것으로 나타났다.

```

                Estimate Std. Error t value Pr(>|t|)
(Intercept)  3.243e-01  2.275e-01  1.425  0.15454
t151        -5.976e-01  1.889e-01 -3.163  0.00164 **
t161        7.265e-01  2.435e-01  2.984  0.00296 **
ot151       4.516e-03  3.006e-03  1.503  0.13345
ot152      -2.115e-03  1.401e-03 -1.510  0.13162
ot153      2.866e-03  1.270e-03  2.257  0.02436 *
ot161      -8.643e-03  3.993e-03 -2.164  0.03082 *
ot171      3.154e-03  1.419e-03  2.223  0.02659 *
r173      -9.712e+01  2.994e+01 -3.244  0.00124 **
r182       3.244e+01  1.773e+01  1.830  0.06771 .
r183      -8.707e+01  2.998e+01 -2.904  0.00381 **
r191      -4.520e+01  2.027e+01 -2.229  0.02616 *
r194       1.089e+03  2.207e+01  49.362 < 2e-16 ***
d173       6.239e-02  2.891e-02  2.158  0.03130 *
d183       7.143e-02  3.859e-02  1.851  0.06465 .
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
Residual standard error: 0.4406 on 610 degrees of freedom
Multiple R-squared:  0.8049,    Adjusted R-squared:  0.8004
F-statistic: 179.8 on 14 and 610 DF,  p-value: < 2.2e-16
    
```

Fig. 6. Summary of linear regression results

SVM 모형으로 19년 4분기 소모개수를 예측한 결과에서는 MSE가 0.7567로 MLP 모형과 함께 우수한 성능을 보였다. 소모개수와 예측된 소모개수의 산점도는 Fig. 7과 같으며, 두 값이 비교적 유사한 결과를 나타냈다.

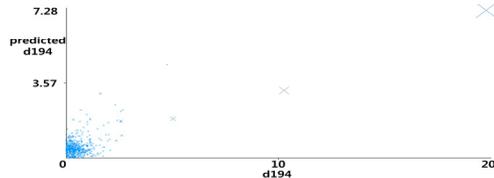


Fig. 7. Scatter plot of SVM model

MLP 모형으로 19년 4분기의 수요를 예측한 결과는 Table 6과 같으며, 은닉노드 수를 달리함에 따라 예측값이 변화하는 것을 확인할 수 있었다. 그 중에서 은닉층 2개, 은닉노드 수를 각각 (10,9)로 입력했을 때 가장 우수한 결과를 얻을 수 있었으며, 이를 시각화하면 Fig. 8과 같다. 은닉노드 수를 (10,9)로 설정했을 때의 MSE는 0.0992로 가장 작았으며, (1,5)로 설정했을 때는 0.4674로 가장 컸다. 이를 통해 MLP 모형에서는 은닉노드 수를 적절히 설정하는 것이 중요한 요인으로 판단할 수 있다. 17년 4분기의 수리부속을 예측할 때는 은닉층 2개 은닉노드 수 (6,9), 18년 4분기는 은닉층 2개, 은닉노드 수 (4,10)으로 입력했을 때 우수한 결과값을 얻을 수 있었다.

Table 6. Prediction results by hidden node(MLP model)

Node	MSE	Node	MSE	Node	MSE
(8,6)	0.1121	(9,6)	0.1181	(10,6)	0.1184
(8,7)	0.1144	(9,7)	0.1028	(10,7)	0.1041
(8,8)	0.1068	(9,8)	0.1135	(10,8)	0.1075
(8,9)	0.1190	(9,9)	0.1102	(10,9)	<b>0.0992</b>
(8,10)	0.1037	(9,10)	0.1132	(10,10)	0.1104

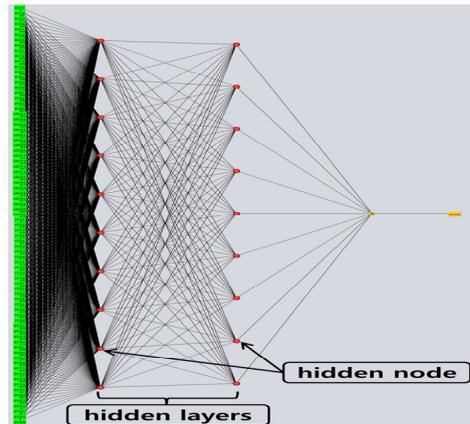


Fig. 8. Structure of MLP model

### 3. 결론

본 연구는 패트리아트 수리부속 수요예측의 정확도를 높이는 것을 목적으로 하였다. 이를 위해 2013년부터 2019년까지 701개의 패트리아트 수리부속 소모실적을 수집하였으며, 이를 분류했을 때 98.6%가 간헐적 수요임을 확인했다. 따라서, 패트리아트에 대해 보다 정확한 수리부속 수요예측을 위해서는 간헐적 수요의 수리부속에 대한 예측이 중요함을 알 수 있었다.

현재 공군에서 적용중인 시계열 모형으로 간헐적 수요에 대해 예측했을 때, 가장 우수한 방법은 지수평활법이었다. 그러나 현재의 방법은 과거의 경향성만을 고려하기 때문에 추가적으로 고려해야할 외부 요인을 식별하였다. 이에 따라, 수리부속 소모개수, 기온, 장비운영시간, 장비 운영시간당 수리부속 소모율을 입력변수로 하는 데이터 마이닝 모형을 구축하여 시계열 모형과의 예측 정확도를 비교 분석하였다. 그 결과 현재 공군에서 적용중인 시계열 모형보다 제안한 데이터 마이닝 모형의 성능이 더욱 우수하였으며, 그중 MLP 모형의 성능이 가장 우수하였다.

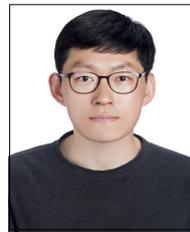
본 연구는 간헐적 수요 예측의 정확도 제고를 위해 수행한 것이며, 예측 정확도가 향상된다면 예산 운영과 장비의 가용도 측면에 영향을 미칠 것이다. 따라서, 향후 이 두 가지의 영향까지 고려한 수요예측을 수행하여 해당 연구를 더욱 발전시킬 필요가 있을 것이다.

## References

- [1] Defense Agency for Technology and Quality(DTaQ), Defense Science and Technology Glossary[Internet], DTaQ, c2017 [cited 2017]. Available From: [http://dtims.dtaq.re.kr:8070/search/detail/term.do?tmnl\\_id=T0007321](http://dtims.dtaq.re.kr:8070/search/detail/term.do?tmnl_id=T0007321) (accessed Oct. 25 2020)
- [2] Y. J. Lee, Ministry of Defense "Reduce 12.9 billion won by increasing the accuracy of demand forecasting" [Internet], Yunhapnews, c2017 [cited 2017 Nov. 24]. Available From: <https://www.yna.co.kr/view/AKR20171124043200014?input=1195m> (accessed Oct. 25, 2020)
- [3] S. H. Kang, Patriot battery shuts down for 132 days[Internet], Newsis, c2013 [cited 2013 Oct. 14]. Available From: [https://newsis.com/ar\\_detail/view.html?ar\\_id=NISX20131014\\_0012431822&cID=10301&pID=10300](https://newsis.com/ar_detail/view.html?ar_id=NISX20131014_0012431822&cID=10301&pID=10300) (accessed Oct. 25, 2020)
- [4] Airforce Headquarters, Maintenance of Repair parts, p.69, Airforce Headquarters, 2019, pp.12.
- [5] Airforce Logistics Command, '17 Research Results of Demand Forecasting Improvement Techniques, p.25, Airforce Logistics Command, 2017, pp.12.
- [6] H. T. Kim, S. H. Kim, "Data mining based army repair parts demand forecast", *Journal of the Korean Data & Information Science Society*, Vol.30, No.2, pp.429-444, March 2019. DOI: <https://doi.org/10.7465/jkdi.2019.30.2.429>
- [7] J. D. Kim, H. J. Lee "A Study on Forecasting Spare Parts Demand based on Data-Mining", *Journal of the Internet Computing and Services*, Vol.18, No.1, pp.121-129, February 2017. DOI: <https://doi.org/10.74726/jksii.2017.18.1.121>
- [8] J. S. Kim, J. S. Hwang, J. W. Jung "A New LSTM Method Using Data Decomposition of Time Series for Forecasting the Demand of Aircraft Spare Parts", *Korean Management Science Review*, Vol.37, No.2, pp.1-18, June 2020. DOI: <https://doi.org/10.7737/KMSR.2020.37.2.001>
- [9] J. D. Croston, "Forecasting and Stock Control for Intermittent Demands", *Operational Research Quarterly*, Vol.23, pp.289-303, September 1972. DOI: <https://doi.org/10.1057/jors.1972.50>
- [10] D. W. Choi, *A Data Mining Approach for Forecasting the Demand of Accidental Automobile Spare Parts with External Factors*, Master's thesis, Yonsei University of Information Industrial Engineering, Seoul, Korea, pp.5-8, 2013.
- [11] M. K. Park, J. G. Baek, "Demand Forecast of Spare Parts for Low Consumption with Unclear Pattern", *Journal of the KIMST*, Vol.21, No.4, pp.529-540, August 2018. DOI: <https://doi.org/10.9766/KIMST.2018.21.4.529>
- [12] B. H. Oh, *A study on weapon system spare parts intermittent demand forecasting using deep learning*, Master's thesis, Korea University of Information and Communication, Seoul, Korea, pp.2-10, 2017.
- [13] T. G. Kim, J. M. Ma "A Data Mining Approach for Intermittent Demand Forecasting of Aircraft Spare Parts - Focusing on the E-737(AEW&C: Airborne Early Warning & Control) Spare Parts -", *Journal of the AMSOK*, Vol.16, No.4, pp.155-164, August 2018. DOI: <https://doi.org/10.30529/amsok.2018.16.4.008>
- [14] A. Ghobbar, C. Friend, "Evaluation of forecasting methods for intermittent parts demand in the field of aviation: a predictive model", *Computer and Operation Research*, Vol.30, No.1, pp.2097-2114, December 2003. DOI: [https://doi.org/10.1016/S0305-0548\(02\)00125-9](https://doi.org/10.1016/S0305-0548(02)00125-9)
- [15] Airforce Air Defence Missile Command, '15 Operational equipment defect analysis and management measures, p.19, Airforce Air Defence Missile Command, 2015, pp.10-14.
- [16] Galit Shmueli, Nitin R. Patel, Peter C. Bruce, *Data Mining for Business Intelligence*, p.455, E&B PLUS, 2012, pp.23-24, 265-272.

### 박 천 규(Cheonkyu Park)

[준회원]



- 2011년 2월 : 서울과학기술대학교 안경광학과 (안경광학 학사)
- 2021년 1월 : 국방대학교 국방과학학과 (국방과학학 석사)

<관심분야>

수요예측, 데이터마이닝

### 마 정 목(Jungmok Ma)

[정회원]



- 2002년 2월 : 육군사관학교 운영분석학과 (운영분석 학사)
- 2008년 8월 : 미국 펜실베이니아 주립대(PSU) (산업공학 석사)
- 2015년 5월 : 미국 일리노이대(UIUC) (산업공학 박사)
- 2015년 9월 ~ 현재 : 국방대학교 국방과학학과 부교수

<관심분야>

국방 모델링 및 데이터 분석학, 무기체계 획득관리