

저장탄약 신뢰성분류 인공신경망모델의 학습속도 향상에 관한 연구

이동녕^{1,2*}, 윤근식², 노유찬²
¹인하대학교 항공우주공학과, ²국방기술품질원

Study on Improving Learning Speed of Artificial Neural Network Model for Ammunition Stockpile Reliability Classification

Dong-Nyok Lee^{1,2*}, Keun-Sig Yoon², Yoo-Chan Noh²
¹Department of Aerospace Engineering, Inha University
²Defense Agency for Technology & Quality

요약 본 연구에서 저장탄약 신뢰성평가(ASRP: Ammunition Stockpile Reliability Program)의 데이터 특성을 고려하여 입력변수를 줄이는 정규화기법을 제안함으로써 분류성능의 저하 없이 저장탄약 신뢰성분류 인공신경망모델의 학습속도향상을 목표로 하였다. 탄약의 성능에 대한 기준은 국방규격(KDS: Korea Defense Specification)과 저장탄약 시험절차서(ASTP: Ammunition Stockpile reliability Test Procedure)에 규정되어 있으며, 평가결과 데이터는 이산형과 연속형 데이터가 복합적으로 구성되어 있다. 이러한 저장탄약 신뢰성평가의 데이터 특성을 고려하여 입력변수는 로트 추정 불량률(estimated lot percent nonconforming) 또는 고장률로 정규화 하였다. 또한 입력변수의 unitary hypercube를 유지하기 위하여 최소-최대 정규화를 2차로 수행하는 2단계 정규화 기법을 제안하였다. 제안된 2단계 정규화 기법은 저장탄약 신뢰성평가 데이터를 이용하여 비교한 결과 최소-최대 정규화와 유사하게 AUC(Area Under the ROC Curve)는 0.95 이상이었으며 학습속도는 학습 데이터 수와 은닉 계층의 노드 수에 따라 1.74 ~ 1.99 배 향상되었다.

Abstract The purpose of this study is to improve the learning speed of an ammunition stockpile reliability classification artificial neural network model by proposing a normalization method that reduces the number of input variables based on the characteristic of Ammunition Stockpile Reliability Program (ASRP) data without loss of classification performance. Ammunition's performance requirements are specified in the Korea Defense Specification (KDS) and Ammunition Stockpile reliability Test Procedure (ASTP). Based on the characteristic of the ASRP data, input variables can be normalized to estimate the lot percent nonconforming or failure rate. To maintain the unitary hypercube condition of the input variables, min-max normalization method is also used. Area Under the ROC Curve (AUC) of general min-max normalization and proposed 2-step normalization is over 0.95 and speed-up for marching learning based on ASRP field data is improved 1.74 ~ 1.99 times depending on the numbers of training data and of hidden layer's node.

Keywords : Artificial Neural Network, Ammunition, Reliability, Normalization, Classification

*Corresponding Author : Dong-Nyok Lee(Inha University, DTaQ)

email: dnlee@dtaq.re.kr

Received March 13, 2020

Accepted June 5, 2020

Revised April 27, 2020

Published June 30, 2020

1. 서론

군수품의 신뢰성은 국방력 유지에 중요한 요소이다. 탄약은 함정, 항공기, 기동장비 등과 달리 사용되기 전 까지 탄약고에 보관되어 대부분의 시간을 보낸다. 또한 탄약은 필요한 경우 단 한번 사용하고 파괴되는 일회성 시스템(one-time system)으로 신뢰성이 높으며, 사용 전에는 고장이나 불량 여부를 확인할 수 없다. 그러므로 보관 중인 탄약은 주기적으로 신뢰성을 확인해야 하며, 이것을 저장탄약 신뢰성평가(ASRP)라고 한다.

저장탄약 신뢰성평가를 통해 매년 선정된 탄종과 로트에 대한 성능과 안전성을 평가한다. 평가결과에 따라서 계속 사용, 폐기, 수리 등의 조치가 취해진다. 저장탄약 신뢰성평가의 수행절차는 대상 선정, 시료채취, 비기능 시험, 기능 시험 및 이화학 시험, 분석 및 평가, 심의로 이루어진다. 비기능 시험은 육안검사, 비파괴검사 등으로 파손, 누락, 탈락 등 이상 여부를 검사한다. 기능 시험은 사격시험이나 정치 시험을 통해 탄약의 전체 혹은 주요 구성품의 기능이 정상적으로 발휘되는지를 시험한다. 이화학 시험은 추진제 등의 안전성을 확인하기 위하여 안정제 함량을 측정한다.

저장탄약 신뢰성 평가를 통하여 다년간 누적된 데이터를 활용한 연구는 지속적으로 수행되어 왔다. 저장탄약 신뢰성 평가 데이터를 이용한 품목별 신뢰도 산출방안에 관한 연구[1], 155mm 백색추진장약 KM4A2 저장수명 추정[2]과 기계식 시한신관 KM577A1 저장수명 추정[3] 등 탄약의 저장수명을 예측하는 연구가 대표적이다. 최근에는 기존의 통계적 방법론과 달리 Noh et al(2018)[4]은 155MM 백색추진장약에 대한 저장탄약 신뢰성 평가 데이터를 신경망 분석, 의사결정나무 등 데이터마이닝 기법을 이용하여 저장 탄약의 계속 사용 여부를 판정하는 저장탄약 신뢰성 분류모델의 분류 정확도가 90% 이상임을 확인하였으며 탄약의 저장신뢰성을 결정하는 주요 요인에 대하여 식별하였다.

본 연구는 기존의 머신 러닝을 활용한 저장탄약 신뢰성분류 연구모델[4]을 바탕으로 저장탄약 평가 데이터의 특성을 고려하여 분류성능의 저하 없이 학습속도를 향상하고자 한다. 이를 위해 국방규격(KDS), 저장탄약 시험절차서(ASTP)에서 규정된 탄약의 성능에 대한 기준을 활용하여 복수의 입력 변수를 하나의 입력 변수로 정규화(normalization)하였다. 입력 변수가 감소하게 되면서 머신 러닝의 연산량이 감소하게 되어 학습 속도가 향상될 수 있었다.

제안된 정규화 기법의 학습속도 향상을 분석하기 위하여 가상의 특성에 대한 학습 데이터와 Noh et al(2018)[4]의 155mm 백색추진장약에 대한 저장신뢰성평가 데이터를 활용하였다. 머신 러닝에는 통계 프로그래밍 언어인 R(ver. 3.5.1)과 인공지능경망 패키지인 neuralnet 패키지(ver. 1.44.2)[5]를 사용하였다.

2. 이론적 배경

2.1 저장탄약의 신뢰성평가

저장탄약의 신뢰성평가 저장 신뢰도 추정과 저장탄약의 신뢰성 분류(계속 사용 가능 여부 판별)로 나누어 볼 수 있다. 또한 누적된 데이터 분석을 통한 신뢰성 예측과 가속노화시험을 통한 신뢰성 예측으로 나누어 볼 수 있다.

국내의 저장탄약 신뢰성평가는 대상 탄종의 로트에 대한 평가이며, 해당 로트의 계속 사용 여부를 중심으로 수행되고 있다. 저장탄약 시험절차서(ASTP)에 따라 시험을 통해 얻어지는 평가결과와 그에 대한 기준에 따라 사용 여부를 결정하는 방식이다.

탄약의 저장 신뢰성을 예측에는 누적된 저장탄약 신뢰성 평가 데이터에 대한 시계열분석을 주로 적요해 왔다.[1-3] 최근에는 로트 마다 저장탄약 시험절차서에 따라 평가해야하는 기존 저장탄약 신뢰성 평가 방식을 벗어나 머신 러닝으로 다년간 누적된 데이터를 학습한 저장탄약 신뢰성 분류모델을 통해 신속하게 저장탄약의 계속 사용 여부를 분류할 수 있는 효율적인 방안을 제시함과 동시에 모델로부터 탄약의 신뢰성을 결정하는 주요한 성능지표를 식별하고자 하였다.[4]

저장탄약 신뢰성평가의 기능 시험, 비기능 시험, 이화학 시험을 통해 얻어진 탄약의 성능지표(포구속도, 결점수 등)의 데이터를 분석하여 저장탄약의 신뢰성을 예측하는 것 이외에 Cho(2010)[6]는 고온가속노화시험으로 얻어진 추진제의 안정제 함량저하를 통해 저장 신뢰성을 예측하였으며, Liu et al(2019)[7]은 탄약의 성능에 영향을 주는 온도, 습도와 저장기간과 고장 수를 ACO(Ant Colony Optimization) 알고리즘과 neural network을 이용하여 저장 신뢰도를 예측하였다.

본 연구는 입력변수 정규화를 통해 저장탄약 신뢰성분류 모델의 학습 속도 향상에 있으며, 분류 정확도의 영향은 없어야 한다. 머신 러닝에 사용한 학습 데이터는 가상의 성능에 대한 적합여부 평가 데이터(300개)와 저장탄약 신뢰성평가 결과(250개 로트의 사용 가능 여부에 대

한 결과)를 사용하였다. 분류 정확도를 검증하기 위하여 학습 데이터의 일부는 머신 러닝에 사용하지 않고 별도의 검증 데이터로 사용하였으며, 분류 정확도를 평가하는 기준으로 AUC를 사용하였다.

2.2 인공신경망

인공신경망은 분류, 수치예측, 패턴인식 등 데이터마이닝에 사용되는 대표적인 머신러닝 모델이다. 뇌가 대규모 병렬 처리기를 생성하기 위해 뉴런(neurons)이 상호 연결되어 네트워크를 구성하는 것처럼 인공신경망은 학습 문제를 풀기 위해 인공 뉴런(또는 노드) 네트워크를 구성한다.[8]

뉴런은 운동뉴런(motor neuron), 감각뉴런(sensory neuron) 등으로 분류할 수 있으나 기능적 구조(functional architecture)는 대부분 동일하다. Fig. 1과 같이 뉴런은 세포체(cell body), 수상돌기(dendrite), 축삭(axon)으로 구성된다. 세포체는 핵(nucleus)을 포함하고 있으며 세포체로부터 확장되어 분지된 수상돌기는 다양한 자극원에서부터 전달되는 정보를 받아 드린다. 수상돌기에서 전달된 정보는 세포체에서 통합되고 세포체에 임계값 이상의 신호가 입력되면 축삭(axon)을 통해 전달되어 다른 수많은 세포를 다시 자극하게 된다.[9]




Fig. 1. Neuron's signal transfer




Fig. 2. ANN node's signal transfer

Fig. 2와 같이 인공신경망 노드의 신호전달과정은 Fig. 1에서 뉴런의 신호전달과정과 유사하다. 노드의 입

력은 뉴런의 수상돌기와 유사하고 노드의 출력은 축삭종말과 유사하다. 인공신경망에서 n-1 번째 계층의 출력 값은 n-1 번째 계층과 n 번째 계층의 노드 사이에 정의된 가중치가 곱해진 합인 가중합(weighted sum)으로 n 번째 계층 노드의 활성화함수(activation function)에 전달된다. n-1 번째 계층의 출력 값이 가중합으로 전달되는 과정은 뉴런의 수상돌기에서 신경전달물질이 입력되어 전기적 신호가 세포체로 전달되는 과정과 유사하다. 또한 n 번째 계층 노드의 활성화함수 출력 값이 다음 계층(n+1 번째 계층)의 노드들로 전달되는 과정은 뉴런의 축삭과 유사하다.

뉴런의 네트워크가 신경계(nervous system)를 구성하여 것과 유사하게 인공신경망은 노드의 네트워크를 구성한다. 인공신경망은 Fig. 3과 같이 입력 계층(input layer)-은닉 계층(hidden layer)-출력 계층(output layer)의 계층(layer)구조이루며, 계층과 계층의 노드와 노드 사이에는 가중치(weighting)가 정의되어 네트워크를 구성한다.




Fig. 3. ANN layer structure

입력 계층에서 변수가 입력되어 인공신경망이 시작되고 은닉계층을 거쳐 최종적으로 예측 값이 출력되는 출력 계층에서 인공신경망은 끝난다. 은닉 계층은 하나 이상의 계층으로 이루어지며, 각 계층은 하나 이상의 노드로 이루어진다. 입력 계층과 출력 계층의 노드는 학습 데




Fig. 4. ANN node's signal transfer

이터에 따라 정해지지만 은닉 계층의 수와 각 계층의 노드 수는 사용자에 의해 결정된다. 인공지능경망의 학습과정은 Fig. 4와 같이 반복 학습을 통해 노드 사이에 가중치가 수렴해 가는 과정이다.

2.3 입력변수의 정규화

활성함수는 노드로 입력되는 통합된 정보를 출력하는 역할을 수행한다. 인공지능경망에서 사용하는 대표적인 함수는 Sigmoid 함수이다.




Fig. 5. Sigmoid function

Fig. 5와 같이 Sigmoid 함수의 출력 값은 입력 값 -5 이하에서는 0으로 수렴하며, 입력 값 +5 이상에서 1로 수렴한다. 입력 변수에 따라 입력 값의 범위가 상이할 수 있고, 입력 변수의 범위가 크게 차이가 있을 경우 입력 변수가 갖는 모델에 기여도가 왜곡될 수 있으므로 입력 변수의 재조정(re-parameterization)이 필요하며 이러한 과정을 정규화(normalization)이라고 한다.

정규화는 선형변환(linear transformation)을 통한 입력변수의 재조정으로 Eq. (1)의 최소-최대 정규화(min-max normalization)나 Eq. (2)에 따른 z 점수 표준화(z-score standardization) 등이 사용된다.

$$X_{norm} = \frac{X - \min(X)}{\max(X) - \min(X)} \quad (1)$$

$$X_{norm} = \frac{X - \mu}{\sigma} \quad (2)$$

Where, μ denotes average of X ,

σ denotes standard deviation of X

2.4 2단계 정규화기법의 제안

하나의 은닉 계층을 갖는 인공지능경망 내 가중치의 수 (N_w)는 Eq. (3)과 같이 계산할 수 있으며, 입력 변수의 수가 줄게 되면 수렴해야 하는 가중치의 수가 줄게 되어

학습소요시간의 감소를 기대할 수 있다.

$$N_w = N_n \times (n_i + n_o) + n_b \quad (3)$$

Where, N_w denotes the number of weights,

N_n denotes the number of hidden layer's nodes,

n_i denotes the number of input variables,

n_o denotes the number of out layer's nodes

n_b denotes the number of bias nodes

본 연구에서 제안하는 정규화 기법은 분류 성능에 저하 없이 입력 변수의 수를 줄이고 머신 러닝에 적합한 입력 변수로 선형변환하는 것이다. 이를 위하여 먼저 저장탄약 신뢰성평가 데이터의 특징에 대하여 검토하였으며, 다음으로 입력 변수의 정규화 기법에 요건에 대하여 검토하였다. 마지막으로 저장탄약 신뢰성 분류에 적합한 정규화 기법을 제시하였다.

저장탄약 신뢰성평가 데이터는 연속형 데이터와 이산형 데이터가 복합적으로 포함되어 있다. 대표적인 이산형 데이터는 시료 수, 결점 수이다. 결점 수는 시험항목에 따라 불발, 비행 중 폭발 등으로 다양하며, 결점의 정도에 따라 치명결정, 중결점, 경결점으로 나눌 수 있다. 연속형 데이터는 포구속도(muzzle velocity), 작동시간 등이 으며 주로 평균과 표준편차 등으로 평가한다. 저장탄약 신뢰성평가 결과에 대한 적합 여부의 기준은 저장탄약 시험절차서에 상한, 하한 또는 상/하한으로 제시된다.

다음으로 입력 변수의 정규화 기법에 대한 요건이다. 만약 입력 변수 사이에 값에 범위가 크게 차이가 있다면 상대적으로 큰 범위를 갖는 입력변수가 출력 오차(output error)에 크게 기여하게 된다. 이때, 알고리즘은 그로 인한 오차를 줄이기 위하여 큰 값을 갖는 입력 변수에 치중하게 되어 작은 값을 갖는 입력 변수의 정보가 무시되게 된다.[8] 그러므로 정규화를 통해 입력 변수의 범위가 unitary hypercube가 되도록 조정하는 것이 중요하다. 최소-최대 정규화는 입력 변수의 범위가 unitary hypercube 되도록 할 수 있는 대표적인 방법이다. 제안되는 정규화 기법은 입력 변수의 범위를 0에서 1사이의 값을 가지면서 입력 변수의 수를 줄일 수 있어야 한다.

국방규격과 저장탄약 시험절차서의 기준을 이용하여 하나의 성능에 대한 평균, 표준편차, 시료수를 로트 추정 불량률로 정규화를 할 수 있다. 로트 추정 불량률은 0에서 1 사이의 값을 갖기 때문에 정규화에 적합하다. 또한 입력 변수 3개를 1개의 값으로 선형변환하기 때문에 인공지능경망의 가중치 수가 줄어 학습 속도의 향상을 기대

할 수 있다.

하나의 성능에 대한 평균, 표준편차와 시료수가 입력 변수이고 평균에 대한 기준이 국방규격이나 저장탄약 시험절차서에 제시된 경우, ANSI/ASQ Z1.9에 따라 로트 추정 불량률을 계산할 수 있다. 만약 상/하한의 기준이 제시된 경우에는 Eq. (4)와 Eq. (5)에 따라 upper quality index와 lower quality index를 계산하고, ANSI/ASQ Z1.9의 Table B-5 “Table for Estimating the Lot Percent Nonconforming Using Standard Deviation Method”에서 시료수와 quality index에 해당하는 p_U (estimated lot percent nonconforming above upper specification limit)와 p_L (estimated lot percent nonconforming below lower specification limit)을 찾아 Eq. (6)과 같이 로트 추정 불량률(p)을 계산한다.[10]

$$Q_U = (U - \bar{X})/s \tag{4}$$

$$Q_L = (\bar{X} - L)/s \tag{5}$$

$$p = p_U + p_L \tag{6}$$

Where, \bar{X} denotes sample mean
 s denotes estimate of lot standard deviation,
 U denotes upper specification limit,
 L denotes lower specification limit

저장탄약 신뢰성평가 데이터 중 이산형 데이터인 결점 수와 시료수는 0에서 1사이의 범위를 갖는 불량률(결점 수/시료수)로 정규화할 수 있다.

불량률과 로트 추정 불량률이 0에서 1사이의 범위를 갖지만, 탄약은 일회성 시스템으로 신뢰도가 높아 탄약의 평가항목이나 성능이 100% 불량 혹은 부적합이 발생한 사례의 학습 데이터가 없을 수도 있다. 이때, 입력 변수를 불량률과 로트 추정 불량률로 정규화하게 되면 정규화(1단계 정규화)된 입력 변수의 최댓값이 1보다 작은 경우가 발생하게 된다. 그러므로 불량률과 로트 추정 불량률이 unitary hypercube를 만족할 수 있도록 최소-최대 정규화를 한 번 더 수행(2단계 정규화)해야 한다.

3. 2단계 정규화기법 제안 및 검증

3.1 학습모델의 분류성능 척도

ROC 곡선(Receiver Operating Characteristic Curve)은 거짓 긍정(FP: False Positive)을 피하면서 참

긍정(TP: True Positive)을 탐지하는 것 사이에 trade off를 관찰하는데 사용되는데 실제 신호와 거짓 경보를 구별하는 수신기 능력을 측정하기 위하여 ROC 곡선을 사용했으나 머신 러닝 모델의 효과를 시각화하는 데에도 유용하다.[8]

Fig. 6은 참 긍정(TP)과 참 부정(TN: True Negative)의 분포와 그에 대응하는 ROC 곡선이다.




Fig. 6. Example for TN&TP distribution & ROC curve (a) TN&TP distribution (b) ROC curve

AUC는 ROC 곡선의 면적을 의미한다. FN(False Negative)는 거짓 부정, FP는 거짓 긍정이다. TPR(True Positive Rate)는 참 긍정률로 Eq. (6)과 같으며, FPR(False Positive Rate) 거짓 긍정률로 Eq. (7)과 같이 정의된다.[11]

$$TPR = \frac{TP}{TP + FN} \tag{6}$$

$$FPR = \frac{FP}{TN + FP} \tag{7}$$

만약 참 긍정과 참 부정이 완벽하게 구분된다면, AUC는 1이다. 하지만 참 긍정과 참 부정을 구분할 수 없다면 AUC는 0.5이다.

3.2 정규화기법 비교 : Case 1

연속형 데이터로 표현되는 가상의 성능 A에 대하여 Table 1과 같이 가정한 후, 최소-최대 정규화하여 학습한 경우(model1)와 로트 추정 불량률로 정규화하여 학습한 경우(model2)에 대하여 분류 성능과 학습 속도를 비교하였다. R(ver. 3.5.1) 및 인공지능망 패키지인 neuralnet 패키지(ver. 1.44.2)를 사용하였으며, 연산은 Intel Core i7-7600U(2.82 GHz) CPU, 16GB DDR4 RAM 과 Window 10(64비트) 조건에서 수행하였다.

Table 1. Acceptance criteria of 'A'

	criteria
lower specific limit of average	98
upper specific limit of average	102
standard deviation	< 2.5

은닉 계층이 1개인 인공지능망 모델을 사용하였으며, 은닉 계층의 노드 수는 10개, 20개인 경우에 대하여 학습 데이터 수에 따라 비교하였다.

인공지능망은 블랙박스 프로세스로 학습과정을 통해 얻어지는 가중치는 모델마다 달라질 수 있다. 이는 학습 데이터와 가중치에 대한 선택의 무작위성으로 인해 발생한다. 그러므로 동일한 학습 데이터를 사용하더라도 모델마다 가중치는 다를 수 있고, 이로 인해 학습시간과 분류 성능에도 차이가 있을 수 있다. 그러므로 조건(노드 수 조건 & 학습 데이터 수 조건)마다 100회의 학습모델을 생성하여 비교하였다. 총 100회 반복하여 학습모델에 대하여, 최대 AUC, 총 학습 소요 시간(TET : Total Elapsed Time)과 학습모델 사이의 총 학습 소요시간의 비(TET ratio)를 기준으로 비교하였다. 총 학습 소요 시간(TET)은 100회 학습모델에서 가중치가 수렴하는데 소요되는 시간의 합이며, 총 학습 소요시간의 비(TET ratio)는 Eq. (8)과 같다.

$$TETratio = \frac{TET_{\min-max}}{TET_{proposed}} \quad (8)$$

특성 A에 대한 임의의 학습 데이터 300개를 활용하여 학습을 수행하였으며 학습에 사용되지 않는 데이터는 분류 성능 검증에 사용하였다. 성능 A의 학습 데이터에 대한 평균과 표준편차에 대한 분포는 Fig. 7과 Fig. 8과 같으며, 시료 수는 17개 ~ 20개 사이이다.




Fig. 7. Distribution for average of 'A'




Fig. 8. Distribution for standard deviation of 'A'

Fig. 9와 같이 두 모델 모두 AUC가 0.95 이상으로 모델의 분류 성능은 양호하지만 모델2가 약간 높고 학습 데이터수가 작으면 그 차이는 커진다. 그리고 Fig. 10서 알 수 있듯이 학습 데이터 수가 증가함에 따라서 두 모델의 총 학습 소요 시간(TET)의 차이는 증가하고 있으며, 총 학습 소요 시간의 비(TET ratio) 또한 Fig. 11과 같이 2.58 배 ~ 6.71 배 차이가 난다. 즉, 정규화 방법에 따라서 두 모델의 분류 성능에는 큰 차이를 보이지 않지만 학습 속도에 차이가 있음을 알 수 있다.




Fig. 9. Maximum AUC(model1&model2)




Fig. 10. TET(model1&model2)




Fig. 11. TET ratio(TET model1/TET model2)

3.3 정규화기법 비교 : Case 2

155mm 백색추진장약 KMOAO 240개 로트의 저장 탄약 신뢰성평가 데이터를 이용하여 연속형 데이터와 이산형 데이터가 같이 포함된 10개 입력변수(시료수, 비기능 및 기능시험 결점수 등)에 대해 정규화 학습 모델의 분류 성능과 학습 속도를 비교하였다. 학습에 사용된 언어 및 패키지와 연산 조건은 “정규화기법 비교 : case 1”과 같다. 각 모델은 아래와 같이 정규화기법을 적용하였고, 입력 변수는 Table 2와 같다.

- 모델1 : 최소-최대 정규화
- 모델2 : 불량률과 로트 추정 불량률로 정규화(1단계)
- 모델3 : 모델2 + 최소-최대정규화(2단계)

학습모델은 1개의 은닉 계층을 갖은 인공신경망 모델을 사용하였다. 정규화기법 비교(case 1)과 같이 각 조건(노드 수 조건 + 학습 데이터 수 조건)마다 100회의 학습 모델을 생성하였다. 은닉 계층의 노드 수는 10개, 20개인 경우와 학습에 사용되는 데이터 수를 140개, 160개, 180개, 200개인 경우를 조합하여 조건을 만들었다. 각 조건에서 최대 AUC, 총 학습 소요 시간(TET)과 학습 모델 사이의 총 학습 소요시간의 비(TET ratio)를 비교하였다.

Table 2. Input variables of 155mm propelling charge data for classification models

	Input variables
Model1	[discrete type data] ·the number of samples ·the number of non-functional critical failures ·the number non-functional moderate failures ·the number of non-functional minor failures ·the number of outlier in projectile's speed [continuous type data] ·average of speed at propelling charge 3 ·standard deviation of speed at propelling charge 3 ·average of speed at propelling charge 7 ·standard deviation of speed at propelling charge 7 ·stabilizer content(percent)
Model2 & Model3	[continuous type data] ·non-functional critical failure rate ·non-functional moderate failure rate ·non-functional minor failure rate ·outlier rate of projectile's speed ·estimated lot percent nonconforming of speed at propelling charge 3 ·estimated lot percent nonconforming of speed at propelling charge 7 ·stabilizer content(percent)

Fig. 12와 같이 3가지 학습 모델의 AUC가 0.95 이상으로 분류 성능은 양호하나, Fig. 13과 같이 노드의 수와 학습 데이터의 수가 증가함에 따라 모델 사이의 총 학습 소요 시간(TET)이 차이가 증가한다. 또한 Fig. 14에서 알 수 있듯이 모델3(제안된 정규화 기법)이 모델1(최소-최대 정규화) 보다 총 학습 소요 시간의 비(TET ratio)가 1.74 배 ~ 1.99 배 차이가 난다. 155mm 백색추진장약 KMOAO의 분류 모델에서도 정규화 방법에 따라서 분류 성능에는 차이를 보이지 않지만 학습 속도에 차이가 있음을 알 수 있다.




Fig. 12. Maximum AUC(model1,model2&model3)




Fig. 13. TET(model1,model2&model3)




Fig. 14. TET ratio(TET model1/TET model3)

모델2(불량률과 추정불량률로 정규화)는 학습 데이터와 노드의 수의 증가하면서 총 학습 소요 시간이 증가하지만, 노드 수가 20개인 경우에서 학습 데이터가 180개 이상인 경우 모델1(최소-최대 정규화)보다 총 학습 소요 시간이 증가하게 된다. 이것은 모델2의 입력변수가 unitary hypercube를 이루지 못함으로 인한 over-fitting에 따른 지연으로 추정된다.

4. 결론

본 연구에서는 저장탄약 신뢰성평가 데이터 특성을 고려하여 입력 변수를 줄이는 정규화 기법으로 제안하였으며, 이를 통해 저장탄약 신뢰성 평가를 위한 인공신경망 모델의 학습 능률을 향상하고자 하였다. 이를 위하여 국방규격(KDS), 저장탄약 시험절차서(ASTP)에서 요구되는 탄약의 특성(성능) 기준을 이용하여 불량률과 로트 추정 불량률로 정규화(1단계)하였다. 또한 일회성 시스템인 탄약의 높은 신뢰성으로 인해 1단계에서 정규화된 입력 변수가 unitary hypercube를 만족시키지 못할 수 있으므로 최소-최대 정규화를 추가로 수행하는 2단계 정규화 기법을 제안하였다. 제안된 정규화기법의 학습속도향상에 대한 효과는 Table 3과 같이 정리할 수 있다.

Table 3. Summary of results (min-max normalization vs proposed normalization)

		Case 1		Case 2	
original data type of classification criteria		continuous		discrete & continuous	
the numbers of hidden layer node		10	20	10	20
reduction rate for the numbers of weights		52.4%	53.6%	73.2%	73.5%
maximum AUC	min-max normalization	0.97 ~ 1.0	0.97 ~ 1.0	0.97 ~ 1.0	0.96 ~ 1.0
	proposed normalization	1.0	1.0	0.96 ~ 1.0	0.96 ~ 1.0
speed-up $\left(TET\ ratio = \frac{TET_{min-max}}{TET_{proposed}} \right)$		3.08 ~ 4.61	2.58 ~ 6.71	1.80 ~ 1.99	1.74 ~ 1.92

두 가지 사례(case 1, case 2)에서 일반적인 최소-최대 정규화와 제안된 정규화 기법의 AUC는 0.95 이상으로 높으며, 제안된 정규화 기법은 분류 성능의 큰 차이 없이 학습속도가 향상되었다. 제안된 정규화 기법에 대하여 결론을 3가지로 정리할 수 있다.

첫째, 분류 성능의 저하 없이 학습 속도를 향상시킬 수 있다. 학습 속도 향상의 주요한 요인은 입력 변수 감소를 통한 가중치 수렴에 소요되는 총 계산량의 감소이다.

둘째, 일회성 시스템인 탄약의 높은 신뢰도로 인하여 불량률과 로트 추정 불량률로 정규화한 경우, unitary hypercube를 만족하기 위하여 최소-최대 정규화를 추가로 수행할 필요가 있다.

셋째, 제안된 정규화 기법을 통해 적은 학습 데이터의 수에서 높은 분류 성능을 기대하였으나 최소-최대 정규화와 비교할 때 학습 데이터 수에 따라 분류 성능에 차이가 없어 학습 데이터 수를 줄여 학습능률을 향상할 수 없는 한계가 있다. 이것은 이미 최소-최대 정규화만으로도 인공신경망의 분류 성능이 높기 때문인 것으로 판단된다.

매년 〇〇종 〇〇로트의 탄약에 대한 저장탄약 신뢰성 평가가 수행되면서 다량의 데이터들이 생성되며, 이를 분석하여 평가 결과를 도출하는 것에도 많은 인력과 시간이 소요된다. 이러한 현실 속에서 머신 러닝은 신속한 분석 결과를 도출해 줄 수 있는 도구로 생각된다. 향후 지속적인 연구를 통해 다양한 품목의 신뢰성평가에 사용할 수 있을 것이라 기대한다.

References

- [1] K.S. Yoon, J.C. Lee, "A Case Study on the Reliability Assessment of Stockpile Ammunition", *Journal of the Korean Society for Quality Management*, Vol.40, No.3, pp.259-269, 2012.
DOI: <https://doi.org/10.7469/JKSQM.2012.40.3.259>
- [2] K.S. Yoon, S.W. Park, "A Study on the Estimation of Shelf-Life for 155mm propelling charge KM4A2 using ASRP's data" *Journal of the Korean Society for Quality Management*, Vol.42, No.3, pp.291-300, 2014.
DOI: <https://doi.org/10.7469/JKSQM.2014.42.3.291>
- [3] D.N. Lee, K.S. Yoon, "A Study on the Estimation of Shelf Life for Fuze MTSQ KM577A1 from ASRP Data" *Journal of Applied Reliability*, Vol.18, No.1, pp.56-65, 2018.
DOI: <https://doi.org/10.33162/JAR.2018.03.18.1.56>
- [4] Y.C. Noh, D.N. Lee, N.W. Cho, "A Study on Determinants of Stockpile Ammunition Using Data Mining", *Proceedings of The Korean Society for Quality Management*, p.20, October 2018.
- [5] S. Fritsch, F. Guenther, M. N. Wright, "neuralnet: Training of Neural Networks", R package version 1.44.2, 2019.
<https://CRAN.R-project.org/package=neuralnet>
- [6] K.H. Cho, "A Study on the Self-life Estimation of the Propellant KM10 by using High Temperature Acceleration Aging Tests", *Journal of the Korea Academia-Industrial Cooperation Society*, Vol.11, No.5, pp.1735-1740, 2010.
DOI: <https://doi.org/10.5762/KAIS.2010.11.5.1735>
- [7] F. Liu, H. Gong, L. Cai, K. Xu, "Prediction of Ammunition Storage Reliability Based on Improved Ant Colony Algorithm and BP Neural Network", *Complexity*, Vol.2019, Article ID 5039097, pp.13, 2019.
DOI: <https://doi.org/10.1155/2019/5039097>
- [8] B. Lantz, "Machine Learning with R : Korean Edition," Packt Publishing Ltd., p.306, p.447, 2017.
- [9] K.A. Mason, P.H. Raven, S.R. Singer, "Biology 11th," McGraw Hill Education, p.890, 2017.
- [10] "Sampling Procedures and Tables for Inspection by Variables for Percent Nonconforming," American Society for Quality, ANSI/ASQ Z1.9, 2008.
- [11] T. Fawcett, "ROC Graphs : Notes and Practical Considerations for Data Mining Researchers," Technical Report, HP Laboratories, US, p.3, 2003.

이 동 녉(Dong-Nyok Lee)

[정회원]



- 2005년 2월 : 인하대학교 항공우주공학과 (학사)
- 2008년 2월 : 인하대학교 생명과학과 (학사)
- 2013년 3월 ~ 현재 : 국방기술품질원 선임연구원
- 2017년 7월 ~ 현재 : 인하대학교 항공우주공학과 (석박사통합과정)

<관심분야>

신뢰성, 머신러닝, 접합성구조해석

윤 근 식(Keun-Sig Yoon)

[정회원]



- 2003년 8월 : 충남대학교 대학원 화학공학과 (공학석사)
- 2010년 8월 : 충남대학교 대학원 화학공학과 (공학박사)
- 1995년 12월 ~ 현재 : 국방기술품질원 책임연구원

<관심분야>

신뢰성, 시험평가, 품질경영, 통계분석

노 유 찬(Yoo-Chan Noh)

[정회원]



- 2015년 2월 : 서울과학기술대학교 기계공학과 (학사)
- 2019년 8월 : 서울과학기술대학교 IT정책전문대학원 산업정보시스템 전공 (공학석사)
- 2015년 6월 ~ 현재 : 국방기술품질원 연구원

<관심분야>

신뢰성, 머신러닝