



J. Korean Soc. Aeronaut. Space Sci. 49(11), 901-907(2021)

DOI: <https://doi.org/10.5139/JKSAS.2021.49.11.901>

ISSN 1225-1348(print), 2287-6871(online)

인공신경망 기반의 유도탄 노즈 공력계수 예측 연구

이정용¹, 이복직²

Application of Artificial Neural Network to Predict Aerodynamic Coefficients of the Nose Section of the Missiles

Jeongyong Lee¹ and Bok Jik Lee²Interdisciplinary Program in Space Systems, Seoul National University¹Department of Aerospace Engineering, Seoul National University²

ABSTRACT

The present study introduces an artificial neural network (ANN) that can predict the missile aerodynamic coefficients for various missile nose shapes and flow conditions such as Mach number and angle of attack. A semi-empirical missile aerodynamics code is utilized to generate a dataset comprised of the geometric description of the nose section of the missiles, flow conditions, and aerodynamic coefficients. Data normalization is performed during the data preprocessing step to improve the performance of the ANN. Dropout is used during the training phase to prevent overfitting. For the missile nose shape and flow conditions not included in the training dataset, the aerodynamic coefficients are predicted through ANN to verify the performance of the ANN. The result shows that not only the ANN predictions are very similar to the aerodynamic coefficients produced by the semi-empirical missile aerodynamics code, but also ANN can predict missile aerodynamic coefficients for the untrained nose section of the missile and flow conditions.

초 록

본 연구에서는 다양한 유도탄 노즈 형상과 유동조건에 대한 공력계수를 예측할 수 있는 인공신경망 기반의 공력 산출 기법을 제시한다. Missile DATCOM를 통해 유도탄 노즈 형상, 유동조건, 유도탄 공력계수로 구성된 학습 데이터셋을 구축하였다. 인공신경망의 예측 성능을 향상시키기 위해 데이터 전처리 과정으로 데이터 정규화를 진행하였고, 과대적합을 방지하기 위해 신경망 학습 과정 중 드롭아웃 기법을 사용하였다. 신경망을 통해 학습하지 않은 유도탄 노즈 형상과 유동조건에 대한 공력계수를 예측하였고 이를 Missile DATCOM 해석 결과와 비교하여 신경망의 성능을 검증하였다. 그 결과 본 연구에서 구축한 신경망은 학습하지 않은 유도탄 노즈 형상과 유동조건에 대한 유도탄 공력계수를 정확하게 산출할 수 있음을 확인하였다.

Key Words : Machine Learning(기계학습), Artificial Neural Network(인공신경망), Missile DATCOM (미사일 DATCOM), Aerodynamic Coefficient(공력계수)

† Received : August 17, 2021 Revised : October 12, 2021 Accepted : October 25, 2021

¹ Graduate Student, ² Professor

² Corresponding author, E-mail : b.lee@snu.ac.kr, ORCID 0000-0002-8572-1522

© 2021 The Korean Society for Aeronautical and Space Sciences

I. 서 론

기존의 유도탄 공력 산출 기법은 준경험식 및 고신뢰도 수치해석 등 물리적 모델링에 근거한 접근 방식과 풍동실험 데이터에 기초하고 있다. 그러나 준경험식 기법은 식마에 의해 변화된 유도탄 형상과 같이 기존에 정의된 형상 파라미터들로 설계하기 힘든 형상에 대해서는 공력을 정확하게 산출할 수 없고, CFD 해석과 풍동실험은 새로운 유도탄 형상에 대한 공력을 산출하기 위해서는 많은 비용을 요구한다. 또한 현재 각기 다른 신뢰도의 공력 산출 기법에서 얻어진 데이터와 풍동실험 데이터 간의 선택 및 융합 문제는 전문가의 경험과 직관에 의존하고 있다. 이에 본 연구에서는 기존에 산출된 공력 데이터를 활용할 수 있으며 새로운 유도탄 형상에 대한 공력계수를 객관적이고 자동적으로 산출할 수 있는 인공신경망 기반의 공력계수 산출 기법을 제시하고자 한다.

인공신경망(Artificial Neural Network, ANN)은 데이터로부터 복잡하고 비선형적인 함수를 쉽게 모델링할 수 있다는 장점이 있어[1], 항공우주 분야에서도 이를 활용한 연구가 다수 진행되고 있다[2-5]. Sekar 등[2]은 합성곱 신경망(Convolutional Neural Network, CNN)과 인공신경망을 사용하여 2D 에어포일 주변의 유동장을 예측하는 연구를 진행하였다. 해당 연구에서 제시한 기법은 CFD 해석과 비교했을 때 150배 절감된 CPU time만을 사용하여 유사한 해석 결과를 도출하였다. 강태영 등[3]은 심층신경망(Deep Neural Network)을 사용하여 유도탄 파편의 예상 탄착점, 분포 영역, 낙하 시간을 추정하였다. 심층신경망은 몬테카를로 시뮬레이션과 비교하였을 때 매우 짧은 시간 안에 정확도 높은 추정 결과를 도출하였다. Penchalaiah 등[4]은 인공신경망 기반의 유도탄 항력계수 분리기법을 제시하였다. 해당 연구에서 분리된 세 종류의 항력계수는 풍동실험 데이터를 통해 얻은 공기역학 모델과 잘 일치함을 보였다. Ritz 등[5]은 인공신경망을 이용하여 동체와 조종면을 포함한 유도탄 전체 형상에 대한 공력계수를 예측하였다. 인공신경망 기반의 대체모델(Surrogate model)을 통해 임의의 유도탄 형상 정보, 마하수, 받음각에 대한 두 가지 유도탄 공력계수를 예측하였다. 그러나 해당 연구에서 유도탄 형상은 단일 종횡비로 한정되었으며, 공력계수 중 axial force coefficient는 정확하게 모델링하지 못했다.

본 연구에서는 유도탄 노즈에 대한 공력 계수를 산출할 수 있는 인공신경망을 제시한다. 학습 및 검증용 공력 데이터를 산출하는 도구로는 Missile DATCOM [6]이 사용되었다. 구축된 신경망을 통해 학습하지 않은 유도탄 노즈 형상과 유동조건에 대한 공력계수를 예측함으로써 신경망의 기존 공력계수 산출 기법 대체 가능성을 확인하였다.

II. 본 론

2.1 인공신경망

2.1.1 인공신경망

기계학습 방법론 중 하나인 인공신경망은 뉴런과 시냅스로 이루어진 생물학적 신경 시스템이 정보를 처리하는 방법에 착안하여 만든 연산모델이다[7]. 인공신경망은 입력층(Input layer), 은닉층(Hidden layer), 출력층(Output layer)로 구성되어 있으며, 각 층은 뉴런으로 구성되어 있다.

인공신경망은 순전파(Forward propagation)와 역전파(Back propagation) 과정을 통해 훈련된다. 인공신경망의 순전파 과정은 인공신경망에서 입력된 값이 입력층에서 출력층 방향으로 연산되는 과정이며 식 (1)과 같이 나타낼 수 있다.

$$Y = h(WX + b) \quad (1)$$

여기서 X 와 Y 는 입력값과 예측값을 나타내며 h , W , b 는 각각 활성화 함수, 가중치, 편향을 나타낸다. 순전파 과정을 통해 각 뉴런의 입력 값에 가중치를 곱하고 편향을 더한 다음, 활성화 함수를 적용하여 출력값을 계산한다. 출력값과 목표값 사이의 오차를 계산하고, 오차를 역으로 전파하여 뉴런과 뉴런 사이 연결선의 가중치 값을 조정하는 과정을 오차 역전파라 한다. 인공신경망의 훈련 알고리즘은 위 과정을 반복 수행하여 출력값과 목표값 사이 오차를 줄인다. Fig. 1은 본 연구에서 사용된 인공신경망의 구축 과정을 설명하는 도식이다.

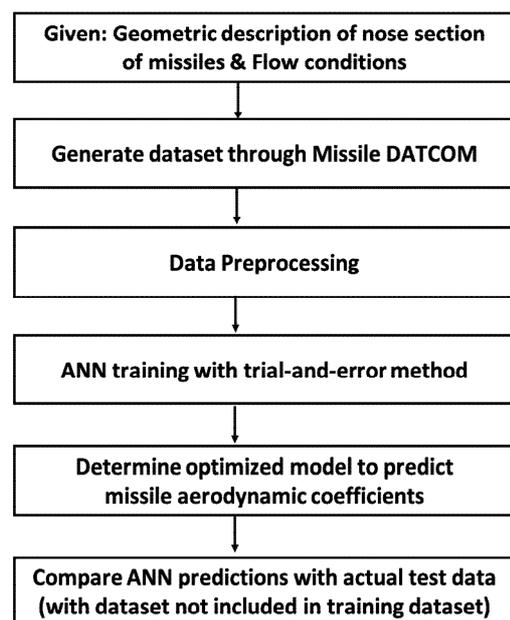


Fig. 1. Overview of the ANN approach

2.1.2 학습 데이터 생성

본 연구에서는 축대칭 형상의 유도탄 노즈 부분만을 공력해석 대상으로 선정하였다. 다양한 유도탄 노즈 형상과 유동조건에 대한 공력계수를 산출하기 위해 비교적 빠른 시간에 공력계수를 산출할 수 있는 준경험식 기법을 이용한 공력해석 코드인 Missile DATCOM을 사용하였다. 본 연구에서는 마하수 1.2 이상 비행조건에서 공력계수를 학습하고 검증하였으며, 본 속도 영역에서 Missile DATCOM은 Van Dyke Hybrid 이론[8]을 통해 노즈 부분 공력을 산출한다. 단, 노즈 팁이 뾰족한 경우 second-order shock expansion 기법[9]을 통해 공력을 산출한다.

본 연구에서는 마하수, 받음각(AOA), 유도탄 노즈의 형태, 유도탄 노즈의 종횡비, 유도탄 노즈의 bluntness radius를 변경하면서 학습 데이터를 생성하였다. Table 1은 학습 데이터를 생성할 때 사용한 유도탄 노즈의 형상조건과 유동조건을 보여준다. 본 연구에서는 노즈의 종횡비를 변경할 때 노즈 기저 직경은 0.6 m로 고정시키고 노즈 길이만 변경하였다. 유도탄의 노즈에서 무게중심까지의 거리는 0으로 설정하였고 고도는 30,000 m로 고정하였다.

유도탄 노즈 형태(5가지), 유도탄 노즈의 bluntness radius (2가지), 종횡비(5가지), 마하수(8가지), 받음각(20가지)을 각각 조합하여 총 8,000가지 경우에 대한 학습 데이터를 생성하였다.

2.1.3 변수 설정

본 연구에서는 신경망 입력변수로 유도탄 노즈 형상을 정의하는 좌표값, 마하수, 받음각을 사용하였다. 노즈 팁을 원점으로 하는 2차원 좌표계 상의 위치 (x, r) 로 형상 좌표값을 정의하였으며, x 는 유도탄 동체 종방향 거리, r 은 x 축에 수직인 단면의 반경에 해

Table 1. Flow conditions and geometric description of the nose section of missiles

Flow condition	Case
Mach number	1.2, 1.5, 2.0, 2.2, 2.5, 3.0, 4.0, 5.0
AOA (degree)	0, 2, ..., 36, 38
Altitude (m)	30,000

Geometric description	Case
Nose shape	cone, ogive, Von Karman, HAACK, power
Fineness ratio (L/D)	1.6, 2.0, 2.4, 2.8, 3.2
Nose bluntness radius (m)	0, 0.06

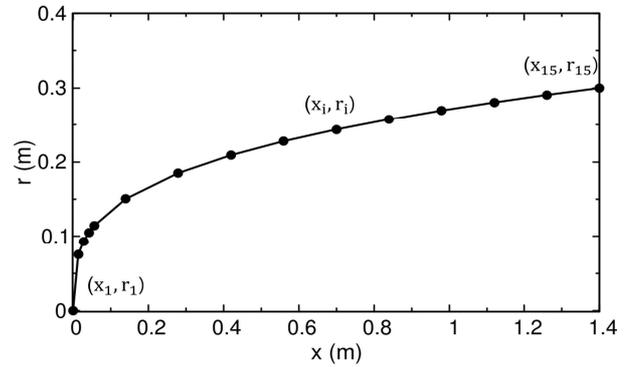


Fig. 2. An example of the geometric description of the nose section of missiles

당한다. 본 연구에서는 Fig. 2와 같이 15쌍의 (x, r) 을 사용하여 학습용 형상 정보를 구축했다. 즉, 노즈 형태, bluntness radius, 종횡비 등의 조합에 의한 50종의 형상과 마하수 및 받음각 조합에 의한 160가지 비행조건에 대해 각각 30개의 좌표값과 2개의 비행조건(마하수, 받음각)을 입력변수로 정의하였다.

신경망 출력변수로는 동체 축에 대한 normal force coefficient (C_N)와 axial force coefficient (C_A), 노즈 팁에 대한 pitching moment coefficient (C_m)를 각각 사용하였다.

2.1.4 데이터 전처리 과정

본 연구에서는 데이터 전처리 과정으로 데이터 정규화(Data normalization)를 진행하였다. 데이터 정규화는 다양한 스케일의 데이터들을 동일한 스케일로 변환시키는 과정이다. 신경망 학습 전에 본 과정을 진행함으로써 신경망의 예측 성능을 개선시킬 수 있다[10]. 이에 본 연구에서는 최소 최대 정규화 기법 (Min-Max Normalization)을 사용하여 모든 학습 데이터를 -1과 1 사이의 값으로 변환시켰으며 사용된 식들은 다음과 같다.

$$X_{norm} = \frac{X - X_{min}}{X_{max} - X_{min}} \times 2 - 1 \quad (2)$$

$$Y_{norm} = \frac{Y - Y_{min}}{Y_{max} - Y_{min}} \times 2 - 1 \quad (3)$$

식 (2)의 X_{norm} 은 변환된 입력 변수 데이터를 나타내고 식 (3)의 Y_{norm} 은 변환된 출력 변수 데이터를 나타낸다.

2.1.5 신경망 모델링

본 연구에서 신경망의 구조, 은닉층의 활성화 함수, 반복횟수(Epochs) 등의 신경망 하이퍼파라미터는 시행 착오법(Trial and error method)에 의해 결정되었다. 신경망 하이퍼파라미터를 결정하는 방법에는 전통적인 시행착오법 및 grid search, random search,

Bayesian optimization 등의 최적화 기법[11]이 있다. 최적화 기법 적용 시 시행착오법보다 더 좋은 예측 성능을 갖는 신경망 모델을 도출할 가능성이 있으나 파라미터 공간에서 다양한 시도를 하기 위해서는 계산비용이 상대적으로 큰 단점이 있다. 이에 반해 시행착오법 적용 시 설계자의 경험과 직관에 의존한다는 한계에도 불구하고 하이퍼파라미터의 수가 크지 않은 경우 선형적인 값들로부터 시작하여 목표 학습 성능을 위한 조합을 찾을 수 있다.

Figure 3은 본 연구에서 사용된 인공신경망의 구조를 보여준다. 입력층을 구성하는 뉴런 수는 32개이며 각각 유도탄 노즈 형상을 정의하는 좌표값(x_i, r_i), 마하수(M), 받음각(AOA)으로 구성되었다. 출력층을 구성하는 뉴런 수는 1개이며 동체 축에 대한 normal force coefficient (C_N) 또는 노즈 팁에 대한 pitching moment coefficient (C_m) 또는 동체 축에 대한 axial force coefficient (C_A)이다. 은닉층은 5개의 층으로 쌓았으며, 은닉층을 구성하는 뉴런 수는 각각 64, 32, 16, 8, 4개이다.

본 연구에서는 과대적합(Overfitting)을 방지하기 위해 드롭아웃(Dropout) 기법을 사용하였다. 과대적합은 신경망이 학습 데이터에 지나치게 가깝게 맞춰져 학습 데이터에 대해서는 좋은 예측 성능을 보이지만 새로 관측될 데이터에 대해서는 일반화 성능이 떨어지는 현상이다[12]. 드롭아웃 기법은 Fig. 4와 같

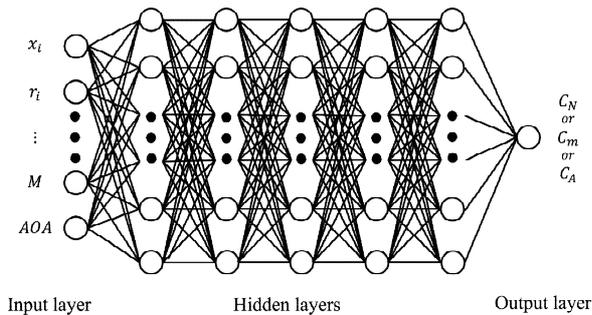


Fig. 3. Architecture of artificial neural network

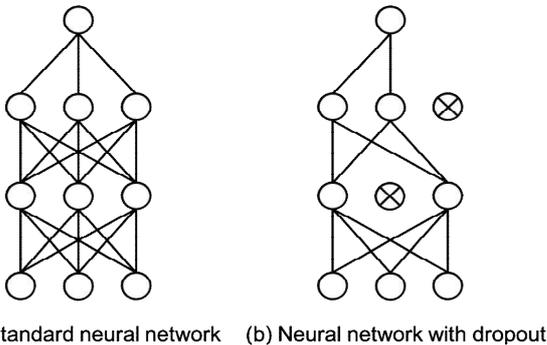


Fig. 4. (a) A standard neural network with 2 hidden layers (b) A neural network with 2 hidden layers and dropout

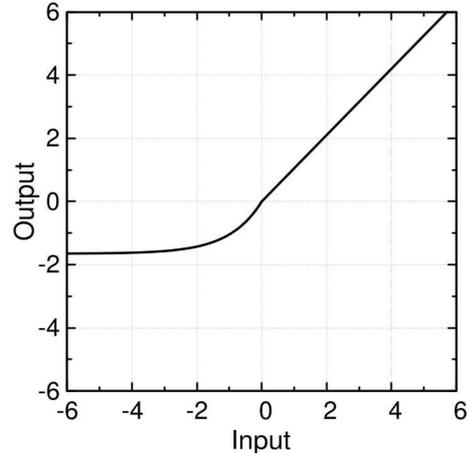


Fig. 5. SELU activation function

이 신경망의 학습 단계에서 임의로 뉴런을 비활성화하여 일시적으로 신호를 전달하지 않는 기법이다. Srivastava 등[13]은 신경망에 드롭아웃 기법을 적용하였을 때 신경망의 과대적합을 방지할 뿐만 아니라 신경망의 정확도가 높아지는 것을 보였다.

은닉층의 활성화 함수 선정을 위해 hyperbolic tangent, sigmoid, Rectified Linear Unit (ReLU), Scaled Exponential Linear Unit (SELU) 등 네 종류의 활성화 함수를 적용하여 검토하였다. SELU[14]는 널리 쓰이는 ReLU의 “dying ReLU[15]” 문제에 대한 대안으로 등장한 활성화 함수로서, 본 연구의 데이터 셋에 대해 검토 대상 중 가장 높은 예측 정확도를 보였다. 가중치는 LeCun initializer[16]를 사용하여 초기화하였다. Fig. 5는 SELU 활성화 함수를 나타내고 있으며, 식 (4)는 SELU 함수의 식을 보여준다. 최적화 알고리즘으로는 계산 효율이 높고 메모리 요구량이 작은 Adam 알고리즘[17]을 선택하였으며 반복 횟수는 500으로 설정하였다. 본 연구에서는 Python으로 작성된 오픈 소스 신경망 라이브러리인 Keras [18]를 통해 인공신경망을 구축하였다.

$$SELU(x) = \begin{cases} \lambda x & , x > 0 \\ \lambda(\alpha e^x - \alpha) & , x < 0 \end{cases} \quad (4)$$

$$\alpha = 1.67326324, \lambda = 1.05070098$$

2.2 학습 결과

2.2.1 학습 오차

본 연구에서는 손실함수(Loss function)의 일종인 평균 제곱 오차(Mean Squared Error, MSE)를 사용하여 최적의 가중치 값을 탐색하였다. 식 (5)는 평균 제곱 오차의 식을 보여준다.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - t_i)^2 \quad (5)$$

여기서 y_i 는 신경망이 예측한 값이고, t_i 는 목표값이다. 전체 데이터의 80%는 학습에 사용되었으며, 나머지 20%는 신경망의 성능 검증을 위해 사용되었다.

Figure 6은 반복횟수에 따른 학습 데이터의 평균 제공 오차와 검증 데이터의 평균 제공 오차를 보여준다. 모든 공력계수에 대하여 학습 데이터의 평균 제공 오차가 검증 데이터의 평균 제공 오차보다 크지 않은 것을 확인할 수 있으며, 이는 학습과정 중 과대적합이 발생하지 않은 것을 보여준다. 또한 epoch 500일 때 모든 공력계수에 대하여 학습 데이터의 평균 제공 오차 값이 거의 일정하기 때문에 충분히 수렴하였다고 판단할 수 있다.

2.2.2 학습 모델 예측 성능 평가

본 연구에서는 구축된 신경망의 공력계수 예측 성능을 평가하기 위해 신경망이 학습하지 않은 유도탄 노즈 형상과 유동조건에 대한 공력계수를 예측하였다.

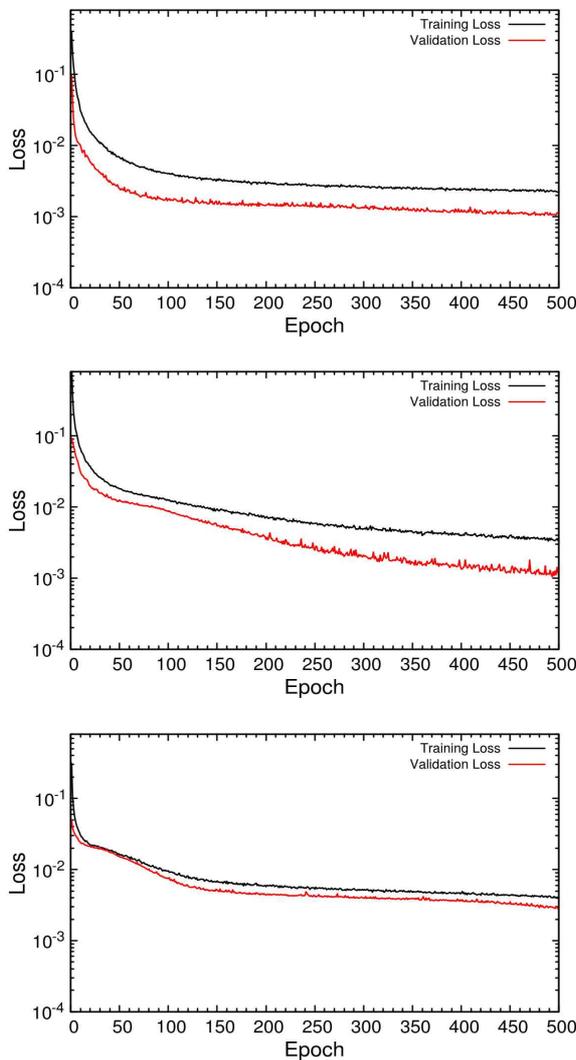


Fig. 6. Training and validation loss (MSE). Top C_N . Middle C_m . Bottom C_A .

Table 2는 평가용 데이터에서의 형상조건과 유동조건을 보여준다. Fig. 7은 신경망이 학습한 유도탄 노즈 형상과 학습하지 않은 유도탄 노즈 형상을 동시에 나타낸다. 학습하지 않은 유도탄 노즈 형상의 직경과 노즈의 길이는 각각 0.6 m와 1.4 m로 설정하였다. 유동조건은 고도 30,000 m, 마하수 2.3 영역에서 받음각을 0도에서 39도까지 1도씩 증가시켜 총 40가지 경우에 대한 평가용 데이터를 생성하였다. Fig. 8은 평가용 데이터에서 받음각에 대한 공력계수를 나타내며 Table 3은 신경망을 통해 예측한 값과 Missile DATCOM 해석 결과 사이의 결정계수(Coefficient of determination, R^2)와 평균 제곱근 오차(Root Mean Square Error, RMSE)를 나타낸다. 결정계수는 식 (6)과 같이 나타내며 평균 제곱근 오차는 식 (7)과 같이 나타낸다.

$$R^2 = 1 - \frac{\sum_{i=1}^k (y_i - \hat{y}_i)^2}{\sum_{i=1}^k (y_i - \bar{y}_i)^2} \tag{6}$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - t_i)^2} \tag{7}$$

여기서 y 는 표본 값, \hat{y} 는 모델 예측값, \bar{y} 는 표본의 평균을 의미한다. 결정계수와 평균 제곱근 오차는 모델의 정확도를 수치적으로 나타낼 수 있는 척도로 사용된다. 결정계수는 1에 가까울수록 그리고 평균 제곱근 오차는 0에 가까울수록 모델이 표본에 잘 맞게 생성되었다고 할 수 있다. 선행 연구사례[5]에서는 초음속 영역에서의 유도탄 공력계수 C_N 에 대한 결정계수와 평균 제곱근 오차는 각각 0.998과 0.147이며 C_m 에 대한 결정계수와 평균 제곱근 오차는 각각 0.997과 0.948이다.

Table 2. Flow conditions and geometric description for the testing dataset

Flow condition	Case
Mach number	2.3
Angle of attack	0, 1, 2, ..., 37, 38, 39
Altitude	30,000 (m)
Geometric description	Case
Nose shape	cone
Fineness ratio (L/D)	2.33
Nose bluntness radius	0.06 (m)

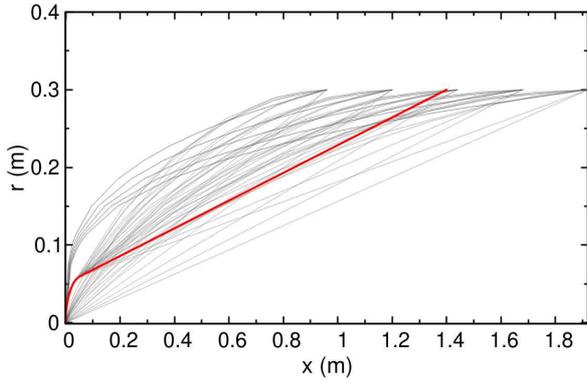


Fig. 7. Nose sections of missiles used for training (gray) and testing (red) the neural network

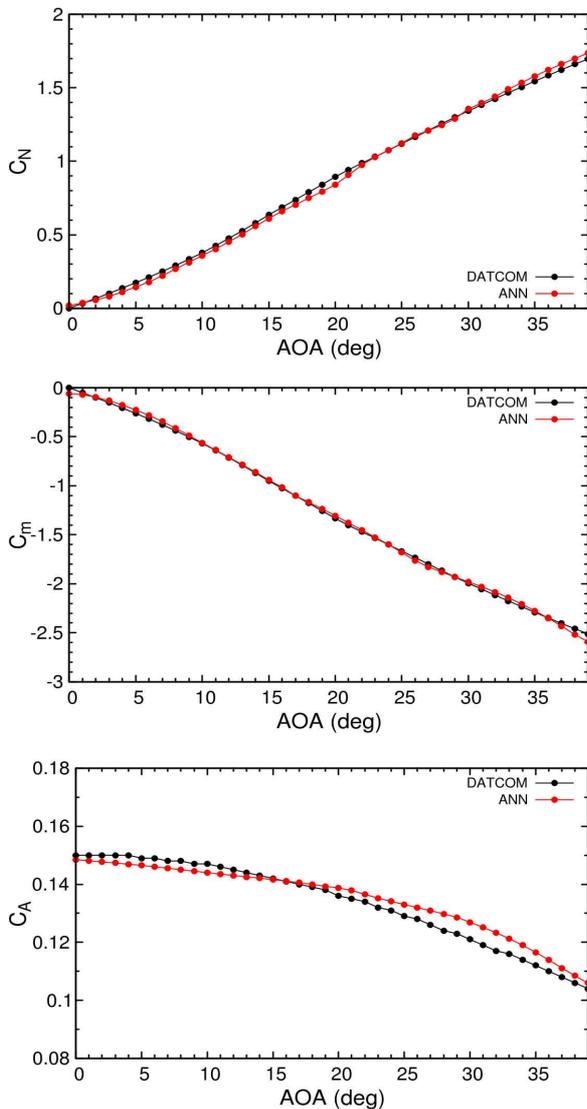


Fig. 8. Aerodynamic coefficients obtained from Missile DATCOM versus ANN predictions - α curve for the testing dataset Top C_N . Middle C_m . Bottom C_A .

Table 3. Coefficient of determination and RMSE between aerodynamic coefficients obtained from Missile DATCOM and ANN predictions for the testing dataset

Error	C_N	C_m	C_A
R^2	0.997	0.998	0.941
RMSE	0.026	0.027	0.0034

본 논문에서 예측된 세 가지의 공력계수는 받음각에 대해 비선형성이 크지 않은 분포를 보였으며, 이러한 특성으로 인해 높은 정밀도의 신경망을 구축할 수 있었다. 단, C_A 는 받음각에 대한 비선형성이 상대적으로 커서 타 공력계수에 비해 낮은 결정계수를 보인 것으로 판단된다. 이를 극복할 수 있는 더 큰 규모의 학습 데이터셋을 제공한다면 개선된 결과를 도출할 수 있을 것으로 기대된다.

Figure 8과 Table 3에서 볼 수 있듯이 본 연구에서는 두 종류의 유도탄 공력계수 뿐만 아니라 유도탄 공력계수 C_A 에 대해서도 높은 정확도의 공력계수 예측 모델을 구축하였다. 또한 본 연구에서 제시한 신경망은 학습하지 않은 유도탄 노즈 형상에 대해서도 유도탄 공력계수를 정확하게 예측할 수 있음을 확인하였다.

III. 결 론

본 연구에서는 인공신경망 기반의 유도탄 공력계수 산출 기법을 제시하였다. 인공신경망의 공력계수 예측 성능을 향상시키기 위해 데이터 전처리 과정으로 데이터 정규화를 진행하였고 학습과정 중의 과대적합을 방지하기 위해 드롭아웃 기법을 사용하였다. 학습하지 않은 유도탄 노즈 형상과 유도조건에 대한 공력계수를 신경망을 통해 예측하였고 이는 Missile DATCOM 해석 결과와 유사하였다. 이를 통해 해당 논문에서 제시한 인공신경망은 학습하지 않은 유도탄 노즈 형상에 대한 세 종류의 공력 계수를 정확하게 예측할 수 있음을 확인하였다.

본 연구에서 제시한 인공신경망은 저충실도 데이터만을 학습하였지만 추후 진행할 연구에서는 CFD 해석 결과 또는 풍동 실험 데이터 등의 고충실도 데이터를 같이 학습시킨 다충실도 신경망(Multi-fidelity neural network)을 구축할 예정이다. 또한 유도탄 전체 형상에 대한 공력계수를 예측할 수 있는 신경망으로의 확장 연구가 진행 중이다.

후 기

본 연구는 데이터 기반 유동 모델링 특화연구실 프로그램의 일환으로 방위사업청과 국방과학연구소의 지원으로 수행되었음.

References

- 1) Almeida, J. S., "Predictive Non-linear Modeling of Complex Data by Artificial Neural Networks," *Current Opinion in Biotechnology*, Vol. 13, No. 1, 2002, pp. 72~76.
- 2) Sekar, V., Jiang, Q., Shu, C. and Khoo, B. C., "Fast Flow Field Prediction over Airfoils Using Deep Learning Approach," *Physics of Fluids*, Vol. 31, No. 5, 2019, 057103.
- 3) Kang, T. Y., Park, K. K., Kim, J. H. and Ryoo, C. K., "Real-Time Estimation of Missile Debris Predicted Impact Point and Dispersion Using Deep Neural Network," *Journal of The Korean Society for Aeronautical and Space Sciences*, Vol. 49, No. 3, 2021, pp. 197~204.
- 4) Penchalaiah, D., Kumar, G. N. and Ghosh, A. K., "Missile Drag Coefficients Segregation Using Artificial Neural Network," *6th Symposium on Applied Aerodynamics and Design of Aerospace Vehicles (SAROD)*, November 2013, pp. 21~23.
- 5) Ritz, S. G., Hartfield, R. J., Dahlen, J. A., Burkhalter, J. E. and Woltosz, W. S., "Rapid Calculation of Missile Aerodynamic Coefficients Using Artificial Neural Networks," *2015 IEEE Aerospace Conference*, March 2015, pp. 1~19.
- 6) Blake, W. B., *Missile DATCOM: User's Manual-1997 FORTRAN 90 Revision*, Air Force Research Lab Wright-Patterson AFB OH Air Vehicles Directorate, Oklahoma, 1998.
- 7) Wang, S. C., *Interdisciplinary Computing in Java Programming*, Springer, Boston, 2003, pp. 81~100.
- 8) Van Dyke, M. D., "First-and Second-order Theory of Supersonic Flow Past Bodies of Revolution," *Journal of the Aeronautical Sciences*, Vol. 18, No. 3, 1951, pp. 161~178.
- 9) Moore, F. G., Armistead, M. A., Rowles, S. H. and DeJarnette, F., R., "Second-Order Shock-Expansion Theory Extended to Include Real Gas Effects," *NAVSWC TR90-683*, Naval Surface Warfare Center Dahlgren Div., Dahlgren, 1992.
- 10) Yu, L., Wang, S. and Lai, K. K., "An Integrated Data Preparation Scheme for Neural Network Data Analysis," *IEEE Transactions on Knowledge and Data Engineering*, Vol. 18, No. 2, 2005, pp. 217~230.
- 11) Feurer, M. and Hutter, F., *Automated Machine Learning*, Springer, Cham, 2019, pp. 3~33.
- 12) Hawkins, D. M., "The Problem of Overfitting," *Journal of Chemical Information and Computer Sciences*, Vol. 44, No. 1, 2004, pp. 1~12.
- 13) Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I. and Salakhutdinov, R., "Dropout: A Simple Way to Prevent Neural Networks from Overfitting," *The Journal of Machine Learning Research*, Vol. 15, No. 1, 2014, pp. 1929~1958.
- 14) Klambauer, G., Unterthiner, T., Mayr, A. and Hochreiter, S., "Self-normalizing Neural Networks," *Proceedings of the 31st International Conference on Neural Information Processing Systems*, December 2017, pp. 972~981.
- 15) Douglas, S. C. and Yu, J., "Why RELU Units Sometimes Die: Analysis of Single-unit Error Back-propagation in Neural Networks," *52nd Asilomar Conference on Signals, Systems, and Computers*, October 2018, pp. 864~868.
- 16) LeCun, Y. A., Bottou, L., Orr, G. B. and Müller, K. R., *Neural Networks: Tricks of the Trade*, Springer, Berlin, Heidelberg, 2012, pp. 9~48.
- 17) Bock, S. and Weiß, M., "A Proof of Local Convergence for the Adam Optimizer," *2019 International Joint Conference on Neural Networks*, July 2019, pp. 1~8.
- 18) Ketkar, N., *Deep Learning with Python: A Hands-on Introduction*, Apress, Berkeley, 2017, pp. 97~111.