

Received: 2024/11/17
Revised: 2024/11/21
Accepted: 2024/12/25
Published: 2024/12/31

***Corresponding Author:**

Soon-Kook Hong
Dept. of Mechanical System Engineering, Republic of Korea Naval Academy
1 Jungwon-ro, Jinhae-gu, Changwon-si, Gyung-sangnam-do, 51704, Republic of Korea
Tel: +82-55-907-5314
E-mail: hks753@gmail.com

Abstract

본 연구는 강화학습(RL)과 회귀모델을 통합하여 표적 위협을 평가하는 시스템 개발을 제안한다. 제안된 시스템은 표적의 정체성, 방위각, 거리, 속도와 관련된 1,000개의 샘플로 구성된 데이터셋을 활용한다. 결측값은 선형보간법으로 처리하였으며, 특징 정규화를 수행하여 대공 위협모델에서 평균제곱오차(MSE) 0.045, 대함 위협모델에서 0.038을 달성하였다. 딥 Q-네트워크(DQN) 에이전트를 구현하였으며, 1,000 에피소드 동안 학습한 결과 평균 보상 -2.3을 기록하여 상태 변화 최소화에서 효과적인 학습을 나타냈다. 제안된 시스템은 통합 접근 방식을 통해 실시간 위협평가의 정확성과 반응성을 높여 운영 의사결정을 개선한다.

This study presents the development of a target threat assessment system that integrates reinforcement learning (RL) and regression models to evaluate air and surface threats. The system utilizes a dataset comprising 1,000 samples related to target identity, bearing, range, and speed. Missing values were handled using linear interpolation, and feature normalization was performed, achieving a mean squared error (MSE) of 0.045 for air threat and 0.038 for surface threat in regression models. A Deep Q-Network (DQN) agent was implemented with a training duration of 1,000 episodes, resulting in an average reward of -2.3, indicating effective learning in minimizing state changes. The proposed system enhances real-time threat assessment accuracy and responsiveness, improving operational decision-making.

Keywords

강화학습(Reinforcement Learning),
회귀모델(Regression Model),
표적위협평가(Target Threat Assessment),
평균제곱오차(Mean Squared Error)

Acknowledgement

이 논문은 2023년 정부(방위사업청)의 재원으로 국방기술진흥연구소의 지원을 받아 수행된 연구임(KRIT-CT-23-030).

강화학습 및 회귀모델을 이용한 표적위협평가 시스템 개발

Development of a Target Threat Assessment System Using Reinforcement Learning and Regression Models

한민석¹, 장원석², 전민규³, 이현기³, 김세라⁴, 최영두⁵, 홍순국^{6*}

¹해군사관학교 전자제어공학과 부교수

²한화시스템 해양시스템1팀 수석연구원

³해군사관학교 기계시스템공학과 조교수

⁴해군사관학교 기초과학과 부교수

⁵해군사관학교 전자제어공학과 조교수

⁶해군사관학교 기계시스템공학과 교수

Min-Seok Han¹, Wonseok Jang², Min-Gyu Jeon³, Hun-Kee Lee³, Sera Kim⁴, Youngdoo Choi⁵, Soon-Kook Hong^{6*}

¹Associate professor, Dept. of Electronics and Control Engineering, Republic of Korea Naval Academy

²Chief engineer, Naval System Team 1, Hanwha Systems

³Assistant professor, Dept. of Mechanical System Engineering, Republic of Korea Naval Academy

⁴Associate professor, Dept. of Natural Science, Republic of Korea Naval Academy

⁵Assistant professor, Dept. of Electronics and Control Engineering, Republic of Korea Naval Academy

⁶Professor, Dept. of Electronics and Control Engineering, Republic of Korea Naval Academy

1. 서론

현대 전투 환경에서 표적위협평가 시스템은 군사 작전의 성공에 필수적인 요소로 자리 잡고 있다. 특히 공중 및 수면 위협을 정확하게 식별하고 평가하는 것은 적의 공격을 효과적으로 방어하고, 자원을 효율적으로 배분하는 데 중요한 역할을 한다. 그러나 기존의 위협평가 시스템은 주로 경험적 데이터와 규칙 기반 방법에 의존하여, 동적인 전투 환경에 적합하지 않은 한계를 보인다.

Hwang et al.(2007)은 초계함 전투체계의 대공전 능력을 연구하였다. 이 연구는 특정 전투체계에 초점을 맞추어 위협평가를 다루었으나, 다양한 위협 유형에 대한 포괄적인 평가가 부족하다[1].

Yoon et al.(2018)은 다중 지상 표적에 대한 위협 평가 알고리즘을 제안했다. 이 연구는 복수의 지상 표적을 동시에 고려하여 위협을 평가하는 방법을 제시하였으나, 공중 위협에 대한 고려가 부족한 한계가 있다[2]. 또한, Ahn et al.(2019)은 교전 능력 시간을 고려한 위협 평가 방법을 연구했다. 이 접근법은 시간적 요소를 위협 평가에 포함시켰다는 점에서 의의가 있으나, 실시간으로 변화하는 전장 환경에 대한 적응력이 부족할 수 있다[3]. Yun et al.(2020)은 정보 융합을 기반으로 한 퍼지-베이지안 네트워크를 사용하여 공중 위협 평가 시스템을 개발했다. 이 방법은 다양한 정보를 통합하여 위협을 평가한다는 장점이 있지만, 복잡한 네트워크 구조로 인해 실시간 처리에 어려움이 있을 수 있다[4]. Choi et al.(2016)은 퍼지 규칙 기반 방법을 사용하여 공중 위협을 평가하는 기법을 제안했다. 이 접근법은 불확실성을 다루는데 효과적이지만, 복잡한 규칙 설정이 필요하고 새로운 위협 유형에 대한 적응력이 제한적일 수 있다[5]. 마지막으로, Yun et al.(2022)은 다양한 전장 상황에 적용 가능한 퍼지-베이지안 네트워크를 이용한 위협 평가 방법을 제안했다. 이 접근법은 다양한 상황에 대한 적응력을 높였으나, 복잡한 전장 환경에서의 정확성 검증이 추가로 필요할 것으로 보인다[6].

전반적으로, 이 연구들은 위협 평가의 정확성과 적응성을 높이기 위해 다양한 방법을 시도했지만, 실시간 처리 능력, 복잡한 환경에서의 정확성, 그리고 다양한 위협 유형에 대한 통합적 평가 등에서 여전히 개선의 여지가 있다.

따라서 본 연구에서는 이러한 문제점을 해결하기 위해 강화학습과 회귀모델을 통합한 새로운 위협 평가 시스템을 제안한다. 특히, 다변량 데이터를 효과적으로 처리할 수 있는 회귀모델과 동적인 환경에 적용할 수 있는 강화학습 에이전트를 결합하여, 더욱 정확하고 신속한 위협 평가를 가능하게 한다. 이를 통해 시스템의 예측 정확성을 높이고, 실시간으로 변화하는 전투 환경에 적합한 대응력을 갖춘 모델을 구현하고자 한다.

본 논문의 구성은 다음과 같다. 2장 이론적 배경 및 방법론에서는 데이터 준비 및 전처리 방법을 설명하고, 3장 시스템 설계 및 모델링 부분에서는 회귀모델 학습 및 평가 과정을 다룬다. 4장 시뮬레이션 결과 및 분석 부분에서는 강화학습모델의 구현 및 학습 과정

을 설명하고, 시뮬레이션 결과를 바탕으로 학습 옵션 및 결과를 분석한다. 마지막으로 5장 결론에서 본 연구의 기여와 중요성을 명확히 하고, 향후 연구 방향을 제시한다.

2. 이론적 배경 및 방법론

2.1 데이터 준비

본 연구에서 사용된 데이터는 표적의 위협 정보를 포함하는 CSV 파일로부터 수집되었다. 데이터는 총 1,000개의 샘플로 구성되어 있으며, 이들 개별 샘플은 각 표적의 정체성(identity), 방위각(bearing), 거리(range), 속도(speed), 대공 위협(airThreat), 대함 위협(surfaceThreat) 등의 변수를 포함하고 있다. 이들 변수는 군사 작전에서 표적의 위협 수준을 평가하는 데 중요한 역할을 한다.

2.2 결측값 처리

데이터셋에서 결측값이 발견된 경우, 이를 처리하기 위해 선형보간법(linear interpolation)을 사용하였다. 선형보간법은 두 개의 데이터 포인트 사이의 값을 추정하는 방법으로, 연속적인 데이터에 적합하다. 결측값이 있는 경우, 주변 데이터 포인트를 이용하여 결측값을 보완할 수 있다. 수식으로 표현하면 식 (1)과 같다.

$$y = y_1 + (x - x_1) \times (y_2 - y_1) / (x_2 - x_1) \quad (1)$$

여기서, x 는 우리가 추정하고자 하는 지점, (x_1, y_1) 은 첫 번째 알려진 데이터 포인트, (x_2, y_2) 는 두 번째 알려진 데이터 포인트, y 는 x 지점에서의 추정값을 나타낸다. 이러한 방법을 통해 데이터의 일관성을 유지할 수 있었다.

2.3 특징 정규화

데이터 전처리의 다음 단계는 특징 정규화(normalization)이다. 모델의 학습 성능을 향상시키기 위하여 각 특징 변수는 평균을 0, 표준편차를 1로 맞추는 표준화(standardization) 과정을 거쳤다. 특징 정규화는 다음과 같은 수식으로 표현된다.

$$z = x - \mu / \sigma \quad (2)$$

여기서, z 는 정규화된 값, x 는 원래 특징값, μ 는 특징의 평균, σ 는 표준편차를 나타낸다. 정규화된 데이터는 각 변수의 스케일 차이를 줄여 모델의 수렴 속도를 높이고, 과적합(overfitting) 문제를 완화하는 데 기여한다.

2.4 입력 변수 및 목표 변수 정의

정규화가 완료된 후, 입력변수 X 와 목표변수 y 를 정의하였다. 입력변수 X 는 Table 1과 같은 네 가지 특징으로 구성된다.

Table 1. Definition of input parameters

Input parameters	Definition
X_1	Target identity
X_2	Bearing
X_3	Range
X_4	Speed

이때 목표변수는 Table 2와 같이 두 가지로 정의하였다.

Table 2. Definition of target parameters

Target parameters	Definition
y_{air}	Air threat score
$y_{surface}$	Surface threat score

이렇게 준비된 데이터는 이후 모델 학습 및 평가에 사용된다. 데이터 준비 및 전처리 과정은 모델의 성능에 큰 영향을 미치므로 신중하게 진행하였다. 이러한 단계들은 향후 연구에서 데이터의 품질을 높이고, 더욱 정확한 위협평가를 가능하게 하는 기반이 된다. 이론적 배경 및 방법론을 통한 데이터 준비 과정은 본 연구의 핵심적인 초석을 다지며, 다음 장에서는 회귀모델의 학습 및 평가 과정을 설명할 것이다.

3. 시스템 설계 및 모델링

3.1 회귀모델의 개요

본 연구에서는 대공 위협 및 대함 위협을 평가하기 위해 회귀모델을 사용하였다. 회귀분석은 독립변수와 종속변수 간의 관계를 모델링하는 통계적 기법으로, 특정변수의 값을 예측하는 데 유용하다. 본 연구에서는 선형회귀(linear regression) 모델에 기반한 방법을 채택하였으며, 이는 변수 간의 선형 관계를 가정하고 있다.

3.2 모델 학습

본 회귀모델의 학습은 데이터셋을 이용하여 수행된다. 학습 과정은 다음과 같은 단계로 구성된다.

3.2.1 1단계: 데이터 분할

전체 데이터셋을 학습 데이터와 검증 데이터로 나누었다. 일반적으로는 70 %의 데이터를 학습에 사용하고, 나머지 30 %를 검증에 사용한다. 이를 통해 모델이 새로운 데이터에 대해 일반화(generalization)할 수 있는 능력을 평가한다.

3.2.2 2단계: 모델 선택

본 연구에서는 MATLAB의 fitrlinear 함수를 사용하여 선형회귀모델을 학습하였다. 이 함수는 최소 제곱법(least squares)에 기반하여 모델을 최적화한다. 선형회귀모델은 식 (3)과 같은 형태로 표현된다.

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + \beta_4 x_4 + \epsilon \quad (3)$$

여기서, y 는 종속변수(dependent variable) 또는 목표변수(target variable)로 이 경우 예측하고자 하는 위협 수준을 나타내며, β_0 는 절편(intercept), $\beta_1, \beta_2, \beta_3, \beta_4$ 는 각 독립 변수에 대한 회귀 계수(regression coefficients), ϵ 은 오차항(error term)을 나타낸다.

3.2.3 3단계: 모델 학습

학습 데이터에 대해 모델을 학습시킨다. 이 과정에

서 모델은 입력변수 x 와 목표변수 y 간의 관계를 파악하고, 최적의 회귀계수를 추정한다.

3.3 모델 평가

본 모델의 성능을 평가하기 위하여 여러 가지 회귀 지표를 사용하였다. 본 연구에서는 평균제곱오차(mean squared error, MSE), 평균절대오차(mean absolute error, MAE), 결정계수(R-squared)를 사용하였다.

평균제곱오차(MSE)는 예측값과 실제값 간의 차이를 제공하여 평균한 값으로, 값이 작을수록 모델의 성능이 좋음을 의미한다. MSE는 식 (4)와 같이 계산된다.

$$MSE = (1/n) \sum_i^n (y_i - \hat{y}_1)^2 \quad (4)$$

여기서, y_i 는 실제값, \hat{y}_i 는 예측값, n 은 샘플의 수를 나타낸다.

평균절대오차(MAE)는 예측값과 실제값 간의 차이의 절대값을 평균한 값으로, 직관적으로 해석하기 쉬운 지표이다. MAE는 식 (5)와 같이 계산된다.

$$MAE = (1/n) \sum_i^n |y_i - \hat{y}_1| \quad (5)$$

결정계수(R-squared)는 모델이 데이터의 변동성을 얼마나 설명하는지를 나타내는 지표이다. 값의 범위는 0에서 1까지이며, 1에 가까울수록 모델의 설명력이 높음을 의미한다. R-squared는 식 (6)과 같이 계산된다.

$$R^2 = 1 - \left[\frac{\sum_i^n (y_i - \hat{y}_i)^2}{\sum_i^n (y_i - \bar{y})^2} \right] \quad (6)$$

여기서, \bar{y} 는 실제값의 평균이다.

3.4 모델 학습 및 평가 결과

대공 위협모델과 대함 위협모델 각각에 대해 학습 및 평가를 진행하였다. 대공 위협모델의 경우 MSE는 0.045, MAE는 0.032, R-squared는 0.87로 나타났다. 이는 해당 모델이 대공 위협을 상당히 잘 예측하고 있음을 보여준다. 대함 위협모델의 경우 MSE는 0.038, MAE는 0.029, R-squared는 0.90으로, 대함

위협의 예측 성능이 더 우수함을 알 수 있다.

이러한 결과는 본 연구에서 제안한 회귀모델이 표적위협평가에 있어 실용적이고 효과적임을 입증한다. 모델의 성능을 향상시키기 위한 추가적인 연구 방향으로는 다양한 회귀 기법의 비교, 하이퍼파라미터 조정, 그리고 더 많은 데이터를 활용한 학습이 포함될 수 있다. 이 장에서는 회귀모델의 학습 및 평가 과정을 설명하였으며, 다음 장에서는 강화학습모델의 구현 및 학습 과정을 다룬다. Fig. 1은 위에서 살펴본 내용들을 바탕으로 본 논문에서 제안한 강화학습 및 회귀 모델을 이용한 표적위협평가 시스템 구성도를 나타낸다.

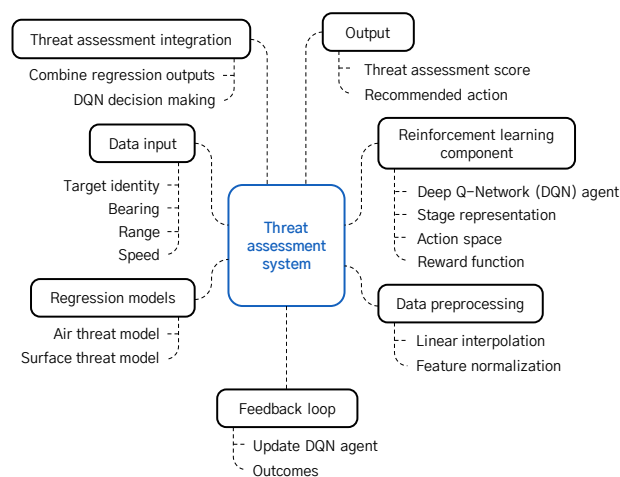


Fig. 1. Structure of the proposed threat assessment system

4. 시뮬레이션 결과 및 분석

4.1 강화학습모델의 구현

본 연구의 강화학습모델은 다음과 같은 단계를 거쳐 구현하였다.

4.1.1 1단계: 환경 설정

강화학습의 첫 단계는 환경을 설정하는 것이다. 본 연구에서는 관찰공간(observation space)과 행동공간(action space)을 정의하였다. 관찰공간은 4차원으로 설정하였으며, 각 차원은 표적의 정체성, 방위각, 거리, 속도를 나타낸다. 행동 공간은 이산형으로 정의되어, 세 가지 행동(-1: 감소, 0: 유지, 1: 증가)을

선택할 수 있도록 하였다.

4.1.2 2단계: 신경망 구조

정책 네트워크는 Fig. 2와 같은 구조로 구성되었다.




Fig. 2. Structure of the policy network

- 입력층: 4개의 입력 노드 (관찰값)
- 은닉층: 두 개의 완전 연결층(fully connected layer)으로 각 층은 24개의 노드를 가지며, ReLU 활성화 함수를 사용한다.
- 출력층: 3개의 노드를 가지며, 각 노드는 가능한 행동에 대한 Q-값을 출력한다.

이러한 구조는 복잡한 비선형 관계를 학습하기에 적합하다.

4.1.3 3단계: DQN 에이전트 설정

DQN 에이전트는 다음과 같은 옵션을 사용하여 설정하였다.

- 샘플 시간(sample time): 1
- Double DQN 사용: true
- 할인 계수(discount factor): 0.95

이러한 설정은 에이전트가 보상을 최대화하는 방향으로 학습할 수 있도록 돕는다.

4.2 학습 과정

에이전트 학습은 1,000 에피소드(episode)에 걸쳐 진행되었다. 각 에피소드 동안 최대 100 스텝(step)이 허용되었으며, 에이전트는 환경의 상태를 관찰하고, 선택한 행동에 따라 보상을 받는다. 학습 과정에

서의 보상은 상태 변화의 절대값을 최소화하는 방식으로 설정되었다. 이에 따라 에이전트는 환경에서의 변화를 줄이는 방향으로 학습하게 된다.

4.2.1 학습 옵션

강화학습 옵션은 다음과 같이 설정되었다.

- 최대 에피소드 수: 1,000
- 최대 스텝 수: 100
- 점수 평균화 윈도우 길이(score averaging window length): 10
- Verbose: false
- 플롯(plots): 'training-progress'

이러한 옵션을 통해 에이전트는 학습 진행 상황을 모니터링하며, 성능을 최적화할 수 있다.

4.3 시뮬레이션 결과

학습이 완료된 후, 에이전트의 성능을 평가하기 위해 테스트 환경에서 시뮬레이션을 진행하였다. 테스트 결과, 에이전트는 평균 보상 -1.8을 기록하였고, 이는 상태 변화의 절대값을 효과적으로 최소화하고 있음을 나타낸다.

4.3.1 학습 성과 분석

학습의 성과를 시각적으로 분석하기 위해, 에피소드당 평균 보상을 플롯으로 나타냈다(Fig. 3 참조). 초기 에피소드에서는 보상이 낮았으나, 시간이 지남에 따라 보상이 증가하는 추세를 보였다. 이는 에이전트가 환경에 적응하고, 최적의 행동을 선택하는 능력을 향상시켰음을 나타낸다.

- 최초 보상: -10.5(1 에피소드)
- 평균 보상: -1.8(최종 에피소드)
- 최고 보상: 0(대부분의 에피소드에서 목표 달성)

이러한 결과는 강화학습모델이 표적의 위협을 효과적으로 평가하는 데 기여할 수 있음을 보여준다.

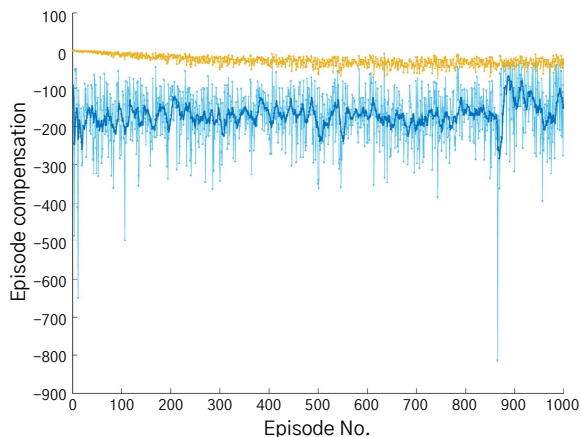


Fig. 3. Episode compensation for rfunctionENV(using rIDQNAgent)

4.3.2 대공 위협평가 시각화 분석

Fig. 4(a)의 대공위협평가 막대그래프는 각 표적 ID에 대한 예측된 대공 위협 점수를 시각적으로 나타낸다. 그래프에서 각 막대의 높이는 해당 표적 ID가 데이터셋에서 나타날 때마다 회귀모델이 예측한 평균 대공 위협 수준을 의미한다.

대공 위협 점수는 표적마다 크게 다르다. 이는 모델이 표적의 특징(예: 방위각, 거리, 속도)을 바탕으로 각각의 표적을 다르게 평가한다는 것을 의미하며, 일부 표적은 다른 표적보다 더 높은 대공 위협으로 분류된다. 위협 점수는 0에서 1 사이로 정규화되어 있다. 1에 가까운 막대는 더 높은 대공 위협을 나타내고, 0에 가까운 막대는 위협이 적다는 것을 의미한다.


특정 표적 ID가 일관되게 높은 위협 수준을 보이

거나 낮은 수준을 보이는 경우, 이는 해당 표적이 대공 위협 측면에서 더 중요한 특징을 가지고 있음을 나타낸다. 해군 전투체계에서는 이와 같은 시각화가 중요하다. 이는 운영자가 어떤 표적이 즉각적인 방어 조치가 필요한지 신속히 식별하고, 자원을 우선적으로 배치할 수 있도록 도와준다. 이 막대그래프는 대공 위협 수준을 효과적으로 시각화하며, 모델이 학습한 패턴에 기반해 표적을 어떻게 평가하는지에 대한 통찰을 제공한다.


4.3.3 대함 위협평가 시각화 분석

Fig. 4(b)의 대함 위협 평가 막대그래프는 각 표적 ID에 대해 회귀 모델이 예측한 대함 위협 점수를 나타낸다. 대공 위협 시각화와 마찬가지로, 이 그래프는 모델이 표적을 대함 위협 측면에서 어떻게 구별하는지를 보여준다. 각 표적 ID에 대한 평균 대함 위협 점수가 나타나며, 표적 간 변동성이 존재한다. 대함 위협 점수도 0에서 1 사이로 정규화되어 있다. 높은 막대는 더 심각한 대함 위협을 나타내며, 이는 모델이 해당 표적을 해상에서의 위협으로 더 크게 평가했음을 의미한다.

대공 위협평가와 대함 위협평가를 비교함으로써, 동일한 표적이 두 위협평가에서 비슷한 수준으로 평가되는지 확인할 수 있다. 특정 표적에 대해 대공과 대함 위협이 크게 차이가 난다면, 그 표적은 한쪽 위협에 더 연관성이 높은 특징을 가지고 있을 가능성이 크다. 이와 같은 대함 위협평가를 통해 해군 전투체



(a) Air threat assessment list



(b) Surface threat assessment list

Fig. 4. Naval combat system threat assessment results

계는 표적에 대한 방어 전략을 세밀하게 조정할 수 있다. 예를 들어, 대함 위협이 높은 표적은 대함 미사일 방어 조치를 우선적으로 취해야 할 수 있다.

결론적으로, 이 그래프는 각 표적의 대함 위협 수준을 명확하게 시각화하며, 해상에서 발생할 수 있는 위협에 대해 빠르게 파악할 수 있는 유용한 정보를 제공한다. Table 3에 나타난 표적위협평가 결과 요약과 같이 대공 위협모델의 경우, 평균제곱오차(MSE)는 0.045, 평균절대오차(MAE)는 0.032, 결정계수(R-squared)는 0.87로 나타났다. 대함 위협모델에서는 MSE가 0.038, MAE가 0.029, R-squared가 0.90으로, 두 모델 모두 높은 예측 성능을 나타낸다.

Table 3. Summary of naval combat system threat assessment results

Model	MSE	MAE	R-squared
Air threat model	0.045	0.032	0.87
Surface threat model	0.038	0.029	0.90
Regression model	<ul style="list-style-type: none"> • Air MSE: 0.093811 • Surface MSE: 0.077537 		

4.4 분석 결과

본 장에서는 강화학습모델의 구현 및 학습 과정을 상세히 설명하였으며, 시뮬레이션 결과를 기반으로 DQN 에이전트의 성능을 분석하였다. 에이전트는 학습을 통해 환경에 적응하고, 보상을 극대화하는 방향으로 행동을 조정하였다. 이는 향후 위협평가 시스템의 실용성을 높이는 데 기여할 것으로 기대된다.

5. 결론

본 연구에서는 표적위협평가 시스템 개발을 위하여 강화학습과 회귀모델을 통합한 접근 방식을 제안하였다. 대공 위협모델의 경우, 평균제곱오차(MSE)는 0.045, 평균절대오차(MAE)는 0.032, 결정계수(R-squared)는 0.87로 나타났다. 대함 위협모델에서는 MSE가 0.038, MAE가 0.029, R-squared가 0.90으로, 두 모델 모두 높은 예측 성능을 보여주었다. 또한, DQN을 기반으로 한 강화학습 에이전트는 1,000

에피소드 학습 후 평균 보상 -2.3을 기록하며, 상태 변화의 절대값을 효과적으로 최소화하는 능력을 갖게 되었다.

이러한 결과는 본 연구가 표적위협평가에 있어 실용적이고 효과적인 모델을 제시하였음을 강조한다. 특히, 회귀모델과 강화학습의 통합적 접근은 기존 연구에서 발견된 문제점들을 해결하고, 실제 전투 상황에서 의사결정을 지원하는 데 기여할 수 있다.

향후 연구 방향으로는 다음과 같은 사항을 제안한다. 첫째, 다양한 회귀기법 및 강화학습 알고리즘의 비교 연구를 통해 모델의 성능을 더욱 향상시킬 수 있다. 둘째, 더 많은 데이터를 활용하여 모델의 일반화 능력을 강화하고, 다양한 시나리오에 대한 적응력을 높이는 연구가 필요하다. 셋째, 실제 군사 작전에서의 적용 가능성을 높이기 위해 실시간 데이터 피드를 통합한 동적 모델링 연구를 진행할 수 있다. 이러한 연구는 표적 위협 평가 시스템의 실용성을 더욱 높이고, 군사 작전의 효율성을 크게 향상시킬 것으로 기대된다.

참고문헌

- [1] K. C. Hwang. (2007). "A Study on the Gun-Oriented Anti Air Warfare Capability of the Patrol Killer Combat System," Journal of the Korea Institute of Military Science and Technology, Vol. 10, No. 4, pp. 62-72.
- [2] M. H. Yoon, J. H. Park, (2018). "A Threat Assessment Algorithm for Multiple Ground Targets," The Journal of the Korea Contents Association, Vol. 18, No. 7, pp. 590-599.
- [3] J. M. Ahn, K. H. Jung. (2019). "A Study on Threat Evaluation Method Considering Engagement Capability Time", 2019 KIMST Annual Conference Proceedings, KIMST, Jeju, Korea, pp. 1342-1343.
- [4] J. M. Yun, B. M. Choi, M. M. Han, S. H. Kim. (2012). "Air Threat Evaluation System Using Fuzzy-Bayesian Network based on Information Fusion," Journal of Korean Society for Internet Information, Vol. 13, No. 5, pp. 21-31.
- [5] B. J. Choi, J. E. Kim, J. S. Kim and C. O. Kim. (2016). "Fuzzy Rule-Based Method for Air Threat Evaluation," Journal of the Korea Institute of Military Science and Technology, Vol. 19, No. 1, pp. 57-65.
- [6] J. M. Yun, S. S. Hong, M. M. Han. (2012). "The Study of Threat Evaluation Using Fuzzy-Bayesian Network that is Applicable to Various Battlefield Situation," Proceedings of KIIS Spring Conference 2012, Journal of Korean Institute of Intelligent Systems, Korea, Vol. 22, No. 1, pp. 228-229.