

불확실 지상 표적의 인공지능 기반 위협도 평가 연구

진승현
국방기술진흥연구소

Artificial Intelligence based Threat Assessment Study of Uncertain Ground Targets

Seung-Hyeon Jin
Korea Research Institute for Defense Technology Planning and Advancement

요 약 미래전의 양상은 네트워크 중심전으로 전체계의 연결을 통한 전장상황 정보획득 및 공유가 주를 이룰 것이다. 따라서 전장에서 생성되는 정보의 양은 많아지지만, 정보를 평가하여 전장을 효율적으로 지휘하는 기술은 부족한 것이 현실이다. 이를 극복하기 위해 대두되는 기술이 전장 위협평가이다. 전장 위협평가는 획득된 정보를 사용하여 지휘관의 신속 결정을 지원하는 기술이지만 획득된 정보에는 표적의 불확실성이 많고 점차 지능화되는 전장상황에 적용하기에 현재 기술수준이 낮은 부분이 있다. 본 논문에서는 표적의 불확실성을 제거하고 고도화되는 전장상황에서도 적용 가능한 인공지능 기반의 전장 위협평가 기법에 대해 제안한다. 사용된 인공지능 시스템으로는 퍼지 추론 시스템과 다층 퍼셉트론을 사용하였다. 퍼지 추론 시스템에 표적의 고유특성을 입력시켜 표적을 분류해내었고 분류된 표적정보를 다른 표적 변수들과 함께 다층 퍼셉트론에 입력하여 해당 표적에 맞는 위협도 값을 산출하였다. 그 결과, 시뮬레이션을 통해 두 가지 시나리오상에서 무작위로 설정된 불확실 표적들을 인공지능경망에 훈련시켰고, 훈련된 인공지능경망에 시험용 표적을 입력하여 산출되는 위협도 값으로 제안한 기술의 타당성을 검증하였다.

Abstract The upcoming warfare will be network-centric warfare with the acquiring and sharing of information on the battlefield through the connection of the entire weapon system. Therefore, the amount of information generated increases, but the technology of evaluating the information is insufficient. Threat assessment is a technology that supports a quick decision, but the information has many uncertainties and is difficult to apply to an advanced battlefield. This paper proposes a threat assessment based on artificial intelligence while removing the target uncertainty. The artificial intelligence system used was a fuzzy inference system and a multi-layer perceptron. The target was classified by inputting the unique characteristics of the target into the fuzzy inference system, and the classified target information was input into the multi-layer perceptron to calculate the appropriate threat value. The validity of the proposed technique was verified with the threat value calculated by inputting the uncertain target to the trained artificial neural network.

Keywords : Artificial Intelligence, Fuzzy Logic, Multi Layer Perceptron, Threat Assessment, Ground Targets

*Corresponding Author : Seung-Hyeon Jin(KRIT)

email: jinsh@dtaq.re.kr

Received April 28, 2021

Accepted June 4, 2021

Revised May 17, 2021

Published June 30, 2021

1. 서론

과학 및 정보기술의 발전으로 인해 첨단 무기체계가 등장하였고, 작전수행 측면에도 많은 변화가 일어났다. 네트워크 중심전(network centric warfare)은 물리적으로 떨어진 체계들을 네트워크로 연결함으로써 실시간 정보공유가 가능한 환경을 구축하는 것으로 미래전의 핵심이다. 정보우위를 통한 신속 명령수행과 지휘 결심의 완전성 보장은 결과적으로 전투력 우위 달성과 전장 주도권 장악을 가능하게 한다[1].

Fig. 1은 미래전 양상에 맞춰 효과적인 운용을 위해 자동화된 무기체계를 나타낸다[2]. 예를 들어, 전방 관측반(foward observer)이 획득한 표적정보를 자동으로 전송하고 지휘통제부는 타격 수단을 정하여 사격제원을 송신한다. 타격체계는 수신된 정보로 자동사격 준비를 마치고 표적에 신속히 발사한다[3].




Fig. 1. Tactical fire command procedure

네트워크 중심전의 핵심기술은 전장 위협평가(threat assessment)이다. 전장 위협평가는 표적정보, 아군환경 등을 고려하여 표적이 아군에 미치는 위협을 수치화하는 기술이다. 전장 위협평가를 통해 아군의 자원관리가 용이해지며 다양한 불특정 위협들에 대해 지휘관의 결심 속도를 높여 다수의 표적에 대한 신속한 작전 수행이 가능하다.

전장 위협평가 방법에는 수학적, 인공지능 접근방식이 존재한다. 수학적 방식은 간단한 수학적식으로 이루어진 알고리즘으로 위협도가 산출된다[4,5]. 반면에 인공지능 방식은 퍼지(Fuzzy), 베이지안(Bayesian)과 같은 기법으로 연구가 되었다[6,7].

전장 위협평가는 전장 상황의 어느 단계보다 확실한 정보가 요구되지만, 기존 연구들은 표적의 불확실성을 고려하지 않은 채 위협평가를 진행하였다. 표적획득 지능화 연구[8]는 CCD와 적외선 데이터 융합 및 특징점

(feature point) 추출과 같은 신호처리 과정이 필요하였다. Fig. 2는 원거리 표적정보 획득을 위해 광학(electro optical) 및 열상(infra-red)장비에 최대 배율을 적용한 모형이다. 원거리에서는 탐지장비의 해상도(resolution)가 저하되어 표적 분류에 어려움이 따른다. 결과적으로 다중대역 영상을 사용하더라도 정보에 불확실성이 존재하게 되는 것이다.




Fig. 2. The target image(left) and uncertain target image(right) modeling[9]

또한, 단순 계산방식의 위협평가는 고도화, 지능화되는 전장 환경에 적용 시 제한점이 있다. 따라서 인간의 지능적 행위가 반영된 데이터로 인공신경망을 학습시켜 다양한 전장 환경에도 유연하게 사용할 수 있는 인공지능 기법이 필요하다.

본 연구에서는 상기된 두 가지의 제한점을 해결하기 위해서 퍼지와 다층 퍼셉트론(MLP: Multi-Layer Perceptron) 기법이 결합된 새로운 방법을 제시한다. 제안기법은 이전 연구에서 대두되었던 표적의 불확실성을 제거하기 위해, 퍼지 추론으로 표적을 분류하여 표적의 모호함을 처리한다. 그 결과, 이전 연구의 복잡한 영상 처리 과정을 거치지 않고 표적의 속도, 크기, 포구 각도와 같은 고유특성만으로 표적의 분류를 진행하는 차이점을 보였다. 또한, 위협도 평가를 위해 다층 퍼셉트론이라는 새로운 인공지능 방법을 적용하였다. 이는 퍼지 추론으로 분류된 표적 분류결과와 표적정보를 인공신경망에 입력하여 표적에 대한 위협도를 산출해냈다.

2. 본론

2.1 지상표적 설정

지상전 환경에서는 센서(sensor)로 탐지해낼 수 있는 다양한 표적들이 존재한다. 대표적으로는 전차(tank), 장갑차(armoured car), 자주포(self-propelled artillery),

보병(infantry)이 있으며 인간은 각각의 표적들을 서로 다른 특징으로 구분하게 된다.

전차의 목적은 적 기갑세력과 직접적인 전투이다. 선봉에서 적의 전차와 맞붙고 방어선을 돌파해 후방의 장갑차와 자주포의 길을 열어준다. 상대방 전차와 직접적으로 맞붙는 만큼 포탄을 막기 위한 두꺼운 장갑으로 구성되며 이로 인해 중량이 무겁다.

장갑차는 차체에 장갑을 덧씌운 전투차량을 말하며 임무에 따라 다양한 종류가 존재한다. 그중 보병용 전투차량은 보병의 기동성과 생존성을 증대시킨다. 장갑차는 빠른 기동성을 위해 주로 소구경의 무장을 탑재해 파괴력은 상대적으로 떨어진다.

자주포는 후방에서 포사격을 통해 아군을 지원하는 임무를 수행한다. 전차와 구별이 힘들 수도 있으나 자주포는 전차보다 훨씬 긴 유효사거리를 가지며 적 부대와 직접적인 전투보다는 전차의 앞에 위치하는 적의 거점이나 방해물을 공격하는 곡사포이므로 두꺼운 장갑이 부착되지 않는다.

보병은 기갑차량들에 비해 크기가 훨씬 작으며 속도도 느리고 소구경 무기들을 휴대하기 때문에 파괴력이 떨어진다.

상기된 듯이 각각의 표적이 다른 특성을 가지기 때문에 지상 표적을 정확히 분류해내는 것은 중요하다. Table 1은 본 연구에서 고려한 표적의 형태와 제원을 개략적으로 나타내었다.

Table 1. Target specification

Type	Tank	Armoured Car	Self-propelled Artillery
Form			
Size (L×W×H)	10 m × 4 m × 2 m	7 m × 3 m × 3 m	15 m × 8 m × 3 m
Weight	40 t~	15 t	30 t
Speed	60 km/h	70 km/h	50 km/h
Weapon	125 mm Cannon	14.5 mm Machine gun	170 mm Howitzer
Range	2~3 km	~1.5 km	30 km~
Armor	Composite, *ERA	**RHA	None

* ERA : 반응장갑(Explosive Reactive Armour)

** RHA : 균질압연장갑(Rolled Homogeneous Armour)

2.2 인공지능 기반 표적 분류 및 위협도 산출

위협도 산출을 위해 표적을 신속하고 정확히 분류해내는 과정은 중요하다. 신속한 분류로 표적의 종류를 정확하고 선제적으로 알아내 대응함으로써 적보다 빠른 전략 수립이 가능하며 이는 전투의 승패로 직결되기 때문이다.

하지만 적의 정보를 모르는 불확실한 전장 환경에서 센서로 관측한 데이터로만 표적을 분류해내는 것은 어려움이 있다. 그 이유는 크게 세 가지가 있으며, 첫 번째는 센서의 하드웨어적 성능 한계로 인해 원거리에서 물체는 해상도가 떨어져 불분명하게 보인다. 두 번째는 해상도 문제 해결을 위한 센서의 성능증가는 중량이나 크기 등 부수적인 제한이 발생하기 때문이다. 세 번째는 Fig. 3에서 볼 수 있듯이 물체를 관측할 때 관측 각도에 따라 물체 형상이 변하여 표적의 불확실성이 증대되기 때문이다.

따라서 원거리에서 탐지 장비의 성능증가 없이 표적의 분류를 위해서는 기존 장비로도 탐지가 가능한 고유특성인 속도, 길이, 포구 각도 등을 사용한다. 그런데도 관측 각도에 따른 불확실성은 여전히 존재하는데 이 문제를 해결하기 위해 본 연구에서는 퍼지 이론을 사용한다. 퍼지 이론은 불확실한 상태를 표현하는 방법으로 기존의 이분법적인 논리에서 벗어나 경계가 명확하지 않은 것을 표현할 수 있다.




Fig. 3. Tank image according to rotation angle[10]

2.2.1 퍼지 소속함수 설정

퍼지 소속함수는 물체의 고유특성인 속도, 길이, 포구 각도로 이루어진다. 각 변수값은 소속함수마다 일정 소속도(degree of membership)로 나타낼 수 있으며 0과 1 사이의 값을 가진다. Fig. 4는 표적 속도에 따른 소속함수를 나타낸다. 예를 들어, 속도가 65km/h인 경우에는 해당 물체가 보통 속도에 속할 소속도는 0.75이고 빠른 속도에 속할 소속도는 0.25가 된다. 즉, “해당 물체는 75%로 보통 속도이고 25%로 빠른 속도일 수도 있다”로 표현된다.




Fig. 4. Fuzzy set of target speed

2.2.2 퍼지 규칙 설정

퍼지 규칙은 입력변수와 출력변수로 연관된 조건문의 집합을 의미한다. 본 논문에서 고려하고 있는 고유특성마다 3개의 퍼지 집합이 존재하므로(ex. 고유변수(길이)→퍼지집합(짧음, 중간, 김)) 총 퍼지규칙은 27개가 된다. Table 2는 포구 각도가 보통이라는 가정하에 속도와 크기에 대해 정의된 표적의 퍼지 규칙을 나타낸다.

Table 2를 통해 크기가 작고 속도가 느린 표적은 보병, 크기가 크고 속도가 빠른 표적은 전차로 규칙이 설정됨을 확인할 수 있다.

Table 2. Fuzzy rule (Cannon angle : medium)

Size \ Speed	Short	Medium	Long
Slow	Infantry	Self-profelled Artillery	Self-profelled Artillery
Moderate	Armoured car	Tank	Tank
Fast	Armoured car	Armoured car	Tank

2.2.3 퍼지 추론 결과 및 분류 현황

퍼지 추론에서는 앞서 설정한 퍼지 규칙을 평가하여 나오는 소속도 값을 후건의 소속 함수에 적용시키는 과정이다. 각각의 규칙에서 나온 결과를 통합하여 역퍼지화(defuzzification)하면 정량적인 결과값을 도출해낼 수 있다.

규칙을 평가하는 방식에는 맘다니(Mamdani)형 추론과 스게노형 추론이 존재하며 본 논문에서는 결과값을 직관할 수 있는 맘다니형 추론법을 따랐다. 역퍼지화 과정에서는 무게중심법을 사용하여 결과값을 계산하였다. Fig. 5, 6은 퍼지 추론 결과와 지상 표적 분류 예시를 나타낸다. 특히 Fig. 6은 3개의 불확실 지상 표적에 대해 속도, 길이, 포구 각도를 토대로 퍼지 추론 결과를 나타내었다. 그 결과 Table 1에서 고려한 표적의 제원과 유사

하게 불확실 표적이 분류됨을 확인했다.




Fig. 5. Fuzzy inference result

	Target #1	Target #2	Target #3
Speed	79.22km/h	65.55km/h	48.98km/h
Length	5.54m	13.47m	15.42m
Angle	7.04°	23.39°	70.25°




Fig. 6. Target inference status

2.2.4 다층 퍼셉트론 구현

퍼지를 이용하여 불확실한 표적이 어느 개체에 속하는지 분류할 수 있었지만, 이것만으로 위협도를 평가했다고 볼 수 없다. 전장 상황에서는 표적 종류 외에도 고려할 다양한 위협변수들이 있기 때문이다.

따라서 위협도 산출은 다층 퍼셉트론을 이용한 인공신경망(ANN: Artificial Neural Network)으로 구한다[11]. 인공신경망은 인간의 지능적 행위가 반영된 데이터로 학습이 되기 때문에 다양한 시나리오에도 인간의 사고방식과 유사하게 위협도 값이 구해진다. 하지만 이를 위해서는 인공신경망을 훈련하는 과정이 필요하며 훈련을 위해서는 잘 정제된 훈련데이터가 필요하다.

아래에 명시된 과정을 따라 인공신경망을 구축한다. 우선 인공신경망에 입력할 정보를 설정해야 하며 그 외에 층의 개수, 각 층 내부의 퍼셉트론 개수, 학습율(learning rate), 활성화함수(activation function) 종류를 결정해야 한다.

2.2.5 다층 퍼셉트론 입력 데이터 정보

Table 3은 본 논문에서 고려하고 있는 다층 퍼셉트론 입력 데이터를 나타낸다. 입력 데이터로는 퍼지 추론 결과인 '불확실 표적의 종류', 또한 관측장비로부터 얻어지는 '표적 근접도(CPA: Closest Point of Approach)', 표적이 바라보는 방향인 '표적 지향'과 작전 측면의 변수로 고려될 '아군 관심지역 내 존재 유무', 현재 수행되는 전쟁 '시나리오'가 된다.

Table 3. Input data of the MLP

Input	Value Range	Remark
Type	1, 2, 3, 4	1 : Infantry 2 : Armoured car 3 : Tank 4 : Self-propelled artillery
CPA	0~1	0(Far) ~ 1(Near)
Orientation	0~1	0 ~ 1(Aggressive Orientation)
Existence	0, 1	0(None), 1(Exist)
Scenario	1, 2	1 : Maneuver warfare 2 : Counter firepower

2.2.6 다층 퍼셉트론 설계

본 논문에서 설계한 인공지능망은 입력층, 은닉층, 출력층의 구조를 가지며 이 중 은닉층은 총 두 개의 층으로 이루어져 있다. 그리고 인공지능망 훈련 시 오차의 수정 계수를 나타내는 학습율과 각 퍼셉트론의 활성화함수를 설정해야 한다. Table 4에 설계된 다층 퍼셉트론의 항목별 수치를 명시하였다.

Table 4. Multi layer perceptron information

Item	Number	Remark
Perceptron	Input	5
	1st Layer	80
	2nd Layer	40
	Output	1
Learning rate	0.05	-
Activation Function	Parametric ReLU[12]	$f(x)=x \ (x \geq 0)$ $f(x)=ax \ (x < 0)$ $a=0.01$

2.2.7 다층 퍼셉트론 훈련 및 위협도 산출

인공지능망이 구성되었다면 훈련하는 과정이 필요하다. 인간의 사고와 비슷한 인공지능망을 구성하기 위해서

는 많은 훈련데이터로 최대한 다양한 상황을 학습시켜야 한다.

Fig. 7은 훈련의 과정과 위협도 산출 과정을 나타낸다. 훈련의 목적은 훈련데이터의 인공지능망 출력값과 훈련데이터마다 사용자가 설정한 라벨값 사이의 오차 최소화이다. 따라서 오차가 줄어드는 방향으로 퍼셉트론의 노드(node)와 가중치(weight) 값을 계속 갱신한다. 훈련의 대표적인 기법으로 역전파(backpropagation)가 있으며 본 연구에서도 역전파를 통한 훈련을 시행한다.

훈련이 완료된 다층 퍼셉트론 구조가 만들어졌다면 시험 데이터를 입력해 위협도 값을 산출한다. 시험 데이터는 무작위 표적정보로 설정하지만, 훈련의 과정이 아니기 때문에 데이터마다 사용자가 라벨값을 책정할 필요는 없다.




Fig. 7. MLP Structure

2.3 전체 구조 요약

본 연구에서 위협도 산출을 위해 설계한 구조를 앞단부터 최종단까지 살펴보면 Fig. 8과 같다. 요약하면 사용자는 관측장비로부터 수신한 3가지의 표적정보(표적 속도, 표적 크기, 포구 각도)를 퍼지 추론 시스템에 입력하여 불확실한 표적에 대해 표적 종류를 분류한다. 그다음 분류된 표적 종류와 근접도, 지향, 지역 존재 유무, 시나리오 변수를 훈련된 다층 퍼셉트론에 입력하여 최종적으로 관측장비에서 탐지된 물체의 위협도를 산출한다. 이를 통해 국방기술의 질적 향상을 기대할 수 있고 향후 다기능 관측경 등 무기체계에 적용하였을 때 빠른 전장위협 평가로 아군의 획기적인 전력 증가가 가능할 것으로 판단된다.




Fig. 8. Research summary diagram

3. 시뮬레이션 결과 및 분석

3.1 전투 시나리오 설정

기본적으로 표적의 위협도는 아군 부대와와의 근접도가 높고 포구가 아군을 지향하고 있으며, 아군의 관심 작전 지역 내에 있는 부대일수록 높으리라 판단한다. 하지만, 표적의 종류에 따른 위협도는 전투 시나리오별로 달라질 수 있다.

Table 5. Treat according to target type in scenario

Scenario \ Treat	Maneuver warfare	Counter firepower
Very High	Tank	Self-profelled artillery
High	Armoured car	Tank
Medium	Infantry	Armoured car
Low	Self-profelled artillery	Infantry




Fig. 9. Maneuver warfare scenario

따라서 시뮬레이션에 앞서 본 연구에서는 2가지의 시나리오(신속기동전, 대화력전)를 가정하고 시나리오별 표적 위협도를 설정하였다(Table 5). 예시로 '신속기동전 (maneuver warfare)'이 펼쳐진 상황에서 아군과 적군의 전차가 서로를 향해 기동하고 있을 때, 아군에게 위협이 되는 표적은 직사화기를 가진 적군의 전차이며 곡사화기인 자주포는 상대적으로 위협도가 낮다(Fig. 9).

3.2 시뮬레이션 환경

시뮬레이션을 위한 운영환경으로 Intel i5 7세대 2.5GHz의 CPU와 8GB의 메모리를 사용하였다. 운영체제는 Windows 10 기반이며, 시뮬레이션 툴은 MATHWORKS社의 'MATLAB 2020a'버전을 이용하여 훈련 및 시험 데이터 생성하고 퍼지 추론 시스템 설계, 다층 퍼셉트론을 구현하였다. 또한, 인공지능망 훈련을 위해 별도의 서버나 단말은 구축하지 않았다.

3.3 훈련 및 시험 데이터 생성

지상 표적의 실제 영상을 획득하는 것은 제한되므로 본 연구에서는 임의의 표적을 가정하고 표적에 대한 무작위 정보를 컴퓨터로 생성한다. 이때, 표적 데이터에는 총 7개의 변수(표적 속도, 길이, 포구 각도, CPA, 표적 지향, 존재유무, 시나리오)가 무작위로 생성되며 사용자는 생성된 데이터를 보고 위협도(라벨값)를 책정한다. 이를 통해, 총 250개의 훈련 데이터(표적정보 및 라벨)를 만들었다.

시험 데이터로는 총 10개의 표적 데이터를 생성하였으며, 훈련데이터와의 차이는 라벨값을 따로 설정하지 않았고 시험 데이터로만 퍼지 및 다층 퍼셉트론 결합구조가 위협도를 산출해내는 과정을 볼 것이다.

3.4 시뮬레이션

시뮬레이션의 절차는 생성된 훈련데이터를 퍼지 시스템에 입력하여 표적 종류를 분류해낸다. 그다음 획득한 표적 종류와 표적정보를 다층 퍼셉트론 구조에 입력하여 출력값을 얻는다. 출력값과 데이터 라벨값 사이엔 오차가 존재하므로 오차를 줄이는 훈련을 실시하고, 훈련이 완료되면 라벨값이 없는 시험 데이터를 입력하여 출력값으로 위협도를 획득한다.

3.4.1 인공지능망 훈련 결과

250개의 훈련데이터를 10000번 훈련 시, 훈련에 걸

린 시간은 약 763초, 비용함수(cost function)인 평균 제곱 오차(MSE: Mean Squared Error)는 약 0.006으로 산출되었다.

Fig. 10에서는 마지막 훈련에 사용된 훈련데이터 10개의 인공지능망 출력값(파란색)과 훈련 전에 사용자가 사전에 설정한 라벨값(빨간색)을 비교하였다. 작은 오차는 존재하지만, 출력값이 라벨값의 추세를 따라가는 것으로 추론해보면 인공지능망의 훈련이 제대로 이루어졌다고 판단된다.

Fig. 11은 앞선 Fig. 10의 출력값과 라벨값의 차이로 위협도의 최대 오차는 0.14, 최소 오차는 0으로 나왔다.




Fig. 10. Compare of output value and label value




Fig. 11. Error of output value and label value

Table 6. Treat assessment result

Test Target	1	2	3	4	5	6	7	8	9	10
Type	3	3	3	3	2	4	4	4	3	2
CPA	0.5	0.9	0.5	0.5	0.5	0.5	0.5	0.5	0.5	0.5
Orientation	0.5	0.5	0.9	0.5	0.5	0.5	0.5	0.5	0.5	0.5
Existence	0	0	0	1	1	1	0	1	1	1
Scenario	1	1	1	1	1	1	2	2	2	2
Treat	0.51	0.82	0.67	0.62	0.57	0.50	0.38	0.53	0.47	0.38

인공신경망의 학습 정도를 판별하는 기준인 MSE는 출력값과 라벨값 차이의 제곱을 평균한 값이다. MSE가 낮을수록 인공신경망 훈련이 잘되어있음을 나타내며 시뮬레이션 결과 0.006이라는 수치가 나왔다. 이 값은 사용자가 표적의 위협도를 판단할 때도 구분이 어려울 정도의 수치로 인공신경망이 큰 오차 없이 사용자의 의도대로 학습되었음을 나타낸다.

Fig. 12에 표현되었듯이 훈련 초기에는 MSE가 큰 값을 보이나 훈련이 거듭될수록 MSE가 낮아짐을 볼 수 있다. 훈련 횟수가 10000번째가 될 때는 MSE 값도 수렴하는 추세를 보이며 인공신경망 훈련이 완료됨을 볼 수 있다.




Fig. 12. MSE within training session

3.4.2 시험 데이터 출력 결과

Table 6에서는 총 10개의 시험 데이터를 인공신경망에 입력한 결과를 나타낸다. 1번부터 10번 표적은 시험 데이터에 설정된 임의의 표적들이며 근접도가 높을수록 (표적 1, 2번), 아군 쪽으로 포구를 지향할수록(표적 1, 3번), 아군의 관심 지역 내에 있는 적 표적(표적 1, 4번)일수록 위협도가 높게 산출된다. 따라서, 총 3가지의 규칙으로 인공신경망이 훈련되었음을 알 수 있다.

- 1) 적 표적과 아군과의 근접도(CPA)가 높을수록 위협도가 높다.
- 2) 적 표적이 아군 방향으로 포구를 지향(orientation)하고 있을수록 위협도가 높다.
- 3) 아군의 작전 관심 지역 내에 적 표적이 존재(existence)할수록 위협도가 높다.

이외의 변수로는 전쟁 시나리오와 표적 종류가 있다. 표적 종류에 따른 위협도는 시나리오별로 달라지기 때문에 두 변수 사이의 관계는 종속적이다(Table 5). 표적 종류를 제외한 나머지 표적정보가 일치할 때 전장 시나리오가 신속기동전으로 설정되어 있다면 전차, 장갑차, 자주포 순으로 위협도가 설정되어 있음을 볼 수 있다(표적 4~6번).

반대로, 대화력전 시나리오상에서는 자주포, 전차, 장갑차의 순서로 앞서 Table 5에서 정한 시나리오별 표적 위협도 순서가 올바르게 반영되어 있음을 알 수 있다(표적 8~10번).

4. 결론

본 논문에서는 지상전 환경에서 탐지되는 불확실 표적의 위협도를 평가하는 새로운 전장 위협평가 기법을 제시하였다.

앞선 전장 위협평가 결과들은 관측장비의 성능이나 관측 각도라는 한계로 인해 불확실 표적에 대해 적절한 위협도 값을 산출해내지 못하는 문제가 존재했다. 본 논문에서는 퍼지 추론 시스템을 이용하여 표적의 고유특성만으로 불확실 표적의 표적 종류를 분류해내는 새로운 기법을 제시하였다.

퍼지의 결과로 나온 표적 종류는 다른 표적 변수

들과 함께 다층 퍼셉트론에 입력 데이터로 활용되었고 최종적으로 다층 퍼셉트론에서 표적정보에 맞는 위협도를 산출해냈다.

산출된 위협도 값의 타당성을 확인하기 위해 2개의 시나리오에서 표적정보를 가정하고 위협도를 산출했다. 산출되는 위협도 값은 사용자의 사고가 반영되어 나온다는 것을 시뮬레이션 결과를 통해 확인하였다.

결과적으로 본 논문에서 제안한 기법이 올바르게 구현되었고 시뮬레이션을 통해 기술적 타당성도 검증이 되어 점차 고도화되는 미래 전장에서도 다양하게 활용 가능하다고 판단된다.

추후 전장 위협평가 기술을 발전시키기 위해서는 다양한 전장 환경을 반영하기 위한 표적 데이터 생성법이나 소속함수의 종류에 따른 표적 분류 정확도, 인공지능망 구조(층의 개수, 퍼셉트론 개수)를 최적화하는 방안들에 관해 연구가 필요하다.

References

- [1] K. E. Lee, S. S. Choi, "A Study on the Principles of Military Operations Coincident with Modern War", *The Journal of Military Studies*, no.7, pp.129-154, 2009.
- [2] M. H. Ahn, J. K. Ji, H. H. Cho, C. S. Sin, Y. W. Park, T. S. Lee, T. Y. Kim, "Tactical Fire Direction Automation for Command and Control of Artillery Battalion Unit", *The Journal of Korean Institute of Communications and Information Sciences*, Vol.35, No.11, pp.1738-1747, Oct. 2010.
- [3] S. Kim, K. H. Kim, S. Y. Kim, "A Concept Study on Efficient Domestic Development of 120mm Self-propelled Mortar System", *Journal of the Korea Institute of Military Science and Technology(KIMST)*, Vol.12, No.2, pp.133-138, Apr. 2009.
- [4] M. H. Yoon, J. H. Park, "A Threat Assessment Algorithm for Multiple Ground Targets", *The Journal of the Korea Contents Association*, Vol.18, No.7, pp.590-599, Jul. 2018.
DOI : <https://doi.org/10.5392/JKCA.2018.18.07.590>
- [5] J. M. Ahn, K. H. Jung, "A Study on Threat Evaluation Method Considering Engagement Capability Time", *2019 KIMST Annual Conference Proceedings*, KIMST, Jeju. Korea, pp.1342-1343, Jun. 2019.
- [6] J. M. Yun, B. M. Choi, M. M. Han, S. H. Kim, "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, Oct. 2012.
DOI : <https://doi.org/10.7472/jksii.2012.13.5.21>
- [7] J. M. Yun, S. S. Hong, M. M. Han, "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, Apr. 2012.
- [8] H. Y. Lee, J. H. Kim, S. Y. Kim, B. J. Choi, S. H. Moon, K. H. Park, "Design of a SIFT based Target Classification Algorithm robust to Geometric Transformation of Target", *Journal of Korean Institute of Intelligent Systems*, Vol.20, No.1, pp. 116-122, Jan. 2010.
DOI : <https://doi.org/10.5391/KIIS.2010.20.1.116>

- [9] Thermo Analytics, "EO/IR Physics-Based Image Sets", Thermo Analytics, 2021, Available from : <https://thermoanalytics.com/eo-ir-image-sets> (accessed Apr. 19. 2021)
- [10] S. H. Kim, W. J. Song, S. H. Kim, "Double Weight-Based SAR and Infrared Sensor Fusion for Automatic Ground Target Recognition with Deep Learning", *Remote Sensing*, Vol. 10, No. 1, Jan. 2018. DOI : <https://doi.org/10.3390/rs10010072>
- [11] N. H. Jeong, S. H. Lee, M. S. Kang, C. W. Gu, C. H. Kim, K. T. Kim, "Target Prioritization for Multi-Function Radar Using Artificial Neural Network Based on Steepest Descent Method", *The Journal of Korean Institute of Electromagnetic Engineering and Science(IIEES)*, Vol.29, No.1, pp.68-76, Jan. 2018. DOI : <https://doi.org/10.5515/KJKIEES.2018.29.1.68>
- [12] He, Kaiming, et al. "Delving deep into rectifiers: Surpassing human-level performance on imagenet classification.", *Proceedings of the IEEE international conference on computer vision*, pp. 1026-1034, Feb. 2015. DOI : <https://doi.org/10.1109/ICCV.2015.123>

진 승 현(Seung-Hyeon Jin)

[정회원]



- 2017년 2월 : 부산대학교 전기공학 (공학사)
- 2019년 2월 : 포항공과대학교 전자전기공학과 (공학석사)
- 2019년 8월 ~ 2020년 12월 : 국방기술품질원(DTaQ) 연구원
- 2021년 1월 ~ 현재 : 국방기술진흥연구소(KRIT) 연구원

〈관심분야〉

레이더, 자원관리, 전장위협평가, 최적화