

# 인공지능을 이용한 대포병탐지레이더의 탄종 식별 Classification Type of Weapon Using Artificial Intelligence for Counter-battery Radar Paper Title

박성진<sup>★</sup>, 진형석<sup>\*</sup>

Sung-Jin Park<sup>★</sup>, Hyung-Seuk Jin<sup>\*</sup>

## Abstract

The Counter-battery radar estimates the origin and impact point of the artillery by tracking the trajectory of the shell. In addition, it has the ability of identifying the type of weapon. Depending on the position between the shell and the radar, the detected signals appear differently. This has ambiguity to distinguish the type of shells. This paper compares fuzzy logic and artificial intelligence, which classifies type of shell using the parameter of signal processing step. According to the research result, artificial intelligence can improve identification rate of type of shell. The data used in the experiment was obtained from a live fire detection test.

## 요약

대포병탐지레이더는 포탄의 궤적을 역으로 추적하여 화포 원점과 탄착점을 추정해 낸다. 부가적으로 추적 화포의 탄종을 식별하는 기능도 포함된다. 레이더를 통해 포탄의 궤적을 추적하는 중에는 포탄과 레이더의 위치에 따라 감지된 신호들이 다르게 나타나는 경우가 발생한다. 이는 포탄의 종류를 식별하기에는 모호한 부분이 있다. 본 논문은 레이더의 신호처리 과정 중에 산출하는 데이터를 바탕으로 퍼지이론과 인공지능을 이용하여 포탄의 종류를 구분하고 비교하였다. 연구 결과에 의하면 인공지능에 의한 정확도가 퍼지이론을 사용한 표적 식별 결과 대비 우수한 식별률이 나오는 것을 확인했다. 실험에 사용된 데이터는 포탄을 실제 발사하여 대포병탐지레이더-II로부터 얻은 것이다.

*Key words : Artificial Intelligence, Neural Network, Weapon Classification, Fuzzy Logic, Counter-battery Radar*

## 1. 서론

비행물체 인식은 1925년 영국 왕립 방공감시단에 의해 시작되어 1957년까지 계속하였다. 1, 2차 대전을 거치면서 공중전의 위협으로부터 인명과 군용 시설을 보호하기 위해서 빠르고 정확한 적군의 항공기 인식이 필요했다. 당시 항공기 식별기준은 육

안으로 WEFT(Wing shape, Engine configuration, Fuselage shape and Tail type) 기준에 의하여 구분하였다. 항공기의 속도와 고도가 높아짐에 따라 육안으로 항공기식별이 불가능하게 됨에 따라 영국 왕립 방공감시단은 1957년에 항공기식별 임무가 공식적으로 없어졌다. 그러나 민간인을 대상으로 4인 1조로 구성된 항공기식별 경진대회를 NATO와

\* LIGnex1

★ Corresponding author

E-mail : Sungjin.park@lignex1.com, Tel : +82-31-288-9748

※ Acknowledgment

Manuscript received Oct. 13, 2020; revised Dec. 13, 2020; accepted Dec. 18, 2020.

This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

함께 1991년까지 계속했다. 미국에서도 비슷한 시기에 WEFT를 항공기 판단기준으로 사용하였다.

2차 세계대전 중에 항공기의 속도가 빨라지고 고도가 높아짐에 따라 레이더를 기반으로 아군기와 적군기를 식별하는 시스템(IFF : friend or foe)이 항공관제와 방공망을 위하여 개발되기 시작하였다[1]. IFF는 암호 신호를 비행체에 발사하여 비행체에서 돌아오는 반응 신호에 따라 적기와 아군기를 식별하였다. IFF 시스템은 1939년 영국에서 20~30MHz 주파수를 이용한 IFF Mark I을 최초로 개발하기 시작하여 1948년에 이르러 미국에서 1GHz 주파수를 이용하는 Mark IV와 V를 개발하는 단계까지 발전하였다. 그 후 Mark X 개발 과정에서 1GHz 주파수를 사용하면서 엔코딩 시스템(Selective Identification Feature)을 도입하여 항공기 기종과 고도 정보가 포함되었다. 현재 사용되고 있는 IFF 시스템은 XII으로서 Mark X와 같은 주파수를 사용하면서 민간기와 군용기를 식별할 수 있고 충돌 방지를 위한 위치정보를 제공한다[2].

레이더 기술과 전자기술이 발전함에 따라 실시간 고속연산이 가능하여 항공기 식별을 뛰어넘어 포탄 추적이 가능하게 되었다. 포탄추적에 사용되는 레이더를 대포병탐지레이더(counter-battery radar)라 한다. 초기 대포병탐지레이더는 아군 위치에 떨어진 고사포의 발사 위치를 찾아 그 기지를 공격하는 목적에 사용되었다. 고사포 궤적은 대칭적인 포물선 형태이므로 몇몇 위치의 데이터만 잡아도 발사 위치 계산이 가능하였기 때문이다. 1970년대부터 고속연산이 가능한 디지털 컴퓨터가 개발되어 보다 복잡한 장거리 포탄 궤적 추적이 가능해졌다. 첨단 통신 시스템의 지원으로 단일 레이더의 정보를 먼 거리로 빠르게 전파가 가능해졌다. 이는 레이더가 더 다양한 정보를 우군에 전송할 수 있게 만들었다[3].

소총, 곡사포, 로켓은 발사각도가 낮으므로 박격포보다 궤적을 추적하기가 어렵다. 순수한 소총 궤적은 발사 순간과 마지막 궤적은 상당히 비대칭적이다. 발사 순간은 비교적 포물선에 가깝지만, 궤적의 후반부는 포물선의 반경이 작아진다. 그리고 이러한 종류의 포탄 궤적은 바람의 세기, 기압, 공기역학 등의 영향을 고려하여 또다시 수정되어야 한다. 이러한 요소들은 비교적 단거리일 경우 큰 영향을 주지 않지만, 장거리일 때는 심각한 영향을

미친다. 포탄의 궤적을 빠른 시간에 정확하게 추적하기 위해서 빔 포밍 방식의 원추형 레이더, 다 위상배열 레이더 등의 레이더가 개발되었다[4].

위와 같은 이론적인 문제 외에 현실에서 일어나는 문제는 대포병탐지레이더 빔이 포탄이 아닌 물체(비행기, 새)로부터 반사되어 오는 신호로 인하여 포탄을 발사한 위치를 추적하는 데 어려움이 있다. 이러한 노이즈 신호를 제거한 후 포탄의 종류를 식별하고 포탄의 종류에 따라 궤도를 역으로 추적하여 발사 기지를 찾아낸다. 포탄에 따라 궤적이 달라서 포탄의 종류를 정확하게 식별하는 일은 중요한 일이다. 최근 레이더 분야에서는 신호처리 과정에서 뉴럴 네트워크를 적용해서 노이즈 제거, 표적 신호 추출 등을 수행하는 연구가 진행 중이다. 영상레이더(synthetic aperture radar) 분야에서는 수신한 RF 신호의 후처리 과정에서 인체의 자세를 이미지로 추출 후 뉴럴 네트워크로 학습을 시키는 연구도 진행하고 있다[5]. 본 논문은 대포병탐지레이더-II 필드 시험을 통해 수집한 표적의 데이터를 이용하여 포탄의 종류 식별을 뉴럴 네트워크를 이용해서 학습시킨 결과를 다룬다.

본 논문은 서론에 이어 본론 1장에서는 대포병탐지레이더로부터 얻는 신호에 대한 이론적인 내용을 살펴본다. 2장과 3장에서는 퍼지이론과 뉴럴 네트워크에 대하여 다룬다. 4장에서는 퍼지 방식과 머신러닝 방법을 실제 레이더 신호에 적용하여 포탄의 종류를 식별하는 실험 방법과 정확도를 비교한 후 결론을 맺는다.

## II. 본론

### 1. 대포병탐지레이더

가. 대포병탐지레이더 운용

대포병탐지레이더는 탄도의 궤적을 역추적해서 화포 발사 지점과 탄착 지점을 추정하는 레이더이다. 또한 이 레이더는 아군의 포탄이 정확하게 목표물을 폭격하는 데 사용될 수 있다. 이 레이더의 기본 동작 원리는 2차원 E-SCAN을 이용한 3차원 레이더이다. 정지 레이더가 수평선을 빠른 속도로 스캔하여 감시망 레이더 커튼을 만들어 그 커튼을 통과하는 물체의 다양한 신호(파라미터)를 얻는다. 이 파라미터를 이용하여 포탄의 종류가 판정되면 그 포탄에 해당하는 궤적을 분석하여 발사 위치를

지도상에 표시하여 정확한 역공이 이루어질 수 있게 한다[6].




Fig. 1. Concept of Counter-battery Radar Operation.  
그림 1. 대포병탐지레이더 운용 개념도

#### 나. 레이더의 파라미터 추출

레이더는 전파를 사용하여 목표물의 거리, 방향, 각도 및 속도를 측정하는 감지 시스템(Detection system)이다. 강한 전자기파를 발사하고 그것이 물체에 맞고 반사되어 되돌아오는 전자파를 분석하여 대상물과의 거리를 측정한다. 기상용 레이더의 경우, 빗방울, 눈송이 등으로부터 반사되는 반사파의 전력 밀도를 측정하여 그 지점에서의 우량(강수강도)을 검출한다. 레이더에 파장이 긴 저주파를 사용하면 전파의 감쇄가 작고 먼 곳까지 탐지할 수가 있지만 정밀한 측정이 되지 않아 해상도는 낮아진다. 반대로 파장이 짧은 고주파는 공기 중에 포함되는 수증기, 눈, 비 등에 흡수 또는 반사되기 쉬우므로 감쇄가 커서 먼 곳까지 탐지하지 못하지만 높은 해상도를 얻을 수가 있다. 따라서 대공 레이더, 대지 레이더 등 원거리의 목표물을 빨리 발견할 필요성이 있는 경우에는 저주파의 전파를 사용하고 사격 관제 레이더 등 목표의 형태나 크기를 정밀하게 측정할 필요성이 있는 경우에는 고주파의 전파를 사용하는 것이 적합하다.

레이더는 대기에 방사한 전자파가 표적에 맞고 반사되어 돌아오는 신호를 통해 표적의 위치를 추정한다. 반사되어 돌아오는 신호의 세기( $P_r$ )는 식 (1)과 같이 표시되며 레이더 방정식이라 부른다[7].

$$P_r = \frac{P_t G_t}{4\pi R^2} \frac{\sigma A_e}{4\pi R^2} \quad (1)$$

여기서  $P_r$ ,  $P_t$ ,  $G_t$ ,  $R$ ,  $\sigma$ ,  $A_e$ 는 각각 수신 출력, 송

신 출력, 송신 이득, 레이더와 물체 사이의 거리, 레이더 반사 면적, 수신 안테나 면적을 나타낸다. 레이더 방정식에서 레이더반사면적 RCS(Radar Cross Section)는 식 (2)와 같이 나타낸다.

$$\sigma = \frac{P_t G_t}{4\pi P_r} \frac{A_e}{4\pi R^4} \quad (2)$$

RCS는 대상 구조(모양 및 재료), 레이더 작동 주파수, 레이더 편광 및 레이더 관찰 각도에 따라 다르다. 간단한 금속 모양의 레이더 단면은 방정식으로 추정할 수 있지만, 항공기와 같은 매우 복잡한 대상의 경우 레이더가 조명되는 방향에 따라 크게 다르다. 이런 RCS 특성은 물체의 종류를 식별하는데 중요한 데이터가 될 수 있다.

송신한 신호 세기와 수신된 신호 세기를 기준으로 레이더와 반사된 물체 사이의 거리  $R$ 은 다음과 같이 나타낸다.

$$R = \sqrt[4]{\frac{P_t G_t}{4\pi P_r} \frac{\sigma A_e}{4\pi}} \quad (3)$$

지속적인 거리 추적은 물체의 이동 경로를 알 수 있고 이동 거리에 따른 속도를 추정할 수 있다.

#### 다. 표준탄도 방정식

경로를 역으로 추적하는 과정에 식 (4)와 같은 표준탄도 방정식을 적용하면 물체의 항력을 추정할 수 있다.

$$u = D + L + M + g + \Lambda \quad (4)$$

여기서  $u$ 는 포탄에 가해지는 운동방정식,  $D$ 는 항력,  $L$ 은 양력,  $M$ 은 매그너스력,  $g$ 는 중력가속도,  $\Lambda$ 는 지구 자전에 의한 코리올리를 나타낸다. 탄도의 궤적을 추정에 중요한 요소인 항력은( $D$ ) 식 (5)와 같이 나타낼 수 있는데.  $\rho$ 는 공기밀도,  $V$ 는 포탄의 속도,  $S$ 는 운동 방향에 수직인 포탄의 단면적이라고 정의하면 다음과 같다[8].

$$D = \frac{\rho V^2 S}{2C_D} \quad (5)$$

항력의 가장 중요한 요소인 항력계수( $C_D$ )는 물체가 어떠한 매개체를 통하여 이동할 때 매개체로부터 받는 저항력 중에서 물체의 운동 방향과 반대

방향으로의 저항력 성분을 나타낸다. 항력은 물체의 속도에 따라서 달라지는데 아음속 구간의 항력은 주로 표면 마찰에 의한 저항력에 의해 발생하고 음속에 가까운 속도에서의 항력은 포탄의 충격파, 포탄 후면의 난류와 와류에 의한 저항력이 강하게 발생한다. 초음속 구간에서의 항력은 와류의 충격파에 의한 저항력이 추가된다[9]. 항력계수 또한 물체의 형상에 따라 달라지므로 표적 식별에 사용할 수 있다.

위와 같은 이론적인 배경으로부터 얻어내는 파라미터를 대포병탐지레이더에서 포탄의 종류를 식별하는 데 사용한다.

2. 퍼지 이론

명확하게 상태를 기술할 수 없는 모호한 대상을 수학적으로 다루고자 만들어진 퍼지 이론은 퍼지 집합(fuzzy set)을 기본으로 구성한다[10]. 고전 집합이론에서는 어떤 요소가 A라는 집합에 속할 확률은 “0” 아니면 “1”이다. 그러나 현실 세계에서는 어떤 요소가 A라는 소속되는 정도가 애매할 수도 있다. 퍼지 멤버십 함수는 입력된 값에 대해 오직 0 또는 1만을 출력으로 내는 것이 아닌 0과 1사이의 임의의 실수를 출력으로 낸다. 이는 요소 A가 그 집합에 어느 정도 속하는가를 의미한다.




Fig. 2. Membership Function Distinguished by 2 Group. 그림 2. 키 크기를 2 그룹으로 했을 때 멤버십 함수

그림 2와 같이 예를 들어 키 큰 사람들의 퍼지 집합에서 멤버십 함수값이 0이면 “크지 않다”, 1은 “크다”, 0.5는 “어느 정도 크다”, 0.01은 “아주 조금 크다”를 의미하게 된다.

이 경우의 멤버십 함수를 구하는 과정을 소개하면 다음과 같다. 130cm 이하의 사람은 “크지 않다”라고 정의하고 190cm 이상의 사람을 “크다”라고

정의할 때 멤버십 함수는 그림 2와 같이 표시할 수 있다. 결국 키가 131cm인 사람은 “크지 않다”가 아니라 “아주 조금 크다”로 정의한다.

이처럼 “크다”, “크지 않다”의 정도로 단순하게 표현하지 않고 중간 과정에 있는 사람을 “크다”의 기준에 어느 정도에 해당하는지 정의할 수 있게 해주는 것이 퍼지 로직이다. 이를 세분화하여 작음, 보통, 큼으로 구분하는 멤버십 함수로 변경하면 그림 3과 같이 나타낼 수 있다. 여러 가지 파라미터를 바탕으로 퍼지 로직을 통해 해당 파라미터의 소속 위치를 비교하면 해당 대상이 어떤 그룹에 속하는지 파악할 확률이 높아진다.




Fig. 3. Membership Function Distinguished by 3 Group. 그림 3. 키 크기를 3 그룹으로 했을 때 멤버십 함수

멤버십 함수( $\mu_A(x)$ )는 삼각형, 사다리꼴, 가우시안, 일반화 한 종형, 시그모이드 함수 등이 있다[11]. 본 논문에 사용할 사다리꼴 멤버십 함수는 그림 4와 같으며 식 6과 같이 표시되며 그 값은 식 7과 같이 결정된다.

$$\begin{aligned} \text{Trapezoid}(x;a,b,c,d) &= 0, \text{ if } x \leq a; \\ &= (x-a)/(b-a), \text{ if } a \leq x \leq b \\ &= 1, \text{ if } b \leq x \leq c \\ &= (d-x)/(d-c), \text{ if } c \leq x \leq d; \\ &= 0, \text{ if } d \leq x \end{aligned} \tag{6}$$

$$\mu_{\text{trapezoid}} = \max\left(\left(\min\left(\frac{x-a}{b-a}, 1, \frac{d-x}{d-c}\right), 0\right)\right) \tag{7}$$




Fig. 4. Trapezoidal Membership Function. 그림 4. 사다리꼴 멤버십 함수

### 3. 뉴럴 네트워크 알고리즘

뉴럴 네트워크는 주어진 입력에 해당하는 출력값을 갖게 하려고 층간의 가중치를 조절하는 비선형 피드백 시스템이다. 본 논문에 사용되는 뉴럴 네트워크는 그림 5와 같이 각 포탄이 가지는 5종의 파라미터를 입력으로 하여 3종의 포탄을 식별하는 구조이다. 이 뉴럴 네트워크는 서로 독립적인 입력과 출력 데이터를 통하여 반복적인 학습을 통하여 인공지능을 가지게 된다. 뉴럴 네트워크의 구조에 따라 성능이 다르지만, 본 논문의 관점은 간단한 구조일지라도 현장에서 얻은 실험 파라미터를 기반으로 한 인공지능 방식이 퍼지 로직 경우보다 우수하다는 것을 보이는 것이다. 뉴럴 네트워크 구조에 따른 성능 평가는 본 논문의 범위 밖으로 다른 문헌에서 자세하게 다루고 있다[12] [13] [14].

그림 5의 기본적인 동작 원리는 다음과 같다. 입력층에서 실험을 통하여 얻은 5종의 파라미터( $x_k$ ) 받아들이고, 10개의 노드를 가지는 히든 층에서 각 파라미터에 비중( $w_{jk}$ )을 곱한 후 출력층에서 각 히든 층의 값을 더해서 결과값( $y_0, y_1, y_2, y_3$ )을 얻는다. 히든 층의 k번째 노드는 식 (7)과 같이 쓸 수 있다.

$$h_k = \sum_{j=1}^n x_j \cdot w_{jk} \quad (8)$$

여기서 n은 입력 수,  $w_{jk}$ 는 j 번째 입력과 히든 층의 n 번째 노드 간의 가중치이다. 히든 노드에서는 오버플로우를 막기 위하여 식(8)과 같은 함수를 수행하고 출력층에서는 식(9)와 같이 출력값을 계산한다.




Fig. 5. Structure of neural network used in this study.  
그림 5. 본 연구에 사용된 뉴럴 네트워크 구조

$$f(h_k) = \frac{1}{1 + \exp(-h_k)} \quad (9)$$

여기서 m은 포탄의 종류이고  $hw_{km}$ 은 히든 노드와 출력 간의 가중치이다. 최종 출력  $y_m$ 은  $yt_m$ 을 이용하여 식 10과 같은 함수  $f(yt_m)$ 을 수행함으로써 얻어진다. 뉴럴 네트워크는 오차역추적 방식을 이용하여 주어진 입력 파라미터( $x_k$ )에 대하여 출력값  $f(yt_m)$ 이 “1”이 되게 각 층간의 가중치를 조절한다. 독립적인 많은 입력 파라미터 세트와 출력 파라미터를 이용하여 반복 수행하면 뉴럴 네트워크가 인공지능을 가지게 된다[15] [16] [17].

$$yt_m = \sum_{j=0}^9 f(h_k) \cdot hw_{km} \quad (10)$$

$(m = 0, 1, 2, 3)$

### 4. 실험 및 분석

#### 가. 파라미터 수집 및 분석

제2장에서 소개한 바와 같이 레이더를 통하여 다양한 파라미터(물체의 거리, RCS, 이동 경로, 항력)를 얻을 수 있다. 이러한 파라미터 중의 하나인 RCS를 시뮬레이션하여 포탄의 종류를 식별한 연구도 있다[18]. 신규 개발된 탄의 경우 형상이 변하여 RCS에 영향을 미칠 수 있으므로 이러한 수정 과정을 거칠 필요가 생길 수 있다. 본 연구에서는 식별하려는 포탄 3종을 발사하여 대포병탐지레이더를 통하여 5종의 파라미터 값을 수집하였다. 3종의 포탄은 각각 602, 53, 107회 발사하여 총 762회 실험이 이루어졌다. 이러한 실험을 통하여 각 포탄의 5종의 파라미터 값을 통계적으로 처리하여 데이터베이스화하였다. 레이더 신호는 약하고 각 파라미터는 포탄에 따라 명확하게 식별되지 않는다. 실험에 의하면 각 파라미터의 특징은 표 1과 같다. 표 1에서  $P_{11}, P_{21}, P_{31}$ 의 의미는 파라미터 1을 측정할 때 탄종 1, 2, 3으로 나올 확률을 의미한다. 다른 확률도 같은 방법으로 해석하면 된다.

1번 파라미터는 그룹 1의 포탄을 찾을 확률은 높으나 그룹2의 포탄으로 오인할 확률도 54%나 된다. 파라미터 5번 경우는 그룹 1 포탄과 그룹 2 포탄으로 판정할 확률이 거의 비슷하다. 어느 파라미터도 100% 확률로 포탄을 식별할 수 없다. 따라서 판정이 애매한 경우 제3장의 퍼지 로직의 멤버십 함수를 조정하거나 제4장의 인공지능 방식을 이용

하여 판정 확률을 높일 필요가 있다. 실제로 퍼지 로직 멤버십 함수는 수집한 데이터를 바탕으로 수정이 이루어졌다. 새로운 형상의 탄이 개발되면 이러한 퍼지 로직 범위를 벗어나서 멤버십 함수를 새로 정의해야 할 경우가 생길 수 있다.

나. 퍼지 로직 멤버십 함수 구성

실험을 통하여 측정한 5 파라미터를 이용하여 그림 6와 같은 멤버십 함수를 구하였다. 그림 6-(a)는 파라미터 1의 값에 따른 포탄 3종의 포탄 그룹이 가지는 확률 즉 멤버십 함수이다. 그림 6-(b)는 파라미터 2의 값에 따른 포탄 3종의 확률을 나타낸다. 그림 6-(c), (d), (e)는 파라미터 3, 4, 5의 멤버십을 나타낸다.

멤버십 함수를 이용하여 탄종을 판별하는 과정을 그룹2를 예를 들어 설명한다. 레이더에서 파라미터 1, 2, 3, 4, 5의 값이 56.0226, 708.8204, 3.3547, 695.4522, 7.7748로 잡혔다고 가정해보자. 그림 6-(a)의 56.0226은 레이더에서 탄종 그룹1의 파라미터 1의 값으로 측정된 것이다. 이 값에서  $P_{11}=1$ ,  $P_{21}=0.54$ ,  $P_{31}=0$ 을 얻을 수 있다. 그림 6-(b)의 상단에 표시한 값 708.8204는 탄종 그룹2의 파라미터2의 값으로 측정된 것이다. 이 값에서  $P_{12}=0$ ,  $P_{22}=0.546$ ,  $P_{32}=0.984$ 를 얻을 수 있다. 나머지 6-(c), (d), (e)를 이용하여 레이더에서 측정된 각 파라미터 값을 이용하여 나머지 파라미터값들을 구할 수 있다.

Table 1. Probability of shell types according to each parameter.

표 1. 각 파라미터에 따른 포탄 종류 확률

	Type 1	Type 2	Type 3
Parameter 1	$P_{11}$ (1)	$P_{21}$ (0.542)	$P_{31}$ (0)
Parameter 2	$P_{12}$ (0)	$P_{22}$ (0.546)	$P_{32}$ (0.984)
Parameter 3	$P_{13}$ (0)	$P_{23}$ (0.677)	$P_{33}$ (1)
Parameter 4	$P_{14}$ (0.071)	$P_{24}$ (0.348)	$P_{34}$ (0.549)
Parameter 5	$P_{15}$ (0.718)	$P_{25}$ (0.776)	$P_{35}$ (1)

각 탄종 그룹에 해당할 확률  $P_n$ 은 식 (11)과 같이 5개의 멤버십 함수에서 그 그룹에 해당하는 확률의 곱으로 나타낸다.

$$P_n = P_{n1} \cdot P_{n2} \cdot P_{n3} \cdot P_{n4} \cdot P_{n5} \quad (11)$$

$$= 1, \quad (\text{if } 1 \leq n \leq 3)$$

$$= 0, \quad (\text{if } P_1 P_2 P_3 = 0, n = 4)$$

그림 5에서 얻은 확률과 식 (10)을 이용해서 레이더에서 얻은 파라미터 값을 이용하여 각 그룹의 확률을 계산하면 식(11)과 같다. 식 (11)에서 우리는 현재 레이더에 들어온 신호는 탄종 그룹2에 해당한다는 것을 알 수 있다.  $P_4$ 의 경우 모든 그룹의 확률이 0일 상황에 해당한다.

$$P_1 = 1 \cdot 0 \cdot 0 \cdot 0.0706 \cdot 0.7181 = 0$$

$$P_2 = 0.5422 \cdot 0.5462 \cdot 0.6774 \cdot 0.3481$$

$$\cdot 0.7765$$

$$= 0.0542$$

$$P_3 = 0 \cdot 0.9840 \cdot 1 \cdot 0.5490 \cdot 1 = 0$$

다. 퍼지 로직 적용 결과

총 762개의 실험데이터는 3개 탄종으로 구성되며 탄종 1, 탄종 2, 탄종 3은 각각 602, 53, 107개의 데이터를 가진다. 각 데이터는 5개의 파라미터를 가지고 있다. 762 데이터 세트의 5개 파라미터를 5-2에서 만든 멤버십 함수에 적용하여 탄종을 판별하여 표 2와 같은 결과를 얻었다. 표 2에서 none은 3종의 탄종에 포함되지 않는다고 판정한 경우이다. 탄종1 중에서 454개 샘플은 탄종1로 샘플 중 75.4% (454/602)를 맞게 식별하였고, 탄종2 2개, 탄종3 72개, None 74개로 탄종1 샘플 중 24.6%를 오식별 하였다. 탄종2 중에서 24개 샘플을 정확하게 식별하였고 식별률은 45.3%이다. 탄종1 8개, 탄종3 1개, None 20개로 전체 탄종2 샘플 중 54.7%를 오식별 하였다. 탄종3에 해당하는 샘플 중 50개를 식별하여 46.7%의 식별 정확도를 보였으며, 나머지 탄종1 40개, None 17개로 탄종3 샘플 중 53.3%를 오식별 하였다. 전체 샘플 중 69.3%를 정확히 식별하였고, 30.7%의 오식별률을 보인다. 퍼지 로직을 적용하면 탄종 1을 제외 하고는 변별력이 없다. 이는 탄종 1보다 탄종 2, 3에 대한 실험데이터가 작은 것이 하나의 원인으로 생각된다.

라. 뉴럴 네트워크를 이용한 탄종 식별

실험에 사용한 데이터는 퍼지 로직과 같이 탄종 1, 2, 3은 각각 602, 53, 107개이고, 각 포탄은 5개의 파라미터를 가지므로 총 762 데이터 세트로 구성된다. 뉴럴 네트워크는 오차 역전파(error back-propagation)



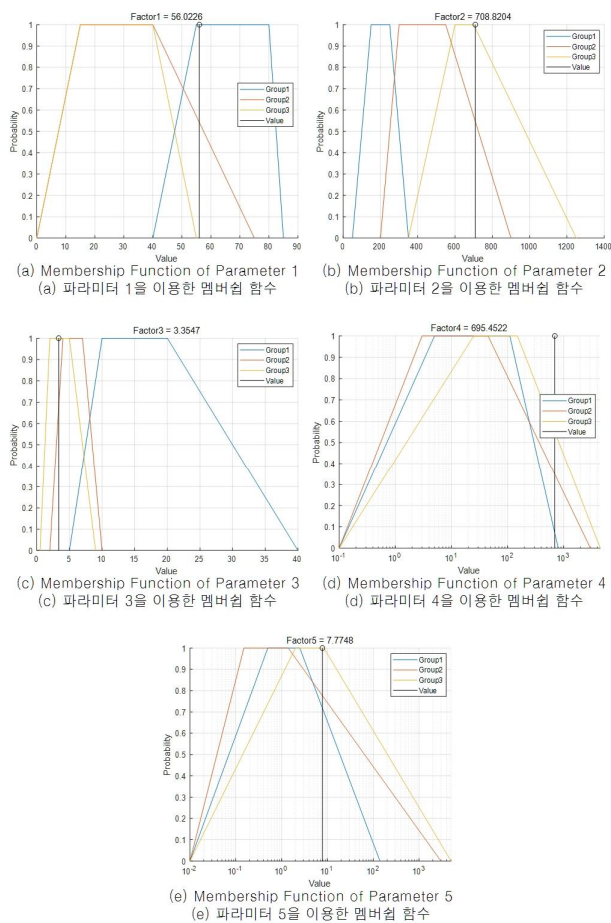


Fig. 6. Membership function using each parameter.  
그림 6. 각 파라미터를 이용한 멤버십 함수

방식을 이용하여 인공지능을 가지게 된다. 즉 입력과 출력이 주어진 상태에서 출력을 갖추기 위하여 뉴럴 네트워크 간의 가중치를 조절한다. 많은 트레이닝 데이터 세트를 이용하여 반복 학습시키면 뉴럴 네트워크의 판단 능력이 좋아지게 된다. 뉴럴 네트워크가 상당한 수준의 판단 능력을 갖추게 하는 데는 많은 시간과 노력이 들지만 충분한 학습을 통하여 각 네트워크 간의 가중치가 정해지면 새로운 판단 대상에 대해서는 뉴럴 네트워크가 feed-forward 방식으로 동작하므로 실시간으로 판단하는 데 어려움이 없다.

본 연구는 뉴럴 네트워크를 이용한 탄종 식별 가능성을 확인하기 위해 MatLab 기본 뉴럴네트워크 생성 툴박스를 이용해 인공지능을 구현하였다. 히든 레이어의 수를 결정하기 위해서 히든 레이어의 개수에 따른 정확도 변화를 실험했다. 실험 결과는 그림 7과 같다.

Table 2. Results of determination of shell applying fuzzy logic.

표 2. 퍼지 로직을 적용한 탄종 판정 결과

	Sum	Type 1 Selected	Type 2 Selected	Type 3 Selected	None	정확도 (오판율)
Type 1	602	454	2	72	74	75.4 (24.6)
Type 2	53	8	24	1	20	45.2 (54.8)
Type 3	107	40	0	50	17	46.7 (53.3)

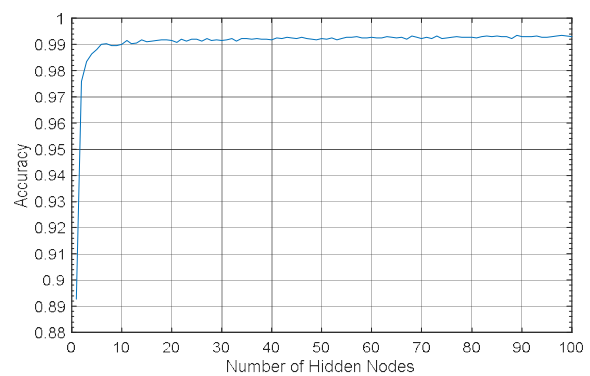


Fig. 7. Accuracy change according to the number of hidden nodes.

그림 7. 히든 노드 수에 따른 정확도 변화

히든 레이어 수는 충분한 정확도를 위해 100개로 설정하고 3개의 탄종을 일정 비율 즉 트레이닝 그룹, 검증그룹(validation group), 테스트 그룹으로 나누어 실험하였다. 트레이닝 그룹의 데이터 세트를 이용하여 뉴럴 네트워크를 학습시킨 후 검증그룹 데이터 세트를 정확도를 확인하는 과정을 반복하여 검증그룹 판단 정확성이 개선되지 않으면 중지한다.

사용하는 Matlab 인공지능 툴박스를 이용하여 최상의 탄종 판정정확도를 얻기 위하여 트레이닝 그룹, 검증그룹, 테스트 그룹의 비율에 따른 특성을 조사하였다. 그룹의 비율이 정해지면 총 762개 실험데이터 세트에서 비율에 맞춰 랜덤하게 선택하여 3개 그룹(트레이닝, 검증, 테스트)으로 나누어 트레이닝을 수행하고 검증그룹 데이터를 통하여 정확도를 확인한다. 같은 비율이라도 패키지를 새로 실행시키면 각 그룹에 선정되는 데이터 세트가 다르게 선정된다. 본 연구에서는 실험 결과의 범용성을 확보하기 위하여 같은 그룹 비율로 총 1000번의 새로운 데이터 세트가 선정되게 프로그램 하였




Fig. 8. Number of learning repetitions according to group composition ratio.  
 그림 8. 그룹 구성 비율에 따른 학습 반복 횟수

다. 그룹 비율에 따른 정확도와 학습 반복 횟수를 요약하면 표 3과 같다. 학습 그룹의 비중이 클수록 정확도가 향상되는 것을 알 수 있다. 학습 그룹의 비중이 아주 작은 경우는 학습 반복 회수는 작으나 정확도가 낮은 편이다. 학습 그룹을 크게 한 경우는 반복 학습 횟수가 많았지만, 정확도가 가장 높다. 본 연구에서는 학습, 검증, 테스트 그룹의 비율을 6:1:3으로 하여 최종실험을 하여 표 3의 결과를 얻었다. 실험 결과에 의하면 탄종 3개에 대하여 평균 99.4% 정확도를 얻을 수 있었다.

Table 3. Accuracy according to composition ratio.  
 표 3. 구성 비율에 따른 정확도

	Composition Rate			Accuracy
	Train	Validation	Test	
Test 1	8	1	1	99.4
Test 2	6	1	3	99.5
Test 3	4	1	5	98.1
Test 4	1	1	8	95.6

### III. 결론

3종류 포탄 총 762발의 포탄을 발사하여 레이더 신호 파라미터(물체의 거리, RCS, 이동 경로, 항력 등)를 얻었다. 레이더 신호 특성상 이 파라미터들만으로 포탄을 명확하게 식별할 수 없다. 본 연구는 판단이 모호할 때 우수한 성능을 보이는 퍼지이론과 뉴럴 네트워크를 이용한 인공지능을 이용하여 탄종을 식별하였다. 두 경우 모두 기본적인 간단한 구조를 사용하였다. 사다리꼴 멤버십 함수를 사용한 퍼지 로직의 경우 데이터가 602세트일 경우 판단 정확도가 75.4%이었지만, 데이터 세트가 107개 이하인 경우는 판단 정확도가 50% 미만이었다. 5개의 입력, 4개의 출력, 1개의 히든 층을 가지는 뉴럴 네트워크의 경우 3개의 탄종 평균 정확도가 99.4%이었다. 본 연구를 통하여 대포병탐지레이더의 탄종 식별에 뉴럴 네트워크를 이용한 학습 시 성능 향상을 기대할 수 있다.



## References

- [1] BAE Systems, "Combat Identification (IFF)," Roland Bros, <https://www.baesystems.com/en/product/iff-familily/>
- [2] Lord Bowden, "The story of IFF (identification friend or foe)," *IEEE Proceedings A-Physical Science, Measurement and Instrumentation, Management and Education*, Reviews, Vol.132, No.65, pp.435-437, 1985. DOI: 10.1049/ip-a-1.1985.0079
- [3] *FM 3-09.12 (FM 6-121) MCRP 3-16.1A Tactics, Techniques, and Procedures for Field Artillery Target Acquisition*, US Army, 2002.
- [4] Van Veen, B. D.; Buckley, K. M., "Beam forming: A versatile approach to spatial filtering," *IEEE ASSP Magazine*, Vol.5, No.2, pp.4-24, 1988. DOI: 10.1109/53.665
- [5] Mehmet S. Seyfioglu, Baris Erol, Sevgi Z. Gurbuz, and Moeness G. Amin, "Diversified Radar Micro-Doppler Simulations as Training Data for Deep Residual Neural Networks," *Proc. IEEE Radar Conf.*, pp.0612-0617, 2018. DOI: 10.1109/RADAR.2018.8378629
- [6] U. Nickel, "Fundamentals of signal processing for phased array radar in Advanced Radar Signal and Data Processing," *Neully-sur-Seine, France: NATO Research & Technology Organisation (RTO)*, pp.1-1, 2006.
- [7] William L. Melvin, James A. Scheer, "Principles of modern radar advanced techniques," *SciTech Publishing*, 2013.
- [8] Heung-joo Lee, "Gun and ballistics," Cheong Moon Gak, 1998.
- [9] Robert, F. L. "Determination of Aerodynamic Drag and Exterior Ballistic Trajectory Simulation for The 155 mm, DPICM M864 Base-Burn Projectile," ARMY BALLISTIC RESEARCH LAB ABERDEEN PROVING GROUND MD, 1989.
- [10] Zadeh L.A., "Fuzzy sets," *Information and Control*, Vol.8, No.3, pp.338-353, 1965. DOI: 10.1016/S0019-9958(65)90241-X
- [11] J. Jantzen. J. Jantzen. "Foundations of fuzzy control," Wiley, 2007.
- [12] E. J. Teoh, K. C. Tan, and C. Xiang, "Estimating the number of hidden neurons in a feedforward network using the singular value decomposition," *IEEE Transactions on Neural Networks*, vol.17, pp.1623-1629, 2006. DOI: 10.1109/TNN.2006.880582
- [13] N. Wanas, G. Auda, M. S. Kamel, and F. Karray, "On the optimal number of hidden nodes in a neural network, in Electrical and Computer Engineering," *IEEE Canadian Conference on Electrical and Computer Engineering*, pp.918-921, 1998. DOI: 10.1109/CCECE.1998.685648
- [14] K. Chen, S. Yang, and C. Batur, "Effect of multi-hidden-layer structure on performance of BP Neural network: Probe," in Natural Computation (ICNC), *2012 Eighth International Conference*, pp.1-5, 2012. DOI: 10.1109/ICNC.2012.6234604
- [15] J. De Villiers, E. Barnard, "Backpropagation neural nets with one and two hidden layers," *IEEE Transactions on Neural Networks*, vol.4, pp.136-141, 1993. DOI: 10.1109/72.182704
- [16] N. Karayiannis, A. N. Venetsanopoulos, "Artificial neural networks: learning algorithms, performance evaluation, and applications vol. 209:" Springer Science & Business Media, 2013.
- [17] K. Mehrotra, C. K. Mohan, and S. Ranka, "Elements of artificial neural networks:" MIT press, 1997.
- [18] Seung-Jae Lee, Sung-Jae Jung, Byung-Soo Kang, Hyung-gi Na, Hyun Kim, Kyung-Tae Kim, "A Study on Shell-Shaped Target Classification Using RCS and Fuzzy Classifier," *The Journal of Korean Institute of Electromagnetic Engineering and Science*, Vol.25, No.5, pp.576-584, 2014. DOI: 10.5515/KJKIEES.2014.25.5.576

---

**BIOGRAPHY**

---

**Sung-Jin Park** (Member)

2010 : BS degree in Electrical  
Communication Engineering,  
Hanyang University. ERICA  
2012 : MS degree in Electronic  
Electricity Engineering, Pusan  
University.  
2013~ : Research Engineer, LIG Nex1.

**Hyung-Seuk Jin** (Member)

2000 : MS degree in Electromagnetic  
Propagation Engineering,  
Kwangwoon University.  
2000~ : Research Engineer, LIG Nex1.