

다표적 마이크로-도플러 영상 분리를 이용한 탄두와 기만체 구분

김유진*, 최인식**

Classification of the Warhead and Decoys using the Multi-Target Micro-Doppler Image Separation

Yu-Jin Kim*, In-Sik Choi**

이 논문은 2025학년도 한남대학교 학술연구비 지원에 의하여 연구되었음.

요 약

단일 빔 내에 다수의 표적 신호가 존재하는 경우에는 탄두와 기만체 구분이 매우 어렵다. 본 논문에서는 탄두는 장동운동(Nutation), 기만체는 전복운동(Tumbling)의 미세운동을 한다고 가정하고, 다표적 신호를 분리하여 탄두와 기만체를 구분하는 방법을 제안한다. 먼저, 산란점 추출, 허프변환, 최소자승법을 이용하여 표적별 궤적을 추정하고 신호를 분리한다. 분리된 신호는 표적의 이동에 의한 매크로 도플러 성분이 제거되고 마이크로-도플러 성분만 남게 되며, 이에 STFT(Short-Time Fourier Transform)를 적용하여 마이크로-도플러 영상을 생성한다. 표적의 비행에 따른 관측각 변화와 다양한 노이즈 환경에서 데이터를 생성하고, 이를 LeNet-5 합성곱 신경망(CNN, Convolutional neural network)을 이용해 학습 및 구분하였다. 실험 결과, 제안한 방법은 SNR 20dB 환경에서 99.98%, SNR 5dB 환경에서 91.13%의 구분 정확도를 달성하였다.

Abstract

Distinguishing warheads and decoys is challenging when the multi-target signals exist within a single radar beam. Recently, micro-Doppler signatures generated by target-specific micro-motions have emerged as a promising classification method. Assuming warheads exhibit nutation and decoys exhibit tumbling, we separated multi-target signals using the scattering center extraction algorithm, Hough transform, and least squares method. This process isolates the micro-Doppler components by removing macro-motion Doppler effects. We transformed these signals into 2D images via STFT and classified them using a modified LeNet-5 CNN. As a result, our CNN achieved 99.98% accuracy at SNR 20dB and 91.13% at SNR 5dB.

Keywords

warhead, decoys, nutation, tumbling, micro-Doppler, classification

* 삼성SDI MES그룹 선임연구원

- ORCID: <https://orcid.org/0000-0003-4945-8672>

** 한남대학교 전기전자공학과 교수(교신저자)

- ORCID: <https://orcid.org/0000-0002-8210-0843>

• Received: Apr. 22, 2026, Revised: Jun. 02, 2026, Accepted: Jun. 05, 2026

• Corresponding Author: In-Sik Choi

Dept. of Electrical and Electronic Engineering, Hannam University, 70 Hannam-ro, Daeduk-gu, Daejeon, 34430, Korea

Tel.: +82-42-629-8568, Email: recog@hnu.kr

1. 서 론

레이더는 전자기파를 송신하고 수신함으로써 원거리의 표적을 감지하고 위치를 파악하는 핵심 센서이다[1]. 특히 탄도미사일 방어체계 중 하나인 종말 고고도 지역 방어(THAAD, Terminal High Altitude Area Defense) 레이더의 경우, 그 감지 거리가 최대 1,500km에 이를 정도로 광범위한 영역을 감시한다[2]. 일반적으로 탄도미사일의 비행 경로는 발사 후 추진체와 분리되는 부스트 페이즈, 대기권 밖 고도에서 중력의 영향으로 비행하는 미드코스 페이즈, 그리고 대기권에 재진입하여 낙하하는 터미널 페이즈의 3단계로 구분된다.

미드코스 페이즈에서는 탄두의 생존성을 높이기 위해 다수의 기만체(Decoy)가 함께 운용되며, 각 단계마다 분리된 추진체 조각이나 기만체 등 탄두 추적을 방해하는 요소들이 다수 존재한다. 이러한 방해 표적들은 레이더 자원 관리의 효율성을 저하시키고 요격 미사일 자원을 낭비하게 하므로, 효과적인 방어를 위해서는 탄두와 기만체를 정확히 구분하는 기술이 필수적이다[3].

표적의 미세한 움직임에 의해 발생하는 도플러 신호인 마이크로-도플러(Micro-Doppler)는 탄두와 기만체를 구분하는 중요한 특성벡터가 된다[4]. 기존에는 미세운동 모델을 기반으로 시간-주파수 영상에서 도플러 변화를 분석하거나, 미세운동하는 표적의 수신 신호로부터 5개의 특성 벡터를 추출하여 표적을 구분하는 연구가 진행되었다[5]. 또한, 동적 레이더 반사 면적(Dynamic radar cross section) 데이터와 RCSnet을 이용한 표적 구분 연구[6], 고해상도 거리 프로파일(HRRP, High Resolution Range Profile)에 라돈 변환(Radon transform) 및 k-NN(k-Nearest Neighbour) 구분기를 적용하는 방식[7] 등 다양한 시도가 있었다. 최근에는 드론이나 사람의 활동을 구분하기 위해 마이크로-도플러 통합 영상에 합성곱 신경망(CNN, Convolutional neural network)을 적용하는 딥러닝 기반 연구도 활발히 이루어지고 있다.

다표적 신호를 분리하는 연구 중에는 허프변환(Hough transform)을 이용하여 거리 프로파일(RP, Range Profile) 상에서 선형 궤적으로 움직이는 다표적 신호를 분리하는 방법이 제안된 바 있다[8]. 그

러나 이 방식은 시간에 따른 표적의 비행 궤적이 비선형적일 경우 거리 보상이 제대로 이루어지지 않아 신호 분리 성능이 저하되는 한계가 존재한다.

본 논문에서는 이러한 기존의 한계를 극복하기 위해, 비선형적 궤적에 대해서도 정밀한 거리 보상이 가능하도록 알고리즘을 개선하여 다표적 신호를 효과적으로 분리하는 방법을 제안한다. 제안하는 방법은 분리된 신호로부터 각 표적별 마이크로-도플러 영상을 생성하고, 이를 수정된 LeNet-5 기반의 CNN에 입력하여 탄두와 기만체를 성공적으로 구분하는 전체 프로세스를 포함한다.

II. 표적별 마이크로-도플러 영상 획득 방법

2.1 다표적 신호 생성

미세운동하는 다표적 신호를 획득하기 위해서 그림 1과 같은 절차를 거쳤다.




그림 1. 다표적 신호 생성 블록도

Fig. 1. Block diagram for obtaining multi-target signals

표적이 비행하는 동안 형상이 변하지 않는 강체라고 가정하였기 때문에 표적으로부터 메쉬를 생성하고 메쉬를 이루는 점들에 대해서 오일러 회전 행렬을 이용하여 미세운동을 구현하고 3차원 공간상에서 평행이동을 이용하여 표적의 비행상황을 구현

하였다. 이때 시간 t_p 에 따른 탄두와 기만체의 미세 운동은 각각 그림 2 및 그림 3과 같다[5][8][9]. θ_{sp} 는 spinning의 회전 각도, θ_{pr} 은 precession의 회전 각도, ϕ_{pr} 은 precession의 기울기각, θ_{co} 는 coning의 회전 각도, ϕ_{co} 은 coning의 기울기 각, θ_{tu} 는 tumbling의 회전 각도를 의미한다.




그림 2. 탄두의 미세운동[9]
Fig. 2. Micro-motion of warhead[9]




그림 3. 기만체의 미세운동[9]
Fig. 3. Micro-motion of decoys[9]

여기서 t_p 는 p 번째 시간을 의미한다. p 는 1부터 P 까지 존재하며 시간에 대한 인덱스를 의미한다. 본 논문에서는 관측시간은 2 [s], PRF는 600 [Hz]이므로 $P=1200$ 으로 설정되었다. 이후 3차원 공간상에서 평행이동을 하고 표적별 메쉬들을 같은 공간에 더 함으로써 각 시간의 통합 메쉬를 획득할 수 있다. 이렇게 획득한 통합 메쉬들에 PO 기법을 적용하여 RCS를 계산한 후, 시간의 순서로 배열하면 동적 RCS를 획득할 수 있다.

2.2 표적별 신호 분리

미세운동하는 다표적 수신신호로부터 시간-거리 프로파일을 생성하면 그림 4와 같은 영상을 획득할 수 있다.




그림 4. 다표적 신호의 시간-거리 프로파일
Fig. 4. Time-range profile for multi-target signal

이러한 시간-거리 프로파일에서 고해상도 산란점 추출 알고리즘[9]을 이용하여 산란점을 추출하면 그림 5와 같은 결과를 얻을 수 있다.




그림 5. 추출한 산란점의 시간-거리 프로파일
Fig. 5. Time-range profile for extracted scattering centers

이렇게 얻은 산란점을 표적별로 분류하기 위해서 표적들의 초기 궤적이 필요하다. 초기 궤적은 허프 변환을 이용하여 획득할 수 있다[6]. 그림 6은 허프 변환으로 획득한 표적의 초기궤적과 실제 산란점의 거리 간의 오차 그래프의 예이다. 이때, 그림 6에서 동그라미로 표시한 부분의 오차는 표적의 궤적이 겹치기 때문에 산란점 추출과정에서 산란점이 잘못

추출되거나 다른 표적의 산란점을 가져오기 때문에 생기는 오차이다. 그림 6과 같이 오차가 존재하는 경우 표적의 마이크로-도플러 영상을 획득하면 미세 운동에 의한 마이크로-도플러 성분뿐만 아니라 거동에 의한 도플러 성분도 포함되어 있다. 이러한 성분을 제거하기 위해서 산란점과 초기궤적간의 거리오차가 거리해상도 2배 이내인 산란점들에 대해 최소자승법을 이용하여 보다 정확한 이동궤적을 획득한다. 그림 7은 최소자승법을 추가로 적용하여 획득한 이동궤적과 산란점의 거리 오차 그래프의 예이다.




그림 6. 허프변환으로 구한 궤적과 산란점의 거리 오차[9]
Fig. 6. Range error between trajectory of Hough transform and scattering centers[9]




그림 7. 최소자승법으로 구한 궤적과 산란점의 거리 오차[9]
Fig. 7. Range error between trajectory of least square method and scattering centers[9]

그림 7과 그림 6을 비교해보면 최소자승법을 추가적으로 적용하였을 때 보다 정확한 궤적이 구해짐을 확인할 수 있다. 이렇게 구한 궤적을 이용하여 표적별 산란점 그룹에 대해 거리를 보상하면 그림 8과 같은 마이크로-도플러 영상을 획득할 수 있다.

그림 8에서 사각형으로 표시한 부분은 제안한 방법을 적용하더라도 남아 있는 앞에서 언급한 잘못된 추출된 산란점에 의해 생긴 노이즈이다.




그림 8. 제안한 기법으로 획득한 마이크로-도플러 영상
Fig. 8. Micro-Doppler image obtained by proposed method

III. CNN 구분기 설계 및 학습

표적 구분 실험을 위해서는 다양한 구분기를 사용할 수 있지만, 2차원 영상을 특성벡터로 이용하는 경우에 가장 적합한 구분기로 CNN 구분기[6]가 많이 이용되므로 본 논문에서는 LeNet-5를 수정하여 마이크로-도플러 영상으로 표적을 구분하는 CNN을 만들었다. 본 논문에서 사용한 CNN의 구조는 그림 9와 같다. 그림 9의 ①은 첫 번째 컨볼루션 층으로써 28×28 컬러영상을 입력받게 된다. 이러한 컬러 영상에 크기가 3×3 인 필터 8개를 적용하여 특성 맵(feature map) 영상을 얻는다. 이때, padding 1칸, stride 1칸, 활성화 함수는 ReLU 함수를 사용하였다. 그림 9의 ②는 평균 Pooling을 사용하였으며 크기는 2×2 , stride는 2칸으로 설정하였다. 그림 9의 ③은 5×5 필터 16개를 사용하였다. padding은 2칸이며, stride는 1칸, 활성화 함수는 ReLU를 사용하였다. 그림 9의 ④는 평균 Pooling을 사용하였으며 크기는 2×2 , stride는 2칸으로 설정하였다. 그림 9의 ⑤는 2차원 영상을 1차원 벡터로 바꿔주는 레이어이며, 그림 9의 ⑥은 활성화 함수로 ReLU 함수를 사용하였다. 그림 9의 ⑦은 활성화 함수로 시그모이드 함수를 사용하였으며, 출력은 구분하는 표적의 그룹이 탄두와 기만체이기 때문에 2개 표적에 대한 구분 결과를 출력하도록 설계하였다.




그림 9. Lenet-5 기반의 CNN 구조
Fig. 9. CNN structure based on Lenet-5




그림 10. CNN 학습을 위한 동적 RCS 획득 각도
(a) 탄두 (b) 기만체 [9]

Fig. 10. Dynamic RCS acquisition angle for CNN training
(a) Warhead (b) Decoy [9]

CNN에 학습에 사용한 데이터는 그림 10과 같이 제자리에서 미세 운동하는 표적으로부터 다양한 관측각에 대해서 동적 RCS 신호를 획득하였다. 그림 11에서 획득한 수신 신호에 STFT 기법을 이용하여 CNN 학습에 필요한 마이크로-도플러 영상을 만들었다. 그림 11(a)는 고각 30°, 방위각 60°에서의 탄두에 대한 마이크로-도플러 영상이며, 그림 11(b)는 기만체에 대한 영상이다.




그림 11. 탄두와 기만체의 마이크로-도플러 영상
(a) 탄두 (b) 기만체

Fig. 11. Micro-Doppler image of warhead and decoy (a) Warhead (b) Decoy

CNN 학습에 필요한 충분한 영상을 확보하기 위해서 획득한 동적 RCS 데이터에 SNR 20dB, 15dB, 10dB, 5dB의 AWGN (additive white gaussian noise)를 추가하여 잡음을 가진 마이크로-도플러 영상을 만들었다. 이를 총 5번 수행하여 학습용 데이터로 398,520개의 영상을 확보하였다. 총 398,520개의 데이터 중 70%인 278,964개의 영상을 이용하여 학습하고, 나머지 30%의 영상을 평가(validation)용으로 이용하였다.

IV. 표적 구분 결과

학습된 CNN 구분기를 이용하여 다양한 노이즈 환경에서 표적 구분 실험을 진행하였다. 표적 구분 결과를 확인하기 위한 테스트 데이터는 SNR별로 12,300개씩을 획득하였다. 12,300개의 영상은 제안한 방법으로 추출한 탄두의 마이크로-도플러 영상 6150개, 기만체의 마이크로-도플러 영상 6150개로 이루어져 있다.

그림 12는 SNR 20dB에서 제안한 표적 분리 기

법을 이용하여 분리한 신호를 이용하여 획득한 마이크로-도플러 영상을 보여준다. 그림 8과 같이 잘못 추출된 산란점에 신호 성분들이 나타나고 있지만, 그림 11과 매우 유사한 영상이 얻어짐을 확인할 수 있다.




그림 12. SNR 20dB에서 제안한 기법을 적용해 획득한 마이크로-도플러 영상 (a) 탄두 (b) 기만체
Fig. 12. Micro-Doppler image obtained by proposed method at SNR 20 dB (a) Warhead (b) Decoy

표 1은 다양한 노이즈 환경에서 CNN을 이용한 구분결과를 혼동행렬로 나타내었다. SNR 5dB 환경에서도 표적의 구분 확률이 91.13%, SNR 10 dB에서 98.77%, SNR 20 dB에서는 99.98%의 구분 확률을 나타내어서 제안하는 탄두 및 기만체 구분 기법이 매우 잘 동작함을 확인하였다.

표 1. SNR별 표적 구분 결과[9]
Table 1. Target classification result by SNR[9]

SNR	Output		Decoy	Warhead
	Input			
15dB	Decoy	100%	0%	
	Warhead	0.05%	99.95%	
10dB	Decoy	100%	0%	
	Warhead	2.46%	97.54%	
5dB	Decoy	89.82%	10.18%	
	Warhead	7.56%	92.44%	

V. 결론 및 향후 과제

본 논문에서는 단일 레이더 빔 내에 탄두와 기만체가 혼재되어 비행하는 다표적 환경에서, 각 표적의 신호를 효과적으로 분리하고 구분하는 딥러닝 기반의 알고리즘을 제안하였다. 산란점 추출 알고리

즘, 허프변환, 그리고 최소자승법을 결합하여 표적의 비선형적인 병진 운동 성분을 정밀하게 보상하였으며, 이로부터 순수한 미세운동 특성만을 담은 마이크로-도플러 영상을 추출하였다. 추출된 영상을 다양한 관측 각도와 SNR이 고려된 대규모 데이터셋으로 구성하고, LeNet-5 기반의 CNN에 학습시킨 결과 SNR 5dB의 열악한 환경에서도 약 91.13%의 안정적인 표적 구분율을 달성할 수 있음을 확인하였다. 본 연구 결과는 향후 탄도미사일 방어체계의 자원 효율성 향상과 요격 확률 증대에 기여할 수 있을 것으로 기대된다.

Acknowledgement

본 논문은 제1저자인 김유진 저자의 한남대학교 석사학위논문(탄두와 기만체가 혼재된 상황에서의 다표적 분리 및 구분[9])을 수정/보완하여 작성한 것임.

References

- [1] M. I. Skolnik, Introduction to RADAR systems: 3rd edition, McGraw-Hill, 2001.
- [2] I. S. Choi, "Technology Trends and Analysis of Long-range Ballistic Missile Detection Radar", Korean Institute of Information Technology Magazine, Vol. 17, No. 1, pp. 55-61, Jun. 2019.
- [3] J. Kim, Y. Kwon, and K. H. Lee, "Analysis of Considerations of the BMD System Construction Depending on the Characteristics of Ballistic Missiles Threat", Korean Journal of Military Art and Science, Vol. 72, No. 1, pp. 1-29, Feb. 2016. <https://doi.org/10.31066/kjmas.2016.72.1.001>
- [4] V. C. Chen, Fayin Li, Shen-Shyang Ho, and H. Wechsler, "Micro-Doppler effect in radar: phenomenon, model, and simulation study", IEEE Transactions on Aerospace and Electronic Systems, Vol. 42, No. 1, pp. 2-21, Jan. 2006. <https://doi.org/10.1109/TAES.2006.1603402>.
- [5] I. O. Choi, S. H. Park, M. Kim, K.-B. Kang, and

- K. T. Kim, "Efficient Discrimination of Ballistic Targets with Micromotions", IEEE Transactions on Aerospace and Electronic Systems, pp. 1-1, Jul. 2019. <https://doi.org/10.1109/TAES.2019.2928611>.
- [6] J. Chen, S. Xu, and Z. Chen, "Convolutional neural network for classifying space target of the same shape by using RCS time series", IET Radar, Sonar & Navigation, Vol. 12, No. 11, pp. 1268-1275, Nov. 2018. <https://doi.org/10.1049/iet-rsn.2018.5237>.
- [7] A. R. Persico, C. Ilioudis, C. Clemente, and J. Soraghan, "Novel Approach for Ballistic Targets Classification from HRRP Frame", 2017 Sensor Signal Processing for Defence Conference (SSPD), London, UK, pp. 1-5, Dec. 2017. <https://doi.org/10.1109/SSPD.2017.8233248>.
- [8] Y. J. Kim, Y. J. Choi, and I. S. Choi, "Separation of Dynamic RCS using Hough Transform in Multi-target Environment", The Journal of Korean Institute of Information Technology, Vol. 17, No. 9, pp. 91-97, Sep. 2019. <https://doi.org/10.14801/jkiit.2019.17.9.91>.
- [9] Y.-J. Kim, "Multi-target separation and classification in the mixed situation of warheads and decoys", Master thesis, Hannam University, Feb. 2000.

최 인 식 (In-Sik Choi)



1998년 2월 : 경북대학교
전자공학과(공학사)
2000년 2월 : POSTECH
전자전기공학과(공학석사)
2003년 2월 : POSTECH
전자전기공학과(공학박사)
2003년 4월 ~ 2004년 1월 :

LG전자 선임연구원

2004년 2월 ~ 2007년 2월 : 국방과학연구소 선임연구원
2007년 3월 ~ 현재 : 한남대학교 전기전자공학과 교수
관심분야 : RADAR 신호처리, RADAR 시스템 설계,
RCS 해석 및 분석, EMI/EMC 해석

저자소개

김 유 진 (Yu-Jin Kim)



표적인식

2018년 2월 : 한남대학교
전자공학과(공학사)
2020년 2월 : 한남대학교
전기전자공학과(공학석사)
2023년 8월~ 현재 : 삼성SDI MES
그룹 선임연구원
관심분야 : 레이더 신호처리,