

ResNet/SVM 기반 GNSS 재밍 식별 기법

유승수*, 유재덕*, 허소은**, 김선용^o

ResNet/SVM-Based GNSS Jamming Classification Scheme

Seungsoo Yoo*, Jaeduk Yoo*, Soeun Heo**,
Sun Yong Kim^o

요약

본 논문에서는 대표적인 전이학습(transfer learning) 방법 가운데 하나인 ResNet (Residual Neural Network)으로 GNSS (Global Navigation Satellite System) 단순 재밍의 특징(feature)을 추출하고, SVM (Supported Vector Machine)으로 6가지 재밍 중 하나의 재밍을 식별하는 GNSS 재밍 식별 기법을 제안하고, 모의실험을 통해 그 성능을 보인다. ResNet은 사용하는 처리 계층의 깊이에 따라 구분하는데, 본 논문에서는 18, 50, 101 계층을 사용하는 ResNet-18/50/101을 사용해 특징을 추출하고, 10 연결 교차검증한 SVM으로 식별할 때, GNSS 재밍 식별 정확도는 각각 96.33%, 97.25%, 97.50%로 처리 계층이 깊어질수록 식별 정확도가 향상됨을 확인했다.

Key Words : GNSS, Jamming, Classification, Transfer Learning, ResNet, SVM

ABSTRACT

In this paper, we propose a jamming classification scheme that extracts the features of Global Navigation Satellite System (GNSS) simple jamming with Residual Neural Network (ResNet) which is one

of the representative transfer learning methods, classifies it as one of the six jamming with Supported Vector Machine (SVM), and shows its performance via simulation. ResNet is classified according to the depth of the layer used, and in this paper, ResNet using 18, 50, and 101 layers was constructed, and the accuracy for extracting features using ResNet-18/50/101 and classifying them as SVMs are 96.33%, 97.25%, and 97.50%, respectively, indicating that the accuracy improves as the layer gets deeper.

I. 서론

GNSS (Global Navigation Satellite System)는 지상에 위치한 수신기의 PNT (Position, Navigation, and Timing) 정보를 실시간으로 얻을 수 있는 체계로서, 사회 전반에 널리 사용되고 있다. GNSS의 사용 증가와 함께 GNSS 신호 대역에 고출력 잡음을 추가하여 GNSS 수신기의 PNT 정보 추출을 방해하거나, 무력화시킬 수 있는 재밍 위협이 증가하고 있다. 재밍에 대응하는 방법 가운데 하나는 재밍 검출 및 식별 방법이다. 재밍 검출 및 식별 방법은 통계적 신호처리에 기반한 방법과 기계학습에 기반한 방법이 있다^[1]. 본 논문에서는 재밍 식별을 위한 기계학습 방법 가운데 대표적인 전이학습 방법인 ResNet (Residual Neural Network)을 사용해 재밍의 특징(feature)을 추출하고, 10 연결 교차검증(10-fold cross validation)한 SVM (Support Vector Machine)으로 재밍이 없는 경우를 포함한 총 6가지 재밍을 식별하는 재밍 식별 기법을 제안하고, 모의실험을 통해 그 성능을 분석한다.

II. 제안한 전이학습기반 GNSS 재밍식별기법

인공신경망은 컴퓨터 기반 인지 및 식별 분야에서 정확도를 사람과 유사한 수준 또는 그 이상으로 크게 향상한 기법이다. 그러나, 인공신경망의 처리 계층이

* 본 연구는 과학기술정보통신부 및 정보통신기획평가원의 대학ICT연구센터사업의 연구결과로 수행되었습니다. (IITP-2023-RS-2023-00258639)

• First Author : (0000-0002-8648-1540) Konkuk University, Department of Electrical and Electronics Engineering, kelvin@konkuk.ac.kr, 조교수, 정회원

◦ Corresponding Author : (0000-0002-4192-2146) Konkuk University, Department of Electrical and Electronics Engineering, kimsy@konkuk.ac.kr, 정교수, 종신회원

* (0009-0002-3095-2224) Konkuk University Department of Electronics Engineering, woejr120@konkuk.ac.kr, 학생(학사)

** (0009-0009-4137-3245) Konkuk University, Department of Electrical and Electronics Engineering, xoeu0@konkuk.ac.kr, 학생(학사)
 논문번호 : 202310-109-B-LU, Received October 23, 2023; Revised October 30, 2023; Accepted October 30, 2023

커지면서 기울기 소실 문제(vanishing gradient problem)가 발생하여 오류가 증가하였으며, 이를 해결하기 위해 이전 입력값을 참조할 수 있게 만든 신경망이 ResNet이다. ResNet은 기본적으로 VGG (Very deep convolutional neural network)-19 구조 사이사이에 처리 계층을 추가해 계층 깊이를 깊게 만들고, 그림 1과 같이 계층 간 지름길(shortcut)을 추가해 오류 입력을 줄였다. 일반적으로 ResNet은 계층 깊이에 따라 18 계층으로 구성하는 경우, ResNet-18처럼 적는다. 일반적으로 ResNet의 처리 계층이 깊은 경우, 식별 정확도가 향상된다⁵⁾.

본 논문에서는 DME (Distance Measure Equipment), AM (Amplitude Modulation)/CW (Continuous-Wave), FM (Frequency Modulation), Chirp, NB (Narrow-Band noise) 재밍 식별을 위한 ResNet과 SVM을 이용한 전이 학습 기반 GNSS 재밍 식별 기법을 제안한다. 고려한 GNSS 재밍은 학습 및

표 1. ResNet의 처리 계층 수에 따른 처리 계층 구성
Table. 1. Layer configuration according to the number of processing layers in ResNet

layer name	output size	18-layer	50-layer	101-layer
conv1	112x112	7*7, 64, stride 2		
con2_x	56x56	3*3 max pool, stride 2		
		$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 2$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$
con2_x	28x28	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 2$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 3$
con2_x	14x14	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 2$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 3$
con2_x	7x7	$\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 2$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$
	1x1	average pool, 1000-d fc, softmax		
FLOPs		1.8×10^9	3.8×10^9	7.6×10^9

성능 평가를 위해 그림 2처럼 성상도(constellation, 상단좌측), 스펙트로그램(spectrogram, 상단우측), 히스토그램 (histogram, 하단우측), PSD (Power Spectral Density, 하단좌측) 이미지를 결합한 이미지 집합을 사용하여, 이미 학습된 ResNet로 특징을 추출하고, 10 연 접 교차 검증한 SVM으로 재밍이 없는 경우를 포함한 총 6가지 재밍 상황을 식별할 수 있는 기법을 제안한다. 제안한 기법의 재밍별 특징 추출을 위해 사용한 ResNet의 처리 계층 수에 따른 처리 계층 구성은 표 1과 같다.

III. 성능 분석 및 결론

고려한 6개 재밍에 대해 각각 1,000개씩 데이터 집합을 생성하고, 이 가운데 800개는 학습과 검증에 사용하고, 200개에 대해 실험한 다음 ResNet-18/50/101을 사용해 특징을 추출하고, SVM으로 판정했을 때 정확도 (accuracy)를 각각 그림 3, 그림 4, 그림 5와 같이 혼동행렬(confusion matrix)로 정리하였다. ResNet-18/50/101 순으로 특징을 추출했을 때, 평균 식별 정확도는 그림 3-5처럼 96.33%, 97.25%, 97.50%이며, ResNet-18에 비해 ResNet-50은 약 0.92%p, ResNet-101은 약 1.17%p 정확도가 향상됨을 확인할 수 있다. DME, NB, No Jam, AM, Chirp, FM 재밍 순으로 ResNet-18로 특징을 추출했을 때 재밍 식별도는 각각 100.0%, 93.0%, 98.5%, 96.0%, 93.5%, 97.0%이며, ResNet-50은 각각 100.0%, 92.5%, 100.0%, 100.0%, 92.5%, 98.5%이며, ResNet-101은 각각 100.0%, 94.0%, 100.0%, 98.5%, 94.5%, 98.0%이다.

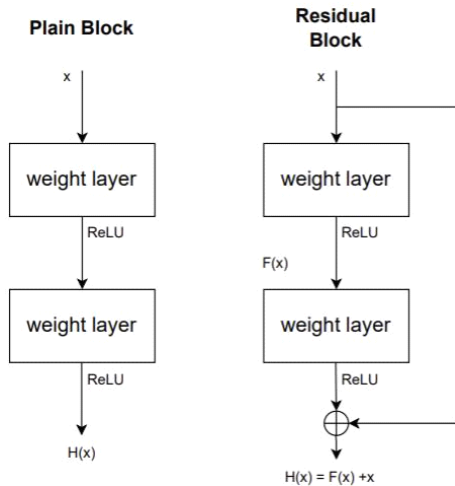


그림 1. 기존 신경망 구조와 ResNet 구조
Fig. 1. Configurations of plain and residual blocks

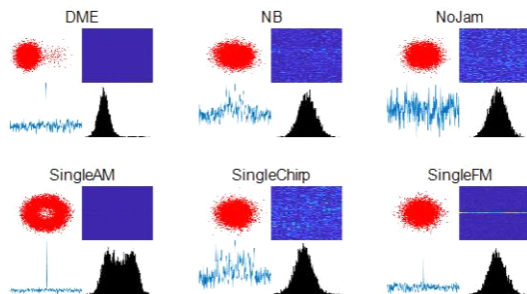


그림 2. 고려한 재밍별 이미지 집합의 예
Fig. 2. Examples of image sets by jamming considered

표 2. ResNet의 처리 계층 수에 따른 F1 점수
Table. 2. F1 scores according to the number of processing layers in ResNet

	ResNet-18	ResNet-50	ResNet-101
DME	1.0000	1.0000	1.0000
NB	0.9323	0.9320	0.9471
No Jam.	0.9850	0.9901	0.9950
AM	0.9648	0.9926	0.9825
Chirp	0.9327	0.9296	0.9474
FM	0.9652	0.9899	0.9776




그림 3. ResNet-18의 혼동행렬
Fig. 3. Confusion Matrix of ResNet-18




그림 4. ResNet-50의 혼동행렬
Fig. 4. Confusion Matrix of ResNet-50

실험 정밀도(precision)와 재현율(recall)의 조화평균으로 계산되며 혼동행렬에서 예측의 정확도를 측정하는 척도로 활용되는 0과 1 사이의 값으로 1에 가까울수록 우수한 성능으로 평가할 수 있는 요소는 F1 점수이며,

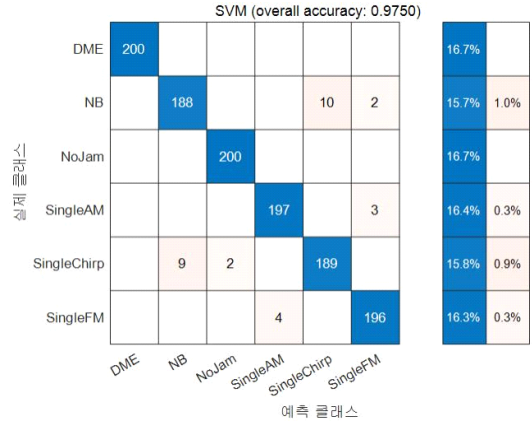


그림 5. ResNet-101의 혼동행렬
Fig. 5. Confusion Matrix of ResNet-101

이는 표 2와 같다. 표 2처럼 DME는 시계열 재밍으로서 완벽히 식별할 수 있으며, 주파수 변화가 큰 Chirp가 가장 식별하기 어렵다. ResNet-101로 특징을 추출한 경우 Chirp의 F1 점수는 0.9474로 다른 방법보다 가장 높다. ResNet은 계층 깊이를 유연하게 조정할 수 있는 구조를 갖고 있어 복잡한 특징을 학습하는 경우 처리 계층을 깊게 구성하여 정확도를 높일 수 있다. 다음에는 Chirp 재밍의 식별 성능이 높은 기법에 대해 집중적으로 연구할 예정이다.

References

[1] R. M. Ferre, A. de la Fuente, and E. S. Lohan, "Jammer classification in GNSS bands via machine learning algorithms," *Sensors*, vol. 19, no. 22, pp. 1-15, Nov. 2019. (<https://doi.org/10.3390/s19224841>)

[2] C. J. Swinney and J. C. Woods, "GNSS jamming classification via CNN, transfer learning & the novel concatenation of signal representations," in *Proc. 2021 Int. Conf. Cyber Situational Awareness and Assessment (CyberSA)*, pp. 1-9, Dublin, Ireland, Jun. 2021. (<https://doi.org/10.1109/CyberSA52016.2021.9478250>)

[3] H. B. Kwon, S. Yoo, and S. Y. Kim, "Transfer learning-based GNSS jamming classification technique using ResNet-18 and SVM," in *Proc. KICS Fall Conf.*, On-Line, Gyeongju, Korea, Nov. 2022.

(<https://www.dbpia.co.kr/pdf/pdfView.do?nodeId=NODE11196988>)

- [4] J. Shin, S. Yoo, and S. Y. Kim, "Transfer learning-based GNSS jamming classification technique using ResNet-50 and SVM," in *Proc. KICS Summer Conf.*, Jeju, Korea, Jun. 2023.

(<https://www.dbpia.co.kr/pdf/pdfView.do?nodeId=NODE11487837>)

- [5] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," in *Proc. 2016 IEEE Conf. CVPR*, pp. 770-778, Las Vegas, NV, Jun. 2016.

(<https://doi.org/10.48550/arXiv.1512.03385>)