

실제 GPS L1 C/A 신호에 대한 기계학습 기반 재밍 신호 식별 기법

유승수*, 신천식*, 김선용^o

Machine Learning-Based Jamming Classification Scheme for Real GPS L1 C/A Signal

Seungsoo Yoo*, Cheon Sig Sin*,
Sun Yong Kim^o

요약

본 논문에서는 실제 GPS L1 C/A (Coarse/Acquisition) 신호와 보유한 실험장비로 실시간 발생시킨 5개의 재밍 신호를 효과적으로 식별할 수 있는 대표적 기계학습 모형인 CNN (Convolution Neural Network) 기반 재밍 신호 식별 기법을 제안한다. 실험 결과 기존 기법의 최고 평균 식별 정확도는 95.29%인데 반해 제안한 기법은 98.23%로서 기존 기법 대비 2.94%P 높은 식별 정확도를 보인다. 또한 기존 기법은 재밍 신호 별 식별 성능 차이가 최대 9.66%P인데 반해 제안한 기법은 최대 3.03%P로서 더 강인한 재밍 식별 기법이다.

Key Words : GPS, Jamming, Machine Learning, SVN, CNN, Classification

ABSTRACT

In this paper, we propose a CNN (Convolution Neural Network)-based jamming signal classification scheme, which is a representative machine learning

model that can effectively classify real GPS L1 C/A (Coarse/Acquisition) signal and five jamming signals generated in real time with our own experimental equipment. As a result of the experiment, the highest average classification accuracy of the conventional scheme is 95.29%, while the proposed scheme is 98.23%, showing a 2.94%P higher classification accuracy than the conventional scheme. In addition, the conventional scheme has a maximum difference of 9.66%P in classification performance for each jamming signal, whereas the proposed method is a more robust jamming classification scheme with a maximum of 3.03%P.

I. 서론

GPS (Global Positioning System) 신호는 의도적이거나 비의도적인 무선 전파 간섭에 매우 취약하며, 간섭 신호로 인해 큰 측위 오차가 발생하거나 수신기가 오작동할 수 있다. 간섭 신호 중 의도적 간섭 신호를 재밍 신호라고도 부른다^{1,2}. 본 논문에서는 간섭완화 기법 중 재밍 신호 식별 기법에 초점을 맞춘다.

대표적인 기계학습 기반 재밍 식별은 [3]에서 제안한 SVM (Supported Vector Machine) 기반 식별 기법과 CNN (Convolution Neural Network) 기반 식별 기법, 그리고 이를 개선한 [4]에서 제안한 향상된 CNN 기반 식별 기법이다. [3]과 [4]에서 고려한 식별 신호는 ▷일반 GPS 신호 (No Jam.), ▷DME(Distance Measurement Equipment)-like 재밍, ▷NB (Narrow-Band noise) 재밍, ▷AM/CW (Amplitude Modulation/Continuous Wave) 재밍, ▷Chirp 재밍, ▷FM (Frequency Modulation) 재밍 신호이다. [3]에서는 수신한 신호를 스펙트로그램 (spectrogram)으로 변환하고, 이에 대한 이미지 처리를 통해 각 신호를 식별하였으며, [4]에서는 별도의 전처리 없이 수신한 신호를 그대로 학습하고, 식별하였다. 그러나 [3]과 [4]에서는 모두 컴퓨터에서 모형화

* 본 연구 논문은 과학기술정보통신부 및 정보통신기획평가원의 출연금으로 수행하고 있는 한국전자통신연구원 디지털 신호처리기반 GPS 전파교란 방어기술 개발 (2020-0-01629) 위탁연구과제의 연구결과입니다. 본 연구 논문의 내용을 발표할 때는 반드시 한국전자통신연구원 디지털 신호처리기반 GPS 전파교란 방어기술 개발 [2020-0-01629] 위탁연구과제로 수행한 연구결과임을 밝혀야 합니다.

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

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

* (ORCID:0000-0003-3192-5543)Electronics and Telecommunications Research Institute, cssin@etri.re.kr, 책임연구원, 정회원
논문번호 : 202109-234-A-LU, Received September 9, 2021; Revised September 12, 2021; Accepted September 12, 2021

한 모의 신호만 활용하여 설계한 모형을 학습하고, 그 성능을 확인하였다. 본 논문에서는 민간용 GPS 수신기에서 가장 많이 사용하는 실제 GPS L1 C/A (Coarse/Acquisition) 신호와 보유한 실험장비로 실시간 발생시킨 제밍 신호 사용하고, 이에 적합하게 [4]에서 제안한 기법을 보완한 향상된 학습 모형을 구성하고, 실험을 통해 그 성능을 확인한다.

II. 제안한 기법

[3]에서 제안한 기존 기법은 반드시 전처리 필터를 사용해 IF (Intermediate Frequency) 대역으로 표본화된 GPS 신호를 스펙트로그램으로 변환하고, 이를 다시 정방형의 이진 흑백 이미지로 변환하는 전처리 과정을 진행해야 한다. 이로 인해 정보 손실이 발생하며, 최종 이진 흑백 이미지가 차지하는 메모리 공간은 줄일 수 있지만 중간 과정의 메모리는 학습과 실험 과정에 그대로 사용해야 하는 단점을 갖고 있다. [4]에서 이를 개선한 전처리 필터가 필요 없는 향상된 식별 기법을 제안하였다. 그러나 [3]과 [4]에서는 모두 컴퓨터에서 모형화한 모의 신호만 활용하여 설계한 모형을 학습하고, 그 성능을 확인하였다. 본 논문에서는 민간용 GPS 수신기에서 가장 많이 사용하는 실제 GPS L1 C/A 신호와 보유한 실험장비로 실시간 발생시킨 제밍 신호 사용하여 [4]에서 제안한 기법을 보완한 향상된 학습 모형을 다음 그림 1처럼 새로 구성하였다.

그림 1처럼 제안한 모형은 [3]에서 제안한 기존 기법처럼 전처리 필터를 사용하지 않고, 수신한 IF 표본을 직접 사용해 훈련, 검증, 실험을 진행한다. 그림 1처럼 각 은닉층은 2D Convolution-Bias Adder- Batch

Normalization- ReLU-Pooling 층으로 구성되어 있다. 2D Convolution 층에서는 Stride 1을 적용한 2^{l+1} 개의 (1×4) 크기의 커널을 이용한다. 여기서 l 은 입력층 이후 은닉층을 첫째 은닉층으로 설정한 은닉층의 층수다. 이후 편이(bias)를 더하고, 배치 정규화 층에서 크기 64의 미니 배치(mini batch) 연산을 진행하며, 입력된 특징 맵(feature map)의 평균 $E[F_{i,k}]$, 분산 $Var[F_{i,k}]$, 공통 승산 계수 γ , 공통 편이 계수 β 를 얻고, 이를 적용한다. 배치 정규화는 미니 배치 단위의 입력을 평균 0, 분산 1로 정규화하는 구실을 하며, 해당 과정을 통해 이전 계층의 매개변수 변화로 인한 해당 계층의 입력 분포가 바뀌는 현상(internal covariance shift)을 방지할 수 있다. 또한, 공통 승산 계수 γ 와 공통 편이 계수 β 를 추가해 활성화 함수의 비선형성을 유지할 수 있다. 배치 정규화된 특징 맵은 ReLU 층을 통해 활성화된 특징 맵(activated feature map)을 얻는다. 이후 은닉층에 순서에 따라 첫째부터 다섯째 은닉층의 경우 Max Pooling과 Drop-Out 층을 거치며, 여섯째 은닉층의 경우 Average Pooling 층을 거친다. 두 계층 모두 Stride는 4로 설계했으며, 입력된 특징 맵에 Stride 4 연산을 진행하기 위해 적절한 크기의 0삽입(zero-padding)을 진행한다. Max Pooling Window는 (1×4) 크기이며, 입력된 특징 맵의 최댓값을 찾아 해당 위치의 값을 결정한다. Average Pooling Window는 (1×16) 크기이며, 평균값을 구해 해당 위치의 값을 결정한다. Max Pooling과 Drop-Out에서 Drop-Out은 신경망 노드(node) 일부를 무작위로 제거해 학습을 진행하는 기법으로 Over-Fitting 방지를 위해 제안되었으며, 일부 No

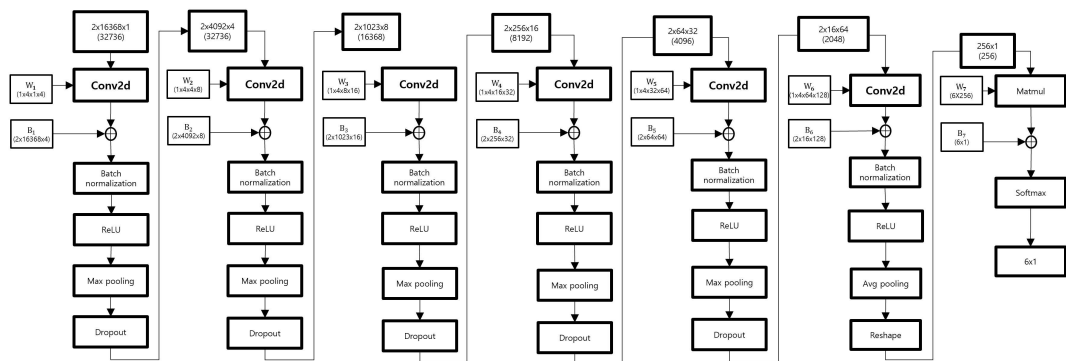


그림 1. 제밍 신호 식별을 위한 제안한 기계학습 모형의 구성도
Fig. 1. Block diagram of proposed machine learning model to classify jamming signals

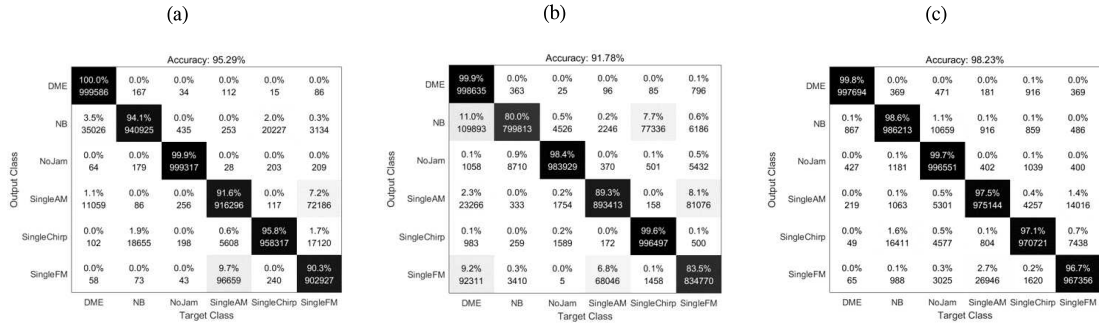


그림 2. 실험을 통해 얻은 여러 재밍에 대한 혼동행렬들: [3]에서 제안한 (a) SVN 및 (b) CNN 기법, (c) 제안한 기법
 Fig. 2. Confusion matrix for various jamming obtained through experiments: (a) SVN and (b) CNN schemes in [3], and (c) proposed scheme in this paper

드를 제거함으로써 중첩되거나 불필요한 특징들이 제거되어 더욱 선명한 특징 맵을 도출한다. 학습 시에는 균등 분포 난수를 적용해 탈락 처리를 진행하고, 시험 시에는 비활성화하도록 설계했다.

III. 실험 결과분석 및 결론

GPS L1 C/A 신호의 표본화 주파수는 40.92 MHz로 설정했다. 데이터 집합은 각 재밍 별 1,000개씩, 총 6,000개로 학습하고, 각 재밍 별 300개씩, 총 1,800개로 검증하고, 각 재밍 별 1,000,000개씩, 총 6,000,000개로 실험하였다. 재밍 대 신호 전력비는 40 - 80 dB 구간에서 균등 확률 분포를 갖는 값으로 재밍 신호를 실시간 생성했다.

본 실험에서 [3]에서 제안한 SVM과 CNN 모델을 그대로 사용했으며, 제안한 기법은 [4]에서 제안한 기법을 실제 신호를 사용해 학습, 검증, 실험을 통해 Max Pooling과 Average Pooling의 하이퍼파라미터를 조정된 기법이다. 실제 신호를 활용했을 때, [3]에서 제안한 기존 기법의 SVM과 CNN의 혼동행렬, 그리고 [4]에서 제안한 모델을 실제 신호에 적합하게 조정된 새로운 CNN 모델의 혼동행렬은 각각 그림 2와 같다. 혼동행렬의 대각 성분이 정확도를 의미하며, No Jam에 대한 정확도는 신호 검출확률이다. 이를 바탕으로 평균 정확도와 재밍 별 정확도를 각각 그림 3(a)와 3(b)처럼 정리할 수 있다.

실험 결과 기존 기법의 최고 평균 식별 정확도는 95.29%인데 반해 제안한 기법은 98.23%로서 기존 기법 대비 2.94%P 높은 식별 정확도를 보인다. 또한 기존 기법은 재밍 신호 별 식별 성능 차이가 최대 9.66%P인데 반해 제안한 기법은 최대 3.03%P로서 더 강한 재밍 식별 기법이다.




그림 3. 실험을 통해 얻은 기존 기법과 제안한 기법의 성능 비교: (a)평균 식별 정확도와 (b) 재밍 별 식별 정확도
 Fig. 3. Comparison of the performance of the proposed scheme with the conventional scheme obtained through experiments: (a) average classification accuracy and (b) classification accuracy by jamming

References

- [1] P. J. G. Teunissen and O. Montenbruck, *Springer Handbook of Global Navigation Satellite Systems*, Springer International Publishing, Cham, Switzerland, 2017.
- [2] J. Lee, H. Lee, and S. Y. Kim, "A feasibility test of the signal detection scheme for GPS L1 C/A signal using deep learning," *J. KICS*, vol. 44, no. 1, pp. 65-67, Jan. 2019.
- [3] 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.
- [4] S. Yoo, "An improved GNSS jamming classification scheme using conventional neural network," *J. Inst. Contr., Robotics and Syst.*, vol. 26, no. 11, pp. 1016-1027, Nov. 2020.