

우주 전파 환경에서 Leaky Integrate-and-Fire 뉴런 기반 Spiking-NN을 이용한 RF 링크 신호 이상 감지 성능 분석

Analysis of RF Signal Anomaly Detection Performance Using Leaky Integrate-and-Fire Neuron-Based Spiking-NN in Space Propagation Environments

이 하 경¹ · 한 정 훈²

Ha-Kyung Lee¹ · Jung-Hoon Han²

요 약

본 논문에서는 우주 전파 환경에서 RF 링크 신호 이상 감지 구조의 성능을 분석한다. ESA 위성 텔레메트리 데이터에 잡음, 신호 손실, 간섭을 단계적으로 추가한 환경을 구성하고, LIF(leaky integrate-and-fire) 뉴런 기반 SNN(spiking neural network) 모델을 적용하여 LSTM 및 1D-CNN 모델과 비교하였다. 실험 결과, 정상 환경에서는 모델 간 성능 차이가 크지 않았으나, 전파 환경 변화가 심화될수록 SNN 구조가 F1-score 기준 가장 낮은 성능 저하율(2.6 %)을 보였으며, LSTM(10.1 %)과 1D-CNN(44.2 %) 대비 우수한 성능을 확인하였다. 이러한 결과는 RF 링크 신호의 이상 감지를 전파 환경 변화에 대한 모델의 강건성 관점에서 해석할 필요성을 시사하며, LIF 뉴런 기반 SNN이 비트 오류율(BER) 관리와 위성 통신 시스템의 운용 가용성 확보를 위한 효과적인 이상 감지 구조임을 제시한다.

Abstract

This study evaluates the RF link anomaly detection under space propagation variations. Noise, signal loss, and interference were progressively added to the European Space Agency (ESA) satellite telemetry data, and the performance of a Leaky Integrate-and-Fire (LIF)-based spiking neural network (SNN) was compared with those of the long short-term memory (LSTM) and 1D-convolutional neural network (CNN) models. While the performance differences were minimal under normal conditions, the SNN showed the smallest F1-score degradation (2.6 %) as environmental variations increased, outperforming LSTM (10.1 %) and 1D-CNN (44.2 %). These results highlight the importance of robustness, and indicate that LIF-based SNN is effective for bit error rate (BER) management and operational availability in satellite communication systems.

Key words: Satellite Telemetry, Anomaly Detection, Spiking Neural Network (SNN)

I. 서 론

우주에서 위성 통신 시스템은 장기간 무인으로 운용되

므로 이상 상황 발생 시 직접 개입이 어렵다. 이에 따라 위성 내부 및 RF 링크 신호를 간접적으로 파악하기 위한 텔레메트리 데이터는 핵심적인 모니터링 수단이다^[1]. 특

한국항공대학교 항공전자정보공학과(Department of Electronic, Telecommunication and Computer Engineering, Korea Aerospace University)

1: 학부생(<https://orcid.org/0009-0005-2400-019X>), 2: 조교수(<https://orcid.org/0000-0002-3721-7700>)

· Manuscript received January 6, 2026 ; Revised January 27, 2026 ; Accepted February 13, 2026. (ID No. 20260106-9S)

· Corresponding Author: Jung-Hoon Han (e-mail: jh.han@kau.ac.kr)

히 RF 링크 이상은 통신 두절 및 임무 실패로 직결될 수 있어 안정적인 이상 감지가 요구된다. 텔레메트리는 다양한 위성 시스템 상태를 포함하지만, 본 논문에서는 RF 링크 신호를 반영하는 다변량 시계열 데이터로 정의한다.

한편 우주 전파 환경에서는 신호의 잡음, 간섭, 감쇠 등 다양한 전파 환경 요인들이 복합적으로 작용하며, 이는 RF 링크 신호의 비정상적인 변화를 유발하는 주요 원인이 된다. 따라서 이러한 전파 환경 변화에서도 이상 감지 모델의 성능이 얼마나 안정적으로 유지되는지가 중요하다. 전통적인 이상 감지 방식의 OOL(out-of-limits)은 신호가 특정 임계값을 벗어나는지로 이상을 판단한다. 그러나 이러한 단순 수치 비교는 매개변수 간 복합적인 상관관계를 반영하지 못해, 유기적인 신호 변화나 미세한 이상 징후를 식별하는 데 한계가 있어 최근 연구에서는 시계열 패턴 학습에 최적화된 딥러닝 기반 이상 감지 구조가 적극적으로 도입되고 있다^[2]. 이에 본 논문에서는 LSTM, ID-CNN 및 SNN 구조를 채택하여 성능을 비교·분석하였다. LSTM 및 CNN 기반 모델은 연속적인 연산 구조에 기반하므로, 급격한 변화가 존재하는 환경에서는 변화 시점에 대한 민감도가 저하되어 이상 감지 성능이 상대적으로 취약할 수 있다^{[3][4]}. 반면, **spiking-NN**은 입력 신호의 발생 시점을 중심으로 정보를 처리하는 이벤트 기반 계산 구조를 갖는다. 여기서 ‘**spiking**’은 뉴런의 막전위가 임계값을 초과할 때만 활성화되는 동작 방식을 의미하며, 스파이크가 발생한 뉴런만이 연산에 참여하게 된다. 이러한 특징은 시간적 변화 패턴이 중요한 RF 링크 신호의 특성과 잘 부합하며, 전파 환경 변화에서도 안정적인 성능을 유지할 수 있다^[5]. 이에 본 논문에서는 LIF(leaky integrate-and-fire) 뉴런 기반 SNN 모델을 RF 링크 신호 이상 감지에 적용하여 기존 모델과의 성능을 비교하고, 전파 환경 변화에 따른 모델의 강건성을 실험적으로 확인함으로써 전파·통신 관점에서 SNN의 유효성을 분석하고자 한다. 본 논문의 구성은 다음과 같다. 제II장에서는 데이터셋 구성과 전처리를 기술하고, 제III장에서는 우주 전파 환경 모델링 및 이상 감지 구조를 설명한다. 제IV장에서는 실험 결과를 제시하고, 제V장에서 성능 평가 및 결론을 도출한다.

II. 데이터셋 및 전처리

본 논문에서는 유럽우주국(ESA, European Space Agency)의 약 14년간 실제 위성 운용 기록이 담긴 위성 텔레메트리 mission 1 데이터셋을 사용하였다^[6]. 동일 서브시스템 및 동일 물리량에 속한 10개 채널을 선택해 입력 벡터로 구성하였으며, Z-score 정규화 후 슬라이딩 윈도우 기반 시계열 샘플을 생성하였다. 학습/검증/시험 데이터를 70/15/15 % 비율로 분할하였으며, 클래스 불균형은 검증 데이터셋의 F1-score를 최대화하는 가중치를 통해 보정하였다.

III. 전파 환경 모델링 및 이상 감지 구조

실제 우주 전파 환경을 모델링하기 위해, 연속적인 잡음, 신호 손실, 순간적인 간섭의 세 가지 유형으로 구분하여 각각 Gaussian noise, dropout, interference로 모사하였다. 변화 강도는 단계적으로 증가시켜 모델별 성능 변화를 평가하였다. 이상 감지 구조에 적용된 LIF 뉴런의 막전위 업데이트는 입력 스파이크의 누적과 누설 효과를 고려한 식 (1)으로 표현된다:

$$V[t] = \beta \cdot V[t-1] + (1-\beta) \cdot I[t] \tag{1}$$

식 (1)과 그림 1에 나타난 LIF 뉴런의 동작 메커니즘에 따라, 이전 시점의 막전위 $V[t-1]$ 은 누설 계수 β 에 의해 감쇠되면서 현재 입력 $I[t]$ 를 누적한다. 이때 본 논문에서는 실수형 데이터를 별도의 변환 없이 입력 전류 $I[t]$ 로 직접 주입하는 **direct encoding** 방식을 사용하였다.




그림 1. LIF 뉴런의 막전위 업데이트 및 스파이크 발생 메커니즘

Fig. 1. Membrane potential update and spike generation mechanism of LIF neuron.

표 1. 모델별 주요 구조 및 세부 설정 파라미터
Table 1. Key structure and detailed parameters by models.

Model	SNN	LSTM	1D-CNN
Features			
Layer	FC+LIF Neurons	1-layer LSTM	2-layer Conv1d
Hidden/filter dimension	64	64	32 (1st) → 64 (2nd)
Feature extraction	Mean firing rate	Last hidden state	Global average pooling
Detailed settings	β : 0.9, Firing threshold: 1.0	Uni-directional	Kernel: 3, Stride: 1, Padding: 1

LIF 뉴런의 누설(leaky) 특성은 저역 통과 필터(LPF)와 유사하게 고주파 잡음을 억제하고, 적분(integration) 과정은 일시적인 신호 손실의 영향을 완화한다. 또한 임계값 기반의 발화(fire) 기제는 미세 노이즈를 차단함으로써, 다양한 전파 환경 변화에서도 안정적인 이상 감지 성능에 기여한다⁵⁾.

SNN과 비교군인 LSTM 및 1D-CNN의 상세 구조는 표 1과 같다. 모든 모델은 10차원의 텔레메트리 데이터를 128 타임 스텝의 윈도우 크기로 입력받으며, 학습 시 Adam 최적화 알고리즘($\eta=10^{-3}$)과 교차 엔트로피 손실 함수를 적용하고, 배치 크기를 128로 설정하는 등 동일한 환경에서 실험을 수행하였다.

그림 2는 표 1의 파라미터를 기반으로 설계된 SNN의




그림 2. LIF 뉴런 기반 SNN 구조
Fig. 2. LIF neuron-based SNN structure.

전체 구조를 시각화한 것이다. 해당 구조는 10차원 입력층, 64개의 LIF 뉴런으로 구성된 단일 은닉층, 정상/이상의 출력층 형태를 가진다. 학습 시에는 스파이크의 미분 불가능 문제를 해결하고자 fast sigmoid 기반의 대리 미분(surrogate gradient) 기법을 적용하였다⁷⁾. 각 모델의 특성에 맞춰 비교군인 LSTM은 내부 Tanh 및 Sigmoid 활성화 함수를 통해 시간적 의존성을 학습하였고, 1D-CNN은 ReLU 활성화 함수와 배치 정규화(batch normalization)를 적용하여 학습의 안정성을 높였다.

IV. 실험 결과 및 성능 평가

성능 평가 지표로는 정밀도(precision)와 재현율(recall)의 조화평균으로 계산되는 F1-score를 사용하였다. 이는 이상 데이터 감지 시 발생할 수 있는 오탐과 미탐을 동시에 반영하여, 데이터 불균형 환경에서 모델의 탐지 신뢰성을 객관적으로 나타낸다. 또한, 전파 환경 변화에 따른 모델의 강건성을 정량화하기 위해 성능 저하율을 정의하였으며, 이는 정상 환경(clean) 대비 F1-score의 감소량을 정규화한 값을 의미한다.

그림 3은 정상 환경(clean) 및 전파 환경 변화에 따른 모델별 F1-score 성능을 나타낸 결과이다. 정상 환경에서 세 모델 간 F1-score 성능 차이가 크지 않았으며, SNN은 상대적으로 적은 학습 파라미터 수(834개)에도 불구하고 LSTM(2,114 및 1D-CNN(19,330개)과 대등한 F1-score(0.6957)를 보였다.




그림 3. 전파 환경 변화에 따른 모델별 F1-score 비교
Fig. 3. Comparison of F1-score for different models under propagation environment.

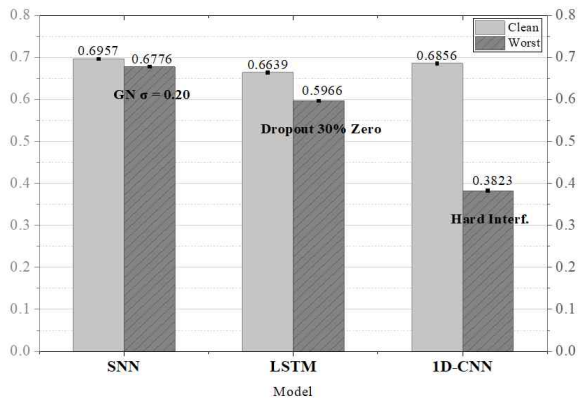


그림 4. 정상 환경과 최대 성능 저하 환경에서의 모델별 F1-score 값 비교

Fig. 4. Comparison of F1-score for different models under clean and maximum degradation environments.

그러나 전파 환경 변화가 심화될수록 모델별 성능 저하 양상은 뚜렷한 차이를 보였으며, SNN은 환경 변화가 심화되더라도 정상 환경 대비 F1-score의 변화가 상대적으로 적게 나타났다. 반면, ID-CNN 모델은 hard interference에서 성능이 급격히 감소하였고, LSTM 모델은 dropout이 심화되는 환경에서 성능 저하가 점진적으로 나타났다.

그림 4와 같이 SNN은 최대 성능 저하율 2.6 %를 기록하며 LSTM(10.1 %)와 ID-CNN(44.2 %) 대비 독보적인 강건성을 보였다. 이는 III장에서의 LIF 뉴런 핵심 동작 기체들이 실제 잡음과 신호 손실 환경에서 유효하게 작용하여, 데이터의 불연속성과 왜곡을 상쇄하였음을 입증한다. 또한, 발화 기체를 통한 필터링은 불필요한 스파이크 생성을 억제하여 전파 환경 변화에 대한 모델의 강건성을 극대화했음을 확인할 수 있다.

V. 결 론

본 논문에서는 우주 전파 환경을 모사한 환경에서 LIF 뉴런 기반 SNN의 RF 링크 신호 이상 감지 성능과 강건성을 분석하고, 이를 LSTM 및 ID-CNN 모델과 비교·평가하였다. 실험 결과, 정상 환경에서는 세 모델 간의 F1-score 성능 차이가 크지 않았으나, 전파 환경 변화가 심화될수록 모델별 성능 저하 양상에 뚜렷한 차이가 나타났다. 특히 SNN은 2.6 %의 가장 낮은 성능 저하율을 기록하며 우

수한 강건성을 보였으며, 이는 입력 신호의 일시적 품질 저하에 대해 LIF 뉴런 동작 특성이 효과적으로 작용함을 의미한다. 이러한 SNN의 안정적인 F1-score 유지는 링크 상태 감지의 신뢰성을 향상시켜 신호 품질 저하 상황에서도 비트 오류율(BER)을 안정적으로 관리할 수 있는 기반을 제공하고, 결과적으로 위성 통신 시스템의 운용 가용성(availability) 확보에 기여할 수 있음을 실험적으로 확인하였다. 이러한 LIF 뉴런 기반 SNN 모델은 우주 통신 환경에서 신뢰성 있는 RF 링크 이상 감지 구조로 활용될 수 있는 가능성을 제시한다.

References

- [1] Q. Li, X. S. Zhou, P. Lin, and S. Li, "Anomaly detection and fault diagnosis technology of spacecraft based on telemetry-mining," in *2010 3rd International Symposium on Systems and Control in Aeronautics and Astronautics*, Harbin, Jun. 2010, pp. 233-236.
- [2] A. Fejjari, A. Delavault, R. Camilleri, and G. Valentino, "A review of anomaly detection in spacecraft telemetry data," *Applied Sciences*, vol. 15, no. 10, p. 5653, May 2025.
- [3] S. Hochreiter, J. Schmidhuber, "Long short-term memory," *Neural Computation*, vol. 9, no. 8, pp. 1735- 1780, Nov. 1997.
- [4] J. Chen, D. Pi, Z. Wu, X. Zhao, Y. Pan, and Q. Zhang, "Imbalanced satellite telemetry data anomaly detection model based on Bayesian LSTM," *Acta Astronautica*, vol. 180, pp. 232-242, Mar. 2021.
- [5] W. Gerstner, W. M. Kistler, *Spiking Neuron Models: Single Neurons, Populations, Plasticity*, Cambridge, Cambridge University Press, 2002.
- [6] European Space Agency, "ESA Anomaly Dataset," 2024.
- [7] E. O. Neftci, H. Mostafa, and F. Zenke, "Surrogate gradient learning in spiking neural networks: Bringing the power of gradient-based optimization to spiking neural networks," *IEEE Signal Processing Magazine*, vol. 36, no. 6, pp. 51-63, Nov. 2019.