

GASF 이미지 인코딩 CNN 기반 데이터 효율적 봇넷 탐지: MLP·FT-Transformer와의 동일 조건 비교

김도현, 하상우, 안균승, 조성제

KCC 2026

2026.06.26

컴퓨터보안 및 OS 연구실

INDEX

01

서론

02

제안 방법

03

실험 및 결과

04

결론 및 향후 연구

01

서론

서론

❖ 네트워크 보안 환경에서는 **정상 트래픽으로 위장한 악성 행위를 조기 탐지**하는 기술 중요

- 주요 탐지 대상: 봇넷(Botnet)

❖ **봇넷(Botnet)**

- 감염 호스트를 원격으로 제어 ⇒ 분산 서비스 거부(DDoS), 정보 유출, 스팸 전송 등 다양한 공격에 활용

❖ **실제 환경에서 봇넷 탐지가 어려운 이유**

- 플로우 통계 피처간 복잡한 비선형 관계

⇒ 단순 규칙 기반 탐지, 얇은 분류 모델만으로는 안정적 탐지와 레이블 확보가 어려움

서론

데이터

Tabular 네트워크 플로우 데이터

입력 표현

1차원 수치 벡터

2차원 GASF 이미지

토큰 임베딩

- 입력 해석이 직관적
- 피쳐 간 복잡한 비선형 관계를 충분히 반영 X

- 지역 패턴과 상호관계를 잘 포착
- 변환 과정에서 표현 손실 가능

- 구조가 복잡하고 연산 비용이 큼
- 어텐션으로 피쳐 간 상호작용을 직접 학습

모델

MLP

CNN

FT-Transformer

데이터셋/출처

- NSL-KDD
- 김태희, 강승호, "실시간 탐지를 위한 인공 신경망 기반의 네트워크 침입탐지 시스템," 2017.

- NSL-KDD
- M. A. Faiaz, D. Mitra, and R. D. Prangon, "Intrusion Detection Using CNN: A Color Mapping Approach on NSL-KDD Dataset," NSysS '24, ACM, 2024.

- CIC-IoMT2024
- "Enhanced Intrusion Detection System for IoMT Devices Using Improved Human Evolutionary Optimization Algorithm and Tabular Transformers," IEEE, 2025.

한계점

기존 연구들은 각 방식을 서로 다른 실험 환경에서 개별 평가

입력 표현 방식 자체가 성능에 미치는 영향을 공정하게 비교 불가

본 연구

동일 조건에서 1차원 수치 벡터(MLP), 2차원 GASF 이미지(CNN), 토큰 기반 어텐션(FT-Transformer)의 3가지 표현 방식을 대조 평가하기 위한 연구

동일 조건 비교 필요 - 피쳐 구성, 전처리 방식, 모델 규모 등
 모델 파라미터 규모를 유사하게 통제 → 입력 표현 방식의 영향만 분리 분석
 학습 데이터 비율 단계적 축소를 통해 GASF 기반 CNN의 학습 데이터 효율성(샘플 효율성)을 정량적 평가

Attacker	Victim	Attack Name	Date	Attack Start Time	Attack Finish Time
18.219.211.138	18.217.218.111-172.31.69.23	Bot	Friday-02-03-2018	10:11	11:34
	18.222.10.237-172.31.69.17				
	18.222.86.193-172.31.69.14				
	18.222.62.221-172.31.69.12				
	13.59.9.106-172.31.69.10				
	18.222.102.2-172.31.69.8				
	18.219.212.0-172.31.69.6				
	18.216.105.13-172.31.69.26				
	18.219.163.126-172.31.69.29				
	18.216.164.12-172.31.69.30				
18.219.211.138	18.217.218.111-172.31.69.23	Bot	Friday-02-03-2018	14:24	15:55
	18.222.10.237-172.31.69.17				
	18.222.86.193-172.31.69.14				
	18.222.62.221-172.31.69.12				
	13.59.9.106-172.31.69.10				
	18.222.102.2-172.31.69.8				
	18.219.212.0-172.31.69.6				
	18.216.105.13-172.31.69.26				
	18.219.163.126-172.31.69.29				
	18.216.164.12-172.31.69.30				

[그림 1] CSE-CIC-IDS2018 봇넷 공격 정보 (Friday-02-03-2018)

출처: Canadian Institute for Cybersecurity (UNB), CSE-CIC-IDS2018

02

제안 방법

데이터셋 및 전처리

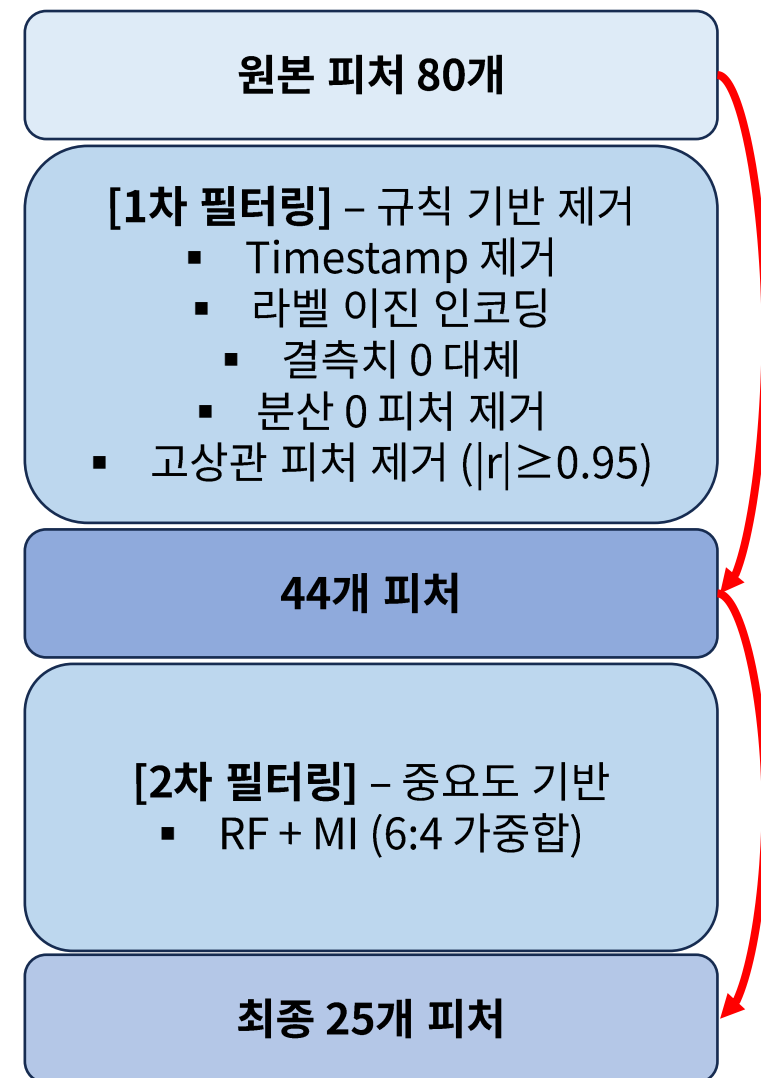
❖ 데이터셋

▪ CSE-CIC-IDS2018 中 Friday-02-03-2018

- *봇넷 공격의 플로우 메타데이터가 포함된 유일한 파일*
- 구성: 1,048,575개 플로우 레코드와 80개의 CICFlowMeter 기반 피쳐

❖ 피쳐 선택(feature selection)

- **1차 필터링:** Timestamp 제거, 라벨 이진 인코딩, 결측치 0 대체, 분산 0 피쳐 제거, 고상관 피쳐($|r| \geq 0.95$) 제거 ⇒ **44개 피쳐**
- **2차 필터링:** Random Forest 피쳐 중요도(feature importance) + Mutual Information 점수
- ✓ 데이터 누수 방지 ⇒ 학습 분할의 200,000행에서만 점수 산출
- ✓ 동점 시 봇넷 C&C 주기 통신 특성을 반영한 도메인 우선순위 적용 ⇒ **최종 25개 피쳐**



데이터 분할 및 학습 설정

❖ 데이터 분할

- 최종 선정된 25개 피처로 구성된 1,048,575개 샘플

⇒ 6:2:2(학습/검증/테스트), 계층적(stratified) 분할로 Bot:Benign 비율(27:73) 유지

- 학습(Training) 세트: Bot:Benign = 1:1 언더샘플링


⇒ 다수 클래스(정상)로의 편향 방지

- 검증·테스트 세트: 원본 분포(27:73) 유지

⇒ 실제 운영 환경에서 평가, 성능 과대평가 방지

- 전 모델이 동일 인덱스 공유

⇒ 입력 표현만 다르고 데이터는 동일 (공정 비교 보장)



❖ 학습 설정

- 검증 F1 기준 Early Stopping(patience=5)

⇒ 불균형 환경에 강건한 지표로 멈춤 시점 결정

- 손실 함수: BCEWithLogitsLoss

- 옵티마이저: MLP·CNN = Adam, FT-Transformer = AdamW (세부 하이퍼파라미터는 Appendix)

비교 모델 구조

모델	입력 표현(shape)	핵심 연산	데이터를 보는 방식	파라미터 수
MLP	1D 수치 벡터(25,)	4층 FC (BatchNorm·Dropout)	모든 피처를 동등하게 처리	1,173,505
CNN	25×25×1 GASF 이미지	합성곱·풀링 2단계 -> FC	이웃 값들의 공간 패턴에 주목	1,198,913
FT-Transformer	피처 토큰+ CLS 토큰	Transformer Self-Attention	피처 간 관계를 직접 학습	1,229,697

❖ 공통 ⇒ 25개 피처 입력 · 이진 분류 · 파라미터 ≈ 120만으로 통제

03

실험 및 결과

모델 성능 비교

❖ 평가설정

- 고정 Test set · 서로 다른 랜덤 시드 3개로 반복 학습 ⇒ 평균

❖ 성능

- 세 모델 모두 정확도 99.96%, F1-score 99.93% 대로 포화 수준
- 단순 성능 지표로는 모델 간 우열을 가리기 어려움 ⇒ 학습 데이터 양에 따른 분석으로 확장

[표 1]. 테스트 세트 성능 비교


Metric \ Model	MLP	CNN-GASF	FT-Transformer
	Accuracy (%)	99.990	99.990
Precision (%)	99.988	99.985	99.962
Recall (%)	99.974	99.978	99.911
F1-score (%)	99.981	99.982	99.936
오분류(건)	21	21	73

데이터 경량화 실험

- ❖ 실험: 학습 데이터를 5% ⇒ 100%로 줄이며 검증 F1 측정
- ❖ 결과 - 5% 조건에서 격차가 드러남: MLP 87.96% 급락 ↔ CNN-GASF 99.87% 유지
 - 25% 데이터의 CNN ≈ 100% 데이터의 MLP (1/4 데이터로 동등)
- ❖ Trade-off: GASF는 1D 대비 약 16.9배 용량
- ❖ 학습 시간 (3-seed 평균): MLP 138초 < CNN 412초 < FT-Transformer 898초
- ❖ 분석: 데이터가 적을수록 GASF·토큰 표현이 1D 벡터(MLP)보다 강건 → 데이터 경량화에 GASF-CNN이 가장 효율적 단, 자원은 완벽한 승자 없음 (저장 용량=1D · 학습 속도=MLP · 데이터 효율=GASF-CNN 우위)

[표 2]. 학습 데이터 비율별 검증 F1 및 학습 용량

Category	Training Data Ratio			
	5%	10%	25%	100%
1D 용량 (MB)	2.9	5.8	14.5	57.9
2D 용량 (MB)	46.6	93.2	233.0	931.6
MLP F1 (%)	87.961	91.503	91.999	99.981
CNN-GASF F1 (%)	99.868	99.933	99.975	99.982
FT-Transformer F1 (%)	99.837	99.868	99.883	99.936



04

결론 및 향후연구

Conclusion

- 레이블 확보가 어려운 네트워크 보안 환경에서 **GASF 이미지 인코딩이 데이터 효율적 탐지 수단이 될 수 있음을 반복 실험을 통해 검증**
- 전체 학습 데이터의 5%라는 동일 조건에서 **CNN-GASF가 F1 99.868%**를 달성하여, MLP(87.961%) 대비 이미지 기반 인코딩의 우수한 샘플 효율성을 확인
- GASF 이미지가 1차원 수치 데이터 대비 약 16.9배의 저장 용량을 차지하나, 정교한 피쳐 선택(25개 미만)을 통해 **이미지 크기와 전체 저장 용량을 추가로 절감할 수 있는 가능성을 제시**
- **저장 용량·학습시간 등 자원 측면에서는 표현 방식별 trade-off가 존재** — 저장 용량은 1D(MLP·FT-T), 학습 속도는 MLP, 데이터 효율성은 CNN-GASF가 우위로, 단일 최적 모델은 없음을 정량 분석

Future Work

- 단일 데이터셋·봇넷 단일 공격 유형이라는 한계 ⇒ **다양한 데이터셋·모델과 추가 비교 실험**
- GASF 외 MTF·RP등 **다양한 이미징 기법 비교, 이미지 크기(피쳐 수)에 따른 성능-용량 최적화**
- 이진분류(Bot/Benign)를 넘어 공격 유형별 **다중분류(multi-class)로 확장하여, DDoS·침투 공격 등 신규 환경에서 데이터 효율적 탐지 검증**

Acknowledgement

본 연구는 2026년 과학기술정보통신부 및 정보통신기획평가원의 SW
중심대학사업 지원을 받아 수행되었음(2024-0-00035).

또한 본 연구는 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원-대학ICT연구
센터(ITRC)의 지원을 받아 수행되었음(IITP-2026-RS-2023-00259967).

Thank you

Q&A



Appendix.

피처 랭킹 Top 20

순위	피처	score	RF	MI
1	Dst Port	0.943	0.100	0.256
2	Init Fwd Win Byts	0.833	0.072	0.299
3	TotLen Fwd Pkts	0.725	0.076	0.202
4	Fwd Pkt Len Max	0.647	0.064	0.199
5	Fwd Pkt Len Mean	0.570	0.051	0.199
6	Init Bwd Win Byts	0.539	0.062	0.125
7	Flow IAT Mean	0.473	0.047	0.146
8	Flow Duration	0.443	0.041	0.146
9	Flow IAT Max	0.437	0.037	0.163
10	Pkt Len Mean	0.419	0.029	0.184

순위	피처	score	RF	MI
11	Fwd Pkts/s	0.408	0.033	0.159
12	Flow Pkts/s	0.406	0.036	0.141
13	Fwd Seg Size Min	0.400	0.040	0.119
14	Bwd Pkt Len Mean	0.379	0.021	0.192
15	Bwd Pkt Len Max	0.368	0.019	0.189
16	Pkt Len Var	0.366	0.020	0.183
17	Flow Byts/s	0.304	0.028	0.104
18	Bwd Pkts/s	0.295	0.019	0.137
19	Tot Fwd Pkts	0.260	0.027	0.074
20	Flow IAT Std	0.229	0.019	0.086

학습설정 - 세부 하이퍼파라미터, 모델 구조

항목	설정
손실 함수	BCEWithLogitsLoss
Early Stopping	검증 F1 기준, patience=5
Batch Size	학습 512, 평가 2048
반복 시드	42, 456, 789 (3회)
학습 epoch(최대)	50

모델	옵티마이저	학습률(LR)	Weight decay
MLP	Adam	5e-4 (0.0005)	미적용, 기본값 0
CNN	Adam	1e-3 (0.001)	미적용, 기본값 0
FT-Transformer	AdamW	3e-4 (0.0003)	1e-4 (0.0001)

모델	구조
MLP	은닉층 2048 → 512 → 128, Dropout 0.3, BatchNorm
CNN	Conv 2블록(32·64 필터, 3×3, padding=1), MaxPool(2), Dropout2d 0.25, FC 128
FT-Transformer	d_model=128, heads=8, layers=6, FFN=256, Dropout 0.1, Pre-LN(norm_first), CLS 토큰