머신러닝 기반 IoT 장치를 식별하는 기법 분석

2023 한국차세대컴퓨팅학회

안석현, 박민수, 조성제, 김홍근

DKU 단국대학교 DANKOOK UNIVERSITY

Computer Security & OS LAB

INDEX

01 서론

1. 서론

❖ 인터넷 기술의 발전으로 IoT(Internet of Things) 기술이 발전

❖ 자동차, 의료, 건축 등 다양한 분야에서 활용되고 있음

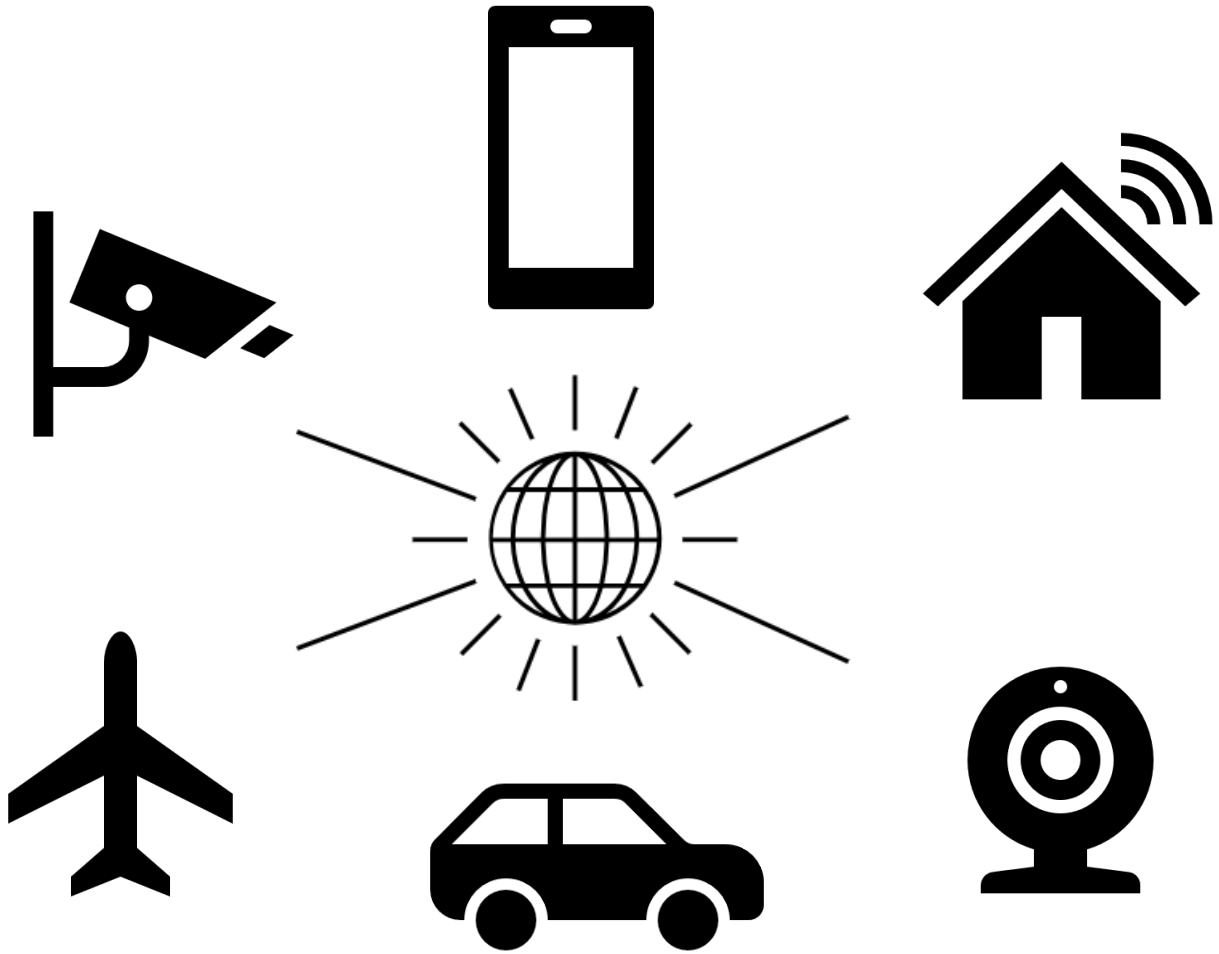

1. 서론

❖ IoT 장치의 문제점

- 제한적인 자원
- 장치의 가용성에 영향을 주지 않기 위한 최소한의 보안 솔루션
- IoT 장치가 많을수록 관리가 어려움
- 기존의 장치가 인터넷에 연결되면서 공격 표면(Attack surface)의 증가

❖ IoT 장치가 악의적인 활동에 노출될 경우 발생할 수 있는 피해

- 다양한 분야에서 사용되고 있어 경제적 피해 및 인명 피해가 발생할 수 있음
- 스마트 홈과 스마트 빌딩 등의 거주 공간에 있는 장치는 사생활 침해가 발생할 수 있음

1. 서론

❖ IoT 장치 식별의 필요성

- IoT 장치의 갯수가 점차 증가하면서 식별되지 않은 장치 관리가 어려움

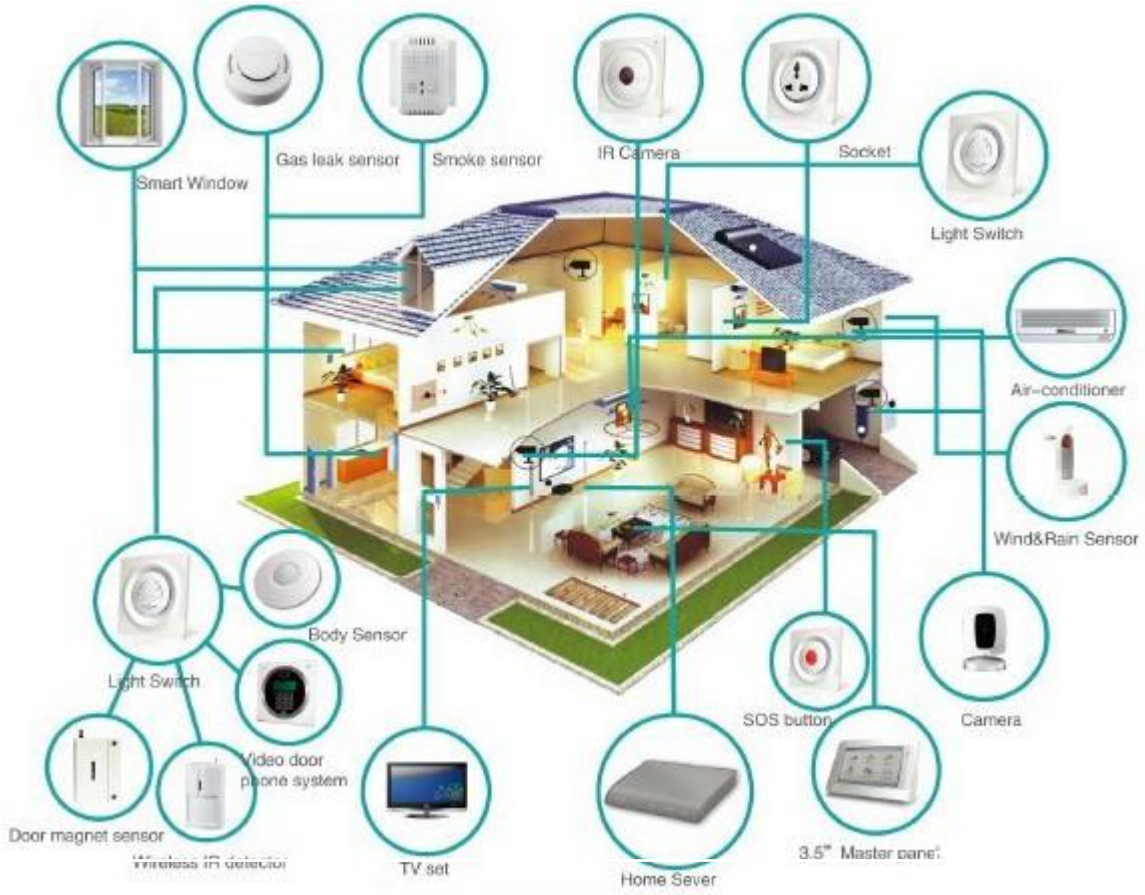

IoT로 연결되는 스마트홈 기기들 <사진=Yourhomesecuritywatch.com>

IoT 장치 <사진=kolonbenits-time.com>

02 배경 지식

2. 배경지식

❖ IoT 장치를 식별하기 위해 특징(Fingerprinting) 정보 생성 방법

- 수동적 방법(passive)
  - 장치와 직접적인 상호작용 없이 특징 정보를 추출
  - IoT 장치의 가용성에 영향을 주지 않지만, 정확한 특징 정보를 얻기 어려우며 시간이 많이 소요된다.

TCPDUMP & LIBPCAP

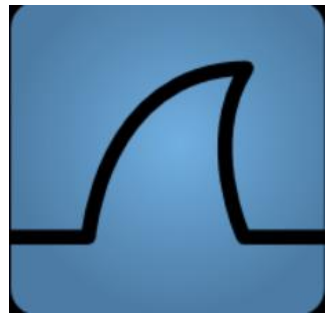

- 능동적 방법(active)
  - 장치와 직접적인 상호작용을 통하여 특징 정보를 추출
  - IoT 장치의 가용성에 영향을 끼쳐 장치가 멈추거나 오작동할 수 있음

NMAP

2. 배경지식

❖ IoT 장치 식별을 위해 다양한 논문에서 머신 러닝을 기반으로 IoT 장치 식별을 시도

❖ LSTM(Long Short-Term Memory)

- RNN 모델의 한 종류, 장기적인 시간 간격에 걸친 데이터 처리에 장점이 존재
- 장기적으로 의존성을 가진 패턴 학습에 강점이 있는 모델

❖ CNN

- 이미지 특징 정보 추출에 장점을 가짐

❖LSTM-CNN

- LSTM & CNN 결합하여 시퀀스 데이터에서 특징을 추출하고 장기적인 패턴을 학습하여 자연어 처리, 음성 인식, 동영상 분석 등의 분야에서 사용

2. 배경지식

❖ RF(Random Forest)

- 앙상블(Ensemble Learning)의 한 종류, 여러 개의 의사 결정 트리를 생성하고 각각의 트리들의 예측 결과를 조합하여 최종 예측을 수행
- 하이퍼 파라미터 조정으로 과적합 방지와 의사 결정 트리의 특성으로 이상치 및 노이즈 등에 대한 강하다는 장점이 존재

❖HMM(Hidden Markov Models)

- 관찰 변수 집합에서 숨겨진 변수의 시퀀스를 추정할 수 있는 확률적 그래픽 모델
- 네트워크 트래픽 추적의 반복 가능한 패턴을 감지

❖Logit Boost

- 앙상블 학습 알고리즘, 분류 오차에 따라 샘플의 가중치 증가
- 올바르게 분류된 샘플의 가중치 감소시켜 모델을 조정하고 예측 성능을 증가시킴

03 머신 러닝 기반 IoT 장치 식별 연구 비교

3. 머신 러닝 기반 IoT 장치 식별 연구 비교

[8] Bai et.al “Automatic Device Classification from Network Traffic Streams of Internet of Things”

- 15개의 IoT 장치(Smart Things, TP-Link Smart plug, Amazon Echo...)를 대상으로 네트워크 트래픽을 19일 동안 수집
- 트래픽 양(traffic volime), 패킷 길이, 네트워크 프로토콜, 트래픽 방향 등의 특징 정보를 사용
- 장치의 종류가 다양해질 경우 정확하게 구별하지 못함.

[9] Thangavelu et.al “DEFT: A Distributed IoT Fingerprinting Technique”

- 16개의 IoT 장치(Echo dot, Smart remote, Camera...) 를 대상으로 네트워크 트래픽을 7일동안 수집
- DNS, HTTP, TLS 등 10개의 프로토콜에서 특징 정보 추출하여 사용
- 실험에 사용된 16개의 장치외에 다른 장치에서는 식별이 불가능할 수 있음

3. 머신 러닝 기반 IoT 장치 식별 연구 비교

[10] Network Traffic Modelimg For IoT-device Re-identification

- IoT Sentinel(31 개) & IEEE TMC 2018(28 개) 데이터 셋 사용
- 네트워크 패킷 헤더, 암호화된 트래픽 등을 특징 정보로 사용

[13] Ensemble machine learning approach for classification of IoT devices in smart home

- 41개의 IoT 장치(Camera, Smart bulb, Smart Things...)를 대상으로 네트워크 트래픽 수집
- IP 주소, 포트 번호, 사용된 프로토콜 등의 특징 정보를 사용
- 앙상블을 이용한 방법으로 리소스가 제한적인 IoT 장치에서 사용이 어려울 수 있음

3. 머신 러닝 기반 IoT 장치 식별 연구 비교

❖ 머신 러닝 기반 장치 식별 관련 연구 비교

동향	Bai et al. [8]	Thangavelu et al. [9]	Najari et al. [10]	Cvitić et al. [13]
데이터 셋 공개 여부	공개	비공개	공개	비공개
IoT 장치 개수	15개	16개	59개	41개
분석 방법	패킷 길이, 네트워크 프로토콜 등	DNS, HTTP, TLS 등의 프로토콜	네트워크 패킷 헤더, 암호화된 트래픽 등	IP 주소, 포트 번호, 네트워크 프로토콜 등
모델	LSTM-CNN 등	Random Forest 등	LSTM 등	Logit Boost 등
수동/능동	수동적 방법(Passive)			
정확도	74.8%	98%	99%	99.7%

04 논의

4. 결론 및 향후 연구

❖네트워크에 연결된 IoT 장치들을 식별하기 위해 여러 기존 연구에서 머신 러닝을 사용하고 있음

- IoT 장치 식별을 하기 위해 네트워크 프로토콜, 패킷 헤더 정보 등을 주요 특징 정보로 사용

❖ IoT 장치와 다른 장치들을 많이 사용하는 스마트 홈, 스마트 빌딩과 같은 환경에서 머신 러닝 기반 IoT 장치를 식별하는 것은 제약이 있을 수 있음

❖ 실시간으로 IoT 장치를 제어하는 경우 가용성에 영향을 줄 수 있음

04 결론 및 향후 연구

4. 결론 및 향후 연구

❖향후 IoT 장치 식별을 위해 우선적으로 파악해야할 특징 정보와 머신 러닝 모델에 대한 정보 및 한계점을 제공

❖ 다양한 분야에서 IoT 장치의 사용이 증가하고 있으며, 장치의 종류 또한 다양해지고 있다.

❖ 자원이 제한적인 IoT 장치에 대한 네트워크 보안 및 개인 정보 보호 문제에 대한 연구가 필요

Q&A