



# CONTENTS

- 1 데이터 분석
- 2 데이터 수집 및 라벨링
- 3 탐지 알고리즘



/01

# 데이터 분석

Team KAISA



# 데이터 분석

## 학습 데이터셋

---

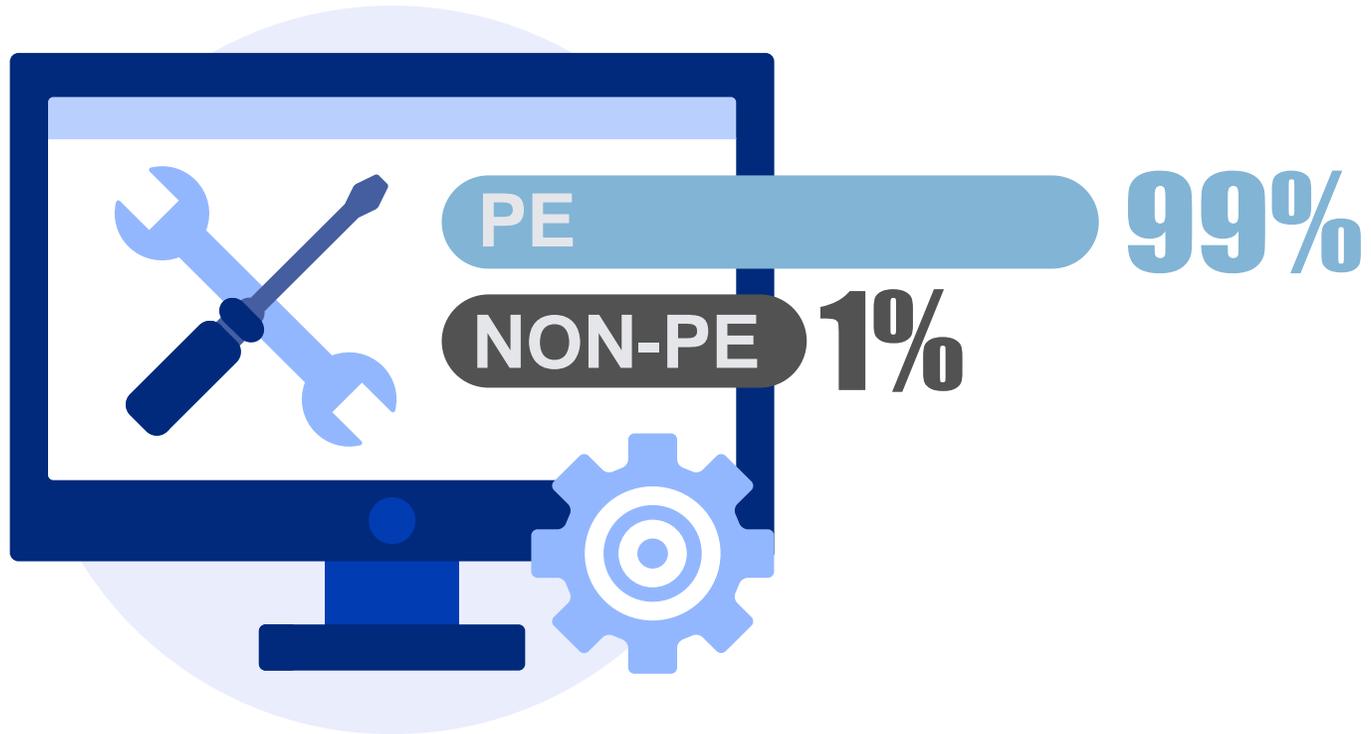
**70%**  
악성



**30%**  
정상

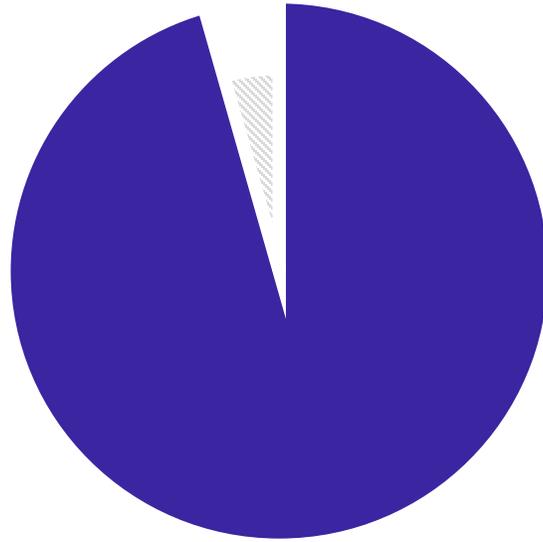
# 데이터 분석

학습 데이터셋 → PE

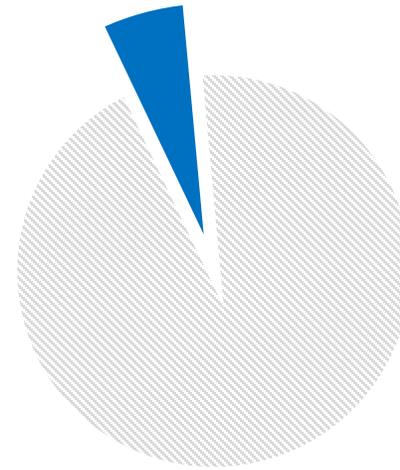


# 데이터 분석

학습 데이터셋 → PE



**90%** PE32



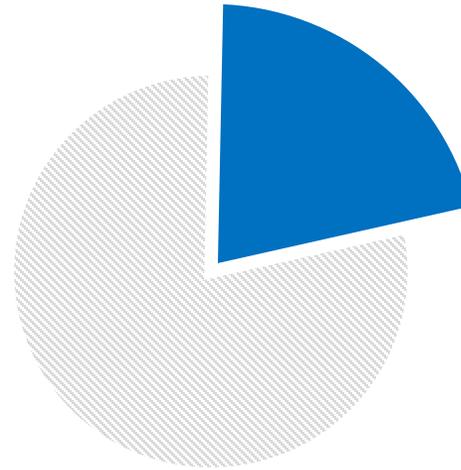
**10%** PE64

# 데이터 분석

학습 데이터셋 → PE → Non-PE



**44%** HTML



**22%** HWP



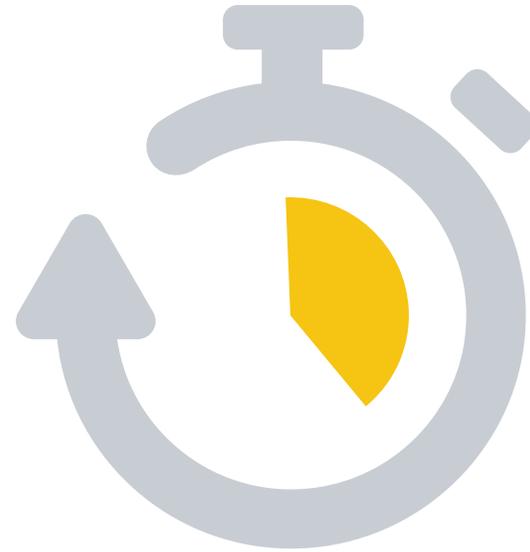
**34%** ETC

# 데이터 분석

## 예선 데이터셋

---

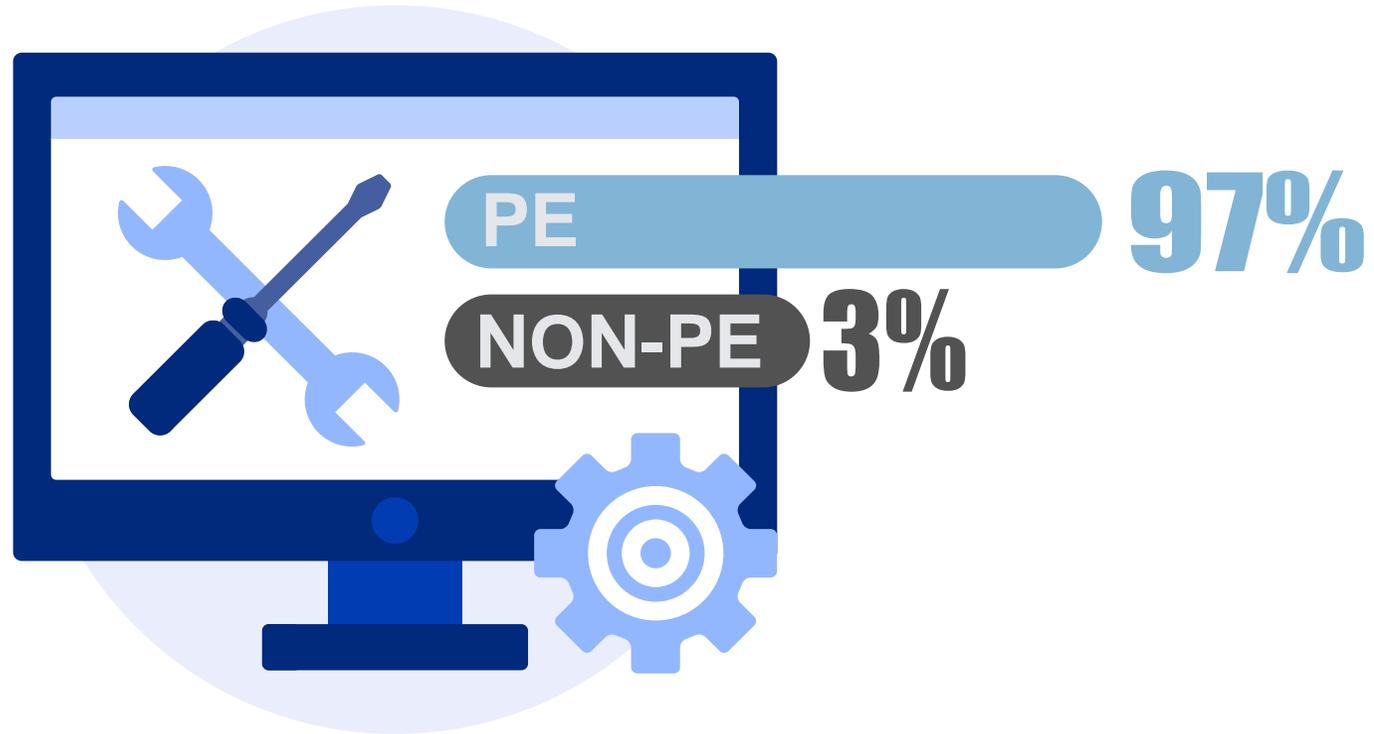
**60%**  
악성



**40%**  
정상

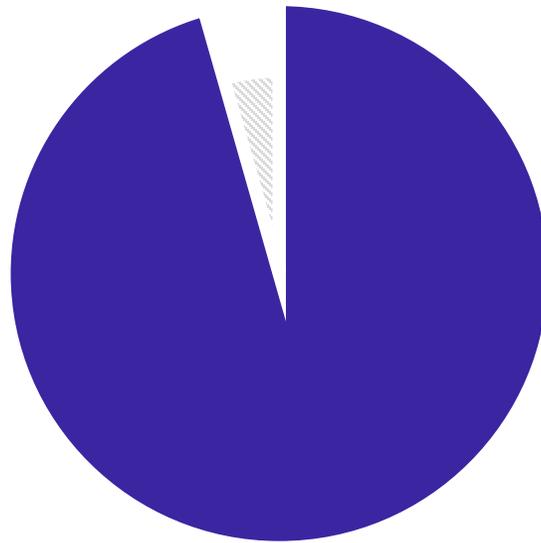
# 데이터 분석

예선 데이터셋 → PE

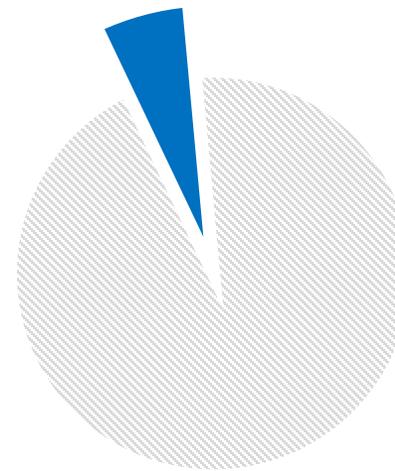


# 데이터 분석

예선 데이터셋 → PE



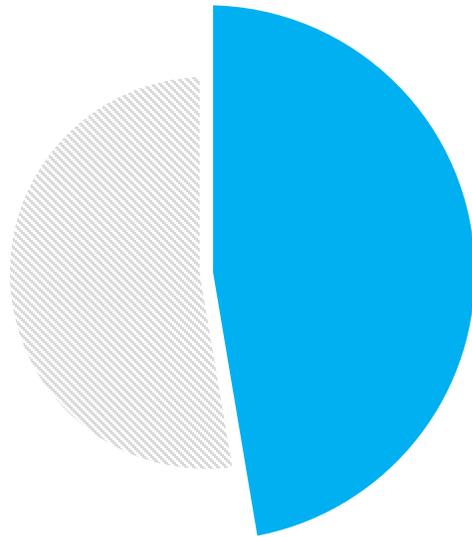
**90%** PE32



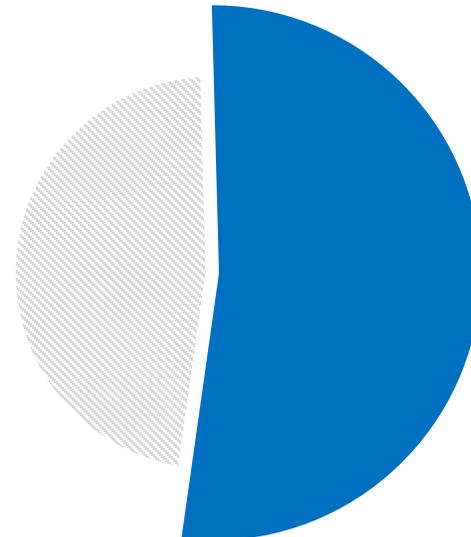
**10%** PE64

# 데이터 분석

예선 데이터셋 → PE → Non-PE



**48%** HTML



**52%** ETC

# /02

## 데이터 수집 및 라벨링

Team KAISA



# 데이터 수집 및 라벨링

01

## 데이터 수집

- VirusTotal, VirusShare, VirusSign

02

## 라벨링

- VirusTotal 을 활용하여 라벨링

03

## 학습에 사용한 데이터 수

- PE32: 약 50만 개
- PE64: 약 30만 개



/03

# 탐지 알고리즘

Team KAISA

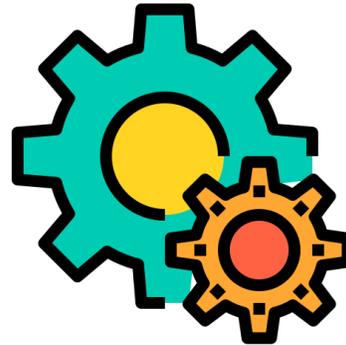
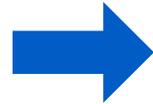


# 탐지 알고리즘

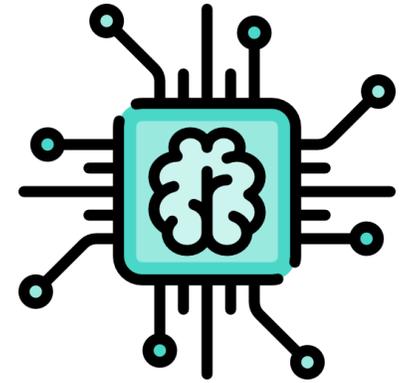
---



파일 분류



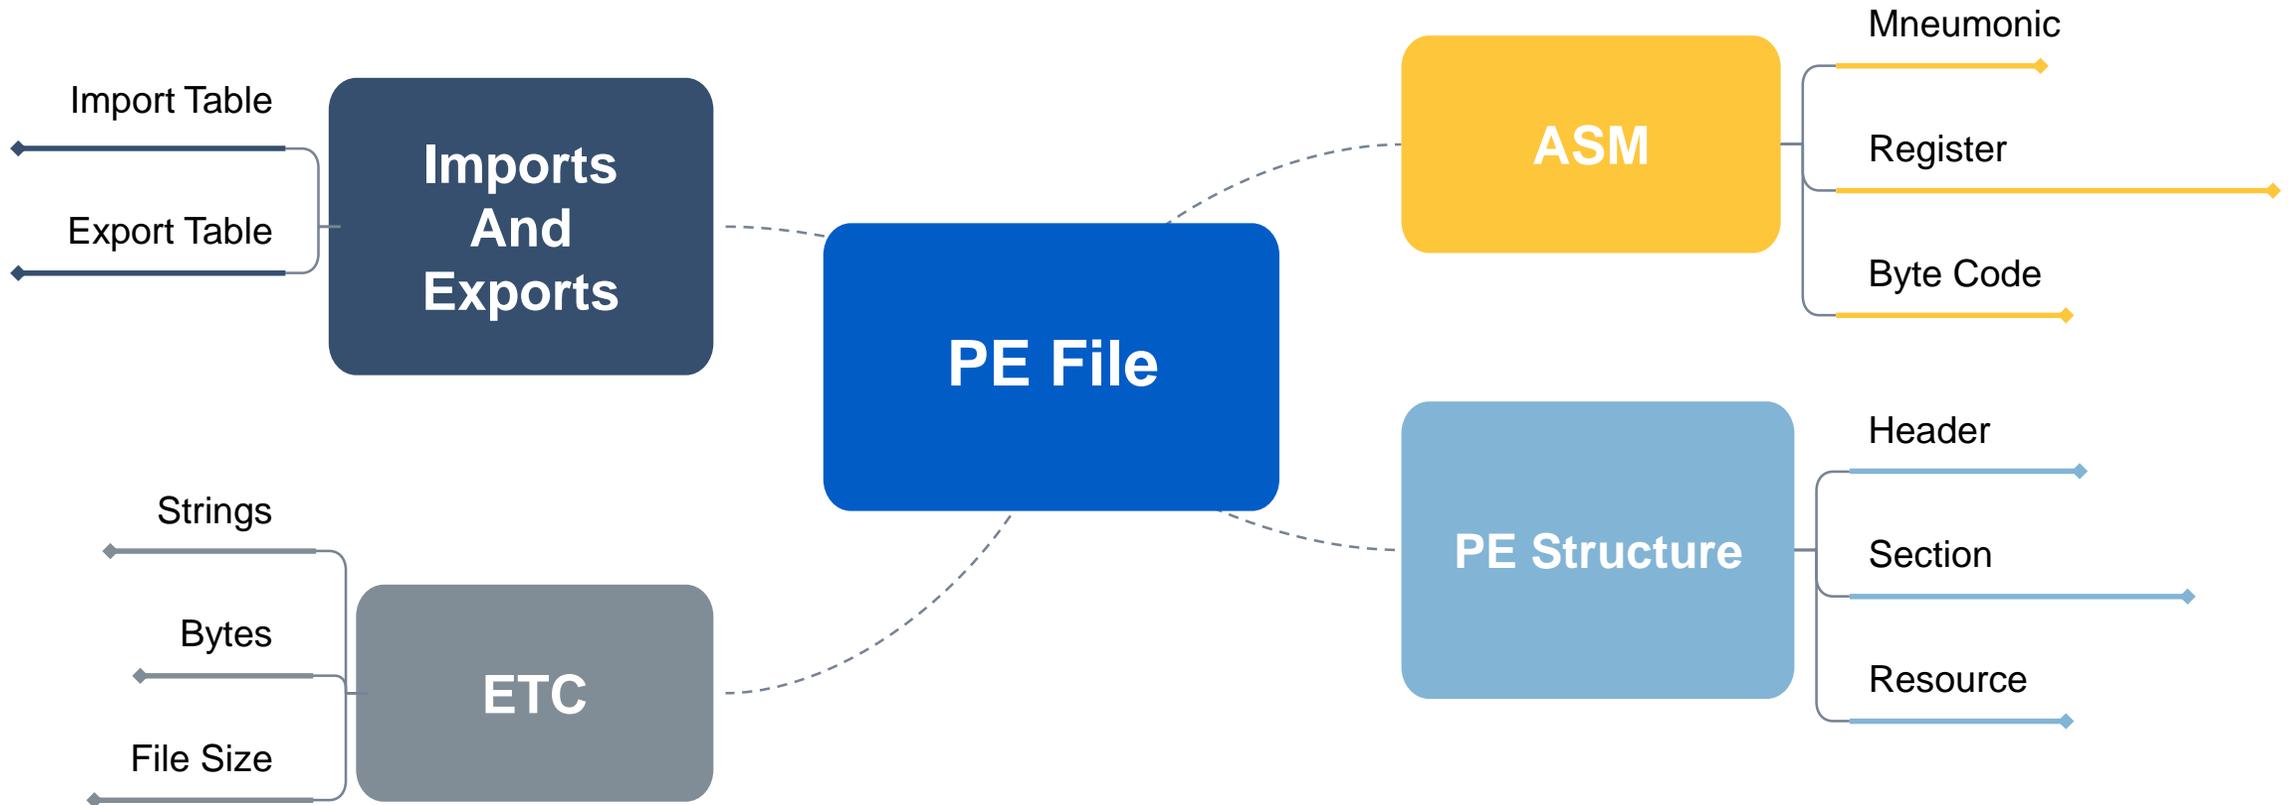
파일 별 특징 추출



탐지

# 탐지 알고리즘

## PE



# 탐지 알고리즘

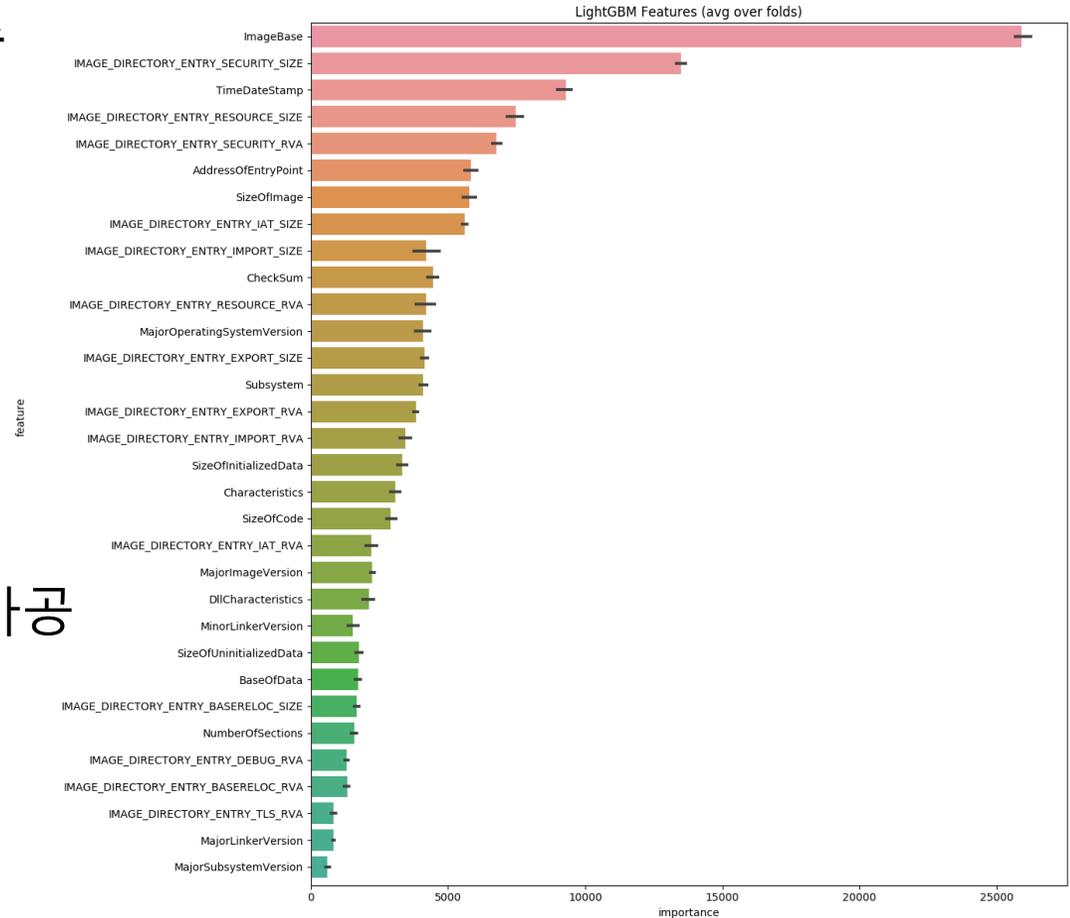
## PE

정적 분석으로 추출할 수 있는 모든 특징 추출



판단은 모델에게

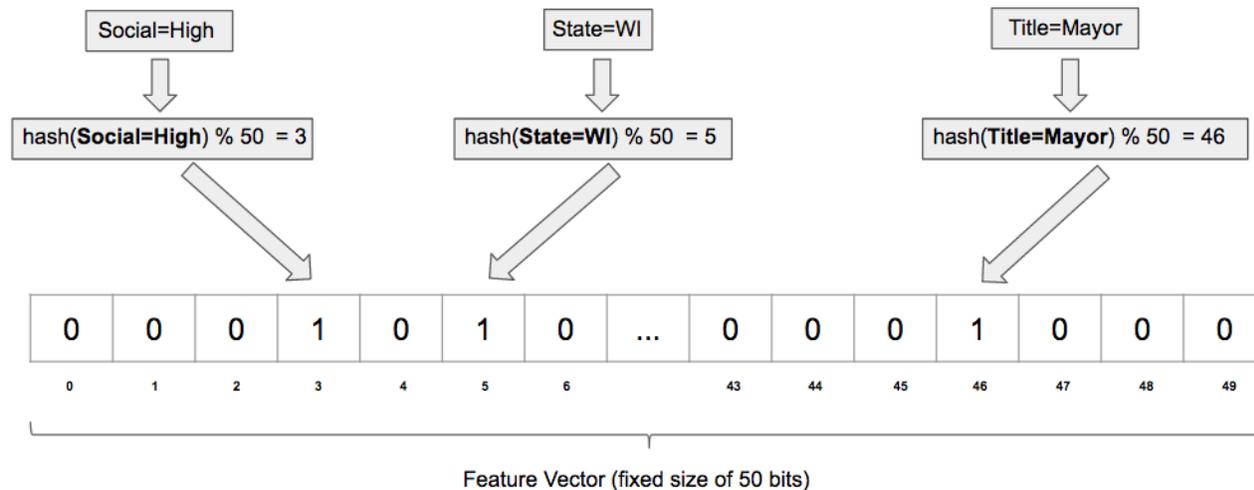
- 정형화 데이터는 정형화 데이터의 값 자체 사용
- 가변적 데이터는 해싱 트릭(Hashing Trick)으로 가공
- 특징 벡터 크기: 10,191차원



# 탐지 알고리즘

## 해싱 트릭

- Kilian Weinberger, Anirban Dasgupta, Josh Attenberg et al. “Feature Hashing for Large Scale Multitask Learning,” International Conference on Machine Learning (ICML) 2009
- 아래의 특징들을 해싱 트릭으로 벡터화
  - ✓ Import Table, Export Table, Rich Header, Strings, Opcode 3-gram



# 탐지 알고리즘

---

## PE

### 사용한 머신 러닝 모델

- LightGBM
- Random Forest
- XGBoost
- DNN

### 학습 데이터

- KISA 데이터셋
- KISA 데이터셋 + 자체 수집 **악성/정상** 데이터
- KISA 데이터셋 + 자체 수집 **정상** 데이터

# 탐지 알고리즘

## PE

### 5 폴드 교차 검증 (5 Fold Cross Validation)

```
seclab@seclab:~/kisa_2019$ python3 tmp.py cv xgb KISA_TRAIN_FEATURE.csv
Generate Dataframe
CV Start...
Fold 1 >> acc score 0.93505039193729
Fold 2 >> acc score 0.9394957983193277
Fold 3 >> acc score 0.9316526610644258
Fold 4 >> acc score 0.9417366946778711
Fold 5 >> acc score 0.945627802690583
5 Fold Average Score: 0.9387126697378996
CV End, Elapsed time: 597.6390080451965
```

```
seclab@seclab:~/kisa_2019$ python3 tmp.py cv xgb KISA_TRAIN_FEATURE.csv
Generate Dataframe
CV Start...
Fold 1 >> acc score 0.9624860022396416
Fold 2 >> acc score 0.969187675070028
Fold 3 >> acc score 0.9647058823529412
Fold 4 >> acc score 0.9697478991596639
Fold 5 >> acc score 0.9714125560538116
5 Fold Average Score: 0.9675080029752173
CV End, Elapsed time: 3228.9058578014374
```

# 탐지 알고리즘

---

## PE

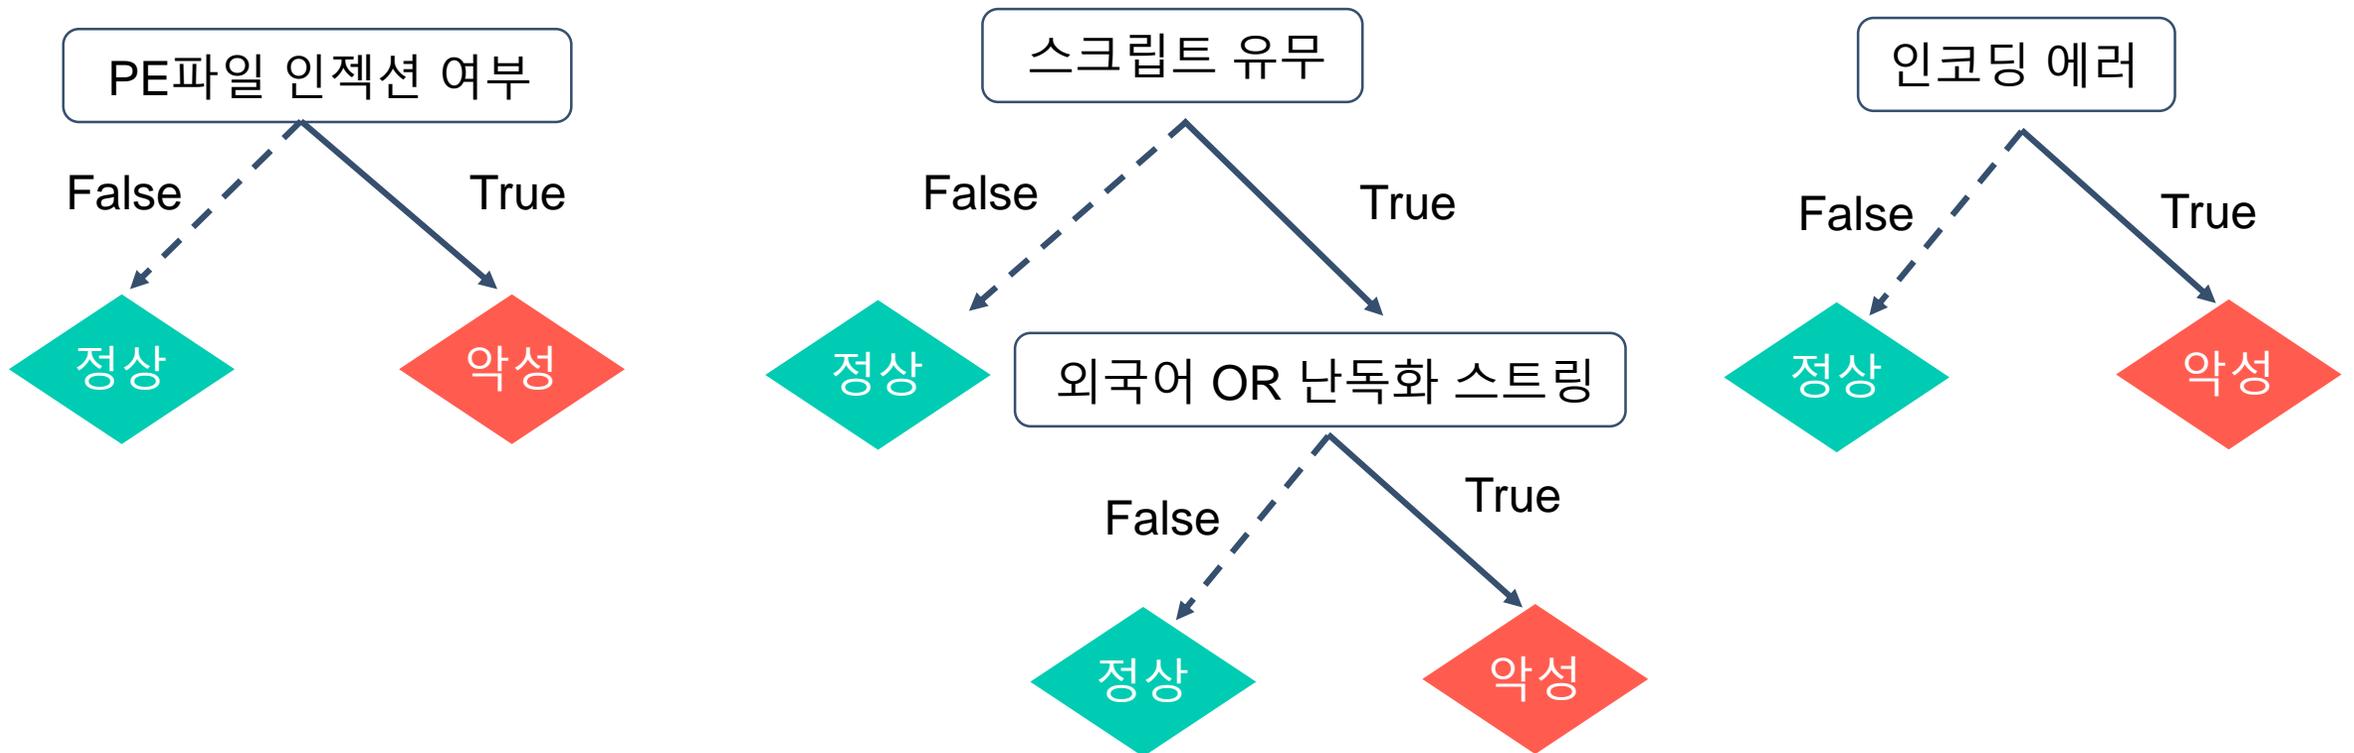
- 탐지
- 모델 별 탐지 결과 블렌딩
  - ✓ 보팅(Voting) 방법 사용
  - ✓ 모델 조합과 악성 기준 설정

$$y_{pred} = y_{1pred} \otimes y_{2pred} \otimes \dots \otimes y_{npred}$$

# 탐지 알고리즘

## HTML JS

아래 알고리즘의 결과와 추출한 값을 피쳐화 → 의사 결정 트리 학습



# 탐지 알고리즘

## HTML JS

### 사용한 피처

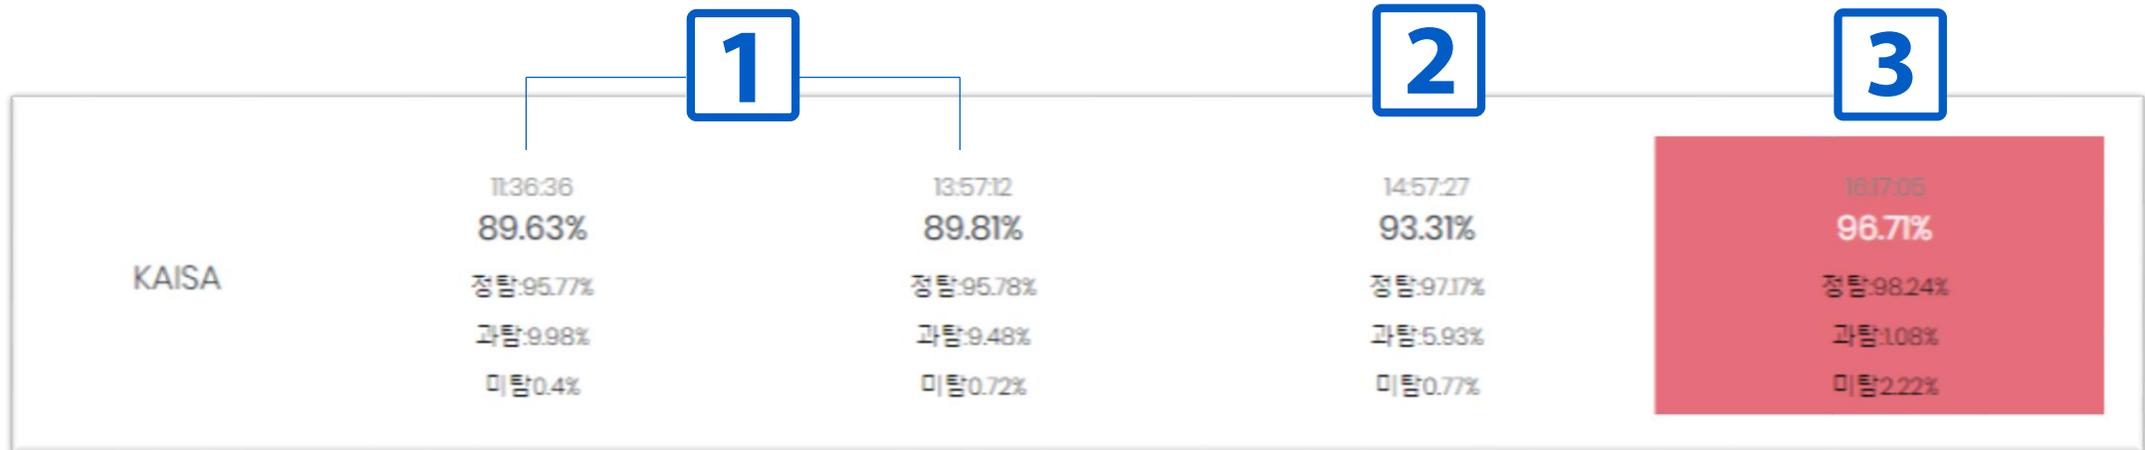
PE	PE 파일 인젝션 유무
Script	스크립트 유무
Strange_lan	HTML 에 포함된 국가 언어 개수 (중국어,아랍어,라틴어 등)
Array_no10	'2138329423 ' 와 같은 난독화 된 문자 유무
Error1	파일 읽기 에러 유무
Error2	인코딩 에러 유무
Entropy	HTML 엔트로피
Tag_count	HTML 태그 개수

# 탐지 알고리즘

## 예선

- LightGBM 단일 모델 사용

1. KISA 학습 데이터 + 자체 수집 악성/정상 데이터
2. 첫 번째 모델, KISA 학습 데이터 모델 블렌딩(AND)
3. 두 번째 모델, KISA 학습 데이터 + 자체 수집 정상 데이터 모델 블렌딩(AND)





# Q&A

Team KAISA

문다민 김영재 손현기 오예린

# 데이터 분석 – Train Set

파일 타입	개수	비율	악성 개수	정상 개수	악성 비율
PE32	8925	89.25	6929	2656	70.24
PE64	978	9.78	681	297	69.63
HTML	42	0.42	36	6	85.71
HWP	20	0.2	10	10	50.00
<b>XML</b>	<b>13</b>	<b>0.13</b>	<b>0</b>	<b>13</b>	<b>0.0</b>
UNKNOWN	13	0.13	1	12	7.69
<b>MS-DOS</b>	<b>3</b>	<b>0.03</b>	<b>3</b>	<b>0</b>	<b>100.00</b>
<b>MACH-O 64</b>	<b>1</b>	<b>0.01</b>	<b>0</b>	<b>1</b>	<b>0.00</b>
<b>WOFF v2</b>	<b>1</b>	<b>0.01</b>	<b>0</b>	<b>1</b>	<b>0.00</b>
<b>PHP</b>	<b>1</b>	<b>0.01</b>	<b>0</b>	<b>1</b>	<b>0.00</b>
<b>PY</b>	<b>1</b>	<b>0.01</b>	<b>0</b>	<b>1</b>	<b>0.00</b>
<b>PYC</b>	<b>1</b>	<b>0.01</b>	<b>0</b>	<b>1</b>	<b>0.00</b>
<b>TXT</b>	<b>1</b>	<b>0.01</b>	<b>0</b>	<b>1</b>	<b>0.00</b>