

블랙박스 AI 기만 공격 기술

박호성

지능보안연구실

공주대학교

목차

▶ Adversarial Examples

- 기만 공격의 목표 / 원리

▶ 기만 공격 분류

- Untargeted attack / Targeted attack
- White-box / Black-box

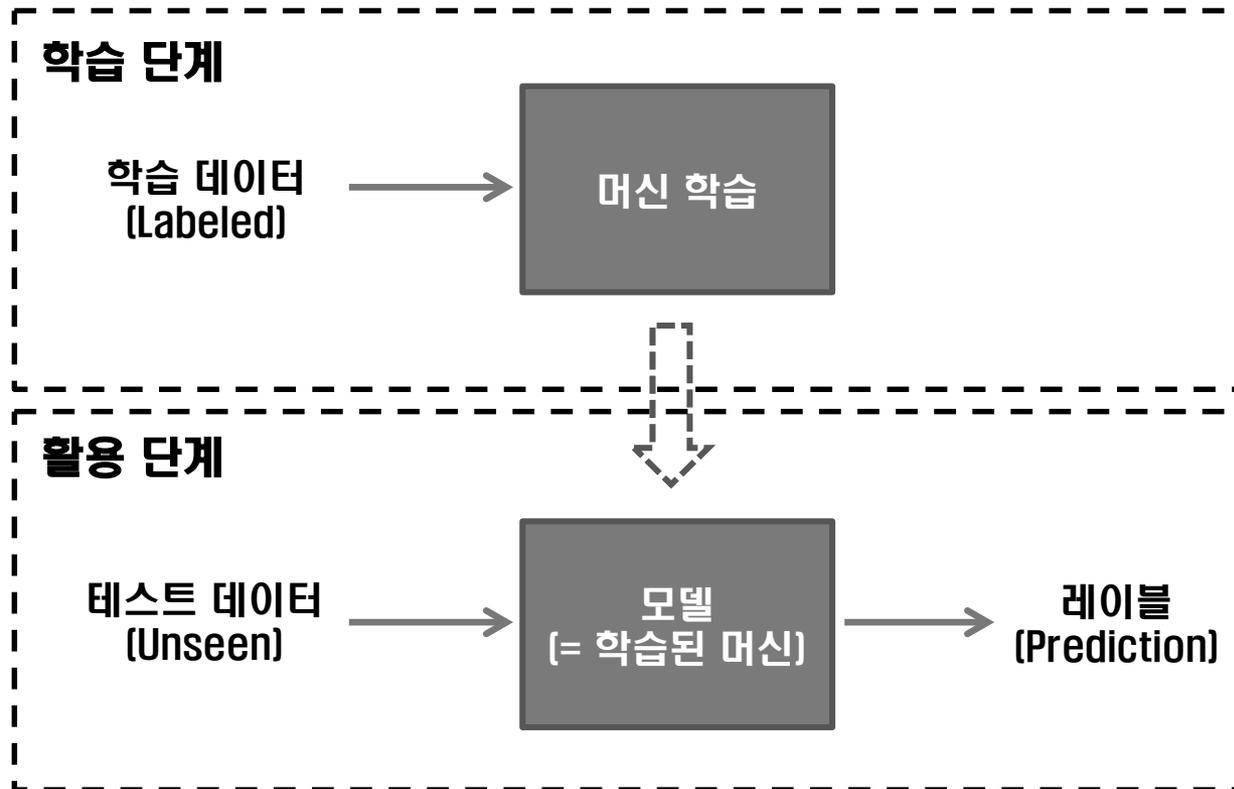
▶ 블랙박스 기만 공격 기술

- Substitute model attack
- Gradient estimation attack
- Model Ensemble attack

Adversarial Examples

Classification Model

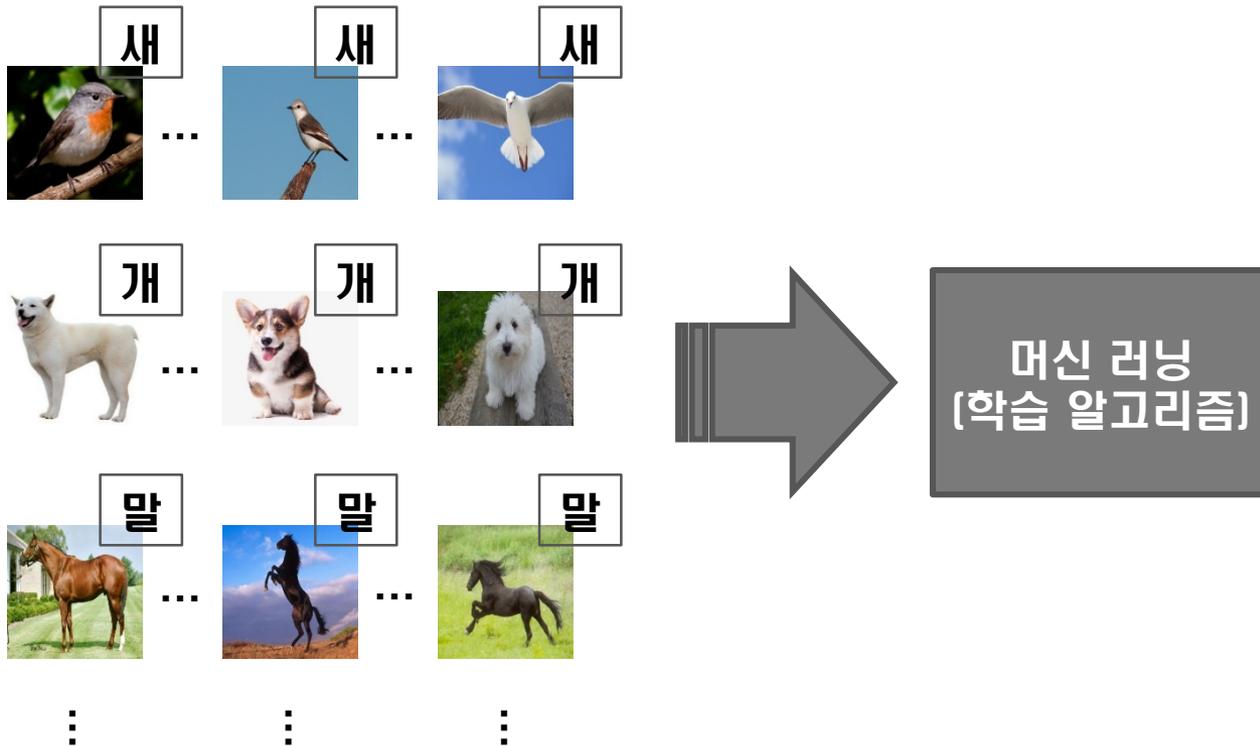
▶ 머신 러닝을 통한 이미지 분류



Classification Model

▶ 학습 단계

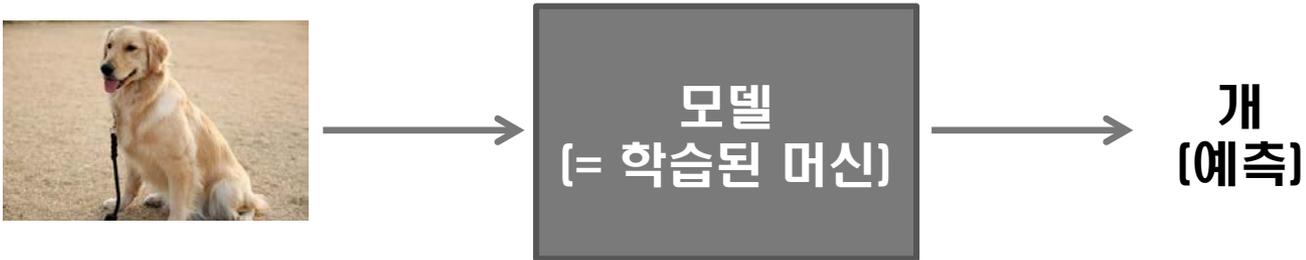
- 다량의 학습 데이터 → 스스로 패턴 분석



Classification Model

▶ 활용 단계

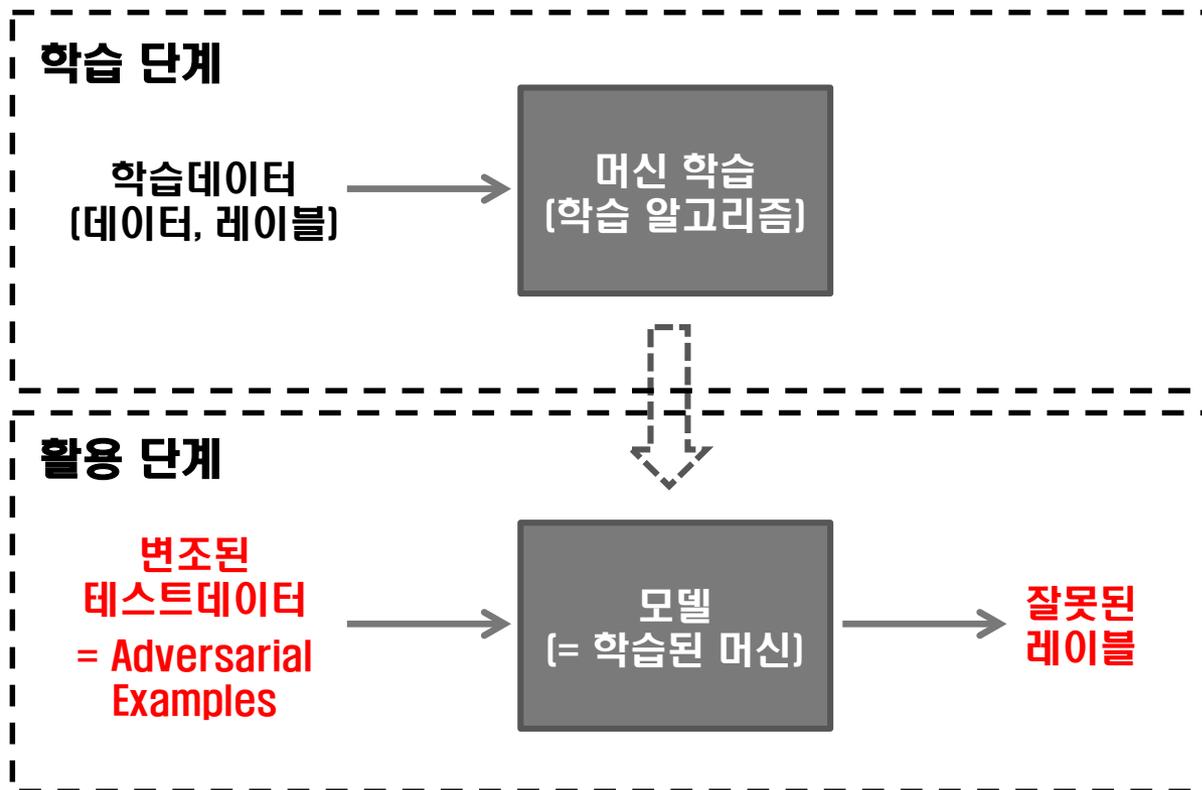
- Unseen data → 결과 예측



Evasion Attack

▶ 기만 공격 (Evasion Attack)

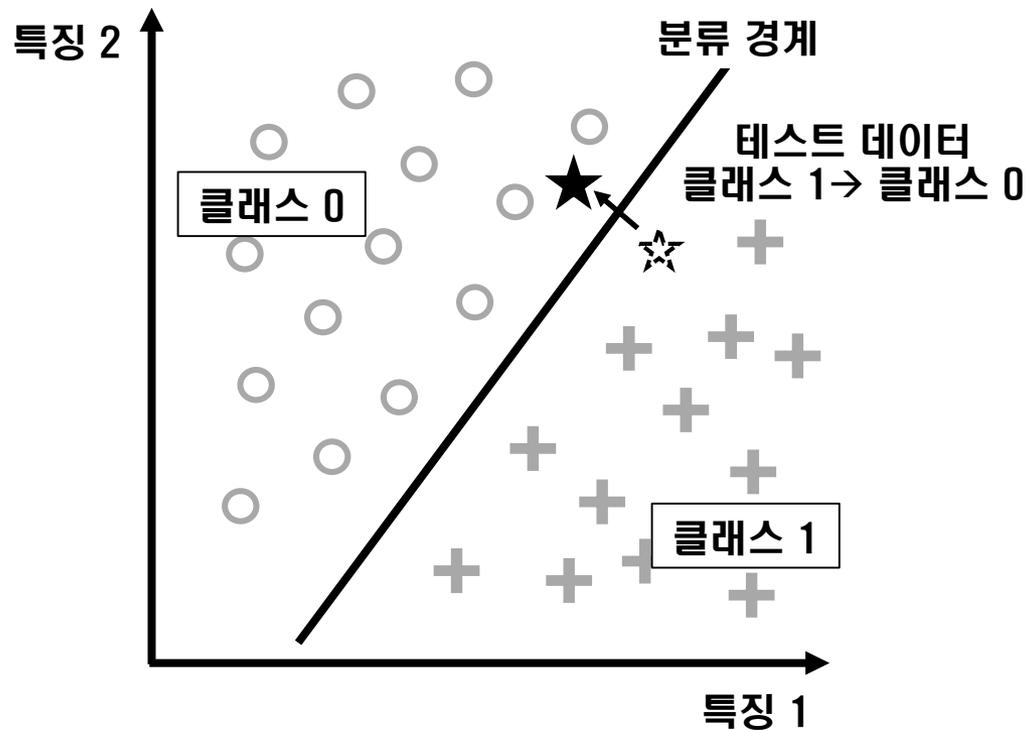
- 활용 단계의 분류 데이터를 변조 → 오작동 유발



Evasion Attack

▶ 목표 / 원리

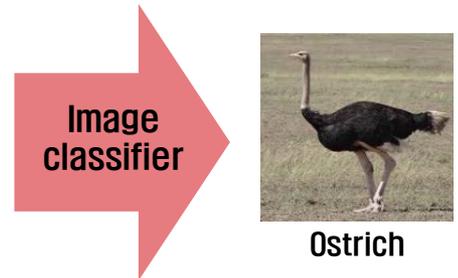
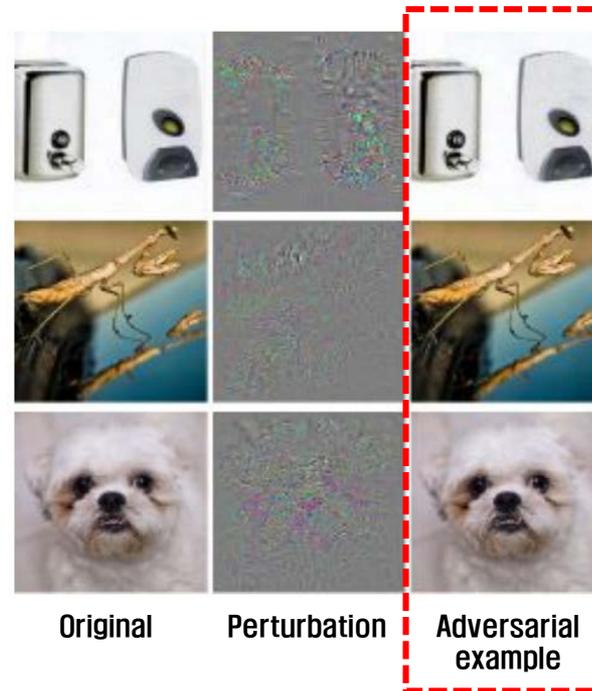
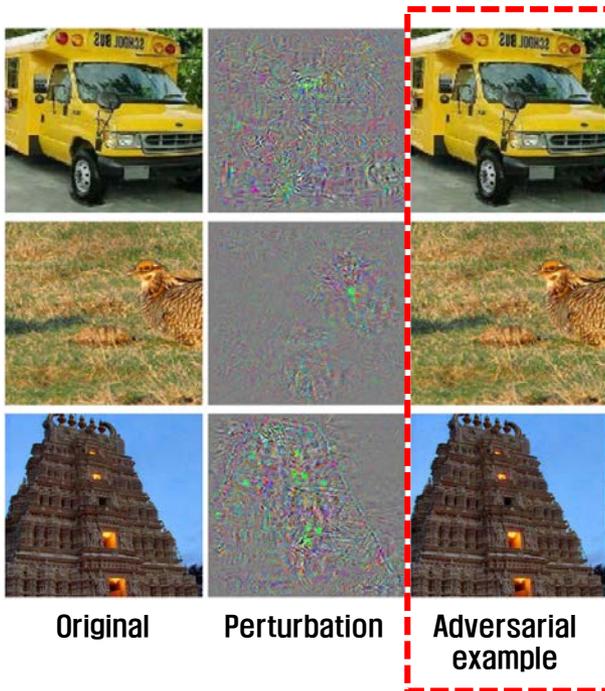
- 최소한의 변조 - 눈에 보이지 않을 정도의 작은 노이즈 추가
- 최대한의 오작동 유발



Evasion Attack

▶ 이미지

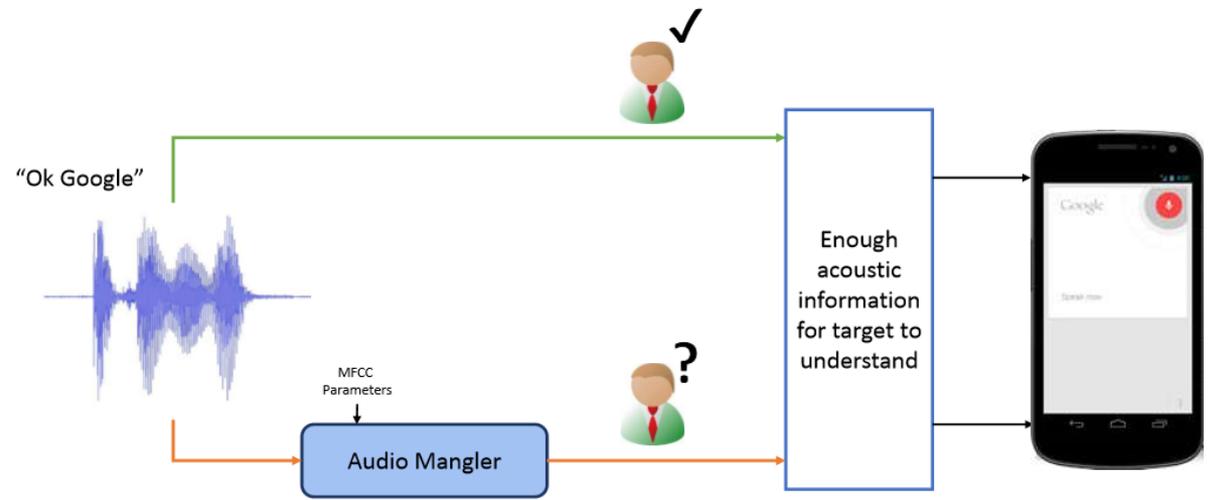
- 4%만 변조해도.. 97%는 잘못 분류
- 사람은 변조된 이미지를 인식하기 어려움



Evasion Attack

▶ 오디오

사람이 알아들을 수 없는 명령어



<출처 : Tavish Vaidya, et. al. Cocaine Noodles: Exploiting the Gap between Human and Machine Speech Recognition, WOOT '15>

명령어 왜곡

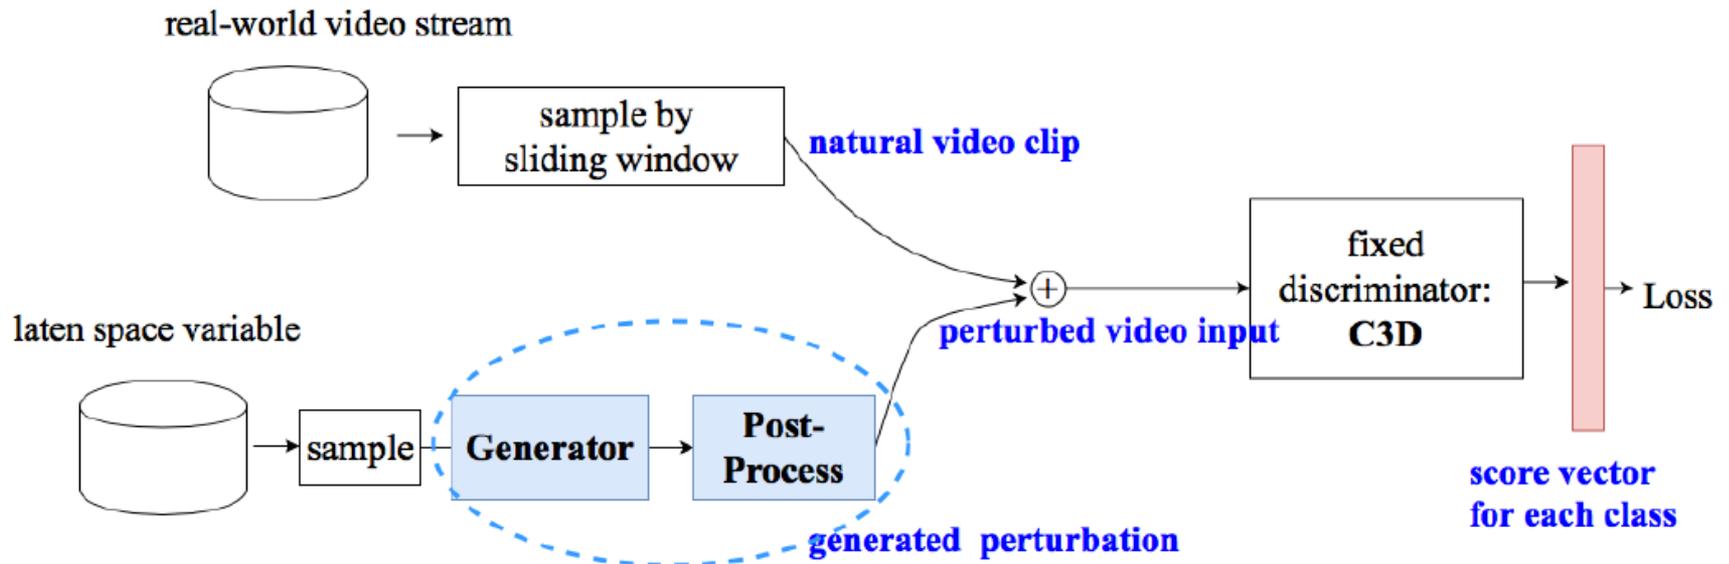


<출처 : Unvi. California , DLS '18>

Evasion Attack

▶ 비디오

- 비디오 clip을 매 프레임마다 약간씩 변조하는 방식
- GAN (Generative Adversarial Netowrk) 활용



기만 공격 분류

기만 공격 분류

▶ 공격 목표(class)에 따라

- Untargeted attack
- Targeted attack

▶ 공격자 환경(능력)에 따라

- White-box attack
- Black-box attack
- Unknown target attack

공격 목표에 따른 분류

▶ Untargeted attack

- 원본 클래스가 아닌 어떤 클래스로 인식하면 공격 성공
- 예) 감시 회피 - 범죄자 도주



Adversarial
Examples



모델
(Classifier)

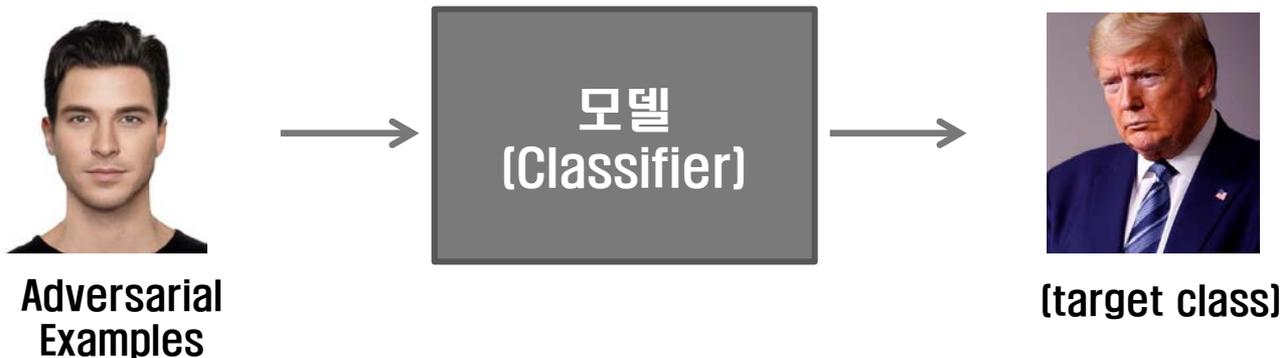


(any class except original class)

공격 목표에 따른 분류

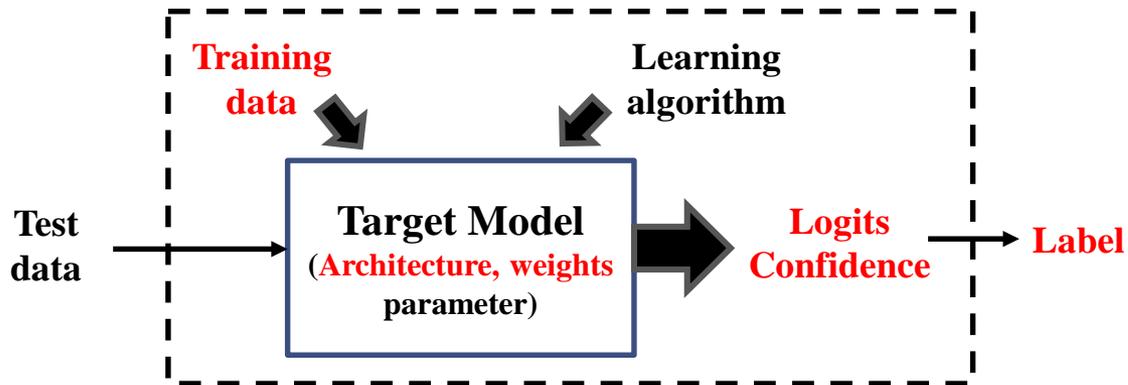
▶ Targeted attack

- **특정(target) 클래스**로 오인식하도록 유도
- Untargeted attack 에 비해 어려움 (class가 매우 많다면?)
- 예) 얼굴 인증 - 특정 인물인 척 권한 도용



공격자 환경(능력)에 따른 분류

▶ 공격자가 타겟 모델에 대해 어디까지 알고 있는가?



< 화이트박스 >



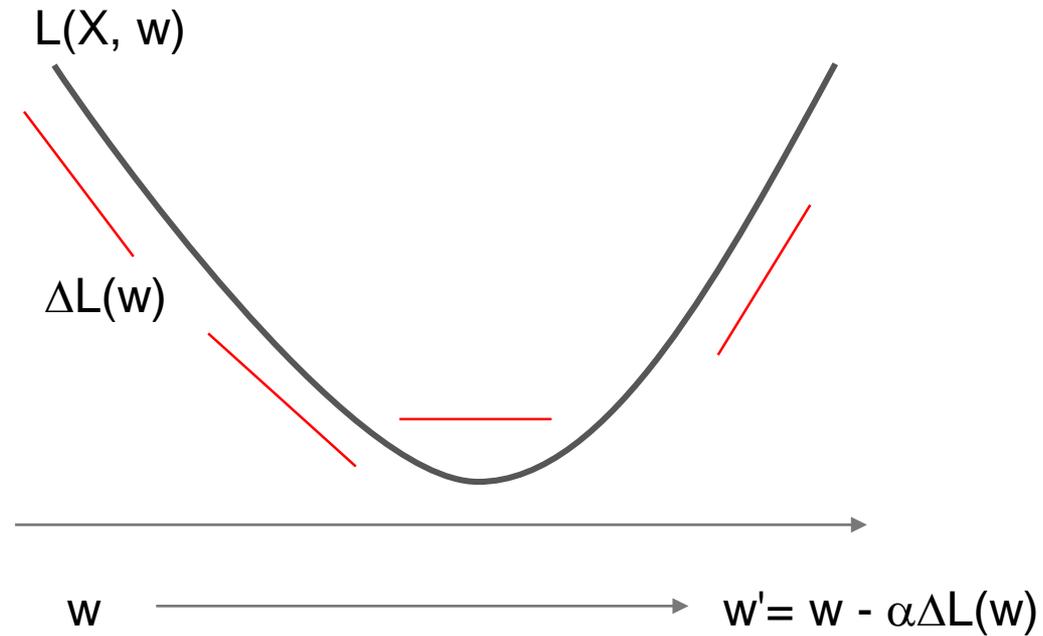
< 블랙박스 >

화이트박스 공격

▶ 머신러닝의 원리

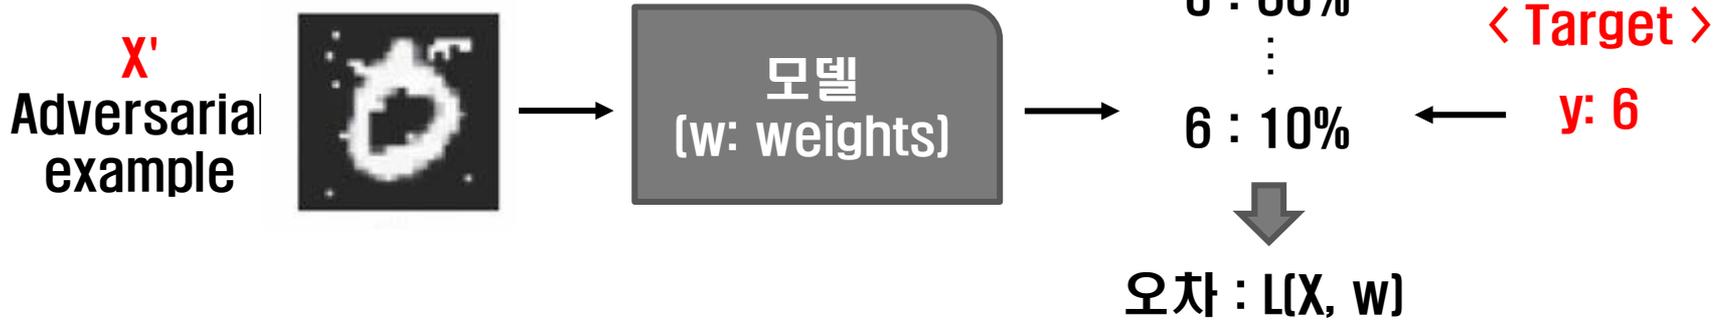


오차를 줄이기 위한 탐색
(Gradient descent)
: 정답의 확률 올리기

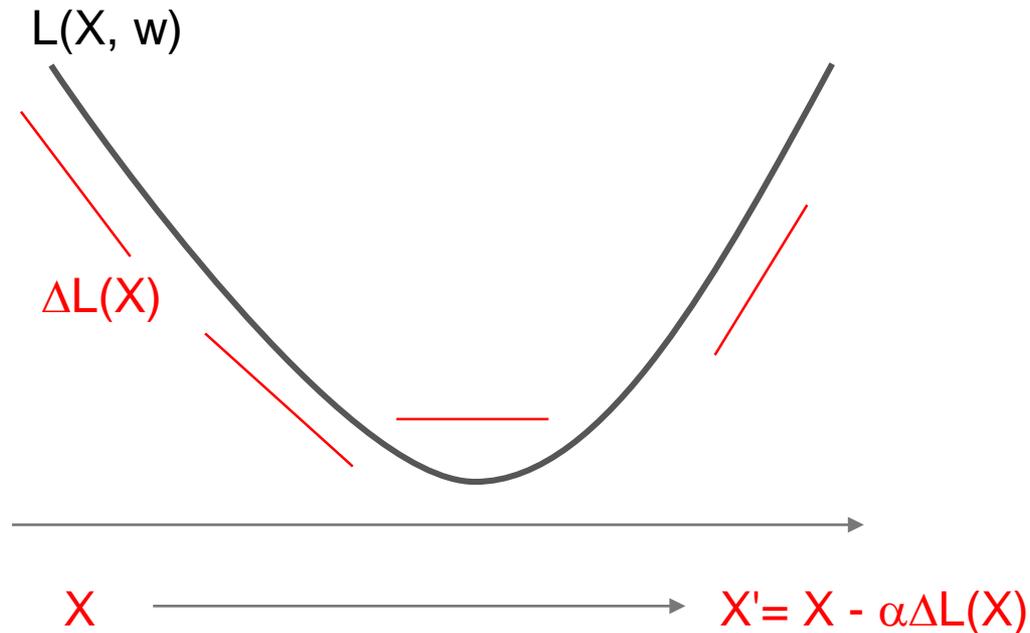


화이트박스 공격

▶ 공격 : 머신러닝과 같은 원리



공격을 위한 탐색
(Gradient descent)
: 타겟의 확률 올리기



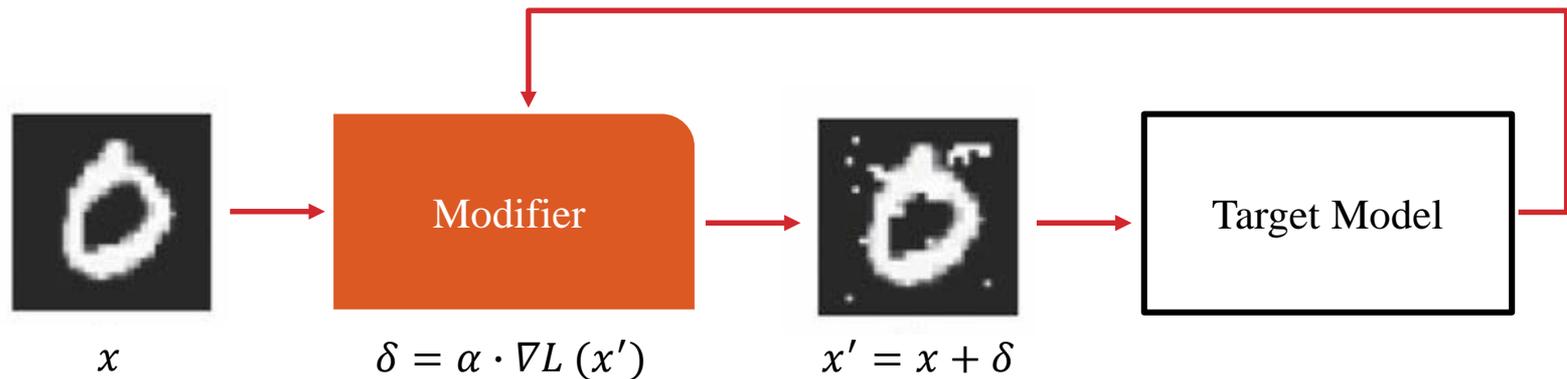
화이트박스 공격

▶ C & W attack (L2 attack)

- 100%에 가까운 성공률
- 타겟 모델 정보를 알기에 가능한 공격

$$L(x') = \|x' - x\|_2^2 + c \cdot f(x')$$

$$f(x') = \max(\{Z(x')_i : i \neq t\} - Z(x')_t)$$



화이트박스 공격

▶ 핵심은 Gradient

- Targeted attack
 - 타겟 클래스의 확률을 높이기 위한 방향
- Untargeted attack
 - 원본 클래스의 확률을 낮추기 위한 방향

▶ Gradient 를 구하기 위해 필요한 정보

- **Weights (architecture)**
- **Logits or confidence**

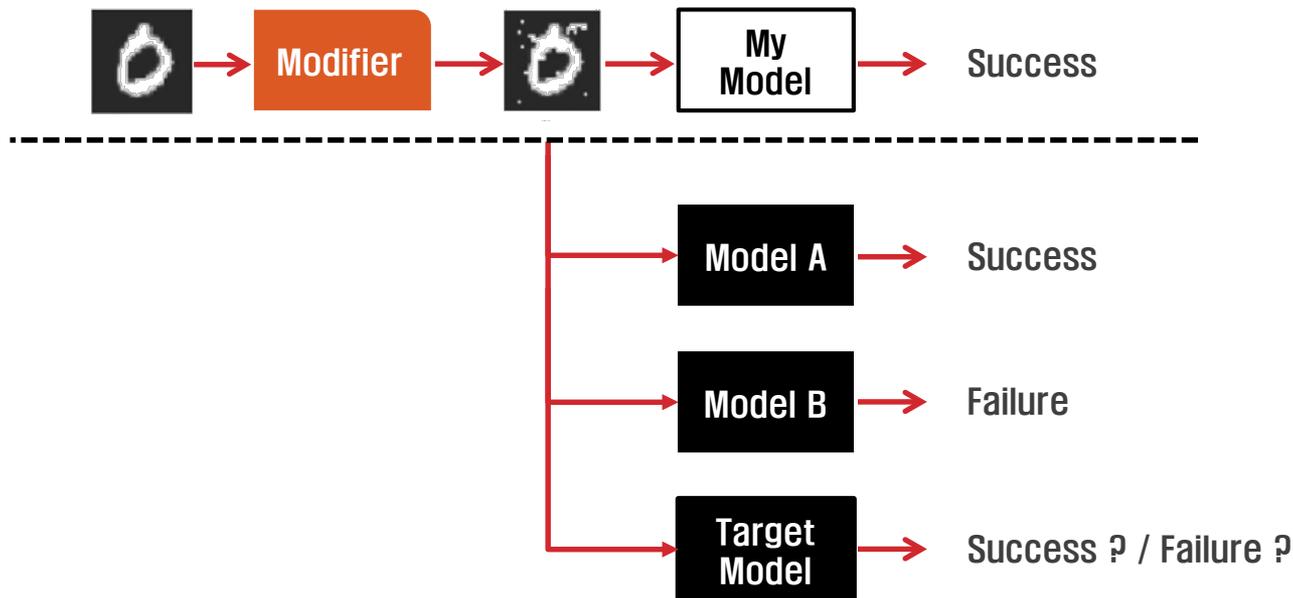
블랙박스 기만 공격 기술

Transferability

▶ 아이디어

- “모델의 목적과 학습 데이터가 비슷하다면, 한 모델을 기반으로 생성한 adversarial example은 다른 모델에도 효과적일 수 있다.”

▶ 단점 : 낮은 공격 성공률



Transferability

▶ 공격 환경 (조건)

- 내 모델과 타겟 모델이 비슷할수록 공격 성공률 향상
- 타겟 모델 정보를 많이 알수록 유리

▶ 관련된 모델 정보 (중요한 순서)

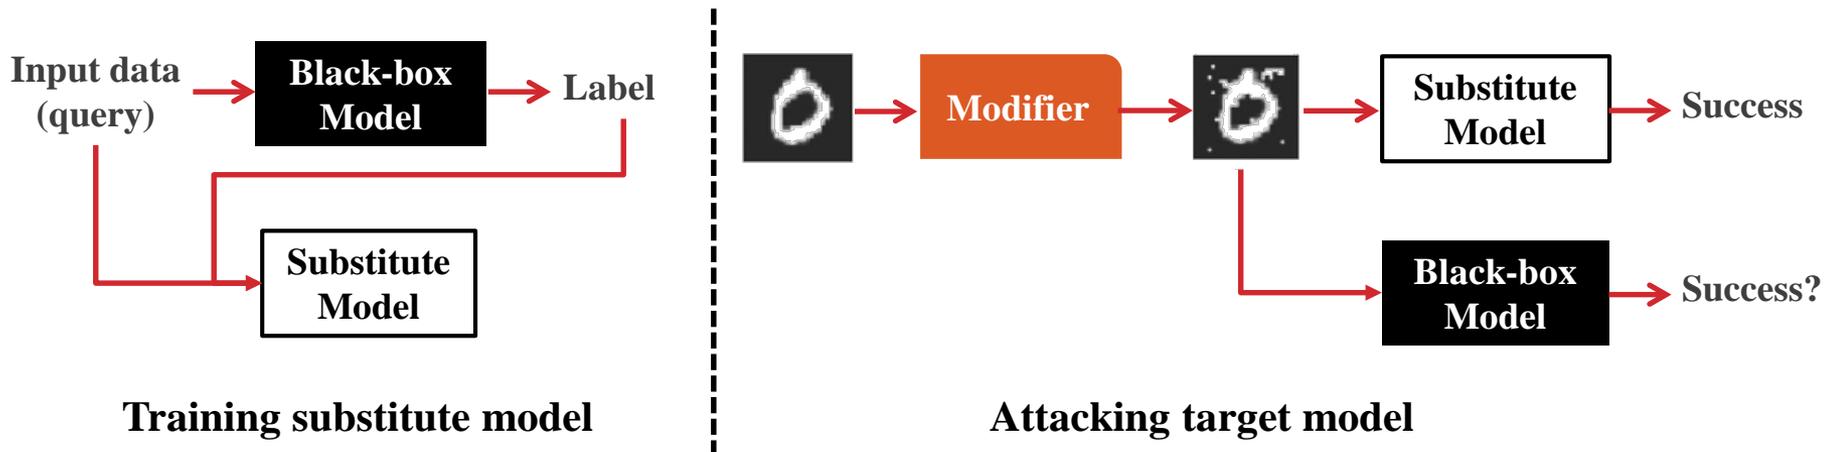
- Training data (e.g. ImageNet, VGGFace2)
- Architecture (e.g. ResNet, Inception)
- Learning algorithm
 - Loss function (e.g. cross entropy)
 - Optimizer (e.g. adam, SGD)
- Hyper Parameters

▶ 방어 : 모델 정보 유출 방지

Substitute Model

▶ 타겟 모델의 모방

- 학습 데이터 : 쿼리와 레이블 (타겟 모델의 분류 결과)
- 새 모델 학습 → 대체 모델
- 대체 모델로 adversarial example 생성 → 타겟 모델 공격



Substitute Model

▶ 블랙박스 환경

- 오직 쿼리에 대한 label 만 사용
- 학습 데이터 스스로 구성 (seed) → 증폭



▶ 장점

- 현실적인 블랙박스 환경에 가장 가까움
- Transferability의 성능 개선

▶ 단점

- 많은 수의 쿼리 필요
- Seed 에 영향을 크게 받음

▶ 방어

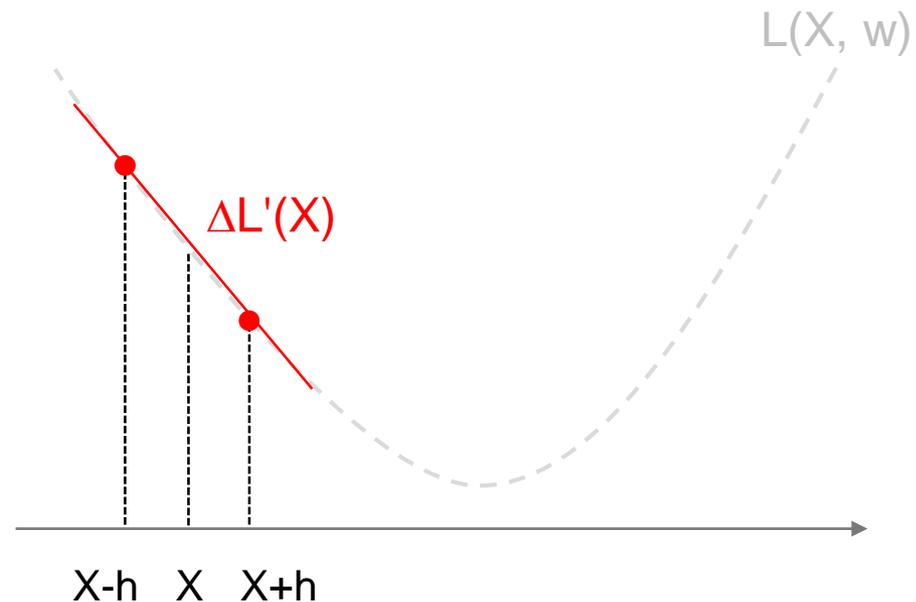
- 쿼리 수 제한

Gradient Estimation

▶ Gradient 추정

- 블랙박스 환경에서 gradient 계산 불가
[weights, architecture, confidence 모두 필요]
- $X-h$, $X+h$ 를 타겟 모델에 쿼리 → **confidence** 획득
- Confidence를 바탕으로 gradient 추정

Estimated gradient : $\Delta L'(X)$
 $\Delta L'(X)$ 는 $\Delta L(X)$ 에 비해 부정확

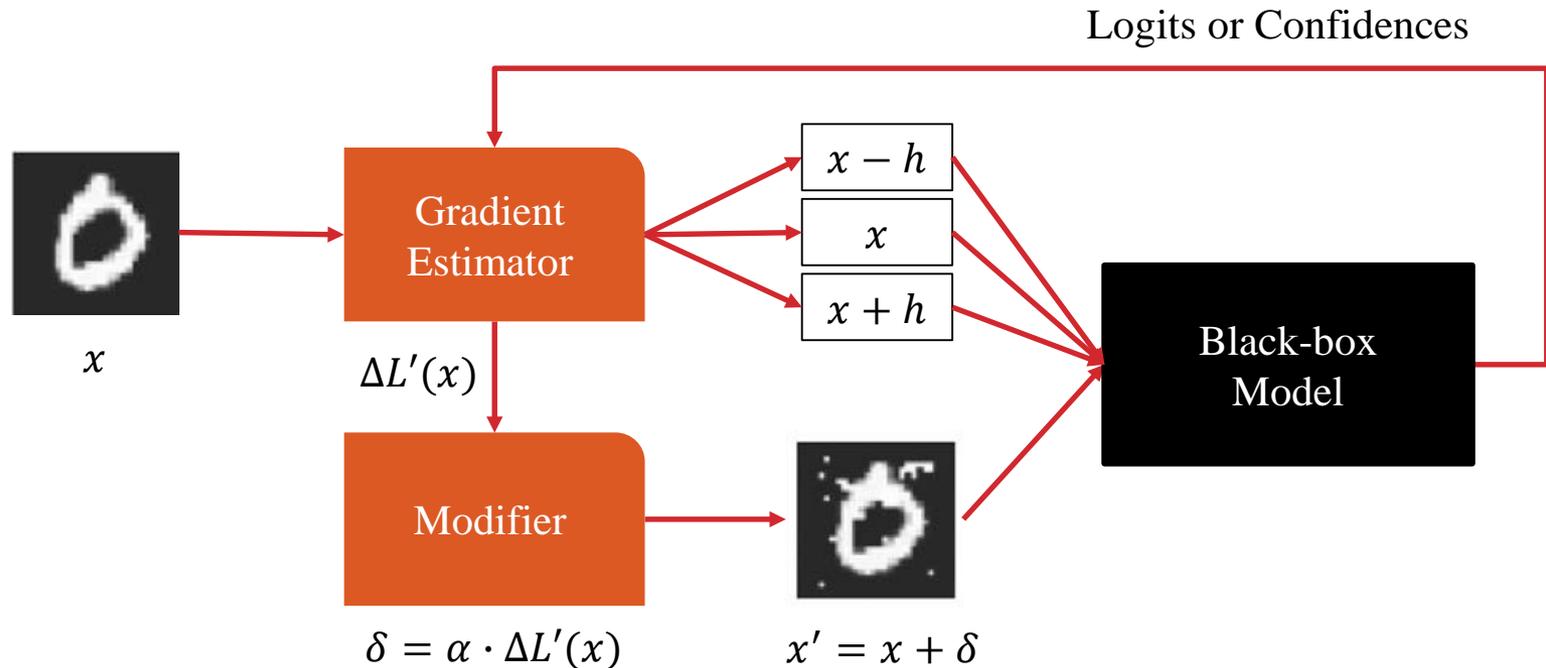


Gradient Estimation

<A. Ilyas et al., Black-box adversarial attacks with limited queries and information, ICML 2018>

▶ 공격 과정

- 쿼리를 통한 gradient 추정
- Adversarial example 생성 (화이트박스과 동일)



<A. Ilyas et al., Black-box adversarial attacks with limited queries and information, ICML 2018>

Gradient Estimation

▶ 블랙박스 환경

- Confidences 사용

▶ 장점

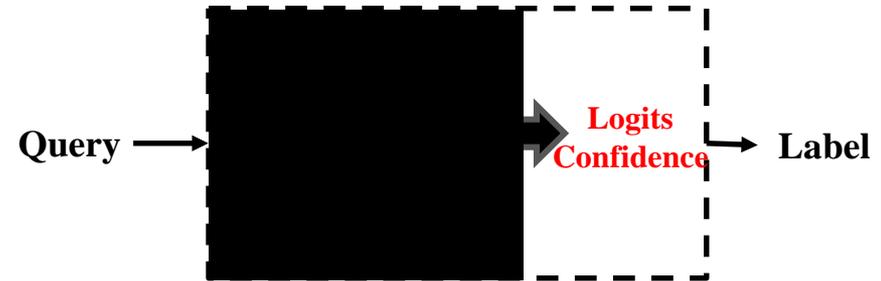
- 별도의 모델, training data 불필요
- VS. Substitute model
 - 공격 성공률 높음, 쿼리 수 적게 필요

▶ 단점

- **Confidences 반드시 필요** [타겟 모델이 제공하지 않으면?]

▶ 방어

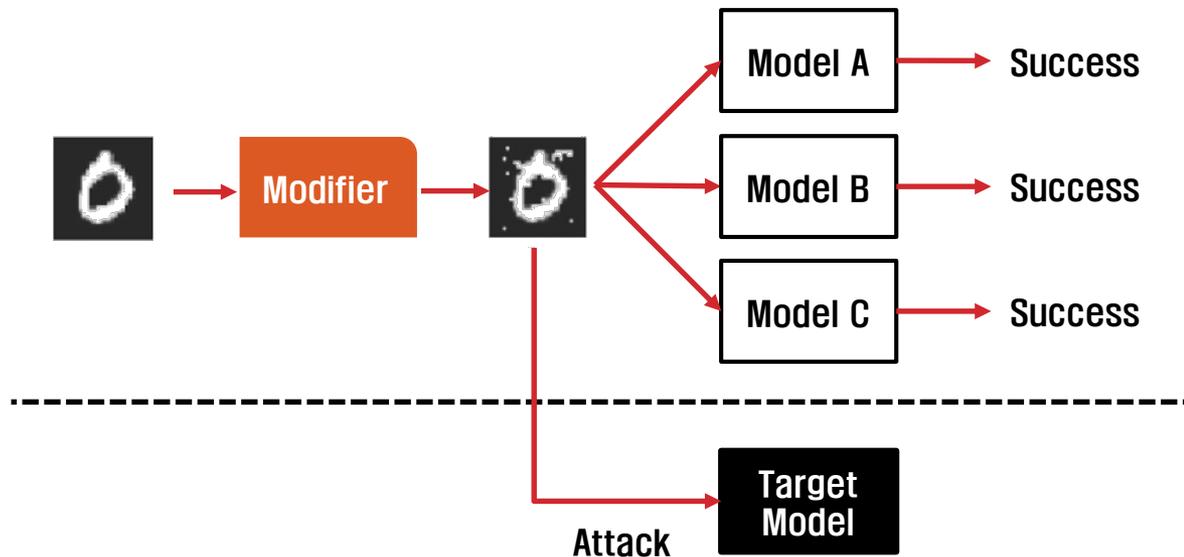
- 쿼리 수 제한, confidence 미제공



Model Ensemble

▶ 모델 앙상블 기반 공격

- 여러 종류의 모델 생성
- 모든 모델을 속이는 adversarial example 생성
- Transferability의 극대화



Model Ensemble

▶ 블랙박스 환경

- 타겟과 동일한 training data

▶ 장점

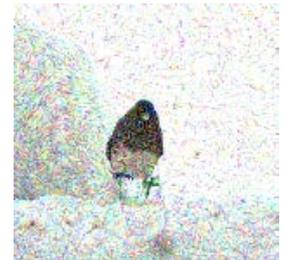
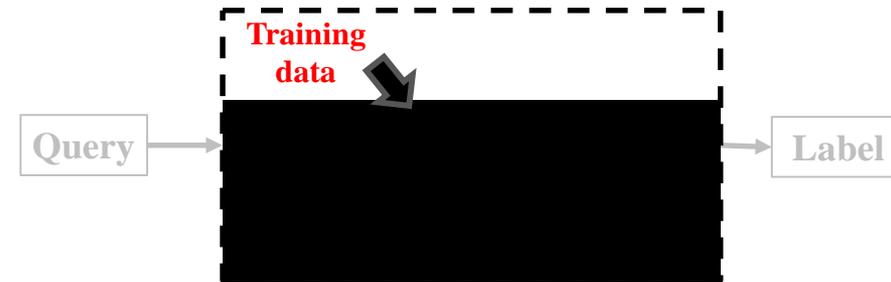
- 쿼리 과정 불필요
- 타겟 모델과의 architecture 차이 극복
- 높은 공격 성공률

▶ 단점

- 타겟 모델과 비슷한 **training data 필요**
(없다면 큰 폭의 성능 하락 예상)
- 노이즈량 (distortion) 이 많음

▶ 방어

- Detection 알고리즘, training data 미제공/변형



블랙박스 기만 공격

▶ 조건

△ : 있으면 성공률이 높아짐

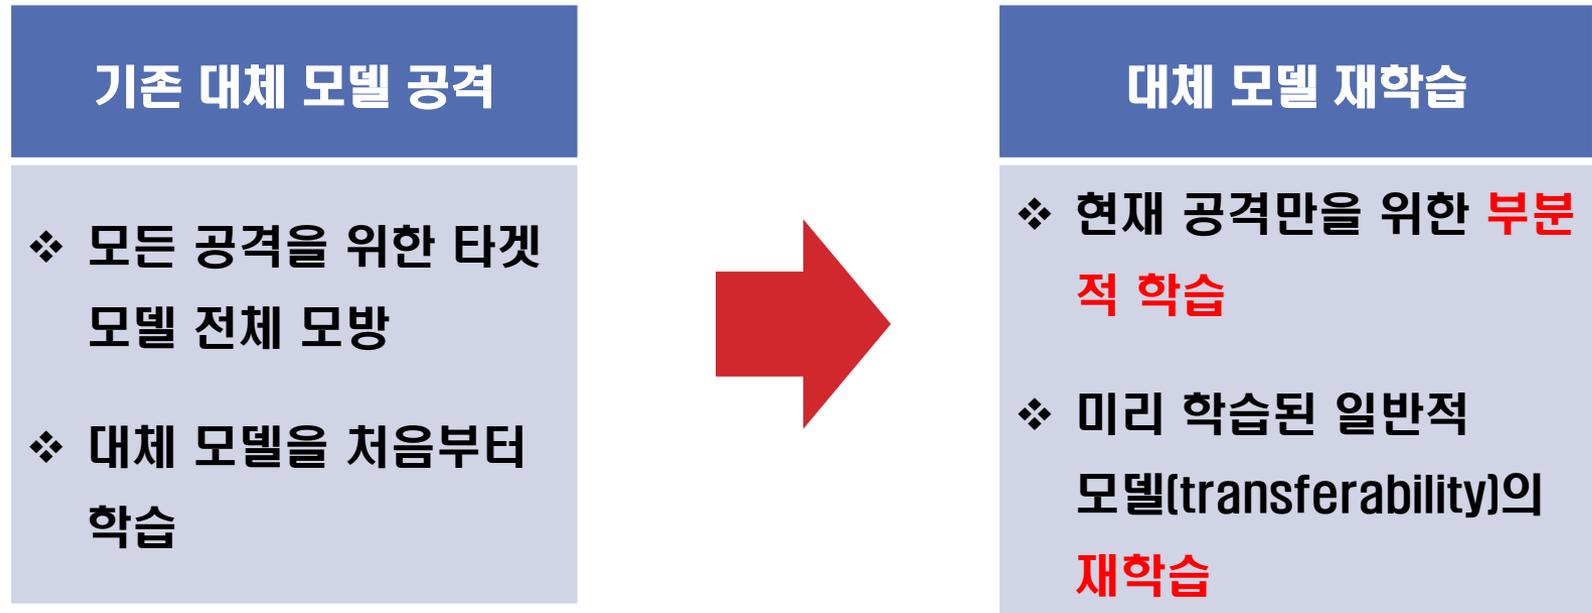
	Training data	Logits Confidence	Architecture	Other information
Transferability	△	X	△	△
Substitute model	X	X	X	X
Gradient estimation	X	O	X	X
Model ensemble	O	X	X	X

▶ 평가

	공격 성공률	쿼리 수	노이즈량
Transferability	하~중	X	하
Substitute model	중상	상	하
Gradient estimation	상	중	하
Model ensemble	상	X	상

Retraining Substitute Model

▶ 주요 아이디어



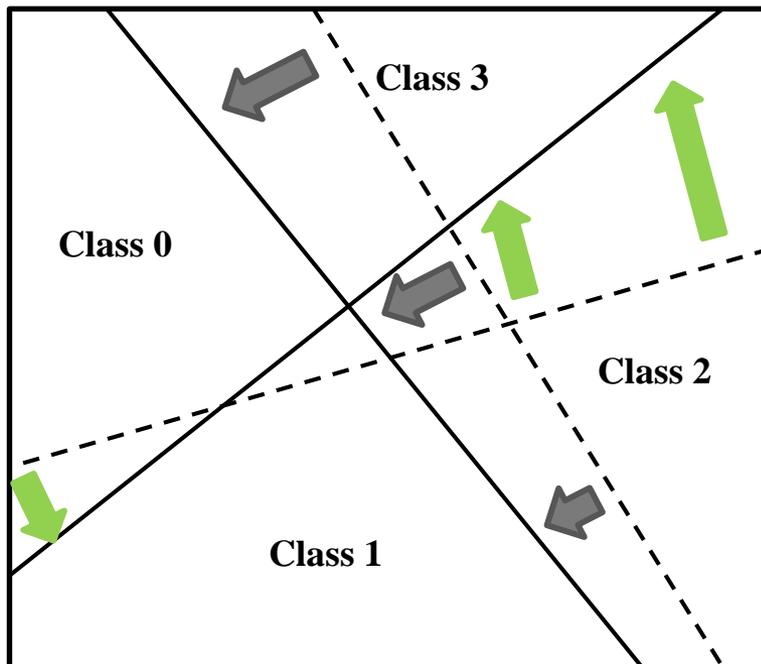
▶ 목표

- 쿼리 개수 감소, 공격 성공률 향상

Retraining Substitute Model

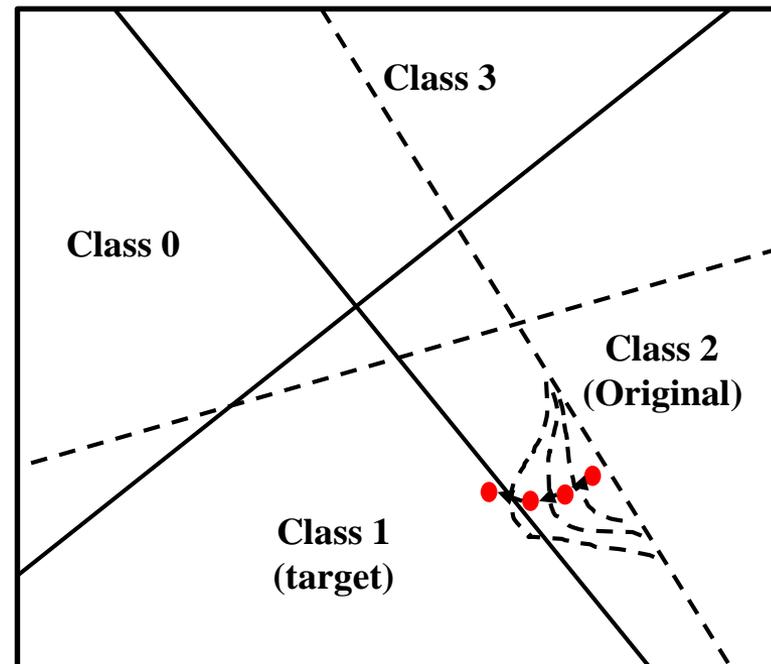
▶ 컨셉

전체 학습



— Target model
-- Substitute model

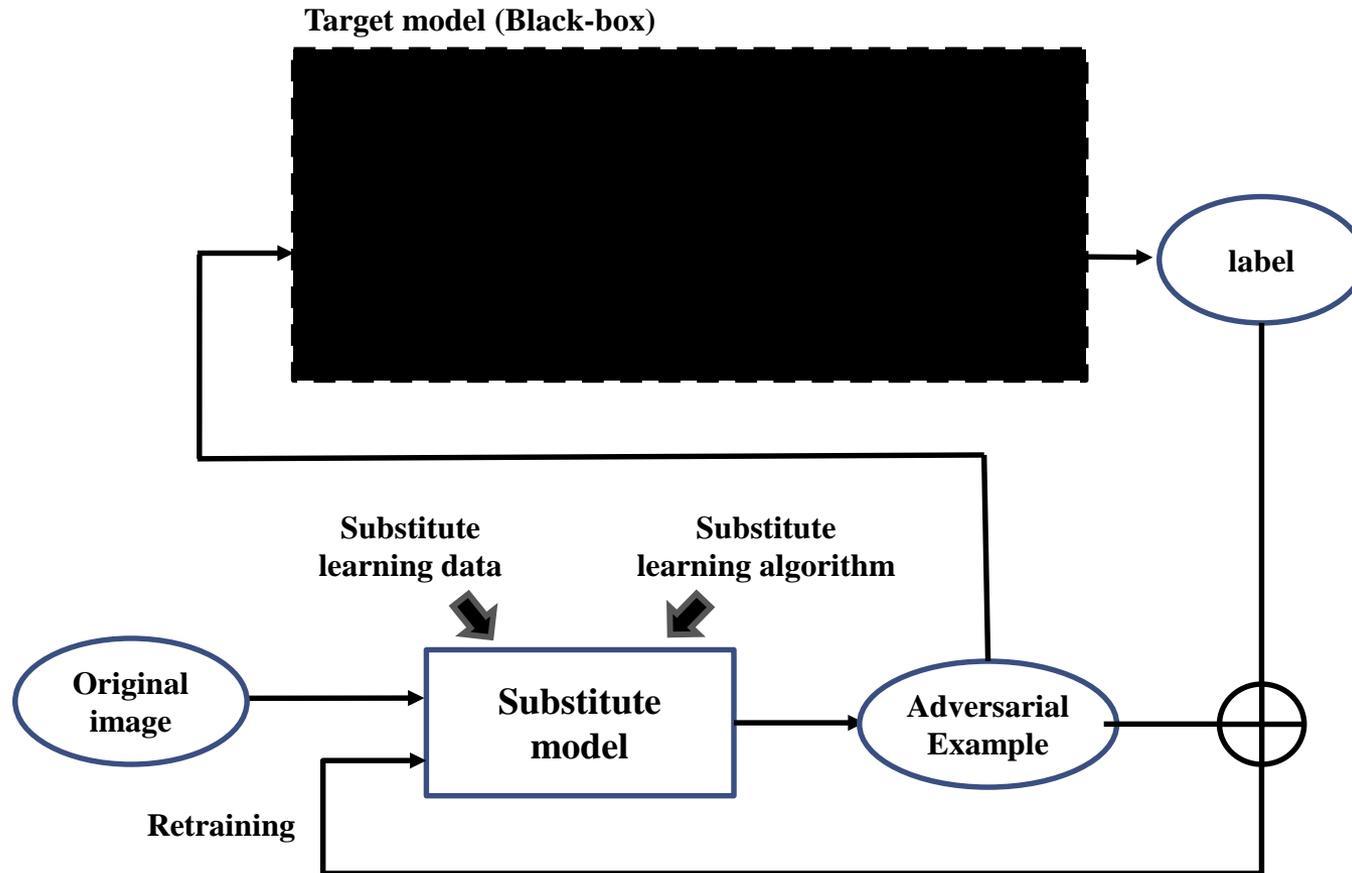
부분적 재학습



— Target model
-- Substitute model

Retraining Substitute Model

▶ 공격 과정



Issues

▶ 각자 큰 단점 → 해결

- 블랙박스 조건 미흡 (confidence, training data)
- 너무 많은 쿼리 필요

▶ 공격 성공률 부족

- 블랙박스 조건 상정
- 큰 데이터셋 상정 (이미지 크기, class 수)

▶ Image classification 한정

- 아직 다른 분야에서는 연구 부족