

Beijing Forest Studio  
北京理工大学信息系统及安全对抗实验中心



# 基于知识蒸馏的模型窃取方法

基于知识蒸馏的模型窃取方法

硕士研究生 丁杨

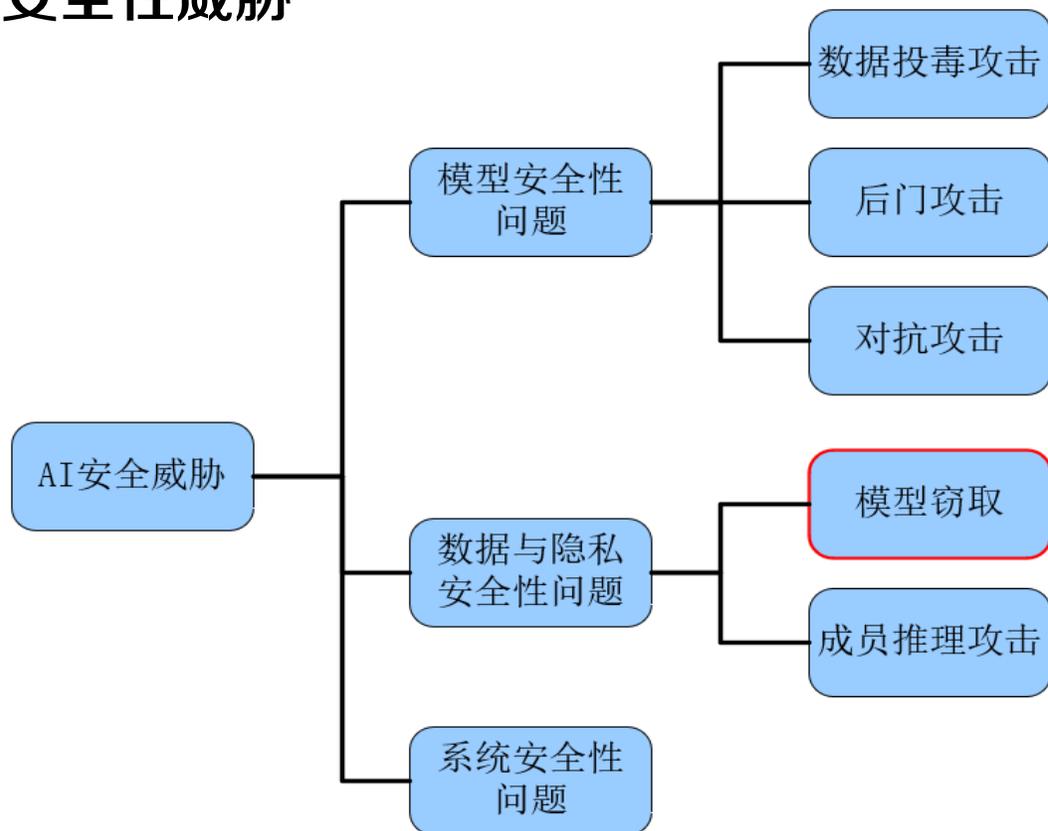
2021年11月14日

- 背景简介
- 基本概念
- 算法原理
- 优劣分析
- 应用总结
- 参考文献

- 预期收获
  - 1. 了解模型窃取方法的发展历史
  - 2. 理解基于知识蒸馏的模型窃取方法的技术原理
  - 3. 了解模型窃取在网络安全领域中的应用

- 人工智能的发展

- 推动社会经济各个领域从数字化、信息化向智能化发展
- 面临着严重的安全性威胁



- 模型窃取的发展历史

- 2016年, Tramer 等人通过求解从机器学习模型结构导出的方程来提取模型的参数, 但只限于SVM、随机森林等**简单的模型**
- 2017年, Papernot 以牺牲替代模型的准确性为代价, 通过近似目标模型的**决策边界**, 近似窃取了DNN模型
- 2018-2019年, Orekondy 等一些科学家先后在已知训练数据、已知训练数据**种子样本**等条件下, 实现了对DNN的窃取
- 最新的研究则关注如何在**未知训练数据**的情况下进行模型窃取



## 基本概念

- 模型窃取

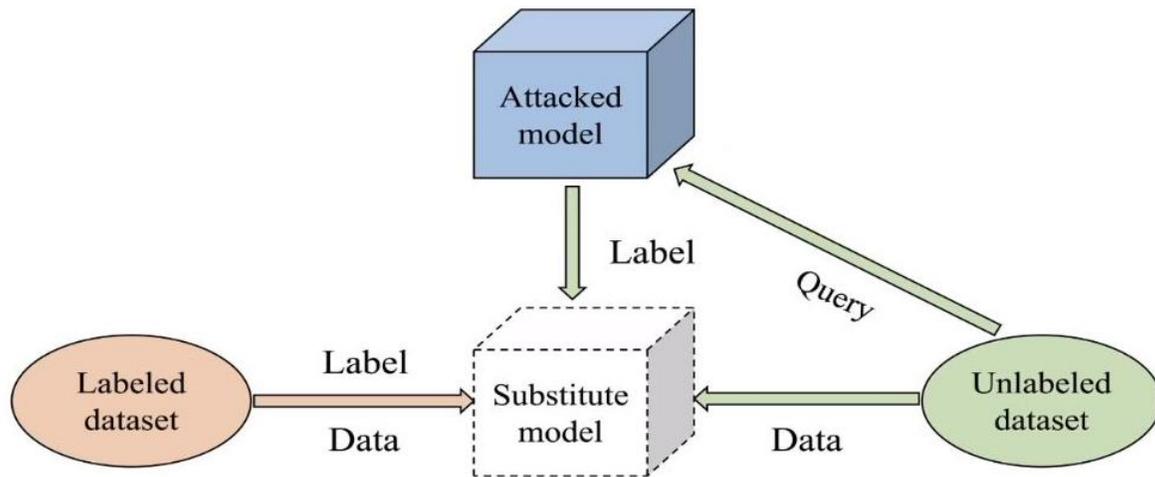
- 概念：一类隐私数据窃取攻击，攻击者通过向目标模型进行查询获取相应结果，窃取目标模型的**参数**或者**对应功能**

- 目的：

- 免费使用模型
- 进行对抗攻击

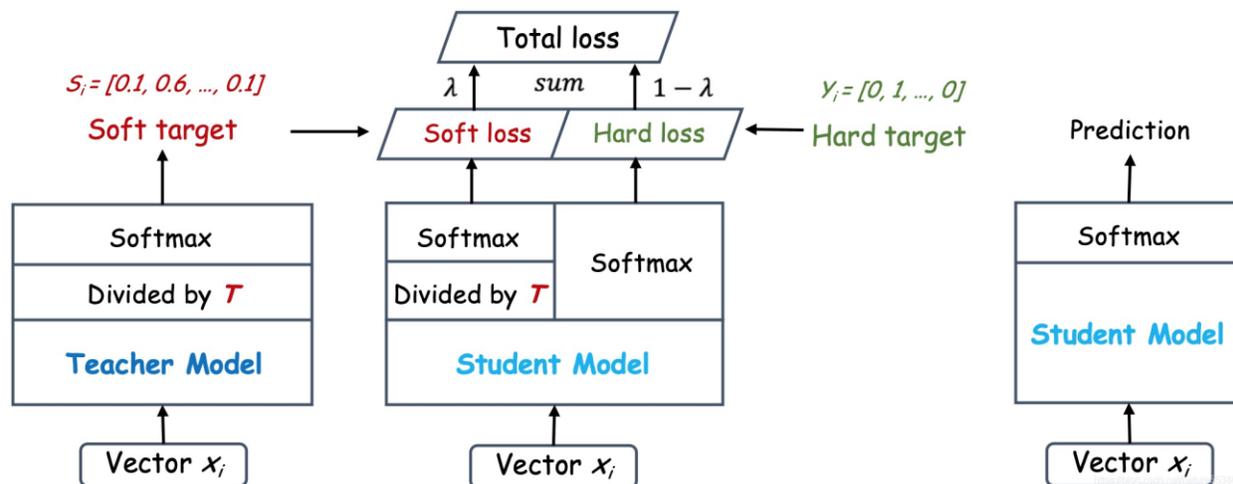
- 方法

- 构建方程求解参数
- 训练替代模型



- 知识蒸馏

- 概念：把复杂模型或者多个模型（Teacher）学到的知识迁移到另一个模型（Student）上
- 本质：**模型压缩**，让小模型去学习大模型的知识，即让Student模型的输出拟合Teacher模型的输出
- Teacher模型和Student模型没有网络结构的限制



- 相对熵

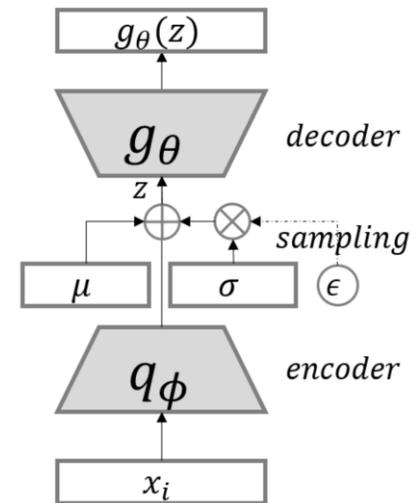
- 概念：又称为Kullback-Leibler散度（Kullback-Leibler divergence）或信息散度（Information divergence），是两个**概率分布差异**的非对称性度量
- 设  $P(x)$   $Q(x)$  是随机变量  $X$  上的两个概率分布，则在离散和连续随机变量的情形下，相对熵的计算公式分别为：

$$\text{KL}(P \parallel Q) = \sum P(x) \log \frac{P(x)}{Q(x)}$$

$$\text{KL}(P \parallel Q) = \int P(x) \log \frac{P(x)}{Q(x)} dx$$

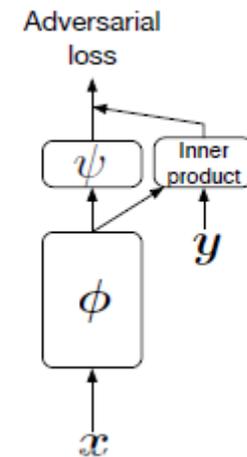
- VAE (变分自编码器)

- 通过编码过程生成输入样本分布的均值与方差，然后通过采样的方法来复原输入样本分布，并且使用复原的分布和真实分布的距离来进行参数的调节



- SNGAN (频谱归一化GAN)

- 输入首先经过网络  $\phi$  提取特征，然后把特征分成两路，一路与经过编码的类别标签  $y$  做点乘，另一路通过网络  $\psi$  映射成一维向量，最后两路相加，作为神经网络最终的输出



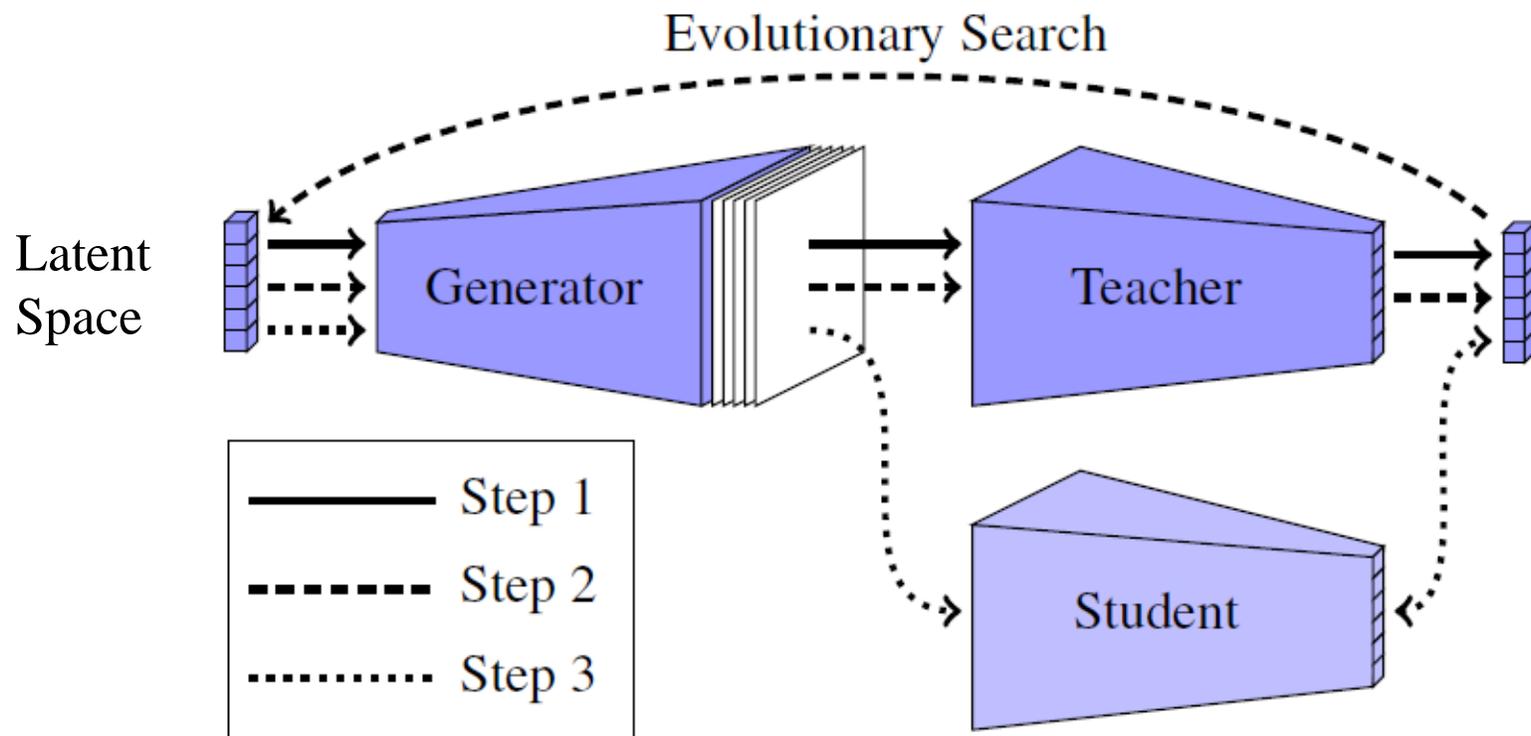


## 算法原理

T	模型窃取
I	Teacher 模型
P	<ol style="list-style-type: none"><li>1. 生成随机样本，随机样本通过生成器得到数据样本</li><li>2. 调用Teacher 模型，得到数据样本的分类预测概率</li><li>3. 基于进化策略优化样本空间</li><li>4. 训练Student 模型</li></ol>
O	Student 模型

P	无法获得Teacher 模型原始的训练数据与内部参数
C	攻击者可以获得Teacher 模型输出的 <b>分类预测概率</b>
D	生成与原训练数据分布相近的训练数据
L	NeurIPS 2020

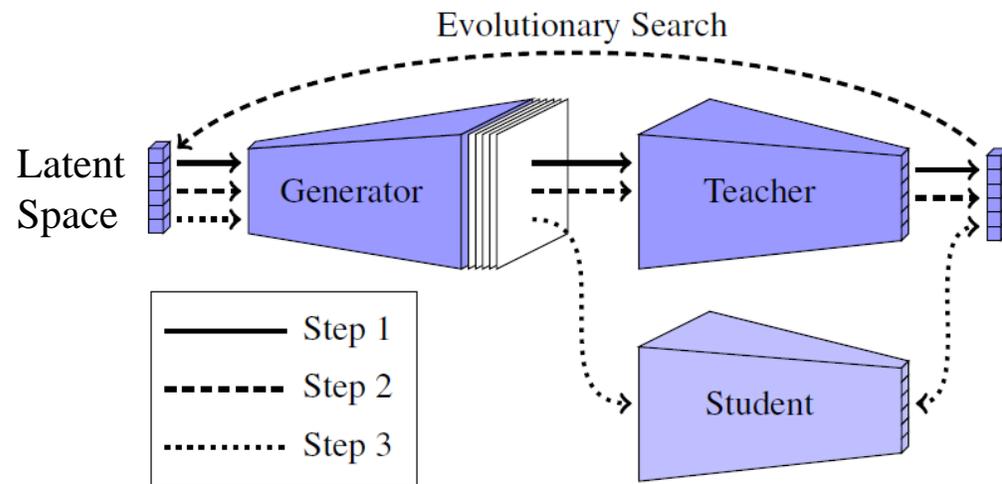
- 算法流程图



$$\min_{\theta_S} \|S(Z \downarrow \uparrow, X' \downarrow) - T(X \downarrow \uparrow, X' \downarrow)\|$$

- 算法流程

- 在潜在空间中生成一组随机样本
- 随机样本通过生成器得到**数据样本**
- 数据样本通过Teacher 模型得到对应的**分类预测概率**
- 采用进化算法，利用类概率信息优化潜在空间
- 使用优化的潜在空间生成数据，训练Student 模型



$$\min_{\theta_S} \|S(Z \downarrow \uparrow, X' \downarrow) - T(X \downarrow \uparrow, X' \downarrow)\|$$

- 进化算法

- 目的:在期望的类上生成高置信度的数据样本

- 过程:

---

**Algorithm 1** Evolutionary Optimization Algorithm

---

**Input:**  $y$  - desired class label,  $T$  - black-box teacher,  $G$  - generator trained on  $Z$ .

**Hyperparameters:**  $K$  - population size,  $k$  - elite size,  $u$  - latent space boundary,  $t$  - threshold for stopping criterion.

**Output:**  $p^*$  - generated data sample with high confidence on desired class  $y$ .

```
1: procedure OPTIMIZE( $y, T, G, K, k$ )
2:   Initialize population from a uniform distribution:  $P \leftarrow \{U(-u, u)\}_K$ 
3:   Select fittest latent vector:  $p^* \leftarrow \min_{p \in P} V(p, y, T, G)$ 
4:   while  $V(p^*, y, T, G) \geq t$  do
5:     Select fittest  $k$  vectors:  $P_e \subset P$ 
6:     Uniformly sample  $K - k$  copies from  $P_e$ :  $P_c \leftarrow \{U(P_e)\}_{K-k}$ 
7:     Mutate copied vectors with Gaussian noise:  $P_c \leftarrow P_c + \mathcal{N}(0, 1)$ 
8:     Replace old population with new one:  $P \leftarrow P_e \cup P_c$ 
9:     Select fittest latent vector:  $p^* \leftarrow \min_{p \in P} V(p, y, T, G)$ 
10:  return  $G(Z \downarrow \uparrow, p^* \downarrow)$ 
```

---

$$\min_v V(v, y, T, G) = \min_v \sum_{i=1}^n (T(X \downarrow \uparrow, G(Z \downarrow \uparrow, v \downarrow) \downarrow) - y_i)^2 = \min_v \sum_{i=1}^n (\hat{y}_i - y_i)^2$$

- 数据集
  - CIFAR-10、CIFAR-100 和Fashion-MNIST
- 实验条件
  - Teacher 模型的训练数据未知
  - 攻击者可以获得Teacher 模型的分​​类预测概率
- 实验设置
  - 预训练生成器(VAE, SNGAN)
  - 预训练Teacher 模型
- 评价方法
  - Student 模型的准确率

- CIFAR-10数据集上的实验
  - Teacher 模型使用AlexNet 架构
  - Student 模型使用Half-AlexNet 架构

Proxy Dataset	CIFAR-100 90 classes	CIFAR-100 40 classes	CIFAR-100 10 classes	CIFAR-100 6 classes
Teacher Accuracy	82.5	82.5	82.5	82.5
Knockoff Nets [31]	74.5	65.7	46.6	36.4
ZSKD [28]	69.5	69.5	69.5	69.5
DeGAN [1]	<b>80.5</b>	76.3	72.6 ± 3.3	59.5
Black-Box Ripper ( <b>Ours</b> )	79.0 ± 0.2	<b>76.5 ± 0.1</b>	<b>77.9 ± 0.3</b>	<b>69.9 ± 0.2</b>

- 随着代理数据集中类的数量越来越少，Student 模型的准确率下降幅度受影响较小

- Fashion-MNIST 数据集上的实验
  - Fashion-MNIST 作为真实数据集，CIFAR-10 作为代理数据集
  - Teacher 模型分别选择VGG-16 与LeNet
  - Student 模型对应选择VGG-16 与Half-LeNet

Architectures	VGG-16	LeNet → Half LeNet
Teacher Accuracy	94.2	89.9
Knockoff Nets [31]	82.9	77.8
ZSKD [28]	-	79.6
DeGAN [1]	-	<b>83.7</b>
VAE (no evolutionary optimization)	78.3	73.1
SNGAN (no evolutionary optimization)	87.6	80.0
Black-Box Ripper with VAE ( <b>Ours</b> )	86.1	78.8
Black-Box Ripper with SNGAN ( <b>Ours</b> )	<b>90.0</b>	82.2

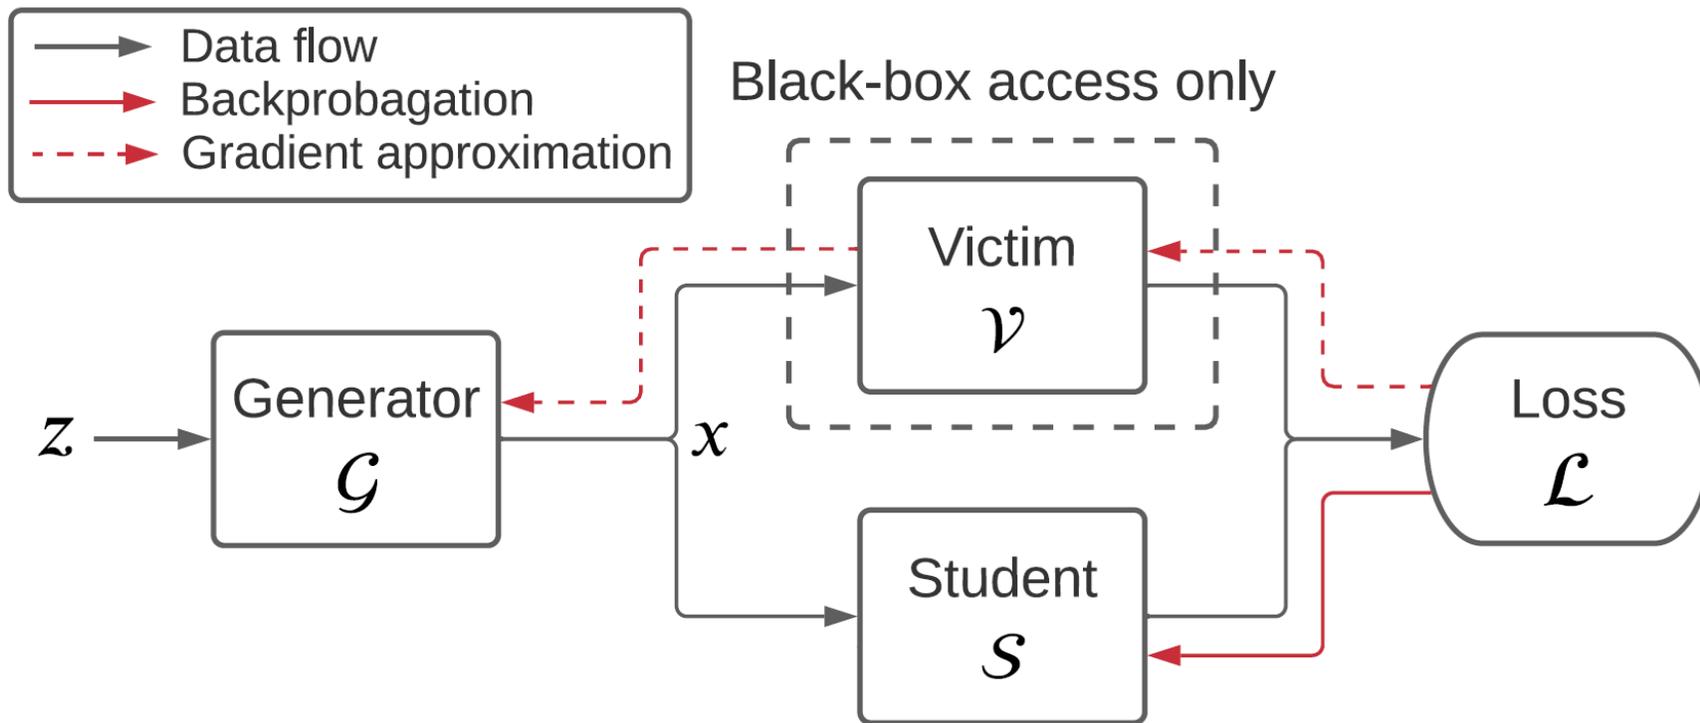


## 算法原理

T	模型窃取
I	Victim模型
P	For { 1. 生成器生成数据 2. 将数据通过Victim模型与Student模型 3. 计算损失函数 4. 反向传播, 优化生成器与Student模型 }
O	Student模型

P	无法获得原始的训练数据与内部参数
C	攻击者可以自由访问Victim模型获得其 <b>分类预测概率</b>
D	Victim模型的梯度信息
L	CVPR 2021

## • 算法流程图



$$\min_S \max_G \mathbb{E}_{z \sim \mathcal{N}(0,1)} [\mathcal{L}(\mathcal{V}(\mathcal{G}(z)), \mathcal{S}(\mathcal{G}(z)))]$$

- 损失函数的选择

- 知识蒸馏中，大多数的损失函数使用**相对熵**

$$\mathcal{L}_{\text{KL}}(x) = \sum_{i=1}^K \mathcal{V}_i(x) \log \left( \frac{\mathcal{V}_i(x)}{\mathcal{S}_i(x)} \right)$$

- 随着Student 模型与Victim 越来越接近，相对熵的梯度快速衰减，使得生成器难以收敛，因此选择了**L1范数**作为损失函数

$$\mathcal{L}_{\ell_1}(x) = \sum_{i=1}^K |v_i - s_i|$$

- 反向传播
  - Student 模型的参数梯度下降

$$z \sim \mathcal{N}(0, 1)$$

$$x = G(z; \theta_G)$$

$$\text{compute } \mathcal{V}(x), \mathcal{S}(x), \mathcal{L}(x), \nabla_{\theta_S} \mathcal{L}(x)$$

$$\theta_S = \theta_S - \eta \nabla_{\theta_S} \mathcal{L}(x)$$

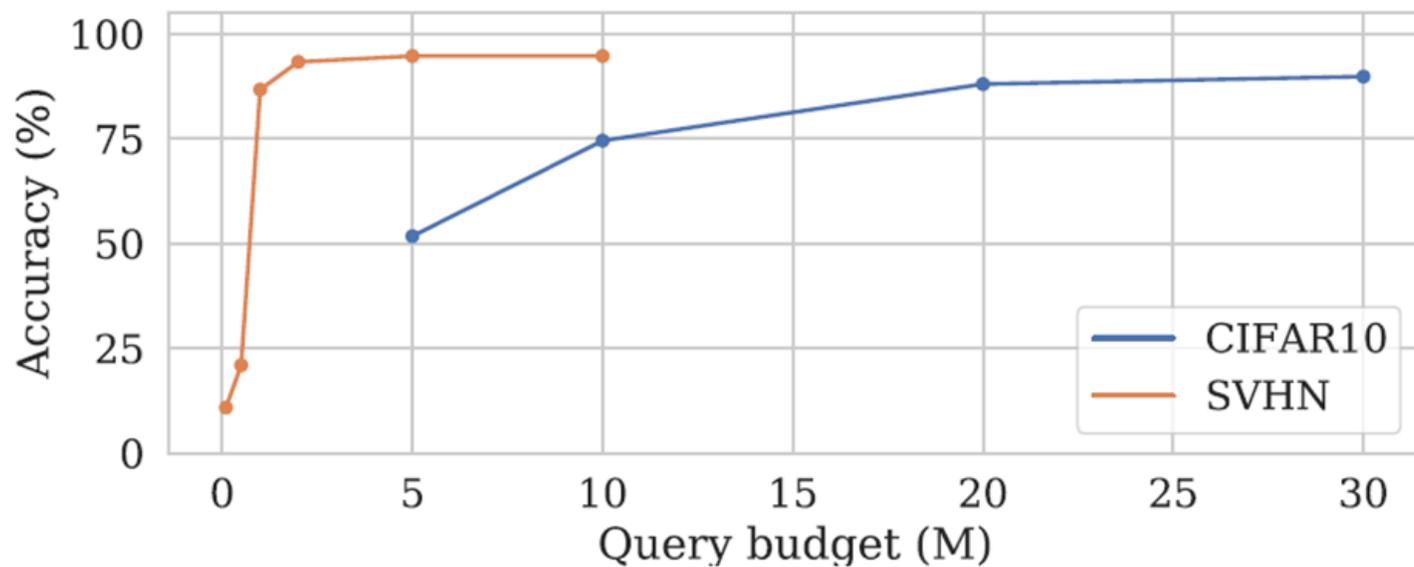
- 梯度逼近
  - 通过函数在多个  $u_i$  方向上的一小步的**平均变化**来计算

$$\nabla_{\text{FWD}} f(x) = \frac{1}{m} \sum_{i=1}^m \frac{f(x + \epsilon \mathbf{u}_i) - f(x)}{\epsilon} \mathbf{u}_i$$

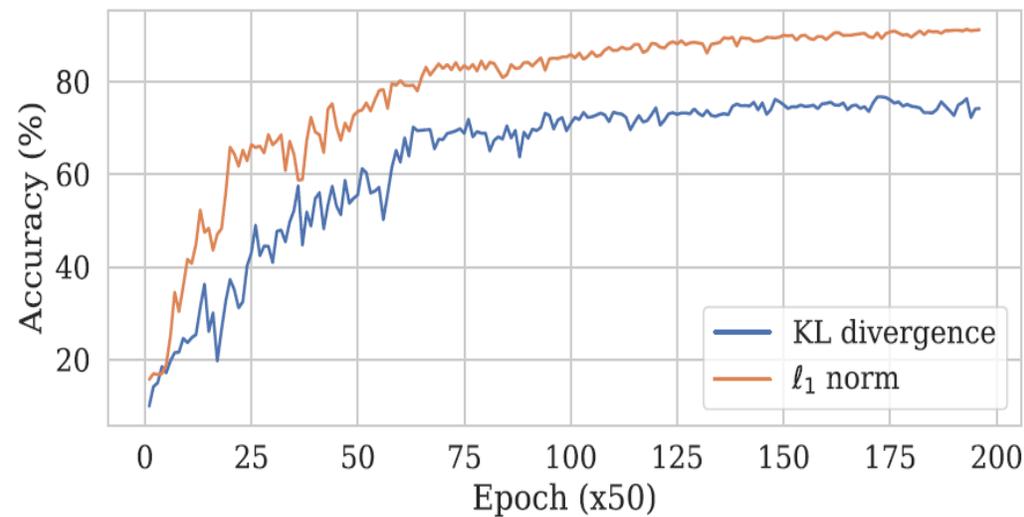
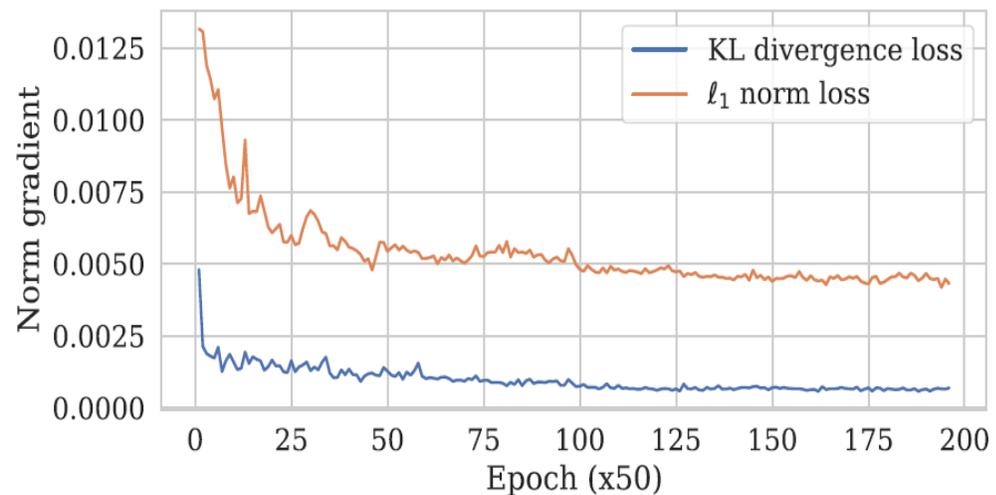
- 数据集
  - SVHN、CIFAR-10
- 实验条件
  - Victim 模型的训练数据未知
  - 攻击者可以获得Victim 模型的分​​类预测概率
- 实验设置
  - 生成器使用三个卷积层，与线性上采样层、批量标准化层和除最后一层外所有层的ReLU 激活函数相互交织
  - 预训练Victim 模型
- 评价方法
  - Student 模型的准确率

- Student模型准确率实验

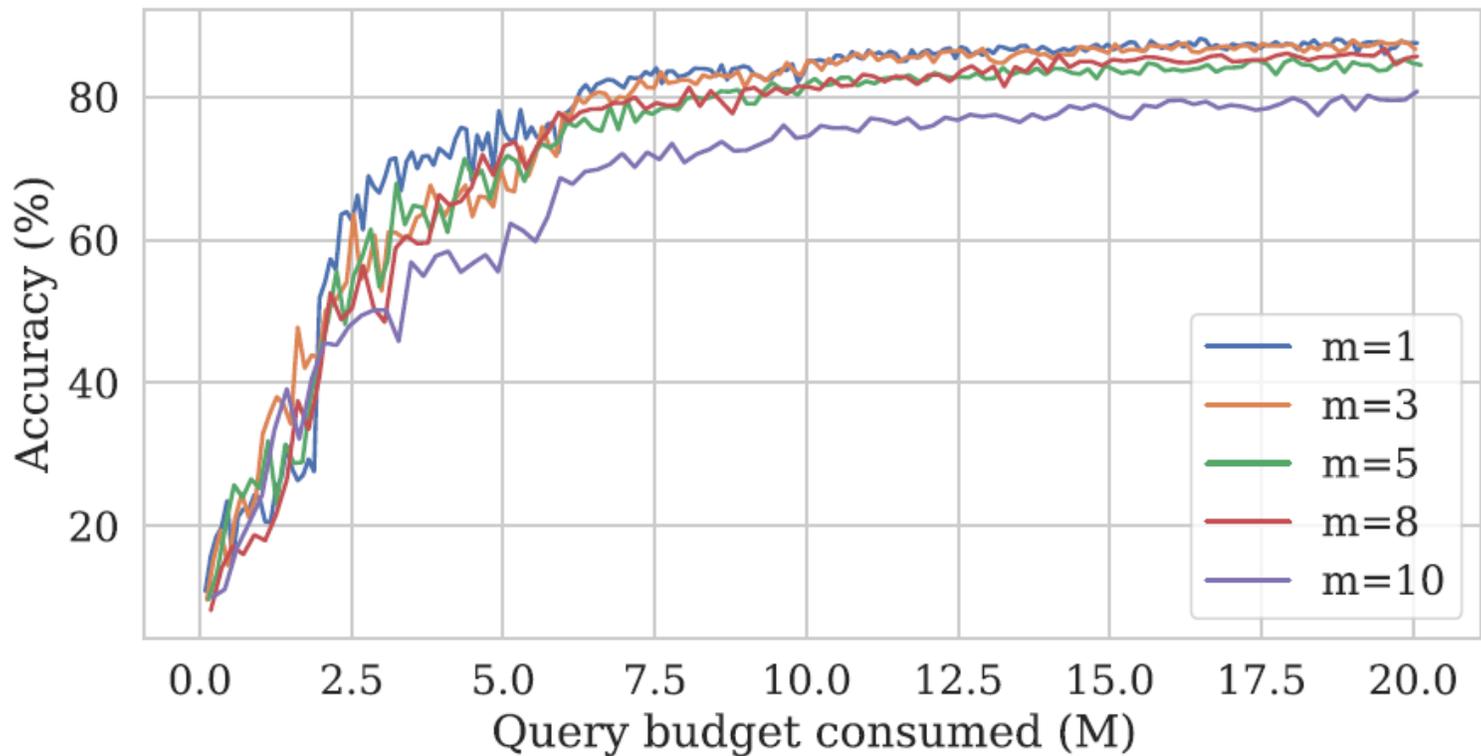
Dataset (budget)	Victim accuracy	DFME	DFME-KL	MAZE* [20]	Log-Probabilities
CIFAR10 (20M)	95.5%	88.1% (0.92×)	76.7% (0.80×)	45.6% (0.48×)	73.2% (0.77×)
SVHN (2M)	96.2%	95.2% (0.99×)	84.7% (0.88×)	91.1% (0.95×)	94.4% (0.98×)



- 消融实验
  - 损失函数的不同选择



- 消融实验
  - 参数 $m$ 的选择



- 优势
  - 两种算法都利用**知识蒸馏**的思想，使用生成器产生数据训练Student 模型，无需Teacher 模型的训练数据
  - DFME 利用**对抗生成网络**的思想，使用生成器产生数据计算模型差异，再由差异修正生成器与替代模型，生成器随实际情况调整
- 不足
  - 需要Teacher 模型的**分类预测概率**信息
  - 需要生成**大量数据**进行目标模型的输入查询，为其生成标签
  - 由于生成数据的不可控，会有大量**无效查询**



## 应用总结

- **算法的应用领域**
  - 通过模型窃取获取目标模型的参数信息，使用白盒方法生成对抗样本
  - 通过模型窃取获得原始训练数据
- **未来的发展**
  - 模型窃取方法的可迁移性
  - 不依赖模型类概率输出的条件下进行模型窃取

- [1] Kariyappa S, Prakash A, Qureshi M K. Maze: Data-free model stealing attack using zeroth-order gradient estimation[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2021: 13814-13823.
- [2] Truong J B, Maini P, Walls R J, et al. Data-free model extraction[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2021: 4771-4780.
- [3] S. Kariyappa, A. Prakash and M. K. Qureshi, "MAZE: Data-Free Model Stealing Attack Using Zeroth-Order Gradient Estimation," 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2021, pp. 13809-13818, doi: 10.1109/CVPR46437.2021.01360.
- [4] Tramèr F, Zhang F, Juels A, et al. Stealing machine learning models via prediction apis[C]//25th USENIX Security Symposium. 2016: 601-618.

# 谢谢!

大成若缺，其用不弊。大盈  
若冲，其用不穷。大直若屈。  
大巧若拙。大辩若讷。静胜  
躁，寒胜热。清静为天下正。

