

# 基于 KNN 最小范化系数攻击在 CNN 上的利用

杨雨澄 李丹

四川大学锦城学院 四川 成都 610072

**【摘要】**若要分析算法的鲁棒性，必须采用生成对抗样本的方式来评价算法鲁棒性。然而目前对于算法鲁棒性没有统一的评判标准，也就是说对于不同的算法，人们会针对性地采取不同的方法来生成对抗样本。在这些攻击算法中，Sitawarin 等人对于 KNN 及其衍生模型提出了基于 KNN 及其衍生模型的攻击方法，其方法和其类似的 KNN 方法比较而言，能快速地找到优秀的对抗样本，在该攻击下对抗样本表现的也十分出色。那么该方法的迁移性能又如何呢，又是否能对其他的算法模型生成优秀的对抗样本呢？本文将利用 Sitawarin 等人的攻击模型对 CNN 算法模型进行攻击，并且进行对比分析造成该结果的原因。

**【关键词】**KNN；对抗样本；鲁棒性；对抗训练

## 1 背景

### 1.1 背景

对抗样本 (adversarial examples) 这一概念在 2014 年由 Szegedy 等人提出，对于进行处理的本样本图片，Szegedy 等人给予其加入微量的噪音，即所谓的扰动后，导致训练后的算法模型对该样本产生错误的判断。

在如今机器学习，深度学习处于已经开始广泛应用的年代，由于对抗样本对算法模型本身具有攻击性和迷惑性，出于安全和实际角度这引起了人们的注意。

### 1.2 对抗样本意义

对抗样本由于其对算法模型具有迷惑性的特点，可以利用于对算法的攻击，这能造成算法模型错误的分类。出于安全角度考虑，这样的攻击将会造成许多可怕的后果，例如智能驾驶中，如果给计算机传入带有扰动的数据，会造成汽车做出错误的判断，从而酿成严重后果。

但另外一方面，这样的对抗样本也可以直接用来评价该算法鲁棒性，用于评价算法模型是否可以避免上述情况。因此近几年对于算法的鲁棒性的研究越来越多。

然而，目前并没有较通用的攻击模型算法，对抗样本的生成可以说都是基于算法模型而具有针对性的，其攻击都是对不同的算法模型和原理采取不同的攻击手段。在这些攻击中，Yang 等人提出了基于 KNN 的一种优秀的攻击算法，本文将不会针对 Yang 等人的算法进行过多讲述，具体请参考相关文献。Sitawarin 等人在 Yang 等人的基础上对基于 KNN 的攻击算法进行了更加深入的研究，提出了一种基于 KNN 及其衍生模型更加优秀的攻击算法。

本文就利用 Sitawarin 等人的攻击算法对 CNN 模型

进行攻击，并分析其结果及原因。

## 2 Sitawarin 等人攻击简介

### 2.1 攻击简介

KNN 算法模型，对样本的判断是选取与其最近邻的 K 个样本，并分为较多的一类，这样的算法对其判断造成的影响，在于最近的几个样本之中，而不是所有的样本均有所影响，因此怎样选取可用于生成对抗样本的 K 个邻近样本，即如何选取指导样本，成为了难题。

Sitawarin 等人的基本思路是，选取距离样本最近的 K 个与目标样本有着不同标签值的样本作为指导样本。

Sitawarin 等人最先提出了基于梯度下降的方法找到优秀的对抗样本，引入 sigmoid 函数和惩罚干扰系数，并且通过二元搜索得到平衡常数 c。

### 2.2 攻击优化

Sitawarin 等人近期提出的基于 KNN 及其衍生模型的攻击是基于其之前提出的攻击算法的再次优化<sup>[1]</sup>，他的整体思想和之前的想法一致，但做出了一些细节上的优化，使得攻击更加优秀。

首先在指导样本上，Sitawarin 等人进行了优化，由于 KNN 算法实际分类是选取其距离最近的 K 个同类标签值最多的样本作为结果，因此直接选取 K 个不同类别的标签值其攻击性不会很强，Sitawarin 对其进行优化，改用选取距离样本最近的 K/2 个与却与目标样本有着不同标签值的样本作为指导样本。

在其提出的攻击算法基础上，Sitawarin 等人对具体实现方式也进行了优化，将 sigmoid 函数用 ReLU 函数替代，引入  $\Delta$  增加数值稳定性，并定期梯度优化阈值，公

式如下。

### 2.3 实验效果

我们通过 Sitawarin 等人优化前后的实验结果和 Yang 等人的采用思想所提出的基于 KNN 算法的攻击算法<sup>[2]</sup>进行对比实验,并且得到以下结果,见表 1:

表 1 sitawarin 等人对比实验结果

k	Attacks	Mean 2-Norm	time
1	Yang. 等人	2.4753	2h
	Sitawarin 等人	3.4337	2m
	Sitawarin 等人优化后	2.7475	5m
3	Yang. 等人	2.9857	11h
	Sitawarin 等人	3.9132	1m
	Sitawarin 等人优化后	2.9671	5m
5	Yang. 等人	3.2473	44h
	Sitawarin 等人	3.9757	1m
	Sitawarin 等人优化后	3.0913	5m

这里的 dist 指的是最小扰动的生成对抗样本到原样本的 l2 距离,即为扰动,该扰动越小,更能说明生成的对抗样本和原样本距离更近,也就意味着更小的扰动就能使得算法模型分类错误。因此 dist 可以用来直接评价攻击算法的好坏, dist 越小代表着该算法攻击效果越好。

通过上表,我们不难发现, Sitawarin 等人的算法在时间效率上明显优于 Yang. 等人,在 K>1 时其优化前的攻击算法的 dist 值略微大于 Yang 等人的攻击算法。但其优化后的攻击算法,虽然多花费了一些时间成本,但其结果显示 l2 范化系数更小,其攻击也更为优秀。

## 3 实验设计

### 3.1 实验目的

将 Sitawarin 等人的攻击方法<sup>[1]</sup>对 CNN 模型进行攻击,并通过分析比较该基于 KNN 及其衍生模型的攻击方法对 KNN 衍生模型产生的攻击效果和对 CNN 模型产生的攻击效果之间的差异。评价该算法的迁移性,以及分析造成差异的原因。

### 3.2 CNN 算法简介

CNN 又称为卷积神经网络,通过卷积提取图片中的特征值,结合神经网络的思想,通过各层输入值与权重进行运算,得到最终结果。

由于该实验是利用的 MNIST 数据集和 CIFAR10 数据集,这两个数据集的特点都是以图片作为数据,因此采用 CNN 算法进行分类是十分合适的。

### 3.3 CNN 与 KNN 模型的差异

CNN 又称为卷积神经网络,其思想在于卷积和神经网络,卷积的核心目的在于提取图片的特征值,比且依赖神经网络作为了运算的主要思想,神经网络是通过所有数据的输入训练建立的模型,他的每个权重是由数据

集内所有的数据决定的,而 KNN 算法模型则是对其距离较为近的数据集影响决定的,因此可能是导致结果差异的重要原因。

### 3.4 实验数据

根据 Sitawarin 等人之前的实验,本文采用相同的数据集进行实现。手写 MNIST 数据集和 CIFAR10 数据集。

### 3.5 实验步骤

(1) 我们采用 Sitawarin 等人基于 KNN 及其衍生的攻击模型,且在 MNIST 数据集和 CIFAR10 数据集上攻击 KNN 算法模型。

(2) 我们采用 Sitawarin 等人基于 KNN 及其衍生的攻击模型,且在 MNIST 数据集和 CIFAR10 数据集上攻击 CNN 算法模型。

(3) 对比这四种攻击的最小 l2 范化系数(即 dist)的差异,并且分析原因。

## 4 结果及分析

### 4.1 实验结果

dist 数值结果,见表 2:

表 2 该攻击在 KNN 和 CNN 算法模型上的结果

数据集	算法模型	Dist	ACC
MNIST	KNN	3.109	0.965
MNIST	CNN	1.740	0.961
CIFAR10	KNN	1.104	0.846
CIFAR10	CNN	0.843	0.643

实验结果过如表 1,我们可以看到,在 MNIST 和 CIFAR10 数据集中, Sitawarin 等人的攻击方法 [1] 都对 CNN 算法模型攻击的更加优秀。这似乎可以直接说明该算法的也适用于对 CNN 攻击,但是其 dist 值与 CNN 和 KNN 这两种算法是否有直接原因?提出了以下猜想。

### 4.2 结果猜想

猜想一:卷积神经网络,其思想在于卷积和神经网络,卷积目的是提取图片的特征值,神经网络作为了运算的主要思想,神经网络是通过所有数据的输入训练建立的模型,他的每个权重是由数据集内所有的数据决定的,而 KNN 算法模型则是对其距离较为近的样本影响决定的,因此可能是导致结果差异的重要原因。

猜想二:不同的算法模型分类得到的分界线有所区别,其分界线的不同,若分界线距离指导样本越近,就越容易产生攻击效果更优秀的对抗样本。导致攻击的 dist 受到影响。

### 4.3 猜想验证

基于猜想一,可根据作者的攻击算法思想来分析 K 值对攻击的影响。Sitawarin 等人的攻击方法。Sitawarin 等人的 1 攻击算法是选取 K/2 个最邻近的且分类不同的

样本作为生成对抗样本的指导样本。如图 1 a) 所示




图 1 指导样本示意图

当  $K$  选取为 1 的时候，原样本选取距离最近的不同类别的样本，梯度下降，直到找到最近的对抗样本位置，并计算出原样本到对抗样本之间的 L2 距离，即  $dist$ 。

当  $K > 1$  时，如图 1 (b) 所示，则是在原样本的基础上选取最近的  $K/2$  个不同类别的样本，再取其均值进行梯度下降。

若  $K$  值过大，会导致选取许多距离过于远的样本作为指导样本，这样会整体使得  $dist$  偏大，得到的攻击效果就会变弱。

本文选取 MNIST 数据集作为实验，分析样本和的关系：




图 2 MNIST 数据集下  $K$  值和  $dist$  的关系图

又由图 2 可以看出， $K$  值和  $dist$  几乎成正向关， $K$  值越大， $dist$  越大，可能是由于  $K$  值越大，其中心距离原样本的区域越远，导致  $dist$  变大。这说明了  $K$  值的确可以影响  $dis$  的大小，

但是若样本呈现内外圆形状且均匀的分类状况的话，随着  $K$  值的增大，其平均值可能还会在圆的中心，如图 3 b)，在这种情况下， $K$  值并不会和  $dist$  呈现正相关。 $dist$  的值会由于样本均匀分布在周围，导致  $dist$  的值小于任意两个非同类样本的距离。这种情况下的  $dist$  也不会随着  $K$  值的增大而增大，而是逐渐趋于稳定。




图 3 猜想下的指导样本示意图

因此  $K$  值并不能很合理地解释为什么 CNN 模型的攻击会比 KNN 模型的攻击效果更好。

基于猜想二：Sitawarin 等人的攻击是针对于 KNN 及其衍生算法模型的攻击，基于 KNN 的原理，他采取的是最近邻的  $K$  个样本作为分类判断依据，对于不同类别样本较为集中的数据 KNN 算法可以十分精确地对预测样本继续进行分类，但是对于数据较为分散，或存在交叉的情况，使用 KNN 算法模型分类，其  $K$  值成为了进行数据的重要条件，该算法对边界线并不能很明确的划分，因此 KNN 算法对边界附近的样本分类不是很理想。如图 4，该图像表面，算法本身的边界确定不同，会导致  $dist$  的值有所差异。




图 4 猜想下的边界示意图

CNN 与 KNN 由于其不相同的算法思想，按照 CNN 的算法思想，其相较于 KNN 而言对边界会更为明确，由此使得 KNN 算法和 CNN 的攻击效果会出现不同。这也是导致  $dist$  值不同原因。

## 5 结束语

通过上述实验可以看出 Sitawarin 等人基于 KNN 的攻击，同样也适用于 CNN 算法模型，且对于 CNN 而言由于其边界相较于 KNN 更加精确的原因，该攻击在 CNN 上的利用能产生更优秀的对抗样本。这也证明了 Sitawarin 等人的攻击是十分优秀的。同样可以利用于 CNN 上，但是该攻击对于 CNN 算法而言，其  $dist$  值作为衡量标准，不能直接和基于 KNN 的算法模型的攻击效果进行直接对比。

## 【参考文献】

- [1]C. Sitawarin and D. Wagner, "On the robustness of deep k-nearest neighbors," vol. abs/1903.08333, 2019. [Online]. Available: <http://arxiv.org/abs/1903.08333>.
- [2]Y. Yang, C. Rashtchian, Y. Wang, and K. Chaudhuri, "Adversarial examples for non-parametric methods: Attacks, defenses and large sample limits," CoRR, vol. abs/1906.03310, 2019. [Online]. Available: <http://arxiv.org/abs/1906.03310>.
- [3] W. Gao, X. Niu, and Z. Zhou, "On the consistency of exact and approximate nearest neighbor with noisy data," CoRR, vol. abs/1607.07526, 2016. [Online]. Available: <http://arxiv.org/abs/1607.07526>.

- 
- [4] H. W. J. Reeve and A. Kab'an, "Fast rates for a knn classifier robust to unknown asymmetric label noise," CoRR, vol. abs/1906.04542, 2019. [Online]. Available: <http://arxiv.org/abs/1906.04542>.
- [5] Christian Szegedy. Wojciech Zaremba. Ilya Sutskever. Joan Bruna. Dumitru Erhan. Ian J. Goodfellow. and Rob Fergus. Intriguing properties of neural networks. In ICLR, 2014.
- [6] C. Sitawarin and D. Wagner, "Minimum-Norm Adversarial Examples on KNN and KNN-Based Models," vol. abs/2003.06559, 2019. [Online]. Available: <http://arxiv.org/abs/2003.06559>.