


# AI纪元:新视角下的企业蓝军

---

演讲人：佘梁 东北大学 软件学院



## 个人及团队介绍

关于个人:

东北大学软件学院信息安全专业 大二在读  
寻云安全团队核心技术支撑  
广州某公司实验室核心安全研究员  
上海某局合作技术支撑

关于寻云安全团队:

自2019年成立以来,团队一直致力于信息安全多领域的研究探索,包括应用安全、系统安全、硬件安全、工控安全、二进制安全、区块链安全等领域  
团队的目标是研发实用型网络安全产品,输送网络安全优质人才,构筑网络安全防线



目前已服务各行业客户:

公安部第一研究所    公安部第三研究所  
广东省公安厅        广州市公安局  
中国电子第六研究所 中国联通  
中国电信              华为


**AI纪元:如何让你的AI快速成为核武器供应商**

**AI纪元:如何让你的AI迅速成为蓝军突破主力**


**AI纪元:如何让你的AI深入敌后**

**AI纪元:AlphaMap-AI coordinated blue Army converged combat platform**

**致谢**




# AI纪元:如何让你的AI快速成为核武器供应商







# 静态审计模型之 注意力模型的细粒度漏洞检测

VulSniper: Focus Your Attention to Shoot Fine-Grained Vulnerabilities. IJCAI-2019, 2019: 4665--4671





$$t_{i,j,k} = \begin{cases} 1 & \text{is\_match}(\text{relations}(v_i, v_j), f(k)) \\ 0 & \text{otherwise} \end{cases}$$



```
import sklearn.decomposition as sk_decomposition
pca = sk_decomposition.PCA(n_components='mle',whiten=False,svd_solver='auto')
pca.fit(iris_X)
reduced_X = pca.transform(iris_X) #reduced_X为降维后的数据
print('PCA:')
print ('降维后的各主成分的方差值占总方差值的比例',pca.explained_variance_ratio_)
print ('降维后的各主成分的方差值',pca.explained_variance_)
print ('降维后的特征数',pca.n_components_)
```

```
import sklearn.discriminant_analysis as sk_discriminant_analysis
lda = sk_discriminant_analysis.LinearDiscriminantAnalysis(n_components=2)
lda.fit(iris_X,iris_y)
reduced_X = lda.transform(iris_X) #reduced_X为降维后的数据
print('LDA:')
print ('LDA的数据中心点:',lda.means_) #中心点
print ('LDA做分类时的正确率:',lda.score(X_test, y_test)) #score是指分类的正确率
print ('LDA降维后特征空间的类中心:',lda.scalings_) #降维后特征空间的类中心
```



那么 如何通过细粒度检测模型进一步提高AI代码审计的准确度?

- 1.增加敏感函数回溯参数过程跟踪
- 2.跟读首页文件
- 3.根据功能点定向审计
- 4.增量数据集回溯训练

# AI纪元:如何让你的AI迅速成为蓝军突破主力

# 某地市要命的百万级级资产

[illegible]

## ◆ 模块化的半自动AI渗透测试

|                        |                                                            |                        |
|------------------------|------------------------------------------------------------|------------------------|
| Environment Analyses   | intranet side environment analyses<br>such as : BloodHound |                        |
| Information collection | Internet side                                              |                        |
|                        | Routine information collection                             | AP                     |
|                        |                                                            | subdomains             |
|                        |                                                            | ip                     |
|                        |                                                            | index url              |
|                        |                                                            | Sensitive url          |
|                        |                                                            | Dynamic url            |
|                        | Social information collection                              | email file information |
|                        |                                                            | chat tool              |
|                        |                                                            | mail                   |
|                        |                                                            | AP                     |
|                        |                                                            | github                 |
|                        |                                                            | hvv information        |
|                        |                                                            | media                  |
|                        | Intranet side                                              |                        |
|                        | secret file                                                |                        |
|                        | mail                                                       |                        |
|                        | AP                                                         |                        |
|                        | email file information                                     |                        |

|                    |                                                                                    |                        |
|--------------------|------------------------------------------------------------------------------------|------------------------|
| Lethal scan module | Internet side                                                                      |                        |
|                    | weak password Scan                                                                 |                        |
|                    | Template scan<br>Swarm tactics -- Penetration tests can be performed on any device | 1day&nday              |
|                    |                                                                                    | Timely Internet update |
|                    |                                                                                    | security-lab--0day     |
|                    |                                                                                    | Product core support   |
|                    | Intranet side                                                                      |                        |
|                    | such as Fscan                                                                      |                        |
|                    |                                                                                    |                        |
|                    |                                                                                    |                        |
| AIModule           | GNN-bypassWaf                                                                      |                        |

|                |                                                      |
|----------------|------------------------------------------------------|
| email fishing  | Phishing emails are automatically generated and sent |
| online fishing | AI-NLP<br>such as :chat-gpt                          |


## Internet side

|                                |                        |  |
|--------------------------------|------------------------|--|
| Routine information collection | AP                     |  |
|                                | subdomains             |  |
|                                | ip                     |  |
|                                | index url              |  |
|                                |                        |  |
|                                | Sensitive url          |  |
|                                | Dynamic url            |  |
| Social information collection  | email file information |  |
|                                | chat tool              |  |
|                                | mail                   |  |
|                                | AP                     |  |
|                                | github                 |  |
|                                | hvv information        |  |
|                                | media                  |  |

## Intranet side

|                        |  |
|------------------------|--|
| secret file            |  |
| mail                   |  |
| AP                     |  |
| email file information |  |

# 如何解决模型的搜索效率问题：强化学习



目标:提高构建的AI模型的挖掘效率

奖惩标准:从开始匹配环境到报告挖掘完成的时间长短

创造合适的奖励函数,使得用时越短,奖励越多


基于价值的强化学习模型




# 基于博弈论分析强化学习是否应当设置惩罚值



## 设置惩罚值

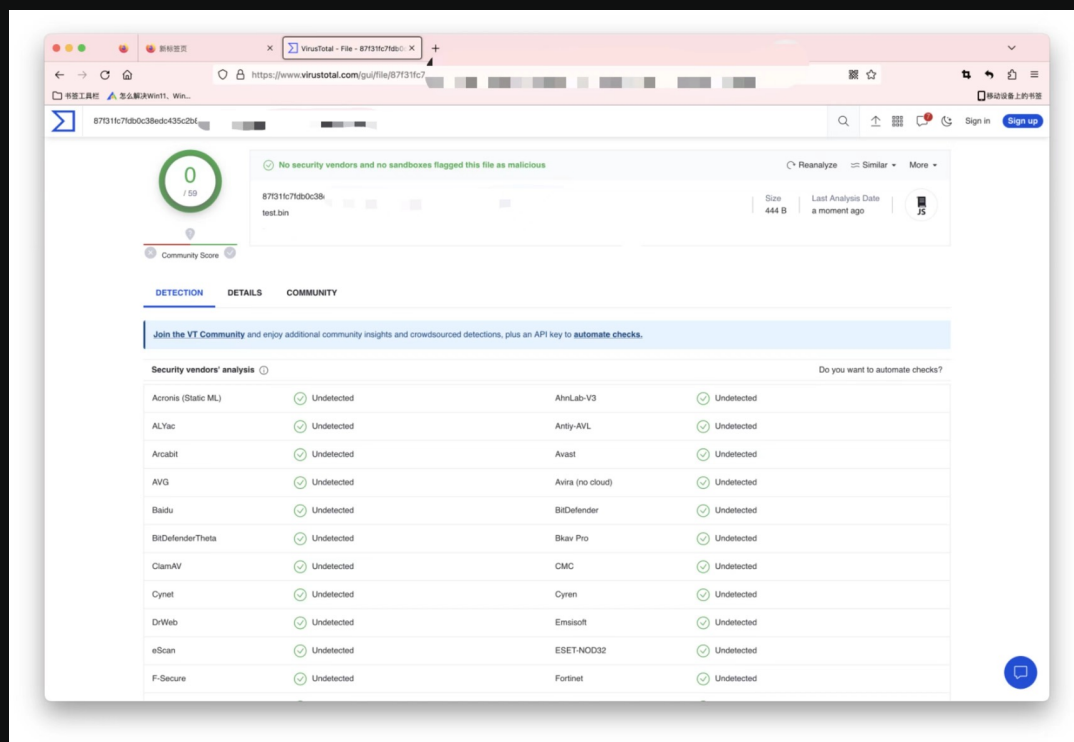



## 不设置惩罚值



# AI纪元:如何让你的AI深入敌后

## 基于生成对抗的半自动化AV对抗






$$\min_G \max_D V(D, G) = \mathbb{E}_{\mathbf{x} \sim p_{\text{data}}(\mathbf{x})} [\log D(\mathbf{x})] + \mathbb{E}_{\mathbf{z} \sim p_{\mathbf{z}}(\mathbf{z})} [\log(1 - D(G(\mathbf{z})))].$$

- GANs是一种以半监督方式训练分类器的方法, 在没有很多带标签的训练集的时候, 可以不做任何修改的直接使用代码
- G的参数更新不是直接来自数据样本, 而是使用来自D的反向传播
- 理论上, 只要是可微分函数都可以用于构建D和G, 因为能够与深度神经网络结合做深度生成式模型
- GANs可以比完全明显的信念网络(NADE, PixelRNN, WaveNet等)更快的产生样本, 因为它不需要在采样序列生成不同的数据.
- 模型只用到了反向传播, 而不需要马尔科夫链
- 相比于变分自编码器, GANs没有引入任何决定性偏置( deterministic bias), 变分方法引入决定性偏置, 因为他们优化对数似然的下界, 而不是似然度本身, 这看起来导致了VAEs生成的实例比GANs更模糊.
- 相比非线性ICA(NICE, Real NVE等,), GANs不要求生成器输入的潜在变量有任何特定的维度或者要求生成器是可逆的.
- 相比玻尔兹曼机和GSNs, GANs生成实例的过程只需要模型运行一次, 而不是以马尔科夫链的形式迭代很多次.

## AI纪元:AlphaMap-AI coordinated blue Army converged combat platform





# 致谢

---

- 寻云安全团队 白羽 沉欢
- 火山信安高级攻防实验室
- 英国华威大学（网络安全中心）  
University of Warwick (BSC)

# 感谢您的观看！

THANK YOU FOR YOUR WATCHING

