

# Avaliação de algoritmos de machine learning para detecção de malware IoT no dataset IoT-23

**Cristian H. M. Souza**

Carlos H. Arima

# Agenda

- Introdução
- Metodologia
- Implementação e resultados
- Conclusão e trabalhos futuros

# Introdução

# Introdução

- Malwares continuam sendo um dos principais desafios à segurança dos sistemas computacionais.
- O advento do paradigma IoT foi acompanhado pelo aumento do número de programas maliciosos com foco nas arquiteturas ARM e MIPS.
- Soluções a nível de rede que utilizam machine learning têm se mostrado efetivas na detecção e mitigação de malwares.

# Introdução

- Este trabalho propõe uma avaliação de algoritmos de machine learning para classificação de malware IoT com base no dataset IoT-23.
- O objetivo principal é auxiliar pesquisadores de segurança na escolha e implementação de modelos para detecção de artefatos maliciosos em tais ambientes.
- Foram implementados os algoritmos de Random Forest, SVM e uma árvore de decisão, além de uma rede neural convolucional.
- Os modelos são comparados com base nas métricas de acurácia, precisão, recall e F1-Score.

# Metodologia

# Metodologia

- O dataset utilizado para treinamento dos modelos propostos neste estudo é o IoT-23, criado pelo Avast AIC Laboratory.
- Esta base contém 20 capturas de malwares coletadas de diversos dispositivos IoT, além de 3 capturas de tráfego benigno.
- Seu objetivo é fornecer aos pesquisadores um grande conjunto de dados reais e rotulados de infecções e tráfego legítimo, visando auxiliar o desenvolvimento de algoritmos de machine learning.

# Metodologia

- Em números totais, o dataset possui 325.307.990 registros, sendo 294.449.255 deles maliciosos.

<b>Tipo de ameaça</b>	<b>Descrição</b>
Attack	Anomalias que não puderam ser identificadas e classificadas.
Benign	Tráfego benigno.
C&C	Tráfego gerado pela comunicação entre um dispositivo infectado e uma estação de comando e controle.
DDoS	Tráfego gerado por ataques de negação de serviço distribuídos.
FileDownload	Tráfego gerado pela transferência de arquivos maliciosos.
HeartBeat	Tráfego gerado pela estação de C&C para verificar a conexão com o alvo.
Mirai	Tráfego que possui características da <i>botnet</i> Mirai.
Okiru	Tráfego que possui características da <i>botnet</i> Okiru.
PartOfAHorizontalPortScan	Tráfego gerado por <i>scanners</i> de rede para coleta de informações.
Torii	Tráfego que possui características da <i>botnet</i> Torii.

# Metodologia

## **Pré-processamento:**

1. Remoção de colunas não importantes.
2. Label encoding.
3. Substituição de valores ausentes.
4. Feature scaling.
5. Separação do conjunto de treinamento e de teste (7:3).

# Implementação e resultados

# Implementação e resultados

- **CNN:** Max pooling 1D, pool\_size=2 e 500 neurônios.
  - Otimizador Adam.
- **RF:** 100 árvores e random\_state=0.
- **SVM:** regularização = 1 e kernel cache = 700 MB.

<b>Algoritmo</b>	<b>Acurácia</b>	<b>Precisão</b>	<b>Recall</b>	<b>F1-Score</b>
CNN	92.83%	0.97	0.99	0.98
Decision Tree	97.33	0.93	0.99	0.96
Random Forest	99.33%	0.97	0.99	0.98
SVM	94%	0.91	0.93	0.92

# Conclusão e trabalhos futuros

# Conclusão e trabalhos futuros

- Este trabalho apresenta uma avaliação de diferentes algoritmos de machine learning para a detecção de malware em dispositivos IoT, utilizando o dataset IoT-23.
- Como trabalhos futuros, pretende-se avaliar o desempenho dos algoritmos contra artefatos maliciosos não presentes no dataset IoT-23, com o objetivo de mensurar a acurácia dos modelos em cenários reais.
- Avaliar o comportamento dos modelos considerando artefatos especializados na evasão de defesas pode fornecer dados importantes para aprimorar a capacidade de detecção dos algoritmos.

# Avaliação de algoritmos de machine learning para detecção de malware IoT no dataset IoT-23

**Cristian H. M. Souza**

Carlos H. Arima