



Comprehensive Ransomware Detection: Optimization of Feature Selection through Machine Learning Algorithms and Explainable AI on Memory Analysis

Lucas Leonel, Diego Nunes Molinos,
Rodrigo Sanches Miani



Faculdade de Computação (FACOM)
Universidade Federal de Uberlândia (UFU)

Introdução

THALES
Building a Future we can all trust



2024 THALES DATA THREAT REPORT REVEALS RISE IN RANSOMWARE ATTACKS, AS COMPLIANCE FAILINGS LEAVE BUSINESSES VULNERABLE TO BREACHES



IMAGE: MX. GRANGER / WIKIMEDIA COMMONS / CC0 1.0

Alexander Martin

September 9th, 2024

Cybercrime

News

Ransomware attack forces high school in London to close and send students home



News and latest trends

58 Ransomware Statistics Vital for Security in 2024

July 12, 2024 · 9 minute read

Ransomware is a type of malware that threatens to destroy or withhold a victim's critical data unless a ransom is paid to the attacker. Unfortunately, cyberattacks are on the rise as we see [71% year-over-year increase](#) in cyberattacks.

Motivação

Muitos ransomwares utilizam técnicas de ofuscação e polimorfismo para evitar detecção baseada em assinaturas estáticas;

Através da análise de dados da memória é possível prever o comportamento do ransomware durante sua execução, e.g. DLLs, *Threads*, Arquivos, Mudanças no Registro etc.

Com o advento dos algoritmos de aprendizado de máquina (*Machine Learning*), a detecção de ransomwares tem evoluído consideravelmente.

Fato é que, uma abrangente análise do conjunto de *features* juntamente com o apoio de ferramentas de IA explicável contribui significativamente para a eficiência dos modelos gerados.

Features no Contexto de Detecção de Ransomware com ML e XAI

Desempenho e Eficiência Computacional;

Risco de Overfitting;

Redução de Falsos Positivos;

Tempo de Treinamento e Atualização dos Modelos;

Desafio(s)

Destacar as características que melhor descrevem comportamentos maliciosos no contexto de Ransomware utilizando informações extraídas da memória.

Reduzir o número de características necessárias para detecção de ransomwares mantendo a confiabilidade do modelo;

Racionalizar o processo de decisão do modelo gerado (DT) para aumentar o nível de confiabilidade do processo de detecção;

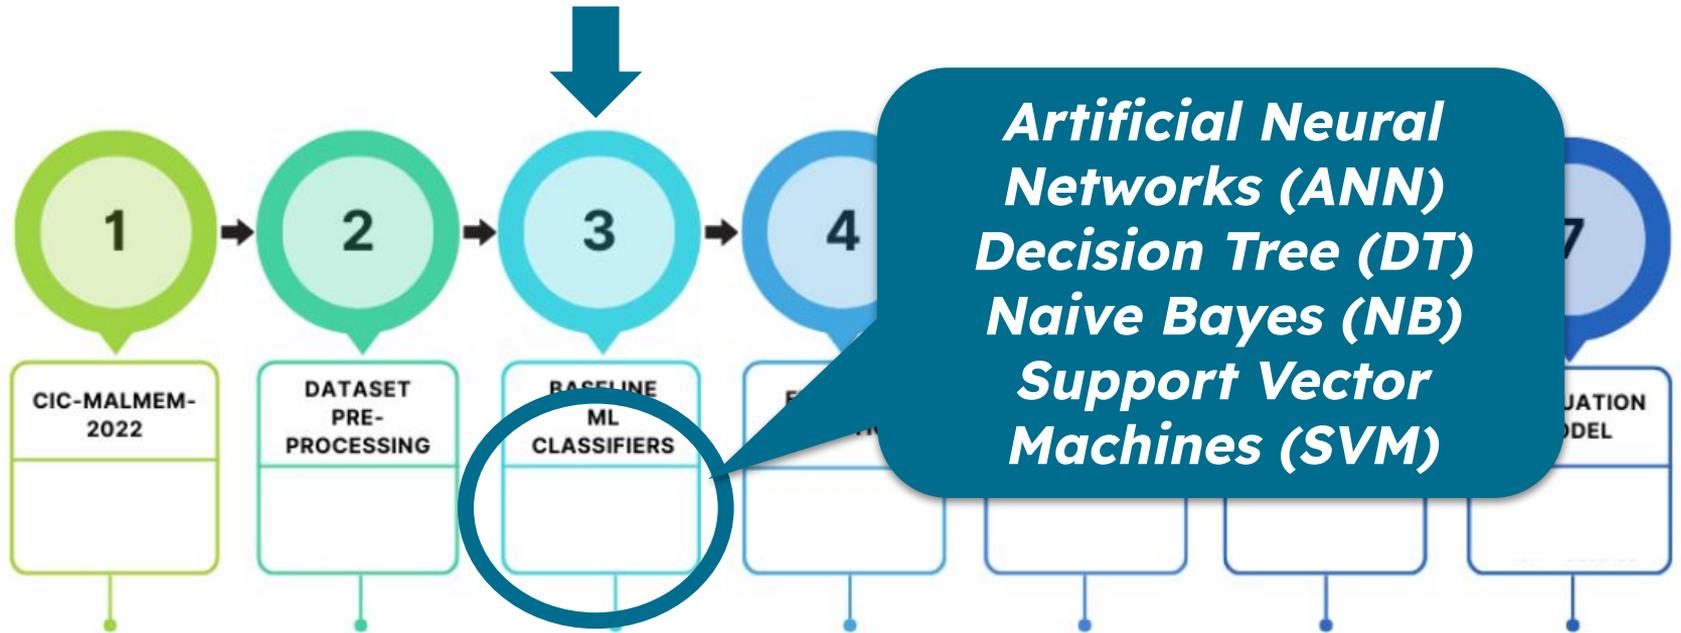
Método



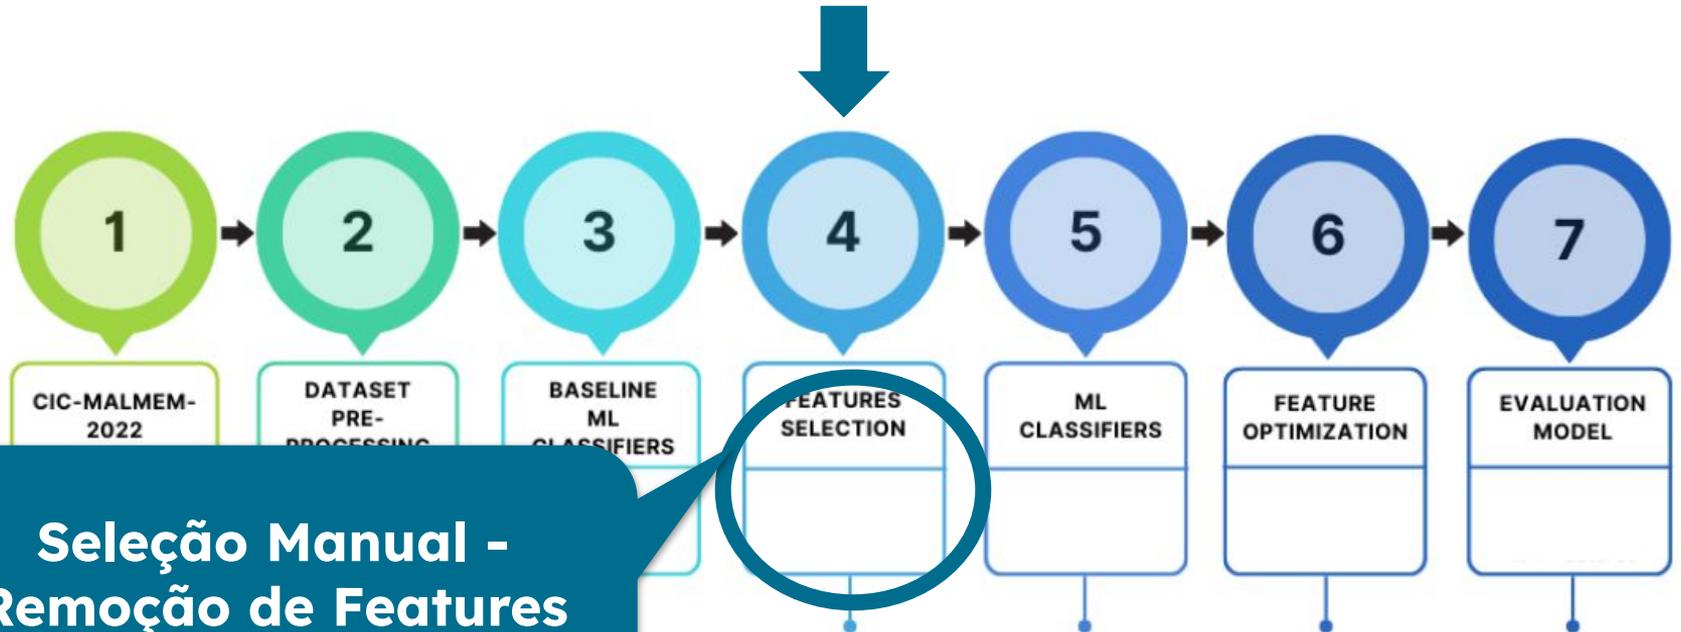
Método



Método

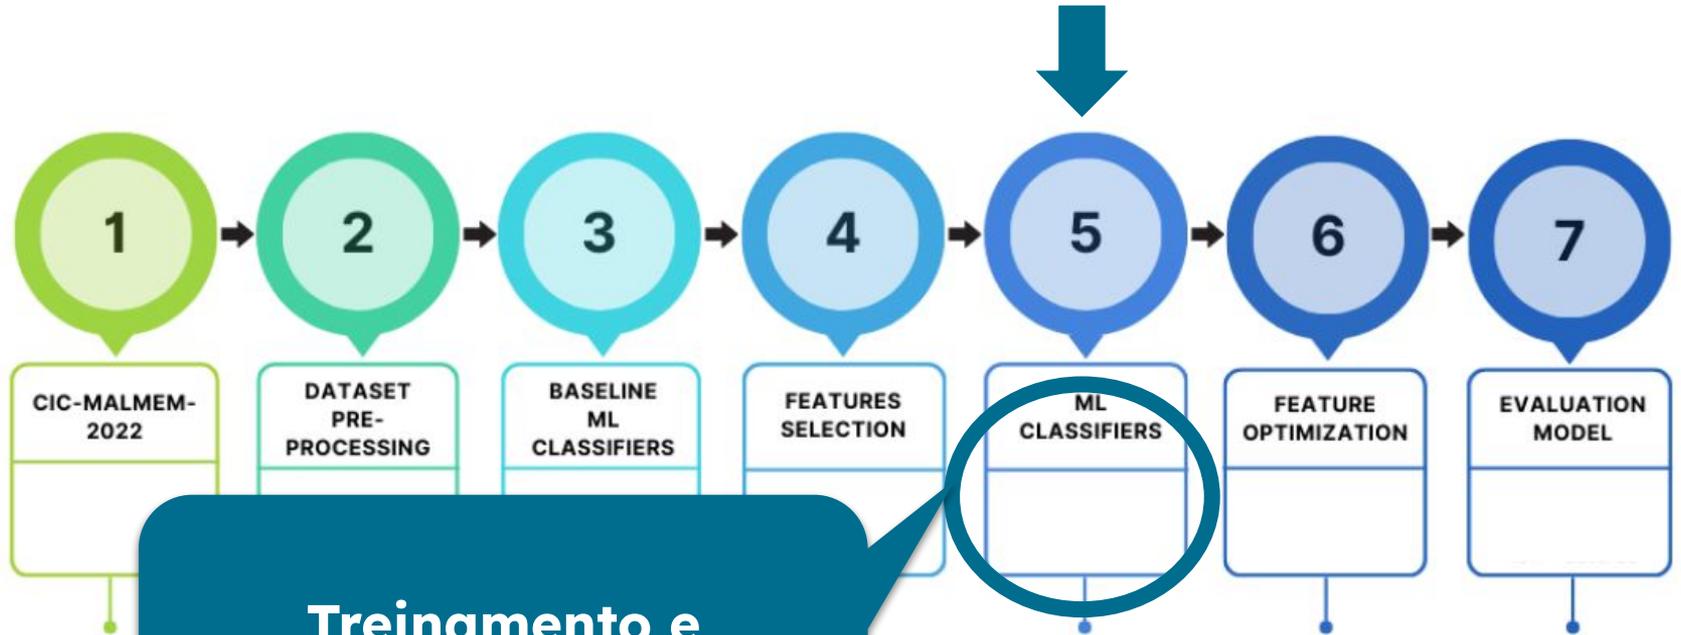


Método



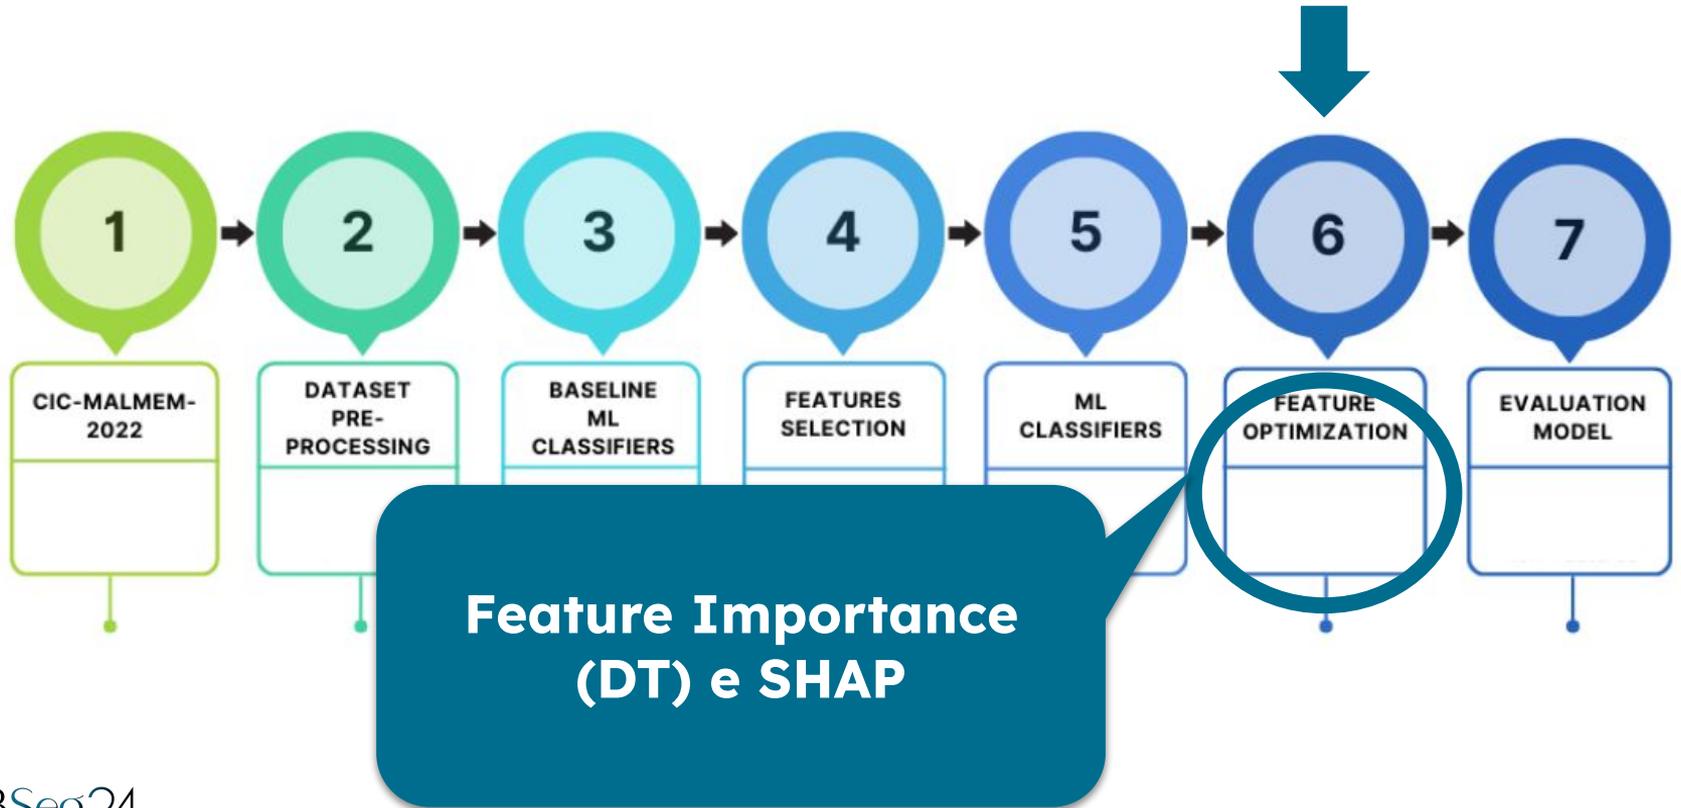
**Seleção Manual -
Remoção de Features
menos significantes**

Método

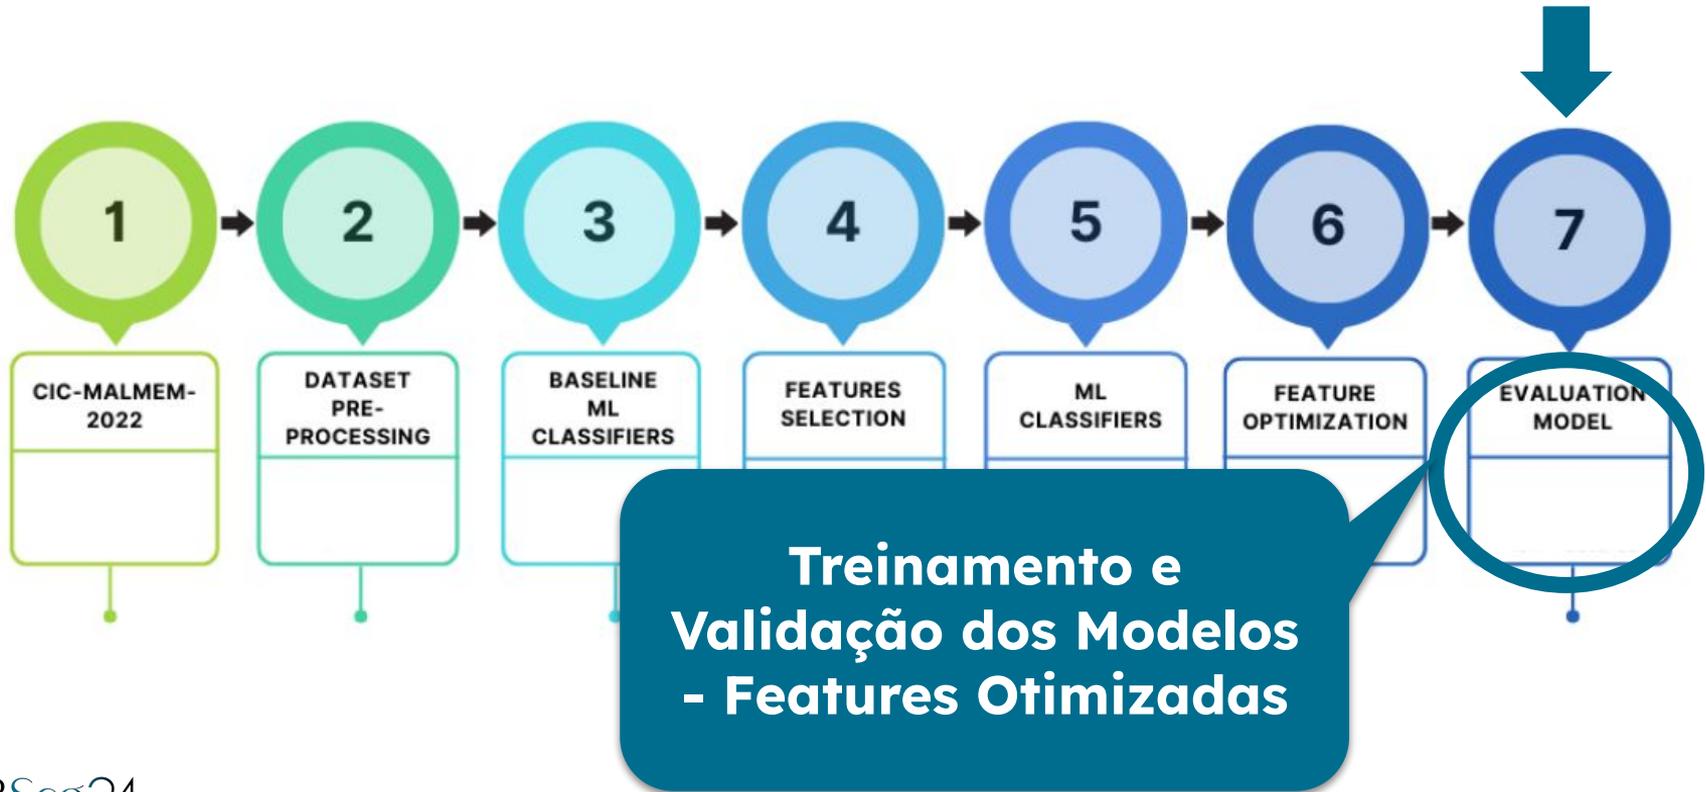


**Treinamento e
Validação dos Modelos**

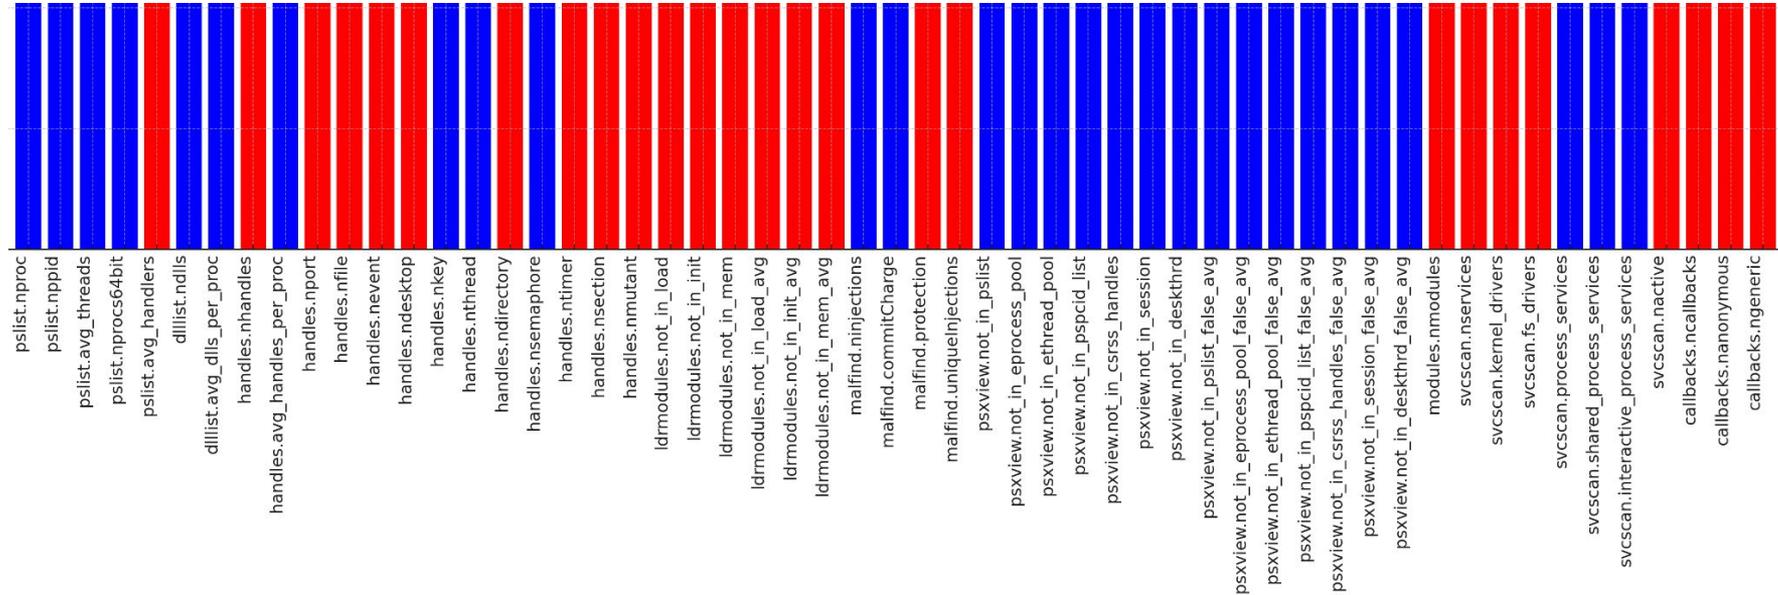
Método



Método

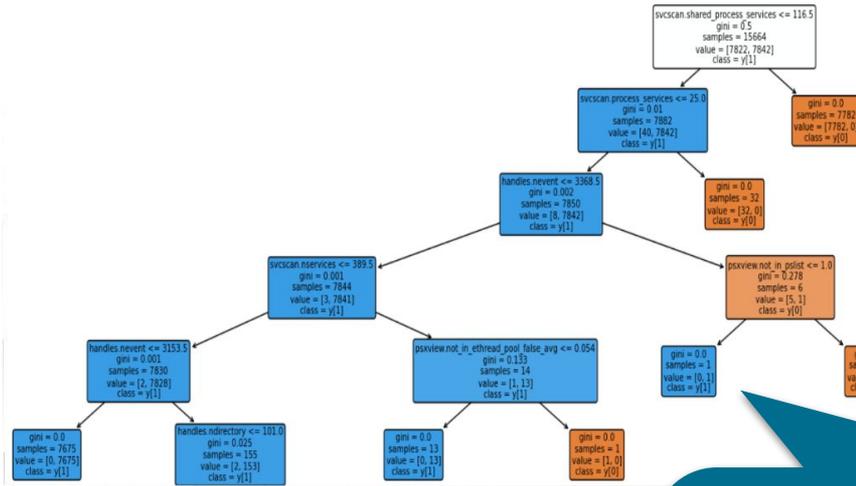


Avaliação

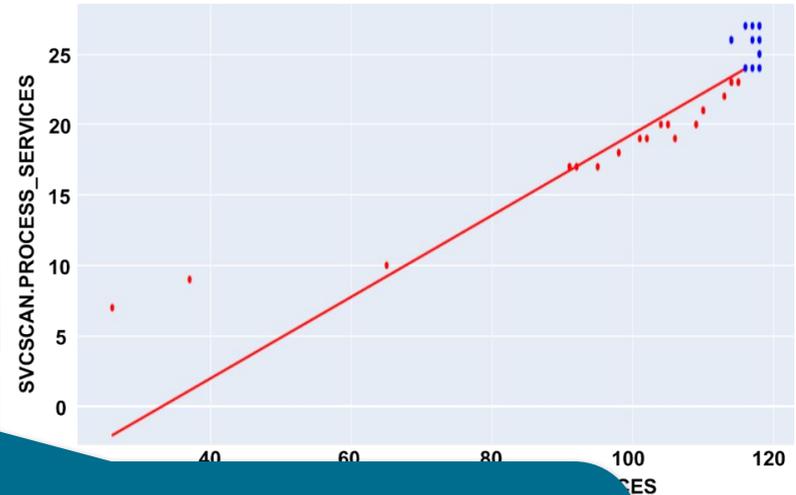


a) Terminated Processes, b) DLL's Records, c) Registry Modifications, d) Active Network Connections e, e) Running Services

Avaliação



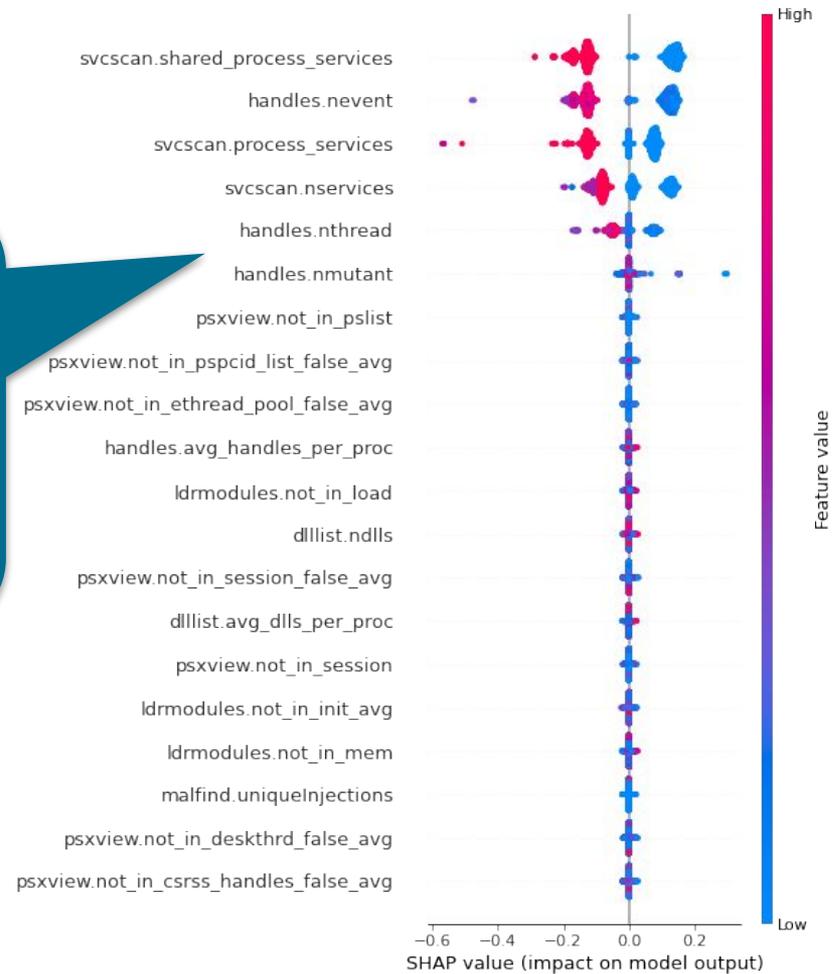
(a)



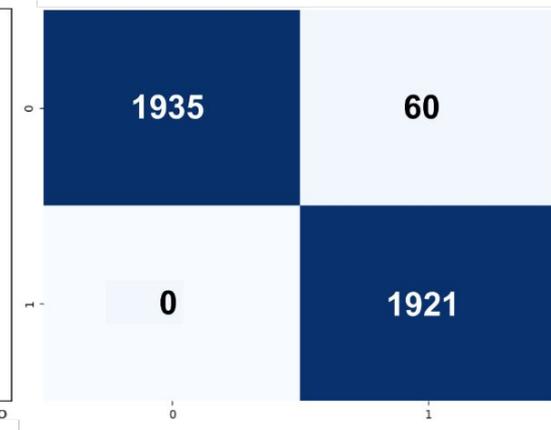
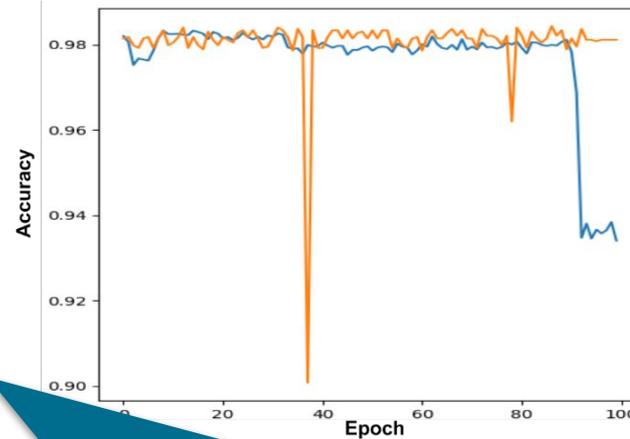
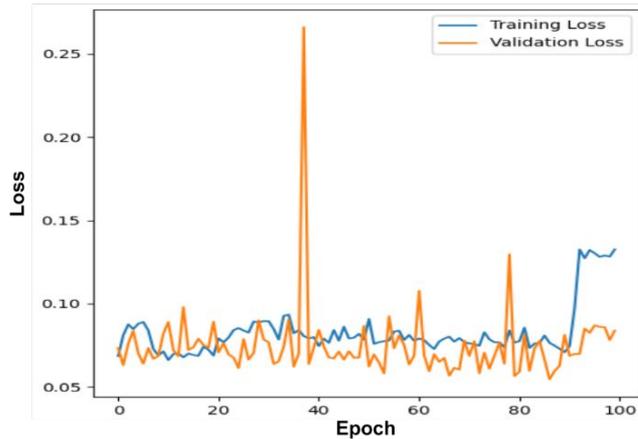
(a) svscan's shared process services,
(b) svscan.process services,
(c) handles.nevent,
(d) svscan.nservices.

Avaliação

- (a) `svs-can.shared_process_services`,
- (b) `handles.nevent`,
- (c) `svscan.process_services`,
- (d) `svscan.nservices`,
- (e) `handles.nthread`

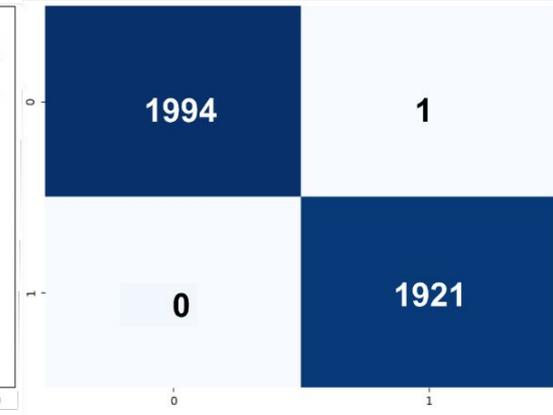
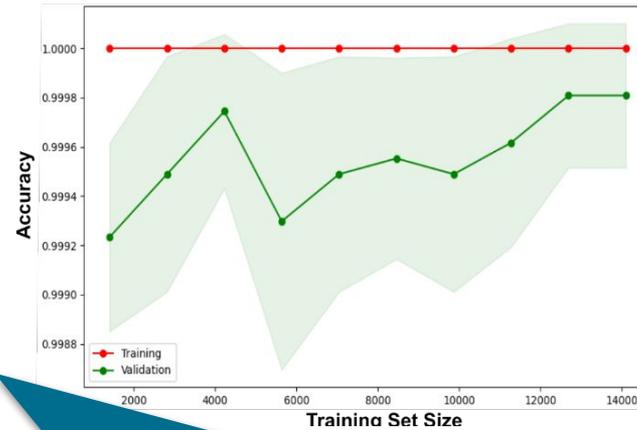
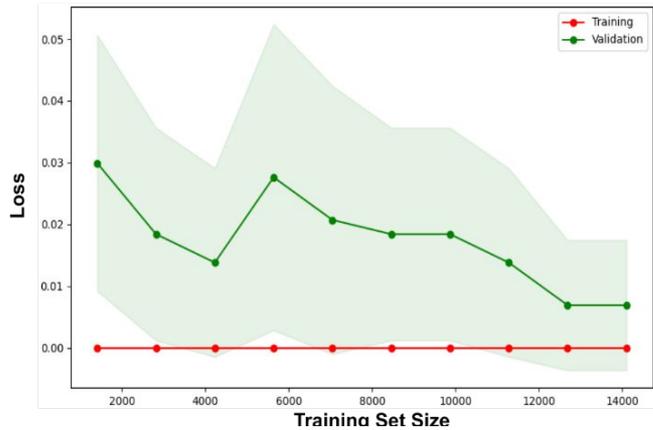


Resultados



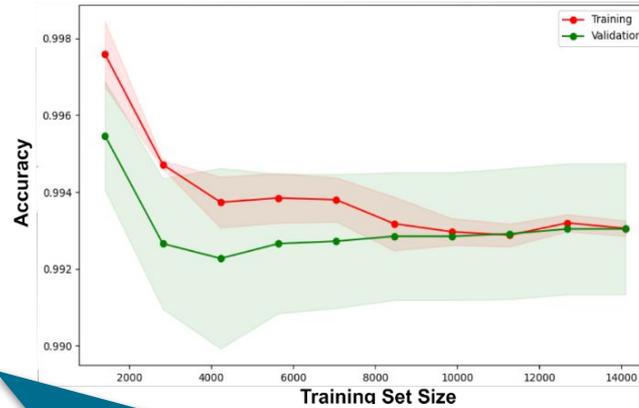
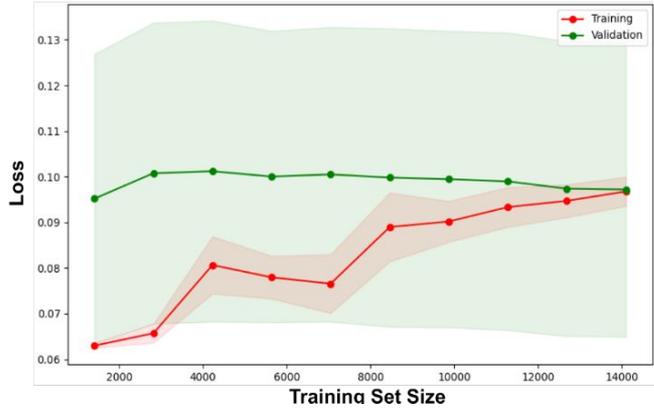
ANN exhibe picos de perda ocasionais durante a fase de validação. No entanto, o modelo demonstra aprendizagem e convergência à medida que o número de *Epochs* aumenta.

Resultados



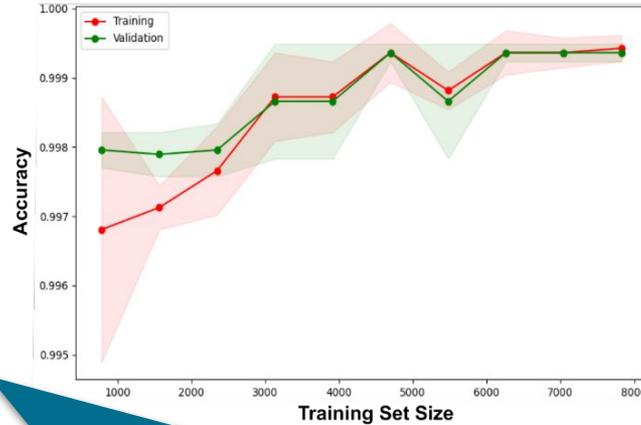
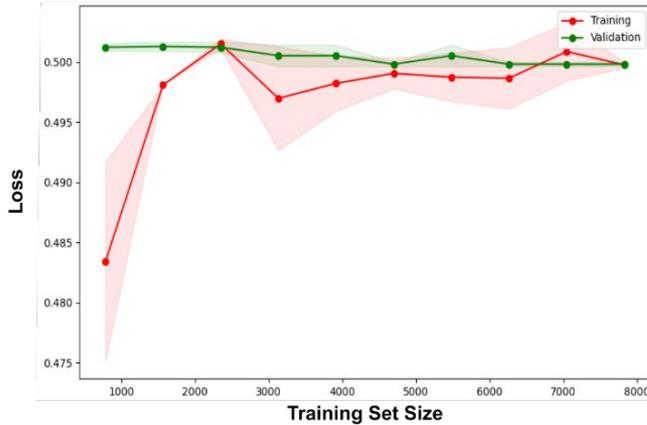
DT apresenta estabilidade tanto no treinamento quanto na validação, mesmo com o aumento de amostras, indicando desempenho confiável do modelo.

Resultados



Assim como o DT, o NB apresenta estabilidade mesmo com o aumento nas amostras.

Resultados



SVM inicialmente aparenta instabilidade, contudo, eventualmente alcança uma convergência à medida que o volume de amostras aumenta.

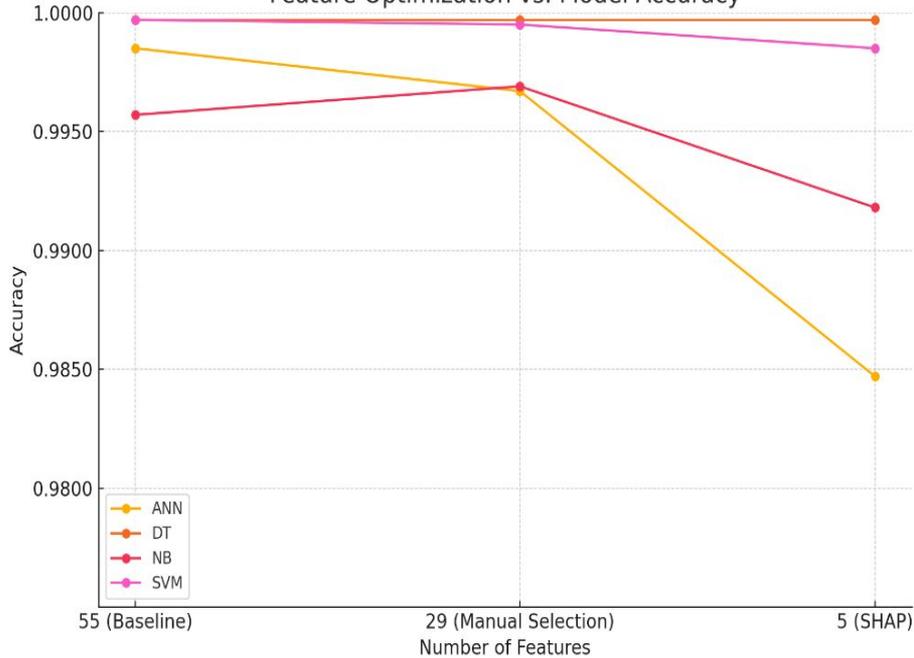
Resultados

Em todos os casos, os modelos parecem ter uma alta taxa de acerto com acurácia próxima de 1.0, tanto no conjunto de treinamento quanto de validação.

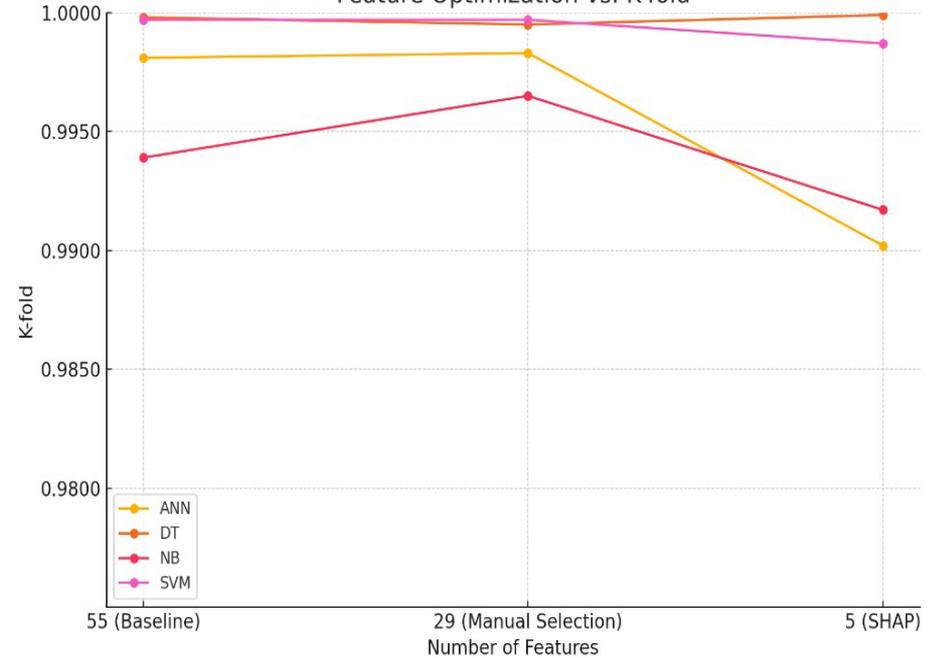
A matriz de confusão indica uma excelente separação entre as classes, com erros mínimos, o que é promissor para uma eventual aplicação prática do modelo.

Resultados

Feature Optimization vs. Model Accuracy



Feature Optimization vs. K-fold



Considerações finais

- Integração de ML e XAI melhorou a detecção de ransomware com maior transparência e otimização, redução de 55 para 5 features.
- A integração de técnicas de XAI foi um ponto fundamental, permitindo a transparência no processo de decisão do modelo gerado pelo DT.

Trabalhos futuros

- Ampliar o conjunto de features, e.g. quantidade de *swap* utilizada e chamadas de alocação dinâmica de memória;
- Aplicar o método utilizado para outros tipos de malwares;
- Adicionar novos classificadores, e.g. algoritmos de boosting, tais como: *AdaBoost* e *Gradient Boosting Machines*.

Obrigado!

Lucas Leonel

lucas.leonelcosta@gmail.com

Diego Nunes Molinos

diego.molinos@ufu.br

Rodrigo Sanches Miani

miani@ufu.br



Universidade
Federal de
Uberlândia



NUSEC
NÚCLEO DE SEGURANÇA DA
INFORMAÇÃO FACOM/UFU





Patrocinadores do SBSeg 2024!

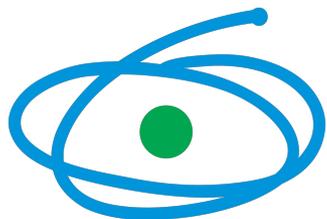
nie.br

egi.br

Google



Tempest



CAPES



SiDi



FAPESP



zscaler™



BugHunt



CNPq



C.E.S.A.R



FACULDADE
IBPTech