



Seleção de Características Multiobjetivo para Detecção de *Malwares Android*

Philippe Fransozi
Jhonatan Geremias
Eduardo K. Viegas
Altair Santin

Pontifícia Universidade Católica do Paraná



Motivação

- Considerando um conjunto de características, extraídas de um arquivo de aplicação *Android*, utilizado como um vetor de *features* em um modelo de classificação, existe algum subconjunto que melhore as taxas de erro e o tempo de inferência?

Tópicos

- Introdução
- Background
- Trabalhos Relacionados
- Proposta
- Resultados
- Conclusão
- Trabalhos Futuros
- Perguntas

Introdução

- **Contexto Acadêmico:** pesquisa foi realizada durante o PIBIC 2023-24, como resultado três artigos foram produzidos:
 - *Seleção de Características Multiobjetivo para Detecção de Malwares Android*, aceito na SBSeg 2024, categoria WTICG;
 - *APKAnalyzer: Ferramenta de Classificação de Malwares Android Baseada em Multi-view e Seleção de Características Multiobjetivo*, aceito na SBSeg 2024, categoria Salão de Ferramentas;
 - *A Multi-view Android Malware Detection Model Through Multi-objective Optimization*, submetido a ICMLA;

Introdução

- **Contexto dos dispositivos móveis Android:**
 - Em 2024, domínio do mercado com $\frac{3}{4}$ de *marketshare*, aproximadamente 3 bilhões de usuários;
 - Em 2023, houve um aumento na detecção de aplicativos maliciosos, aproximadamente 53% de aumento; grande parte dessas amostras oriundas da loja oficial de aplicativos *Google Play*.

Introdução

- **Contexto dos métodos de análise de malware Android:**
 - **Análise dinâmica** obtém comportamentos maliciosos durante a execução do aplicativo. Trata-se de um método que exige maiores esforços relacionados ao ambiente para simulação (sandbox) e aos estímulos adequados para reprodução do comportamento malicioso;
 - **Análise estática** obtém indícios de um comportamento malicioso a partir do conteúdo do aplicativo (permissões obtidas do arquivo manifest.xml). Trata-se de um método mais simples, rápida implementação e escalável.

Introdução

- **Contexto dos métodos de detecção de malware Android:**
 - Na literatura, encontramos inúmeros métodos para a tarefa de detecção, dentre os quais temos os métodos baseados em modelos de aprendizado de máquina. Em geral: um vetor de características é utilizado como entrada de um modelo de classificação que o classifica como malicioso ou benigno;
 - Vetores de características, originados de diferentes conteúdos de um arquivo, são amplamente utilizados na classificação, e a abordagem *multi-view* tem mostrado melhorar a generalização e confiança do sistema.

Introdução

- **Objetivo geral:**
 - Apresentar um modelo de classificação de *malware Android* com *multi-view* e seleção de características com otimização multiobjetivo;
- **Objetivos Específicos:**
 - *Dataset* com 40 mil amostras de arquivos, 20 mil maliciosas e 20 mil benignas;
 - Módulo de análise estática para extração de características e criação dos vetores;
 - Módulo para seleção de características, com otimização multiobjetivo, e classificação *ensemble*.

Introdução

- **Contribuições:**

- *Dataset* com 40 mil amostras de aplicativos *Android*, disponível publicamente, composto por permissões, *api calls* e *opcodes*;
- Modelo de detecção de *malware Android* implementado com *multi-view* e estratégia de otimização multiobjetivo. Nossa proposta melhorou a taxa verdadeiro positivo em uma média de 5,2, exigindo até 65% dos custos com processamento.

Tópicos

- Introdução
- **Background**
- Trabalhos Relacionados
- Proposta
- Resultados
- Conclusão
- Trabalhos Futuros
- Perguntas

Background

- Técnicas de aprendizado de máquina raramente são utilizadas em produção porque a classificação geralmente requer a análise de múltiplos indícios do conteúdo de um arquivo APK, enquanto a maioria das abordagens se concentra na análise de um único grupo de características, por exemplo, as permissões;
- A maioria dos modelos propostos, com múltiplos conjuntos de características, utiliza redes neurais profundas (DNN), que melhoram a precisão do sistema, embora impliquem desvantagens significativas em termos de requisitos de memória e processamento.

Tópicos

- Introdução
- Background
- **Trabalhos Relacionados**
- Proposta
- Resultados
- Conclusão
- Trabalhos Futuros
- Perguntas

Trabalhos Relacionados

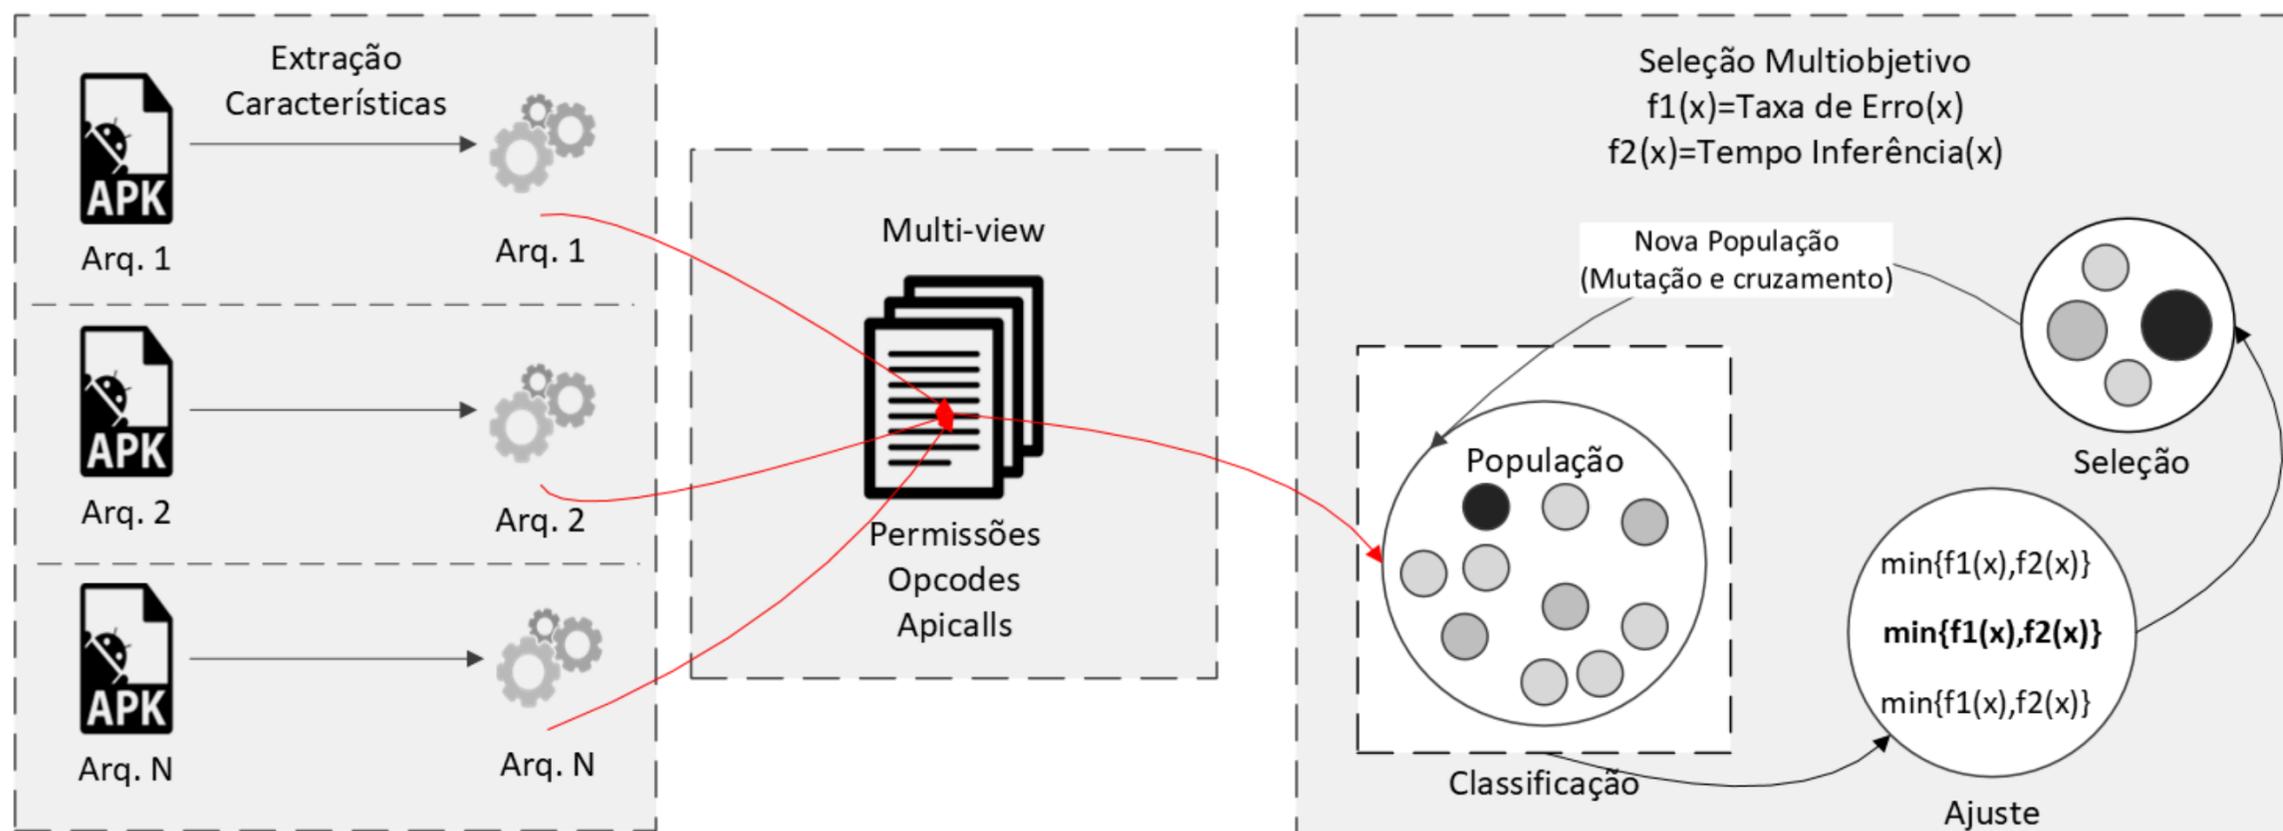
- Um grande número de trabalhos utilizam uma única *view* no processo de classificação:
 - Modelo de aprendizado de máquina baseado em permissões, com seleção de características, apresentou melhoras na precisão da classificação, porém utilizou um número limitado de amostras;
 - Modelo de DNN aprimorou a acurácia em comparação com estudos anteriores, mas não explorou *multi-view* para melhorar a generalização do modelo;

Tópicos

- Introdução
- Background
- Trabalhos Relacionados
- **Proposta**
- Resultados
- Conclusão
- Trabalhos Futuros
- Perguntas

Proposta

- Para superar o desafio da detecção de *malware Android* em um cenário *multi-view*, o esquema proposto é implementado através de uma abordagem de otimização multiobjetivo:



Proposta

- Extração de Características:
 - Utiliza-se o método de análise estática para extrair todas as características dos arquivos APK;
- Multi-view:
 - Nosso modelo utiliza três conjuntos de características (*views*) de um arquivo APK: permissão (manifest.xml), códigos de operação (dex) e chamadas de API (dex);
 - Cada *view* forma um vetor de características que será utilizado em modelos de classificação;

Proposta

- Seleção multiobjetivo:
 - O conjunto *multi-view* alimenta um pipeline de classificação:
 - aprendizado de máquina e seleção de características com otimização multiobjetivo;
 - Cada uma das *views* é classificada por um modelo (*Decision Tree* (DT) e *Random Forest* (RF)), produzindo um resultado de classificação para cada *view*, os quais são combinados por uma votação por maioria, produzindo o resultado final da classificação.

Proposta

- Seleção multiobjetivo:
 - A tarefa de otimização multiobjetivo visa encontrar um subconjunto de características para cada *view* de modo a minimizar o tempo de processamento e a taxa de erro.

Tópicos

- Introdução
- Background
- Trabalhos Relacionados
- Proposta
- **Resultados**
- Conclusão
- Trabalhos Futuros
- Perguntas

Resultados

- A avaliação do modelo orientou-se por três questões de pesquisa:
 - QP1: Qual é a precisão na detecção tradicional de *malware* Android utilizando aprendizado de máquina com uma única *view*?
 - QP2: De que maneira nossa abordagem de otimização multiobjetivo aprimora a acurácia da classificação?
 - QP3: Quais são as vantagens e desvantagens do nosso modelo em termos de custo de processamento, medido pelo tempo de inferência?

Resultados

- Para responder as questões de pesquisa, foi preciso inicialmente:
 - Criar um *dataset* para avaliar de forma confiável o desempenho do nosso modelo em um contexto de *multi-view*:
 - Amostras obtidas da plataforma AndroZoo;
 - 20 mil amostras maliciosas (selecionadas apenas quando 2 soluções no VirusTotal indicassem ser um *malware*);
 - 20 mil amostras benignas;

Resultados

- Extrair as características das amostras, tornando-as adequadas para o processo de classificação;
- Três views consideradas:
 - API calls: 63.460 características (.dex);
 - Opcode: 224 características (.dex);
 - Permissões: 19.083 características (manifest.xml);

Resultados

- O conjunto de dados inicial foi dividido em três subconjuntos:
 - Treino: 40%, utilizado para construir os classificadores;
 - Teste: 30%, utilizado no processo de otimização multiobjetivo;
 - Validação: 30%, utilizado para avaliar o sistema final.
- Construção dos modelos de classificação, parâmetros:
 - DT: critério de gini, sem limite de profundidade;
 - RF: 100 árvores de decisão, cada uma com os mesmos parâmetros do classificador DT.

Resultados

- Normalização dos *datasets* aplicando o método min-max;
- Dimensionalização dos *datasets* aplicando PCA com 100 componentes;
- Construção do módulo de seleção de características com multiobjetivo:
 - Algoritmo NSGA-II, utilizando a API pymoo;
 - População de tamanho 100; 100 gerações; taxa de cruzamento 0,3; probabilidade de mutação 0,1;

Resultados

- O problema do NSGA-II foi parametrizado com 300 variáveis e 2 objetivos; Cada variável pode assumir valor entre 0 e 1;
- Cada 100 variáveis representa um vetor de características de uma *view*;
- Se o valor da variável for menor que 0,5 (50%) a característica é excluída do vetor;
- A avaliação dos classificadores foi baseada em suas taxas de *True Positive* (TP) e *True Negative* (TN):
 - TP: amostras de *malware* corretamente classificadas;
 - TN: amostras de *goodware* corretamente classificadas;

Resultados

- QP1: Qual é a precisão na detecção tradicional de *malware Android* utilizando aprendizado de máquina com uma única *view*?
 - RF:
 - Api calls: 83,17% TP;
 - Opcode: 84,32% TP;
 - Permissões: 78,45% TP;
- Resultado QP1: não oferece o nível necessário de confiança para uma implementação em ambiente de produção.

Resultados

- QP2: De que maneira nossa abordagem de otimização multiobjetivo aprimora a acurácia da classificação?
 - RF:
 - *Multi-view*: 87,22% TP;
- Resultado QP2: nossa abordagem demonstrou uma melhoria na precisão da classificação; Em média, nossa metodologia elevou os índices TP em 5,2 pontos.

Resultados

- Visão Geral dos resultados:

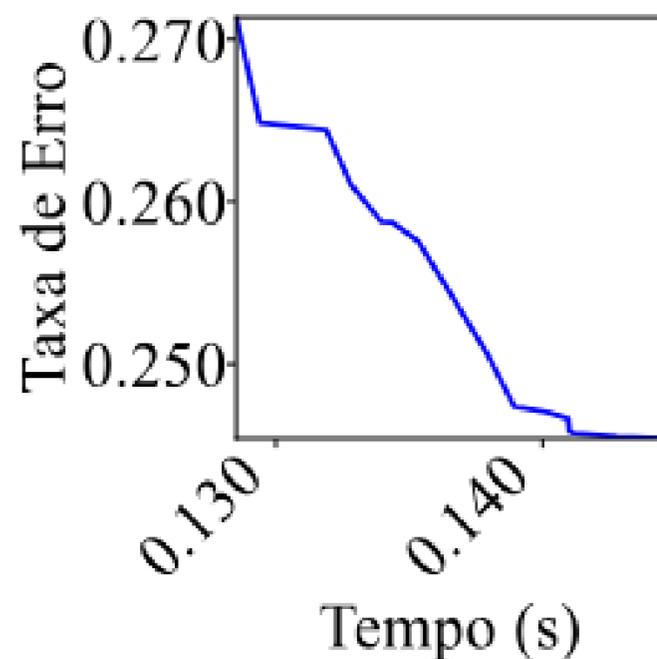
View	Classificador	Acurácia (%)		
		<i>TP</i>	<i>TN</i>	<i>F1</i>
<i>API Calls</i>	DT	70.91	71.02	70.95
	RF	83.17	77.18	80.84
<i>Opcode</i>	DT	70.34	70.91	70.45
	RF	84.32	76.57	81.16
Permissões	DT	68.43	68.82	68.49
	RF	78.45	75.14	77.41
Nossos Resultados	DT	75.86	75.35	75.74
	RF	87.22	78.18	83.24

Resultados

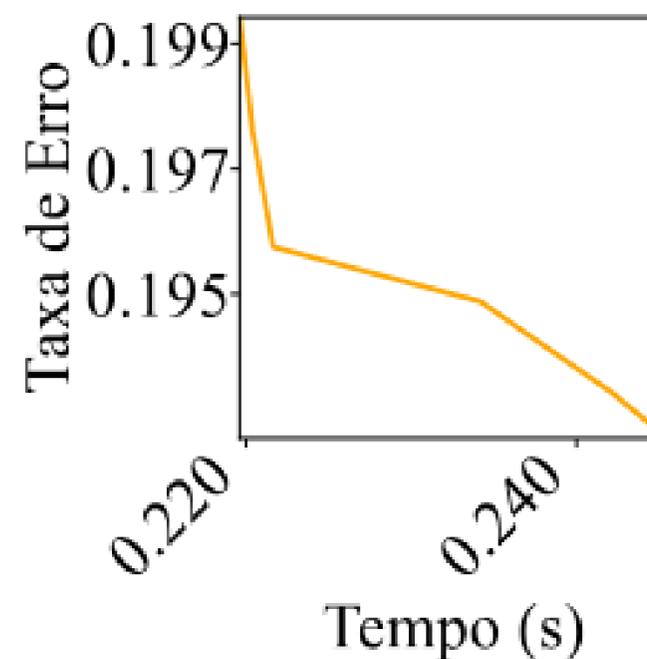
- QP3: Quais são as vantagens e desvantagens do nosso modelo em termos de custo de processamento, medido pelo tempo de inferência?
 - Exigiu apenas 65%, 78% e 66% dos custos de processamento correspondentes ao uso de todas as características com os classificadores DT e RF;
- Resultado QP3: o modelo pode reduzir os custos de processamento de inferência associados.

Resultados

- Curva de Pareto do modelo proposto. Observa-se uma correlação direta entre custos de processamento de inferência e a taxa de erro do sistema:



(a) *DT Multi-view*



(b) *RF Multi-view*

Tópicos

- Introdução
- Background
- Trabalhos Relacionados
- Proposta
- Resultados
- **Conclusão**
- Trabalhos Futuros
- Perguntas

Conclusão

- A seleção de um subconjunto de características de cada *view* maximiza a precisão da classificação quando combinada através de um conjunto de classificadores;
- As experiências conduzidas em um novo *dataset* demonstram a viabilidade da nossa proposta, resultando em uma melhora significativa na precisão e uma redução nos custos computacionais de inferência.

Tópicos

- Introdução
- Background
- Trabalhos Relacionados
- Proposta
- Resultados
- Conclusão
- **Trabalhos Futuros**
- Perguntas

Trabalhos Futuros

- Mestrado:
 - Início do mestrado como aluno ouvinte;
 - Continuação da pesquisa com foco em detecção de *malwares Android* baseado em análise multimodal:
 - estudo da literatura;
 - delimitação do problema;
 - em linhas gerais: características provenientes de diferentes origens (estática, dinâmica, metadados), estratégias para lidar com a ausência de características, modelos de deep learning.

Tópicos

- Introdução
- Background
- Trabalhos Relacionados
- Proposta
- Resultados
- Conclusão
- Trabalhos Futuros
- Perguntas

Obrigado!

Philippe Fransozi
Jhonatan Geremias
Eduardo K. Viegas
Altair Santin

{philipe.hfransozi, jgeremias, eduardo.viegas, santin}@ppgia.pucpr.br

Perguntas!



Patrocinadores do SBSeg 2024!

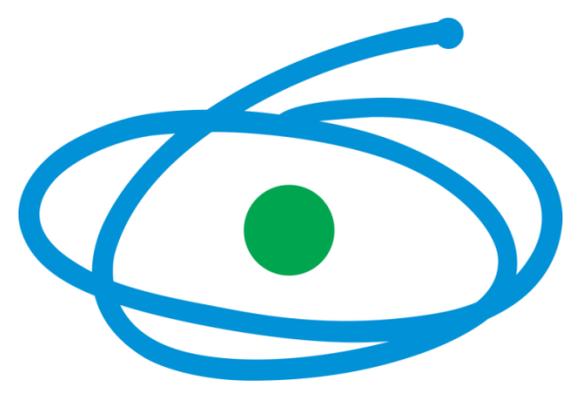
nic.br

egi.br

Google



Tempest



CAPES



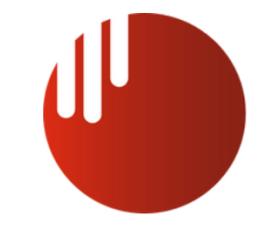
SiDi



BugHunt



C . E . S . A . R



FACULDADE
IBPTech