# Uma Análise de Métodos de Seleção de Características aplicados à Detecção de Malwares Android

XXII SIMPÓSIO BRASILEIRO DE SEGURANÇA DA INFORMAÇÃO E DE SISTEMAS COMPUTACIONAIS


UFAM


Taina Soares, Diego Kreutz,
Vanderson Rocha, Estevão Costa,
Luiza Leão, Jonas Pontes, Joner Assolin,
Gustavo Rodrigues, Eduardo Feitosa

# DETECÇÃO DE MALWARES ANDROID E SELEÇÃO DE CARACTERÍSTICAS

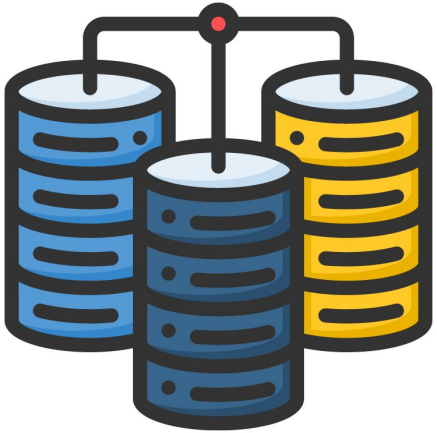

modelos de
aprendizado de máquina

datasets de alta
dimensionalidade

# DETECÇÃO DE MALWARES ANDROID E SELEÇÃO DE CARACTERÍSTICAS

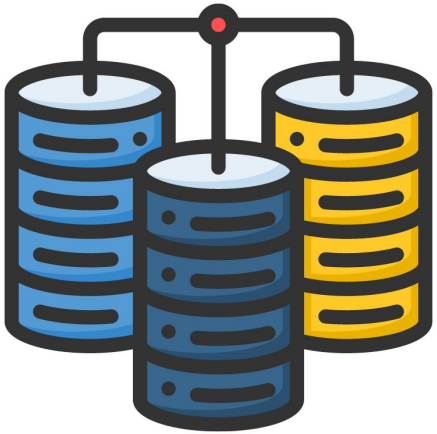

datasets de alta dimensionalidade

**Exemplos:**

- DefenseDroid > 11k features
- Drebin > 1m features e amostras

# DETECÇÃO DE MALWARES ANDROID E SELEÇÃO DE CARACTERÍSTICAS

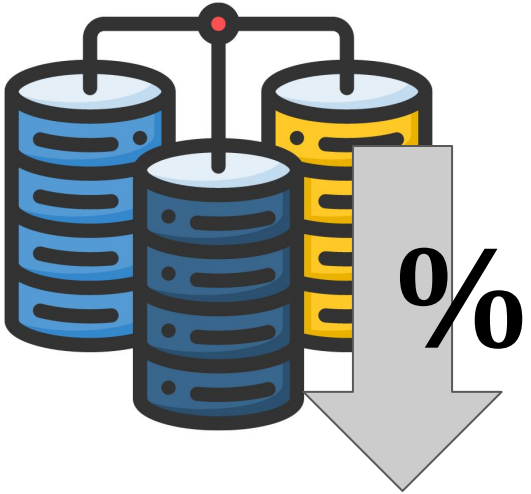


modelos de
aprendizado de máquina

datasets reduzidos

# MÉTODOS DE SELEÇÃO DE CARACTERÍSTICAS

- Específicos para algum tipo de característica
  - SigAPI - chamadas de API
  - SigPID - permissões
- Redução de tempo computacional
- Modelos com maior capacidade de generalização

# MÉTODOS DE SELEÇÃO DE CARACTERÍSTICAS - REDUÇÃO

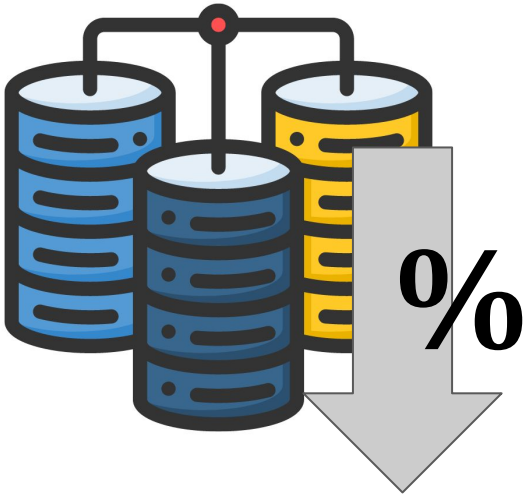


**Exemplo: SigAPI ~75% de redução**

- Drebin (subconjunto)
  - 73 API Calls
- MalGenome (subconjunto)
  - 69 API Calls

# ROTEIRO

1. Trabalhos relacionados
2. Motivação
3. Métodos selecionados e implementados
4. Metodologia
5. Resultados e discussão
6. Considerações finais
7. Trabalhos futuros

# TRABALHOS RELACIONADOS

- Comparação de técnicas clássicas de seleção estatística
  - Redução
  - Qualidade de detecção

# TRABALHOS RELACIONADOS

- Comparação de técnicas clássicas de seleção estatística
  - Redução
  - Qualidade de detecção

Exemplos:

- chi-quadrado
- ganho de informação
- regras de associação

# TRABALHOS RELACIONADOS

- Comparação de técnicas clássicas de seleção estatística
  - Redução
  - Qualidade de detecção

# TRABALHOS RELACIONADOS

- Propostas de métodos elaborados de seleção
  - SigPID
  - SigAPI
  - ALR
  - RFG

# EXEMPLO: FUNCIONAMENTO DO SIGPID

- Seleção de dados multinível
- 3 níveis de seleção:
  - PRNR (classificação de permissão com taxa negativa)
  - SPR (classificação de permissão baseada em suporte)
  - PMAR (mineração de permissões com regras de associação)
- Dataset reduzido (características selecionadas)

# EXEMPLO: FUNCIONAMENTO DO SIGPID

- Drebin_215 (113 permissões)
  - PRNR (108)
  - SPR (30)
  - PMAR (27)

# MOTIVAÇÃO DO ESTUDO

- Comparação de métodos sofisticados
- Métodos originalmente avaliados para datasets específicos

# MOTIVAÇÃO DO ESTUDO

| Método | Dataset |
|---|---|
| SigPID | Próprio (*) |
| SigAPI | Próprio (*) |
| RFG | Próprio (*) |
| ALR | Android Malware Dataset |

# MOTIVAÇÃO DO ESTUDO

| Método | Dataset |
|---|---|
| SigPID | Próprio (*) |
| SigAPI | Próprio (*) |
| RFG | Próprio (*) |
| ALR | Android Malware Dataset |

- Drebin
- Google Play
- APKPure

# MOTIVAÇÃO DO ESTUDO

**Qual o comportamento para diferentes datasets?**

# MOTIVAÇÃO DO ESTUDO

**Qual o comportamento para diferentes datasets?**

- Dimensionalidade
- Esparsidade
- Balanceamento (B:M)

# MÉTODOS SELECIONADOS E IMPLEMENTADOS

- Reprodutibilidade
- Bons resultados
- Complexidade

| Método | Característica |
|---|---|
| SigPID | *Permissões* |
| ALR | *Permissões* |
| SigAPI | *Chamadas de API* |
| RFG | *Chamadas de API* |

# METODOLOGIA

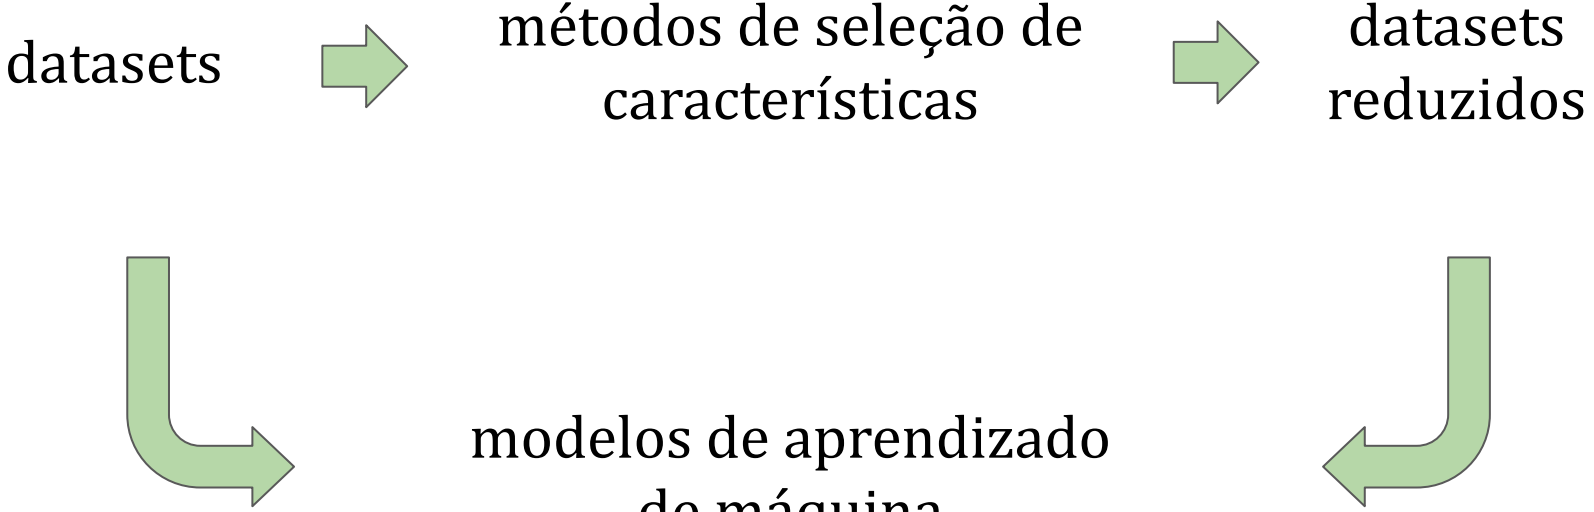

# METODOLOGIA - DATASETS

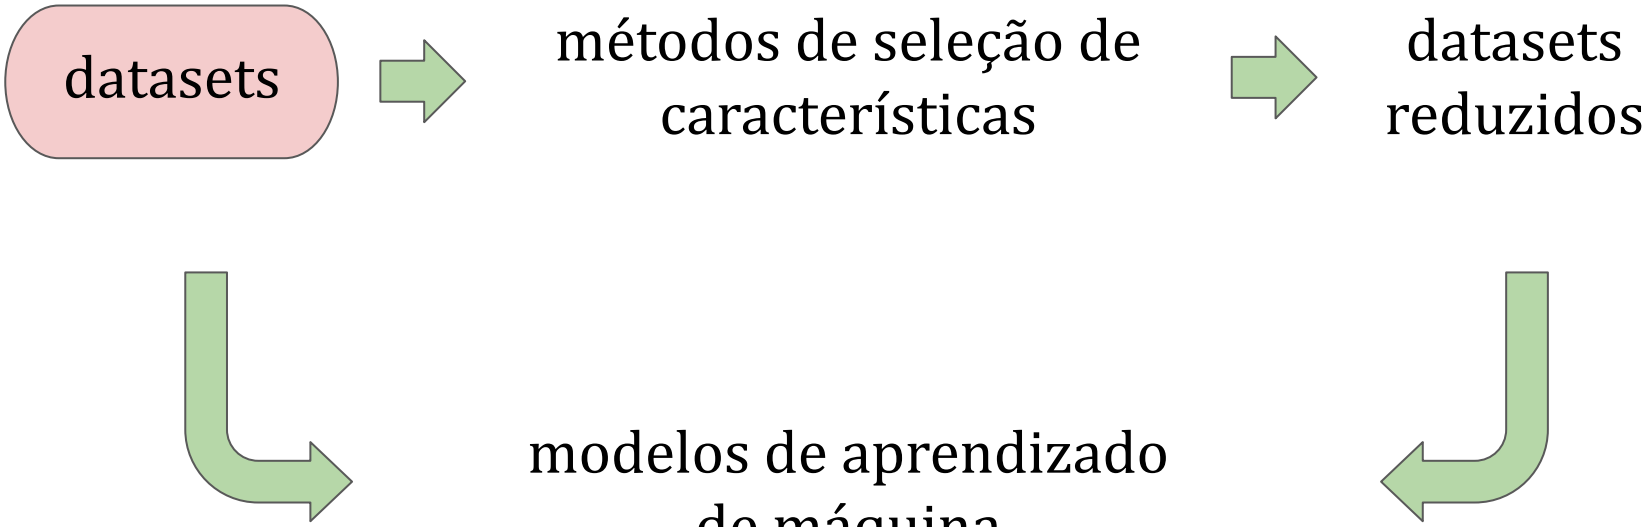

# METODOLOGIA - DATASETS

| Nome | Número de amostras | B : M |
|---|---|---|
| *md46k* | 46.670 | 15,4 : 1 |
| *androcrawl* | 96.732 | 8,5 : 1 |
| *drebin_215* | 15.031 | 1,7 : 1 |

# METODOLOGIA - DATASETS

datasets

- datasets de chamadas de API
- datasets de permissões

# METODOLOGIA - DATASETS DE CHAMADAS DE API

| Nome | Número de características |
|---|---|
| *md46k* | 1.524 |
| *androcrawl* | 24 |
| *drebin_215* | 73 |

# METODOLOGIA - DATASETS DE PERMISSÕES

| Nome | Número de características |
|---|---|
| *md46k* | 1.316 |
| *androcrawl* | 49 |
| *drebin_215* | 113 |

# METODOLOGIA - MÉTODOS

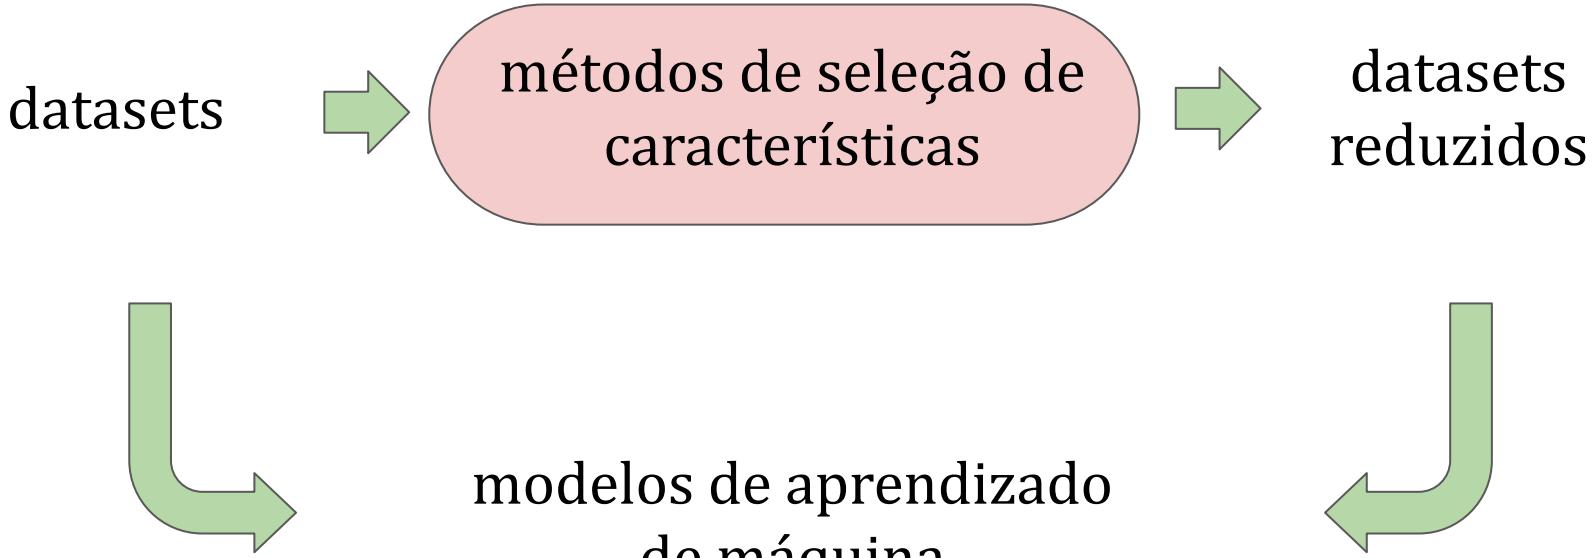

# METODOLOGIA - MÉTODOS

métodos de seleção de características

datasets de chamadas de API → SigAPI e RFG

datasets de permissões → SigPID e ALR

# METODOLOGIA - DATASETS REDUZIDOS

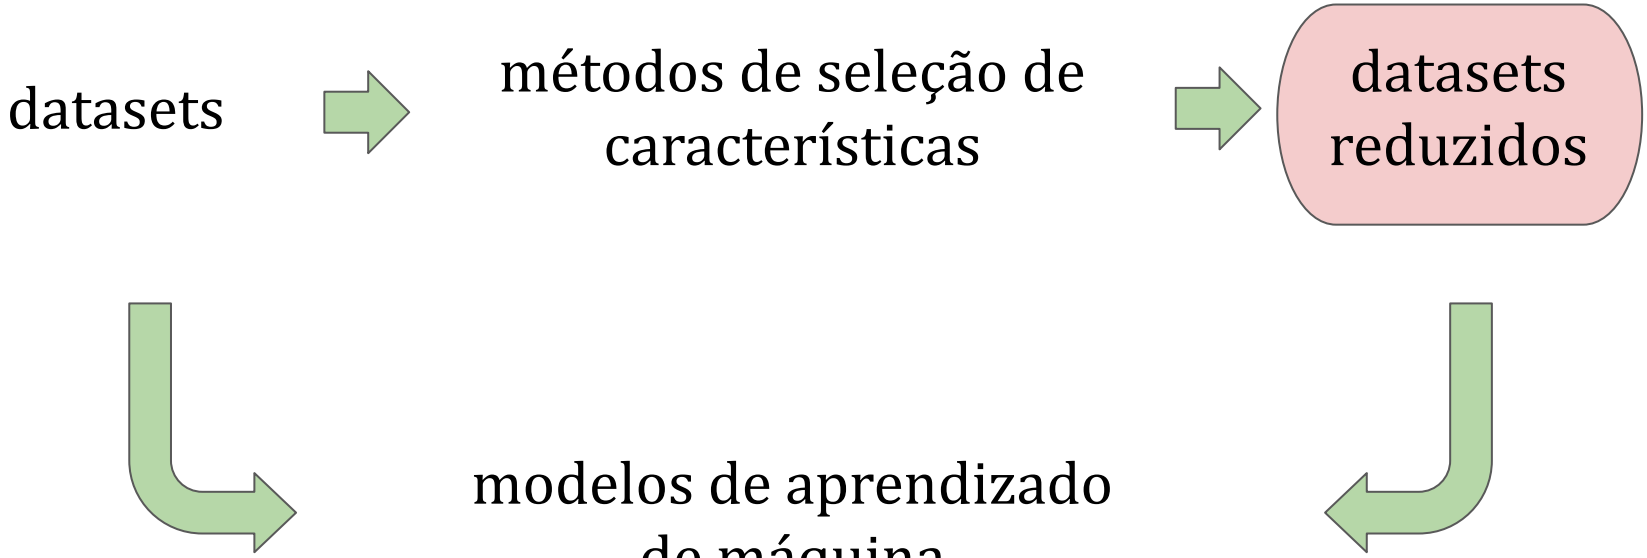

# METODOLOGIA - MODELOS

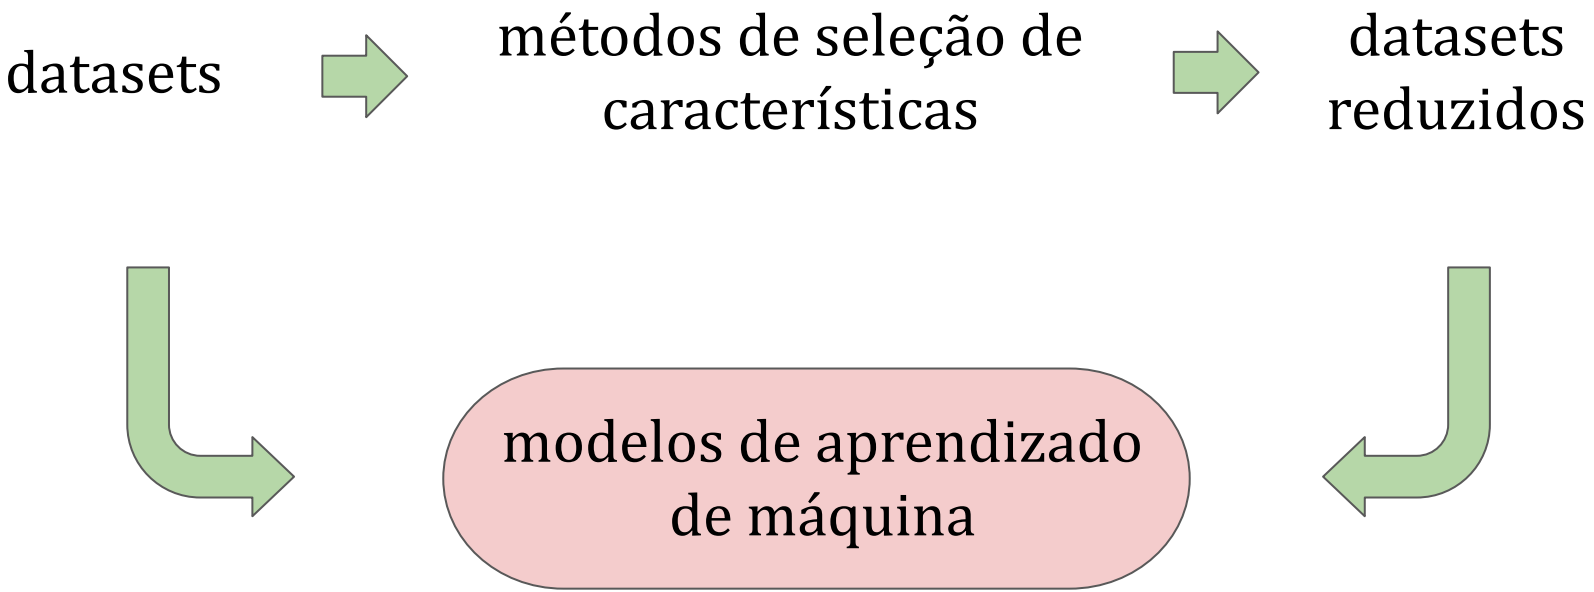

# METODOLOGIA - MODELOS

modelos de aprendizado de máquina

- Random Forest (RF)
- Support Vector Machine (SVM)

# METODOLOGIA - MODELOS

**RF:**

- 100 árvores
- Raiz quadrada da quantidade de características para procurar a melhor divisão entre classes

❏ Valores padrões da scikit learn

# METODOLOGIA - MODELOS

**SVM:**

- Kernel Radial Basis Function (RBF) e heurística de redução para diminuir tempo de treino

❑ Valores padrões da scikit learn

# REPOSITÓRIO FEATURE SELECTION

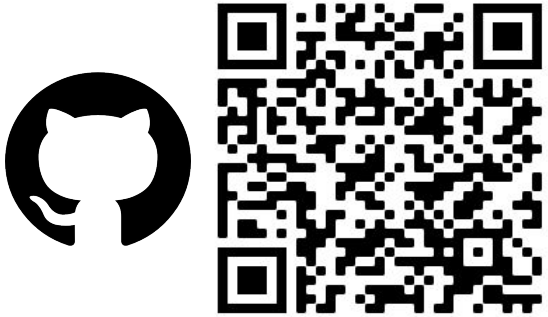

# RESULTADOS - SELEÇÃO DE CHAMADAS DE API (SIGAPI E RFG)

| | Redução (%) | | Tempo (s) | | Desempenho (ROC_AUC) | | |
|---|---|---|---|---|---|---|---|
| **Dataset** | **SigAPI** | **RFG** | **SigAPI** | **RFG** | **SigAPI** | **RFG** | **Sem redução** |
| *drebin_215* | 79,45 | 71,23 | 540 | 203 | 94,40 | 91,71 | 97,55 |
| *md46k* | 99,15 | 8,07 | 180803 | 4322 | 70,23 | 79,95 | 79,95 |
| *androcrawl* | 95,83 | 12,5 | 314 | 391 | 81,56 | 90,94 | 91,18 |

# RESULTADOS - SELEÇÃO DE CHAMADAS DE API (SIGAPI E RFG)

| | Redução (%) | | Tempo (s) | | Desempenho (ROC_AUC) | | |
|---|---|---|---|---|---|---|---|
| **Dataset** | **SigAPI** | **RFG** | **SigAPI** | **RFG** | **SigAPI** | **RFG** | **Sem redução** |
| *drebin_215* | 79,45 | 71,23 | 540 | 203 | 94,40 | 91,71 | 97,55 |
| *md46k* | 99,15 | 8,07 | 180803 | 4322 | 70,23 | 79,95 | 79,95 |
| *androcrawl* | 95,83 | 12,5 | 314 | 391 | 81,56 | 90,94 | 91,18 |

Mais demorado -> utilização de sete técnicas

# RESULTADOS - SELEÇÃO DE CHAMADAS DE API (SIGAPI E RFG)

| | Redução (%) | | Tempo (s) | | Desempenho (ROC_AUC) | | |
|---|---|---|---|---|---|---|---|
| **Dataset** | **SigAPI** | **RFG** | **SigAPI** | **RFG** | **SigAPI** | **RFG** | **Sem redução** |
| *drebin_215* | 79,45 | 71,23 | 540 | 203 | 94,40 | 91,71 | 97,55 |
| *md46k* | 99,15 | 8,07 | 180803 | 4322 | 70,23 | 79,95 | 79,95 |
| *androcrawl* | 95,83 | 12,5 | 314 | 391 | 81,56 | 90,94 | 91,18 |

Redução maior em todos os casos

# RESULTADOS - SELEÇÃO DE CHAMADAS DE API (SIGAPI E RFG)

| | Redução (%) | | Tempo (s) | | Desempenho (ROC_AUC) | | |
|---|---|---|---|---|---|---|---|
| **Dataset** | **SigAPI** | **RFG** | **SigAPI** | **RFG** | **SigAPI** | **RFG** | **Sem redução** |
| *drebin_215* | 79,45 | 71,23 | 540 | 203 | 94,40 | 91,71 | 97,55 |
| *md46k* | 99,15 | 8,07 | 180803 | 4322 | 70,23 | 79,95 | 79,95 |
| *androcrawl* | 95,83 | 12,5 | 314 | 391 | 81,56 | 90,94 | 91,18 |

Melhor resultado para *drebin_215_api_calls*

-> mais balanceado e conjunto reduzido de features

# RESULTADOS - SELEÇÃO DE CHAMADAS DE API (SIGAPI E RFG)

| | Redução (%) | | Tempo (s) | | Desempenho (ROC_AUC) | | |
|---|---|---|---|---|---|---|---|
| **Dataset** | **SigAPI** | **RFG** | **SigAPI** | **RFG** | **SigAPI** | **RFG** | **Sem redução** |
| *drebin_215* | 79,45 | 71,23 | 540 | 203 | 94,40 | 91,71 | 97,55 |
| *md46k* | 99,15 | 8,07 | 180803 | 4322 | 70,23 | 79,95 | 79,95 |
| *androcrawl* | 95,83 | 12,5 | 314 | 391 | 81,56 | 90,94 | 91,18 |

Grande variação

# RESULTADOS - SELEÇÃO DE CHAMADAS DE API (SIGAPI E RFG)

| | Redução (%) | | Tempo (s) | | Desempenho (ROC_AUC) | | |
|---|---|---|---|---|---|---|---|
| **Dataset** | **SigAPI** | **RFG** | **SigAPI** | **RFG** | **SigAPI** | **RFG** | **Sem redução** |
| *drebin_215* | 79,45 | 71,23 | 540 | 203 | 94,40 | 91,71 | 97,55 |
| *md46k* | 99,15 | 8,07 | 180803 | 4322 | 70,23 | 79,95 | 79,95 |
| *androcrawl* | 95,83 | 12,5 | 314 | 391 | 81,56 | 90,94 | 91,18 |

Melhores resultados em geral -> estabilidade

# RESULTADOS - SELEÇÃO DE PERMISSÕES (SIGPID E ALR)

| | Redução (%) | | Tempo (s) | | Desempenho (ROC_AUC) | | |
|---|---|---|---|---|---|---|---|
| **Dataset** | **SigPID** | **ALR** | **SigPID** | **ALR** | **SigPID** | **ALR** | **Sem redução** |
| *drebin_215* | 71,68 | 69,03 | 48 | 2 | 94,05 | 89,18 | 95,86 |
| *md46k* | 99,77 | 46,05 | 7106 | 746 | 50,00 | 52,81 | 62,06 |
| *androcrawl* | 87,76 | 97,96 | 176 | 3 | 50,00 | 50,00 | 49,84 |

# RESULTADOS - SELEÇÃO DE PERMISSÕES (SIGPID E ALR)

| | Redução (%) | | Tempo (s) | | Desempenho (ROC_AUC) | | |
|---|---|---|---|---|---|---|---|
| **Dataset** | **SigPID** | **ALR** | **SigPID** | **ALR** | **SigPID** | **ALR** | **Sem redução** |
| *drebin_215* | 71,68 | 69,03 | 48 | 2 | 94,05 | 89,18 | 95,86 |
| *md46k* | 99,77 | 46,05 | 7106 | 746 | 50,00 | 52,81 | 62,06 |
| *androcrawl* | 87,76 | 97,96 | 176 | 3 | 50,00 | 50,00 | 49,84 |

Mais demorado

# RESULTADOS - SELEÇÃO DE PERMISSÕES (SIGPID E ALR)

| | Redução (%) | | Tempo (s) | | Desempenho (ROC_AUC) | | |
|---|---|---|---|---|---|---|---|
| **Dataset** | **SigPID** | **ALR** | **SigPID** | **ALR** | **SigPID** | **ALR** | **Sem redução** |
| *drebin_215* | 71,68 | 69,03 | 48 | 2 | 94,05 | 89,18 | 95,86 |
| *md46k* | 99,77 | 46,05 | 7106 | 746 | 50,00 | 52,81 | 62,06 |
| *androcrawl* | 87,76 | 97,96 | 176 | 3 | 50,00 | 50,00 | 49,84 |

Ótimo resultado para *drebin_215_permissions*

-> leva em consideração balanceamento

# RESULTADOS - SELEÇÃO DE PERMISSÕES (SIGPID E ALR)

| | Redução (%) | | Tempo (s) | | Desempenho (ROC_AUC) | | |
|---|---|---|---|---|---|---|---|
| **Dataset** | **SigPID** | **ALR** | **SigPID** | **ALR** | **SigPID** | **ALR** | **Sem redução** |
| *drebin_215* | 71,68 | 69,03 | 48 | 2 | 94,05 | 89,18 | 95,86 |
| *md46k* | 99,77 | 46,05 | 7106 | 746 | 50,00 | 52,81 | 62,06 |
| *androcrawl* | 87,76 | 97,96 | 176 | 3 | 50,00 | 50,00 | 49,84 |

Reduções pouco seletivas em datasets esparsos e desbalanceados

# CONSIDERAÇÕES FINAIS

- Relação dos métodos com particularidades dos datasets
  - Resultados oscilam para diferentes datasets
  - SigAPI, SigPID e ALR -> datasets balanceados
  - RFG mostrou mais estabilidade
    - Etapa robusta de validação

# TRABALHOS FUTUROS

- Avaliação dos métodos com uma gama ainda maior e mais diversificada de datasets
  - conjuntos de dados maiores e sem pré-processamento

# TRABALHOS FUTUROS

- Avaliação dos métodos com uma gama ainda maior e mais diversificada de datasets
  - conjuntos de dados maiores e sem pré-processamento
- Avaliação de outros métodos de seleção de características

# TRABALHOS FUTUROS

- Avaliação dos métodos com uma gama ainda maior e mais diversificada de datasets
  - conjuntos de dados maiores e sem pré-processamento
- Avaliação de outros métodos de seleção de características
- Identificação de parâmetros de otimização que podem impactar os métodos de seleção

# TRABALHOS FUTUROS

- Avaliação dos métodos com uma gama ainda maior e mais diversificada de datasets
  - conjuntos de dados maiores e sem pré-processamento
- Avaliação de outros métodos de seleção de características
- Identificação de parâmetros de otimização que podem impactar os métodos de seleção
- Avaliação de resultados a partir da combinação de métodos

# TRABALHOS FUTUROS

- Avaliação dos métodos com uma gama ainda maior e mais diversificada de datasets
  - conjuntos de dados maiores e sem pré-processamento
- Avaliação de outros métodos de seleção de características
- Identificação de parâmetros de otimização que podem impactar os métodos de seleção
- Avaliação de resultados a partir da combinação de métodos

# OBRIGADA PELA ATENÇÃO!

UFAM

unipampa
Universidade Federal do Pampa

Uma Análise de Métodos de  Seleção de Características aplicados à Detecção de Malwares Android

tainasoares.aluno@unipampa.edu.br