AVALIAÇÃO DE MÉTODOS DE CLASSIFICAÇÃO BASEADOS EM REGRAS DE ASSOCIAÇÃO PARA DETECÇÃO DE MALWARES ANDROID

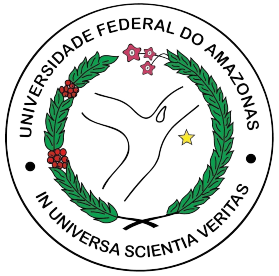

UFAM

unipampa

Universidade Federal do Pampa

Vanderson Rocha
Diego Kreutz
Jonas Pontes
Eduardo Feitosa

Universidade Federal do Amazonas (UFAM)
Universidade Federal do Pampa (UNIPAMPA)

DETECÇÃO DE MALWARES

BRATA: malware para Android rouba seus dados e reseta o celular

25/01/2022 às 17:50 • 1 min de leitura

Crypto malware in patched wallets targeting Android and iOS devices

ESET Research uncovers a sophisticated scheme that distributes trojanized Android and iOS cryptocurrency wallets

Lukas Stefanko

24 Mar 2022 - 01:30PM

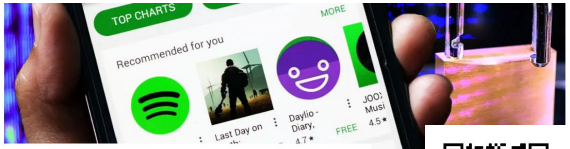

SECURITY & PRIVACY

Check your phone! More bad apps caught hiding in the Google Play Store

BY CHARLIE FRIPP, KOMANDO.COM • MARCH 21, 2022 SHARE:

APRENDIZADO DE MÁQUINA

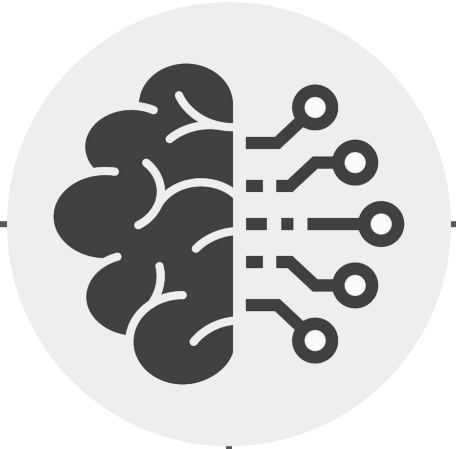

SUPERVISIONADO

NÃO SUPERVISIONADO

APRENDIZAGEM PROFUNDA

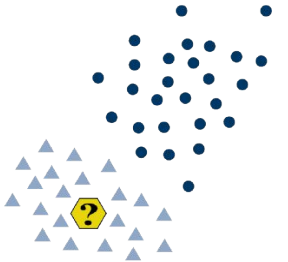

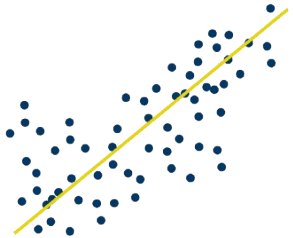

CLASSIFICAÇÃO REGRESSÃO

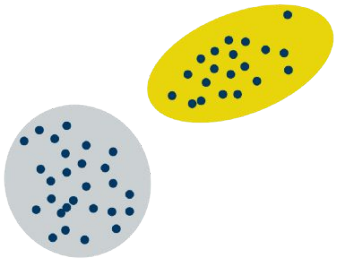

AGRUPAMENTO

CLASSIFICAÇÃO BASEADA EM REGRAS DE ASSOCIAÇÃO

- Gestão de Relacionamento
- Diagnóstico Médico
- Combate à Fraudes

OBJETIVO

Análise exploratória de diferentes métodos de classificação.

Algoritmos Clássicos	Método
Apriori	CBA
FP-Growth	CMAR
ECLAT	EQAR

ROTEIRO

- **Mineração de Regras de Associação**
- Método de Classificação EQAR
- Metodologia
- Resultados
- Considerações Finais

DEFINIÇÃO

Padrões, Correlações ou Associações

Se (Antecedente) ⇒ Então (Consequente)

Se {*ACCESS_NETWORK_STATE, READ_PHONE_STATE, SEND_SMS*}
⇒ Então Malicioso

PRINCIPAIS MÉTRICAS

- Suporte
- Confiança

Leite	Pão	Ovo
1	0	1
1	1	0
1	1	1
1	1	1
0	0	1

PRINCIPAIS MÉTRICAS

- Suporte

Frequência (Leite ∪ Pão) / N = 3/5 = 0.6 (60%)

- Confiança

Leite	Pão	Ovo
1	0	1
1	1	0
1	1	1
1	1	1
0	0	1

PRINCIPAIS MÉTRICAS

- Suporte

Frequência (Leite ∪ Pão) / N = 3/5 = 0.6 (60%)

Leite	Pão	Ovo
1	0	1
1	1	0
1	1	1
1	1	1
0	0	1

- Confiança

Frequência (Pão) / Frequência (Leite) = 3/4 = 0.75 (75%)

ROTEIRO

- Mineração de Regras de Associação
- **Método de Classificação EQAR**
- Metodologia
- Resultados
- Considerações Finais

ETAPAS

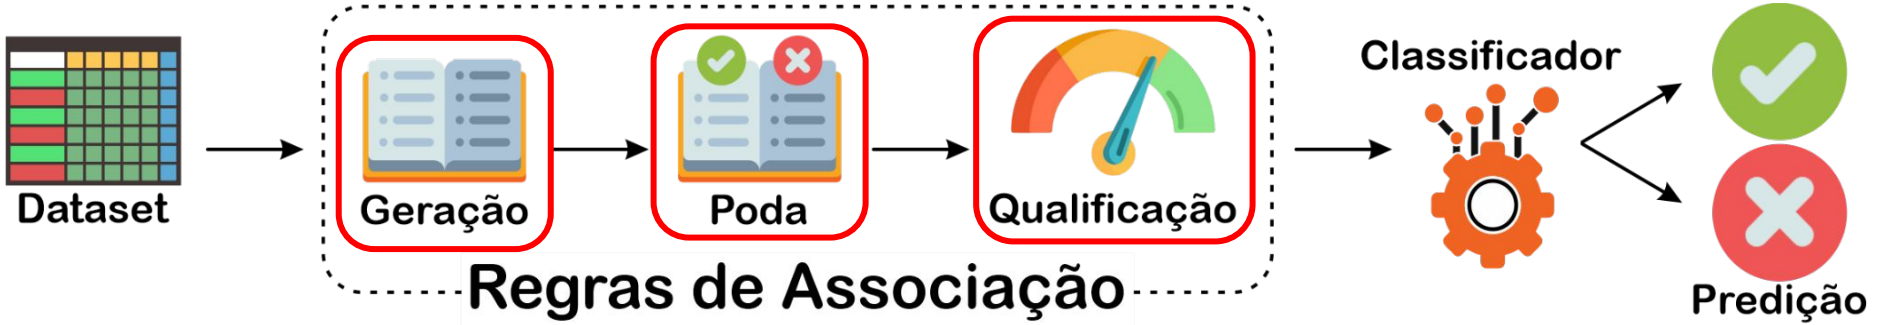
Dataset
Geração
Poda
Qualificação
Regras de Associação
Classificador
Predição

GERAÇÃO

Algoritmo 1: Geração e Poda de Regras de Associação

Entrada:

D: *dataset* de treino
minSup: suporte mínimo
minConf: confiança mínima

1 $\text{dataset}_{\text{malignas}} \leftarrow t \in D \wedge t[class] = 1;$ // amostras malignas
2 $\text{dataset}_{\text{benignas}} \leftarrow t \in D \wedge t[class] = 0;$ // amostras benignas

3 $\text{regras}_{\text{malignas}} \leftarrow$ **gerar_regras**($\text{dataset}_{\text{malignas}}$, minSup, minConf)
4 $\text{regras}_{\text{benignas}} \leftarrow$ **gerar_regras**($\text{dataset}_{\text{benignas}}$, minSup, minConf)

5 $\text{regras}_{\text{dif}} \leftarrow \text{regras}_{\text{malignas}} \setminus \text{regras}_{\text{benignas}}$
6 $\text{regras}_{\text{sub}} \leftarrow X \in \text{regras}_{\text{dif}} \wedge X \not\subset Y, \forall Y \in$ regras
7 regras $\leftarrow X \in \text{regras}_{\text{sub}} \wedge X \not\supset Y, \forall Y$

8 **retorna** *regras*

$X \Rightarrow Y$

PODA

Algoritmo 1: Geração e Poda de Regras de Associação

Entrada:

D: *dataset* de treino
minSup: suporte mínimo
minConf: confiança mínima

1 $dataset_{malignas} \leftarrow t \in D \wedge t[class] = 1;$ // Conjunto de malignas
2 $dataset_{benignas} \leftarrow t \in D \wedge t[class] = 0;$ // Conjunto de benignas
3 $regras_{malignas} \leftarrow$ **gerar_regras**($dataset_{malignas}$, ...)
4 $regras_{benignas} \leftarrow$ **gerar_regras**($dataset_{benignas}$, ...)
5 $regras_{dif} \leftarrow regras_{malignas} \setminus regras_{benignas}$
6 $regras_{sub} \leftarrow X \in regras_{dif} \wedge X \not\subset Y, \forall Y \in regras_{benignas}$
7 $regras \leftarrow X \in regras_{sub} \wedge X \not\supset Y, \forall Y \in regras_{sub}$
8 **retorna** *regras*

$C_1 \cup C_8 \Rightarrow$ Classe

QUALIDADE DE REGRAS

- Cobertura
  - Maximizar Amostras Positivas
- Consistência
  - Minimizar Amostras Negativas

	Malignas	**Benignas**
Amostras Cobertas Pela Regra	p	n
Total de Amostras	P	N

QUALIFICAÇÃO DE REGRAS

Algoritmo 2: Qualificação de Regras de Associação

Entrada:

D: *dataset* de treino
regras: conjunto de regras (Algoritmo 1)
métrica: função de métrica de qualidade a ser utilizada

```
1 P ← quantidade de malignas em D
2 N ← quantidade de benignas em D
3 regras_qualidade ← ∅;                    // lista (regra, qualidade)
4 para cada regra r ∈ regras faça
5     p, n ← encontrar_cobertura(r)
6     q ← métrica(p, n, P, N)
7     regras_qualidade ← regras_qualidade ∪ (r, q)
8 retorna regras_qualidade
```

ROTEIRO

- Mineração de Regras de Associação
- Método de Classificação EQAR
- **Metodologia**
- Resultados
- Considerações Finais

MÉTODOS DE CLASSIFICAÇÃO

Método	Geração de Regras	Classificação das Regras	Poda	Predição
CBA	Apriori	Confiança, Suporte Geradas Primeiro	Cobertura (Método M1)	Máxima Probabilidade
CMAR	FP-Growth	Confiança, Suporte Cardinalidade	Cobertura (Método M1), Regras Redundantes	Multiplas Regras
CPAR	PRM	Acurácia de Laplace	Seleção dos K Melhores	Multiplas Regras
EQAR	ECLAT	Confiança, Suporte	Qualidade de Regras, Diferença de Conjuntos	Correspondência Exata

MÉTODOS DE CLASSIFICAÇÃO

Método	Geração de Regras	Classificação das Regras	Poda	Predição
CBA	Apriori	Confiança, Suporte Geradas Primeiro	Cobertura (Método M1)	Máxima Probabilidade
CMAR	FP-Growth	Confiança, Suporte Cardinalidade	Cobertura (Método M1), Regras Redundantes	Multiplas Regras
CPAR	PRM	Acurácia de Laplace	Seleção dos K Melhores	Multiplas Regras
EQAR	ECLAT	Confiança, Suporte	Qualidade de Regras, Diferença de Conjuntos	Correspondência Exata

MÉTODOS DE CLASSIFICAÇÃO

Método	Geração de Regras	Classificação das Regras	Poda	Predição
CBA	Apriori	Confiança, Suporte Geradas Primeiro	Cobertura (Método M1)	Máxima Probabilidade
CMAR	FP-Growth	Confiança, Suporte Cardinalidade	Cobertura (Método M1), Regras Redundantes	Multiplas Regras
CPAR	PRM	Acurácia de Laplace	Seleção dos K Melhores	Multiplas Regras
EQAR	ECLAT	Confiança, Suporte	Qualidade de Regras, Diferença de Conjuntos	Correspondência Exata

CONJUNTOS DE DADOS

Dataset	Caracteristicas	Amostras		
		Malignas	Benignas	Total
KronoDroid Emulador	383	28745	35246	63991
KronoDroid Dispositivo Real	383	41382	36755	78137
DREBIN-215	215	5560	9476	15036

CONJUNTOS DE DADOS

Dataset	Caracteristicas	Amostras		
		Malignas	Benignas	Total
KronoDroid Emulador	383	28745	35246	63991
KronoDroid Dispositivo Real	383	41382	36755	78137
DREBIN-215	215	5560	9476	15036

CONJUNTOS DE DADOS

Dataset	Caracteristicas	Amostras		
		Malignas	Benignas	Total
KronoDroid Emulador	383	28745	35246	63991
KronoDroid Dispositivo Real	383	41382	36755	78137
DREBIN-215	215	5560	9476	15036

CONJUNTOS DE DADOS

Dataset	Caracteristicas	Amostras		
		Malignas	Benignas	Total
KronoDroid Emulador	383	28745	35246	63991
KronoDroid Dispositivo Real	383	41382	36755	78137
DREBIN-215	215	5560	9476	15036

PARÂMETROS

- Tamanho Máximo da Regra: 5
- Confiança Mínima: 95%
- Validação
  - Cruzada
  - Estratificada
  - 5 Partições

PARÂMETROS

- RF
  - Árvores na Floresta: 100
  - Divisão Entre Classes: Raiz Quadrada
- SVM:
  - Kernel: Radial Basis Function (RBF)
  - Heurística de Redução

MÉTRICAS

- Acurácia
- Precisão
- Recall
- F1 Score
- MCC

ROTEIRO

- Mineração de Regras de Associação
- Método de Classificação EQAR
- Metodologia
- **Resultados**
- Considerações Finais

SUPORTE

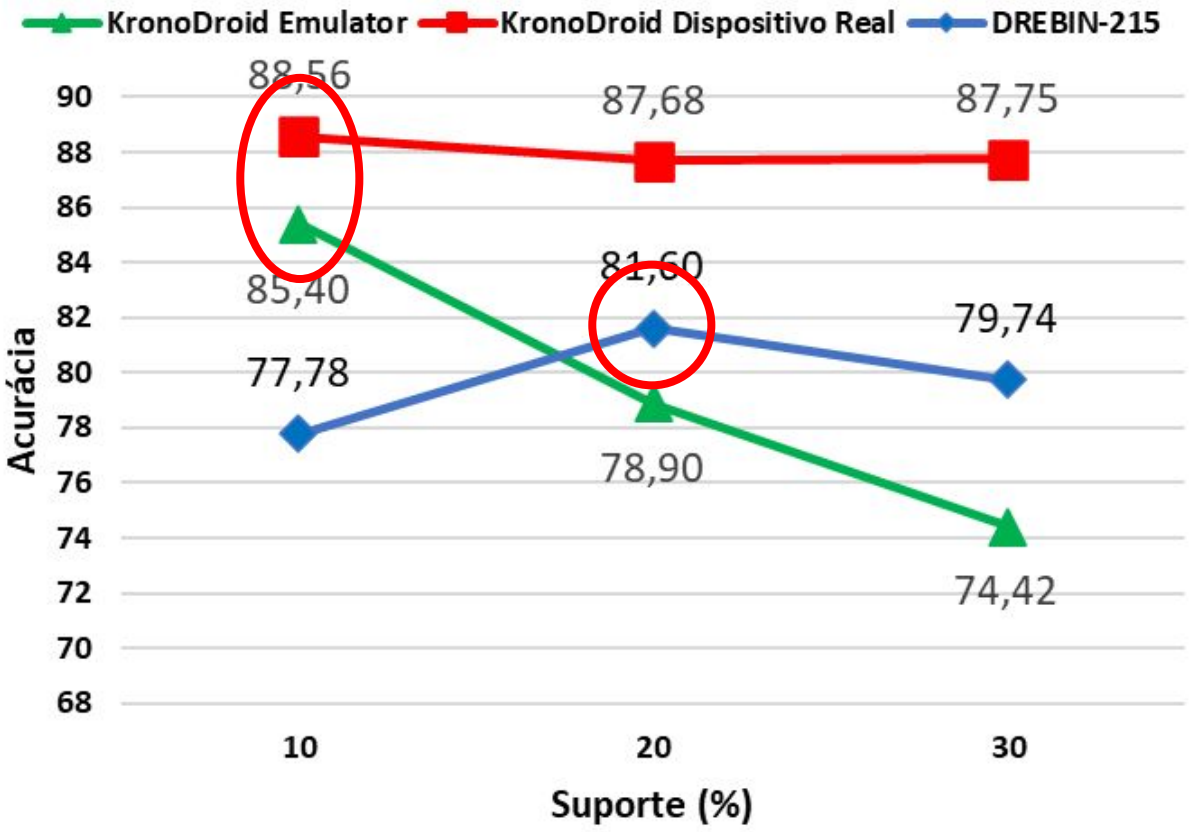
KronoDroid Emulator
KronoDroid Dispositivo Real
DREBIN-215
Acurácia
90
88
86
84
82
80
78
76
74
72
70
68
88,56
87,68
87,75
85,40
81,60
79,74
77,78
78,90
74,42
10
20
30
Suporte (%)

THRESHOLD

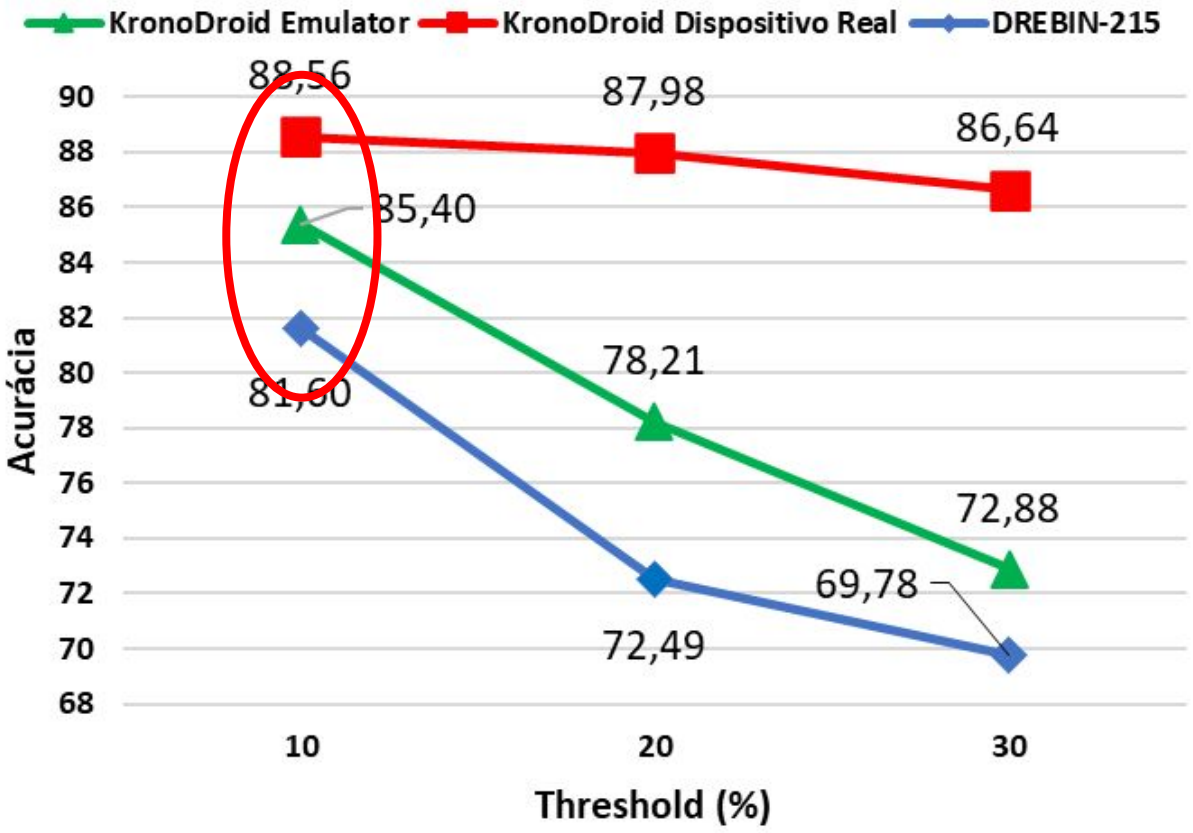
KronoDroid Emulator
KronoDroid Dispositivo Real
DREBIN-215
88,56
87,98
86,64
85,40
78,21
72,88
81,60
72,49
69,78
90
88
86
84
82
80
78
76
74
72
70
68
Acurácia
10
20
30
Threshold (%)

KRONODROID - DISPOSITIVO REAL

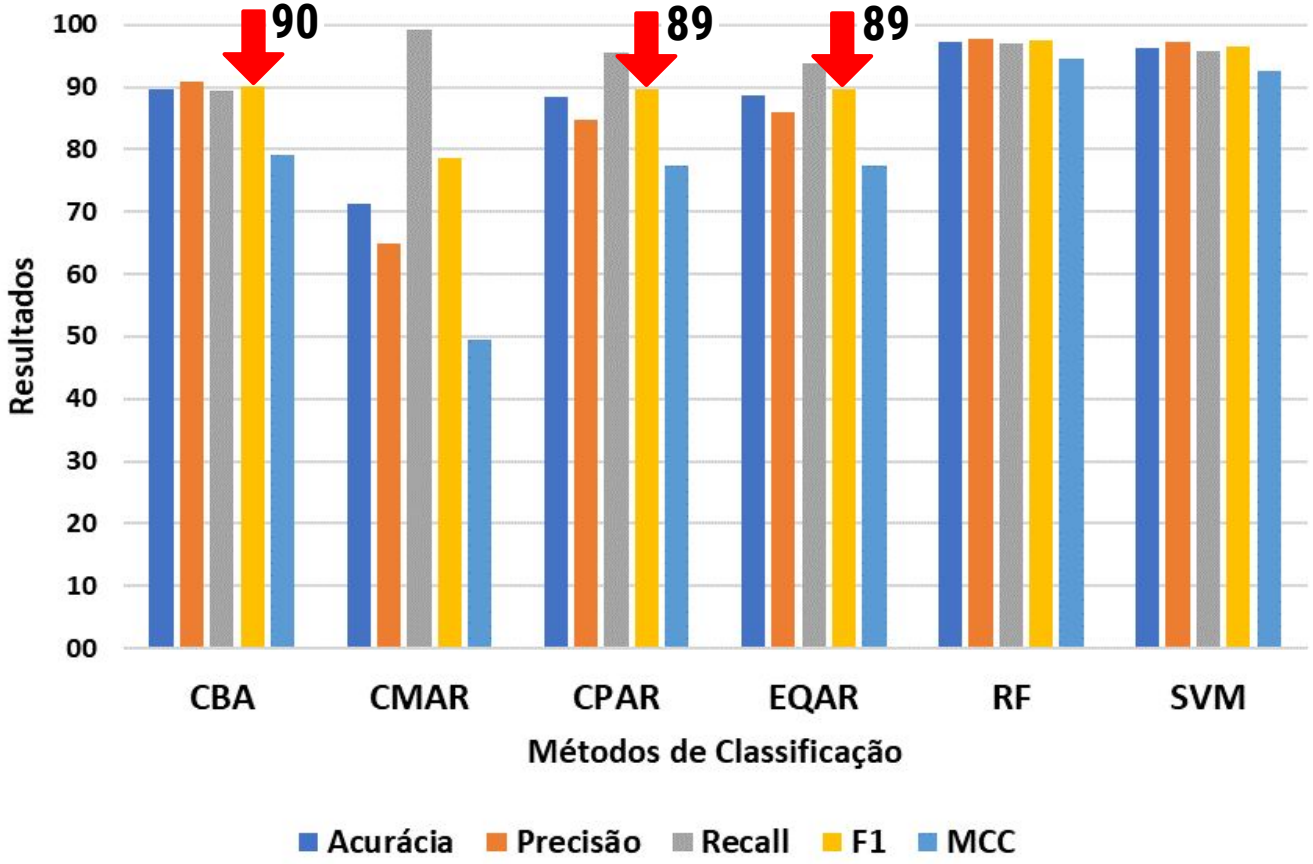

KRONODROID - DISPOSITIVO REAL

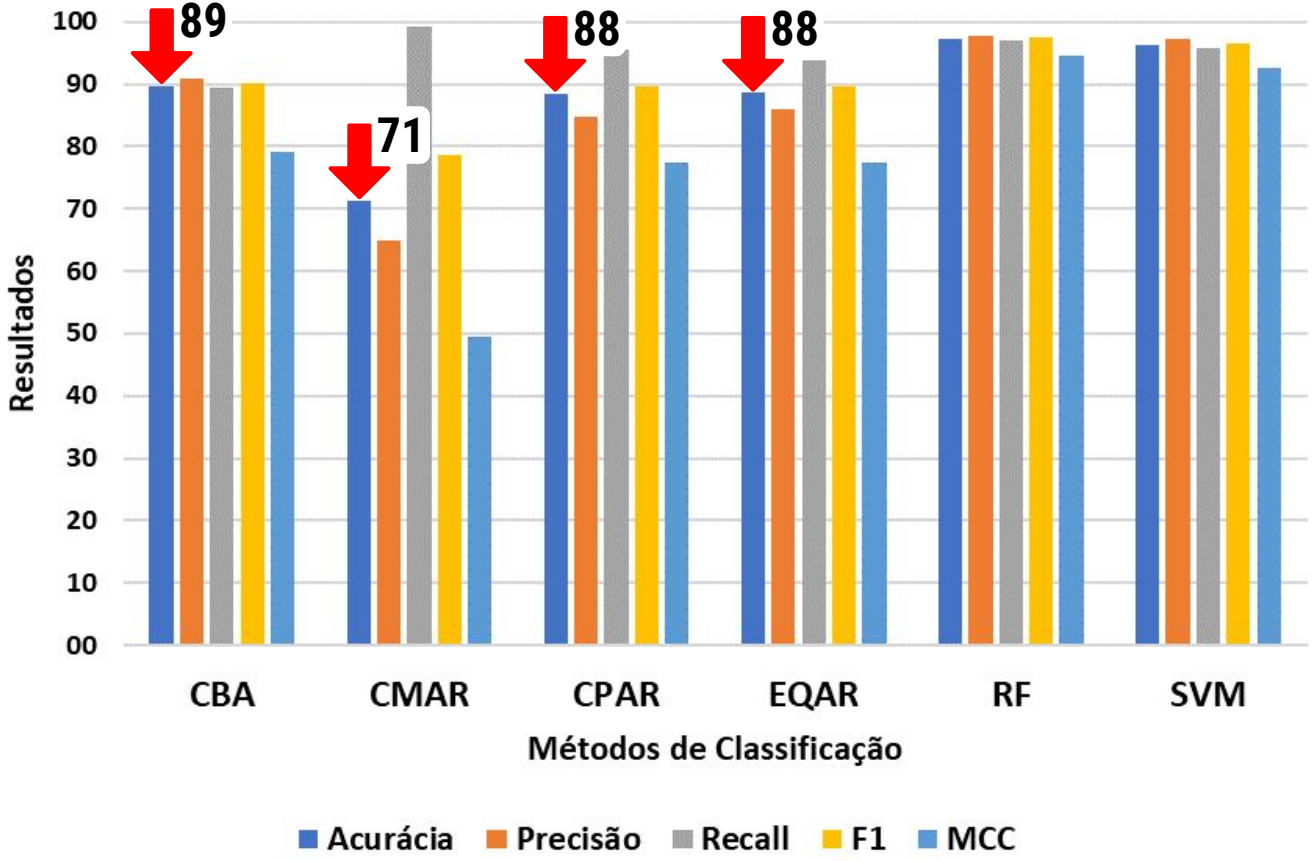

KRONODROID - DISPOSITIVO REAL

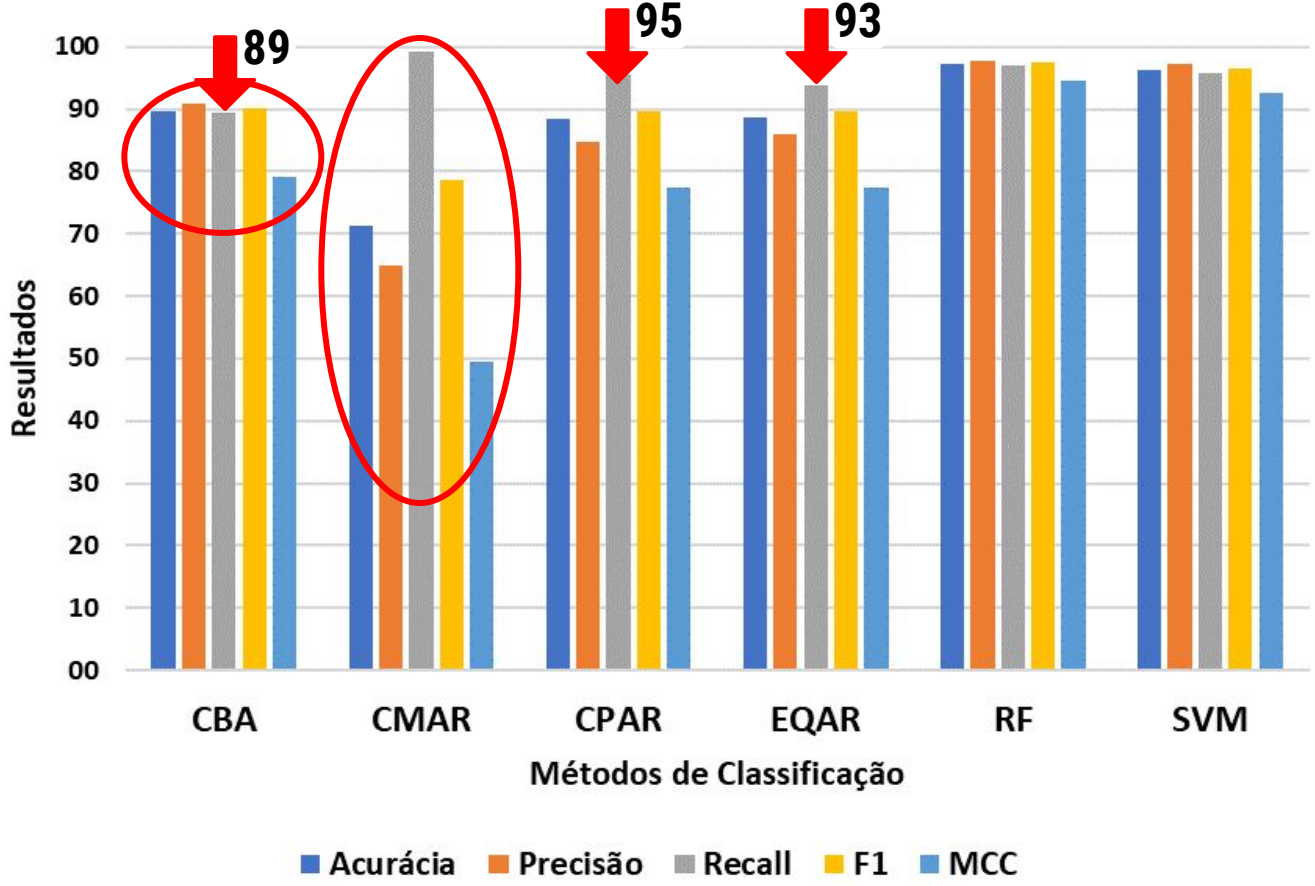

KRONODROID - EMULADOR

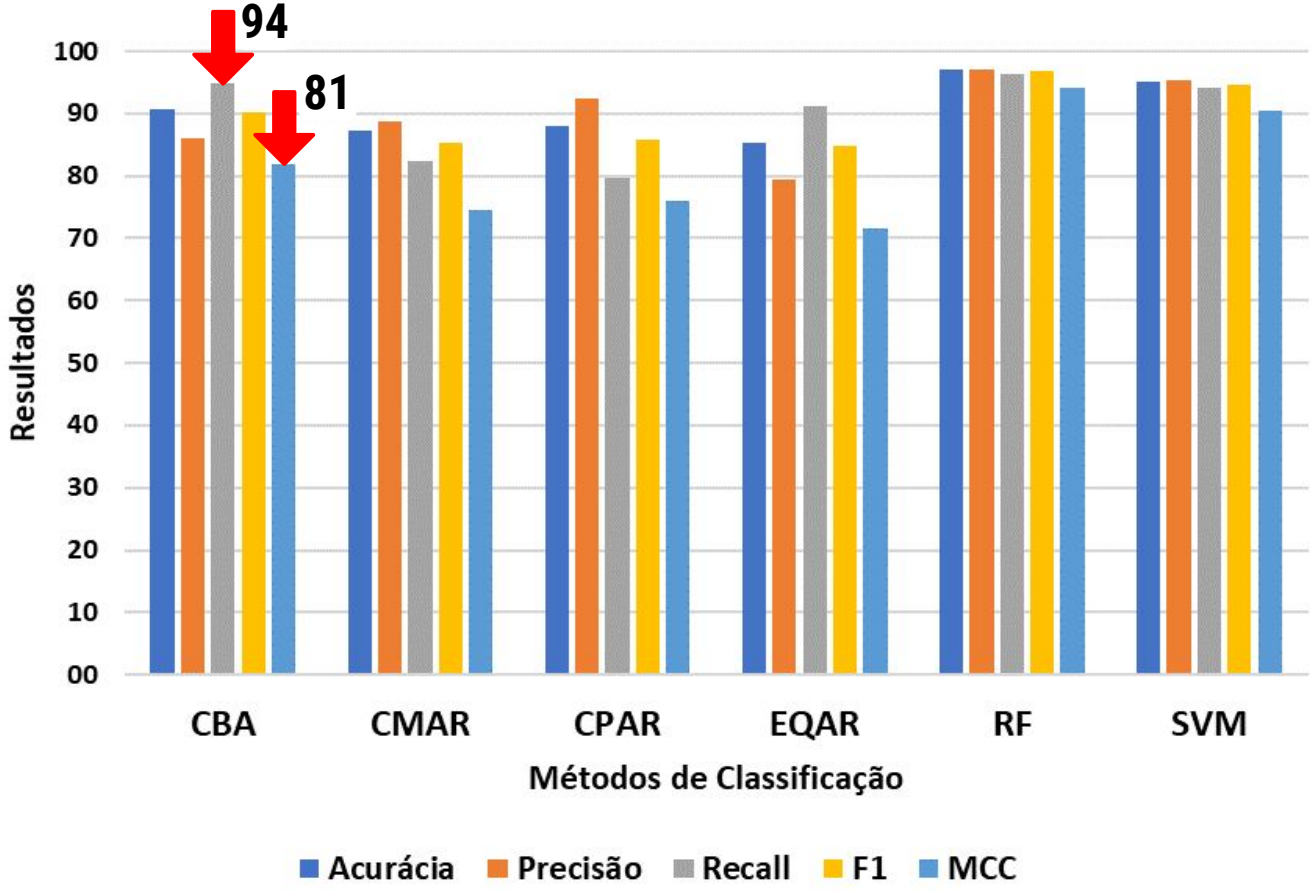

DREBIN-215

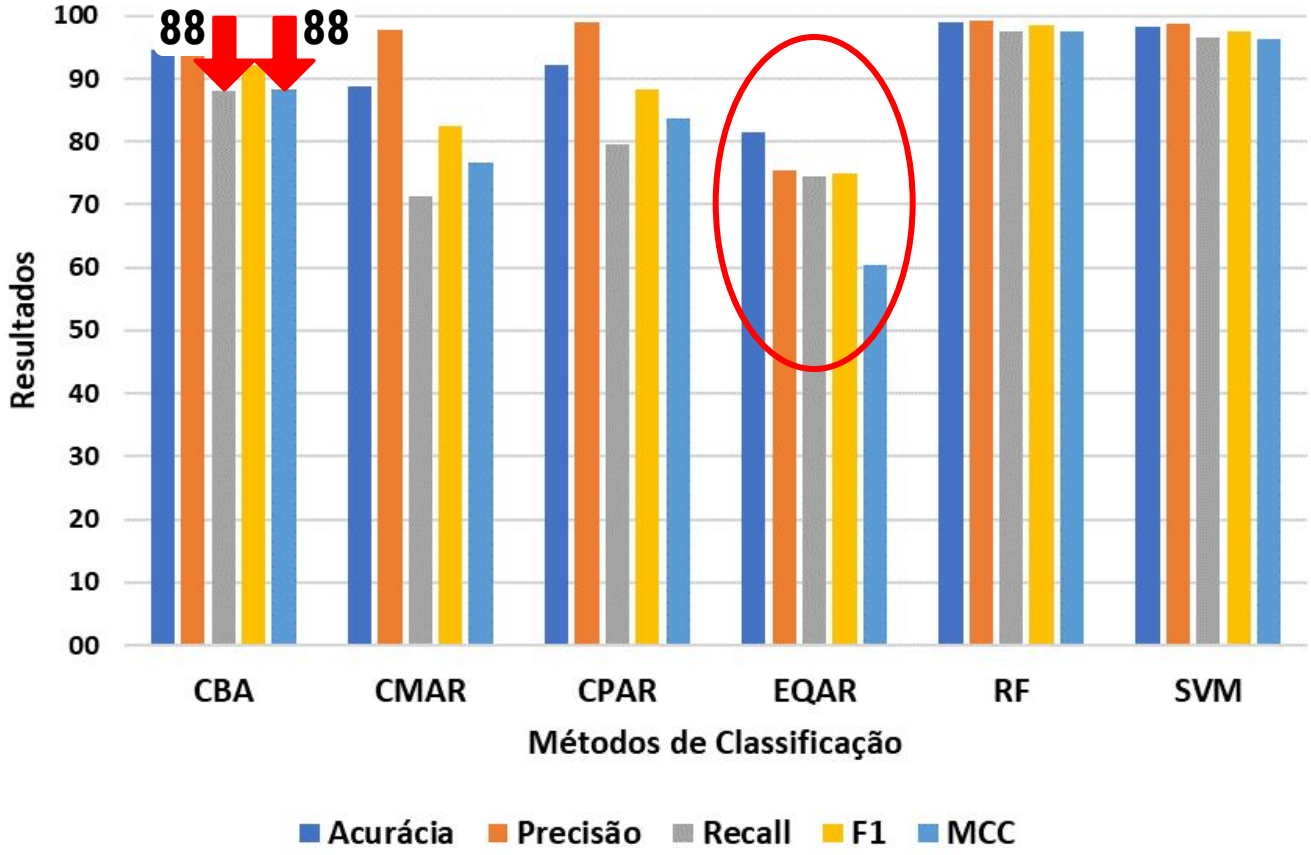
88
88
100
90
80
70
60
50
40
30
20
10
00
Resultados
CBA
CMAR
CPAR
EQAR
RF
SVM
Métodos de Classificação
Acurácia
Precisão
Recall
F1
MCC

ROTEIRO

- Mineração de Regras de Associação
- Método de Classificação EQAR
- Metodologia
- Resultados
- **Considerações Finais**

TRABALHOS FUTUROS

- Expandir e Aprimorar o EQAR
- Reduzir FP e FN
- Avaliar
  - Novos Conjuntos de Dados
  - Outros Modelos de Aprendizagem de Máquina

OBRIGADO

Perguntas?

vanderson@ufam.edu.br
ppgi.ufam.edu.br