



POLVO-IIDS: Um Sistema de Detecção de Intrusão Inteligente Baseado em Anomalias

**Paulo Manoel Mafra¹, Joni da Silva Fraga¹, Vinícius Moll¹,
Altair Olivo Santin²**

Pós-Graduação em Engenharia de Automação e Sistemas (PGEAS)

Grupo de Computação Segura e Confiável (GCSEG)

Universidade Federal de Santa Catarina (UFSC)¹

Pontifícia Universidade Católica do Paraná (PUC-PR)²

Roteiro

- ⑥ Introdução
- ⑥ Detecção de anomalias
- ⑥ Modelo desenvolvido
- ⑥ Testes
- ⑥ Considerações

Sistemas de detecção de intrusão são classificados como:

- ⑥ Baseados em assinaturas
 - △ São muito bons para detectar intrusões conhecidas
 - △ Falham na detecção de novos ataques e em variantes de ataques já conhecidos
 - △ A geração de novas assinaturas é um processo custoso

Sistemas de detecção de intrusão são classificados como:

- ⑥ Baseados em anomalias
 - △ É gerado um modelo de comportamento normal do sistema
 - △ Detecta variações deste modelo em tempo real
 - △ Pode gerar muitos falsos positivos

Detecção de anomalias

Detectores baseados em anomalias podem ser:

- ⑥ Baseados em sistemas especialistas
 - △ Possuem um conjunto de regras que descrevem o comportamento normal do sistema
- ⑥ Baseados em aprendizagem
 - △ Aprendem o comportamento normal do sistema, geralmente de forma automática

Detecção de anomalias

Requisitos:

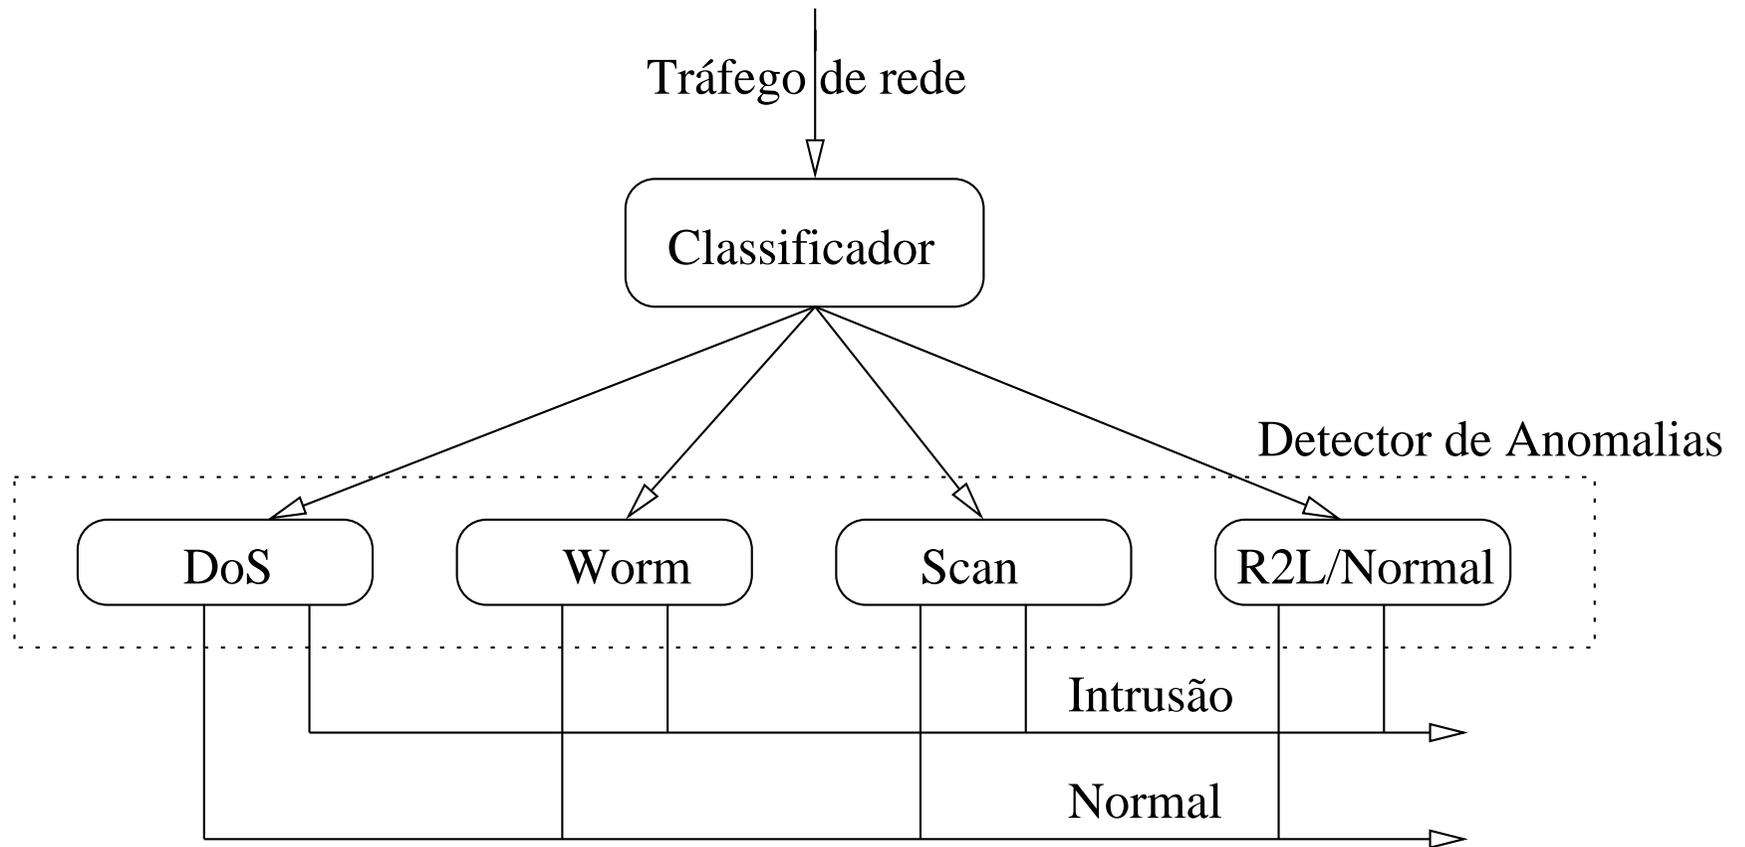
- ⑥ Evolução e atualização do sistema de forma automática
- ⑥ Ser genérico para qualquer serviço de rede
- ⑥ Precisão na detecção de anomalias, com baixa taxa de falsos positivos
- ⑥ Ser resistente a ataques similares (variações de ataques)
- ⑥ Ser eficiente para operar em grandes larguras de banda, causando baixo impacto na latência da rede

Problemas presentes em IIDS

- ⑥ Precisão na detecção
- ⑥ Treinamento do sistema
 - △ Dados usados no treinamento \neq dados Internet
 - △ Modelo de sistema adotado
- ⑥ Grande quantidade de dados para analisar
- ⑥ Dificuldade de atuação em ambientes reais (Internet)
- ⑥ Dificuldade de resposta do IIDS

Modelo desenvolvido

Modelo geral do sistema:



Modelo desenvolvido

Classificador:

- ⑥ Faz a seleção prévia do tráfego
- ⑥ Usa uma rede neural de Kohonen
- ⑥ Aprende padrões de forma automática
- ⑥ Os padrões são genéricos
- ⑥ Categorias geradas: **DoS, Worm, Scan e R2L/Normal**
- ⑥ Rede neural com 41 entradas e 4 saídas
- ⑥ Distância entre neurônios $d = \sqrt{\sum_i (v_i - w_i)^2}$
- ⑥ Aprendizado por reforço
- ⑥ Ajuste nos valores de aptidão de 0,9 para 0,8

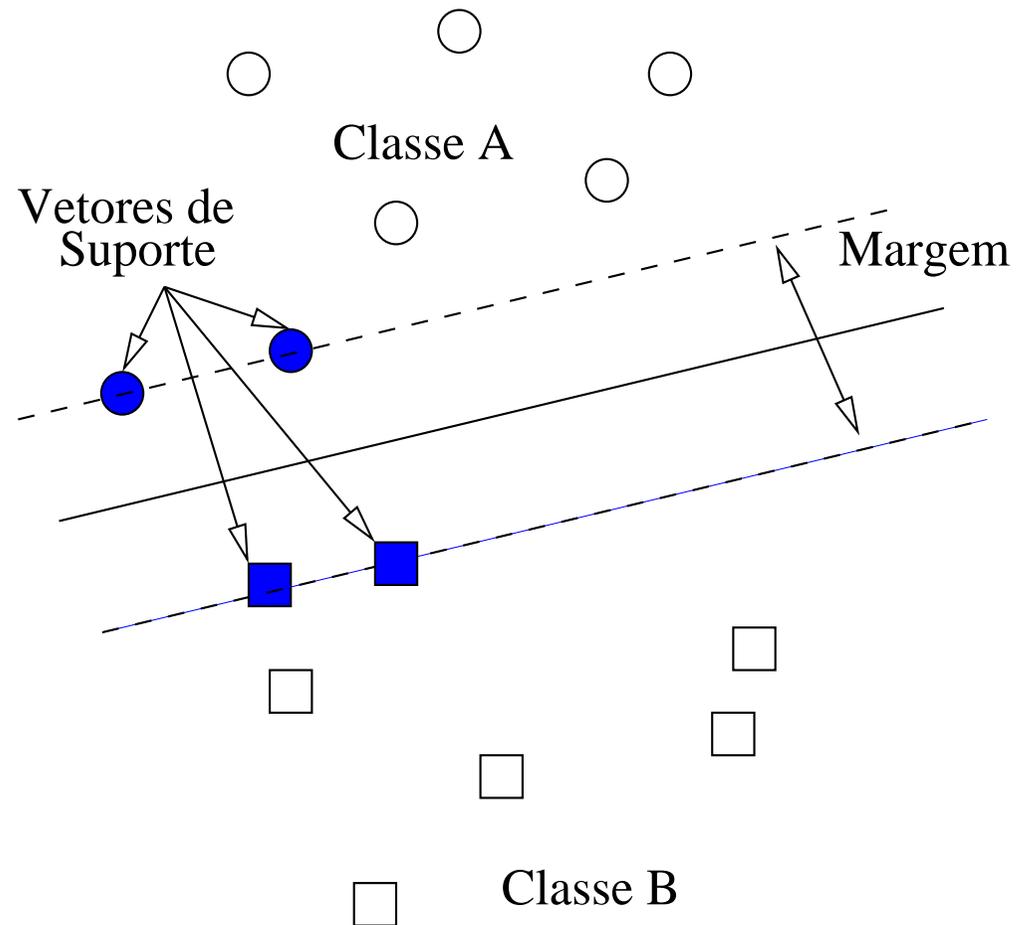
Modelo desenvolvido

Detector de Anomalias:

- ⑥ Usa quatro *Support Vector Machines* (SVM)
- ⑥ Cada SVM é responsável por um tipo de detecção
- ⑥ SVMs suportam ruído na entrada
- ⑥ Testes indicam que SVMs funcionam melhor ao separar apenas duas classes
- ⑥ Simplicidade na configuração

Modelo desenvolvido

Detector de Anomalias:



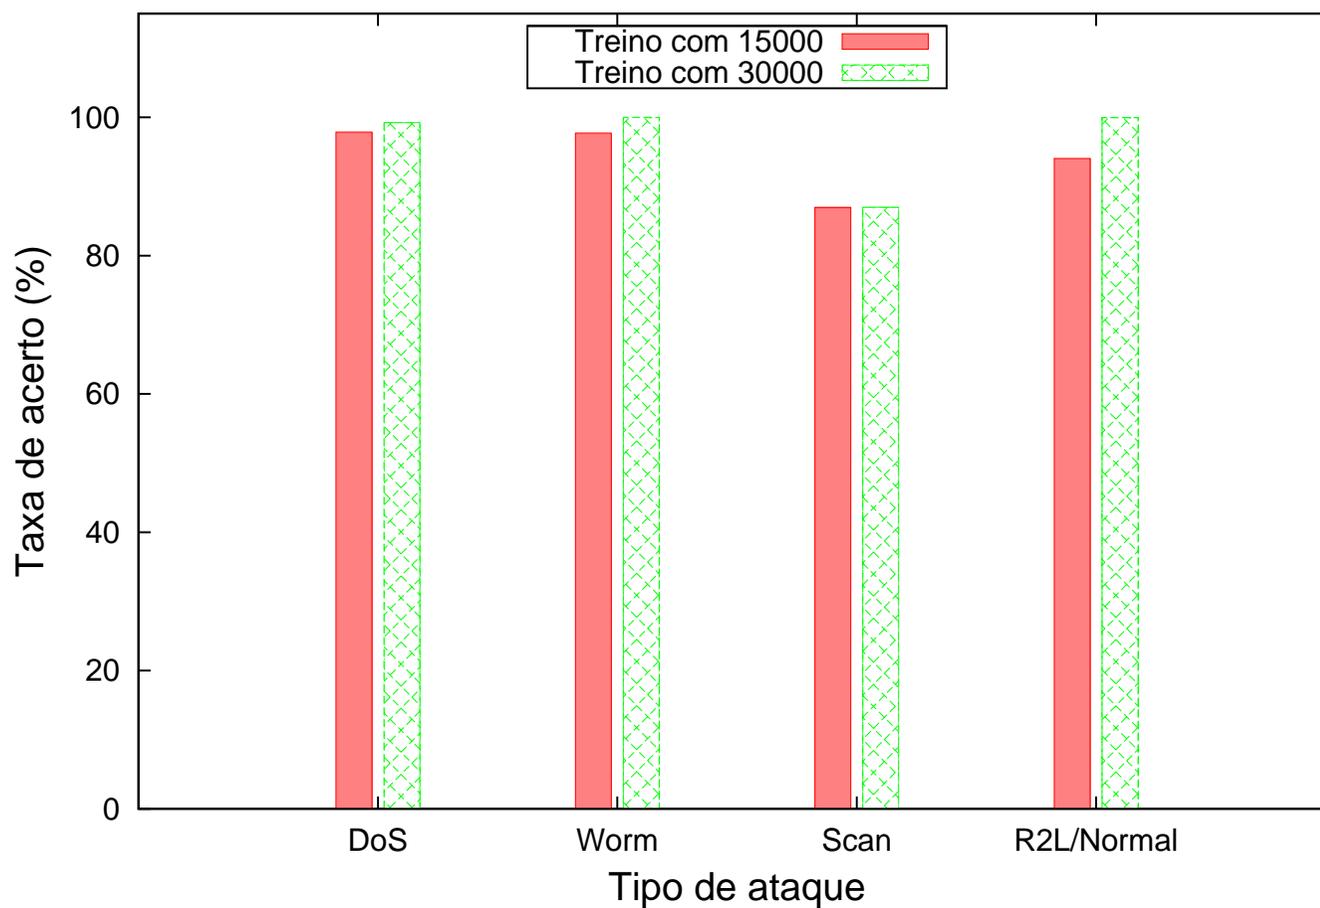
Testes

- ⑥ Protótipo foi desenvolvido usando o *framework* JOONE (Java Object Oriented Neural Engine)
- ⑥ Hardware: um computador com 4GB de memória e dois processadores Intel Xeon de 1.6GHz
- ⑥ Dados do KDD Cup 1999 para detecção de intrusão
- ⑥ Treinamento: 15.000 e 30.000 entradas com reforço de 100 vezes e 1000 vezes
- ⑥ Testes: 97.143 entradas (Tráfego normal, DoS, Worm, Scan ou R2L)

Testes



Detecção com reforço de 1000 vezes



Comparação de resultados entre IIDSs:

IIDS	Acerto Médio	Desvio Máximo
Anomalous Payload-based IDS	58,80 %	41,20 %
HPCANN	77,49 %	22,53%
MADAM ID	77,97 %	17,97%
Multi-level Hybrid Classifier	89,19 %	22,52%
POLVO-IIDS	96,55 %	9,53 %

Considerações

- ⑥ O emprego de redes neurais artificiais e SVM permitiu uma taxa de detecção maior
- ⑥ O modelo possibilita o emprego de tráfego real
- ⑥ O treinamento pode acontecer de maneira constante, mesmo com algum tráfego malicioso
- ⑥ Tempo de treinamento é elevado
- ⑥ Ainda não possui um mecanismo de resposta

Perguntas

