INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA
RIO GRANDE DO NORTE

SBSeg 2019
XIX Simpósio Brasileiro de Segurança da Informação e de Sistemas Computacionais

LaTARC Research Lab

# PhishKiller

## Uma Ferramenta para Detecção e Mitigação de Ataques de Phishing Através de Técnicas de Deep Learning


**Cristian Souza (IFRN)**

Marcilio Lemos (UFRN)
Felipe Dantas (IFRN)
Robinson Alves (IFRN)

# Agenda

1. Phishing: Conceitos básicos;
2. Proposta: Apresentação do PhishKiller e trabalhos relacionados;
3. Avaliação e resultados: Descrição dos testes para validação da proposta;
4. Conclusão: Considerações finais e trabalhos futuros.

# 1. Phishing

- Tentativa de obter credenciais através da suplantação de identidade por parte dos criminosos.

# Etapas de um ataque de phishing

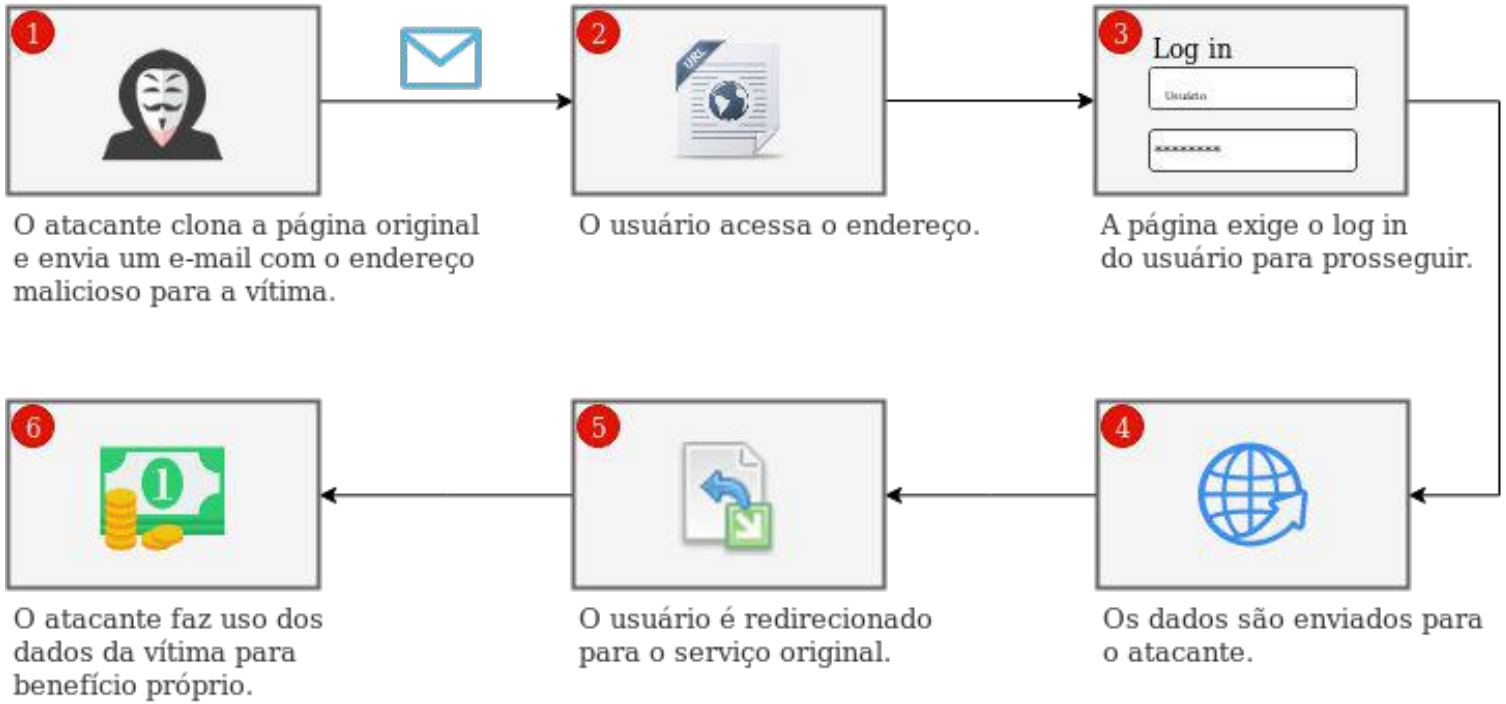

# Estatísticas

1. 23% dos internautas brasileiros sofreram ao menos uma tentativa de phishing em 2018;
2. 60% dos ataques simulam instituições financeiras;
3. 58% dos sites maliciosos já utilizam HTTPS;
4. 76% das organizações já presenciaram uma tentativa de phishing;
5. Tentativas de phishing aumentaram 40.9% em 2018.

Fontes: **Kaspersky Lab** e **Wombat Security**

# Características de um URL

# Características de um URL malicioso

- Na tentativa de enganar os usuários mais desatentos, o atacante adiciona elementos do URL original ao endereço malicioso.
- Há um padrão na maioria dos endereços maliciosos:
  - Grande quantidade de dígitos;
  - Muitos caracteres repetidos sequencialmente ou muito aleatórios;
  - Muitos subdomínios.
- Exemplos (fonte: PhishTank):
  - `http://appleid-appleupdatesec.com-appidkey4834668.com/manage/`
  - `http://mhammadrizwan1600.000webhostapp.com/paypal.php`
  - `https://paypal.co.uk.os3z.icu/n/`

# 2. PhishKiller

- O presente trabalho tem como objetivo prover uma solução para detecção e mitigação de ataques de phishing.

Para isso, o mecanismo deve:

  - Detectar os ataques no lado do cliente (*client-side*);
    - Alcançar um alto grau de generalização;
  - Impedir o acesso ao site malicioso por parte do usuário;
  - Não exigir esforço por parte do usuário para que o mesmo seja protegido.

# Trabalhos relacionados

| Proposta | #1 | #2 | #3 |
|---|---|---|---|
| [Sahingoz et al. 2019] | ✓ | | 97.98% |
| [Jain and Gupta 2018] | ✓ | | 99.09% |
| [Tyagi et al. 2018] | | | 98.40% |
| [Niakanlahiji et al. 2018] | ✓ | | 95.40% |
| [Desai et al. 2017] | | ✓ | 96.11% |
| [Marchal et al. 2014] | | | 94.91% |
| [Belabed et al. 2012] | | | 98.40% |
| **PhishKiller** | ✓ | ✓ | 98.30% |

Legenda:

**#1:** a solução não faz consultas a servidores WHOIS ou indexadores de sites;

**#2:** propõe alguma ferramenta para efetivamente mitigar o ataque;

**#3:** porcentagem de acertos do mecanismo avaliado.

# Trabalhos relacionados: Classificação

1. Sahingoz et al. (2019): Processamento de linguagem natural / *random forest*;
2. Jain and Gupta (2018): *Random Forest*;
3. Tyagi et al. (2018): *Random Forest e Principal Component Analysis*;
4. Niakanlahiji et al. (2018): *Random Forest*;
5. Desai et al. (2017): *Random Forest*;
6. Marchal et al. (2014): Regressão linear;
7. Belabed et al. (2012): *Support Vector Machine*;
8. **PhishKiller (2019):** *Long short-term memory* (LSTM).

# Arquitetura do PhishKiller

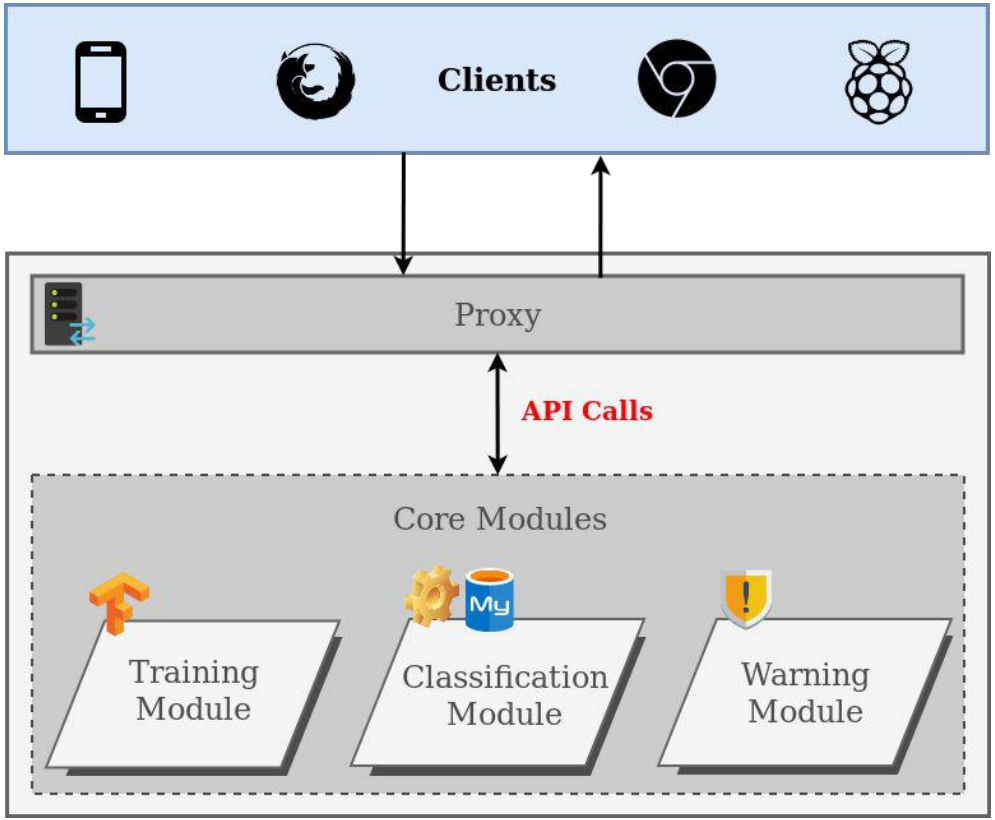

# Proxy

- Configurado no navegador do cliente.
- É responsável por interceptar as requisições para envio do URL ao classificador.
- Suporte ao HTTPS (com auxílio do *framework* Tornado).

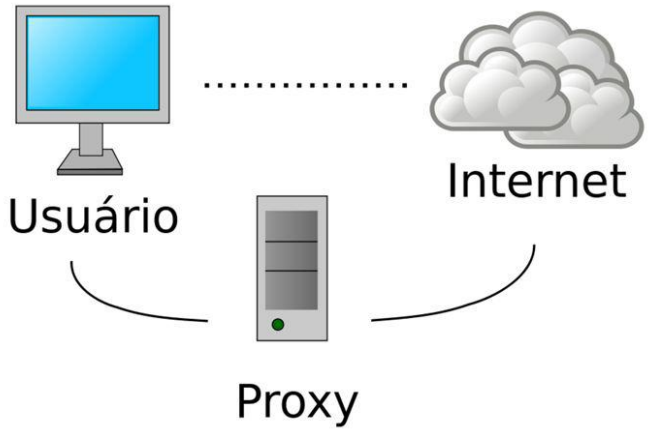

# Training Module

- Responsável por realizar o treinamento da rede neural.
- Utiliza o TensorFlow e Keras como *back-end*.
- Pré-processamento com Word2Vec (CBOW).
- Técnicas empregadas: Modelo de convolução 1D e LSTM.
- O *dataset* utilizado tem 452.835 endereços, dos quais 108.013 são de phishing e 344.829 são autênticos.
- 80% do *dataset* foi utilizado para treinamento e 20% para testes.


# Classification Module

- É requisitado sempre que um URL é detectado pelo proxy.
- Consulta se o URL já existe no banco de dados.
- Em caso negativo, faz a predição do endereço (maligno ou benigno).
- Ao encontrar um endereço malicioso, salva o mesmo no banco de dados para evitar futuras classificações desnecessárias.

# Warning Module

- Responsável por exibir uma página com informações ao usuário.

# 3. Avaliação e resultados

- Ambiente para testes:
  - Dell Inspiron I14-5457-A30
  - 2.40 GHz Intel Corei7-6500U
  - 8GB RAM
  - Ubuntu 18.04.02 LTS
  - 30Mbps Internet link
  - curl v7.64.0

- Ambiente de treinamento:
  - VM com Intel Xeon E5-2620 2.40 GHz (8 núcleos)
  - 16 GB RAM
  - Ubuntu 18.04.02 LTS

# 3. Avaliação e resultados

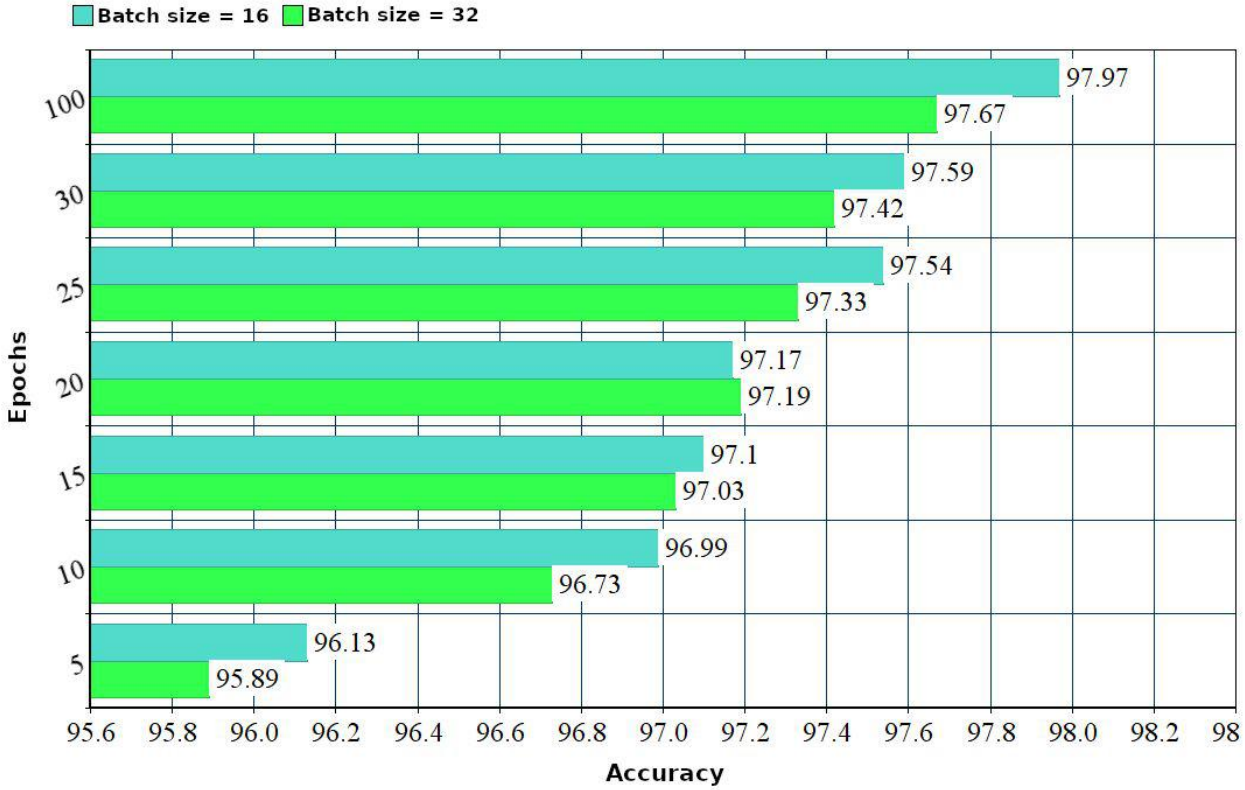

# 3. Avaliação e resultados

| Épocas | Tempo *batch size* = 16 | Tempo *batch size* = 32 |
|---|---|---|
| 5 | 38.96 | 23.58 |
| 10 | 69.13 | 46.70 |
| 15 | 103.53 | 69.51 |
| 20 | 139.96 | 95.12 |
| 25 | 175.83 | 116.86 |
| 30 | 205.54 | 142.44 |
| 100 | 884.32 | 440.57 |

# 3. Avaliação e resultados

- Acurácia nos 20% do *dataset*: **97.59%**.
  - 30 épocas e *batch size* de 16.
- Acurácia em testes automatizados com o *curl*: **98.3%**.
  - URLs: 1000 malignas e 1000 benignas.
- Tempo médio para classificar um endereço: **81.68ms**.

# Demonstração

# 4. Conclusão

- Neste trabalho foi proposto o PhishKiller, uma ferramenta para detecção e mitigação de ataques de phishing.
- O mecanismo faz uso de um proxy, que captura os sites acessados e envia seus endereços para classificação baseada em deep learning.
- A solução apresenta uma boa generalização, com acurácia de 98.3% e *delay* de 81.68ms.

# 4. Conclusão

- Alguns problemas:
  - As técnicas empregadas exigem uma grande base de dados;
  - A acurácia pode cair significativamente no caso de um *dataset* pouco criterioso;
  - Tempo de treinamento elevado.

- Trabalhos futuros:
  - Adaptação do sistema para o contexto de Software-defined networking (SDN).

# Agradecimentos


- Os autores agradecem ao CNPq e ao IFRN pelo fomento ao desenvolvimento do presente trabalho.

- Agradecemos também à Comissão Especial em Segurança da Informação e de Sistemas Computacionais (CESeg) pelo subsídio da incrição para participação no SBSeg 2019.