
AnonShield

Pseudonimização segura e escalável de dados de incidentes e vulnerabilidades em CSIRTs

host: 100.111.20.23 → [IP_ADDRESS_a4f2b1c3]

Cristhian Kapelinski

Orientador: Diego Kreutz

Ciência da Computação, UNIPAMPA, Campus Alegrete



Universidade Federal do Pampa

O que é um CSIRT?

A equipe que cuida da segurança digital. **Como os bombeiros, mas para ataques digitais.**

- **Recebe**
alertas de ataques e falhas
- **Investiga**
o que aconteceu e o impacto
- **Responde**
contém e corrige o problema




Vulnerabilidades de rede

- **Varreduras de vulnerabilidades**



- **De rede, não de código**
host, portas e serviços

- **Raio-X da rede**
revela portas e fraquezas



Registros de incidentes

- Tickets de incidente ataques já detectados

- Vêm dos CSIRTs


  

- Expõem a vítima e-mails, nomes, IPs



A escala do problema: vulnerabilidades

O número de vulnerabilidades cresce muito mais rápido que a capacidade de analisá-las.




**Crise de enriquecimento da
NVD/NIST (2026)**

A NIST só analisa os CVEs prioritários. O resto fica sem classificação, e sobra para o CSIRT local.

(NIST, 2026)

A escala do problema: incidentes

As notificações de incidentes saltaram de milhares para milhões em duas décadas.



Notificações de incidentes ao CERT.br, por ano (CERT.br/NIC.br)

A capacidade não acompanha

Déficit global de ~4,8 milhões de profissionais de segurança. Cada registro tratado por uma CSIRT carrega dados pessoais a proteger.

(ISC2 Workforce Study, 2024)


Automação com IA

LLMs que **priorizam,**
classificam e **sugerem**
respostas.



Sensibilidade dos dados

- **Identificadores de rede**
IP, hostname, certificado
- **Dados pessoais**
nomes e e-mails das vítimas
- **Perigoso se vazar**
expõe a rede e fere a LGPD



Como preparar esses dados para usar a IA com **segurança**, em **escala**, sem perder a **utilidade**?



A resposta deste trabalho: pseudonimização.

O que é uma entidade?

- **Um tipo reconhecido**
um dado pessoal ou um artefato técnico
- **Exemplos de entidade**
IP, hostname, nome, hash, certificado

host: "100.111.20.23" → "[IP_ADDRESS_a4f2b1c3]"

Exemplo: antes e depois (Tenable)

Original


```
{  
  "host-ip": "100.111.20.23",  
  "host-fqdn": "dns01.corp.br",  
  "mac-address": "00:1A:2B:3C:4D",  
  "severity": "High",  
  "cvss3_base_score": 7.4,  
  "port": 443  
}
```

Anonimizado

```
{  
  "host-ip": "[IP_ADDRESS_48624b5c]",  
  "host-fqdn": "[HOSTNAME_7e9d2a]",  
  "mac-address": "[MAC_ADDRESS_c8b1]",  
  "severity": "High",  
  "cvss3_base_score": 7.4,  
  "port": 443  
}
```

Vermelho: sensível · Teal: pseudonimizado · Preto: preservado · campos do Tenable (exemplos)


O pipeline de pseudonimização




Estágio 1: Entrada

O sistema lê vários formatos. Arquivos grandes são lidos em fluxo.

1 Input Data




Leitura em fluxo (streaming)



Estágio 2: Detecção (NER)


2 NER Detection




Failed login from **100.111.20.23** user=**cristhian.kapelinski**

o NER e o RegEx reconhecem o IP e o nome como entidades

Cache (vem antes)



GPU no modelo NER




Estágio 3: HMAC-SHA256

Cada entidade vira um pseudônimo gerado com uma chave secreta.

100.111.20.23 → [IP_ADDRESS_48624b5c]


3 HMAC-SHA256

o prefixo guarda o **tipo da entidade**; o resto é o **hash gerado com a chave secreta**.



Estágios 4 e 5: Persistência e Saída

4 Persistence



Persistência

banco SQLite (tabela **entities**): guarda o hash completo

Tipo	Original	Pseudônimo	Hash completo (64c)
IP_ADDRESS	100.111.20.23	[IP_ADDRESS_48624b5c]	48624b5c9a3f2e1d...
HOSTNAME	srv-web-01	[HOSTNAME_e5c53b15]	e5c53b15a1d2f3e4...

5 Output



Saída (ex.: XML)

estrutura mantida; sensíveis (teal) viram pseudônimo, o resto (preto) é preservado


```
<result>
  <host>[IP_ADDRESS_5b02f379]</host>
  <hostname>[HOSTNAME_e5c53b15]</hostname>
  <port>[PORT_2edd4ed6]</port>  <cvss>10.0</cvss>  <severity>Critical</severity>
</result>
```

A linha de pesquisa AnonLFI



Evolução da linha AnonLFI

Linhas de código e número de módulos por versão.



↗ Motivação: a escala operacional

- 70.951 vulnerabilidades do CAIS/RNP
- Antes: +92 horas inviável em escala
- Daí o AnonShield feito para escalar



Conjuntos de dados

Base	Origem	Formatos	Arquivos	Tamanho	Finalidade
D1	OpenVAS (laboratório VulnLab)	CSV, TXT, PDF, XML	130	9 a 34 MB	Acurácia e desempenho
D1C	Conversão do D1 (outros formatos)	XLSX, DOCX, PDF-img, JSON	130	até 1,5 GB	Acurácia e desempenho

Laboratório de serviços vulneráveis

VulnLab: 130 containers Docker vulneráveis, em 11 categorias de serviços.

Aplicações web vulneráveis • 21



OWASP



DVWA

Linguagens e runtimes • 12



Python



Node.js



PHP

Monitoramento e logging • 6



Grafana



Kibana




Prometheus

Rede e infraestrutura • 19



OpenSSH



OpenLDAP



Memcached

CMS e plataformas web • 11



WordPress



Drupal



GitLab

Mensageria e streaming • 5



RabbitMQ



Kafka



ActiveMQ

Bancos de dados • 17



MySQL



PostgreSQL



MongoDB

DevOps e CI/CD • 9



Jenkins



SonarQube



Sonatype
Nexus

CVEs específicos • 5



Log4Shell

Servidores web e de aplicação • 17



Apache



Nginx



Tomcat

Sistemas operacionais • 8



Ubuntu



Debian



CentOS

Varredura com OpenVAS



Cada container é varrido com OpenVAS/GVM (Greenbone); os relatórios formam o D1.



- **OpenVAS/GVM (Greenbone)**
motor de varredura de vulnerabilidades
- **Perfil Full and fast**
~30 a 60 min por host
- **Cobertura de portas**
todas as portas IANA atribuídas (TCP e UDP)
- **130 alvos**
cada container do VulnLab é varrido

~14 h de varredura total 520 relatórios (130 alvos × 4 formatos: PDF, XML, CSV, TXT)

🎯 Metodologia

- **Amostra: 67 de 6.472 (D1)**
90% confiança, 3 especialistas
- **13 tipos de entidades**
avaliados manualmente
- **Métricas**
Precisão, Recall (crítica), F1



Acurácia

Versão	Precisão	Recall	F1
AnonLFI 1.0	32,4%	18,8%	23,8%
AnonLFI 2.0	80,9%	40,7%	54,2%
AnonShield (standalone)	91,7%	96,1%	93,8%

Comparação na estratégia standalone (detecção própria do AnonShield: NER + RegEx). Modelo NER: SecureModernBERT.

Conjuntos de dados

Base	Origem	Formatos	Arquivos	Tamanho	Finalidade
D2	Tenable (CAIS/RNP, privado)	CSV, JSON	1	550 MB	Desempenho
D3	Sintético (gêmeo público do D2)	CSV, JSON	1	445 MB	Desempenho

Desempenho em escala operacional

738x

speedup sobre o AnonLFI 2.0

ANTES (AnonLFI 2.0, estimado)


~92 horas

DEPOIS (AnonShield)

7,5 minutos



Reconhecimento



Resultados da avaliação de artefatos (CTA)



Melhor Artefato do SBRC 2026

Selecionado entre os 65 artefatos avaliados no evento.



Selos de artefato concedidos



Utilidade analítica dos dados

Os dados pseudonimizados já sustentam pesquisa publicada:

Severo et al. (2025)

Classificação automatizada de incidentes em SOC's com LLMs e engenharia de prompt.

Melhor resultado: **92,27% de acurácia** (Gemini 2 + Progressive-Hint Prompting)



Almeida et al. (2025)

Modelos de linguagem on-premise vs. comerciais para classificar incidentes em CSIRTs.

On-premise **~60%** vs. **>90%** dos comerciais



Trabalhos futuros (TCC II)

Avaliação comparativa entre dados pseudonimizados e originais, medindo o equilíbrio entre **privacidade e utilidade na classificação de vulnerabilidades e incidentes com modelos de linguagem.**

Atividade	Ago	Set	Out	Nov	Dez
Preparação das bases e tarefas downstream					
Implementação do pipeline de utilidade					
Ajuste fino com preservação de privacidade					
Execução de experimentos e análise					
Redação e revisão do artigo final					

Artigos e materiais



SBSeg 2025



WRSeg 2025



SBRC 2026



anonshield.org

código e artefatos

Obrigado.

Apoio:  

Cristhian Kapelinski · Orientador: Diego Kreutz