

UNIVERSIDADE FEDERAL DO PAMPA

Programa de Pós-Graduação em Engenharia de Software (PPGES)

# MulitaMiner

**Extração estruturada de relatórios de scanners de vulnerabilidades com modelos de linguagem**

---

Dissertação de Mestrado em Engenharia de Software

**Douglas Lautert**

Orientador: Prof. Dr. Diego Kreutz


Alegrete, 2026

# Roteiro

---

- 1 Problema e objetivos**
- 2 Fundamentação**
- 3 Pesquisa 1: viabilidade**
- 4 Pesquisa 2: evidência**
- 5 Pesquisa 3: ferramenta**
- 6 Síntese e conclusões**

# A pesquisa em três etapas



**Cada etapa responde a uma limitação concreta da etapa anterior.**

## PARTE 1

# Problema e objetivos

---

O gargalo do ciclo de gestão de vulnerabilidades

# O ciclo de gestão de vulnerabilidades

---

- Equipes de resposta a incidentes varrem os ativos
- Scanners: OpenVAS (aberto) e Tenable WAS (comercial)
- Cada varredura gera um relatório em PDF
- Os PDFs são arquivados como registro histórico

**O acervo deveria ser a memória operacional da instituição.**

# O acervo em PDF não é consultável

---

- PDF é feito para leitura humana, não para consulta
- “Quais máquinas ainda expõem esta CVE?” vira trabalho manual
- Sem consulta, não há triagem nem priorização
- O histórico existe, mas não é usado

**Memória viva vira arquivo morto.**

## Os scanners não falam a mesma língua

| Aspecto       | OpenVAS                | Tenable WAS           |
|---------------|------------------------|-----------------------|
| Orientação    | Detalhe técnico        | Risco e priorização   |
| Seções        | Vulnerability Insight  | Risk Information      |
| CVE-2017-9798 | Severidade 5,0 (média) | Severidade 7,5 (alta) |

**Mesmos campos, nomes diferentes. Mesma falha, severidades diferentes.**

## A pressão sobre as equipes cresce

---

**48 mil**

registros CVE  
em 2025

**131**

novos registros  
por dia

**263%**

de crescimento  
desde 2020

**44%**

sem enriquecimento  
na NVD

**E o plano mais barato do Tenable custa cerca de R\$ 21 mil por ano.**



# Problema e hipótese

---

## PROBLEMA

**O histórico de varreduras é inútil na operação.**

PDFs heterogêneos, sem estrutura consultável. Conversão manual não escala.

## HIPÓTESE CENTRAL

**O gargalo está no pipeline, não no modelo.**

Investir na entrega do documento rende mais do que trocar de LLM.

# Questões de pesquisa

---

**QP1**

É viável extrair registros estruturados de PDFs com LLMs?

**QP2**

Quanto do ganho vem do pipeline e quanto vem do modelo?

**QP3**

O método se sustenta em uma ferramenta aberta, em escala e a baixo custo?

# Objetivo geral

---

**Tornar relatórios de scanners consultáveis,  
usando LLMs.**

---

E medir quanto disso depende do pipeline, e não do modelo.

**Produto da investigação: MulitaMiner, ferramenta de código aberto.**

# Objetivos específicos

---

- a** Unificar os campos de OpenVAS e Tenable WAS
- b** Demonstrar a viabilidade da extração com LLMs
- c** Medir omissão e alucinação, não apenas similaridade
- d** Isolar o efeito do pipeline frente ao do modelo
- e** Entregar ferramenta aberta e artefatos reprodutíveis

# Conceitos centrais

| Conceito               | Significado neste trabalho                               |
|------------------------|----------------------------------------------------------|
| Extração estruturada   | Texto livre vira registros com campos nomeados           |
| Esquema canônico       | 18 campos fixos, independentes do scanner                |
| Omissão                | Parte da referência que ficou de fora (métrica primária) |
| Alucinação             | Registro extraído que não existe na referência           |
| ERM                    | Exact Record Match: campos determinísticos todos exatos  |
| Engenharia de pipeline | Segmentação, tokens, prompt e reparo de saída            |

# O que a literatura cobre, e o que não cobre

## JÁ COBERTO

- Extração com LLMs em domínio científico e clínico
- Documentos visualmente ricos (DocLLM, MinerU)
- Entidades de inteligência de ameaças
- Unificação de fontes públicas já textuais

## EM ABERTO

- Relatórios de scanners em PDF
- Segmentação consciente da estrutura do documento
- Métricas de cobertura, não só de similaridade
- Ferramenta aberta com referências reproduzíveis

# Segmentação: onde o pipeline quebra

---

## HOJE: CHUNKING FIXO

- Corta a vulnerabilidade ao meio
- Perde a visão global do registro
- Trunca seções técnicas
- Cortes ruins disparam alucinação

## PROPOSTA: POR REGISTRO

- Um bloco por vulnerabilidade
- Orçamento de tokens por modelo
- Tokenizer nativo de cada modelo
- Reparo de JSON e redivisão adaptativa

## Por que similaridade não basta

---

- ROUGE-L e BERTScore medem o que foi extraído
- Nada dizem sobre o que ficou de fora
- Metade das vulnerabilidades pode render escore excelente
- E uma extração pela metade é operacionalmente inútil

**Omissão é a métrica primária: deixar passar custa mais do que registrar a mais.**



## Lacunas e respostas

| Lacuna                    | Resposta                         | Etapa |
|---------------------------|----------------------------------|-------|
| Scanners heterogêneos     | Esquema canônico de 18 campos    | 1 e 3 |
| Segmentação fixa          | Um bloco por vulnerabilidade     | 2 e 3 |
| Avaliação só lexical      | Bateria com omissão e alucinação | 2     |
| Ganho atribuído ao modelo | Três versões, mesmos modelos     | 2     |
| Sem ferramenta aberta     | MulitaMiner sob licença MIT      | 3     |


## PARTE 2

# As três pesquisas

---

Viabilidade, evidência e ferramenta: contribuições encadeadas

# Como o pipeline evoluiu em três versões



**Mesmos cinco modelos nas três versões. ERM: 37,5% → 90,4%**

# Viabilidade da extração com LLMs

---

- Mapeamento campo a campo entre os dois scanners
- Mapeamento embutido no prompt, com NULL para campos ausentes
- Pipeline modular: ler, dividir, extrair, validar, consolidar
- 1 relatório OpenVAS, 34 vulnerabilidades, referência manual
- 5 modelos comparados

# Quatro modos de falha

---

## 1 Limite de contexto

O registro inteiro não cabe

## 2 Truncção semântica

Cortes em NVT: e CVSS:

## 3 Perda de delimitador

Summary e Impact se fragmentam

## 4 Variação entre execuções

Tokenização e amostragem

**Todos ligados à forma como o documento chega ao modelo.**

# O que entregou e o que faltou

## ENTREGOU

- Viabilidade demonstrada
- Esquema unificado entre scanners
- Protocolo com referência curada

## FALTOU

- Só 1 relatório e 34 vulnerabilidades
- Segmentação ainda de tamanho fixo
- Só similaridade lexical: omissão invisível

**Essas lacunas definem a Pesquisa 2.**

## A pergunta central

**Quanto do ganho vem do modelo e quanto vem do pipeline?**

**V1**

Linha de base  
com chunking fixo

**V2**

Segmentação  
por regra estrita

**V3**

Ajuste por modelo  
e reparo de saída

**As três versões avaliadas sobre exatamente os mesmos cinco modelos.**

## Protocolo experimental

---

**3**

referências  
curadas

**208**

vulnerabilidades  
de referência

**5**

modelos de  
linguagem

**450**

execuções  
independentes

- Alvos em contêineres Docker, com perfis conhecidos
- Curadoria em duas etapas, com revisão campo a campo
- Dez repetições por combinação, com IC bootstrap de 95%



# Bateria de métricas

---

## Alinhamento

Omissão e alucinação por vulnerabilidade

## Qualidade por campo

ERM sobre os campos determinísticos

## Similaridade textual

BERTScore, ROUGE-L e Token-F1

## Severidade

F1 macro ponderado pela cobertura

## Resultado: o pipeline explica o ganho

---

Sem trocar os modelos, em 450 execuções:

**37,5% → 90,4%**

ERM  
(registros exatos)

**20,5% → 1,7%**

Omissão  
por vulnerabilidade

**25,1% → 8,3%**

Omissão  
por campo

**A omissão cai cerca de doze vezes. Nenhuma troca de modelo chega perto.**

# O caso GPT-5 e a convergência

## O CASO MAIS EXPRESSIVO

- GPT-5 na V1: omissão de 66% a 81%
- Parâmetros uniformes não davam conta
- Na V3, recuperado por completo

## CONVERGÊNCIA ASSIMÉTRICA

- Dispersão entre modelos: 41,8 p.p.  
→ 2,9 p.p.
- Quem mais sofria é quem mais melhora
- Efeito nivelador dos exemplos no prompt

**A similaridade da V1 é bimodal: sem medir cobertura, pareceria boa.**

## O que a Pesquisa 2 firma

---

- Nenhuma técnica isolada é inédita: o inédito é medir a integração
- A bateria de métricas torna a omissão visível
- Absorvida a variância entre modelos, decide-se por custo e latência
- Limite: apenas 3 referências curadas

**Esse limite define a Pesquisa 3.**

# MulitaMiner: a ferramenta

---

**12.500**

linhas de Python  
em 19 módulos

**18**

campos do  
esquema canônico

**6**


perfis de  
scanner

**4**

formatos de  
exportação

- Aplicação de linha de comando, licença MIT
- Configuração declarativa em JSON, sem tocar no código
- Novo modelo ou scanner: basta um arquivo novo

# Fluxo de processamento



**Falha na extração dispara redivisão adaptativa do bloco.**

## Avaliação em escala

---

**129**

relatórios  
OpenVAS

**6.343**

registros de  
referência

**40x**

maior que a  
Pesquisa 2

- Referência objetiva: exportação nativa em CSV do OpenVAS
- Sem curadoria humana, sem viés de denominador pequeno
- Varredura dinâmica de contêineres, em rede isolada

## Resultados em escala

---

**67,5% → 78,3%**

Correção agregada  
(V1 para V3)

**14,1% → 2,8%**

Omissão  
(V1 para V3)

**< 1 p.p.**

Diferença entre os  
cinco modelos na V3

- Na V3 os cinco modelos ficam entre 77,9% e 78,9%
- O erro residual está nos campos interpretativos



## Custo de execução

---

**119 mi**

tokens no  
lote da V3

**US\$ 73,82**

custo do lote  
completo

**US\$ 0,032**

por PDF no  
LLaMA 4

**US\$ 0,342**

por PDF no  
GPT-5

### CONFIGURAÇÃO RECOMENDADA

**DeepSeek: 78,3% de correção, 2,7% de omissão, US\$ 0,035 por PDF.**

## PARTE 3

# Síntese e conclusões

---

A tese defendida, os artefatos e o que permanece em aberto

## As três pesquisas em uma tabela

| Etapa      | Natureza    | Escala                             | Efeito                                |
|------------|-------------|------------------------------------|---------------------------------------|
| Pesquisa 1 | Viabilidade | 1 relatório<br>34 vulnerabilidades | Esquema unificado e modos de falha    |
| Pesquisa 2 | Evidência   | 450 execuções<br>5 modelos         | ERM de 37,5% para 90,4%               |
| Pesquisa 3 | Ferramenta  | 129 relatórios<br>6.343 achados    | Ferramenta aberta e padrão confirmado |

**Cada mudança de protocolo nasceu de uma limitação concreta da etapa anterior.**

## Artefatos e reprodutibilidade

---

- Código do MulitaMiner sob licença MIT
- As três versões do pipeline preservadas em repositórios distintos
- Perfis declarativos de seis scanners e dos modelos avaliados
- Referências curadas (208 vulnerabilidades) e em escala (6.343 achados)

<https://mulitaminer.github.io>

## Limitações e ameaças à validade

---

- Referência curada única, sem estatística entre anotadores
- Apenas três alvos curados, o que limita a generalização
- A referência em escala penaliza campos interpretativos
- Avaliação restrita a modelos acessados por API

## Recomendações práticas, em ordem

---

- 1 Investir na segmentação antes do modelo
- 2 Ajustar tokens e tokenizer por modelo
- 3 Ancorar o prompt em um esquema explícito
- 4 Medir cobertura, e não apenas similaridade
- 5 Só então escolher o modelo, por custo e latência

## A tese defendida

---

**Engenharia de pipeline vale mais do que trocar de modelo.**

- O gargalo nunca esteve na capacidade dos modelos
- ERM de 37,5% para 90,4%, omissão de 20,5% para 1,7%
- Confirmado em 129 relatórios por menos de US\$ 75
- O princípio não depende do domínio

# Trabalhos futuros e produção científica

## TRABALHOS FUTUROS

- Escalar para Tenable WAS, Nessus e Qualys
- Ampliar as referências curadas
- Executar com provedores locais
- Quarta versão, com reextração por campo

## PRODUÇÃO CIENTÍFICA

### **Pesquisa 1 | ERRC 2025**

*Structured Extraction of Vulnerabilities in OpenVAS and Tenable WAS Reports Using LLMs*

### **Pesquisa 2 | SBSeg 2026 (submetido)**

*A Multi-Version Evaluation of LLM-Based Vulnerability Report Extraction*

### **Pesquisa 3 | SBSeg 2026, código aberto**

*An LLM-Based Tool for Structuring Vulnerability Scanner Reports*



# Obrigado

---

**Engenharia de pipeline vale mais do que trocar de modelo.**

Douglas Lautert | Orientador: Prof. Dr. Diego Kreutz

PPGES, Universidade Federal do Pampa

<https://mulitaminer.github.io>