

# Detecção Inteligente de Malwares em Sistemas Windows

Jessica C. Patricio<sup>1</sup>, Carlos H. Paiva<sup>1</sup>, Renan L. Rodrigues<sup>1</sup>, Rafael L. Gomes<sup>1</sup>

<sup>1</sup>Universidade Estadual do Ceará (UECE), Fortaleza, Ceará, Brasil.

{jessica.cacau,henrique.paiva,renann.rodrigues}@aluno.uece.br

rafa.lopez@uece.br

## 1. Introdução

A ocorrência de malwares em sistemas operacionais Windows continua sendo uma das principais preocupações para as empresas e instituições, pois este é dominante em ambientes corporativos e domésticos. Os Malwares (tais como Spywares, Trojans e Ransomwares) responsáveis pelos ataques são frequentemente distribuídos online, direcionados a usuários, empresas e entidades governamentais [Costa et al. 2024].

Neste contexto, propõe-se uma solução baseada em Inteligência Artificial e análise de processos, que visa detectar malwares por meio da inspeção do conteúdo da memória principal de dispositivos com sistema operacional Windows. A arquitetura da solução foi concebida por ser portátil, escalável e com impacto mínimo nos dispositivos. O funcionamento baseia-se no monitoramento do dispositivo com a extração de dumps de memória RAM. O conteúdo extraído é compactado e enviado para um ambiente de análise remoto, onde são extraídas características dos processos. Esses dados são então submetidos a um modelo de IA previamente treinado, capaz de classificar como legítimo ou malicioso.

A Figura 1 apresenta uma visão geral da arquitetura proposta composta por dois componentes: o *device*, fazendo referência à sua execução no dispositivo a ser monitorado, responsável pela extração e envio de dados a partir do dispositivo monitorado, e o *service*, fazendo referência à sua função como serviço em borda dedicado à análise, responsável pelo armazenamento dos dados, análise remota e classificação.

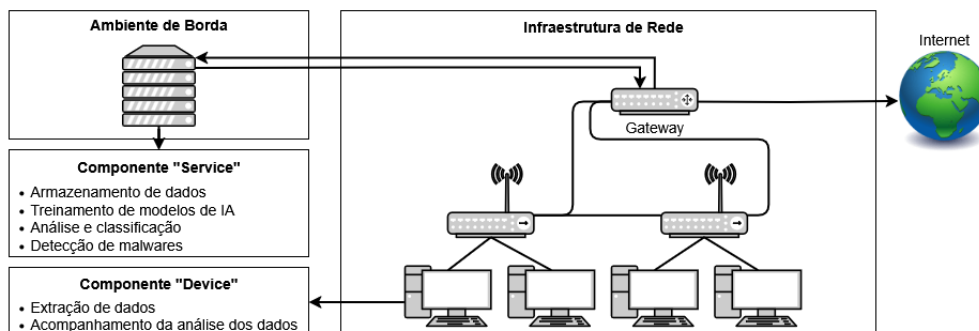


Figura 1. Visão Geral da Solução.

Durante sua operação, o dispositivo realiza a extração do dump de memória com o WinPmem<sup>1</sup>, uma ferramenta de aquisição de memória, gerando um arquivo RAW. Esse arquivo é então compactado com o uso da biblioteca zipfile<sup>2</sup>, visando à eficiência do envio, visto que o arquivo gerado pode ser muito grande e gerar uma sobrecarga na rede. Por sua vez, o *service* inicia-se com a descompressão do arquivo recebido, seguida da

<sup>1</sup><https://github.com/Velocidex/WinPmem/releases/tag/v4.0.rc1>

<sup>2</sup><https://docs.python.org/3.10/library/zipfile.html>

análise do conteúdo RAW com o VolMemLyzer<sup>3</sup>, que extrai características dos processos da memória. Essas características são a entrada de um modelo de IA previamente treinado (com os dados da base [Carrier et al. 2022]) para detecção de malwares, ou seja, classifica o processo como malicioso ou não.

## 2. Experimentos

O experimento de eficiência de extração e análise de dumps de memória RAM foi realizado em máquinas virtuais (VMs) executando o sistema operacional Windows 10 com 2GB, 4GB e 8GB de memória RAM. Os dumps gerados pelas ferramentas demandaram, em média, tempos de processamento em torno de 6ms, 23ms e 88ms para as VMs de 2GB, 4GB e 8GB, respectivamente, enquanto que a análise destes demandaram um tempo de 360ms, 679ms e 890ms para as VMs de 2GB, 4GB e 8GB, respectivamente. Adicionalmente, foi avaliada a capacidade de compressão da solução, onde a duração da compressão demandou cerca de 131 segundos e a taxa de compressão em torno de 70%, viabilizando a eficiência e escalabilidade do sistema (devido a economia de largura de banda), mesmo com múltiplos dispositivos monitorados simultaneamente.

Com relação à capacidade de detecção de malwares, foram analisadas as técnicas KNN, CART, MLP e RF, visto que estas possuem abordagens de aprendizado distintas. Os resultados são apresentados na Tabela 1. A partir desses resultados, é possível notar que as técnicas KNN, CART e RF possuem a melhor taxa de detecção, mas KNN e RF possuem um maior tempo de detecção. Desta forma, o modelo CART se apresentou como a técnica mais viável para integrar a solução, visto que possui a maior taxa de detecção juntamente com o menor tempo de detecção. Com base nos resultados, foi possível avaliar a viabilidade da solução de detecção de Malwares.

**Tabela 1. Desempenho de Detecção de Malwares e Processos Benígnos**

Caso	Recall	Acurácia	AUPRC	Tempo de Detecção
KNN	0.99	0.99	0.99	171.88
CART	0.99	0.99	0.99	15.66
MLP	0.95	0.95	0.97	31.25
RF	0.99	0.99	0.99	78.09

## Agradecimentos

Os autores agradecem ao CNPq (N<sup>o</sup> 303877/2021-9 e N<sup>o</sup> 405940/2022-0) e a CAPES (N<sup>o</sup> 88887.954253/2024-00) pelo apoio financeiro.

## Referências

Carrier, T., Victor, P., Tekeoglu, A., and Lashkari, A. H. (2022). Detecting obfuscated malware using memory feature engineering. In Mori, P., Lenzini, G., and Furnell, S., editors, *Proceedings of the 8th International Conference on Information Systems Security and Privacy, ICISSP 2022, Online Streaming, February 9-11, 2022*, pages 177–188. SCITEPRESS.

Costa, M. A., Costa, Y. M., Almeida, Y. O., Cardoso, F. J., and Gomes, R. L. (2024). Connection management using automated firewall based on threat intelligence. In *Proceedings of the 2024 Latin America Networking Conference, LANC '24*, page 32–37, New York, NY, USA. Association for Computing Machinery.

<sup>3</sup><https://github.com/ahlashkari/VolMemLyzer/releases/tag/V2.0.0>