

Ferramentas de extração de características para análise estática de aplicativos Android

**Jonas Pontes, Estevão Costa¹, Vanderson Rocha¹, Nicolas Neves¹,
Eduardo Feitosa¹, Joner Assolin², Diego Kreutz²**

¹ Universidade Federal do Amazonas (UFAM)

²Universidade Federal do Pampa (Unipampa)

{pontes, ecc, nicolas.neves, efeitosa}@icomp.ufam.edu.br,
vanderson@ufam.edu.br, {jonerassolin.aluno, kreutz}@unipampa.edu.br

Resumo. Neste estudo, investigamos algumas das ferramentas utilizadas para a extração de características estáticas de aplicações Android, que são frequentemente utilizadas por métodos de detecção de malwares. Demonstramos que as ferramentas podem diferir quanto ao quantitativo e a apresentação dos dados extraídos, o que acaba condicionando sua aplicabilidade às necessidades específicas de cada projeto.

1. Introdução

O Android ocupa a maior fatia no mercado de sistemas operacionais para dispositivos móveis, estando presente em aproximadamente 73% do total de *smartphones* no mundo, em agosto de 2021¹. Esse crescimento também o torna o alvo preferido dos criminosos cibernéticos, que produzem aplicações maliciosas (*malwares*) para atingir objetivos financeiros, sociais ou políticos [Pan et al., 2020, Bibi et al., 2020].

Para a detecção de *malwares*, as atividades iniciais são identificação e extração de características que possam levar a percepção se o aplicativo é ou não malicioso. Tipicamente, as técnicas utilizadas para extraer as características são as análises estática, dinâmica ou híbrida. Na análise estática, as características do *Android Package* (APK) são extraídas sem a necessidade de execução do aplicativo; na análise dinâmica, a extração de características é realizada a partir da execução da aplicação; e na híbrida, há a combinação dos dois tipos anteriores. A abordagem de análise estática é a mais utilizada para detecção de aplicativos maliciosos, pois consome menos tempo e recursos computacionais quando em comparação às outras técnicas [Wang et al., 2019].

A importância das características para o processo de detecção de *malwares* é facilmente compreendida quando se empregam soluções baseadas no aprendizado de máquina [Wang et al., 2019, Sharma and Rattan, 2021]. Isto porque, para o correto funcionamento, essas soluções (e seus modelos) dependem de conjuntos de dados (*datasets*) corretos e atualizados, requerendo assim a extração detalhada de características dos aplicativos [Dharmalingam and Palanisamy, 2021, Alazab et al., 2020, Zhang et al., 2020].

Neste trabalho objetivamos avaliar empiricamente ferramentas de extração de características estáticas de APKs, buscando identificar aquelas que melhor se ajustam à extração de características para a construção de *datasets* atualizados para detecção de

¹<https://gs.statcounter.com/os-market-share/mobile/worldwide>

malwares Android. Para a avaliação selecionamos 7 ferramentas e submetemos 6 delas a um processo de extração de características de aplicativos rotulados como benignos e maliciosos, de diferentes tamanhos e diferentes níveis de APIs Android. Como contribuições, podemos destacar: (a) identificação das ferramentas com o melhor desempenho para extração de características de APKs; e (b) análise e discussão de questões de usabilidade e exigências computacionais das ferramentas avaliadas.

O restante do trabalho está organizado da seguinte forma. Na Seção 2 apresentamos a metodologia para a seleção e avaliação de ferramentas. Nas Seções 3 e 4 discutimos os resultados e apresentamos as considerações finais, respectivamente.

2. Metodologia

O processo de seleção e avaliação das ferramentas foi composto pelas seguintes etapas: (i) busca por ferramentas de extração; (ii) escolha das ferramentas de interesse; (iii) definição dos aplicativos a serem testados; e (iv) avaliação qualitativa das ferramentas. Na primeira etapa, realizamos uma busca por ferramentas de extração de características estáticas de aplicativos Android, em que as revisões sistemáticas (e.g., [Faruki et al., 2014, Hijawi et al., 2021, Schmicker et al., 2018]) e documentos técnicos específicos da área^{2,3} foram o ponto de partida.

A partir da lista inicial de 33 ferramentas, na segunda etapa, avaliamos a admissibilidade de cada ferramenta. Como critério de inclusão, definimos a capacidade de extração a partir do APK e a geração de uma saída estruturada, da qual fosse possível identificarmos as características coletadas. Admitimos, igualmente, ferramentas de engenharia reversa, i.e., que tem como saída os arquivos originais que compõem o APK, incluindo o de manifesto (*AndroidManifest.xml*), a partir do qual podemos facilmente extrair características. Como principais critérios de exclusão, definimos: (i) a capacidade de extrair características dos APKs e (ii) estar disponível para qualquer pessoa utilizar sem restrições ou custos financeiros. Assim, ferramentas que fazem tipicamente parte do processo de detecção de *malwares* (e.g., conversores de arquivos *.class* para Java, visualizadores de arquivos binários, ferramentas de teste de penetração), mas não apresentam uma saída com as características do APK, foram eliminadas.

A partir da leitura das documentações ou artigos, realizada por no mínimo dois coautores, excluímos 26 ferramentas da lista inicial. As 7 ferramentas selecionadas (Androguard⁴, PSCout⁵, Android Decompiler⁶, AndroParse⁷, PHP APK Parser⁸, Mobile Audit⁹ e Apktool¹⁰) estão resumidas na Tabela 1.

As dependências para instalação (e.g., comandos, bibliotecas, linguagens) de cada uma das ferramentas estão listadas na Tabela 2.

²<https://github.com/ashishhb/android-security-awesome>

³<https://malwareanalysis.co/resources/tools/android>

⁴<https://github.com/androguard/androguard>

⁵<https://github.com/dlgroupuft/PScout>

⁶<https://github.com/dirkvranckaert/AndroidDecompiler>

⁷<https://github.com/rschmicker/AndroParse>

⁸https://github.com/iwinmin/php_apk_parser

⁹<https://github.com/mpast/mobileAudit>

¹⁰<https://ibotpeaches.github.io/Apktool>

Tabela 1. Ferramentas para descompactação de arquivos selecionadas

Ferramenta	Entradas	Saídas
Androguard	Arquivos .dex, .odex, .apk	Permissões, componentes do APP, <i>AndroidManifest.xml</i> , arquivos .dex, gráfico de fluxo de controle, <i>intents</i> , código de operação, classes
	<i>AndroidManifest.xml</i>	Permissões
Android Decompiler	Arquivo .apk	Arquivos do APK, incluindo <i>AndroidManifest.xml</i> , código-fonte, arquivos de recursos
	Arquivo .apk	APIs, <i>intents</i> e permissões
PHP APK Parser	Arquivo .apk	<i>AndroidManifest.xml</i> , permissões, componentes do APP, <i>intents</i> , classes.
	Arquivo .apk	Permissões, componentes do APP e outras <i>strings</i>
Mobile Audit	Arquivo .apk	Arquivos do APK, incluindo <i>AndroidManifest.xml</i> , recursos e <i>classes.dex</i>
Apktool	Arquivo .apk	Arquivos do APK, incluindo <i>AndroidManifest.xml</i> , recursos e <i>classes.dex</i>

Tabela 2. Dependências das ferramentas

Ferramenta	Dependências
Androguard	Python 3, pip, dependências do pacote “androguard”: asn1crypto, click, colorama, future, ipython, lxml, matplotlib, networkx, pydot e pygments
Android Decompiler	Java
AndroParse	Go, Glide, Android Asset Packaging Tool (AAPT), Java e make
Apktool	Java
Mobile Audit	Docker e Docker compose
PHP APK Parser	PHP, composer, php7.2-zip, php-mbstring e php-simplexml
PScout	Perl, Java e XML::Simple

É importante relatar que a ferramenta AndroParse não foi avaliada como as demais em razão da falta de informações necessárias para instalação e execução. Não existe especificação das versões de suas dependências, bem como os comandos de configuração da ferramenta (*make*) e de teste da instalação (*make unittest*) apresentam erros em diversos ambientes. Testes de instalação da AndroParse, sem sucesso, foram realizados nos sistemas operacionais Windows 10 e Linux (Ubuntu 20.04 LTS, Kernel 5.11.0-27-generic, 64 bits e também nas versões Ubuntu 18.04 LTS e 16.04 LTS), por 5 co-autores (avaliadores). A descrição completa dos ambientes de teste do AndroParse e das demais ferramentas estão disponíveis no endereço de documentação dos sistemas operacionais¹¹.

Para avaliar o processo de extração e sua qualidade, definimos um conjunto de aplicativos benignos e malignos (terceira etapa), em igual proporção, e com diferentes níveis de APIs Android, principalmente as mais recentes. Neste trabalho, utilizamos 10 aplicativos, sendo cinco benignos (B) e igual quantidade de *malwares* (M), contemplando os níveis de API Android 28, 29 e 30. Utilizamos o Google Play Store e o repositório¹² desenvolvido por [Wang et al., 2021] como fonte dos APKs benignos e maliciosos, nesta ordem. A seleção ocorreu de forma aleatória, dentro do critério de APIs de níveis 28-30, isto é, APIs mais recentes do Android. A Tabela 3 lista os aplicativos selecionados, incluindo informações sobre o tamanho, versões da API e resumo criptográfico.

Por fim, para avaliar qualitativamente as ferramentas (quarta etapa), consideramos os seguintes procedimentos: (i) definir as características de interesse; (ii) submeter diferentes aplicativos, maliciosos e benignos a cada ferramenta; (iii) e comparar as saídas produzidas. A avaliação de uma ferramenta de extração de características de aplicativos

¹¹<https://github.com/Malware-Hunter/ExternalTools/blob/main/wrseg21>

¹²<https://zenodo.org/record/4660140#.YUEZURmSmUl>

Tabela 3. Aplicativos considerados nesta pesquisa

Nome	Resumo Criptográfico (SHA256)	Nº Bytes	API
Cartola FC (B)	aeda946f4099638ab800d19c13d94b66d1615d3a72d3388415476ae9eb2519e2	34.424.777	29
Instagram (B)	c3bf7adf8403cee6ba7bdfa5a3fbf105a9071c21fa19d3c8d480cdf6f609d2a2	40.166.591	30
IPTV (B)	28da45ae147f377719f3d3178aa14c22df4fc761b13193367c6f5ba82fe7899d	22.460.779	28
Spotify (B)	e4986faf1c91f10574c252212bec22c8a51446ba30e2ec3b1705c0d25b635cd9	30.940.271	29
WhatsApp (B)	454d0a18ff06084a952a709247360558717b7e6537d3b2637b0007691cee456f	33.727.503	29
Tracking COVID-19 (M)	0aa1f7e03588373e3520256d43df0f3ce32f5c0eed5c90910a2f5bab8911fff	3.172.731	29
Covid19 Symptom Tracker (M)	0b2131a3d58e6980496ea8b26ee18c72fa08389750d7812180ce459946099841	1.849.005	28
COVID-RD (M)	0ba773c0bffa04c9f6a6216667873cce339bda28646d267f651b6bce4cc36d0	52.267.255	28
COVID-19 (M)	0d2b8232bf5e40deea3acf91c398e4a34085a06f3ef9fa109eefdc954661c5df	7.821.886	28
Corona Help (M)	1b3207137156f94076d85c67638e561b366a1bbf5225c50e525c3ed5df0cd317	25.148.214	29

Android pode considerar quais características ela é capaz de obter, bem como a quantidade coletada. Neste trabalho avaliamos as ferramentas considerando as características permissões, *intents*, API, componentes do APP e *opcode*, as quais são as mais utilizadas, como características estáticas, pelos trabalhos levantados por [Wang et al., 2019].

3. Resultados e discussões

3.1. Análise das ferramentas de extração

Para mensurar a capacidade em extraír características estáticas dos APK, consideramos, inicialmente, a soma de cada característica extraída nos cinco APKs maliciosos (M.) e nos cinco benignos (B.). Nesta análise, apenas as 4 ferramentas de extração de características foram consideradas. A Tabela 4 apresenta o resultado da extração de características, considerando as características permissões, API, *intents*, componentes do APP e *opcode*¹³.

Tabela 4. Resultado da extração de características estáticas

Ferramenta	Permissões		Intents		API		Componentes do APP		Opcode	
	B.	M.	B.	M.	B.	M.	B.	M.	B.	M.
Androguard	144	43	292	53	3470999	658404	934	91	13376816	2614284
PHP APK Parser	140	39	74	13	0	0	565**	46**	0	0
Mobile Audit	144	33	*	*	0	0	846*	91*	0	0
PScout	9	0	0	0	0	0	0	0	0	0

Como podemos observar, Androguard é a ferramenta que obteve o melhor desempenho em relação a extração das características. É importante destacarmos que a documentação da ferramenta informa que há suporte apenas até a API 29 do Android (APIs superiores são tratadas como 29). Para todas as características analisadas, a ferramenta apresenta valores iguais ou superiores às demais.

Mobile Audit foi a ferramenta que obteve resultados mais próximos do Androguard quanto à extração de permissões. Entretanto, não apresentou resultados para API e *opcode*. Ademais, vale destacar que o conjunto de características que formam os componentes do aplicativo no Mobile Audit difere daquele apresentado por [Wang et al., 2019]

¹³Um *OpCode* (Código de Operação) é uma instrução única (atômica) que pode ser executada pela CPU. No caso do Android, *opcodes* são as instruções da máquina virtual Dalvik para execução do aplicativo.

– que é o mesmo apresentado na análise componentes de aplicativo extraídos via Androguard, ou seja, além de *activity*, *service*, *broadcast receiver* e *content provider*, a ferramenta considera *intents* como parte de componentes do aplicativo, não sendo possível isolar as *intents* dentro do conjunto apresentado (destacado por * na Tabela 4).

A ferramenta PHP APK Parser foi capaz de extrair permissões em quantidade próxima àquelas obtidas via Androguard e Mobile Audit. Por outro lado, extraiu bem menos *intents* que a Androguard. Quanto aos componentes do aplicativo, somente é capaz de extrair *activities* (denotado por ** na Tabela 4). As demais características de interesse deste trabalho não são extraíveis através desta ferramenta.

A PScout, apesar de obter características de aplicações Android, não o faz a partir de um APK, como as demais ferramentas citadas. Ele necessita do arquivo de manifesto do aplicativo e neste trabalho utilizamos o Apktool para obtê-lo do APK. Os resultados conseguidos a partir da ferramenta são modestos se comparados aos das demais ferramentas. Destacadamente, não há obtenção de nenhuma característica de aplicação maliciosa. Analisando o código-fonte da ferramenta, notamos que a ferramenta retorna apenas permissões cuja tag XML “permission” possui o atributo “protectionLevel” com o valor de “signature” ou “signatureOrSystem”, ou que esteja combinado com a expressão regular Perl “m/system/i”. Desse modo, o parser não retorna todas as permissões existentes em um arquivo *AndroidManifest.xml*, pois permissões podem ser declaradas em outras tags XML (e.g., “uses-permission” e “uses-permission-sdk-23”).

3.2. Análise das ferramentas de engenharia reversa

Com relação as ferramentas de engenharia reversa, Android Decompiler executou com falhas e não realizou a extração dos arquivos originais do APKs. A causa dessa falha é o fato dessa ferramenta se tratar de um *shell script* que utiliza outras ferramentas de engenharia reversa em versões antigas, que não são mais mantidas ou atualizadas nos sistemas operacionais atuais. O repositório da ferramenta no GitHub não é atualizado desde Outubro de 2014. Além disso, consta em seu repositório que a formatação de código do *shell script* não tem suporte para todas as plataformas, e que foi construído para MacOS, mas que a maior parte dele deve funcionar nos ambientes UNIX. Portanto, devido a este suporte limitado e aos erros obtidos durante os testes, notamos que a ferramenta Android Decompiler não é mais (atualmente) uma alternativa viável para realizar engenharia reversa de APKs.

A ferramenta Apktool, por outro lado, mostrou-se mais completa para engenharia reversa, e que ao ser combinada com um *parser*, possibilita a extração de diversas características. Portanto, supera o Android Decompiler em questão de utilização e viabilidade técnica. Podemos destacar também que a ferramenta tem um repositório vasto de versões, sendo a versão mais atual do ano de 2021. Os resultados sustentam o motivo pelo qual ela é frequentemente utilizada em trabalhos que necessitam de engenharia reversa.

4. Considerações Finais

Neste trabalho, apresentamos uma avaliação qualitativa de ferramentas de extração de características estáticas e engenharia reversa de aplicativos Android, considerando permissões, API, *intents*, componentes de aplicativo e *opcode* como características-alvo. Os resultados mostram que, dentre as ferramentas consideradas, Androguard apresenta os

melhores resultados quanto à extração de características, capturando dados para todas as características consideradas, mesmo que para isso demande um tempo maior para a análise do APK. Mobile Audit e e PHP APK Parser também apresentaram bons resultados para extração de permissões, mas os resultados deixam a desejar se considerarmos todas as características. Quanto às ferramentas de engenharia reversa, Apktool entregou aquilo que se espera: é uma ferramenta atualizada e que exporta os arquivos do APK. Portanto, resumidamente, nosso estudo indica que Apktool e Androguard são ferramentas recomendáveis para engenharia reversa e extração de características, respectivamente.

Como trabalhos futuros, podemos citar: (a) ampliar a pesquisa, considerando um conjunto maior de ferramentas e APKs; (b) comparar as ferramentas quantitativamente, considerando uso do processador, memória e tempo de execução; (c) construir um *dataset* para detecção de *malwares* Android utilizando as ferramentas destacadas.

Agradecimento

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001 e financiado, conforme previsto nos Arts. 21 e 22 do decreto nº 10.521/2020, nos termos da Lei Federal nº 8.387/1991, através de convênio nº003/2021, firmado entre ICOMP/UFAM, Flextronics da Amazônia Ltda e Motorola Mobility Comércio de Produtos Eletrônicos Ltda.

Referências

- Alazab, M., Alazab, M., Shalaginov, A., Mesleh, A., and Awajan, A. (2020). Intelligent mobile malware detection using permission requests and api calls. *Future Generation Computer Systems*, 107:509–521.
- Bibi, I., Akhunzada, A., Malik, J., Iqbal, J., Musaddiq, A., and Kim, S. (2020). A dynamic dl-driven architecture to combat sophisticated android malware. *IEEE Access*, 8:129600–129612.
- Dharmalingam, V. P. and Palanisamy, V. (2021). A novel permission ranking system for android malware detection—the permission grader. *Journal of Ambient Intelligence and Humanized Computing*, 12(5):5071–5081.
- Faruki, P., Bharmal, A., Laxmi, V., Ganmoor, V., Gaur, M. S., Conti, M., and Rajarajan, M. (2014). Android security: a survey of issues, malware penetration, and defenses. *IEEE communications surveys & tutorials*, 17(2):998–1022.
- Hijawi, W., Alqatawna, J., Al-Zoubi, A. M., Hassonah, M. A., and Faris, H. (2021). Android botnet detection using machine learning models based on a comprehensive static analysis approach. *Journal of Information Security and Applications*, 58:102735.
- Pan, Y., Ge, X., Fang, C., and Fan, Y. (2020). A systematic literature review of android malware detection using static analysis. *IEEE Access*, 8:116363–116379.
- Schmicker, R., Breitinger, F., and Baggili, I. (2018). Androparse—an android feature extraction framework and dataset. In *International Conference on Digital Forensics and Cyber Crime*, pages 66–88. Springer.
- Sharma, T. and Rattan, D. (2021). Malicious application detection in android — a systematic literature review. *Computer Science Review*, 40:100373.
- Wang, L., He, R., Wang, H., Xia, P., Li, Y., Wu, L., Zhou, Y., Luo, X., Sui, Y., Guo, Y., and Xu, G. (2021). Beyond the virus: A first look at coronavirus-themed mobile malware.
- Wang, W., Zhao, M., Gao, Z., Xu, G., Xian, H., Li, Y., and Zhang, X. (2019). Constructing features for detecting android malicious applications: Issues, taxonomy and directions. *IEEE Access*, 7:67602–67631.
- Zhang, X., Zhang, Y., Zhong, M., Ding, D., Cao, Y., Zhang, Y., Zhang, M., and Yang, M. (2020). Enhancing state-of-the-art classifiers with api semantics to detect evolved android malware. In *Proceedings of the 2020 ACM SIGSAC, CCS ’20*, page 757–770, New York, NY, USA. ACM.