




Universidade Federal do Pampa



UFAM



ADBuilder



Ferramenta de Construção de Datasets para Detecção de Malwares Android

Salão de Ferramentas do XXII Simpósio
Brasileiro de Segurança da Informação
e de Sistemas Computacionais

SBSeg 2022

**Lucas Vilanova, Diego Kreutz, Joner Assolin,
Vagner Quincozes, Charles Miers, Rodrigo
Mansilha, Eduardo Feitosa**

Desafios dos datasets



Dados duplicados



Dados defasados



Valores inválidos



Identificação das características



Quantidade e qualidade



Defasagem na rotulagem



Defasagem na rotulagem



Smart Gallery 1.1

- 2019 >> 0 (benigno)
- 23/03/2022 >> 20 (malware)

Smart Cleaner

- 2020 >> 0 (benigno)
- 23/03/2022 >> 19 (malware)

Uma solução para o problema

Entrada



Lista de APKs

ADBuilder



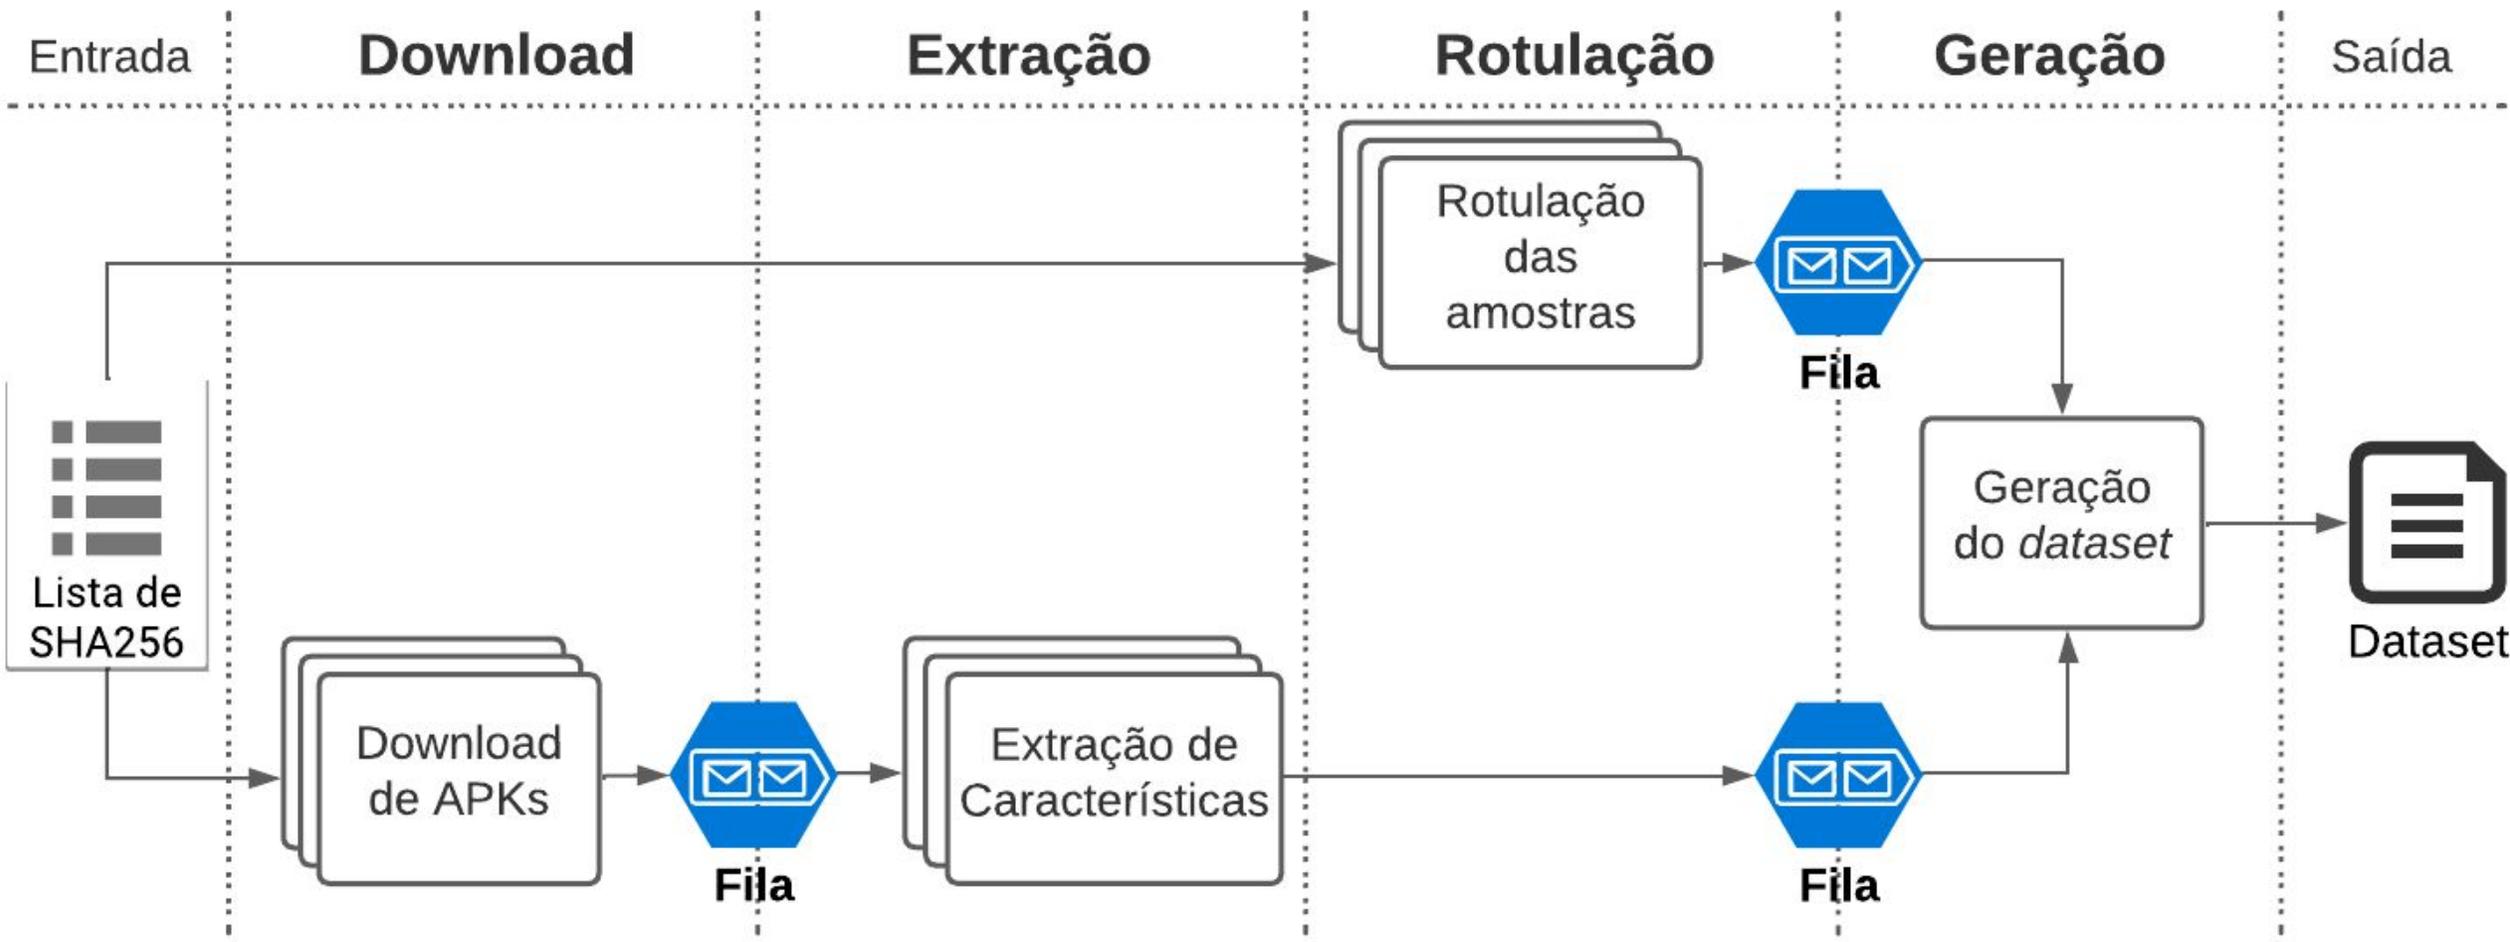
Saída



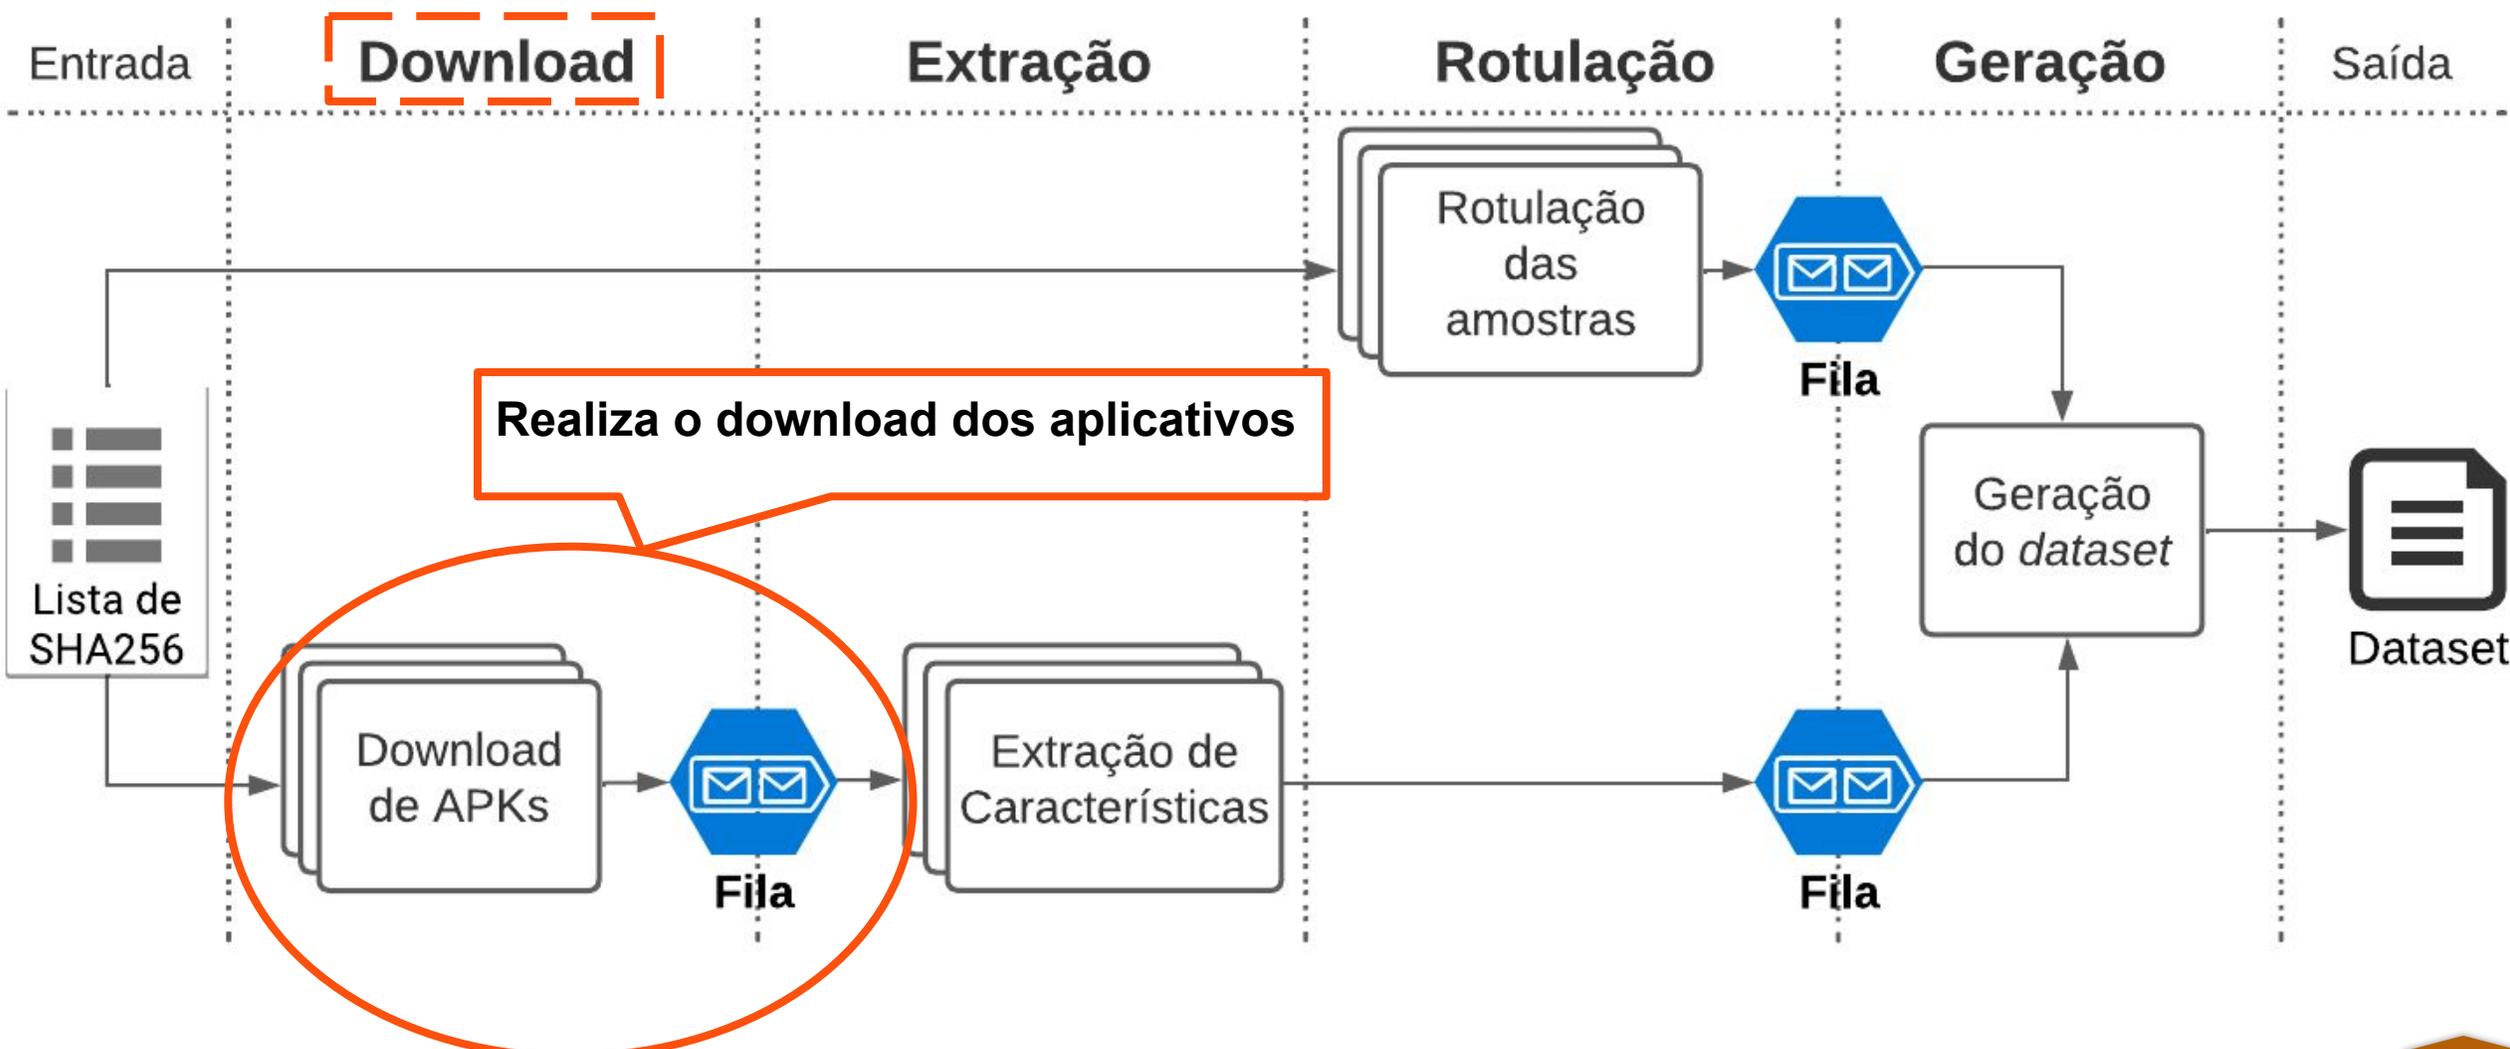
Dataset Android

- Limpo e tratado;
- Rotulação atualizada;

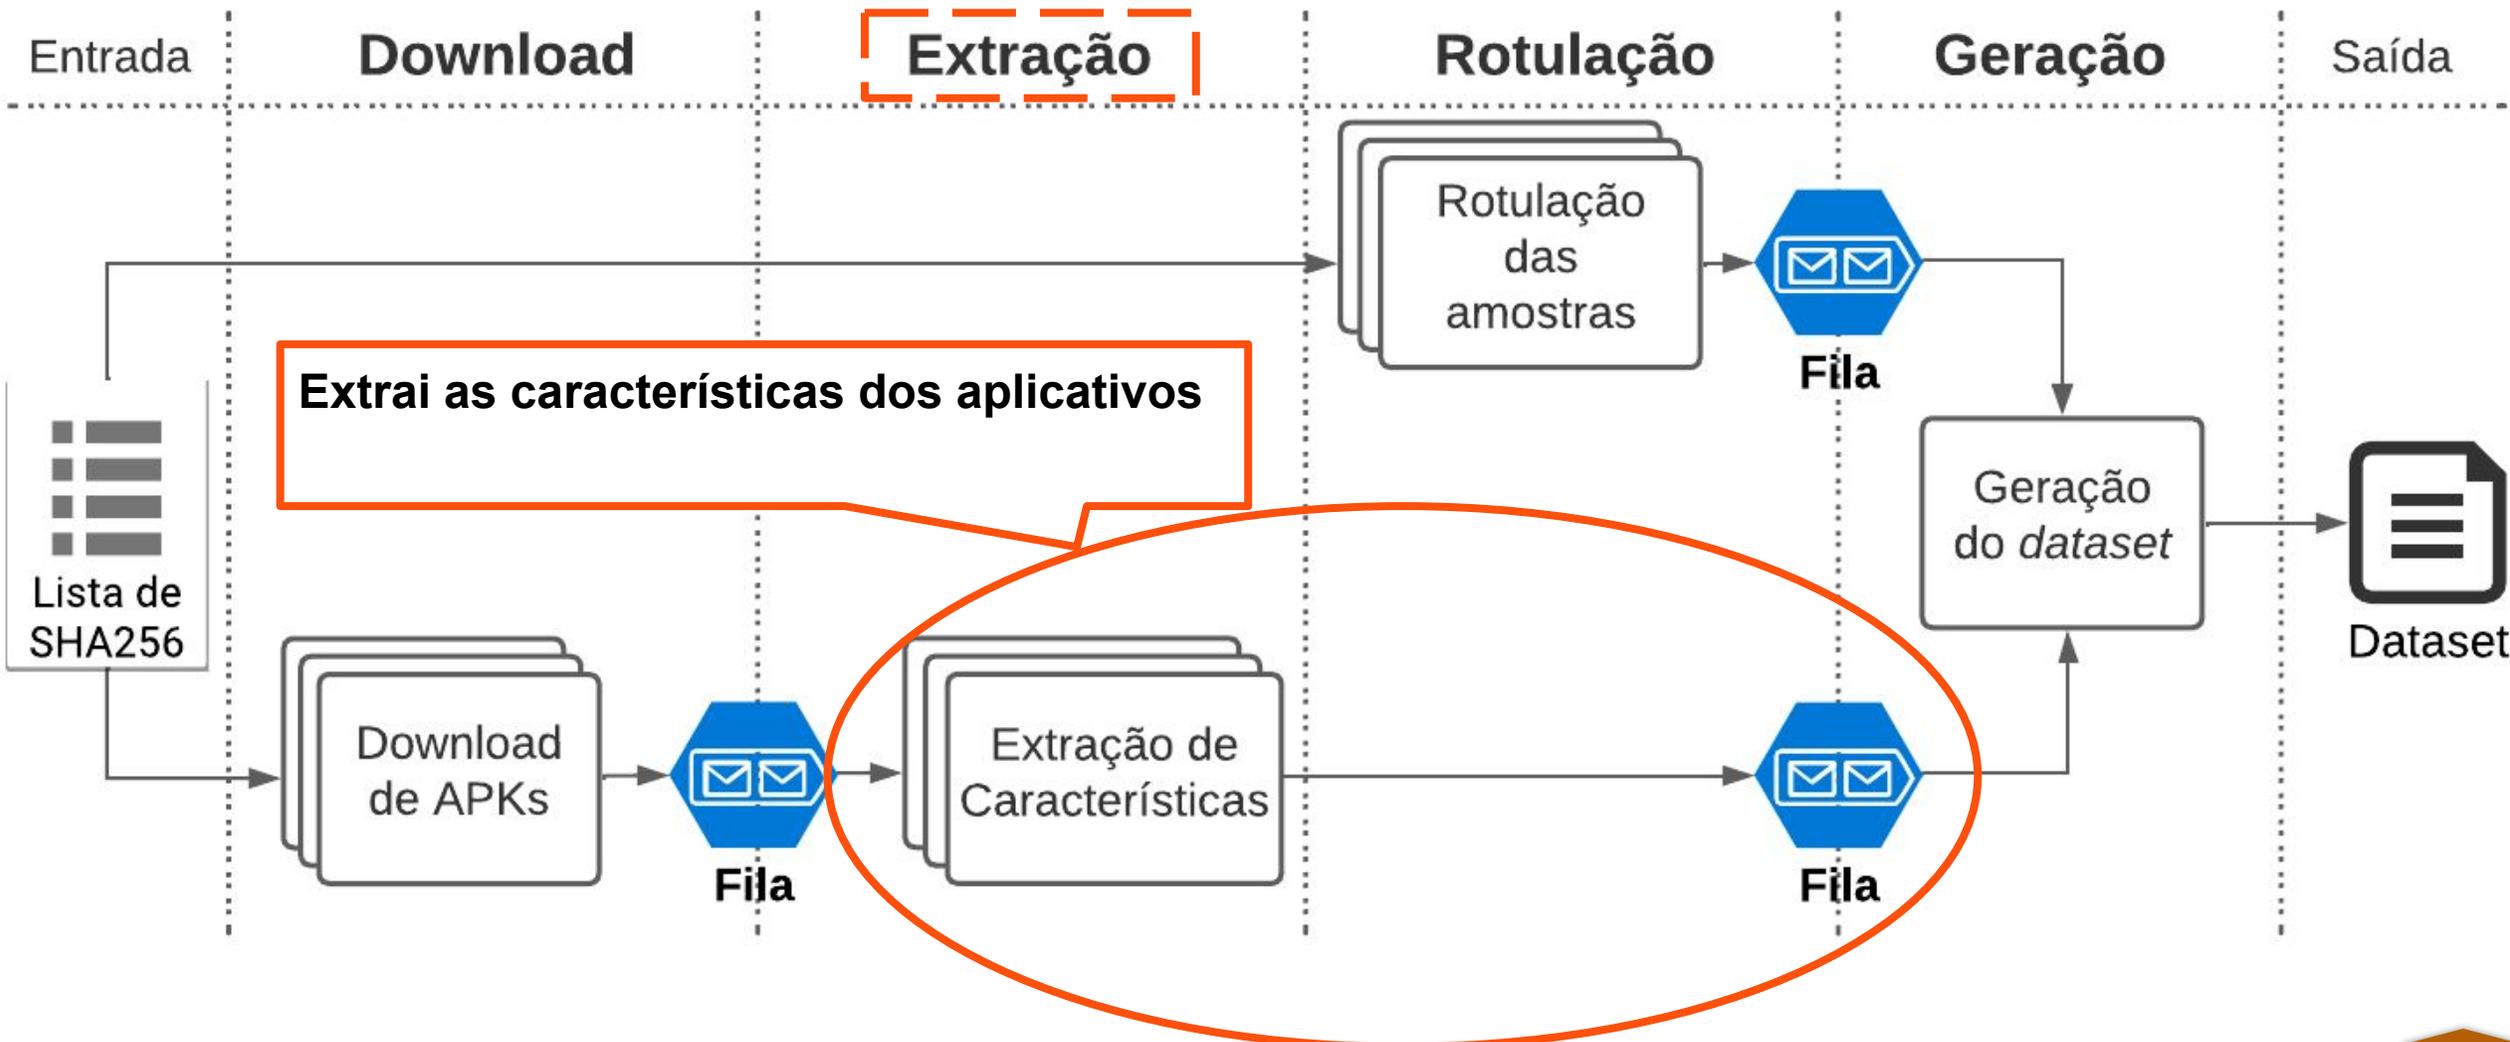
Arquitetura da Ferramenta



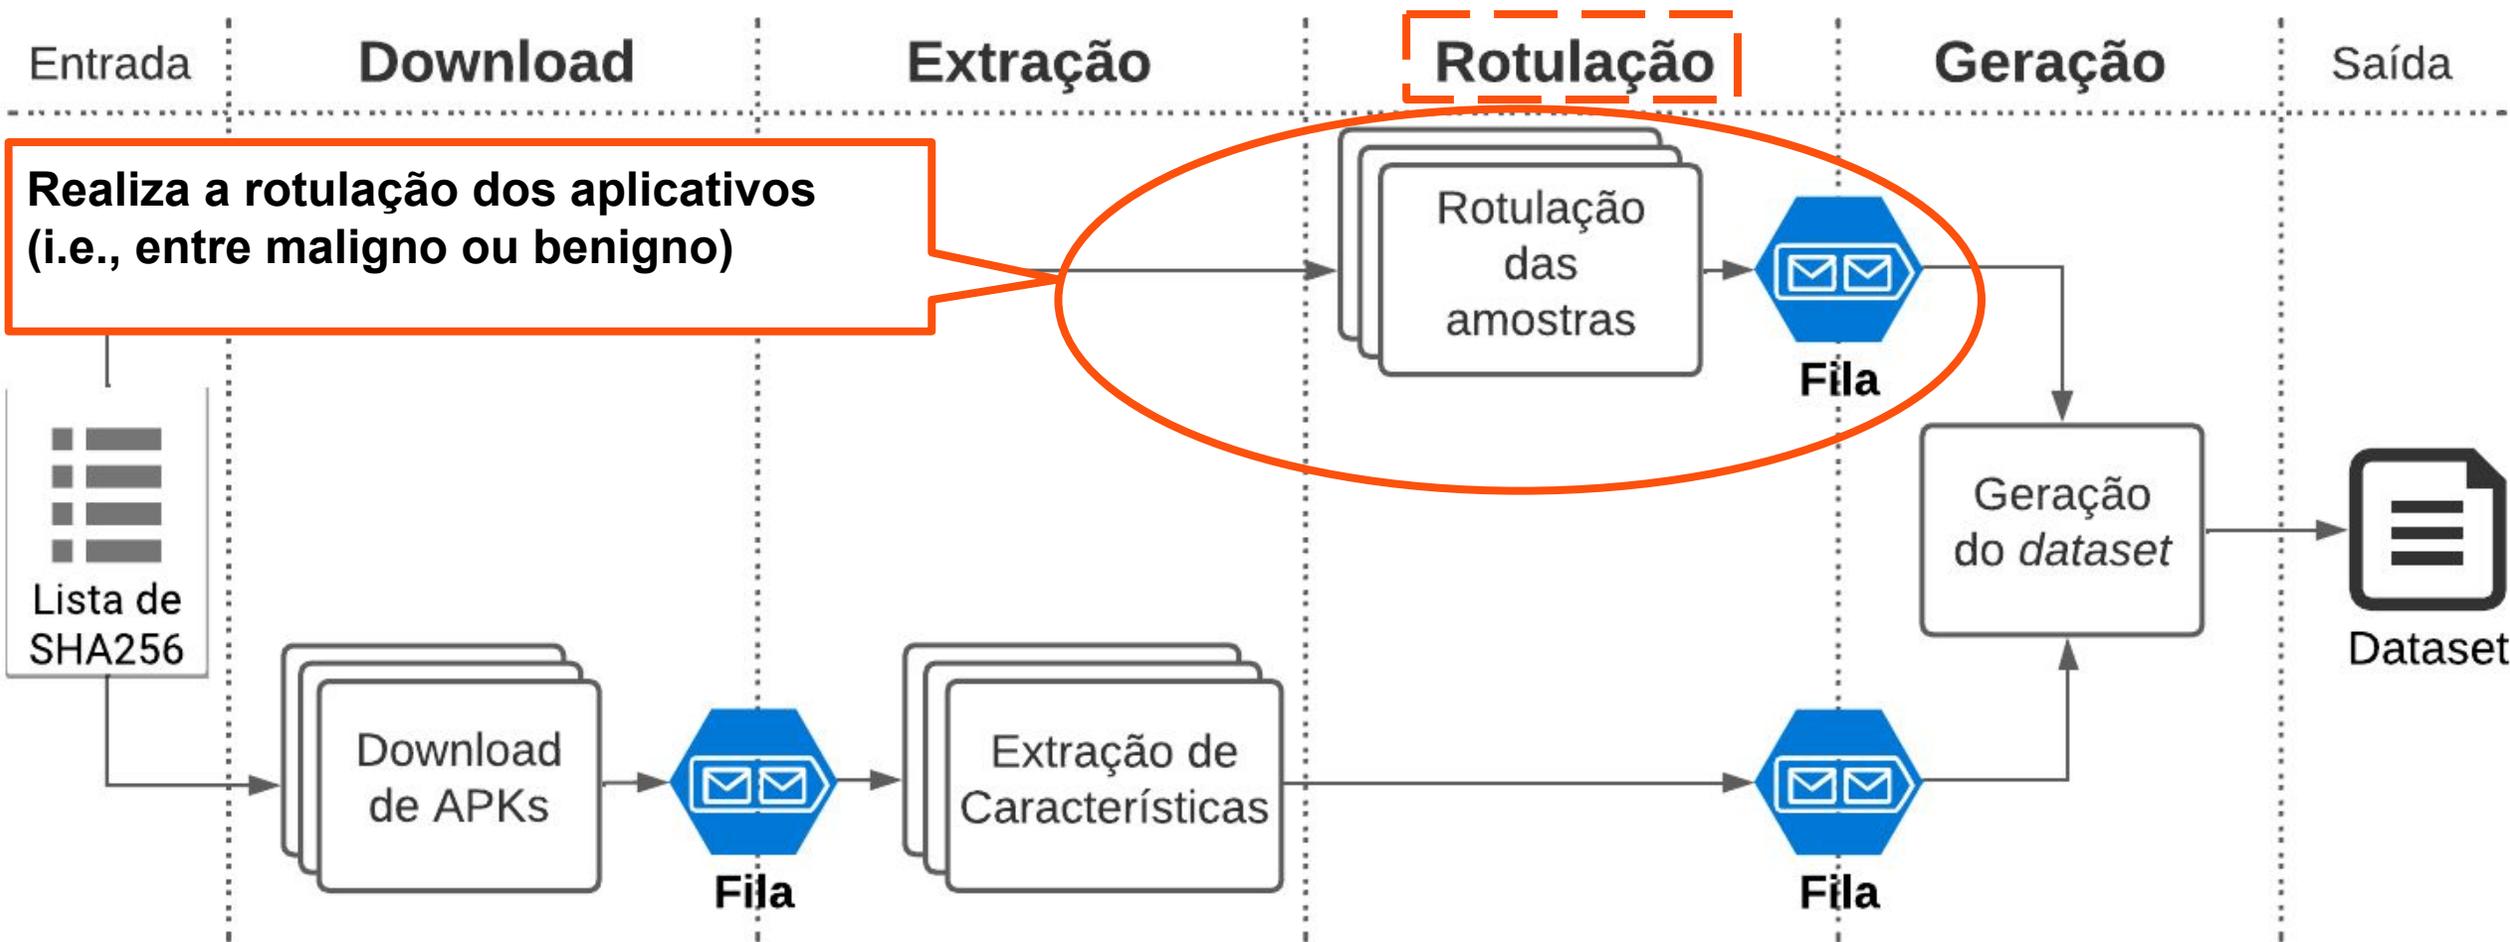
Arquitetura da Ferramenta



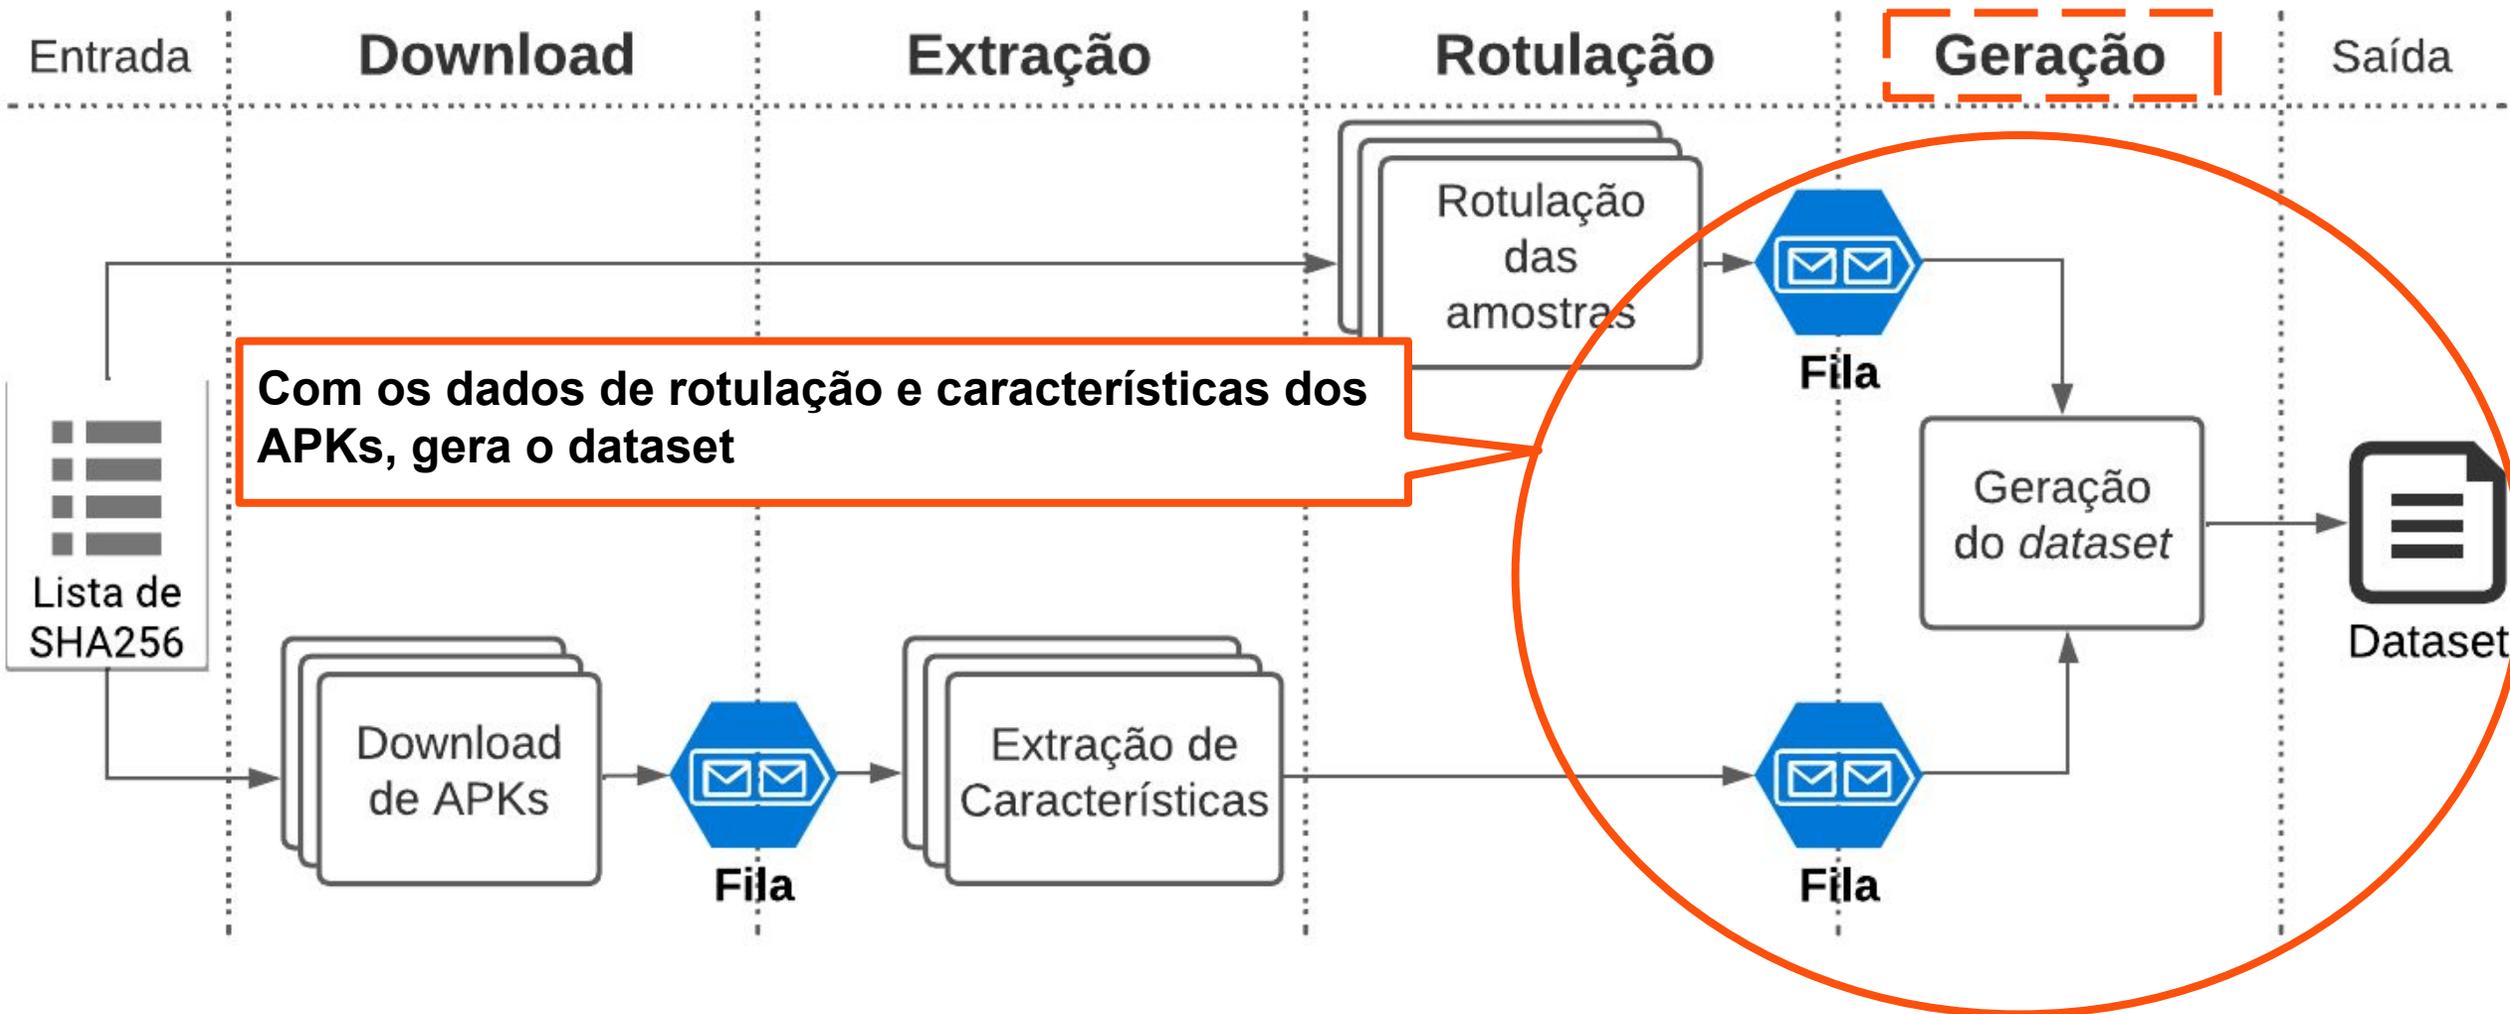
Arquitetura da Ferramenta



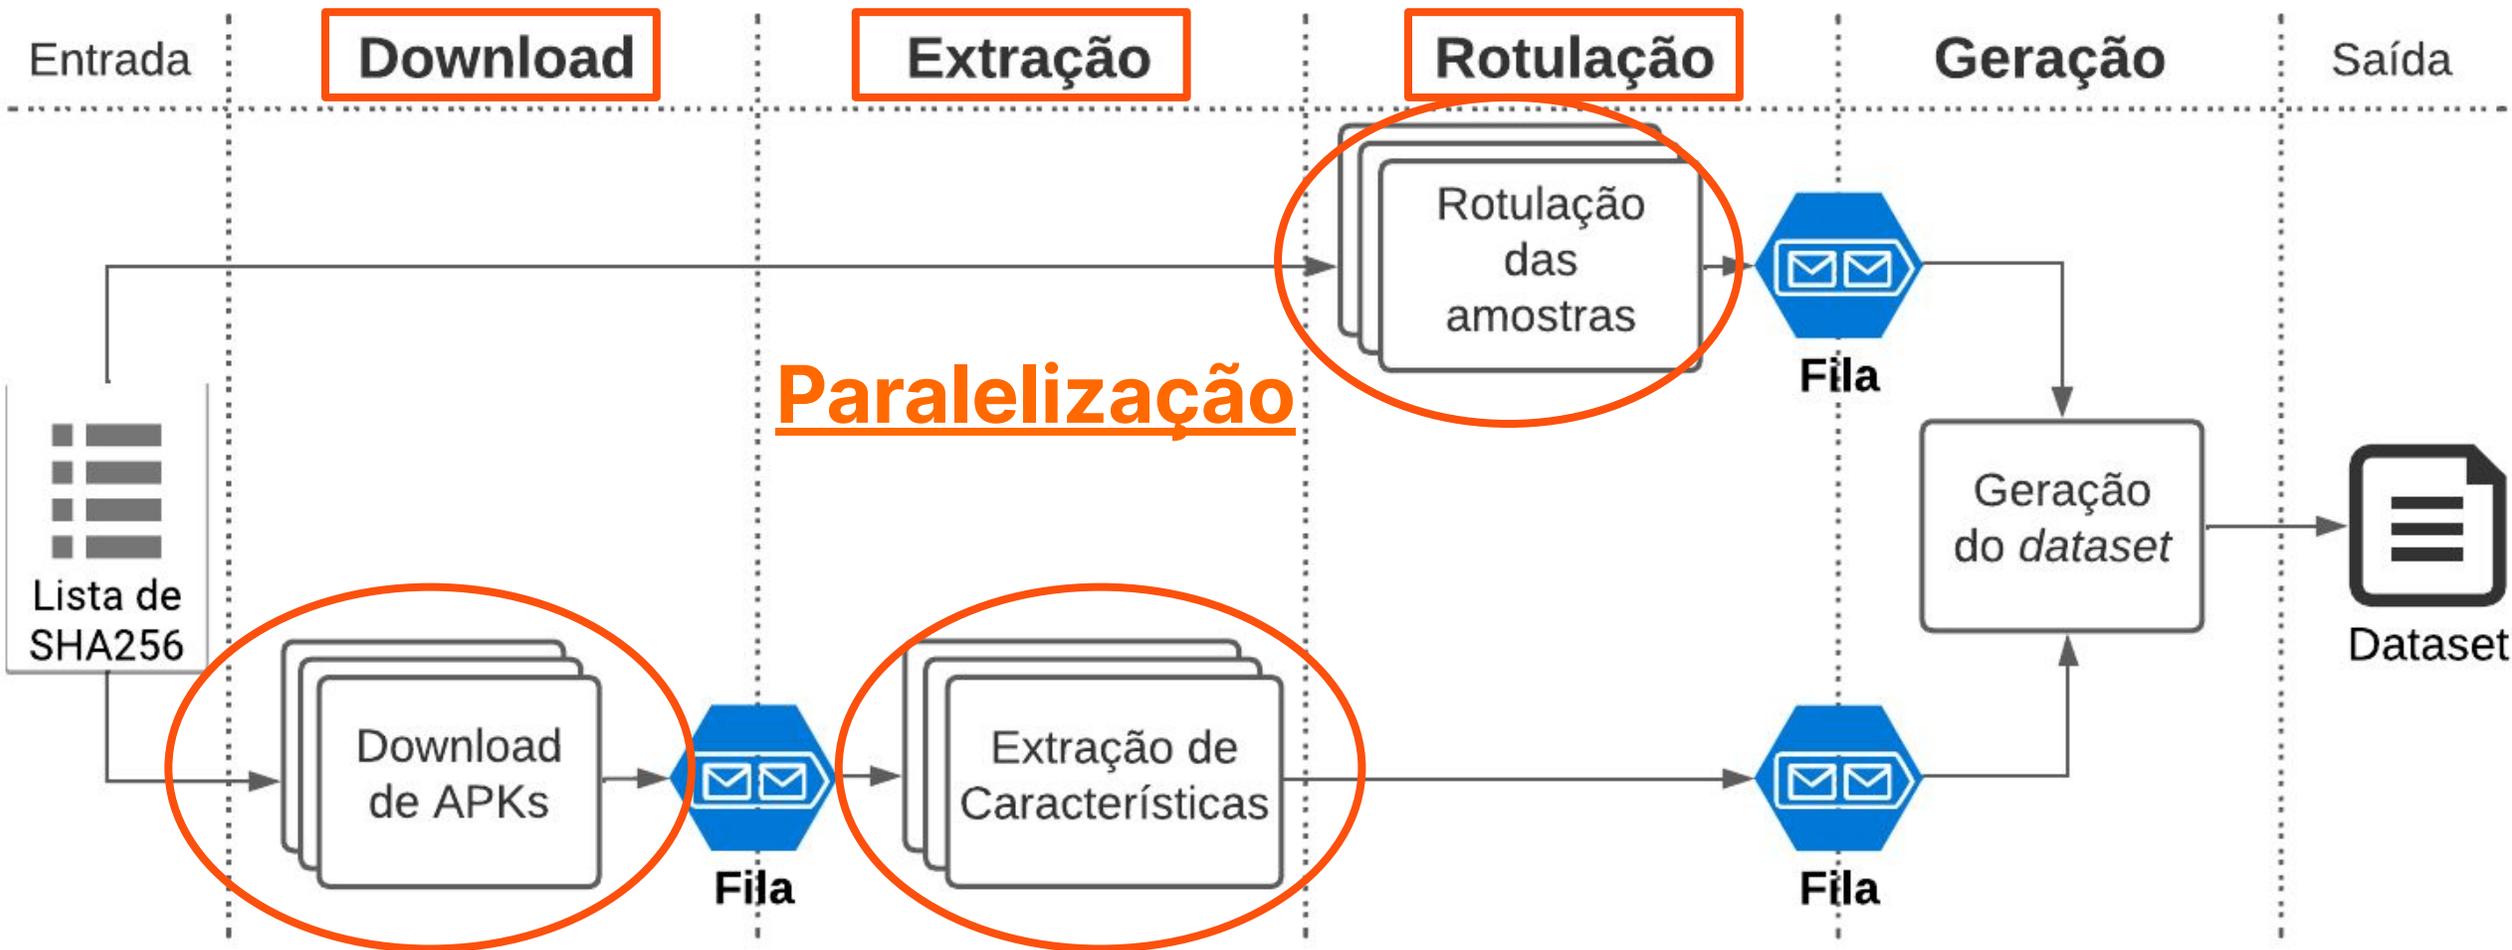
Arquitetura da Ferramenta



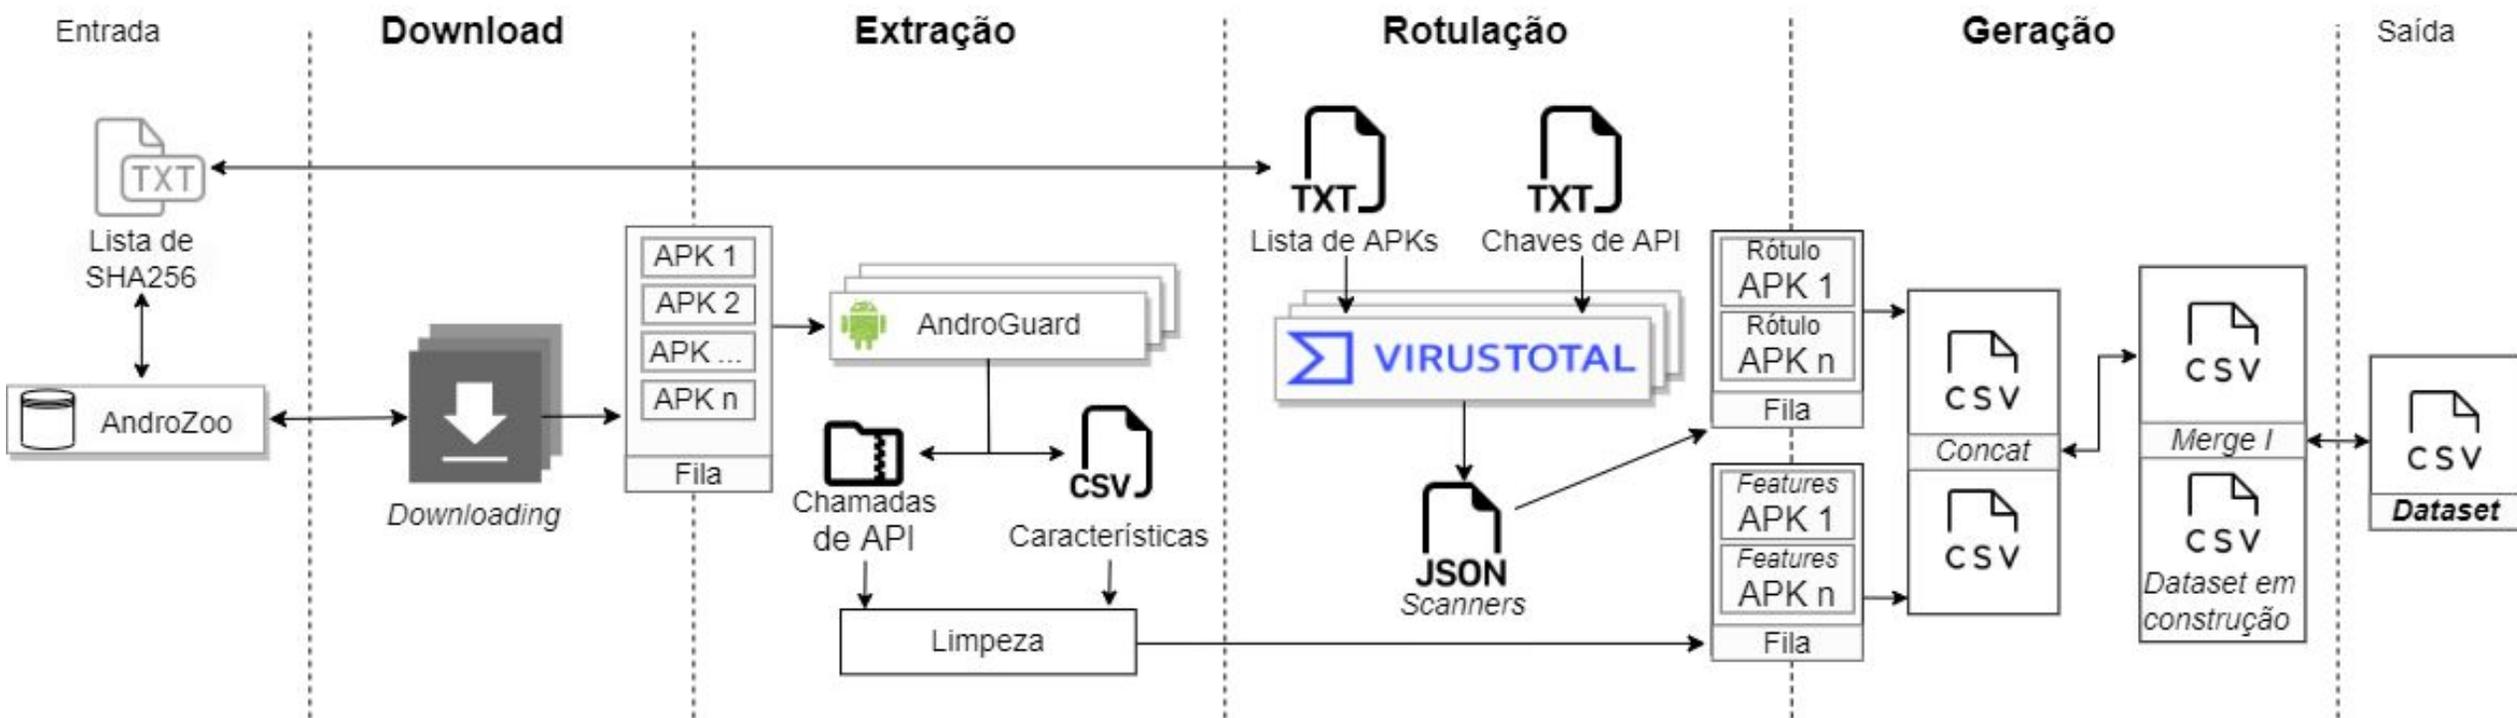
Arquitetura da Ferramenta



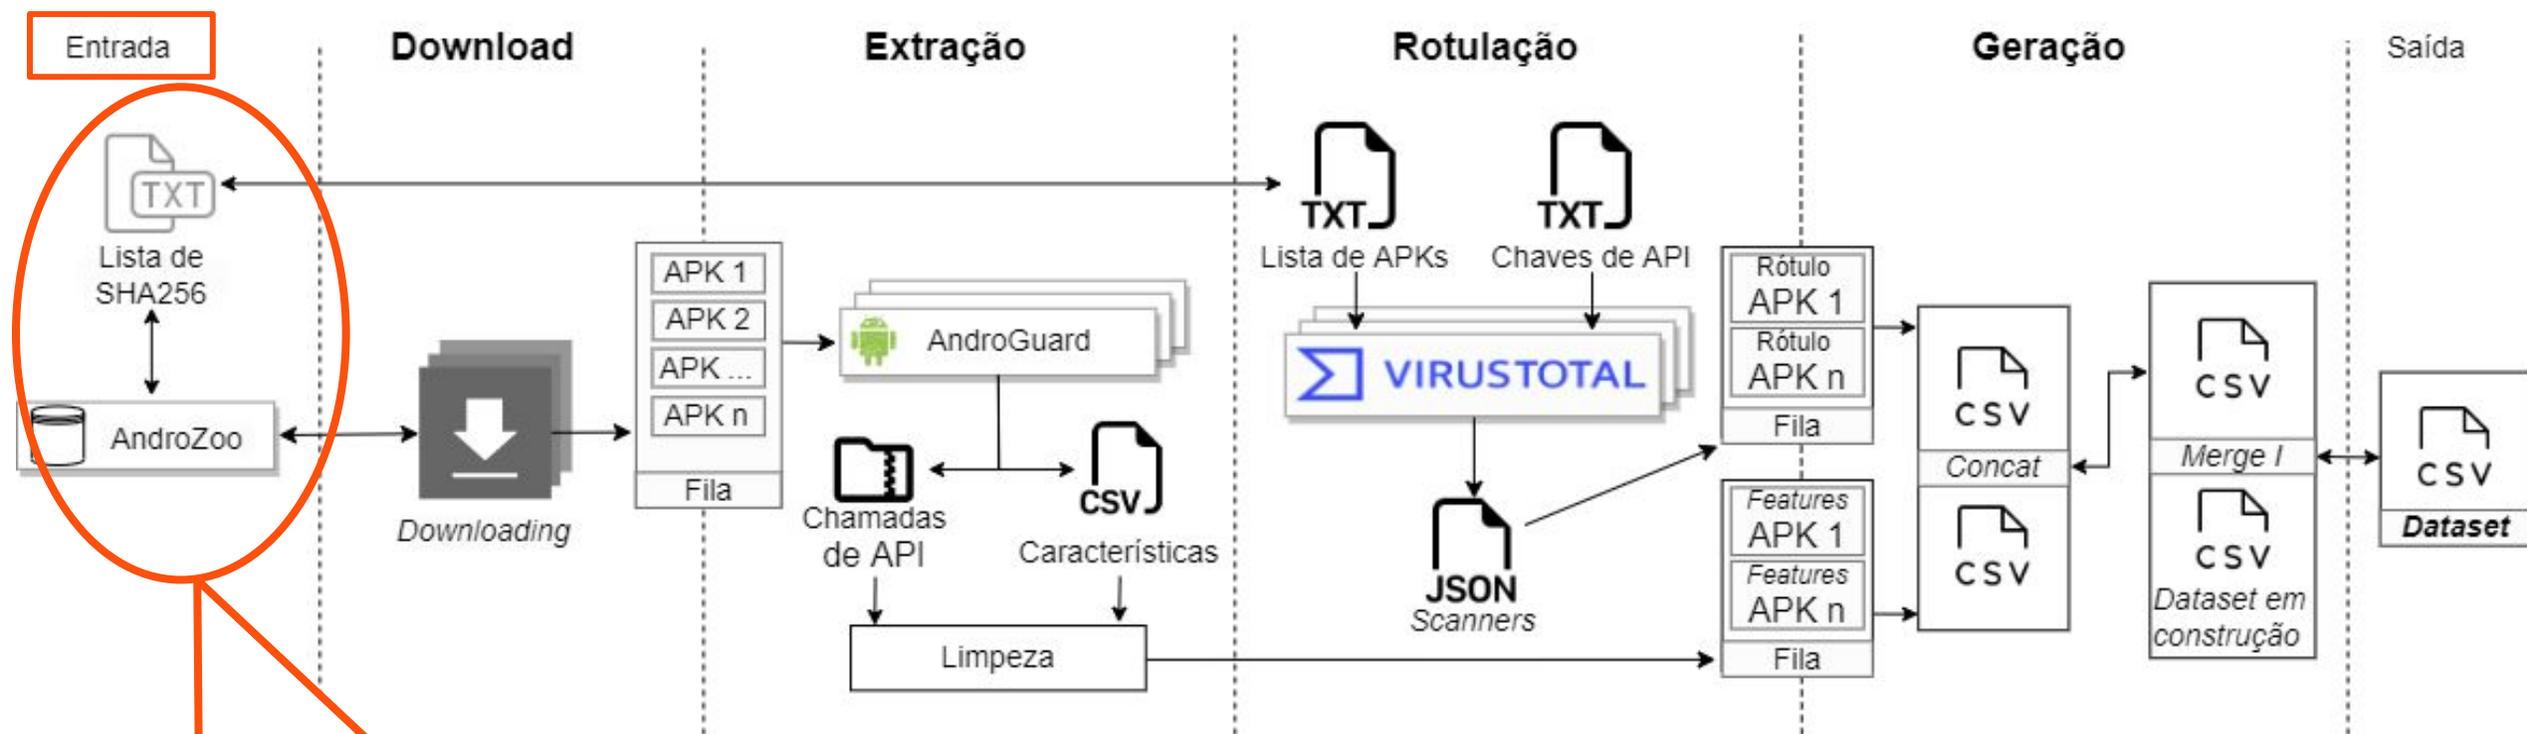
Arquitetura da Ferramenta



Implementação da Ferramenta



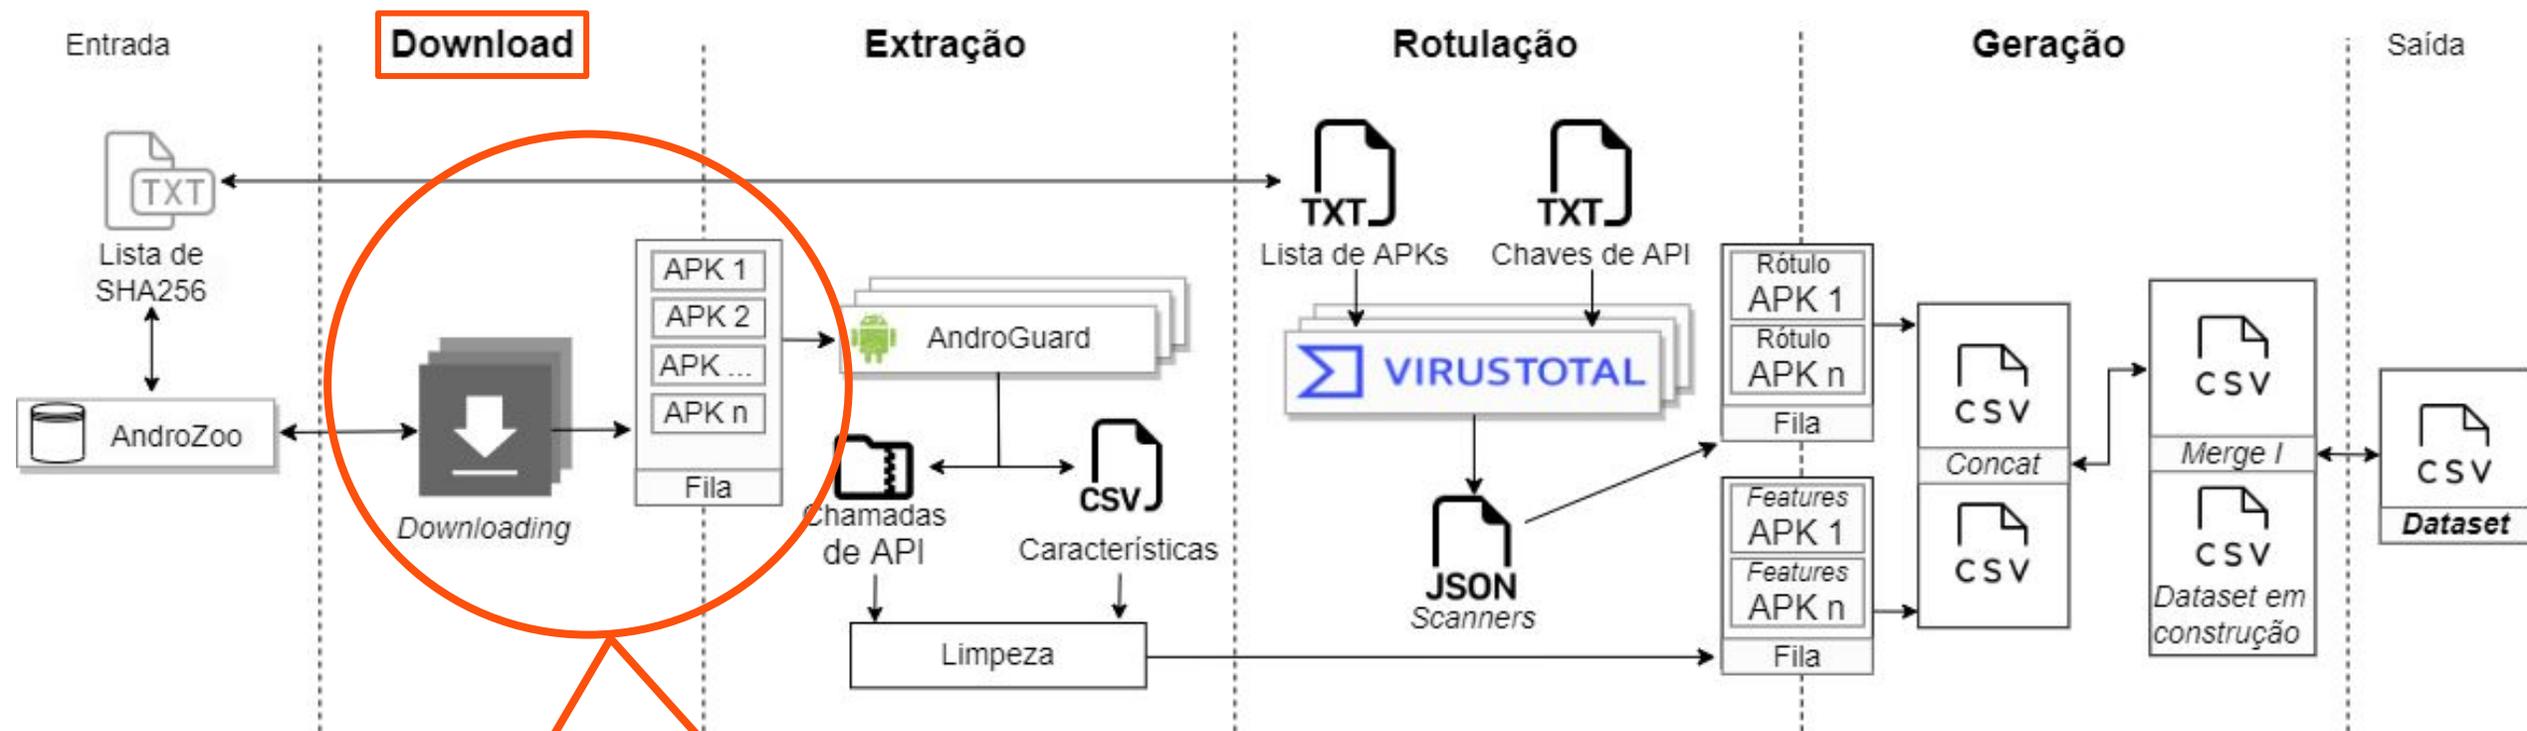
Implementação da Ferramenta



Repositório AndroZoo

- Contém mais de 20M de APKs
- Disponibiliza um conjunto de metadados

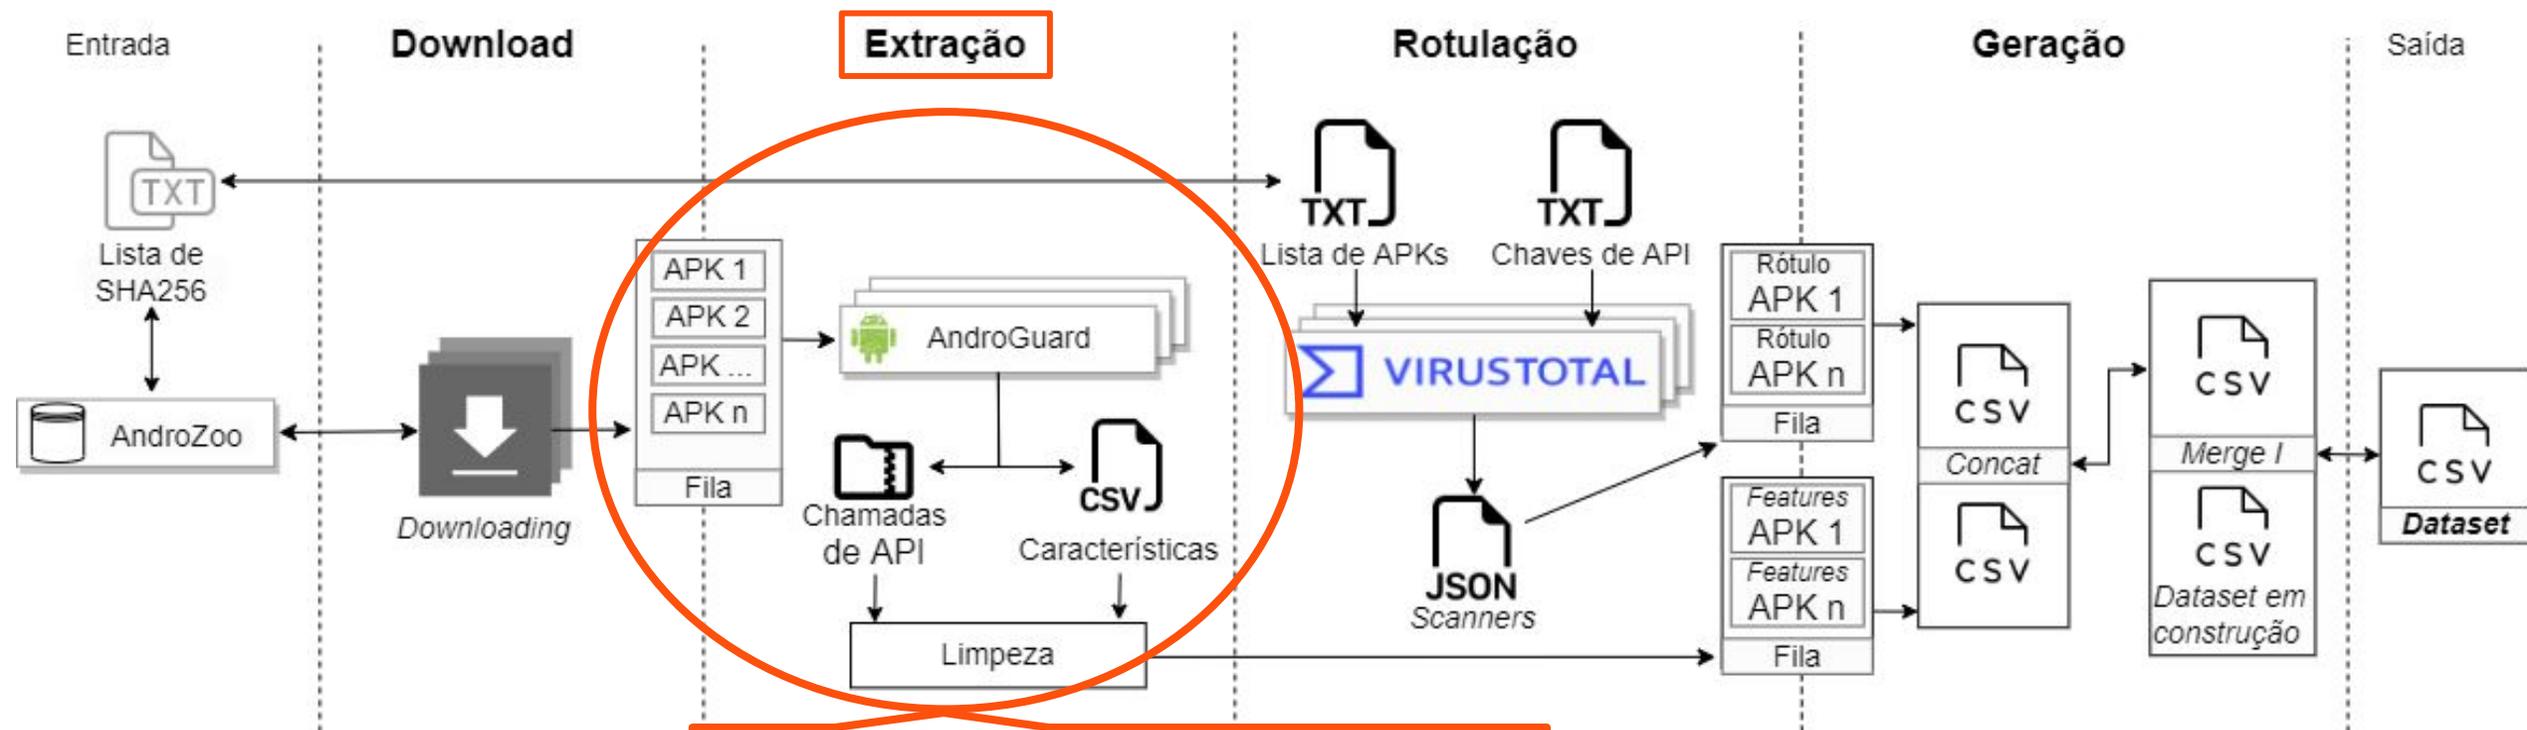
Implementação da Ferramenta



Entrada de Download
Lista de SHA256 dos APKs

Saída de Download
Aplicativo Android

Implementação da Ferramenta



Entrada de Extração

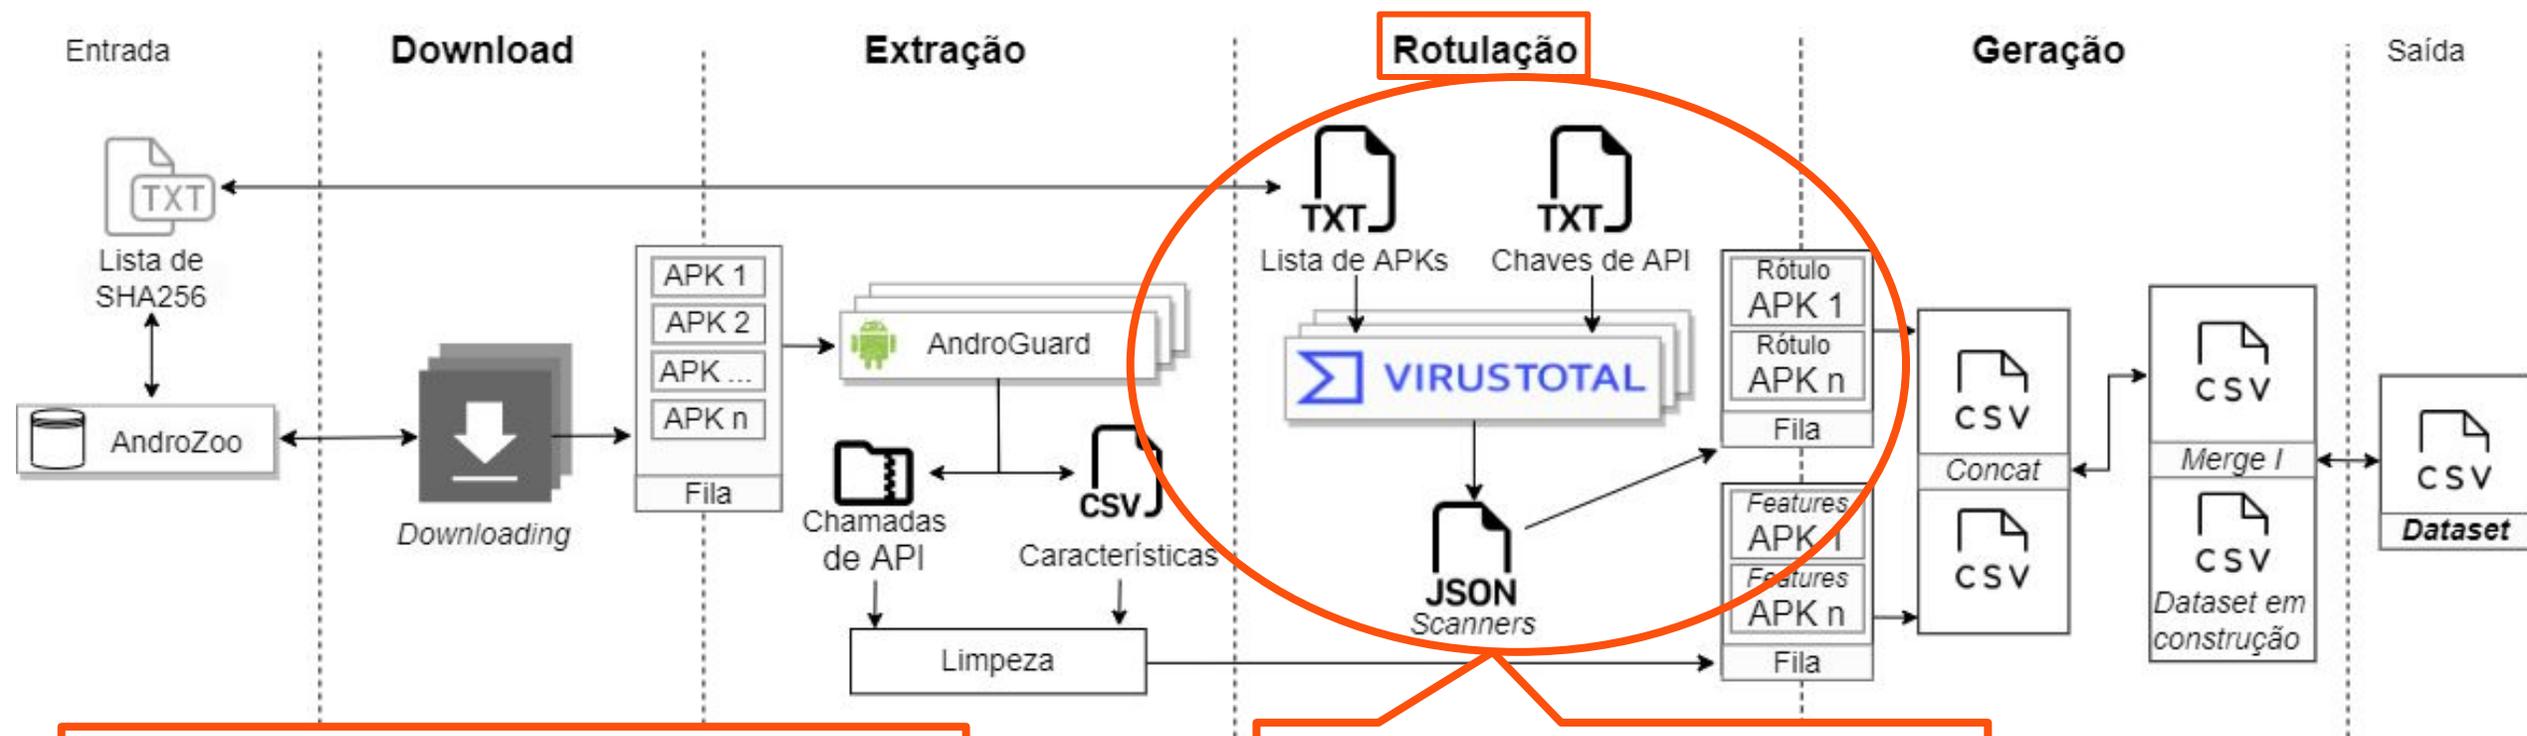
Aplicativo Android

Saída de Extração

CSV de características

Extração das chamadas de API

Implementação da Ferramenta



Chave de API gratuita:

- 500 requisições / dia
- 4 requisições / minuto
- 15.500 requisições/ mês
- 1 conta >> 1 chave de API

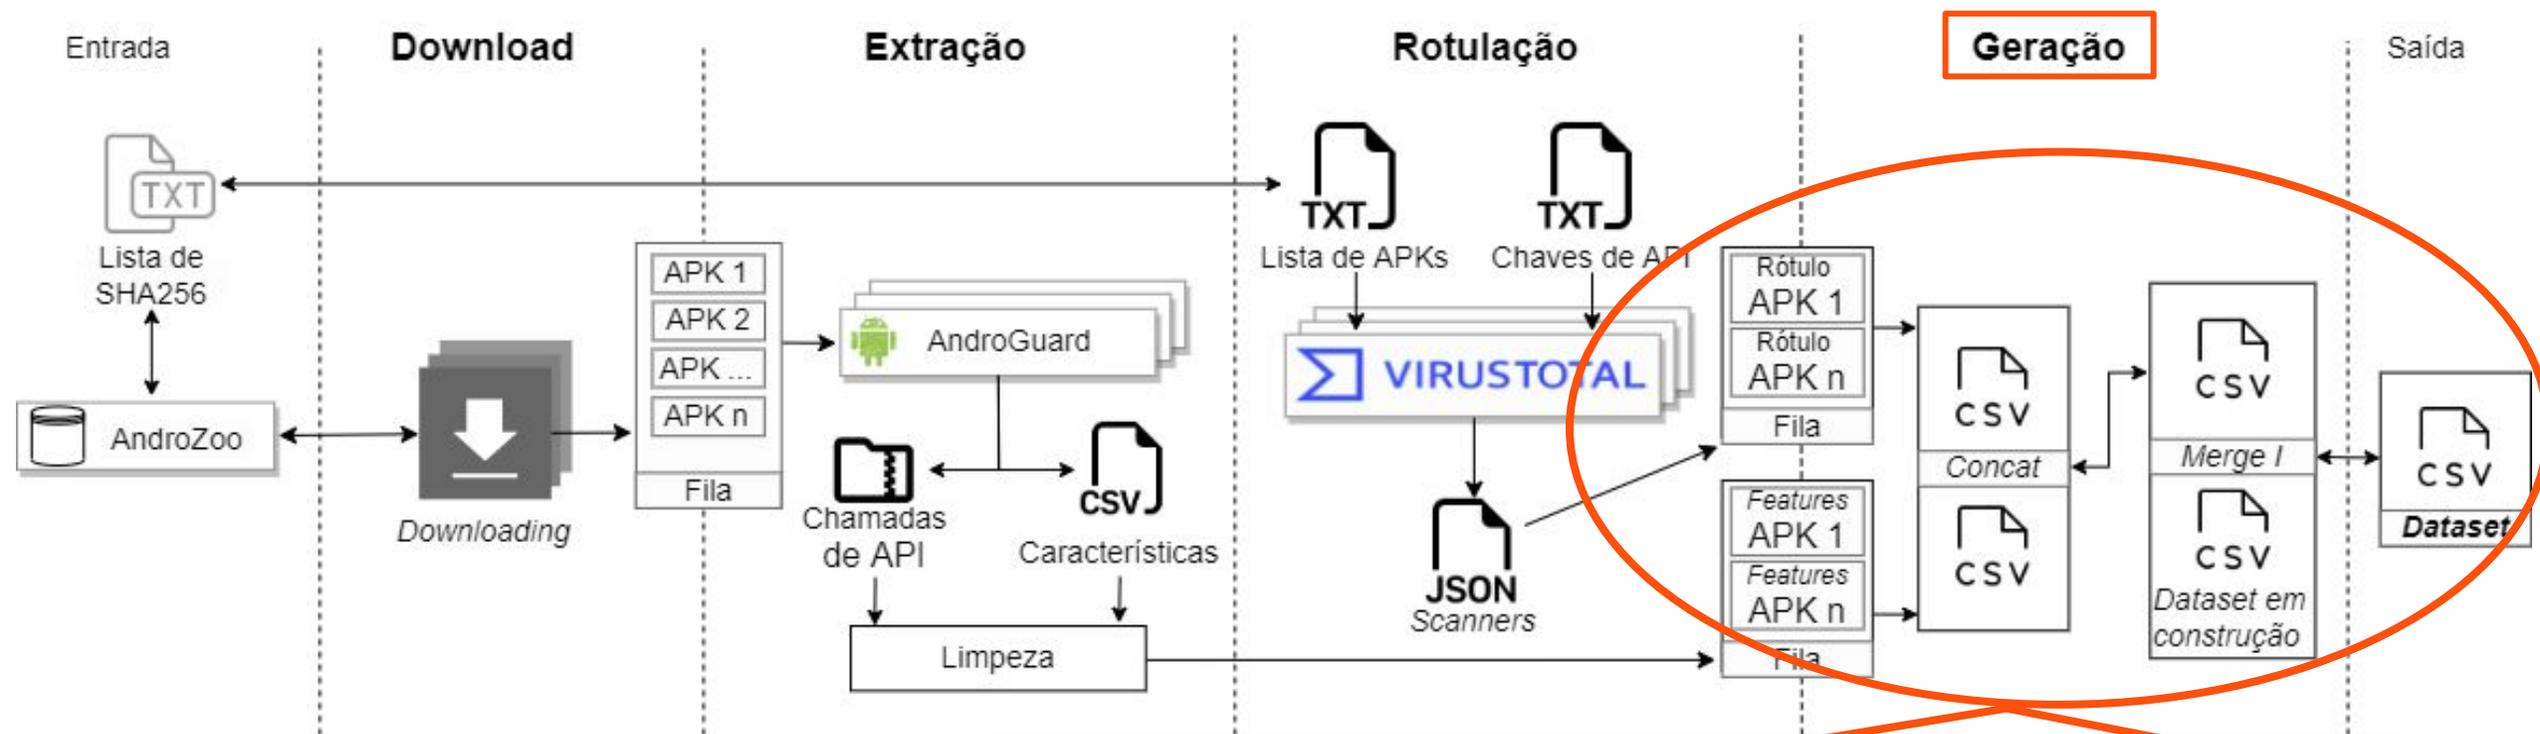
Entrada de Rotulação

Lista de SHA256 dos APKs
Lista de chaves de API

Saída de Rotulação

Dados de rotulação

Implementação da Ferramenta



Entrada de Geração

CSV de características dos APKs
Dados de rotulação dos APKs

Saída de Geração

Dataset

Saída (dataset)

SHA256	NOME	LABELLING	Permission :: INTERNET	Intent :: action.MAIN	APICALL :: Landroid/telephony /TelephonyManager .getLine1Number()
7de5dbe3407e4b 36afb82b2d8e6f5 49a7d1a33489b3 51746d77b0ebf8 efadfea	Radio Adorai	0	1	1	0
6d0477a4299e97 e8a8aa346a4f74 aea9cc5f60b3c7 308d0b86ea2c35 b10b3382	Pure Booster Pro	14	1	1	1

Ambiente da demonstração

- Linux Ubuntu 20.04 LTS | Kernel 5.10.16.3-microsoft-standard-WSL2
 - Python (3.8)
- **Comandos:**
 - curl (7.68.0) e time (GNU bash 5.0.17)
- **Bibliotecas:**
 - pandas (1.3.5)
 - androguard (3.3.5)
 - networkx (2.2)
 - lxml (4.5)
 - numpy (1.22.3)



Agradeço!

Repositório GitHub 



UFAM

lucasvilanova.aluno@unipampa.edu.br

