

ESSE Mobile Security – VO 3: Statische und dynamische Analyse von Applikationen

Raphael Kiefmann, Paul Kalauner, Christian Schanes



Grundlagen zur Code-Analyse

Statische Analyse

Dekompilierung

Deassemblierung

Spezialfall Datenforensik

Dynamische Analyse

Diagnostische Anwendungen

Debugging von Anwendungen

Dynamische Instrumentation

frida Demo

Grundlagen zur Code-Analyse

- Analyse dient als Grundlage, um Angriffe auf Applikationen durchzuführen
 - es existieren verschiedene Methoden
- zwei verschiedene Arten von Analyse, die sich zumeist untereinander ergänzen
 - statisch (die Applikation wird analysiert, ohne die Applikation laufen zu lassen)
 - dynamisch (die Applikation wird zur Laufzeit analysiert)
- siehe auch *Introduction to Security (183.594)*

Statische Analyse

- dient oftmals als Grundlage für die dynamische Analyse
 - erlaubt die Identifikation von gesuchten Eintrittspunkten
 - gibt oftmals einen Ausblick darauf, was zu erwarten ist

- Zugang zu Source-Code erforderlich
 - Direkt: Source-Code verfügbar (z.B. Open-Source)
 - Indirekt: Dekompilierung

- mobile Applikationen sind ZIP-Bündel
 - Android-Applikationen werden in einer *.apk Datei gebündelt
 - iOS-Applikationen werden in einer *.ipa Datei gebündelt
- die Bündel enthalten Ressourcen (Mediendateien, Bibliotheken, etc.) & die eigentliche Anwendung
 - Android-Anwendungen sind im *.`(o)dex` Dateiformat (Dalvik Executable) gespeichert
 - iOS-Anwendungen sind im Mach-O Dateiformat gespeichert

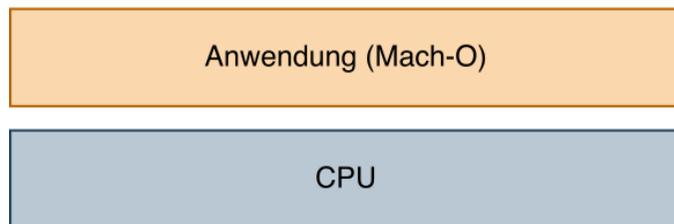
Dekompilierung von .dex Objekten

- .dex Objekte entstehen durch das Kompilieren von Sprachen wie Kotlin und Java zu Bytecode
- vergleichsweise einfach zu dekompilieren
 - der Bytecode ist sehr „ähnlich“ dem Originalcode
- gängige Disassembler & Decompiler sind
 - apktool (deassembliert Ressourcen aber dekompiliert sie nicht)
 - jadx (deassembliert und dekompiliert Ressourcen)
 - dex2jar (deassembliert .dex Objekte in .class Objekte)
 - kann zum Beispiel mit JD-GUI angesehen werden

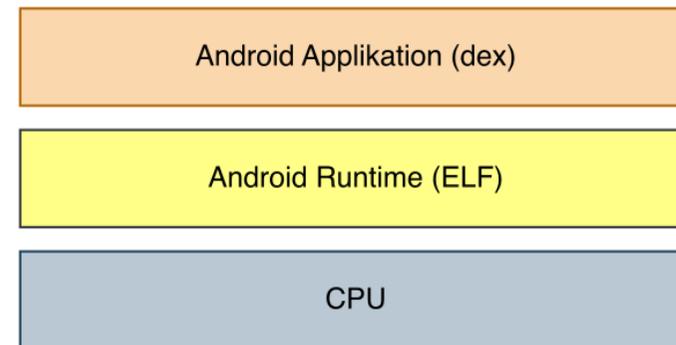
Maschinencode vs. Bytecode

- Bytecode muss von der VM in Maschinencode umgewandelt werden, bevor er ausgeführt werden kann

iOS Applikation



Android Applikation



- Mach-O, geteilte Bibliotheken (*.dylib, *.so) sind Maschinencode
- im Gegensatz zu Bytecode plattformabhängig
 - spezielle Instruktionen
 - unterschiedliche Hardware
- meistens hochoptimiert und daher keine Meta-Informationen wie beim Bytecode

- ghidra (deassembliert & dekompiert)
- radare (deassembliert & kann mit Erweiterungen auch dekompiert werden)
 - iaito ist eine GUI für radare
- IDA Pro (deassembliert & dekompiert)
- Hopper (deassembliert)

- oftmals ist nicht nur spannend wie, sondern auch welche Daten verarbeitet werden
- die Daten werden entweder persistent im Dateisystem gespeichert oder temporär im Arbeitsspeicher hinterlegt
- auch sensible Daten müssen zumindest temporär gespeichert werden, um sie zu verarbeiten
 - Speicherabbilder (müssen zur Laufzeit gemacht werden) erlauben eine Momentaufnahme der verarbeiteten Daten zu einem gewissen Zeitpunkt
 - Speicherabbilder können mit fridump (auf allen Plattformen mit **frida** Unterstützung) oder LiME (nur auf Linux) erstellt werden

- auch kryptographische Schlüssel müssen – teilweise persistent – abgelegt werden
 - bei unsicherer Speicherung einfach zu finden

⇒ *Selected Topics of Digital Forensics I (194.065)*

Dynamische Analyse

- bei der dynamischen Analyse werden die Applikationen zur Laufzeit analysiert
- kein Source-Code erforderlich
- oftmals laufen gewisse Applikationen nicht auf Plattformen, die zum Reverse Engineering verwendet werden
 - Mechanismen zur Erkennung von Geräten, die gerootet oder jailbreakt wurden
 - Mechanismen zur Erkennung von Emulatoren
 - Mechanismen zur Erkennung von Tools zur dynamischen Analyse

- einfachste Form der dynamischen Analyse
- keine direkte Manipulation von Daten
- Verwendung von existierender “Debugging Infrastruktur”
 - durchsuchen von Logs
 - Mitverfolgung von abgesetzten Systemcalls
 - iosttrace
 - strace
 - jtrace

- Debugging ermöglicht normalerweise das Nachvollziehen von Fehlern im Programmablauf
- gängige Debugger sind
 - gdb (Linux und macOS)
 - lldb (plattformunabhängig)

- Breakpoints erlauben, das Programm an einer gewissen Stelle zu stoppen
- Werte können ausgelesen werden
- Werte können auch neu gesetzt werden
- erlaubt das Hinzufügen von fremden Code
 - eine einfache Form der dynamischen Instrumentation
- das Setzen von Breakpoints verlangsamt den Ablauf eines Programmes meist deutlich

- Watchpoints sind nicht an einem fixen Ablauf des Programms, sondern konditional
 - Stellen im Speicher können überwacht werden und es kann darauf reagiert werden, falls sich der Wert ändert
- wie auch bei Breakpoints existieren zwei verschiedene Typen von Watchpoints
 - software-basiert: der Breakpoint muss in den Code injiziert werden, verlangsamt dadurch den Ablauf
 - hardware-basiert: die CPU ist dafür verantwortlich auf Änderungen zu reagieren, dadurch ist der Performance-Verlust nicht zu groß

- das Debugging ist meist nur während der Entwicklung relevant
 - beim Entwickeln enthalten die Anwendung meistens zusätzliche Debug Informationen
 - Namen von Funktionen und Variablen
 - die zusätzlichen Informationen ermöglichen dem Debugger, die Codestelle zu referenzieren
- Debugger sind oft auf bestimmte Sprachen eingeschränkt:
 - gdb und lldb für Maschinencode
 - Java Debugger nur für JVM-basierte Sprachen (Groovy, Kotlin, Java, etc.)

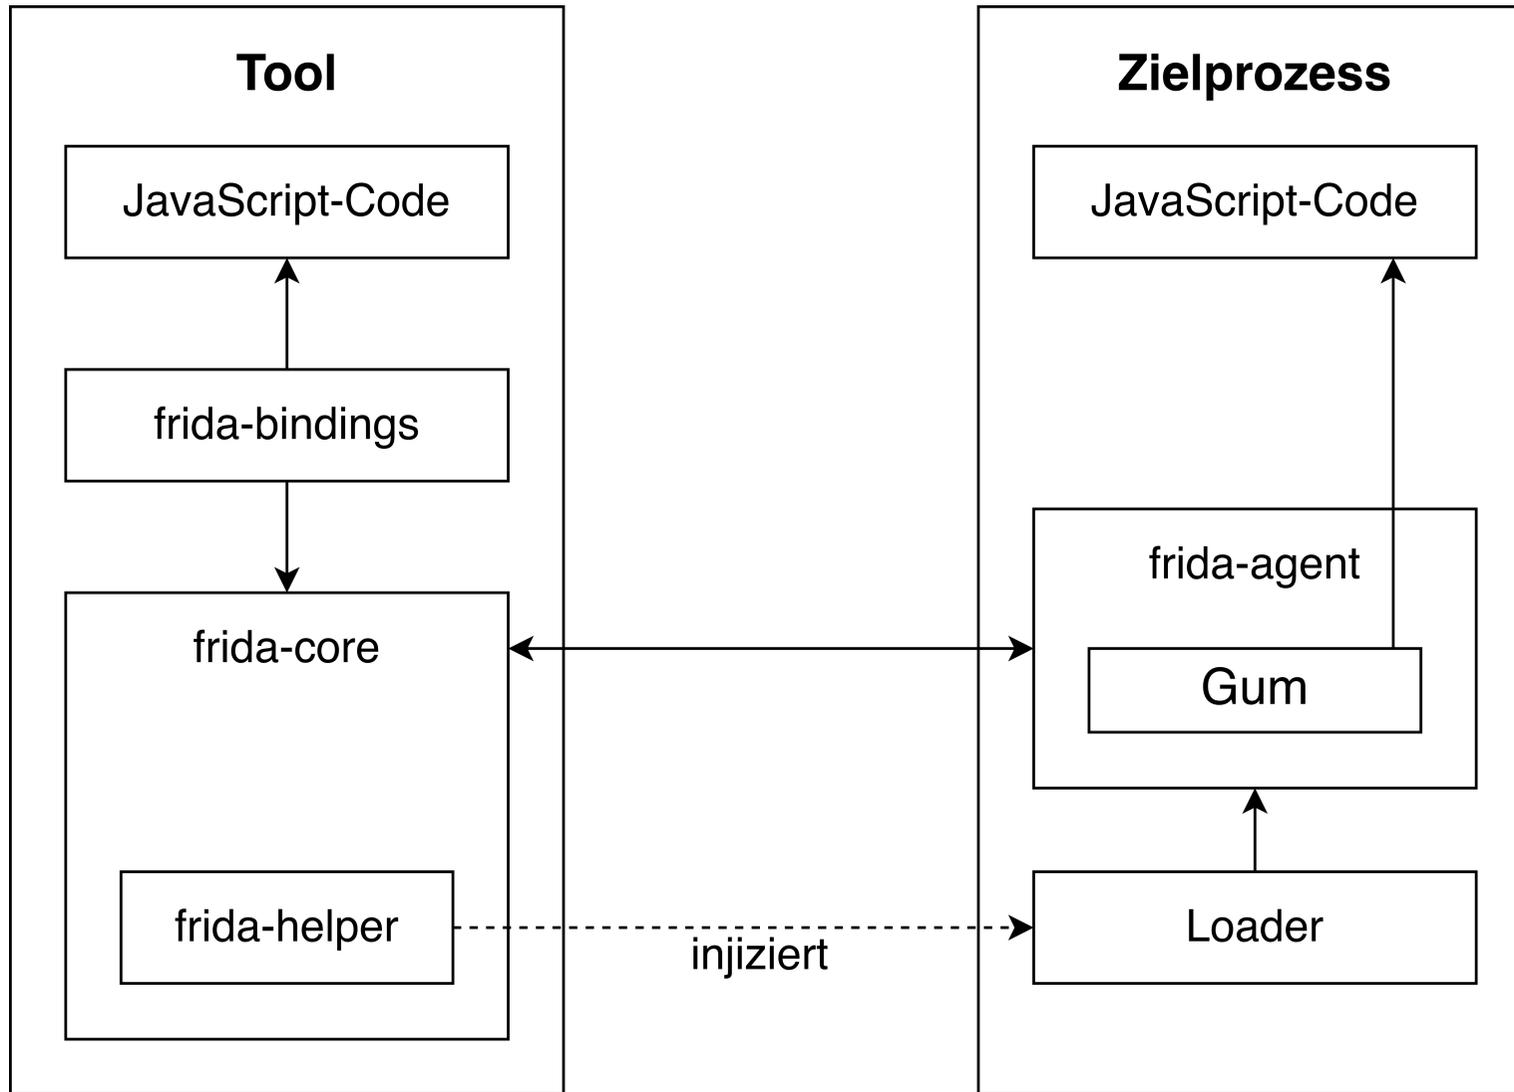
- basiert auf der Idee von Debuggern
- das Werkzeug für die dynamische Instrumentation hängt sich zu einer App zur Laufzeit dazu
- modifiziert die Instruktionen eines Programms während der Laufzeit
- erlaubt so die Ausführung von zusätzlichem Code ohne die zugrundeliegende Applikationen persistent zu ändern

- die Entwicklung erfolgt seit 2010 (siehe GitHub)
 - von Ole André V. Ravnås und Håvard Sørnbø geschaffen, um ihnen beim Reverse Engineering zu helfen
- zu einem **DER** Tools für das Reverse Engineering geworden
- ermöglicht die dynamische Instrumentation von Applikationen auf Android, iOS, Linux, macOS, Windows
- in verschiedenen Sprachen geschrieben
- (offizielle) APIs
 - JavaScript/TypeScript API (am besten dokumentiert)
 - C API
 - etc.

- frida erlaubt die Veränderung von so ziemlich allen Bestandteilen einer Applikation zur Laufzeit
 - die Werte von Variablen können geändert werden
 - Funktionen können komplett umgeschrieben werden
 - Rückgabewerte können manipuliert werden
 - etc.
- wird dadurch ermöglicht, dass sich das frida Framework bei einer Applikation „dazuhängt“
 - genaue Details können der offiziellen Dokumentation & den Präsentationen von Ole André V. Ravnås entnommen werden

- frida ermöglicht u.a. das Mitverfolgen von allen Instruktionen (Stalker) aber auch einzelnen Funktionen (frida-trace)
- das Mitverfolgen aller Instruktionen ist selten aufschlussreich
- die statische Analyse liefert hier meistens Informationen zu wichtigen (Eintritts)punkten

- **frida-core**: Kernlogik, inkludiert Injection-Code
- **Gum**: Instrumentation-Library, welche eine JavaScript-Engine inkludiert und von *frida-core* über JavaScript-Bindings (GumJS) verwendet wird
- **frida-agent**: Shared-Library, läuft im Zielprozess, nimmt Befehle von *frida-core* entgegen und leitet diese an *Gum* weiter
- **frida-helper**: Injiziert *frida-agent* in den Zielprozess
- **frida-bindings**: Stellt Funktionen anderen Programmiersprachen zur Verfügung
- **frida-server**: Macht *frida-core* für Remote-Hosts über TCP verfügbar



(Vergleiche <https://frida.re/docs/hacking>)

- *frida-helper* nutzt `ptrace`, um mit Zielprozess zu interagieren und speichert aktuellen Programmstatus
- *frida-helper* allokiert mittels `mmap` einen Speicherbereich für den Loader-Code
- Loader wird an allokierten Speicherbereich kopiert
- Loader wird ausgeführt und *frida-agent* wird geladen
- Wiederaufnahme der normalen Programmausführung

frida Demo

- über die Jahre wurden verschiedene Tools basierend auf frida entwickelt
 - von Projekten mit eingeschränktem Funktionsumfang bis hin zu großen Frameworks
- das bekannteste Beispiel ist **objection**
 - stellt vorgefertigte frida-Scripts für verschiedenste Zwecke zur Verfügung
- weitere Beispiele sind:
 - **r2frida**: ermöglicht das Einhängen des Deassemblierungs- und Dekompilierungsframeworks zur Laufzeit
 - **fridump**: ermöglicht Dumpen des Arbeitsspeichers eines Prozesses

- heutzutage haben viele Apps eine Internet-Anbindung
- oftmals werden wichtige Informationen nachgeladen oder an einen Server geschickt
- es existieren mehrere Varianten, um den Netzwerkverkehr mitzuschneiden

⇒ Einheit **Absicherung von Netzwerkverkehr** am **24.11.2022**

- Code-Analyse: statisch vs. dynamisch
- statisch = Source-Code ansehen
- dynamisch = zur Laufzeit, kein Source-Code erforderlich
- Tools:
 - Debugger
 - frida
 - ...

- Android Runtime (ART) and Dalvik: <https://source.android.com/devices/tech/dalvik>, abgerufen: 07.11.2022
- Dalvik Executable format: <https://source.android.com/devices/tech/dalvik/dex-format>, abgerufen: 07.11.2022
- frida: The Engineering Behind the Reverse Engineering: <https://frida.re/slides/osdc-2015-the-engineering-behind-the-reverse-engineering.pdf>, abgerufen: 07.11.2022
- GitHub: frida: <https://github.com/frida>, abgerufen: 07.11.2022

- Elenkov (2014): Android Security Internals
- Drake, et al. (2014): Android Hacker's Handbook
- Chell (2015): The Mobile Application Hacker's Handbook
- Vijay Kumar Velu. Mobile Application Penetration Testing. Birmingham: Packt Publishing Ltd, 2016. isbn: 978-1-78588-337-8.

Vielen Dank!

<https://establishing-security.at/>

