

AI Application Penetration Test

Finden Sie heraus, wie sicher Ihre KI-Anwendung ist



Gibt der Chatbot auf Ihrer Webseite auch bei manipulierten Eingaben wirklich keine Interna heraus? Wird über Ihre KI-API nur das ans CRM übertragen, was auch übertragen werden soll? Ein spezialisierter Penetration Test deckt Schwachstellen in Ihrer KI-Anwendung und deren Integration in Backend-Systeme, Schnittstellen und Datenflüsse auf.



Penetration Tests nach der
OWASP LLM Application &
Generative AI Security Top 10



Ideale Grundlage, um
compliant mit Standards wie
ISO/IEC 42001 oder dem
EU AI Act zu werden



Erfahrene Spezialisten – mit der
Expertise aus 40 Jahren
IT-Sicherheit made in Germany

Welche Schwachstellen wir aufdecken

Prompt-Injection-Schwachstellen,
einschließlich:

- ➔ Direct Prompt Injection
- ➔ Indirect Prompt Injection
- ➔ Jailbreaking
- ➔ Universal Jailbreaking

Supply-Chain-Risiken,
wie z. B.:

- ➔ Verwendung von Drittanbieterpaketen mit bekannten Schwachstellen
- ➔ Einsatz veralteter oder unsicherer KI-Modelle

**Die unsachgemäße Verarbeitung
von Ausgaben, z. B. durch:**

- ➔ Cross-Site Scripting (XSS)
- ➔ SQL Injection
- ➔ Remote Code Execution (RCE)
- ➔ XML External Entity (XXE)

Schwachstellen bei Schnittstellen,
auf die die KI Zugriff hat, z. B. bei:

- ➔ APIs
- ➔ Datenquellen wie Fileserver oder SQL Server
- ➔ MCP Server

**Die unbeabsichtigte Preisgabe
sensibler Infos, etwa durch:**

- ➔ Offenlegung des System-Prompts
- ➔ Preisgabe von Trainingsdaten, die für das Finetuning verwendet wurden
- ➔ Weitergabe von Nutzerdaten, die durch andere Benutzer eingebracht wurden
- ➔ Einsicht in sensible Informationen innerhalb der Anwendung


Welche Systeme wir für Sie analysieren



Mit einem AI Application Penetration Test kann nahezu jede produktiv eingesetzte LLM-gestützte oder generative KI-Anwendung überprüft werden – unabhängig davon, ob sie „off the shelf“ integriert, via API angebunden oder individuell entwickelt wurde. Entscheidend ist die Analyse des Zusammenspiels aus Modell, Logik, Schnittstellen und Benutzerinteraktion.

- ✓ Chatbots für Kundenservice oder HR
- ✓ KI-Assistenten für interne Prozesse (z. B. Ticketbearbeitung)
- ✓ Copiloten für Entwickler oder Analysten
- ✓ Textklassifikations- oder Zusammenfassungsdienste
- ✓ Text-to-Image- & Image-to-Text-Tools
- ✓ KI-gestützte Präsentations- oder Content-Generatoren
- ✓ MCP (Model Context Protocol) Server
- ✓ und viele mehr

Ihr Ergebnisbericht



Nach dem Penetration Test erhalten Sie einen umfassenden Abschlussbericht. Darin aufgelistet:

- ✓ eine Übersicht über alle gefundenen Schwachstellen, die von Angreifern ausgenutzt werden könnten
- ✓ die Einschätzung der Ausnutzbarkeit & der möglichen Auswirkungen
- ✓ Empfehlungen zur Behebung
- ✓ Management Summary

Zertifizierte Expertise



Erkennen Sie Schwachstellen in Ihrer KI-Anwendung, bevor andere sie ausnutzen.

✉ sales@gdata-adan.de ☎ +49 (0) 234 / 9762-820

© Copyright 2025 G DATA CyberDefense AG. Alle Rechte vorbehalten. Kein Teil dieses Dokuments darf ohne vorherige schriftliche Genehmigung der G DATA CyberDefense AG Deutschland kopiert oder reproduziert werden.

Microsoft, Windows, Outlook und Exchange Server sind eingetragene Marken der Microsoft Corporation. Alle anderen Marken- oder Produktnamen sind Warenzeichen ihrer jeweiligen Eigentümer und sind daher entsprechend zu behandeln.


G DATA
advanced analytics