

Generative KI: Fluch oder Segen für die Cybersicherheit?

Claudia Eckert,

Fraunhofer AISEC, TU München, acatech

19.1. 2026 Omnisecure 2026

Generative KI: Fluch oder Segen für die Cybersicherheit?

Agenda

- 1. Einordnung:** (Generative) KI: Nutzen/Grenzen?!
- 2. Fluch?** Risikopotentiale: Neue Angriffsflächen und typische Fehlerszenarien
- 3. Segen?** Potenziale: Wo generative KI sinnvoll unterstützen kann
- 4. Regulatorik:** Anforderungen an vertrauenswürdige KI
- 5. Ausblick:** Resilienz als Gestaltungsaufgabe
- 6. Take home Message**

1. Einordnung: (Generative) KI: Fluch oder Segen?



Automatisierte Fertigung



Personalisiertes Gesundheitsmonitoring



Predictive Crime



KI-gesteuerte Energienetz



KI-unterstütztes Trading



KI in der Verteidigung

1. Einordnung: Generative KI

Generative KI und die Bedeutung für die Cybersicherheit:


- **Fluch?** Führt sie zu verstärkten Sicherheitsrisiken?
- **Segen?** Hat sie das Potential, das Sicherheitslevel in Unternehmen zu erhöhen?
- **Fluch?** Stoßen klassische Sicherheitsparadigmen an ihre Grenzen?
- **Segen?** Hilft sie, Software-Qualität nachhaltig zu verbessern, SW sicherer zu machen?
- **Fluch?** Trägt sie zur Verstärkung unserer digitalen Abhängigkeit bei?
- **Segen?** Hilft sie, Regularien automatisiert, nachweislich umzusetzen?



2. Fluch: Erweiterte Angriffsmöglichkeiten durch generative KI-Systeme

Zusammenfassender Überblick über Bedrohungen für Unternehmen durch KI (Basis OWASP 2025)

(1) Angriffe **auf** generative KI führen zu Nutzungs-Risiken: **Beispiele**



2. Fluch: Erweiterte Angriffsmöglichkeiten durch generative KI-Systeme

Angriff: Prompt Injection: gezielte Manipulation von Eingabedaten

- **Ziel:** u.a. Einschleusen von Befehlen, wodurch z.B. Daten abfließen können
- **Einfaches Beispiel:** Indirekte Prompt Injection über einen Chatbot
 - Angreifer platziert Malware auf Webseite: z.B. Nutzerfragen an Angreifer senden
 - Nutzer verwendet Chatbot mit seinen, ggf sensitiven Eingabedaten
 - Chatbot nutzt manipulierte Webseite, Weitergabe sensibler Daten an Angreifer

Angriff: Risiken durch Ausgaben/Antwortverhalten:

Ziele: z.B. aus Antworten lassen sich Rückschlüsse auf die sensible Trainingsdaten ziehen.

- Angreifer schleust über LLM Schadcode ein, der ungeprüft ausgeführt wird.
- LLM generiert fehlerhaften Programmcode, Integration in vorhandene Software

2. Fluch: Erweiterte Angriffsmöglichkeiten durch generative KI-Systeme

(2) Angriffe **durch** generative KI: **Neue Angriffsvektoren** durch KI-generierte Angriffe

- **Datenbasierte Angriffe:** Data-Poisoning in Trainingsdaten:
 - **Ziel:** Antwortverhalten des LLM wird gezielt **manipuliert**
 - **Supply Chain Angriffe:**
 - **Ziel:** unsichere, vtrainierte Modelle oder unsichere Plug-ins von Dritten als Bestandteil von LLMs **platzieren**
- **Agenten-basierte Angriffsgenerierung**
 - **Ziel:** Automatisierte **Lagebilderstellung** und **automatisierte Generierung zugeschnittener Angriffe**
 - Nutzen von OSINT Tools: Orchestrierung von **autonomen Agenten:** Schwachstellen-Suche,....,
 - Automatisierte **Exploit-Generierung:** Zusammenführung strukturierter, unstrukturierter Daten



2. Fluch: Erweiterte Angriffsmöglichkeiten durch generative KI-Systeme

Show-Case von Anthropic in 2025: KI als Angriffscoordinator

- **LLM entwickelt eine reale Angriffskampagne:**

- **Lagebilderstellung für Zielpersonen:** Automatisierte Reconnaissance (Auswertung öffentlich verfügbarer Informationen zu Personen, Rollen, Technologien),
- **Personalisieren:** Erstellung stark personalisierter Phishing-Nachrichten,
- **Adaptieren:** Anpassung von Tonalität der Nachrichten und Vorgehen basierend auf Reaktionen,
- **Orchestrierung:** Koordination mehrerer Angriffsschritte über Prompts, Kontext und externe Tools

- **Charakter des Angriffs**

- KI übernimmt **autonom, proaktive Aufgaben** entlang der Angriffskette
- Angriff wird **wirksamer, schneller, skalierbarer und adaptiver**

Demonstration: Das LLM agiert als **kampagnenfähiger Koordinator**, nicht nur als Assistenzwerkzeug

2. Fluch: Erweiterte Angriffsmöglichkeiten durch generative KI-Systeme

Angriff gilt als ein Wendepunkt!

- Was neu ist
 - Keine neuen Exploits oder Zero-Days erforderlich
 - End-to-End-Automatisierung ganzer Angriffsketten
 - Kontinuierliche Anpassung ohne permanente menschliche Steuerung
 - Deutlich gesenkte Eintrittsbarrieren für komplexe Angriffe
- Warum klassische Security hier an Grenzen stößt
 - Angriff entsteht durch Zusammenspiel von Kontext, Entscheidung und Aktion, aber Traditionelle Abwehr fokussiert auf Angriffsteilschritte und einzelne Angriffs-Signaturen
 - Geschwindigkeit der Angriffsdurchführung überholt manuelle Analyse- und Reaktionsprozesse
 - Fehlende/fehlerhafte lokale Schutzmaßnahmen wirken sich schnell über Systemgrenzen aus.



2. Fluch: Erweiterte Angriffsmöglichkeiten durch generative KI-Systeme

Angriff gilt als ein Wendepunkt!

- Zentrale Erkenntnis
 - Die Hauptangriffsfläche ist nicht das Modell, sondern
 - die Integration von KI in Daten-, Tool- und Aktionssysteme
 - Kontext (Prompts, Feedback, externe Quellen) wird Teil der Steuerlogik
- Implikation
 - Generative KI wirkt als **systemischer Risikobeschleuniger**
 - Sicherheitsfragen verlagern sich von Algorithmen zu **Architektur, Governance und Kontrolle**

Fazit: Das Risikopotential wird **erheblich verstärkt** durch KI



Zwischenfazit: Absicherung von KI-Systemen ist sine qua non!

Defense-in-Depth für KI-Systeme

■ Vorbereitung/Pre-processing


- Input-Sanitization, Prompt-Shielding
- Absicherung von RAG-Quellen (Allowlists, Content-Scanning)

■ Modell & Lieferkette

- Robustheitstests, Red-Teaming, Poisoning-Detection, ...
- Signieren von Modellen und Datensätzen, ...
- Dokumentation von Training, Fine-Tuning und Datenquellen

■ Ausgabe-Nachbearbeitung/Post-processing

- Output-Moderation, Policy-Checks, Human-in-the-Loop
- API-Hardening, Authentifizierung, Context-Isolation
- Rate-Limiting, Monitoring, Logging
- Erkennung und Bewertung von Halluzinationen



3. Segen: Wo generative KI sinnvoll unterstützen kann

- **Sichere Softwareentwicklung/Sicherheitsanalyse: u.a.**
 - **Code-Reviews:** Schwachstellen? Schadcode-Teile?
 - **POI-Erkennung:** Unterstützung bei Analyse
- **Security Operations: u.a.**
 - **Verbesserte Lagebeurteilung:** z.B. Log-File Aufbereitung
 - **Kontextualisierung:** Hintergrundinformation zu Alarmen
 - Automatisierte **Report Generierung**, z.B. bei Incidents
- **Detection Engineering:** proaktiv neue Regeln/Tests entwickeln
 - Analyst beschreibt: „**was**“ erkannt werden soll,
 - KI **generiert das „wie“**: Prüfcode zu neuer Regel, Testverfahren, ...



3. Segen: Wo generative KI sinnvoll unterstützen kann


Beispiel: LLMs, um Schadcode zu erkennen und dessen Verhalten zu erklären

Problem:

- Binaries sind schwer verständlich (Black-Boxes)
- Angreifer nutzen Obfuscation, um relevante Muster und Charakteristika zu verschleiern
- Verhalten von Malware zu verstehen ist schwierig

Ziel: Nutzen von LLMs, um Malware zu identifizieren und erklären

- Slicing the output: previous and next n steps from an interesting node
- Add information to functions and literals
- Replace code with comments/existing explanations




3. Segen: Wo generative KI sinnvoll unterstützen kann

Beispiel: Automatische Erkennung von DSGVO-relevanten Codestellen mittels LLM

Problem:


- Privacy Review von Source Code muss stets aktuell sein
- Sehr arbeitsintensiv

Ziel: LLMs für die Erkennung von persönlichen Daten




Zwischenfazit: GenAI für Cybersicherheit hat viel Potential

- **Generative KI als Assistenz**
 - für Sicherheits-Analysten, Software-Entwickler: sicherer Code
 - für System-Verantwortliche: Compliance Prüfung, Detection Engineering
 - für die Ausbildung: lernen, erklären fehlerhafter Code-Snippets
 - für personalisierte Sicherheits-Unterstützung: zugeschnitten auf Experten-Level
- **LLMs zur Erkennung und Erklärung**
 - Erkennung von Schwachstellen durch z.B. Ähnlichkeitssuche auf CWE- oder CVE-Einträgen
 - Identifikation, Erklärung von Root Causes von Crashes bei Fuzzing-Tests



Aber offene Diskussion:

- Wo sind Grenzen für den Einsatz von Gen AI?
- Nutzung autonomer Agents versus Souveränität und Kontrollierbarkeit?



4. Anforderungen an vertrauenswürdige KI-Ökosysteme

Ziel: Sichere und vertrauenswürdige Nutzung von KI-Ökosysteme

- Blick auf KI-Modelle/Algorithmik greift zu kurz!
- Kontrollierbarkeit:
 - klare Systemgrenzen, differenzierte Rechte, klare Rollen/Verantwortlichkeiten
- Robustheit:
 - Schutz vor Prompt-Injection, adversarialen Angriffen, Data-Poisoning
- Integrität & Provenance:
 - Daten-Qualität, Herkunftsnachweise, Versionierung und Signierung von Modellen und Daten
- Nachvollziehbarkeit:
 - Logging, Traceability, reproduzierbare Entwicklungs- und Betriebsprozesse
- Betriebssicherheit:
 - Monitoring, Incident-Management, kontrollierte Updates, Einschränkbarkeit von KI-Funktionen

Erforderlich: Governance-Strukturen mit Regeln, Prozessen, Verantwortlichkeiten für KI-Ökosysteme!



4. Regulatorik: Anforderungen des EU AI Act



Kern-Message

- Der AI Act verlangt **keine perfekte KI**,
- sondern **kontrollierbare, nachvollziehbare und verantwortbare KI-Systeme**
- Regulierung adressiert **Architektur, Prozesse und Governance** – nicht nur das Modell
- AISEC arbeitet an **Metriken und Prüfkatalogen** zur Überprüfung

- **Risikomanagement über den gesamten Lebenszyklus**
 - Systematische Identifikation und Bewertung von Risiken
 - Berücksichtigung von Fehlverhalten, Fehlentscheidungen und unbeabsichtigten Wirkungen
 - Regelmäßige Neubewertung bei Änderungen von Daten, ...
- **Transparenz & Nachvollziehbarkeit**
 - Dokumentation von Modell, Datenquellen und Systemgrenzen
 - Nachvollziehbare Funktionsweise und Entscheidungslogik
 - Transparenz gegenüber Nutzern, Betreibern und Aufsicht
- **Daten- und Modellgovernance**
 - Kontrolle über Trainings-, Feinjustierungs- und Betriebsdaten
 - Maßnahmen zur Sicherstellung von Datenqualität und Integrität
 - Umgang mit Bias, Drift und unerwartetem Verhalten
- **Menschliche Aufsicht**
 - Klar definierte Rollen und Eingriffsmöglichkeiten
 - Fähigkeit zum Übersteuern, einschränken von KI-Funktionen
 - Keine vollständig unkontrollierte Automatisierung in high-risk Sz.
- **Robustheit, Sicherheit und Betrieb**
 - Schutz vor Manipulation, Misskonfiguration und Kontextangriffen
 - Monitoring im laufenden Betrieb, Incident-Handling , Updates

5. Resilienz als Gestaltungsaufgabe

Erkenntnis 1:

Generative KI-Modelle sind Teil komplexer digitaler KI-Ökosysteme

- KI-Modelle sind nicht isoliert, sie werden in Ökosystemen betrieben
- Risiken für KI-Nutzung durch starke Abhängigkeit von digitalen Technologien: Cloud, IAM

Erkenntnis 2:

- Verstärkt Risiken durch Kopplung von KI mit Aktionen (Agentic AI)
- Verstärkt Risiken durch hohen Automatisierungsgrad bei geringer Transparenz

Gestaltungsauftrag:

- Defense-in-Depth Absicherung: Modelle + Plug-ins + RAG + Supply-Chain
- Alternative Modelle, Wissensbasen bereitstellen: z. B. über Open Source, domänen-LLM
- Vertrauenswürdige Plattformen betreiben: z.B. basierend auf Confidential Computing

Take Home Message

Generative KI und die Bedeutung für die Cybersicherheit:

- Verändert Sicherheitsrisiken **quantitativ und qualitativ**
→ Fluch!
- Hat das Potential, mittelfristig das Sicherheitslevel in Unternehmen zu erhöhen
→ Segen!



Noch ist das Spiel offen: wir haben viele Gestaltungsmöglichkeiten:

- Neue Ansätze zur Steigerung der Robustheit, Nachvollziehbarkeit, Kontrollierbarkeit und Zertifizierungsschemata müssen entwickelt und integriert werden.
- Alternativen entwickeln, um digitale Abhängigkeiten zu reduzieren: z.B. OSS
- Governance und Tooling entwickeln, um Anforderungen automatisiert umzusetzen



Fraunhofer-Institut für Angewandte
und Integrierte Sicherheit AISEC

Vielen Dank für Ihre Aufmerksamkeit




Kontakt

Claudia Eckert
Fraunhofer-Institut für Angewandte und
Integrierte Sicherheit AISEC
Lichtenbergstraße 11
85748 Garching bei München
marketing@aisec.fraunhofer.de
wwwaisec.fraunhofer.de



@FraunhoferAISEC



[Webseite](#)



[Anmeldung zum
Newsletter](#)



[Cybersecurity Blog](#)