

# Herausforderungen der Künstlichen Intelligenz im Kontext der Cybersicherheitsentwicklung

Claudia Plattner, Präsidentin BSI

19. April 2024

# Kompetenzzentrum Künstliche Intelligenz des BSI

## IT-Sicherheit für KI

Wir untersuchen neuartige Bedrohungen für KI-Systeme und entwickeln geeignete Gegenmaßnahmen

## Angriffe durch KI

Wir verfolgen neue KI-gesteuerte und KI-unterstützte Angriffsmethoden gegen IT-Systeme und Infrastrukturen und entwickeln geeignete Gegenmaßnahmen

## IT-Sicherheit durch KI

Wir ermöglichen die Nutzung von KI-Methoden zur Verbesserung der IT-Sicherheit, z. B. zur Prävention, Detektion und Reaktion bei Cyber-Angriffen

## KI und digitaler Verbraucherschutz

Wir fördern den sicheren und transparenten Einsatz von KI-Methoden in Verbraucherprodukten und steigern die Beurteilungsfähigkeit der Verbraucherinnen und Verbraucher für KI-basierte Systeme

## Normen und Standards für KI

Wir entwickeln und bewerten Prüfkriterien, Prüfmethoden und Prüfwerkzeuge für nachweisbar sichere und vertrauenswürdige KI-Systeme mit dem Ziel, Normen und Standards für diese Systeme zu entwickeln



# Herausforderungen im Bereich KI

## Technologische Herausforderungen



- Spezielle KI-Eigenschaften sowie Komplexität erschweren die Sicherheitsbewertung
- Hochdynamisches Entwicklungsfeld macht stetige Entwicklung und Anpassung von Gegenmaßnahmen für Angriffe notwendig
- Ein sicherer Betrieb erfordert etablierte Best Practices und Standards




**Sicherheit, Transparenz, Erklärbarkeit, Verlässlichkeit, Robustheit und Nicht-Diskriminierung** stellen beim Einsatz von KI generell eine Herausforderung dar

## Geopolitische Herausforderungen

- Kritische Abhängigkeiten im Bereich Software und Hardware von Anbietern aus nicht EU-Staaten
- Staatlicher Einsatz von generativer KI im Bereich Desinformation

## Personelle Herausforderungen

- Qualifiziertes Fachpersonal ist begrenzt verfügbar
- Wachsender KI-Einsatz steigert Bedarf an Experten
- Austausch und Vernetzung von Spezialisten sowie Bündelung der Kräfte werden immer wichtiger



Quelle: Nicholas Carlini, Scientist @ Google DeepMind



# Einfluss von KI auf die Cyberbedrohungslage

## Chancen für Angreifer und Verteidiger

### Beispiel: KI-assistierte Ransomware-Angriffe

- KI-Programmierassistenten
  - **beschleunigen** Erstellung von Schadcode
  - verringern benötigtes Vorwissen
- KI **beschleunigt** die Analyse und Ausnutzung von Schwachstellen
- KI ermöglicht **skalierbare** Verteilung von Schadsoftware durch hochwertiges & individualisiertes Social Engineering
- KI **beschleunigt** Auswertung exfiltrierter Daten
- KI „unterstützt“ Betroffene bei Bezahlung des Lösegelds in Kryptowährung

**Kein Zukunftsthema: Angreifer nutzen KI bereits heute**

- > KI ermöglicht **höhere Produktivität** (Geschwindigkeit von Angreifern)
- > KI ermöglicht **skalierbare Angriffe** (über Sprachbarrieren hinweg)

**Cybersicherheit muss Top-Priorität sein**  
**KI-Produktivitätsgewinn auch für Verteidigung nutzen**

## Einflussfaktoren



# Sicherheitsherausforderungen in Bezug auf Nutzung von großen KI-Sprachmodellen

## Vielfältiges Nutzungspotential



## Sicherheitsherausforderungen

Fehlende Faktizität und Halluzinieren  
 Fehlende Erklärbarkeit  
 Eingeschränkte Reproduzierbarkeit  
 Vertraulichkeit eingegebener Daten




Adversarial attacks  
 (Indirect) prompt injections  
 Poisoning attacks  
 Privacy attacks

SCHWACHSTELLE | GEFÄHRDUNG | VORFALL | IT-ASSETS

## Indirect Prompt Injections - Intrinsische Schwachstelle in anwendungsintegrierten KI-Sprachmodellen

CSW-Nr. 2023-249034-1032, Version 1.0, 18.07.2023



- Technologiebedingte Schwachstelle
- Systematische Risikoanalyse durchführen
- Mitigationsmaßnahmen beachten

# Zusammenarbeit und Unterstützungsmöglichkeiten




## Unterstützungsmöglichkeiten des BSI für Landesverwaltungen

Auf Dauer angelegte  
Kooperation

- **Verstetigte** und **vereinheitliche Unterstützung** der Länder zu hochdynamischen KI-Entwicklungen
- Bereitstellung von **Informationen** und **Tools**
- Projektbegleitende **KI-Sicherheitsberatung**
- **Austausch** von Best Practices und **Einbezug** und **Übersicht** zu Entwicklungen aus der **Forschung**
- Bereitstellung und Entwicklung von praxisnahen **Bewertungsverfahren** für KI
- Länderübergreifende Koordination zur **Mitgestaltung** von kommenden **KI-Normen** und **KI-Standards**

Fehlender Rechtsrahmen



- **Bündelung von Expertise** (KI, Cloud, Rechenzentrumssicherheit, Hochverfügbarkeit)
- **Lagebilder** für Länder
- **Austausch-Plattform** in Echtzeit
- Prüfung Hard-/Softwareprodukte
- **Detektion** für Ländernetze
- Koordinierung **IT-Sicherheitsvorfälle**

Zentralstelle

# Vielen Dank für Ihre Aufmerksamkeit!

## Kontakt

Claudia Plattner  
Präsidentin

Claudia.Plattner@bsi.bund.de  
<https://de.linkedin.com/in/claudiaplattner>

Bundesamt für Sicherheit in der Informationstechnik (BSI)  
Godesberger Allee 87  
53175 Bonn  
[www.bsi.bund.de](http://www.bsi.bund.de)

Das BSI als die Cyber-Sicherheitsbehörde des Bundes gestaltet Informationssicherheit in der Digitalisierung durch Prävention, Detektion und Reaktion für Staat, Wirtschaft und Gesellschaft.