


IT-Sicherheit, bes. KI

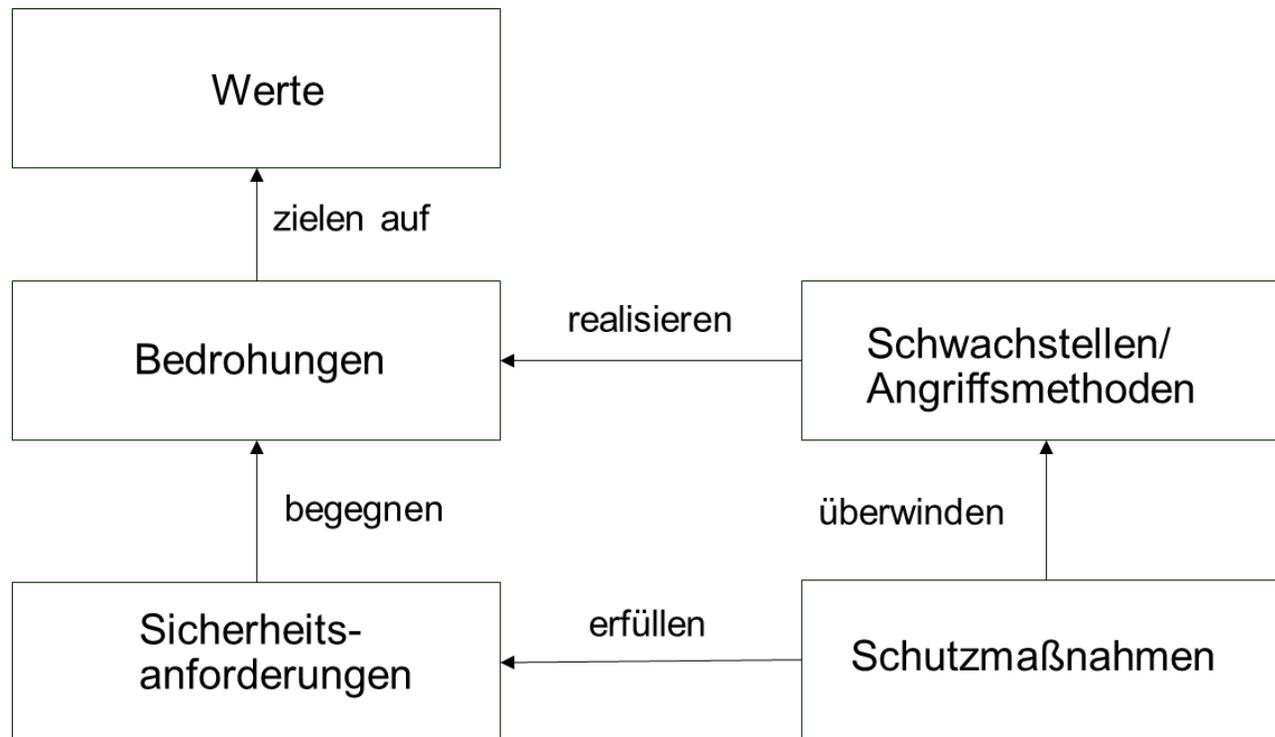
Stand der Technik

Saarbrücken
EDV-Tag Juris
11. September 2024

Prof. Dr. Rüdiger Grimm
Fellow GI
Universität Koblenz
Fraunhofer SIT Darmstadt



I. Begriffliche Einordnung



II. Bedrohungen - Sicherheitsanforderungen

1. Missbrauch personenbezogener Daten – Privatheit/Datenschutz
2. Lauschen und Spionage – Vertraulichkeit
3. Fälschen – Integrität
4. Identitätsdiebstahl – Korrekte Herkunft (Originalität)
5. Dienstverweigerung (Denial of Service) – Verfügbarkeit
6. Ableugnen – Nicht-Abstreitbarkeit
7. Eindringen und Hacking – Zugriffskontrolle

II a. Moderne Bedrohungen

8. Kriminalität

- Angriffe mit dem Ziel der illegalen Bereicherung
- zB. Lahmlegen – Erpressen (Unis Gießen 2019, Essen 2022)
- Vorbereitung krimineller Aktivitäten
- Verwischen von Spuren, z.B. Anonymität, Darknet

9. Cyberwar

- Gegen kritische Infrastrukturen
- Desinformation
- Spionage

10. KI – das unbekannte Wesen

s.u. #10 ff

III. Besondere Angriffstechniken

1. Kryptoanalyse
2. Viren, Würmer, Trojanische Pferde
3. Bot-Netze: Kapern von PCs
4. SPAM, Phishing, Pharming: Stehlen von Zugangsdaten
5. DDoS – Distributed Denial of Service
6. Tracking/Tracing
7. Unautorisierte Ausforschung und Big Data
8. Medienfälschung
9. **Maschinelles Lernen zur Unterstützung von Angriffen**

s.u. #13

IV. Grundlegende Schutzmaßnahmen

1. Rechtliche, technische und organisatorische Maßnahmen 
2. Kryptografie
3. Digitale Signatur
4. Post-Quantum-Verschlüsselung 
5. Smartcards und TPM
6. Digitale Wasserzeichen
7. Authentifizierung und Zugriffskontrolle
8. **Maschinelles Lernen zur Abwehr von Angriffen** 
9. Abwehr, Aufdeckung und Prävention
10. Security by Design und Privacy by Design

Zu „IV.1 Rechtliche + technische + organisatorische Maßnahmen“

- Beispiel Persönlichkeitsschutz – Löschfristen
 - Datenschutz GVO
 - Löschverfahren
 - Datenschutzbeauftragte, Schulungen usw.
- Beispiel Urheberschutz
 - UrhG, bes. §106 Strafbewehrung; Orga-RL (z.B. DFN)
 - Wasserzeichen, Ähnlichkeitserkennung, Plagiat-SW
 - Medienbeauftragte, Aufklärung usw.
- Beispiel Cyberverteidigung
 - Meldepflichten NIS-2 (EU-RL seit 2022)
 - Erkennung von Angriffen
 - Sicherheitsbeauftragte, Schulungen usw.

Zu IV.4 „Post-Quantum-Verschlüsselung“

- Quantencomputer (QC)
 - unentschiedene Quantenzustände für hochparalleles Rechnen
 - Brechen von Kryptoverfahren durch Brute-Force-Rechnung
 - In 10-20 Jahren einsatzbereit
- QC-Resistenz für langlebige Produkte und Verfahren
 - Medizin
 - industrielle Produktionssteuerung
 - Entwicklung von Autos, Flugzeugen und Raumfahrt

... 4. Post-Quantum-Verschlüsselung

- NIST-Kandidaten für QC-Resistenz
 - selbstkorrigierende Code-Fehler-Verfahren
 - Hashbäume
 - Gleichungssysteme mit multivariaten Polynomen
 - mathematische Gitter
 - sogenannte Isogenien supersingulärer elliptischer Kurven
- CRYSTALS-KYBER und CRYSTALS-Dilithium
- **To do:** Verbesserung, Inventarisierung, normierte Schnittstellen

V. KI – Maschinelles Lernen

- Computerprogramme entwickeln Algorithmen und Modelle, die in großen Datenmengen Muster und Beziehungen erkennen und daraus zugehörige Vorhersagen oder Entscheidungen ableiten
- Nützliche Anwendungen
- Aber auch: Angriffe

Starke und schwache KI

- Starke KI
 - wie Menschen selbstständig Situationen verstehen, aus ihnen lernen und daraufhin in neuen Situationen Urteile fällen und Probleme lösen („Turing-Test“)
 - „...not yet a reality...“
- Schwache KI, Maschinelles Lernen
 - Data Mining: große Datenmengen analysieren und für diese Antworten auf konkrete Anwendungsfragen entwickeln
 - „überwachtes“ bzw. „unüberwachtes Lernen“

„Überwachtes“ bzw. „unüberwachtes Lernen“

- „Überwachtes Lernen“
 - Ziel: korrekte Aussagen über unbekannte Daten
zB Bilder: „Das ist eine Katze“
 - Trainingsphase mit „wahr/falsch“-markierten Bildern
 - Klassifizierung von Daten, zB Bilder, Spam, kriminelle Kommunikation, Betrug
 - Prognosen zukünftiger Ereignisse, zB Aktienkurse, kriminelle Handlungen
- „Unüberwachtes Lernen“
 - Ziel: bisher unbekannte Muster in oder Beziehungen zwischen Daten finden
 - Nicht für Prognosen, sondern
 - Reduktion von Eigenschaftsdimensionen, zB Datenkompression
 - Gruppenbildung (Clustering), zB Anomalien (Muster auch ohne Trainingsphasen), zB Kundensegmentierung, zB Kaufempfehlungen

Zu „III.9 Angriffe mit KI – Maschinelles Lernen“

- Dynamisches Fälschen von Videomaterial („Deep Fake“)
https://www.sit.fraunhofer.de/fileadmin/videos/Anwendertag_2024_01_final.mp4
- Einstreuen von Propaganda in politische Internetforen
(Wahlkampf)
- Suche nach Schwachstellen im Netz
- Design von Authentifizierungsmaterial
(Bilder, Texte, Passwörter)
- Irreführung „guter“ Lernverfahren
Verfälschung der Trainingsdaten oder der Zielfunktion

- **Irreführung „guter“ Lernverfahren**

Beispiel **Adversarial Examples:**

Fälschung von Trainingsdaten,
die gezielt verändert werden,
um Fehlentscheidung des Modells zu provozieren

zB durch Löschen von Erkennungsmerkmalen

zB durch Einbringen falscher Erkennungsmerkmale



„Leckere Birnen“

Zu „IV.8 Abwehr mit KI – Maschinelles Lernen“

- Erkennung von Kommunikationsanomalien im Netz („Intrusion Detection“)
- KI-Klassifikation: Filtern von
 - unangemessene Bilder aus massenweisem Bildmaterial
 - kriminelle Kommunikation in Chatforen
 - Betrugsmaschen oder ungewöhnliches Kaufverhalten im E-Commerce
 - unstimmmiges Authentifizierungsmaterial in lernbaren Mustern oder Datenrelationen
- KI-Verteidigung von KI-Angriffen

... IV.8 ... KI-Abwehr von KI-Angriffen

- GAN – Generative Adversarial Networks
 - **Zwei** konkurrierende Künstliche Neuronale Netze:
 - **Generator** als Angreifer generiert künstliche Daten
 - **Diskriminator** als Verteidiger erkennt Daten als echt oder künstlich
- zB. Authentifizierungsmaterial
 - Eindringling lernt täuschen
 - Diskriminator lernt erkennen
- Generator = „böse“? Nicht unbedingt:
 - Hochqualitative künstlich erzeugte Daten sind wertvolle Trainingsdaten für „gute“ KI-Lernverfahren
 - zB Ziel, mithilfe von GAN Privatheit-schützende Trainingsdaten herzustellen

Fazit

- KI ist nicht gut oder böse
- Nutzung von KI erfordert Transparenz
- Herrschaftsanspruch: Wer trainiert die Systeme?
- Welche Sprachkultur dominiert ChatGPT?
- KI erfordert aktive Gestaltung
- Jugend muss KI kennen und einschätzen lernen

Literaturverweis:

Hornung, G.; und Schallbruch, M. (Hrsg.): IT-Sicherheitsrecht, Praxishandbuch, Nomos, 2. Auflage 2024, ca. 1000 Seiten, gebunden ISBN 978-3-7560-0496-6.

Darin §2: IT-Sicherheit aus technischer Sicht (Grimm/Waidner)