Westfälische Hochschule
Gelsenkirchen Bocholt Recklinghausen
University of Applied Sciences

IT-Sicherheit *und* Künstliche Intelligenz

Prof. Dr. (TU NN)
Norbert Pohlmann

Professor** für **Cyber-Sicherheit** und **Leiter** des **Instituts für Internet-Sicherheit – if(is), Westfälische Hochschule, Gelsenkirchen
Vorstandsvorsitzender Bundesverband IT-Sicherheit - TeleTrusT
Vorstand im Verband der Internetwirtschaft - eco

if(is) internet-sicherheit.

Inhalt

- Einordnung, Definitionen, Begriffe und Prinzipien
- Künstliche Intelligenz für IT-Sicherheit
- Angreifer nutzen Künstliche Intelligenz
- IT-Sicherheit für Künstliche Intelligenz
- Künstliche Intelligenz braucht Vertrauen
- Zusammenfassung und Ausblick

Einordnung
→ (Künstliche Intelligenz) **Maschinelles Lernen**

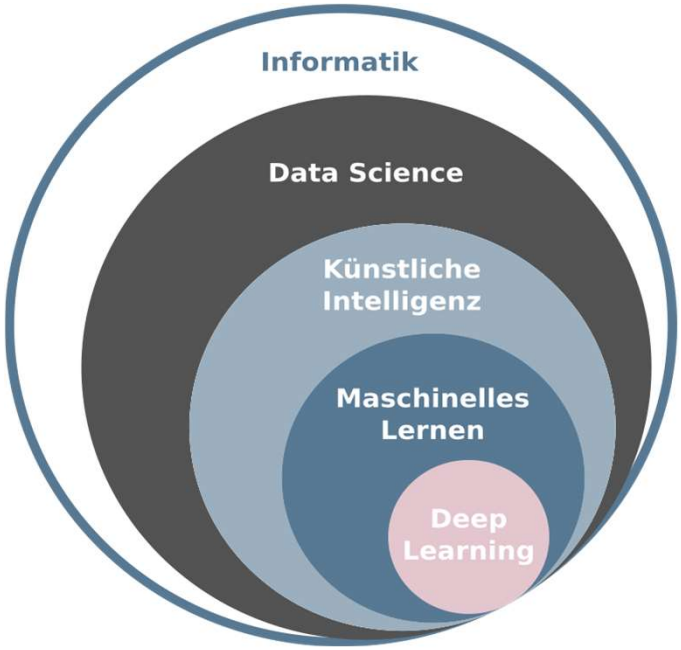

- **Data Science** bezeichnet generell die **Extraktion von Wissen aus Daten**.
- **Starke „Künstliche Intelligenz“** *(Zukunft)*
  soll automatisiert „**menschenähnliche Intelligenz“** nachbilden.
  Singularität, Artificial General Intelligence (AGI) - („Maschinen“ verbessern sich selbst, *sind „intelligenter“ als Menschen*)
- **Schwache „Künstliche Intelligenz“** *(heute sehr erfolgreich)*
  Maschinelles Lernen (ML) ist ein Begriff für die **Generierung von Wissen aus Erfahrung** (in Daten) durch Computer.
- **Deep Learning** → Methode des MLs → **verbesserte Ergebnisse**
- **Large Language Modell (LLM)** Basismodell für generative KI ***(Stochastischer Papagei)***
- **Generative KI (GenAI)** *ist eine Form* der künstlichen Intelligenz, die *gestützt auf ihren Trainingsdaten* Texte, *Bilder*, Code und verschiedene andere **Inhalte produzieren** kann.

Singularität
→ Artificial General Intelligence (AGI)

- Singularität bezieht sich auf einen **hypothetischen Zeitpunkt**, bei dem sich die KI selbstständig so rasant entwickelt, das **wesentliche / unumkehrbar Veränderungen** für die **Menschheit** entstehen.
- **Folge**: Der Mensch verliert **die Kontrolle über die KI-Technologie** *und* **die Zukunft wird ungewiss** (*Innovationen*, Werte, *Wirtschaft*).
- **Chancen**: Es werden **Lösungen zu fundamentalen Fragen des Lebens geschaffen.**
- **Risiken**: Im Bereich der **Ethik**, **Unvorhersehbarkeit** und potenziell negative **Auswirkungen** des schnellen technologischen Fortschritts auf die Gesellschaft.

Singularität ist eine interdisziplinäre Herausforderung

- **Vollständigkeit** der genutzten der Daten / des (KI-)Wissens
- **Fehler** bei der Künstlichen Intelligenz (Algorithmus, Modell, Daten)
- **Physikalische Grenzen** der Leistungsfähigkeit, die „KI“ zu rechnen
- **Menschliche Restriktion:** genetisches Repertoire (Lernen / logischen Denken)

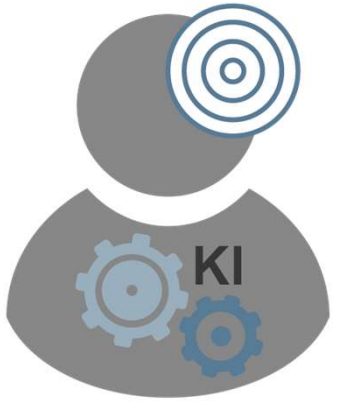

Singularität sollte nicht unser Ziel sein

→ **der Mensch muss die Kontrolle behalten**

→ **Superalignment** (**KI** agiert im Einklang mit menschlichen Werten und Zielen)

Ein Prinzip von Künstlicher Intelligenz (KI)
→ Garbage in – Garbage out

Paradigma

Standards für die Datenqualität:

→ **Inhalthöhe** der Daten und ***Korrektheit***
→ **Nachvollziehbarkeit** (Datenquellen)
→ ***Vollständigkeit*** und **Repräsentativität**
→ **Verfügbarkeit** und ***Aktualität***

Qualitativ hochwertige und sichere **Sensoren** motivieren

Weitere Aspekte zur Erhöhung der Qualität:

→ Datenpools etablieren
→ Austausch von Daten fördern
→ Interoperabilität schaffen
→ Open Data-Strategie puschen

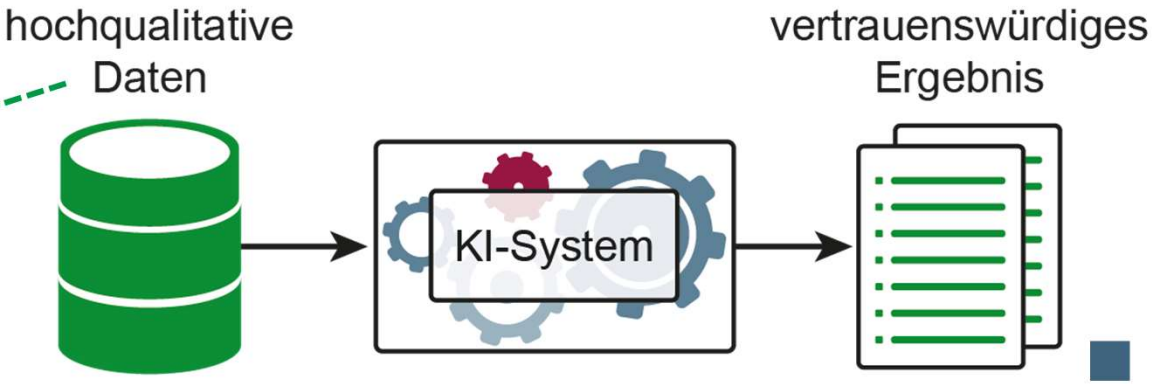

Vertrauenswürdigkeit von Ergebnissen
→ Umgang mit den KI-Ergebnissen

- **„Keep the human in the loop“**
  - KI-Ergebnisse werden als **Handlungsvorschlag** für den Nutzer verstanden.
  - *Dieses fördert die **Selbstbestimmtheit** des Nutzers und erhöht das Vertrauen*

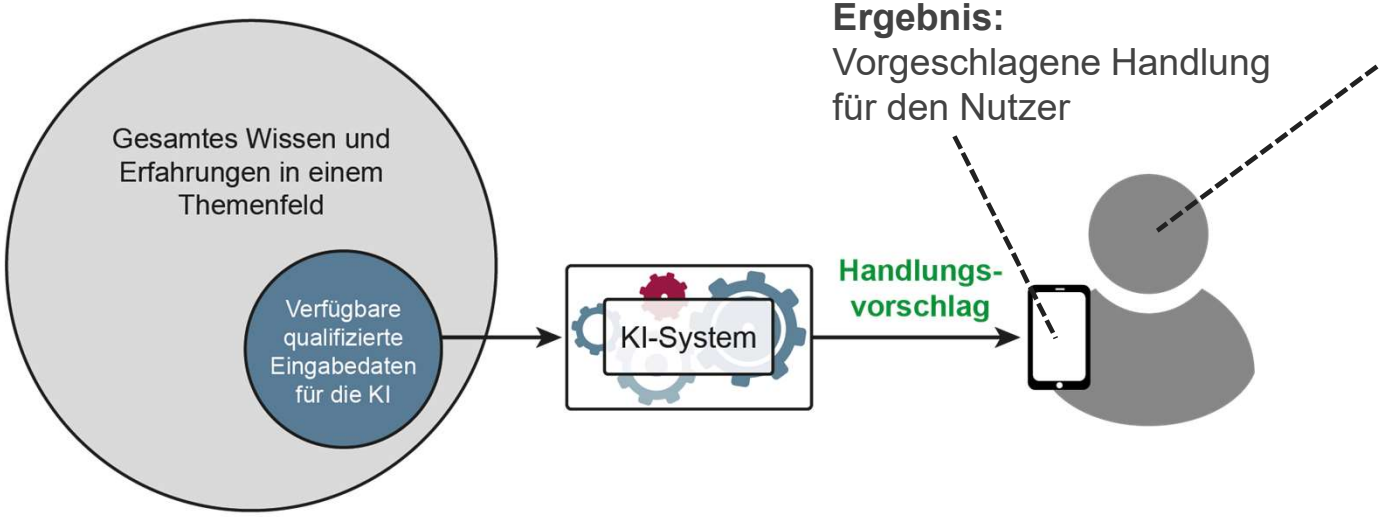

- **Automatisierte Anwendungen wie z. B. autonomes Fahren**
  - ***Hoher Aufwand:*** Simulation, Test und Validierung
  - ***Umgang mit dem Restrisiko:*** Verantwortung, Haftung und Versicherung

Künstliche Intelligenz für IT-Sicherheit
→ Erkennen von Angriffen

Erhöhung der **Erkennungsrate** von **Angriffen**

- Netzwerk, *IT-Endgeräte*, Server, *IoT-Geräte*, Cloudanwendungen …
- adaptive Modelle (neue Angriffe erkennen)
- Anomalien: normal *versus* verdächtig

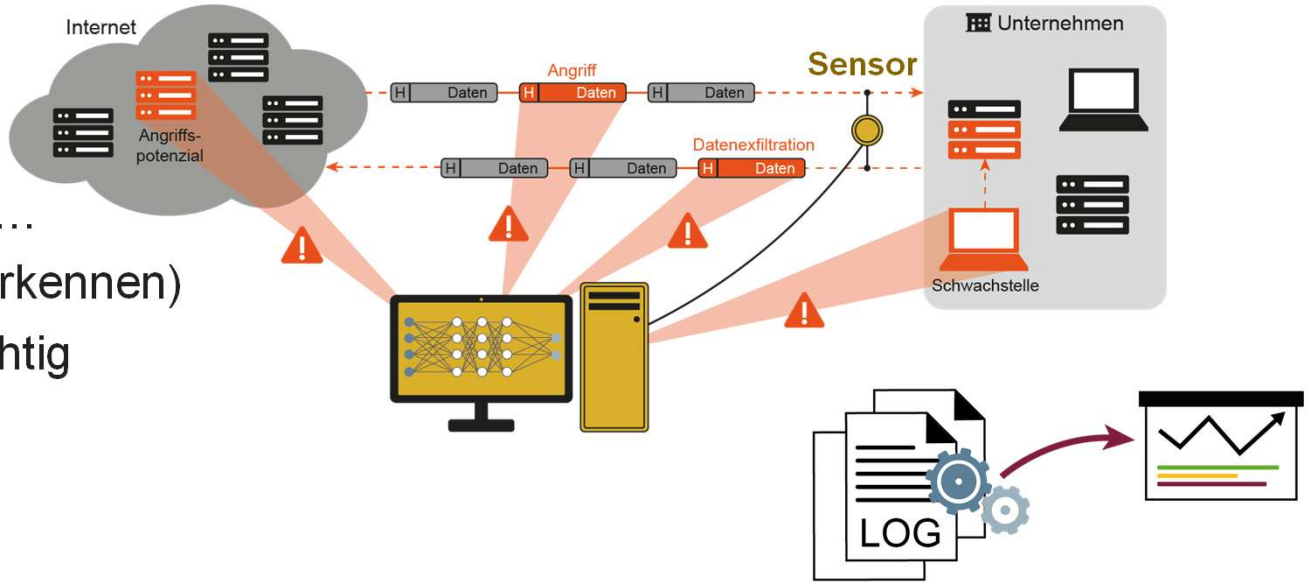

Weitere Bereiche, bei denen die verbesserte **Erkennung** eine wichtige Rolle spielt:

- Netze / Internet
- *Malware*, Spam …
- Fake-News
- *Deepfake*
- ...

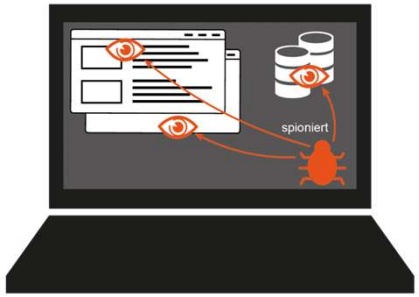

Künstliche Intelligenz für IT-Sicherheit
→ Unterstützung von IT-Sicherheitsexperten

if(is) internet-sicherheit.

Erkennen von **wichtigen sicherheitsrelevanten Ereignissen** mit einer **Priorisierung**

- **Idee:** IT-Sicherheitsexperten von **zeitaufwendiger Analysearbeit** zu **entlasten**.
- *Ein **KI-System analysiert** hunderte / tausende sicherheitsrelevante Ereignisse und zeigt, nach **welchen Prioritäten** diese **abgearbeitet** werden müssen.*

→ Dadurch wird der höchste Schutz **in der aktuellen Situation** für die Organisation erzielt.

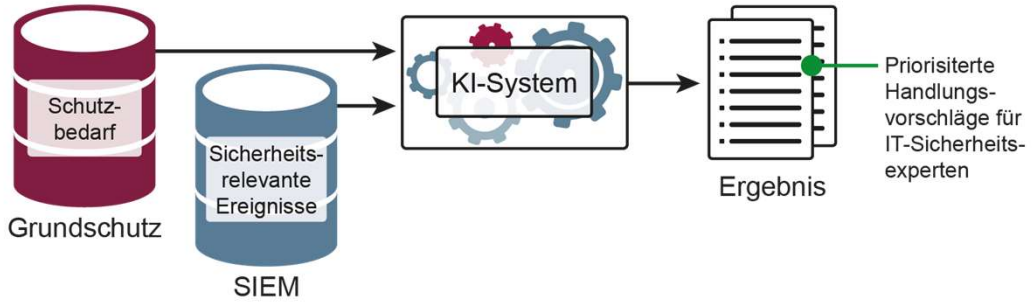

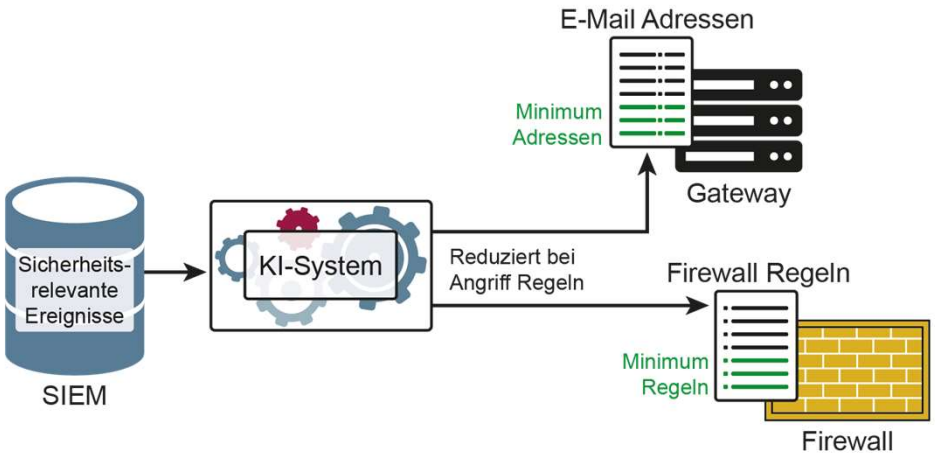

(Teil-)Autonomie bei Reaktionen

- **Idee:** Wenn ein Angriff oder eine besondere Bedrohung erkannt wird, werden sofort die **Firewall- und E-Mail-Regeln automatisch reduziert**.
- *Die **wichtigen Prozesse** für eine Organisation bleiben **erhalten** (Minimum Regeln).*

→ Dadurch wird **Angriffsfläche** für die Angreifer deutlich **reduziert** und damit Schäden verhindert.

Künstliche Intelligenz für IT-Sicherheit
→ Weitere Bereiche

Sichere Softwareentwicklung

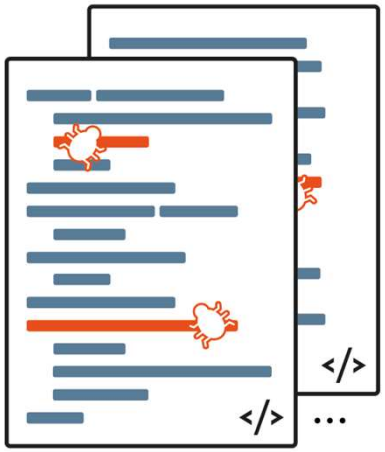

Threat Intelligence

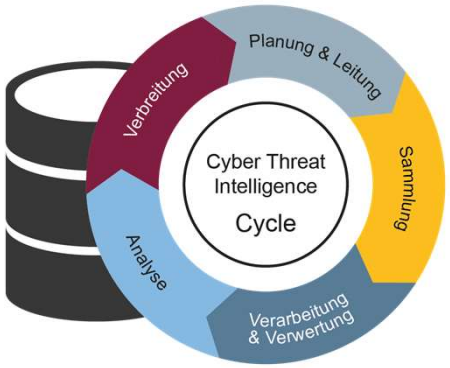

IT-Forensik

… und vieles mehr …

Angreifer nutzen Künstliche Intelligenz
→ Prinzipielle Angriffe

Angriffsvektoren identifizieren

- **Ziel**: Schwachstellen / Sicherheitslücken mithilfe von KI bei den Opfer IT-Systemen aufzudecken, um **Angriffsmöglichkeiten / -potentiale abzuschätzen** und **Angriffe durchzuführen**.

IT-Sicherheitsmaßnahmen überwinden

- **Ziel:** „Leuchtkegel“ (Schwellen, Sequenzen …) des Angriffserkennungssystems werden mithilfe von **KI so analysiert**, um mit den Ergebnissen **Angriffe unentdeckt** umzusetzen.

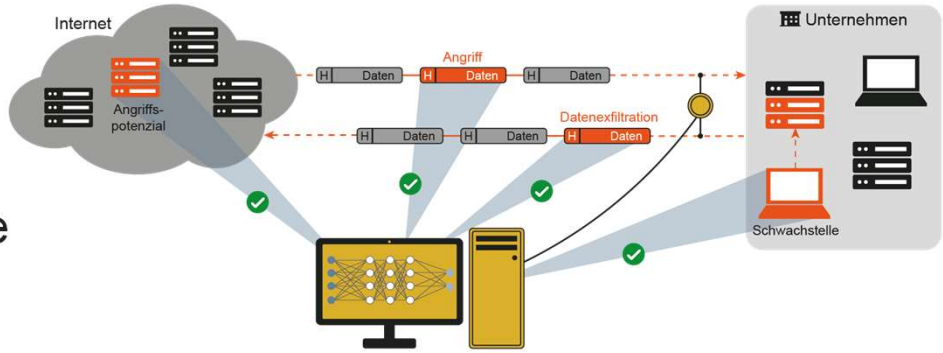

Automatisiertes Angreifen

- **Ziel:** Social Bots zur **automatischen Generierung** von **Fake-Accounts** und **Fake-News** zur Manipulation von Menschen.

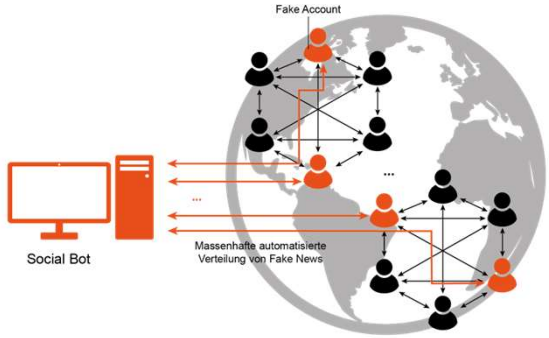

Angreifer nutzen Künstliche Intelligenz
→ ChatBots wie ChatGPT

Social Engineering+++

- Spear-Phishing (Erster Schritt für die meisten Angriffe)
- Fake-News (Manipulation Menschen / Gesellschaften)
- Deepfake (CEO-Fraud)

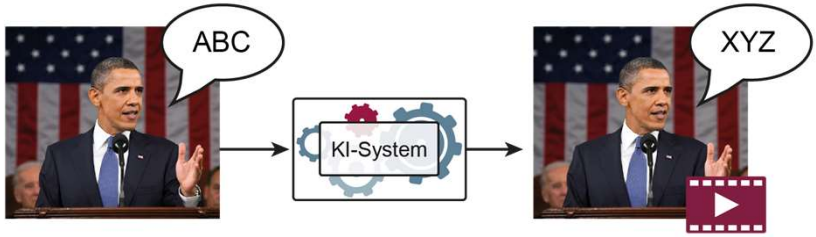

Beschleunigtes Entwickeln von Angriffen

- Polymorphe Malware

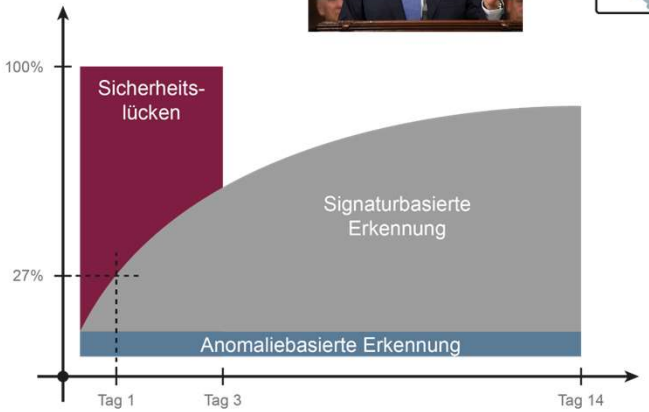

Vertrauliche Informationen als Input eines zentralen Dienstes

- Zusätzliche Angriffsfläche der vertraulichen Informationen
- Nicht-gewünschte Integration der vertraulichen Informationen in die Trainingsdaten

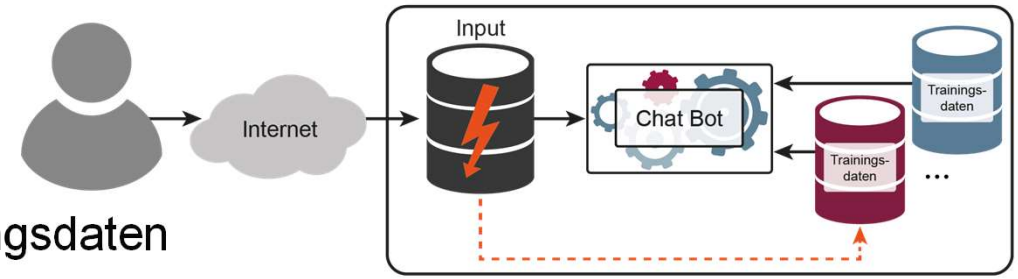

IT-Sicherheit für Künstliche Intelligenz

→ Angriffe

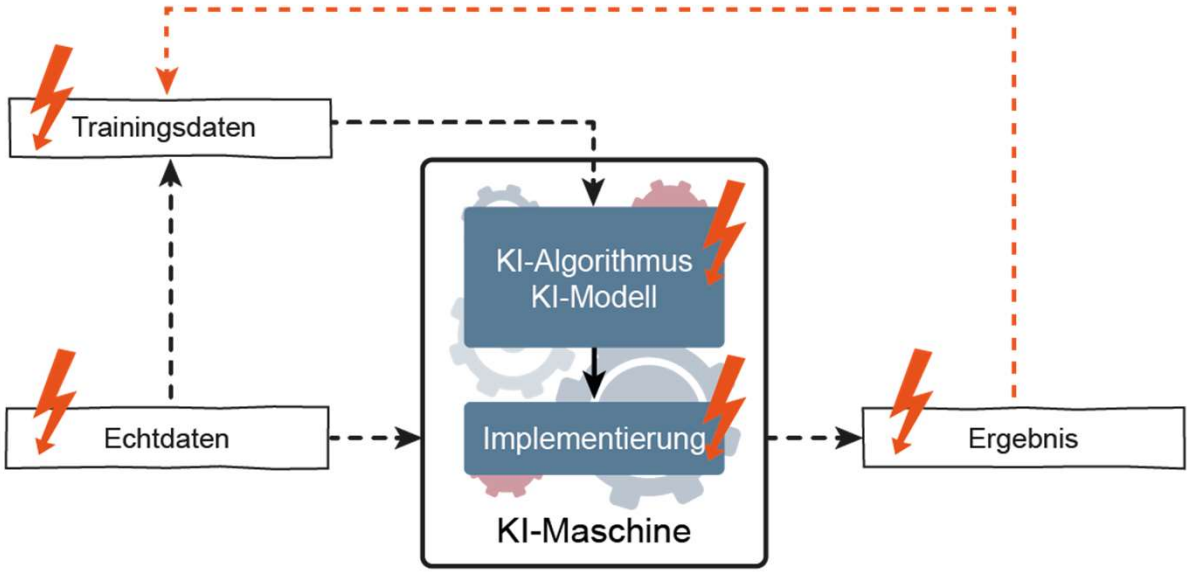

Angriffe auf KI-Systeme

→ *Poisoning Attack*

→ *Evasion Attack*

→ *Exploratory Attack*

→ *…*

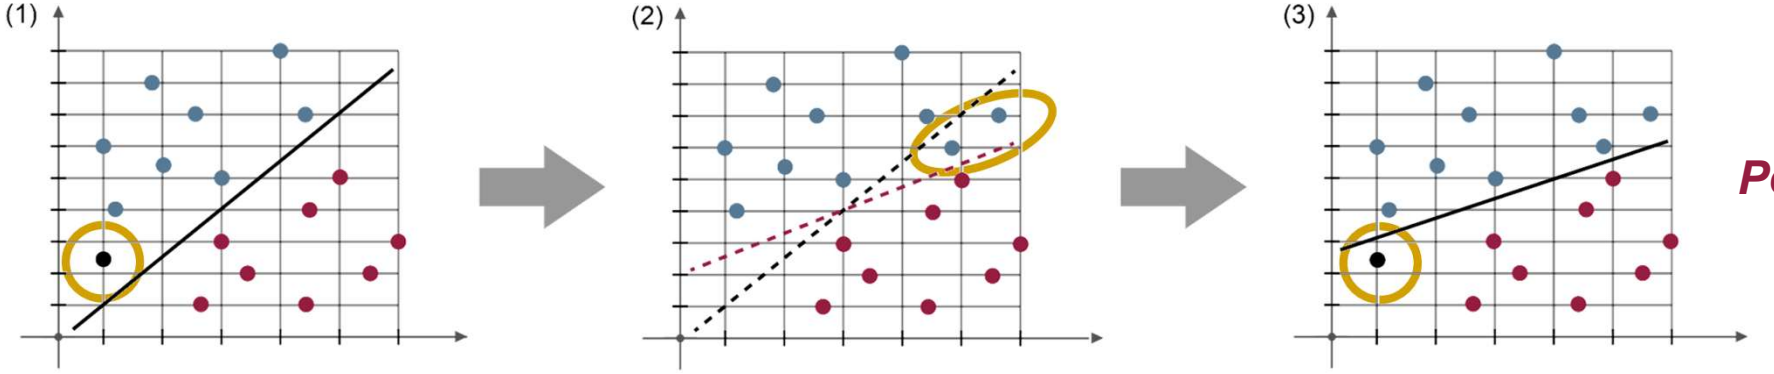

Poisoning Attack

IT-Sicherheit für Künstliche Intelligenz

→ IT-Sicherheitsmaßnahmen

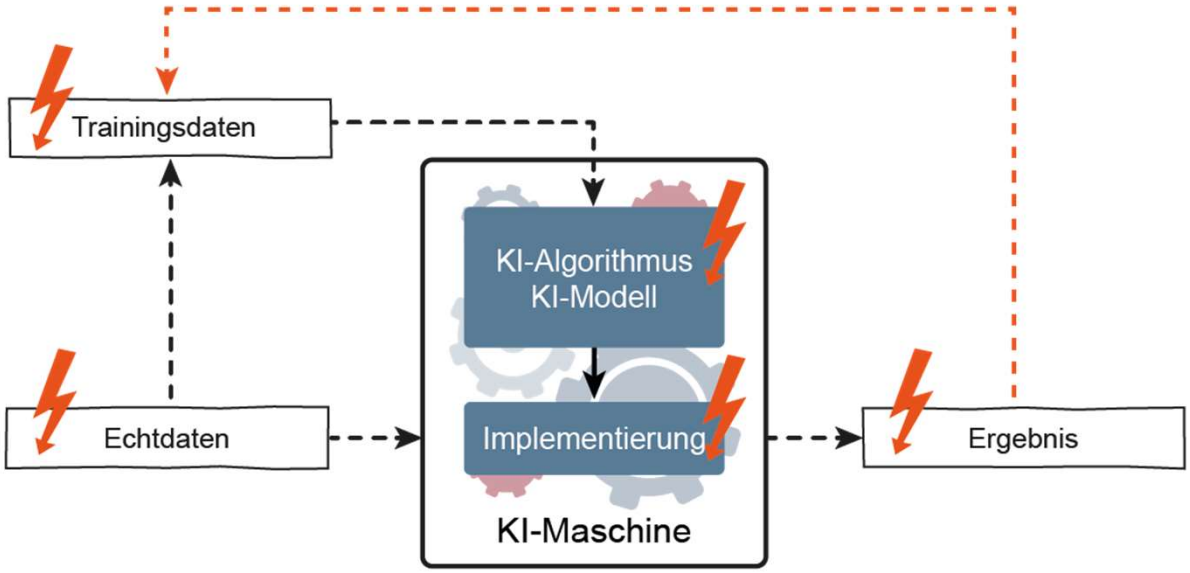

Nutzung** einer **qualitativ hochwertigen KI-Technologie

Schutzziele:

- → ***Integrität***
  (Erkennen von Manipulation der Daten)
- → ***Vertraulichkeit***
  (Wahrung von Geschäftsgeheimissen)
- → ***Datenschutz***
  (Schutz von personenbezogenen Daten)
- → ***Verfügbarkeit***
  (der Anwendung und Ergebnisse)

***Stand der Technik** bei den **IT-Sicherheitsmaßnahmen** nutzen*

- → *der **Daten** (Trainingsdaten, Echtdaten/Inputdaten, Ergebnisse),*
- → *der **KI-Maschine** (Algorithmen, Modelle, Implementierung) und*
- → *der **Anwendung***

Der Einsatz von KI basiert auf Vertrauen

→ Vertrauenswürdigkeit schafft Vertrauen

Status Quo: Aufgrund der Digitalisierung erhöht sich der Grad an Komplexität, wodurch es für den Anwender zunehmend schwieriger wird, einzelne ***KI-/IT-Sicherheit-Lösungen*** und deren Hintergründe ***verstehen*** und ***bewerten*** zu können.

Folge: Die ***Unsicherheit*** macht den Menschen Angst und ***schränkt*** sie in ihrer ***Handlungsfähigkeit ein***.

Fazit: Vertrauen ist unerlässlich, um handlungsfähig sein zu können.

Wichtig: Anwender wollen Vertrauen können.

Das bedeutet: KI-/IT-Sicherheit-Hersteller müssen vertrauenswürdig agieren.

Fazit: Damit der Anwender ein gerechtfertigtes Vertrauen in *KI-/IT-Sicherheit-Hersteller* sowie deren *KI-/IT-Sicherheit-Lösung* aufbauen kann, müssen diese alles tun, um ihre Zuverlässigkeit, Ehrlichkeit und ihre Qualifikation unter Beweis zu stellen.

Der Einsatz von KI basiert auf Vertrauen
→ Vertrauenswürdigkeitsmodell

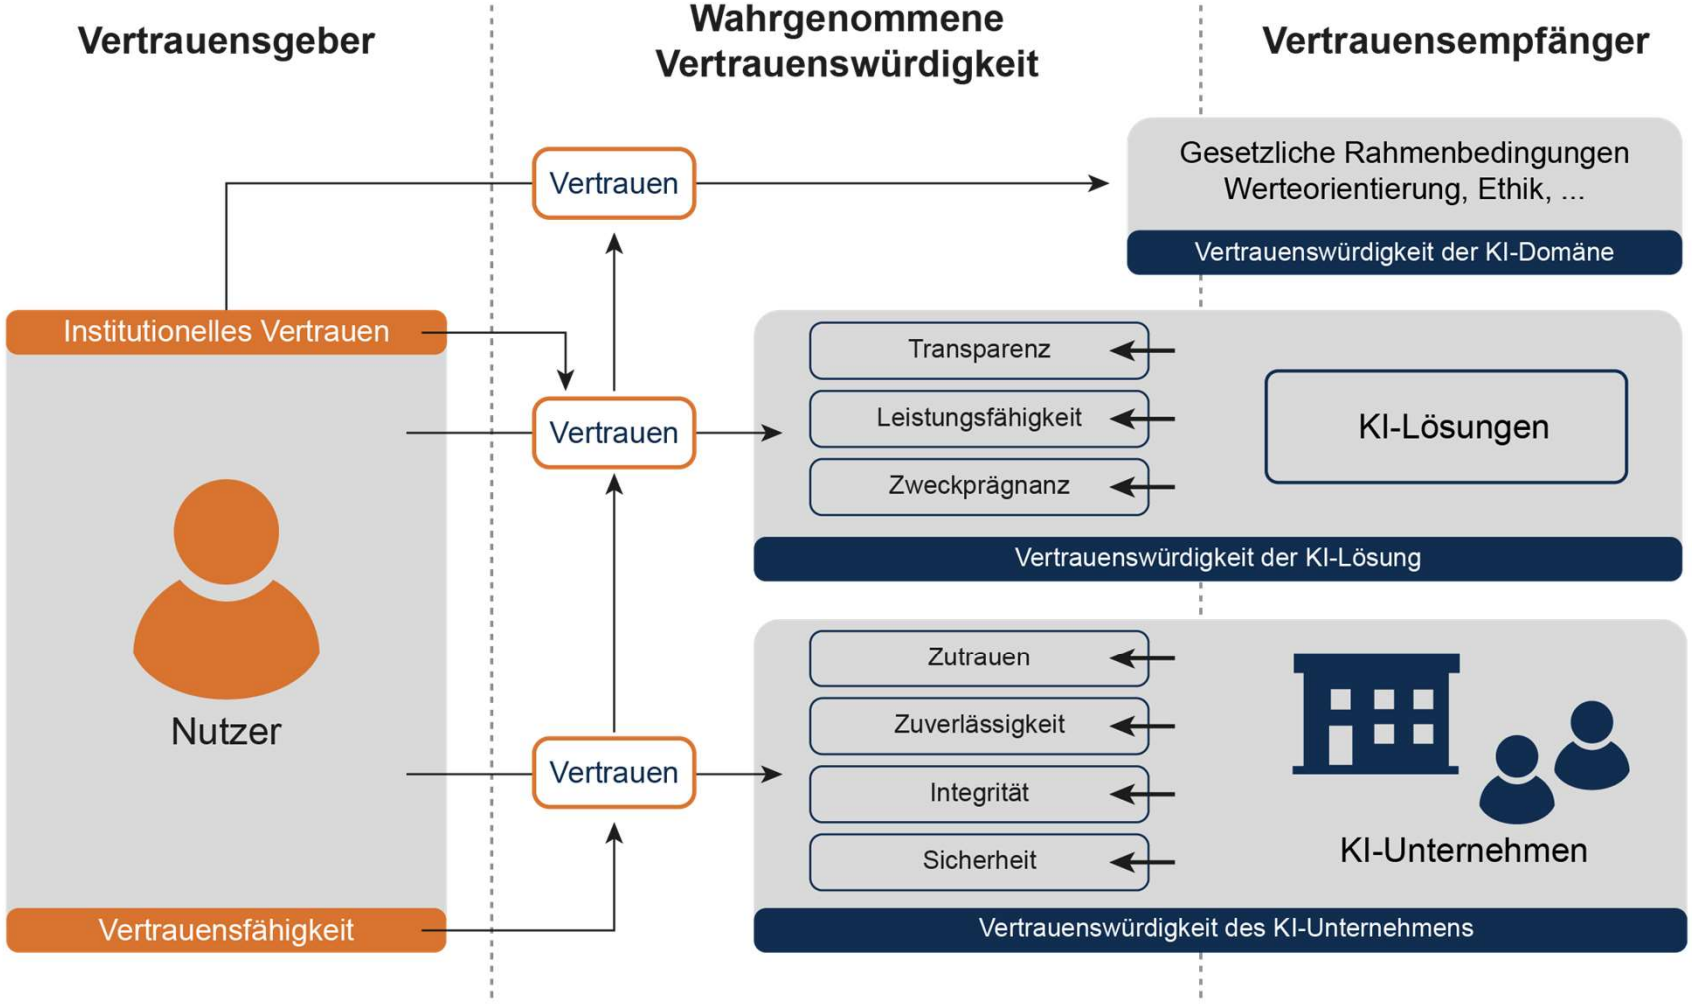

Beispiele ethischer Herausforderungen
→ Privatheit vs. Allgemeinwohl

- Eine **Notwendigkeit für die Auswertung von personenbezogenen Daten** von Mitarbeitern könnte sich zum Beispiel in dem Fall ergeben, wenn ein **Energieversorger** (Kritische Infrastruktur) **angegriffen wird**.

- **Es besteht das Dilemma:**
  Eine ethische Handlungsweise erfordert, dass grundlegende **Rechte wie die Privatheit** nicht zugunsten eines höheren Ziels vollständig aufgegeben werden dürfen.

- Dagegen steht gemäß **Utilitarismus** die **Prämisse des Strebens nach dem Gesamtnutzen für die Gesellschaft**.

- **Daraus resultiert die ethische Fragestellung:**
  Wann ist es angeraten die **Rechte des Individuums** zugunsten des **Wohles für die Gemeinschaft** aufzuheben?

Beispiele ethischer Herausforderungen
→ Strike Back: Problem Unvollständigkeit der Daten

- Dem Konstrukt des **‚Strike Back'** liegt die Hypothese zugrunde, dass **ein Angriff durch einen Gegenangriff beendet** werden kann.
- Die KI kann den Strike Back berechnen und automatisiert durchführen.
- Aber was ist, wenn dies gleichzeitig auch die Stromversorgung eines Krankenhauses lahmlegen würde?
- **Die ethische Frage in diesem Kontext müsste lauten:**
  Ist es möglich die Vollständigkeit der Daten zu erreichen und deren Relevanz zu beurteilen damit eine KI die richtige Entscheidung treffen kann?

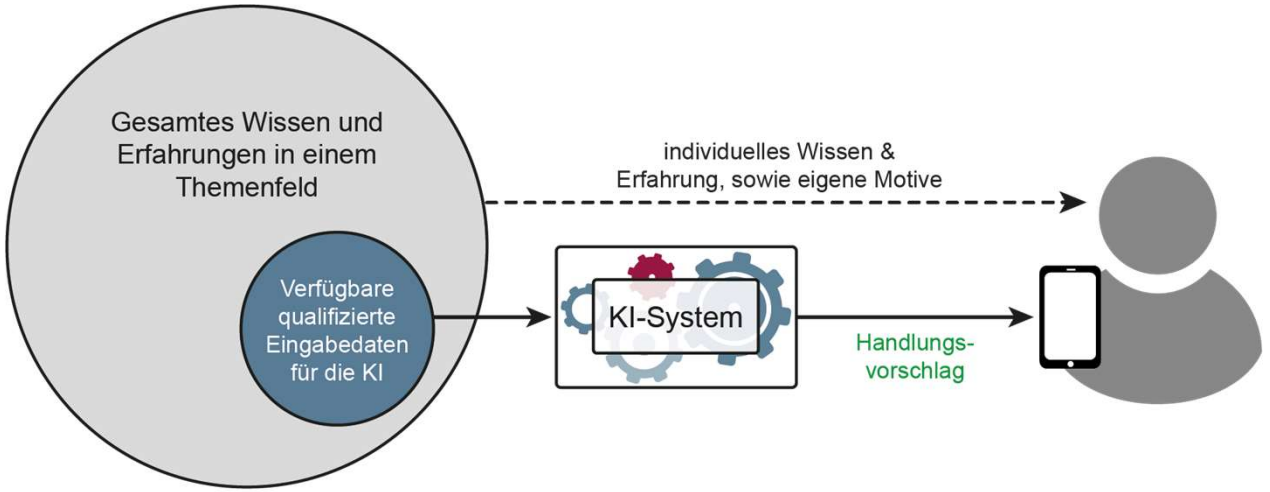

IT-Sicherheit *und* Künstliche Intelligenz
→ Zusammenfassung und Ausblick

- **Künstliche Intelligenz ist eine sehr wichtige Technologie im Bereich der IT-Sicherheit**
  - Erkennen von Angriffen, Bedrohungen, Schwachstellen, Fake-News ...
  - Unterstützung / Entlastung von IT-Sicherheitsexperten
  - Sichere Software-Entwicklung
  - ...
- **Wir müssen unsere KI absichern, damit sie vertrauenswürdige Ergebnisse liefern kann**
  - Hacker greifen an und manipulieren Daten, Algorithmen/Modelle und Ergebnisse
  - ...
- **Machtverhältnis zwischen Angreifern und Verteidigern muss sich verändern**
  - Die Angreifer nutzen KI sehr professionell und erfolgreich für ihre Angriffe
  - Die Verteidiger müssen KI deutlich intensiver - gemeinsam mit allen Verteidigern - umsetzen
  - Der Austausch von sicherheitsrelevanten Daten, wird helfen, besser zu werden
  - ...

Westfälische Hochschule
Gelsenkirchen Bocholt Recklinghausen
University of Applied Sciences

IT-Sicherheit *und* Künstliche Intelligenz

*Wir brauchen die **KI** in der **IT-Sicherheit**.*
*Aber: Wir müssen auch die **Risiken** der **KI** aktiv **reduzieren**!*

Prof. Dr. (TU NN)
Norbert Pohlmann

Professor** für **Cyber-Sicherheit** und **Leiter** des **Instituts für Internet-Sicherheit – if(is), Westfälische Hochschule, Gelsenkirchen
Vorstandsvorsitzender Bundesverband IT-Sicherheit - TeleTrusT
Vorstand im Verband der Internetwirtschaft - eco

if(is) internet-sicherheit.

Anhang / Credits

Wir empfehlen

Cyber-Sicherheit

Das **Lehrbuch** für Konzepte, Mechanismen, Architekturen und Eigenschaften von Cyber-Sicherheitssystemen in der Digitalisierung“, Springer Vieweg Verlag, Wiesbaden 2022
https://norbert-pohlmann.com/cyber-sicherheit/

7. Sinn im Internet (Cyberschutzraum)

https://www.youtube.com/cyberschutzraum

CYBER SCHUTZRAUM

Master Internet-Sicherheit

https://it-sicherheit.de/master-studieren/

(M) MASTER internet-sicherheit.

Glossar Cyber-Sicherheit

https://norbert-pohlmann.com/category/glossar-cyber-sicherheit/

Cyber-Sicherheit GLOSSAR

It‘s all about Trust!

https://vertrauenswürdigkeit.com/

Quellen Bildmaterial

Eingebettete Piktogramme: Institut für Internet-Sicherheit – if(is)

Besuchen und abonnieren Sie uns :-)

WWW
https://www.internet-sicherheit.de

Facebook
https://www.facebook.com/Internet.Sicherheit.ifis

Twitter
https://twitter.com/_ifis

https://twitter.com/ProfPohlmann

YouTube
https://www.youtube.com/user/InternetSicherheitDE/

Prof. Norbert Pohlmann
https://norbert-pohlmann.com/

Der Marktplatz IT-Sicherheit

(IT-Sicherheits-) Anbieter, Lösungen, Jobs, Veranstaltungen und Hilfestellungen (Ratgeber, IT-Sicherheitstipps, Glossar, u.v.m.) leicht & einfach finden.
https://www.it-sicherheit.de/

Literatur

N. Pohlmann, S. Schmidt: „Der Virtuelle IT-Sicherheitsberater – Künstliche Intelligenz (KI) ergänzt statische Anomalien-Erkennung und signaturbasierte Intrusion Detection“, IT-Sicherheit – Management und Praxis, DATAKONTEXT-Fachverlag, 05/2009

D. Petersen, N. Pohlmann: "Ideales Internet-Frühwarnsystem", DuD Datenschutz und Datensicherheit – Recht und Sicherheit in Informationsverarbeitung und Kommunikation, Vieweg Verlag, 02/2011

M. Fourné, D. Petersen, N. Pohlmann: “Attack-Test and Verification Systems, Steps Towards Verifiable Anomaly Detection“. In Proceedings der INFORMATIK 2013 - Informatik angepasst an Mensch, Organisation und Umwelt, Hrsg.: Matthias Horbach, GI, Bonn 2013

U. Coester, N. Pohlmann: „Verlieren wir schleichend die Kontrolle über unser Handeln? Autonomie hat oberste Priorität“, BI-SPEKTRUM Fachzeitschrift für Business Intelligence und Data Warehousing, 05-2015

U. Coester, N. Pohlmann: „Ethik und künstliche Intelligenz – Wer macht die Spielregeln für die KI?“, IT & Production – Zeitschrift für erfolgreiche Produktion, TeDo Verlag, 2019

N. Pohlmann: „Künstliche Intelligenz und Cybersicherheit – Diskussionsgrundlage für den Digitalgipfel 2018“ https://norbert-pohlmann.com/app/uploads/2018/12/Künstliche-Intelligenz-und-Cybersicherheit-Diskussionsgrundlage-für-den-Digitalgipfel-2018-Prof.-Norbert-Pohlmann.pdf

N. Pohlmann: „Künstliche Intelligenz und Cybersicherheit - Unausgegoren aber notwendig“, IT-Sicherheit – Fachmagazin für Informationssicherheit und Compliance, DATAKONTEXT-Fachverlag, 1/2019

U. Coester, N. Pohlmann: „Wie können wir der KI vertrauen? - Mechanismus für gute Ergebnisse“, IT & Production – Zeitschrift für erfolgreiche Produktion, Technik-Dokumentations-Verlag, Ausgabe 2020/21

D. Adler, N. Demir, N. Pohlmann: „Angriffe auf die Künstliche Intelligenz – Bedrohungen und Schutzmaßnahmen“, IT-Sicherheit – Mittelstandsmagazin für Informationssicherheit und Datenschutz, DATAKONTEXT-Fachverlag, 1/2023

P. Farwick, Pohlmann: „Chancen und Risiken von ChatGPT – Vom angemessenen Umgang mit künstlicher Sprachintelligenz“, IT-Sicherheit – Mittelstandsmagazin für Informationssicherheit und Datenschutz, DATAKONTEXT-Fachverlag, 4/2023

N. Pohlmann: Lehrbuch „Cyber-Sicherheit“, Springer Vieweg Verlag, Wiesbaden 2022
Druckausgabe (ISBN 978-3-658-36242-3) und eBook (ISBN 978-3-658-36243-0).

Weitere Artikel siehe: https://norbert-pohlmann.com/artikel/