


# 1. Vernetzungstreffen im Rahmen des AI Policy Forums

KI in der  
öffentlichen Verwaltung

Mittwoch, 19. Oktober 2022  
Festsaal Technisches Museum Wien



**AIM AT 2030**  
Artificial Intelligence Mission Austria



## Themensession 4: **Cybersicherheit und KI**

- **Mario Drobits**, AIT - *Sicherheit mittels KI – Was kann KI zu einer sicheren Verwaltung beitragen?*
- **Martin Pirker**, FH St. Pölten - *IT-Security und AI vor dem Hintergrund des AI Acts*
- **Camillo Nemec**, BMLV - *Cybersicherheit und KI aus verteidigungspolitischer Sicht*

# SICHERHEIT MITTELS KI

1. Vernetzungstreffen “KI in der öffentlichen Verwaltung”

Wien, 19.10.2022

Mario Drobics

AIT Austrian Institute of Technology



März 2022 - Stephansdom



## Hackerangriff auf Kärnten: 80.000 Stammdatenblätter ausgelesen

Im Rahmen des Leaks sind Datenblätter mit Namen, Geburtsdaten, Adressen und Telefonnummern aufgetaucht

10. Juni 2022, 15:04, 300 Postings

IT-SICHERHEIT

## Cyberangriff auf Uni: Erste Daten im Darknet aufgetaucht

Unter anderem dürften Reisepässe, ... worden sein. Den Angriff beanspruchten sie für sich

Mickey Manakas, Andreas Proschofsky  
27. Juni 2022, 17:02, 83 Postings

MEDIZINISCHE  
UNIVERSITÄT  
INNSBRUCK

<https://www.derstandard.at/story/20001364-stammdatenblaetter-ausgelesen>

<https://www.derstandard.de/story/2000136948190/cyl-uni-erste-daten-im-darknet-aufgetaucht>

## Cyberangriffe auf das österreichische Außenministerium angeblich erfolglos

"Schadsoftware konnte keine Auswirkungen entfalten." Angreifer hatten versucht, sich mithilfe von Phishing-Mails in interne Systeme

ÖNplus WIRTSCHAFT

## Cyberangriff auf Gunskirchner Motorenhersteller BRP-Rotax

steiermark ORF.at

6.9.2022

Steiermark-News

Steiermark-Magazin

Der ORF Steiermark

Volksgruppen

Ganz Österreich



CHRONIK


<https://steiermark.orf.at/stories/317233>

## Hackerangriff legt Feldbacher EDV lahm

Am Wochenende ist die Stadt Feldbach Opfer eines Hackerangriffs geworden: Das EDV-System wurde übernommen; sollte die Stadt ihre Daten wiederhaben wollen, müsse Lösegeld bezahlt werden.

<https://fu>

# CYBER-SECURITY VORFÄLLE



Targeted sectors per number of incidents (April 2020-July 2021)

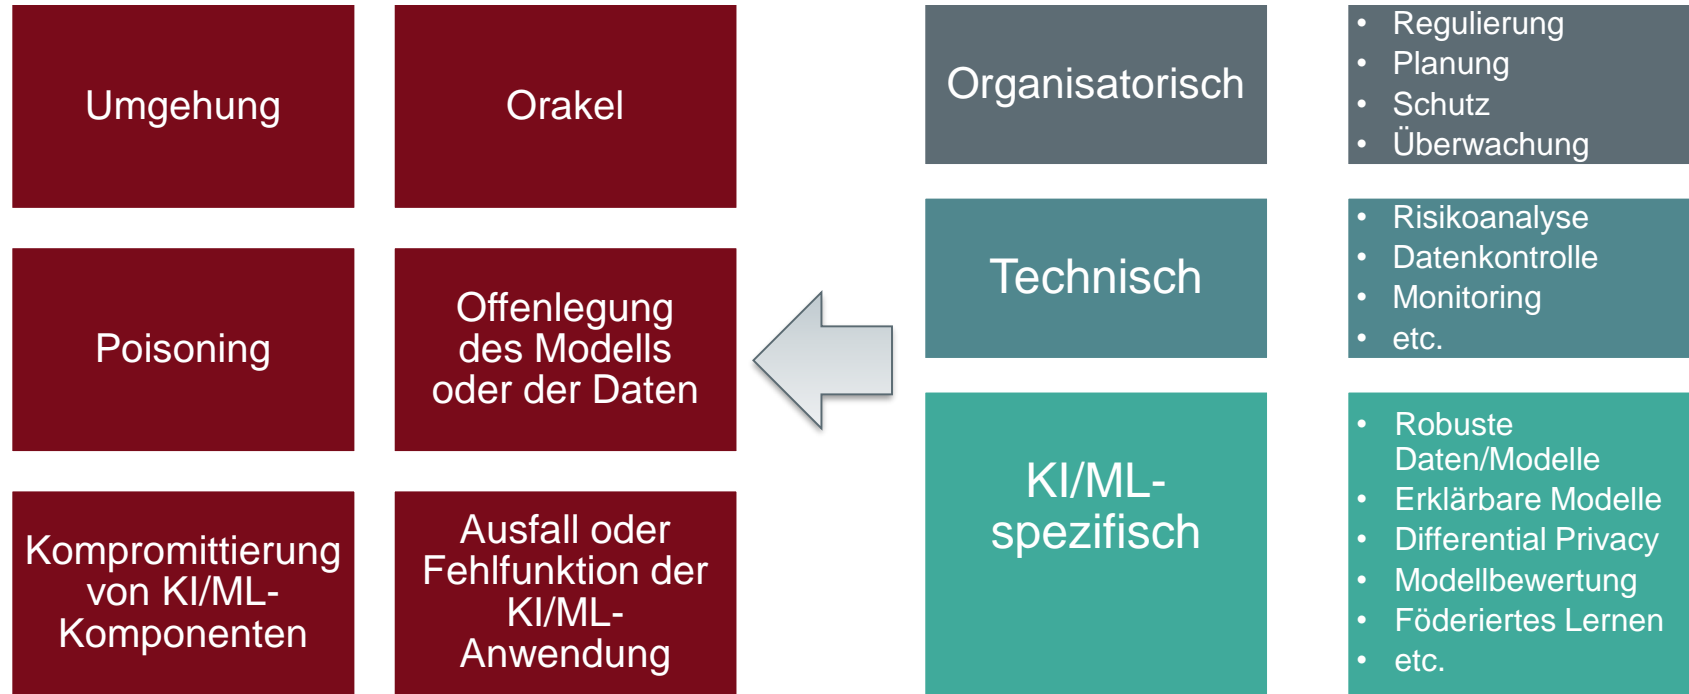
# CYBER-SECURITY BEDROHUNGEN



# BEDROHUNGEN KI-BASIERTER SYSTEME



# BEDROHUNGEN FÜR KI-BASIERTE SYSTEME






# SCHUTZ DER DATEN

- Vernetzte Datennutzung erfordert verstärkte Maßnahmen zum Schutz der Daten
  - **Identifikation** der Systeme & Anwender:innen
  - **Autorisierung** der Zugriffe
  - **Sichere** Datenübermittlung
  - **Vertrauensvolle & nachvollziehbare** Datenspeicherung / -nutzung

➔ **Schutz des Datenökosystems**



# KI ZUM SCHUTZ KOMPLEXER SYSTEME



# CYBER-SECURITY IN KOMPLEXEN SYSTEMEN

- **Komplexe Systeme wachsen organisch** von unten nach oben

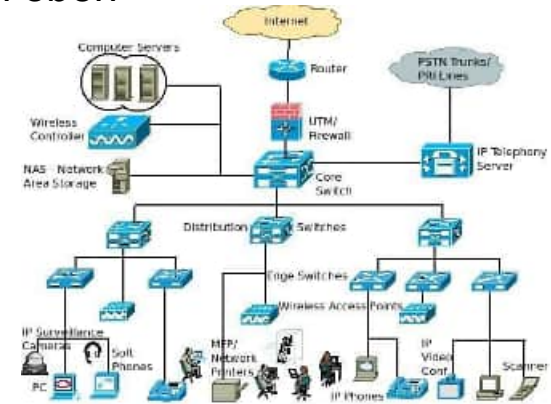
- Implementierungs- und Konfigurationsfehler führen zu Schwachstellen
- Konstruktionsfehler verursachen Schwachstellen

➔ **Prävention scheitert letztlich**

- Monitoring konzentriert sich auf die frühzeitige Erkennung von feindlichen Aktionen
- Der heutige Stand der Technik ist immer noch:

- Hauptsächlich Untersuchung des Netzwerkverkehrs (gängige Tools)
- Signaturbasierte Suche nach bekannten fehlerhaften Elementen
- Protokolldatenuntersuchung mit SIEMs – meist nur vordefinierte Regeln
- Begrenzte Anomalieerkennung



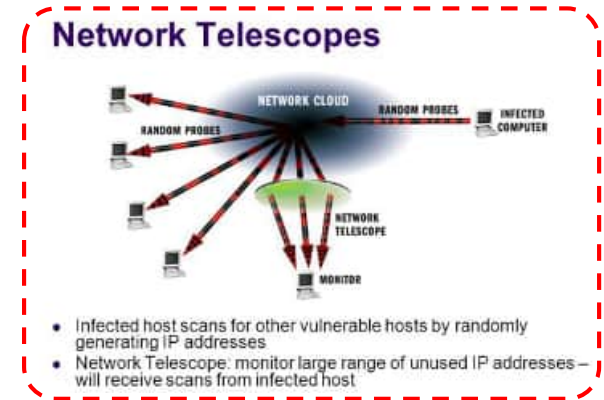

➔ **Wie erkennt man unbekannte Angriffe?**



# AI-BASIERTE ANALYSEN AUF NETZWERKEBENE



- Erkennung von Phishing-Websites durch **lexikographische Analyse**
- Identifizierung von Schadgeräten durch **Darkspace UnSolicited Traffic Analyse**
- **Deep Learning zur Malware-Erkennung** über verschlüsselten Netzwerkverkehr
- **Generative KI zur Anomalie-erkennung**
- **Explainable AI** zur Interpretation von Deep-Learning-Modellentscheidungen

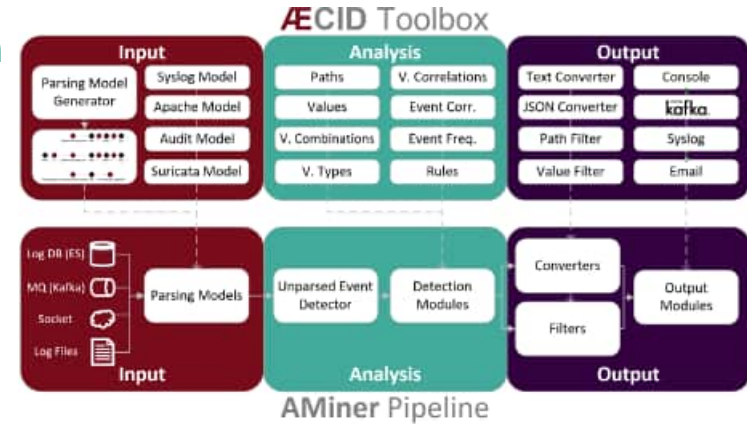


# AI-BASIERTE ANALYSE AUF SYSTEMEBENE

- **Angreifer nutzen Systeme jedoch anders** als legitime Benutzer...
  - Zugriff auf andere DMZ-Server von einem kompromittierten Webserver
  - Verwendung der SSH-Wartungsschnittstelle anstelle der Weboberfläche
  - Anmeldung mit Backup-System-SSH-Schlüssel, der für die SFTP-Dateiübertragung vorgesehen ist
- **Neuartige Ansätze des maschinellen Lernens**
  - **Beobachten** eines Systems und seiner "normalen" Auslastung
  - **Dynamischer Aufbau** eines Modells, das eine Baseline darstellt
  - **Warnung bei signifikanten Abweichungen** von diesem Ausgangswert
- **Sichtbarkeit** von gegnerischen Aktionen ist der Schlüssel!
  - **Ausführliche Protokolldaten** von Diensten, Anwendungen, Betriebssystemen

# ÆCID UND AMINER

- [ÆCID](#) ist ein ausgereiftes Einbruchmeldesystem, das Protokolldaten verwendet
- Erfasst **Protokolldaten von beliebigen Systemen**
  - Funktioniert mit domänenspezifischen und bisher unbekannt Systemen, ist also nicht auf vordefinierte Parser angewiesen  
→ **selbstlernend!**
  - **Light-weight**, verteilte Anomalydetektion
  - Clients werden mit **geringem Speicherbedarf** und **minimaler CPU-Auslastung** ausgeführt
  - Nicht in Konkurrenz zu etablierten Systemen, sondern als zusätzlicher Detektionsmechanismus



<https://github.com/ait-aecid/logdata-anomaly-miner>

# KI ZUR ERKENNUNG VON DESINFORMATION



# BEKÄMPFUNG VON DESINFORMATION

Fake News und Desinformation  
in sozialen Medien

Audio/Video/Text Analytics

Verbraucherschutz



Identification of  
Fake Shops



Price  
discrimination in  
the Internet



Fact  
checker



<https://euhybnet.eu/>



- ≡ Federal Chancellery
- ≡ Federal Ministry Republic of Austria Europe, Integration and Foreign Affairs

- ≡ Federal Ministry Republic of Austria Defence
- ≡ Federal Ministry Interior

- ≡ Bundesministerium Soziales, Gesundheit, Pflege und Konsumentenschutz



AIT's Fact Checking Platform



MAL ZWEI



SINBAD

preis.wert




defalsif-ai





# NATIONALE LEITINITIATIVE – KI-BASIERTE FACT-CHECKING PLATTFORM

 Bundeskanzleramt

 Bundesministerium Landesverteidigung

 Federal Ministry Republic of Austria Europe, Integration and Foreign Affairs

**APA**

**ORF**





Einfaches Benutzerinterface

Multimedia Analyse

Multimodale KI



Data Collection



Hybrid CoE  
The European Centre of Excellence for Countering Hybrid Threats

**VICTORIA**  
VIDEO ANALYSIS FOR INVESTIGATION OF  
CRIMINAL AND TERRORIST ACTIVITIES

 UNITED NATIONS  
OFFICE OF COUNTER TERRORISM  
UN Counter-Terrorism Centre (UNCTC)

# THANK YOU!


Mario Drobics, 19<sup>th</sup> October 2022



# IT-Security und AI vor dem Hintergrund des AI Acts



# AI everywhere

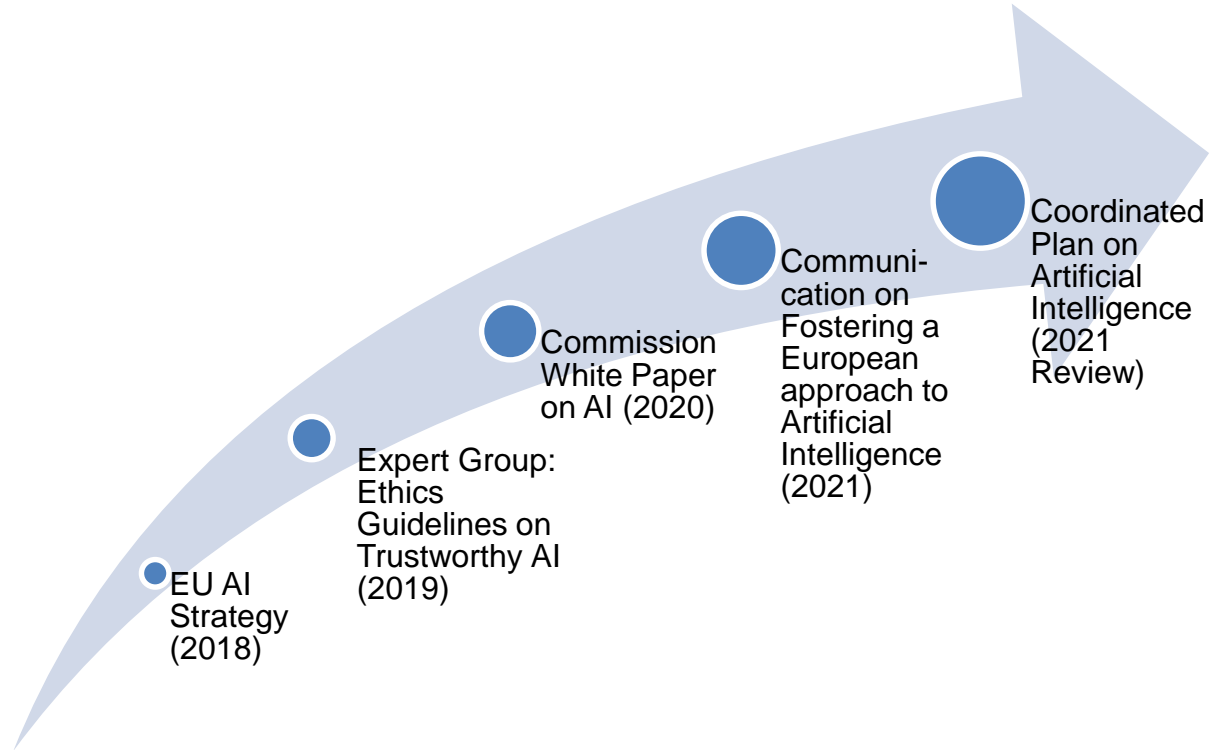


# AI ...und Security?

- ✦ AI wird allgegenwärtig
- ✦ AI wird „commodity“
- ✦ AI trifft / beeinflusst Entscheidungen
- ✦ AI schafft neue Möglichkeiten
- ✦ AI schafft ein Sicherheitsproblem?



# Der Artificial Intelligence Act



# Schlüsselinhalte

## ★ „AI-Systeme“

- ★ Definition von AI
- ★ Unterkategorie: "Hochriskantes KI-System"
- ★ Definitionen in den Anhängen I-III



## ★ Verpflichtungen insbesondere für Anbieter und Nutzer von "Hochrisiko"-KI-Systemen

- ★ verbotene KI-Praktiken (Art 5); Transparenzpflichten (Art 52); „Sandboxing“ (Art 53)

## ★ Hohe Strafen / Sanktionen


## ★ Risikoabschätzung und Security bekommen einen hohen Stellenwert

## AI Act

- ✦ Definiert in Annex I
- ✦ Lehnt sich an OSZE-Definition an
  - ✦ Nicht für Gesetzestexte geplant
- ✦ Problem
  - ✦ Taxativ
  - ✦ Anfänglich sehr technologiespezifisch
  - ✦ „Catch-All“
    - ✦ Rule-Based Systems
    - ✦ Statistische Methoden
    - ✦ Predictive Algorithms

## Generell

- ✦ AI extrem schwierig zu definieren
  - Speziell die „Randbereiche“ wie Entscheidungsbäume
  - Emergenz-Problem / Gruppendynamik





# Security Testing

## „Klassische“ Probleme

- Größe / LoCs
- Abgekapselter Code
  - Externe Module
  - Stabilität
  - Review?
- Komplexe Algorithmen
  - Systemische Fehler?
- Erwartete vs. Realer Nutzung
- Time & Money

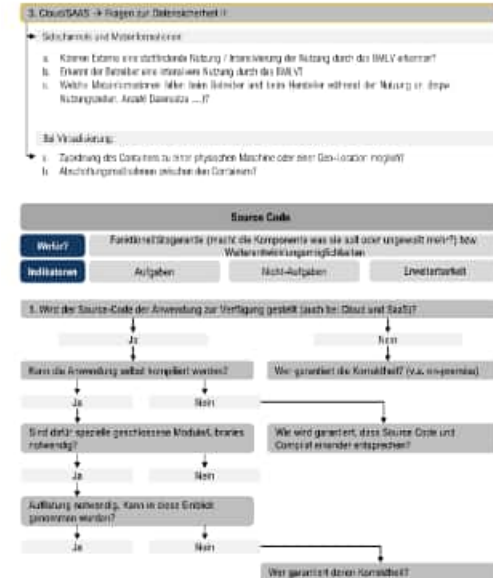
## Neue Herausforderungen

- Explainability-Problem
  - Halting-Problem squared
- Modell
  - Aus welchen Daten? Datenkontrolle? Data Cleansing
  - Fehlende Stabilität
  - Model as a Service?
- Beeinflussung durch Testing
  - Fuzzy-Tests versus Echtdaten
- Risikoabschätzung
  - „Klassische“ Security-Intelligence

# Beschaffung

- Neue Kriterien
  - Transparenz
  - „Einfachheit“ der Methodik
  - Richtige Ansprechpartner
  - „Ist das überhaupt AI?“
- Neue Angriffsvektoren
  - Modelle
  - Daten (Training & Processing)
  - Aktivitäts(meta)monitoring
- Komplexe Thematik
- Download: [www.secureAI.info](http://www.secureAI.info)

## Beschaffungsleitfaden - Detailsicht III



Panik?



# Kontakt



Peter Kieseberg  
Institut für IT Sicherheitsforschung  
Fachhochschule St. Pölten  
[peter.kieseberg@fhstp.ac.at](mailto:peter.kieseberg@fhstp.ac.at)

# Cybersicherheit und Künstliche Intelligenz aus verteidigungspolitischer Sicht

ObstdhmfD Mag. Camillo NEMEC  
Generaldirektion Verteidigungspolitik

# Bedrohungen Risiken Herausforderungen

Ukraine Russland Krieg



Regionale und globale Krisen und Konflikte

Geopolitische Auswirkungen

Hybride Bedrohungen (**Cyber**, Desinformation, Deepfakes, Bedrohung der kritischen Infrastruktur)

Internationaler Terrorismus und organisierte Kriminalität

Digitalisierung (**Künstliche Intelligenz**)




Weltraum

Blackout

Klimawandel (Naturkatastrophen, technische oder humanitäre Katastrophen, Kampf um Ressourcen)

Anhaltende Flüchtlingsdebatte und Migrationsströme

Pandemie und globale Wirtschaftliche Folgen



# Cybersicherheit

Das Internet als globaler öffentlicher Raum

fortschreitende Digitalisierung

Geopolitische Rivalität

Sicherheits- und verteidigungspolitische politische Relevanz (politisch, wirtschaftlich, militärisch, gesellschaftlich)

Nexus innere und äußere Sicherheit

Akteursvielfalt

Cyber als operativer Bereich von Konflikten (Warfighting Domain)

Rolle der Streitkräfte

Schwellenwert Cyber Angriff

Attribuierung



# Künstliche Intelligenz

Domänenübergreifende Querschnittsthematik (multidisziplinär und transformativ)

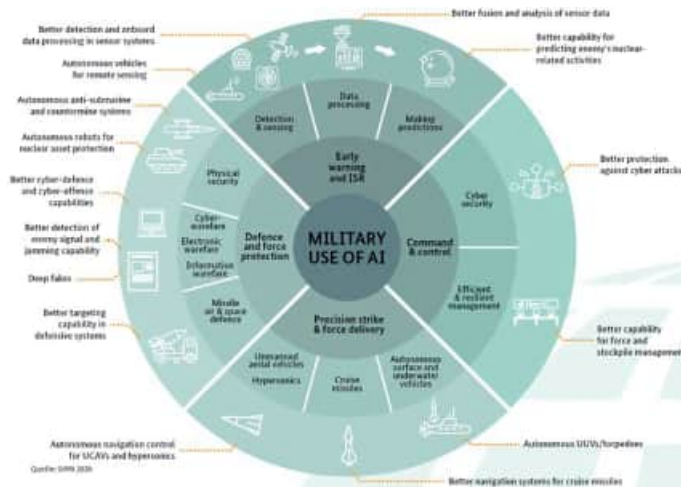
Streitkräfte und Bedrohungsdispositiv

Instrument der Geopolitik

Militärische Anwendungsgebiete (Chancen und Risiken)

Dual-Use-Charakteristik

Kontroversen um Definitionen und Grad menschlicher Kontrolle von letalen autonomen Waffensystemen





# Danke für die Aufmerksamkeit

[camillo.nemec@bmlv.gv.at](mailto:camillo.nemec@bmlv.gv.at)



Bundesministerium  
Energie

Ministerium  
für Klimaschutz,  
Energie, Verkehr,  
und Technologie