

# Ethik und KI

Dr. Aljoscha Burchardt

ASTT-TAGUNG 2022: EINE WELT OHNE BABEL?



Deutsches Forschungszentrum für  
Künstliche Intelligenz GmbH



# By way of a definition...

KI Systeme kommen einem intelligent vor.



KI Systeme haben in der Lösung der Aufgabe eine gewisse Freiheit.





# Wie funktioniert KI?

# Motivation

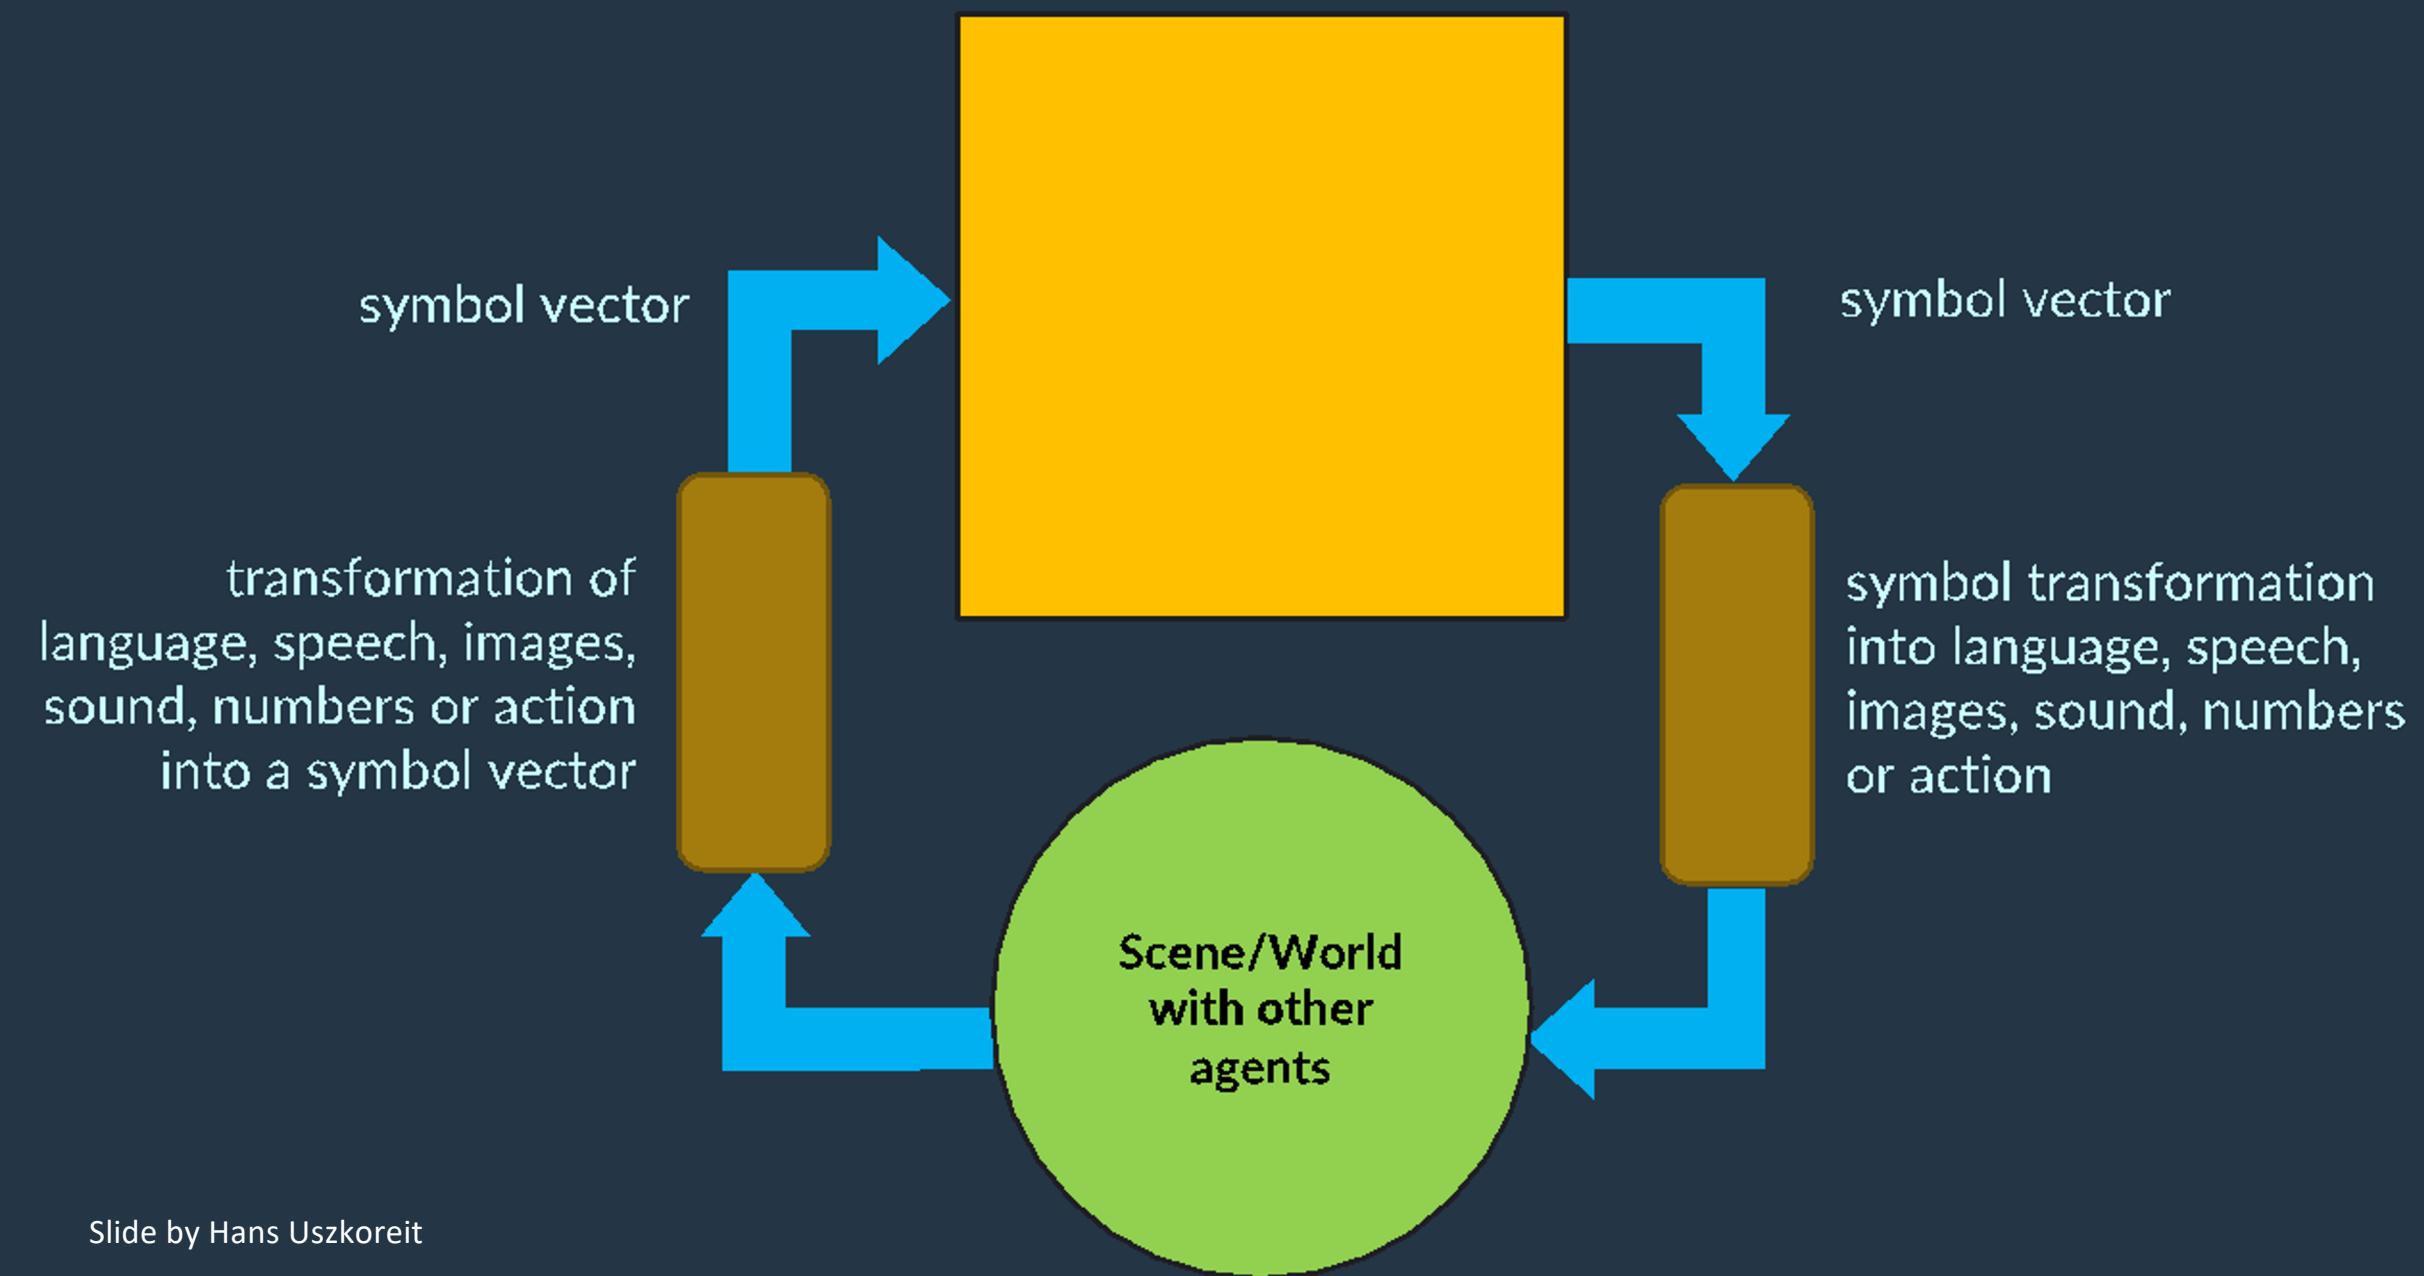
## Implicit knowledge



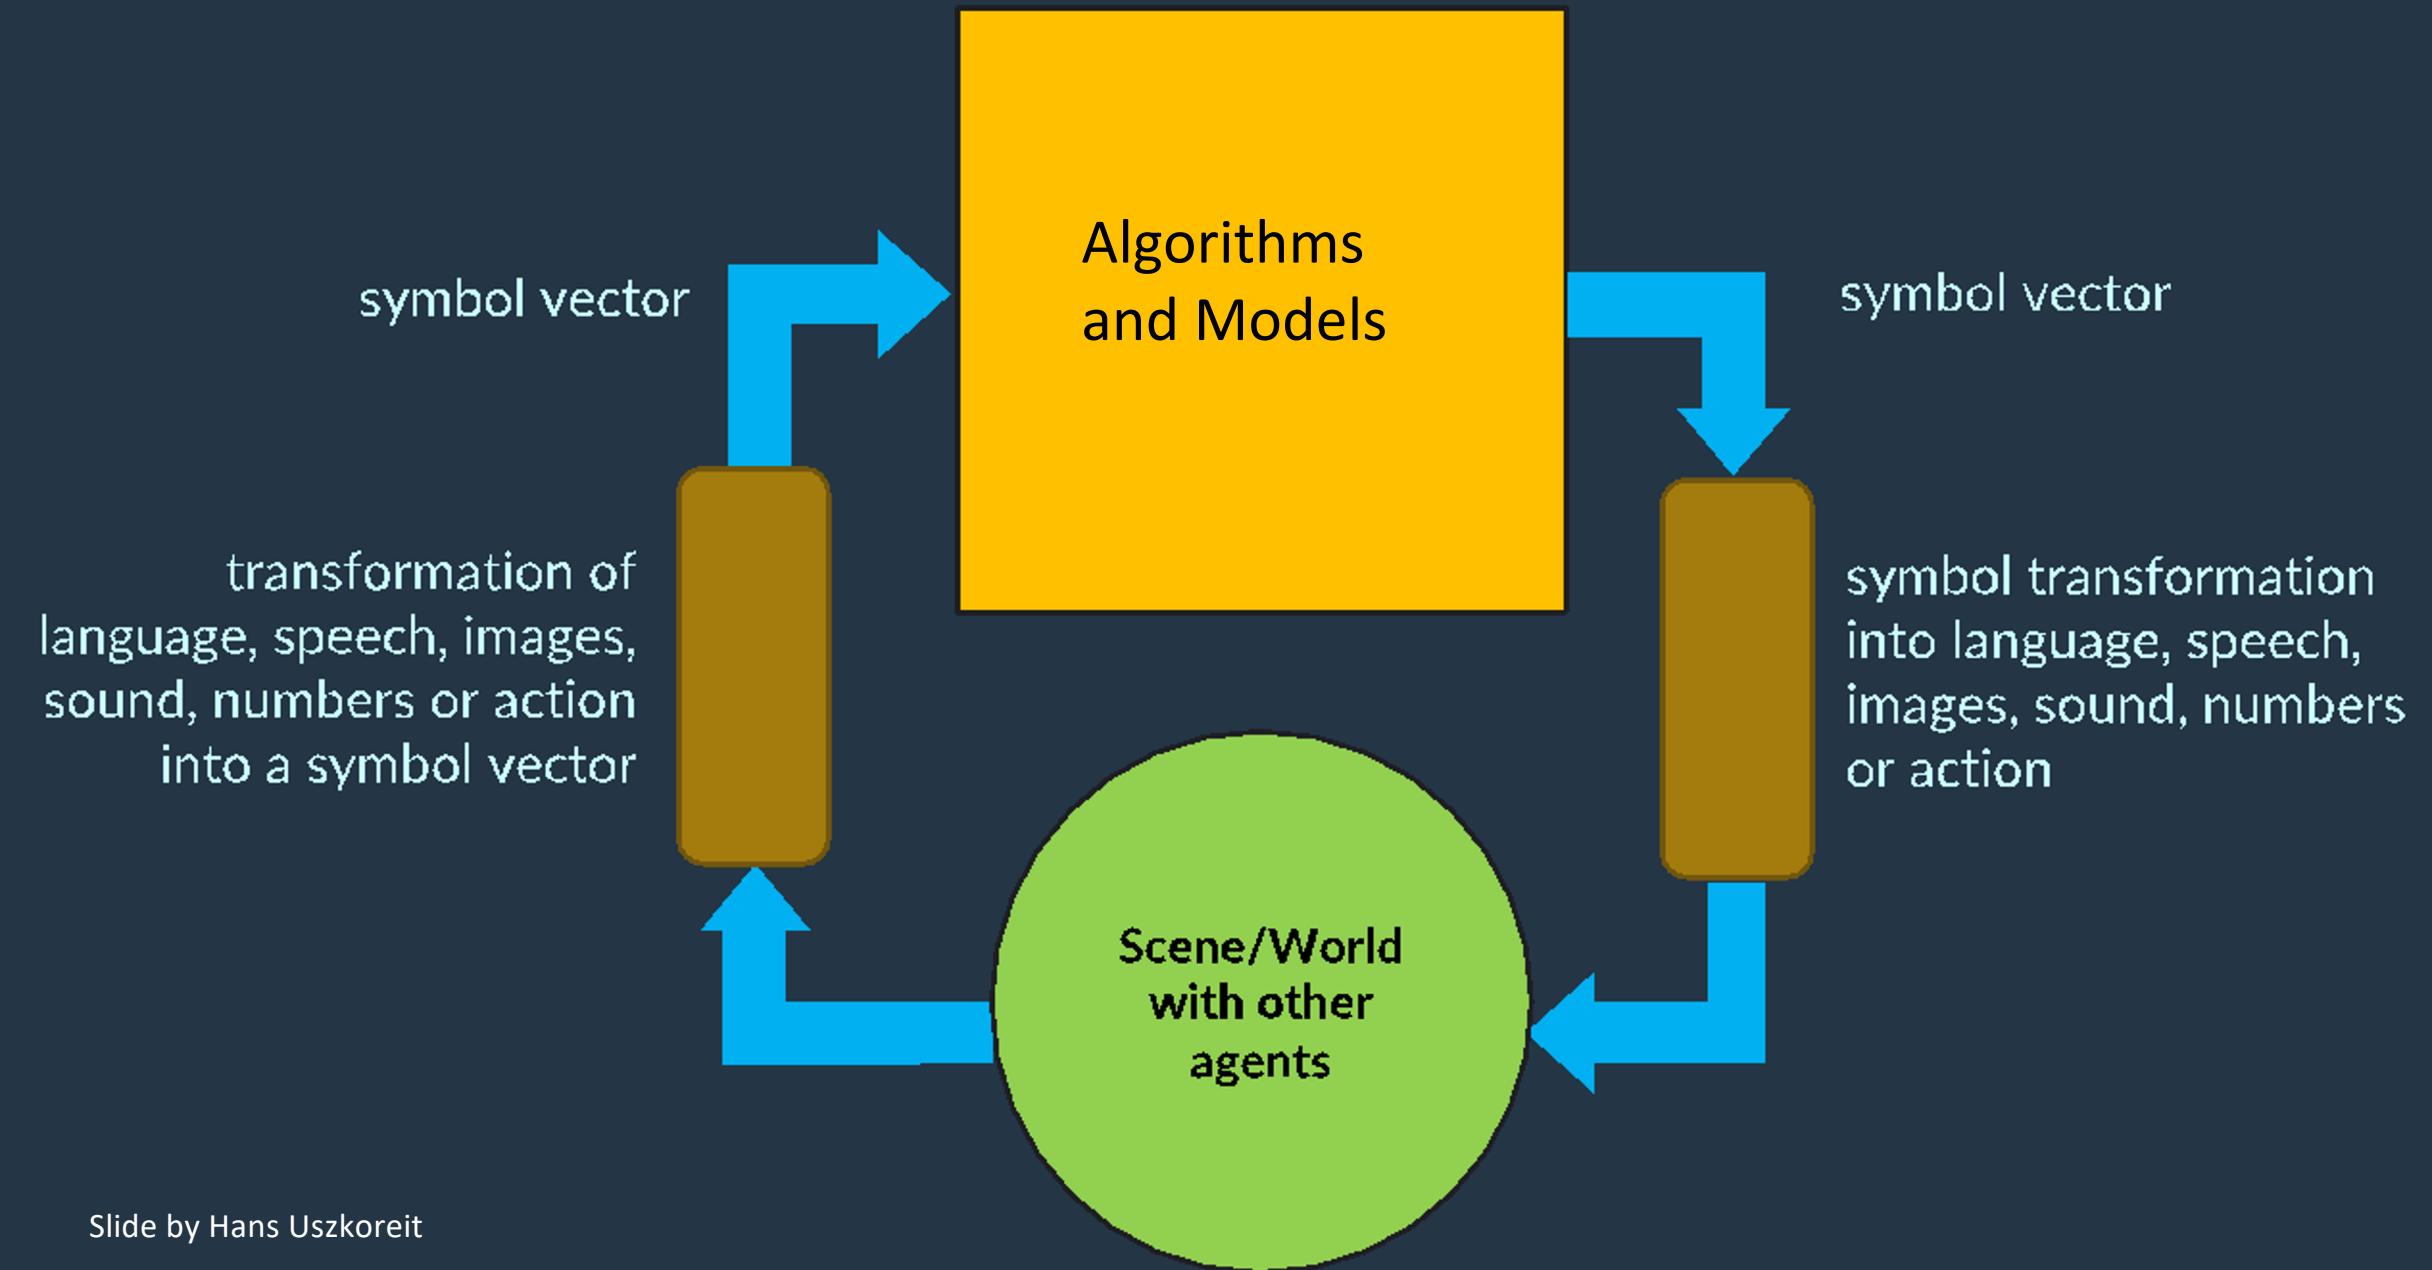
## Explicit knowledge



## AI System



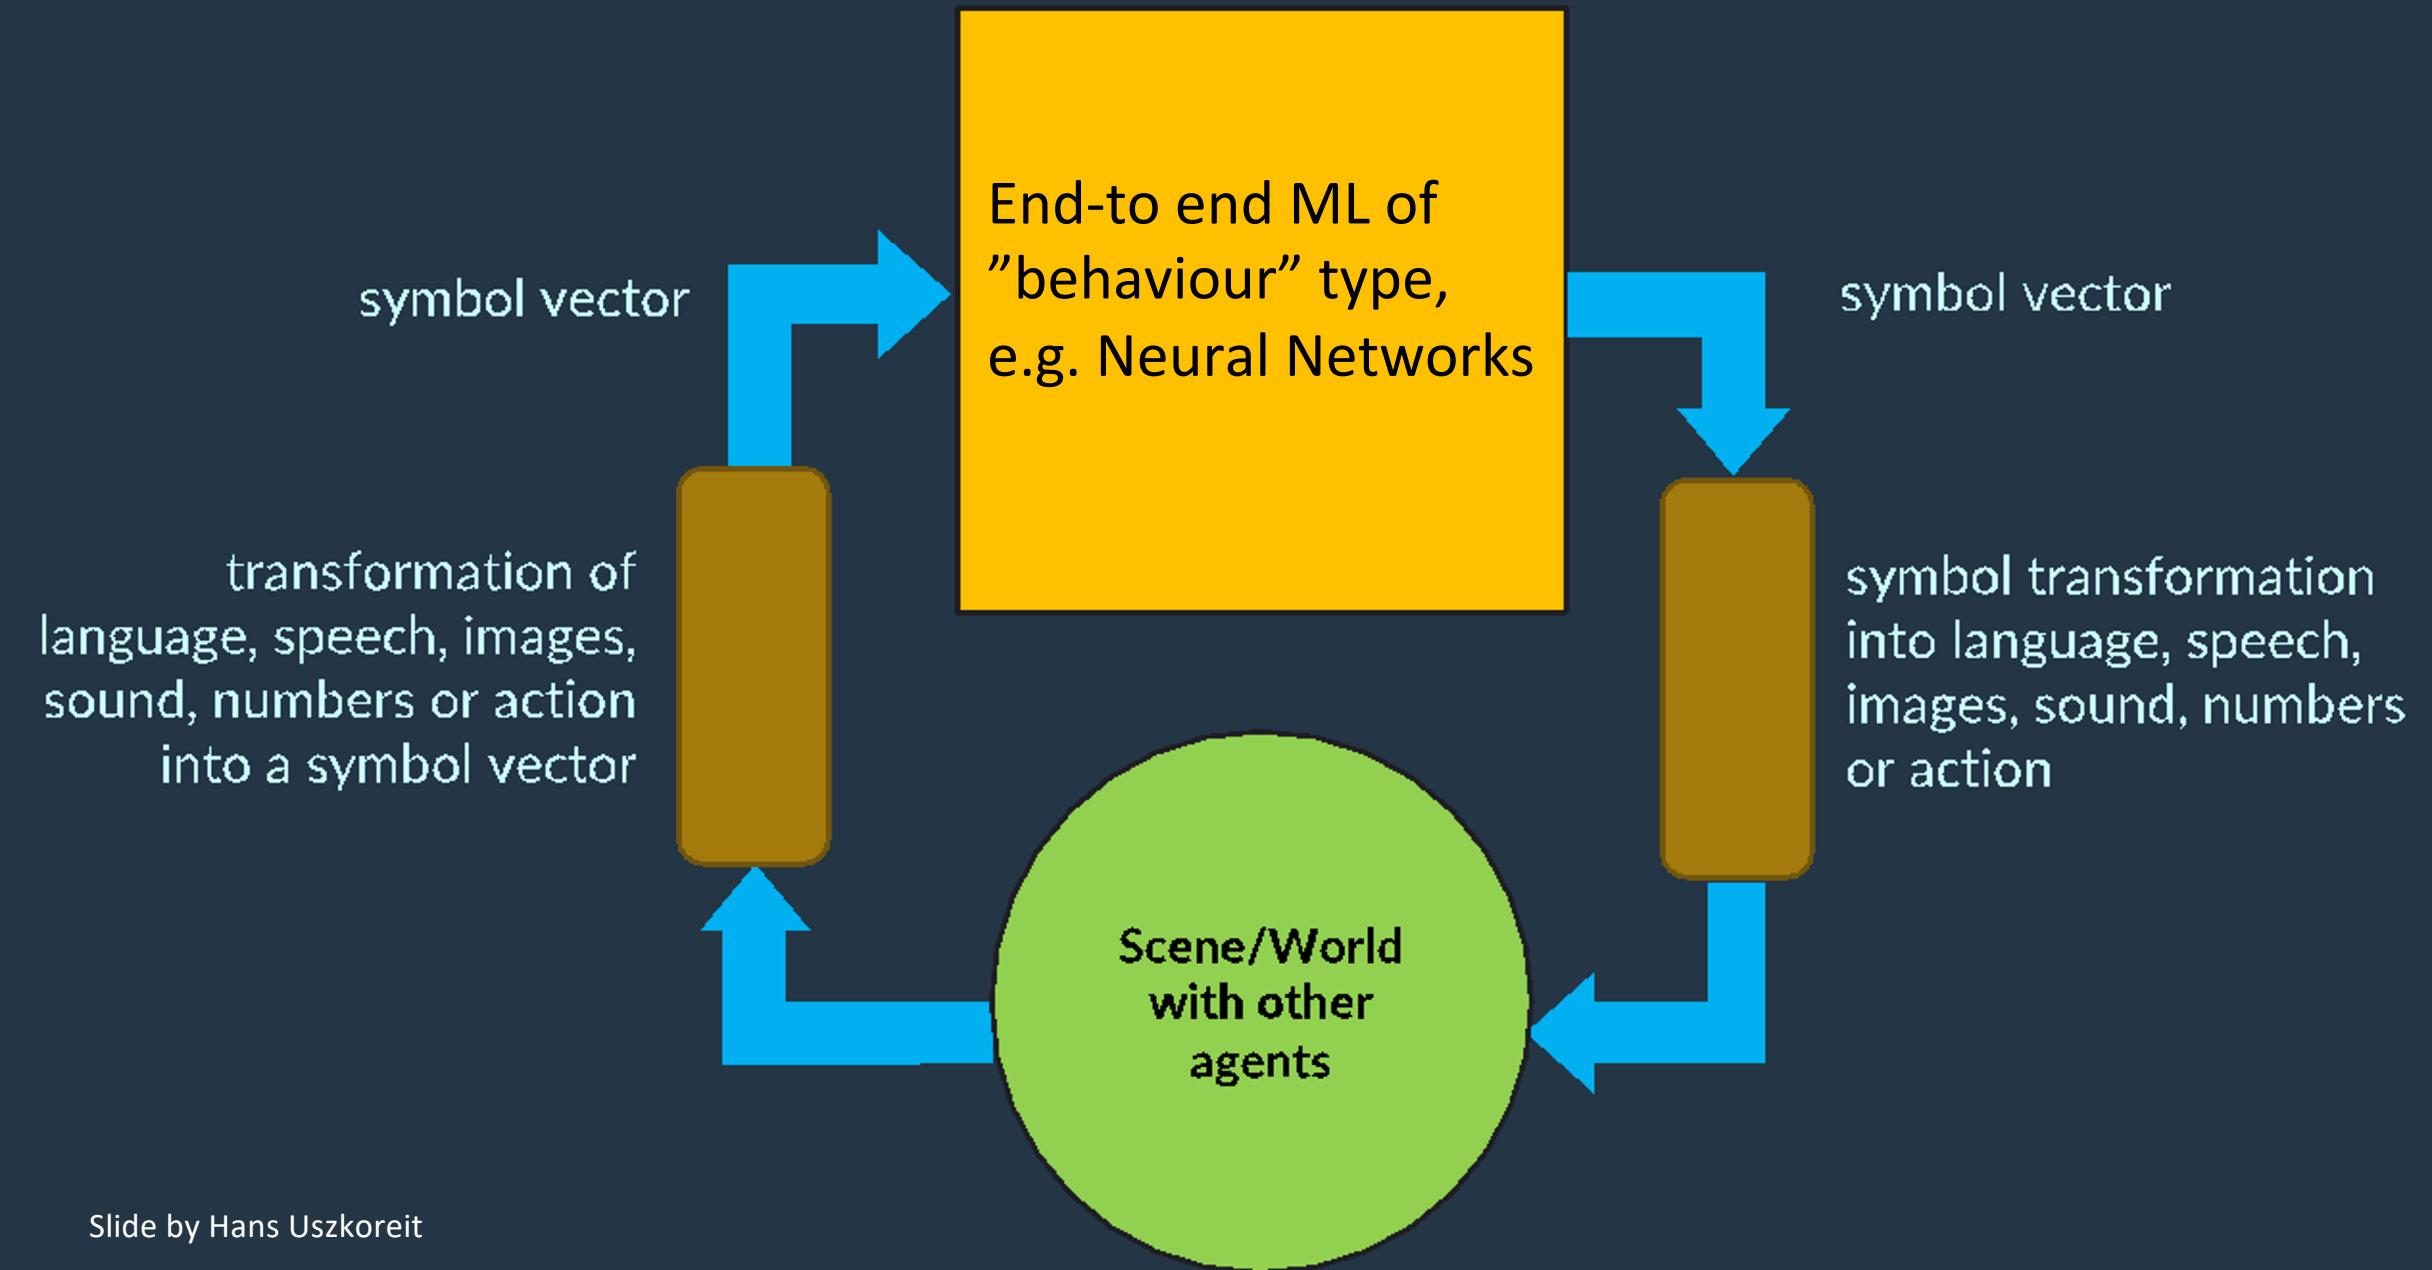
## AI System



# Algorithmus vs. Black Box Models

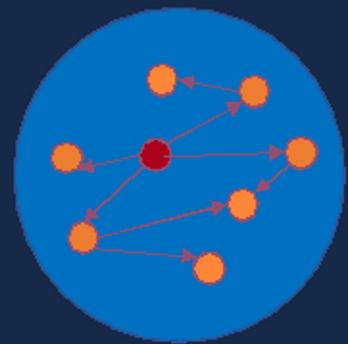


## AI System



input vector may represent:

- an image
- a sentence in English
- a sentence in German
- a speech recording
- sales figures
- camera input



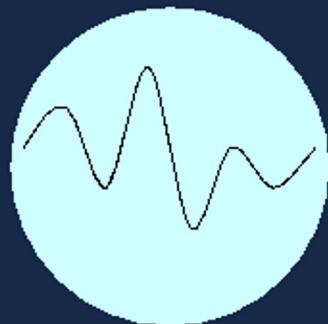
input symbol vector



training data	labels
input vector 1	label vector 1
input vector 2	label vector 2
input vector 3	label vector 3
input vector 4	label vector 4
input vector 5	label vector 5
input vector 6	label vector 6

label vector may represent

- a type of object
- a sentence in English
- a sentence in German
- a spoken phrase
- sales figures
- driving action



output symbol vector



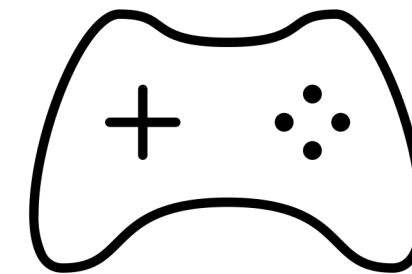
# Machine Learning Examples

## Supervised



Tumor: yes  
Tumor: yes  
Tumor: no

## Reinforcement Learning



Score: 74

Hallo Welt.	Hello world.
This is an example.	Dies ist ein Beispiel.
And so on.	Und so weiter.

# Begriffsklärung: Ethik vs. Moral

Individuelle Ebene	Reflexionsebene
Hans handelte moralisch.	Maria studiert Ethik.
Maria verhielt sich sozial.	Hans studiert Soziologie.

- Moral: normative (nicht unbedingt kodifizierten) Regeln, Sitten und Gebräuche in einer gegebenen Gemeinschaft (nicht: rechtlich; nicht: reine Konventionen wie Höflichkeit).
- Ethik: Wissenschaft von der Moral, als Reflexionswissenschaft
- (Es gibt noch andere Verwendungen der Begriffe.)

Vorsicht: false friend!



ethical  $\cong$  moralisch

## Was kann „ethische KI“ bedeuten?

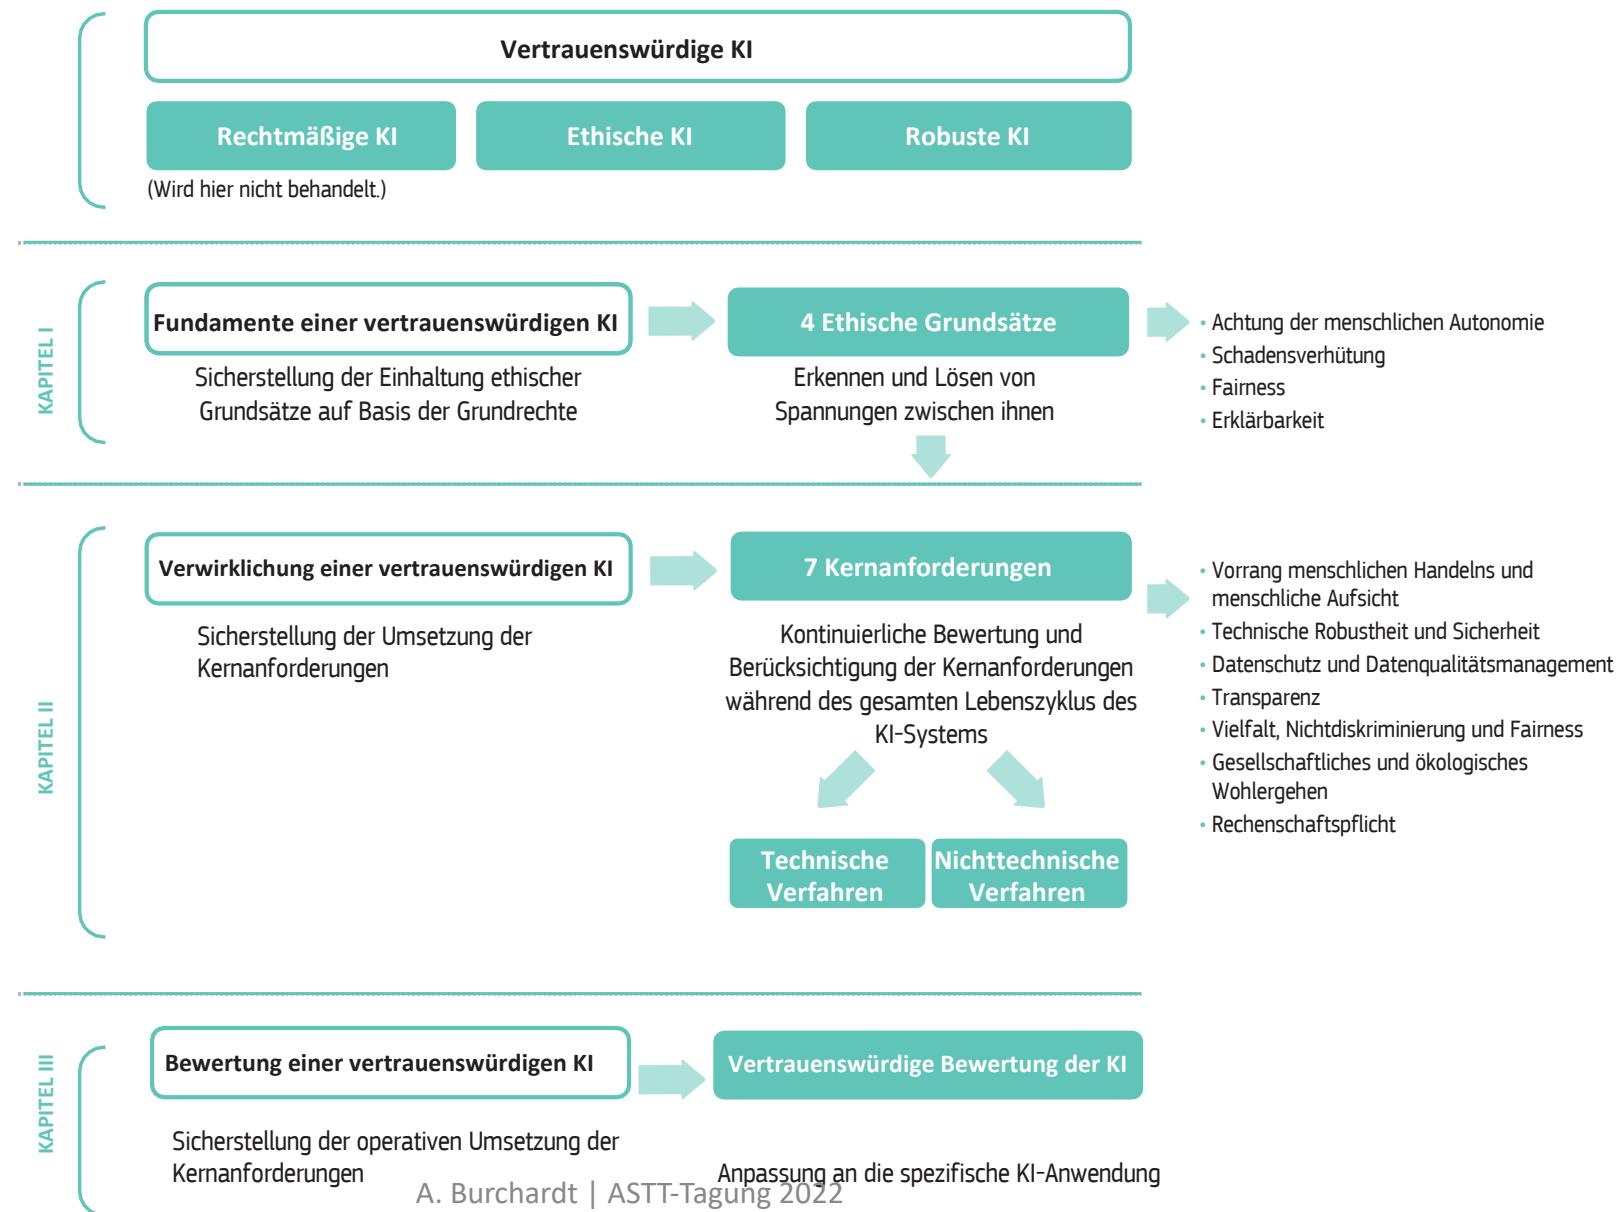
1. Entwicklung von Systemen, die moralisch gute Zwecke realisieren (sollen).
2. In den Entwicklungs- und Implementationsprozess derartiger Systeme oder in deren Nutzung fließen ethische Überlegungen ein.
3. KI-basierte Systeme werden zu dem Zweck entwickelt und implementiert, ethische Deliberation, Begründung und die moralische Entscheidungsfindung zu unterstützen bzw. zu erleichtern (“Moral Machine”).



Bild: <https://www.jpc.de>

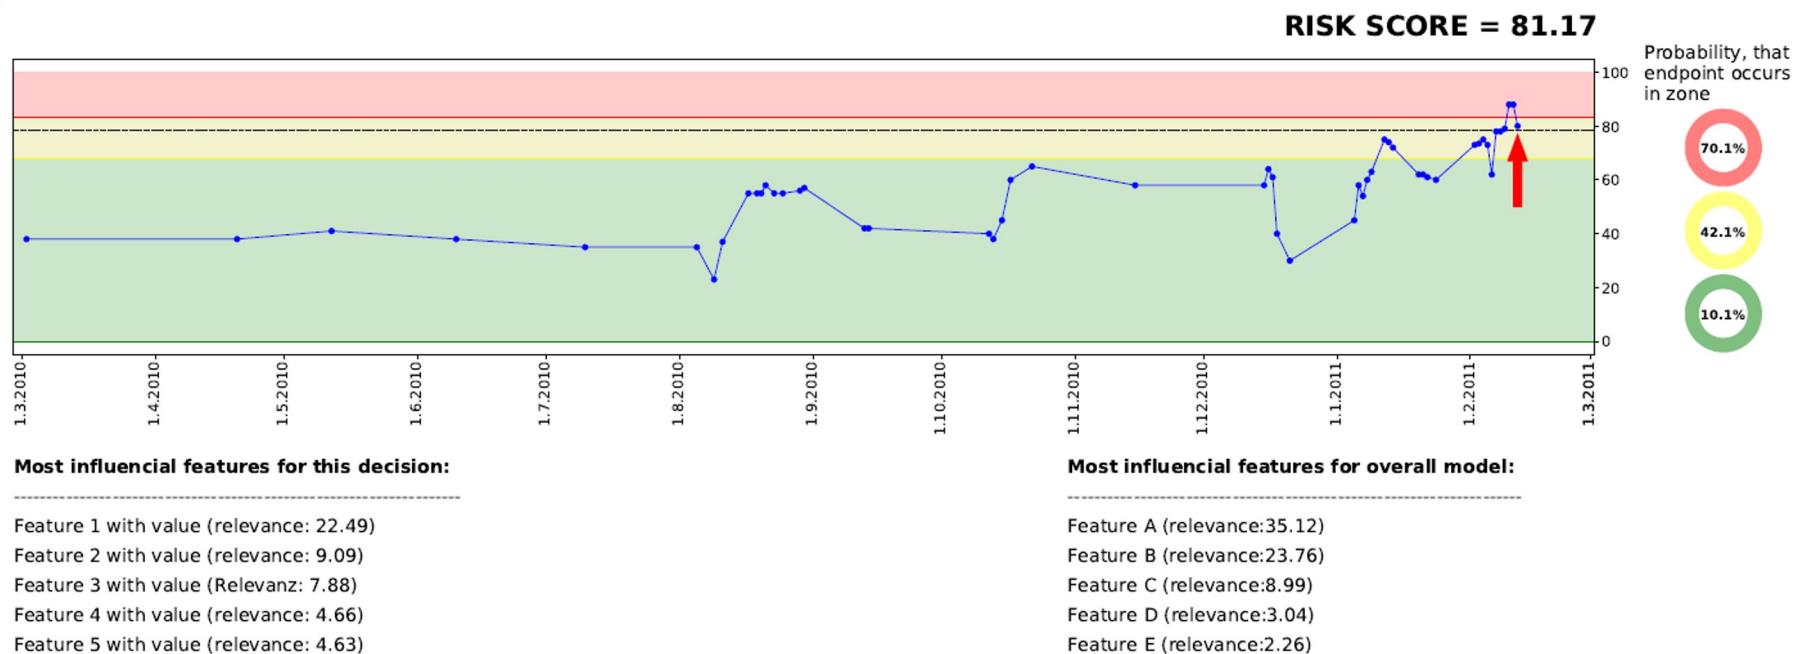
# Rahmen für eine vertrauenswürdige KI

- EU HLEG on AI



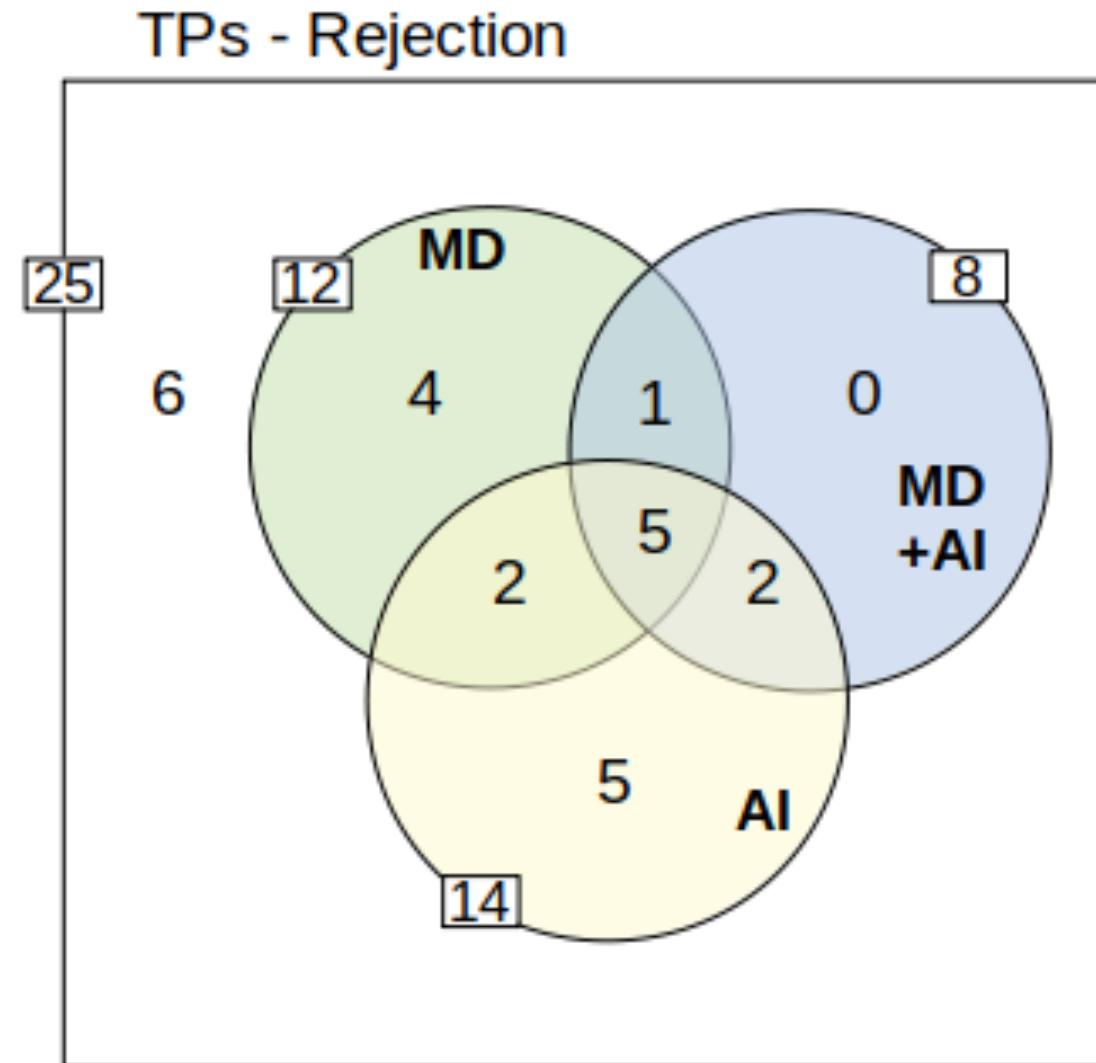
# Data & Model

A dashboard with risk score, traffic light system and feature relevance



# AI vs MD vs MD+AI: Findings

- AI outperforms MDs
- Junior MD performs lower than Senior MD
- Junior MD increases in performance using AI, while Senior MD decreases in performance!
- MDs seem to be influenced by decision of AI
- MDs and AI partially detect different patients at risk



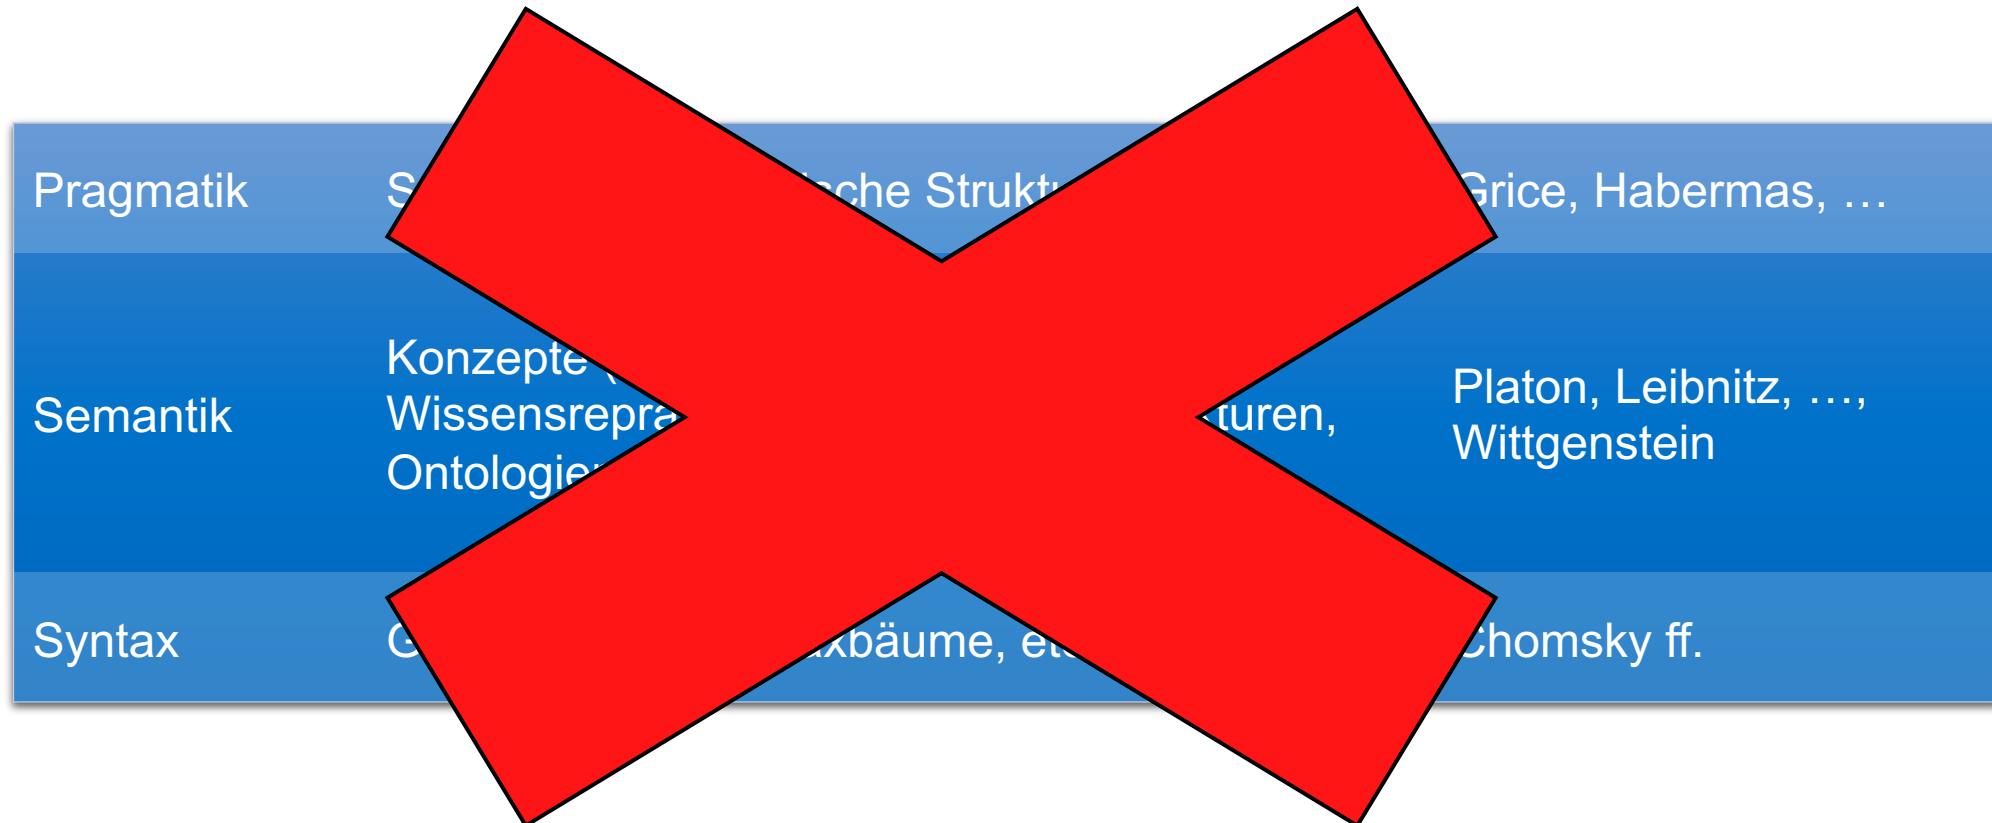
# Meaningful human control



# Idealistische Sicht der Computerlinguistik

Pragmatik	Sprechakte, Rhetorische Struktur, etc.	Grice, Habermas, ...
Semantik	Konzepte (Entitäten, Relationen, Events), Wissensrepräsentation (Merkmalsstrukturen, Ontologien, Logik), Inferenz, etc.	Platon, Leibnitz, ..., Wittgenstein
Syntax	Grammatiken, Syntaxbäume, etc.	Chomsky ff.

# Idealistische Sicht der Computerlinguistik



# Holzschnittartige Sicht auf NLP / Sprachtechnologie

- Flache Verarbeitung an der „Wort-Oberfläche“
  - Sehr wenig explizites Weltwissen, kaum sprachliches Wissen im Einsatz
- Trade-Off (inhaltliche) Kontrolle vs. Skalierbarkeit/Performanz
- In der Praxis im Wesentlichen drei Ansätze
  1. Symbolische Wissensverarbeitung („Datenbanken“)
  2. Klassisches Machine Learning („Bag of Words“ und Merkmale)
  3. Neuronale Netze („Word Embeddings“)

# Kontrolle bei der Maschinellen Übersetzung

## History of MT

- „Shifting words“
- Rule-based MT
- Translation Memories
- Classical Machine Learning
- Today's Machine Learning

## History of AI

- Algorithmics
- Expert systems
- Heuristic Algorithms
- Features / Statistics
- Neural Networks

# Machine Translation Example

≡ Google Übersetzer



 Text

 Dokumente

SPRACHE ERKENNEN

DEUTSCH

ENGLISCH



ENGLISCH

DEUTSCH

FRANZÖSISCH

Du sollst nicht ehebrechen.



You shall not commit adultery.

Du sollst nicht Ehe brechen.

You shouldn't commit adultery.

Du sollst nicht eher brechen.

You shouldn't break sooner.

Du sollst nicht ehe brechen.

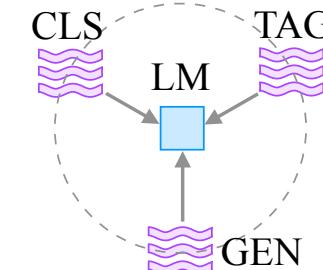
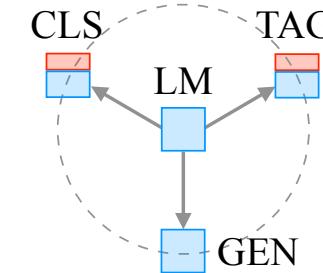
You shall not break before marriage.

# Neuronale Architekturen im Wandel

- Taskspezifische Modelle, fully supervised



GEN



- Vortrainiertes Sprachmodell + Finetuning

- Vortrainiertes großes Sprachmodell + Prompting

Grafiken leicht abgewandelt aus:  
<https://arxiv.org/pdf/2107.13586.pdf>

# Sprachmodelle

- Aufgabe: Nächstes Wort vorhersagen
- Trainingsdaten: Web, Mehrsprachiges, Programmcode, etc.
- BERT
  - >100 Millionen Parameter
  - Trainingsdaten: Tausende Millionen Wörter
- GPT-3
  - 175 Milliarden Parameter
  - Trainingsdaten: Hunderte Milliarden Wörter
  - **GPT-3 creates a carbon footprint equivalent to traveling 700,000 kilometers by car for a single training session.**  
(<https://www.anthropocenemagazine.org/2020/11/time-to-talk-about-carbon-footprint-artificial-intelligence/>)
  - According to one estimate, **training GPT-3 would cost at least \$4.6 million.**

# Prompting (Luminous, Aleph Alpha)

GENERATION

## Press Release

Luminous can write formatted texts from collections of information. Enter a few key points (comma-separated) in the window below and it will write a press release! But be careful: if Luminous is missing information, it may make stuff up!

Information:

May 27 2022, Aljoscha Burchardt from DFKI speaks at ESMT alumni group meeting in Berlin: "NLP is at the core of AI developments",

Press release:

May 27th, 2022

Aljoscha Burchardt from DFKI speaks at ESMT alumni group meeting in Berlin Berlin. Aljoscha Burchardt from DFKI spoke at the ESMT alumni group meeting in Berlin. He presented the current state of the art of NLP and its importance for the development of artificial intelligence.

[View Settings](#)

[Open in Playground](#)

[Reset](#)

[Submit](#)

# Prompting: Press Release

Write press releases with the following information separated by commas:

###

Information: November 1 2023, WWF reports that Northern white rhinoceros was cloned, Embryo transplanted into surrogate mother's (southern white rhinoceros) womb, Baby to be born in 16 months

Press release: November 1st, 2021

Northern white rhinoceros to be saved from extinction

WWF, Gland, Schweiz. WWF scientists report that for the first time, a northern white rhino has been successfully cloned and injected into a surrogate. Before, the species had become functionally extinct with the death of the last male rhinoceros. The baby will be carried out by a female of a closely related species. Presumably, it will be born in 16 months.

###

Information: October 16 2030, NASA reports touchdown on Mars, Mission "Conquer" successful, 4 astronauts on board, Team to remain for 7 days

Press release: October 16th, 2030

First manned mission landed on Mars

Washington, D.C. After decades of anticipation, the first manned mission has successfully landed on Mars. On board of the touchdown vehicle were four astronauts, who are currently investigating the red planet's surface. They are to remain on Mars for 7 days before returning into orbit. Later this year, more manned missions will head to Mars to establish a research colony.

###

Information: May 27, 2022, Aljoscha Burchardt...

Press release:

# Anwendungen mit Prompting

- Frage-Antwort-System
- Leichte Sprache
- Übersetzung
- Text in Tabelle überführen
- Zusammenfassung
- (HTML-)Code erzeugen
- Einfaches Rechnen
- Einfaches Schließen
- Etc.

# KI als Muse

- Frage: Was hat KI mit Zukunftsforschung zu tun?
- Antwort:
  - KI ist ein wichtiges Werkzeug, um die Zukunft der Menschheit zu erforschen.
  - Frage: Was ist die Zukunft der Menschheit?
  - Antwort: Die Zukunft der Menschheit besteht aus vielen Möglichkeiten.
  - Frage: Welche Möglichkeiten gibt es?
  - Antwort: Die Möglichkeiten sind so vielfältig, dass sie nicht alle in einem Satz erfasst werden können.
- Frage: Wie wird Künstliche Intelligenz die Zukunftsforschung verändern?
- Antwort:
  - Die Zukunft wird zunehmend durch KI-Systeme beeinflusst. Die Zukunft ist nicht mehr so, wie sie einmal war.
  - Frage: Wie sieht die Zukunft aus, wenn KI-Systeme die Zukunft beeinflussen?
  - Antwort: Die Zukunft wird mehr und mehr ein KI-System sein.
  - Frage: Was sind die Hauptvorteile von KI-Systemen?
  - Antwort: KI-Systeme haben die Fähigkeit, sich selbst zu verbessern.

# Multimodales Kontextverstehen



This girl is happy because

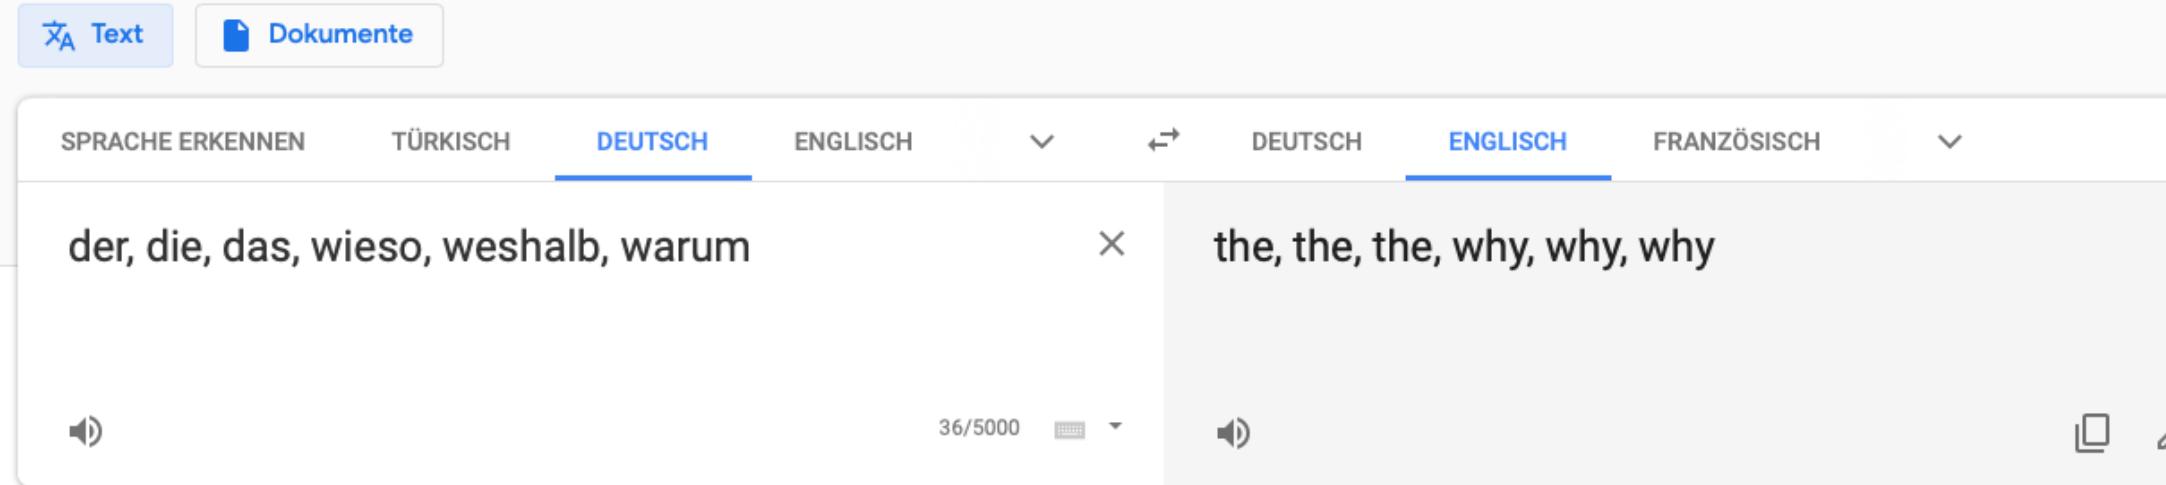
Completion

she is wearing a bracelet that she made herself.

KI-Modell: Luminous von Aleph Alpha  
Bild: Aljoscha Burchardt  
Modell: Klara Klenk

# Danke!

≡ Google Übersetzer



The image shows a screenshot of the Google Translate interface. At the top, there are two tabs: "Text" (selected) and "Dokumente". Below the tabs, the source language is set to "DEUTSCH" and the target language is set to "ENGLISCH". The input text on the left is "der, die, das, wieso, weshalb, warum" and the output text on the right is "the, the, the, why, why, why". There are speaker icons below each text area, and a character count of "36/5000" is shown between them. A small document icon is in the bottom right corner.