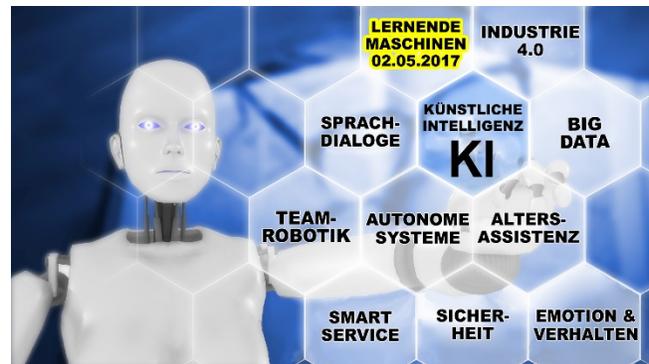


Künstliche Intelligenz versus menschliche Intelligenz: Wie lernen, verstehen und denken Computer?



Prof. Dr. rer. nat. Dr. h.c. mult.
Wolfgang Wahlster



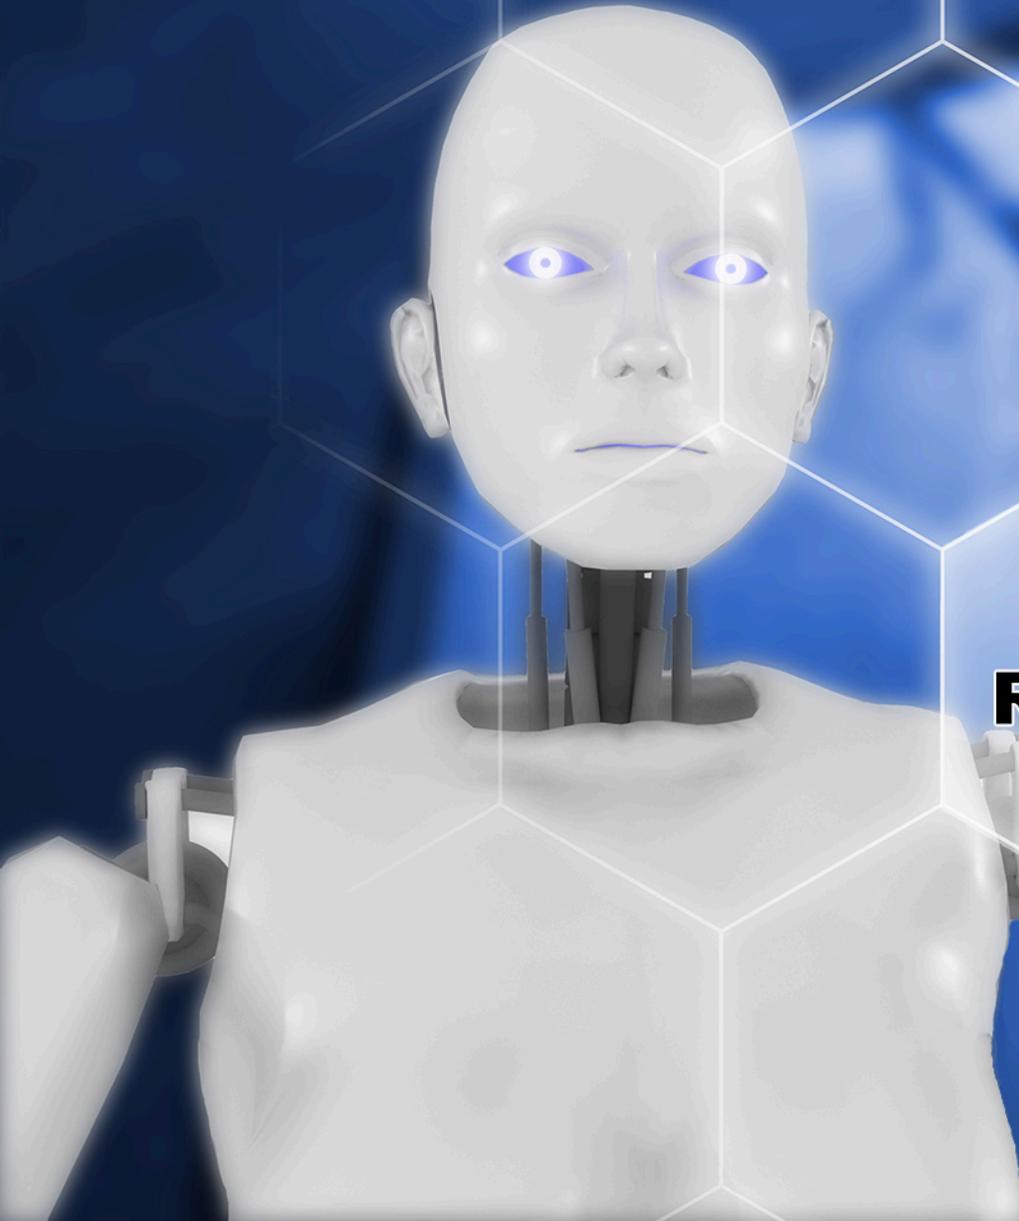
Deutsches Forschungszentrum für Künstliche Intelligenz GmbH
Saarbrücken/Kaiserslautern/Bremen/Berlin/Osnabrück

Tel.: (0681) 85775-5252

E-mail: wahlster@dfki.de

www.dfki.de/~wahlster





**LERNENDE
MASCHINEN**
02.05.2017

**INDUSTRIE
4.0**

**SPRACH-
DIALOGE**

**KÜNSTLICHE
INTELLIGENZ**

**BIG
DATA**

KI

**TEAM-
ROBOTIK**

**AUTONOME
SYSTEME**

**ALTERS-
ASSISTENZ**

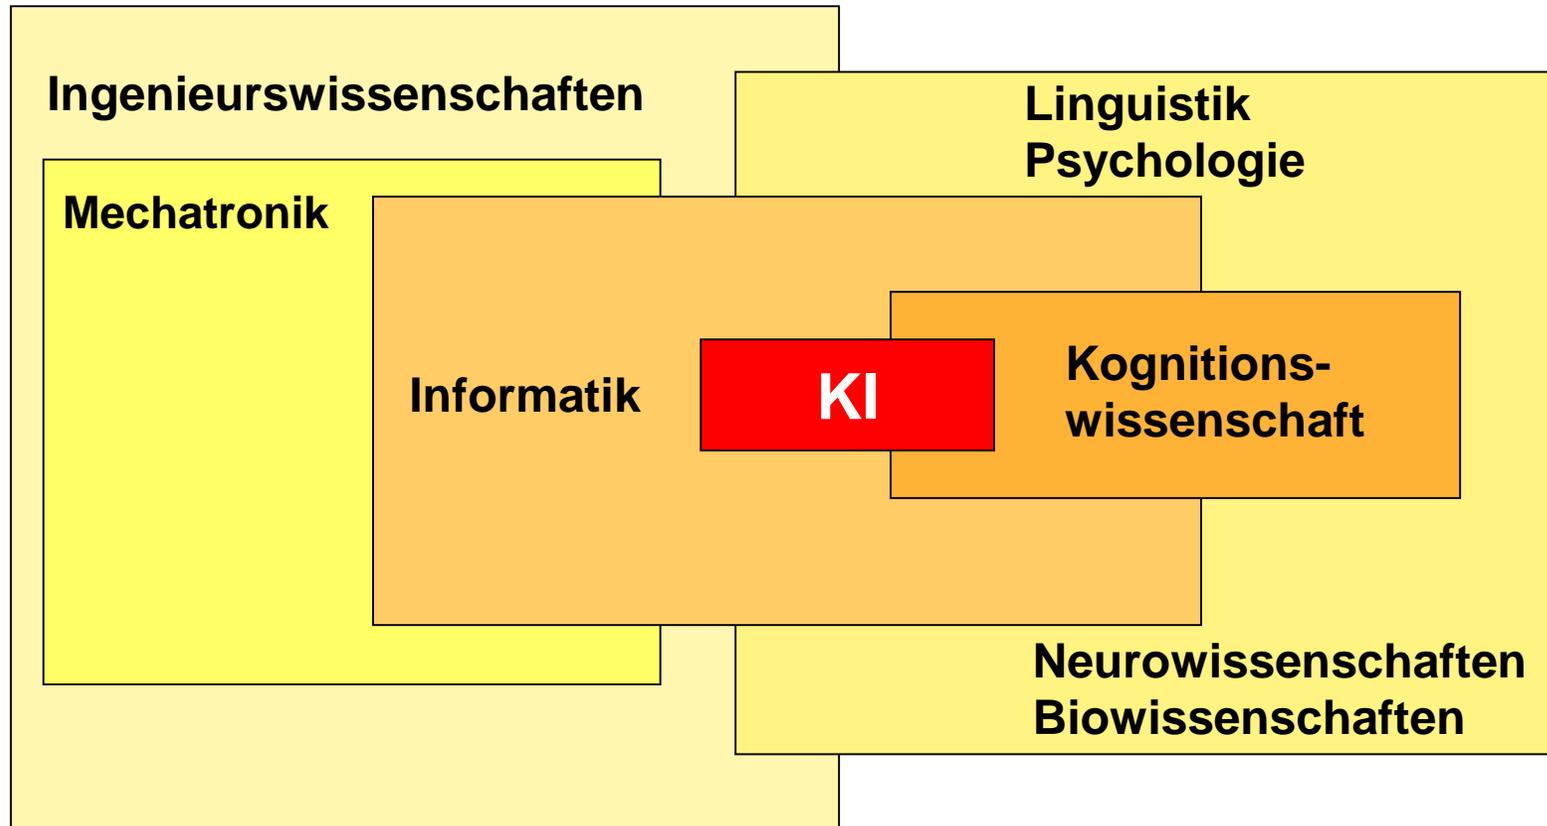
**SMART
SERVICE**

**SICHER-
HEIT**

**EMOTION &
VERHALTEN**

Künstliche Intelligenz (KI)

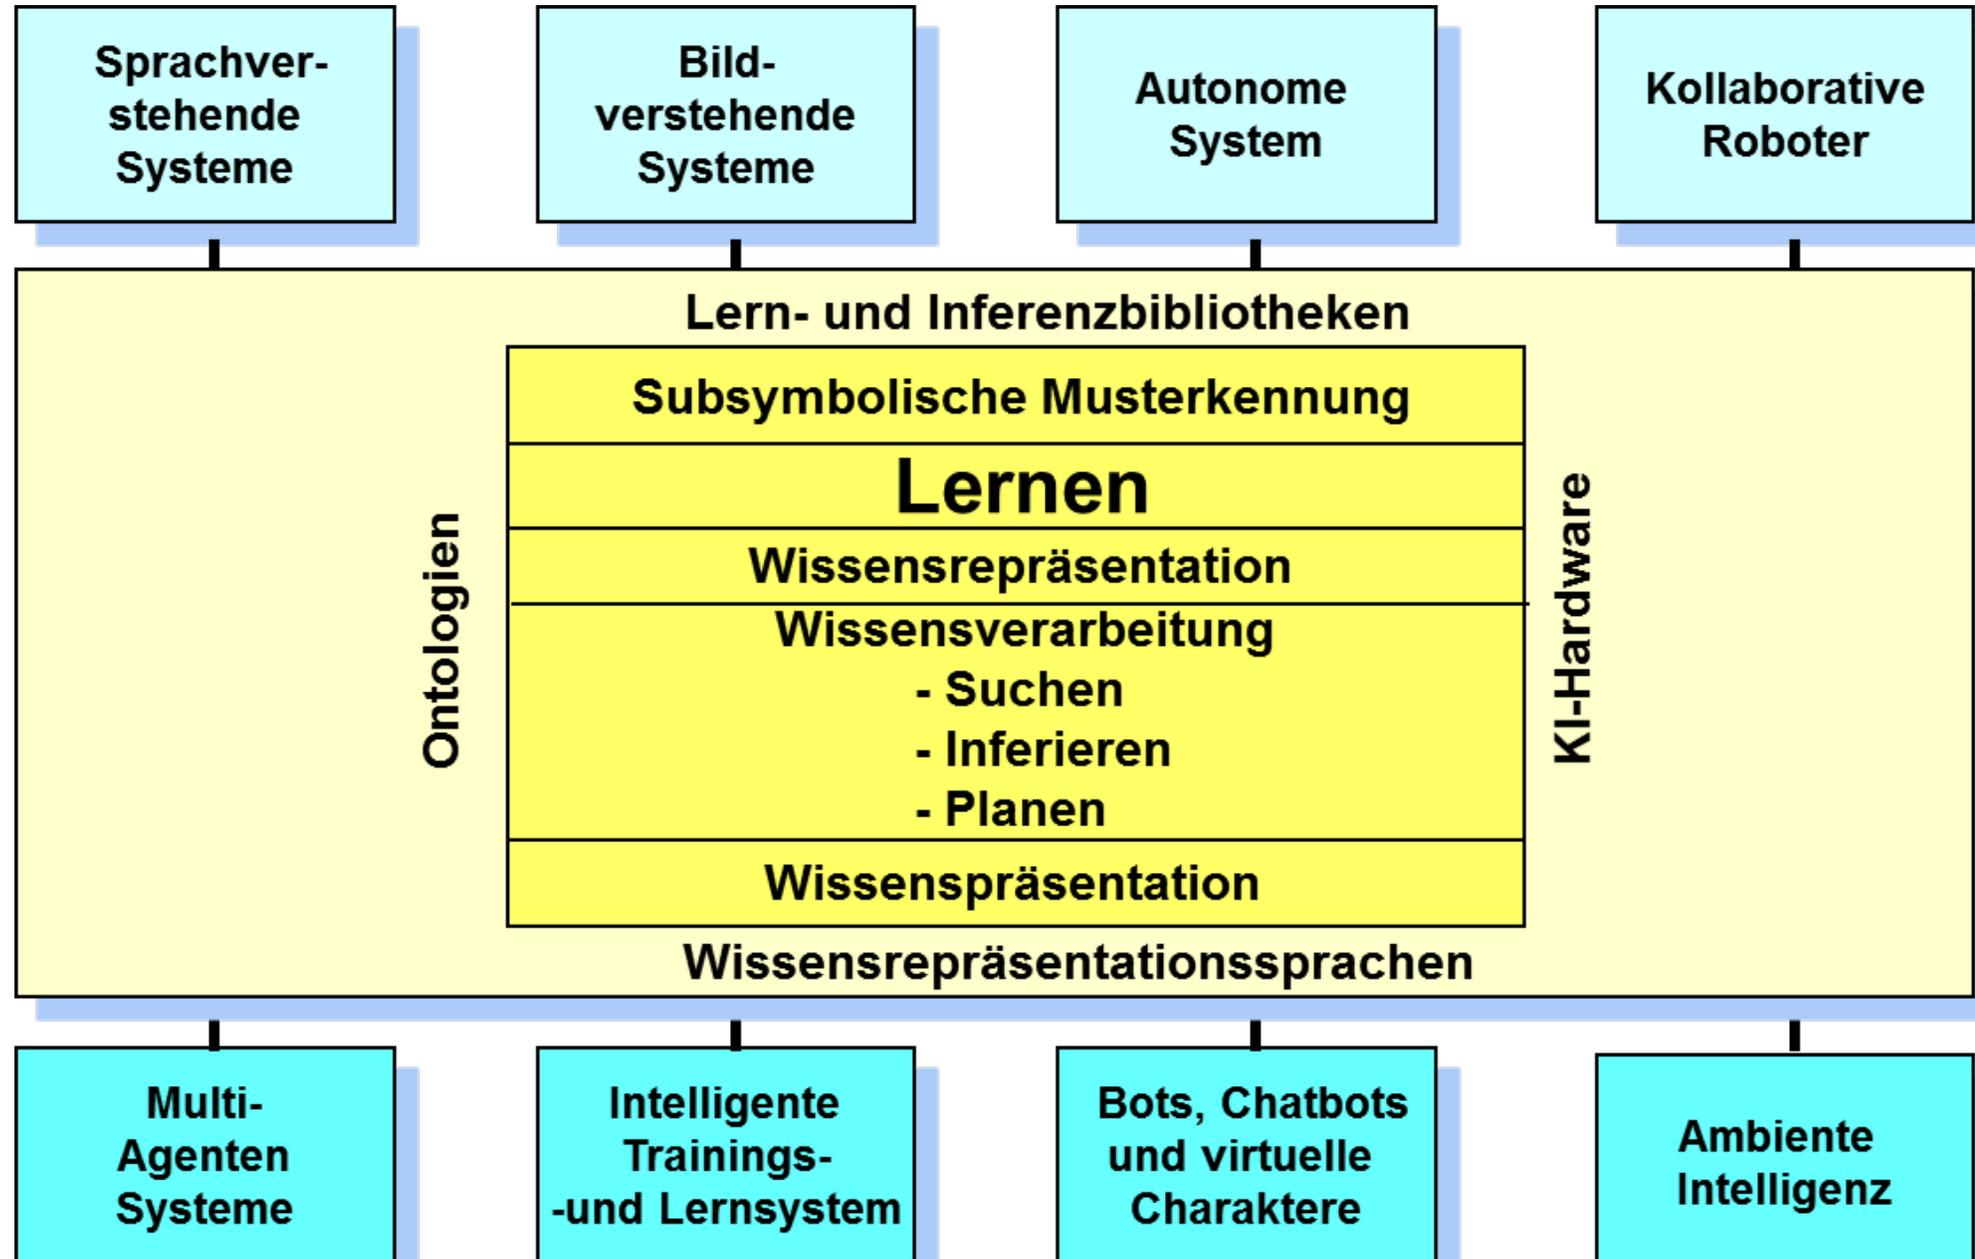
- Die KI hat:
- ingenieurswissenschaftliche Ziele
 - kognitionswissenschaftliche Ziele



Künstliche Intelligenz: Realisierung von intelligentem Verhalten und den zugrundeliegenden kognitiven Fähigkeiten auf Computern

KI = Künstliche Informatik

Kerngebiete und Einsatzfelder der KI



Wie können Computer menschliche Sprache, Gestik und Mimik verstehen und erzeugen?

Wie können mobile Roboter Teams bilden und gemeinsam Ziele erreichen?

Wie können Computer Bilder und Filme interpretieren und erzeugen?

Wie können Computer für den Menschen unzugängliche Orte explorieren?



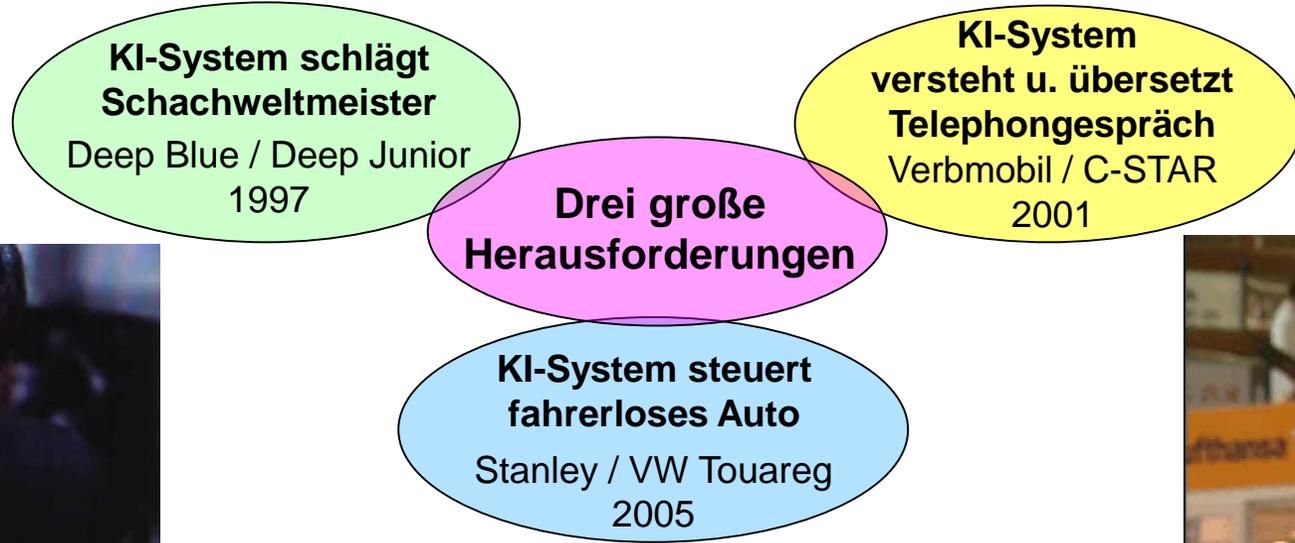
Wie können Computer aus Erfahrung lernen?

Wie können Computer zu intelligenten Assistenten für den Menschen werden?

Wie können Computer Emotionen von Menschen erkennen und darauf reagieren?

Wie können Computer auch aus unsicherer Information nützliche Schlussfolgerungen ziehen?

Durchbruchserfolge nach 60 Jahren Forschung zur Künstlichen Intelligenz



Die Erfolge des Deep Machine Learning im Bereich der Brett- und Kartenspiele



- 1980 BKG 9.8 schlägt Weltmeister im Backgammon**
- 1997 Deep Blue schlägt Schachweltmeister**
- 2016 AlphaGo schlägt Go-Großmeister**
- 2017 KI-System Libratus schlägt Poker-Profis**

Deutschland hat das weltweit größte Forschungszentrum für Künstliche Intelligenz



Die sieben Zukunftslabore am DFKI



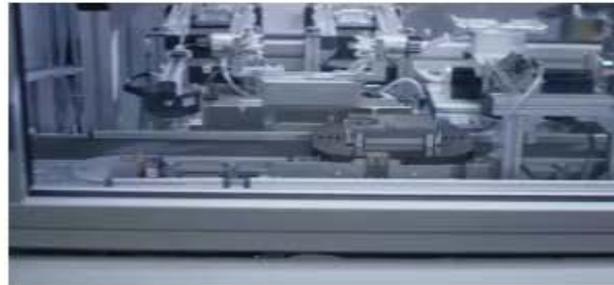
Der Supermarkt der Zukunft
IRL



Das Auto der Zukunft
ADAS



Die Seniorenwohnung der Zukunft
BAALL



Die Fabrik der Zukunft
Smart Factory



Die Roboter der Zukunft
RIC



Die Stadt der Zukunft
Smart City



Das Büro der Zukunft
smart office space

Künstliche Intelligenz für die zweite Welle der Digitalisierung

Erste Welle:

Daten digital

- Erfassen
- Speichern
- Übertragen
- Verarbeiten

Zweite Welle:

Daten digital

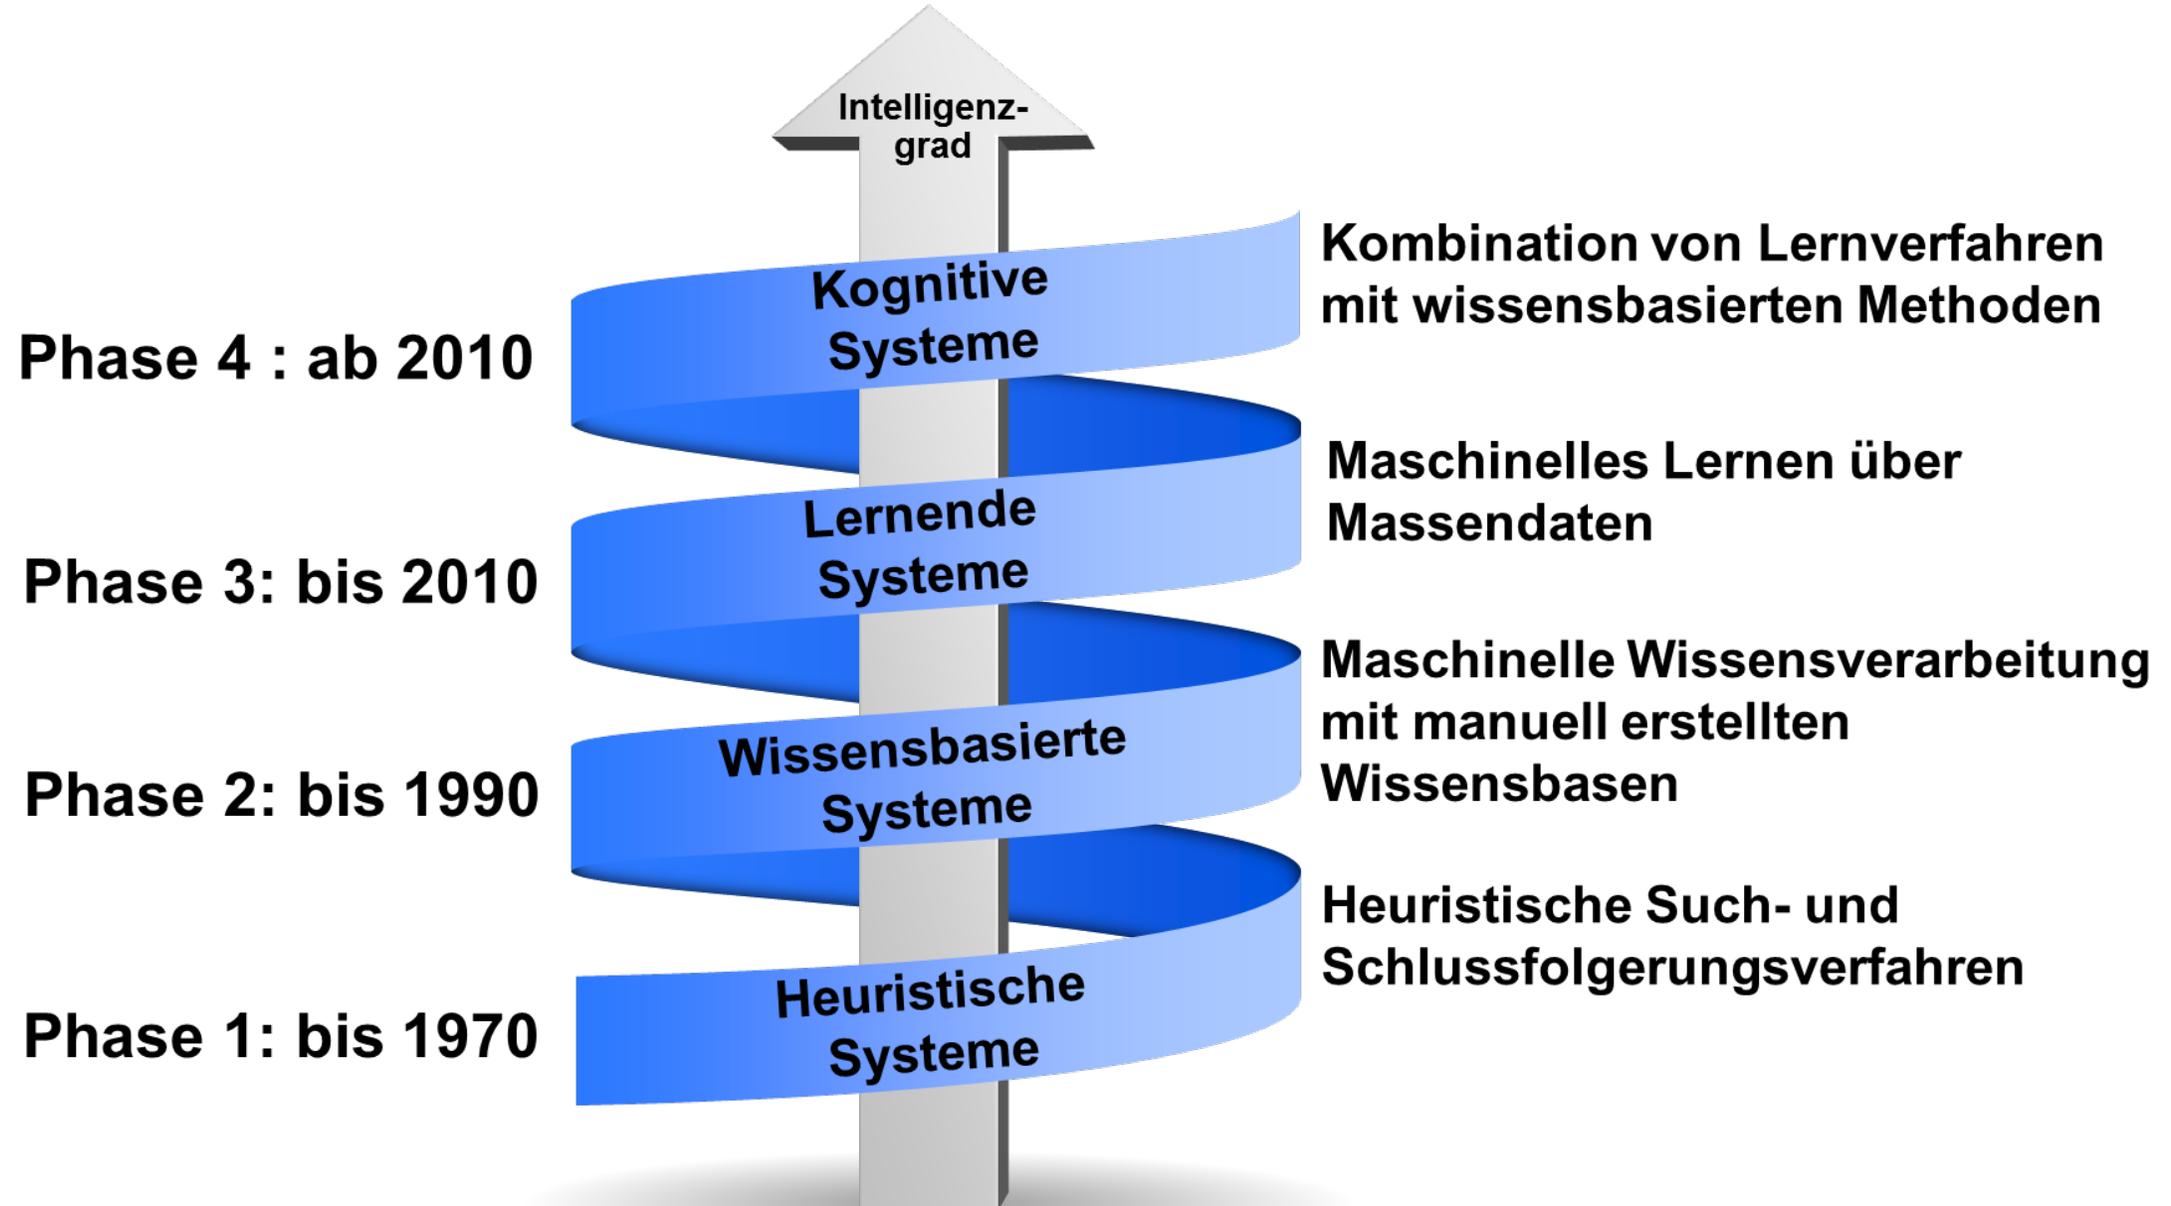
- Verstehen
- Veredeln
- Aktiv nutzen
- Monetarisieren

Maschinenlesbare Daten:
Internet- und Cloudtechnologien

Maschinenverstehbare Daten:
Künstliche Intelligenz und Maschinelles Lernen

➔ Digitalisierung „mit Sinn und Verstand“

Die vier Phasen der KI-Forschung



Regelbasierte Wissenverarbeitung

Regel 1
Wenn (Anlasser arbeitet normal)
Dann (Batterie OK)

Regel 2
Wenn (Batterie OK)
Und (Benzinfilter sauber)
Dann (Problem = Zündanlage)

Regel 3
Wenn (Batterie OK) Und (Wert Tankuhr > 0)
Und (nicht Benzinfilter sauber)
Dann (Defekt = Benzinzuleitung)

Regel 4
Wenn (nicht Scheibenwischer OK) Und (nicht Licht OK)
Dann (Defekt = Batterie leer)

Regel 5
Wenn (nicht Wert Tankuhr > 0)
Dann (Defekt = Tank leer)

Regel 6
Wenn (Problem = Zündanlage)
Und (Verteilerdose OK)
Dann (Defekt = Zündspule)

**Regel
Interpretation**

Batterie OK

Anlasser arbeitet normal
Scheibenwischer OK
Licht OK
Wert Tankuhr > 0
Benzinfilter sauber
Verteilerdose OK



**Regelbasis,
Faktenbasis,
Regel-Interpretation**

Emergente Softwaresysteme – Parallele Regelinterpretation in Agentensystem



Lokales Verhalten jedes Agenten führt zu globaler Kollisionsfreiheit
Skalierbarkeit: 10, 100, 10 000 Agenten

Nicht-monotones Schließen – Vorläufige Schlüsse unter Annahmen

- Das meiste, was wir über die Welt wissen, ist nur „fast immer“ wahr.
- Wir haben nie vollständiges Wissen über die Welt.

→ Ein Vogel fliegt typischerweise, soweit es nicht gerade ein Pinguin, Strauß, Kiwi, usw. ist. Mögliche Formalisierung:

$$\forall x: \text{Vogel}(x) \wedge \neg \text{Pinguin}(x) \wedge \neg \text{Strauß}(x) \dots \\ \Rightarrow \text{Fliegt}(x)$$

→ Probleme:

- 1) Können wir je „...“ vollständig angeben?
- 2) Wir können nicht für irgendeinen Vogel schließen, dass er fliegen kann, wenn wir nicht wissen, dass er kein Pinguin, kein Strauß, kein Kiwi und kein ... ist.



Lösungsansatz: Default-Logik in der KI

→ Wir würden gern etwas wie „Vögel fliegen typischerweise“ haben.

- **Möglichkeit:** Zusätzliche (nicht-logische) Inferenzregeln:

$$\frac{\text{Vogel}(x) : \text{Fliegt}(x)}{\text{Fliegt}(x)}$$

Intendierte Bedeutung:

Wenn x ein Vogel ist, und die Annahme $\text{Fliegt}(x)$ *möglich ist ohne zu Inkonsistenz zu führen*, dann nehme $\text{Fliegt}(x)$ an.



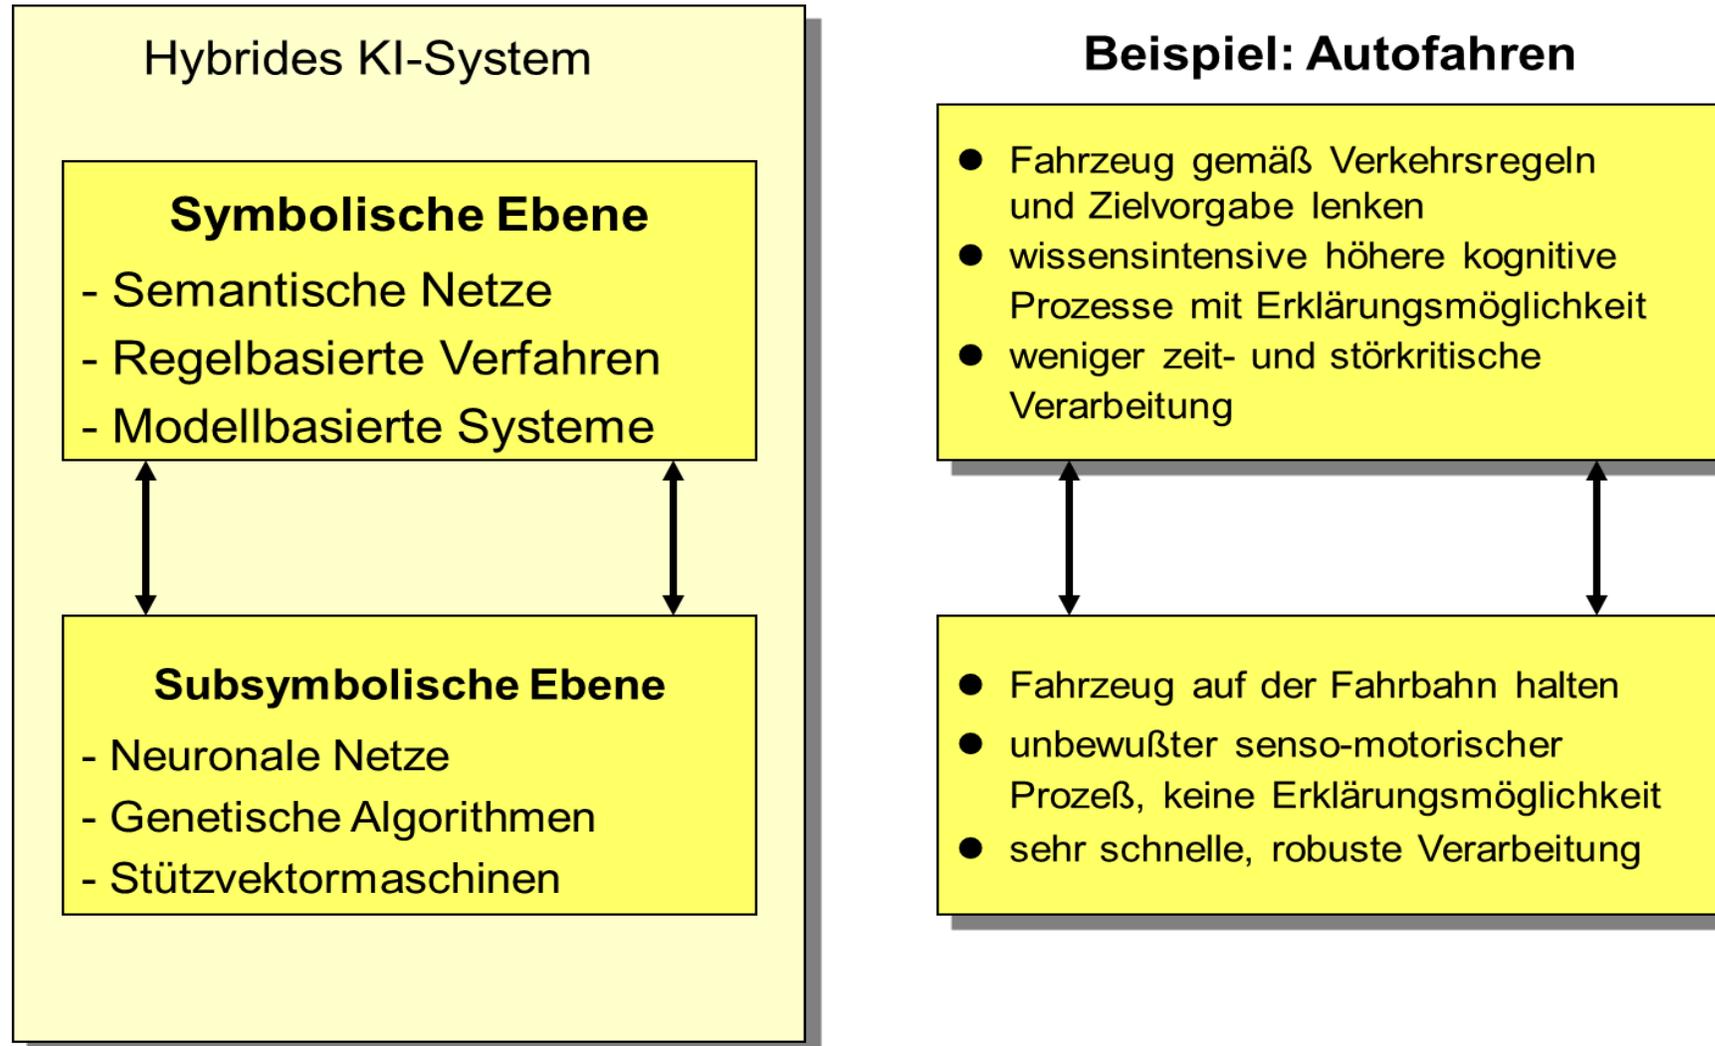
- **Ausnahmen** werden dann durch einfache Implikationen dargestellt:

$$\forall x: \text{Pinguin}(x) \Rightarrow \neg \text{Fliegt}(x)$$

$$\forall x: \text{Strauß}(x) \Rightarrow \neg \text{Fliegt}(x)$$

$$\forall x: \text{Kiwi}(x) \Rightarrow \neg \text{Fliegt}(x)$$

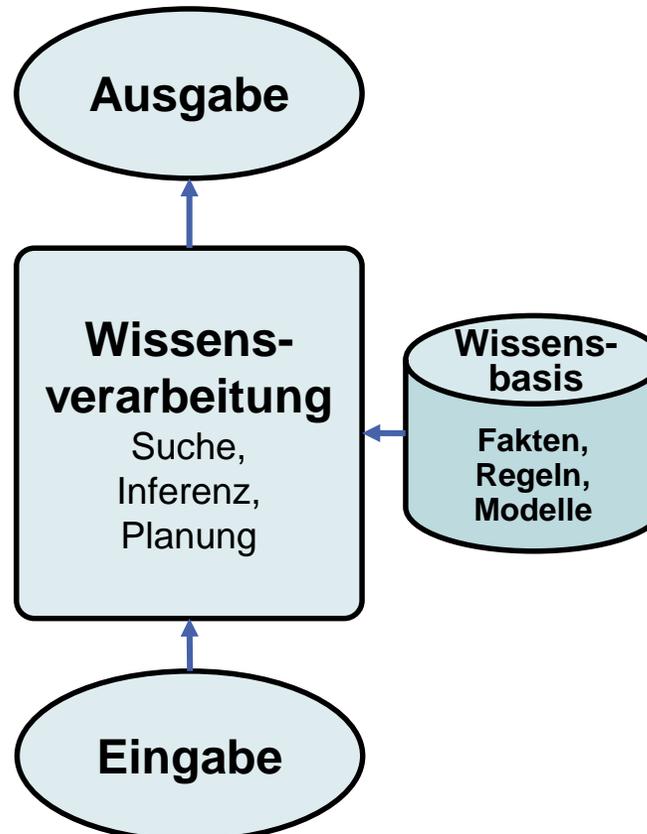
Die Notwendigkeit hybrider KI-Systeme



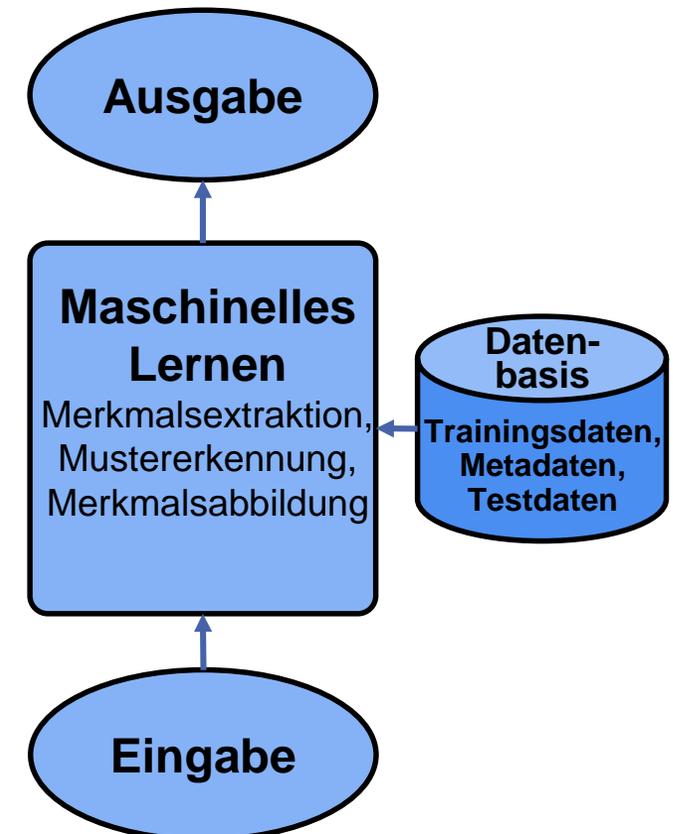
Von programmierten Systemen zu selbstlernenden Systemen



- Flaschenhals: Programmierer**
- hoher Entwicklungsaufwand
 - aufwändige Adaption
 - geringe Erklärungsfähigkeit



- Flaschenhals: Wissensbasis**
- hoher Entwicklungsaufwand
 - hoher Pflegeaufwand
 - + gute Erklärungsfähigkeit



- Flaschenhals: Trainingsdaten**
- + geringer Entwicklungsaufwand
 - + leichte Anpassbarkeit
 - schlechte Erklärungsfähigkeit

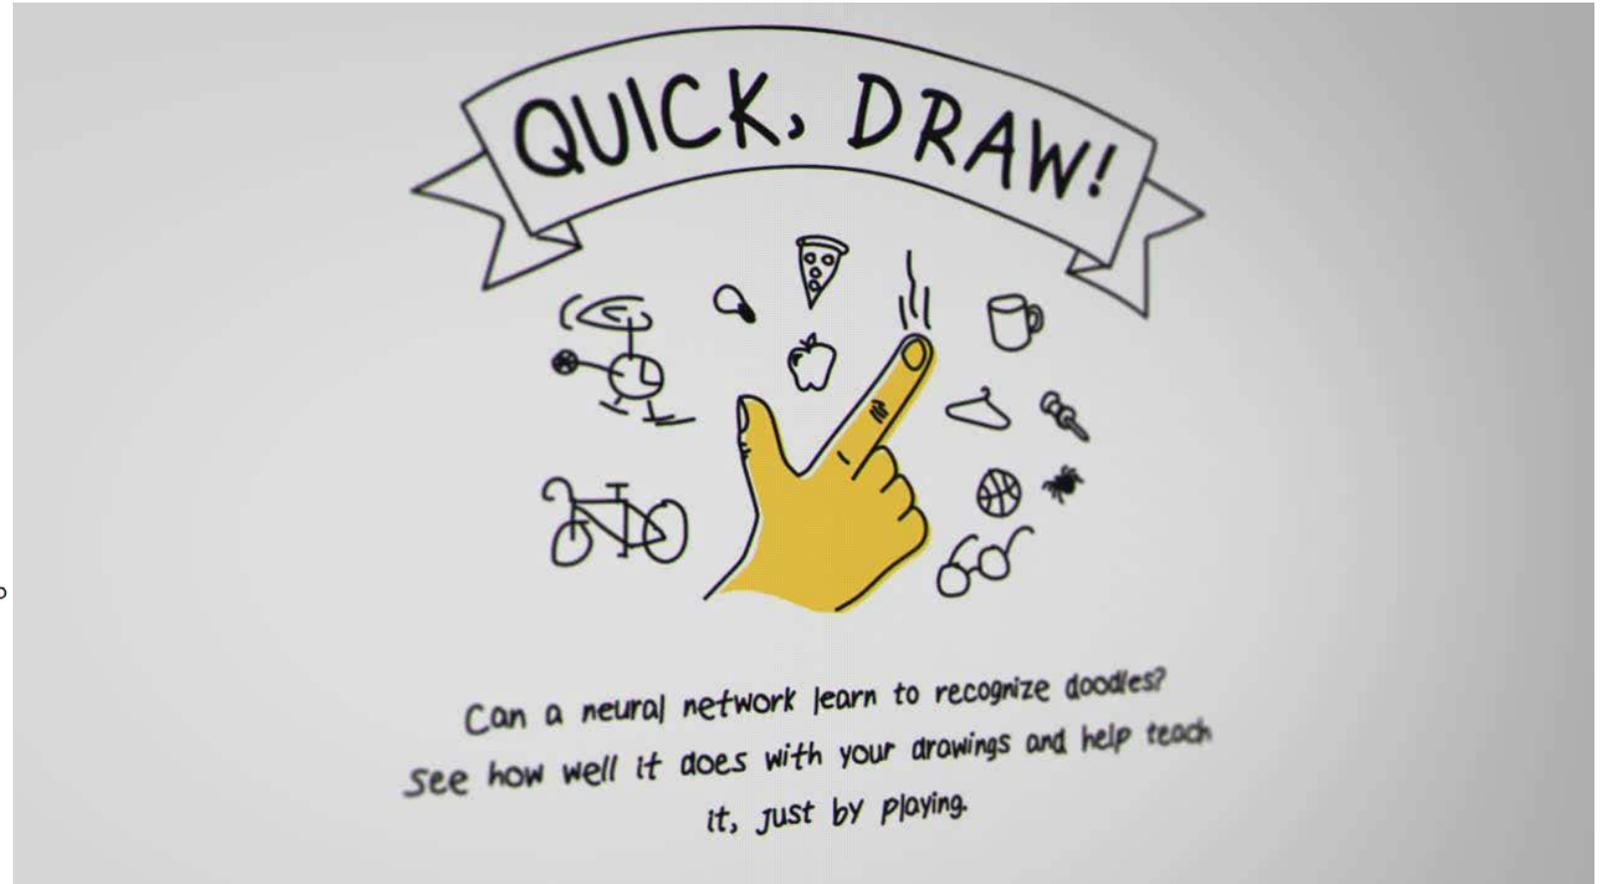
Maschinelles Lernen zur inkrementellen Erkennung von Objekten in Strichzeichnungen: Quick, Draw ! von Google



Can a neural network learn to recognize doodles?

Help teach it by adding your drawings to the world's largest doodle data set, which could be shared publicly to help with machine learning research in the future.

Let's Draw!



Einfaches Beispiel einer Klassifikationsaufgabe für überwachtes Lernen

$f(\text{) = \text{“Merkel”}$

$f(\text{) = \text{“Gabriel”}$

$f(\text{) = \text{“Merkel”}$

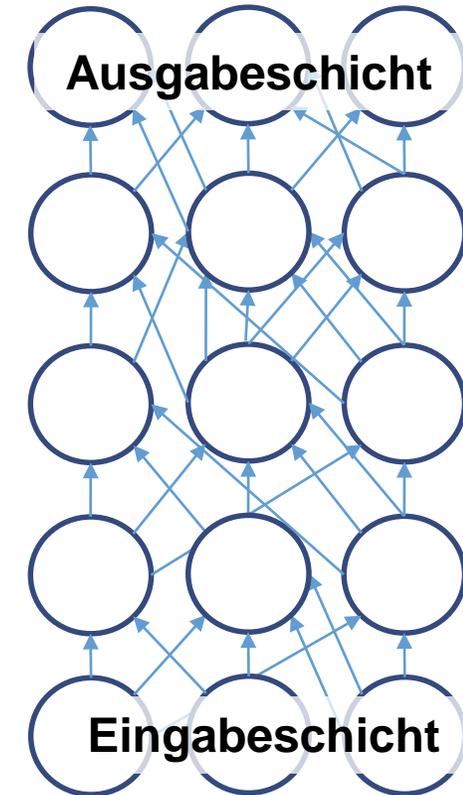
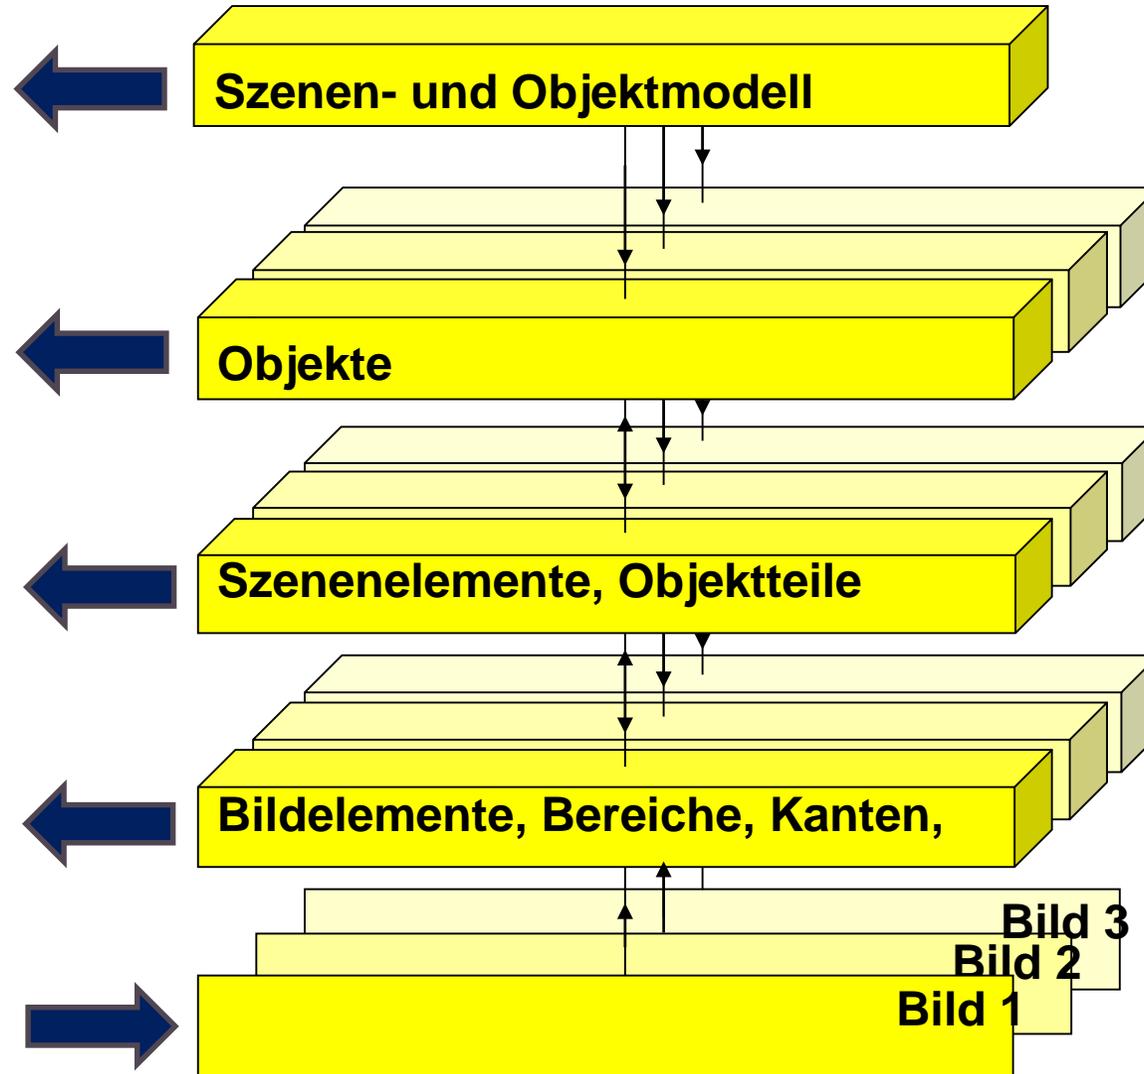
$f(\mathbf{x}) = y$; $y =$ Ausgabe, $x =$ Eingabe, $f =$ Klassifikationsfunktion

Trainingsphase: Generieren einer Funktion f , die den Klassifikations-fehler über den Trainingsdaten minimiert.

Testphase: Anwendung von f auf Daten, die nicht in den Trainingsdaten enthalten waren.

Deep Learning für das Bildverstehen: Netzwerke aus mehreren Schichten merkmalserkennender Neuronen

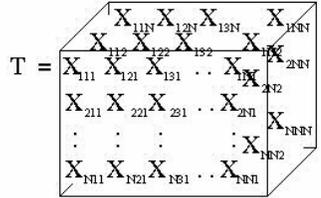
Unfall auf
Landstraße



TensorFlow von Google als Werkbank für das Maschinelle Lernen



TensorFlow als Graph von Operationen über Tensor Datenpaketen



- Ein Skalar ist ein Tensor
- Ein Vektor ist ein Tensor
- Eine Matrix ist ein Tensor

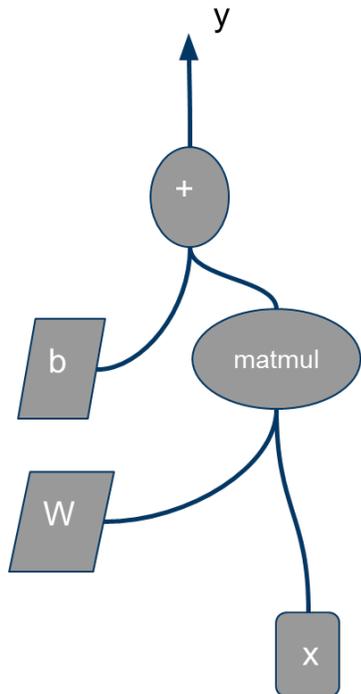
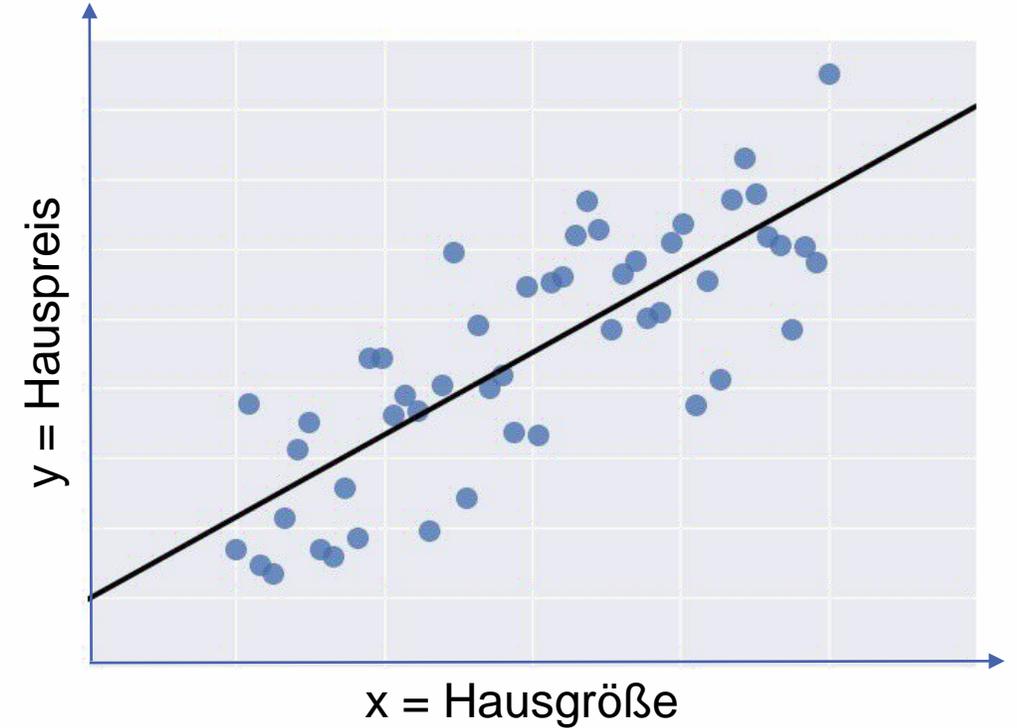
$$y = Wx + b$$

Ausgabe

Eingabe

Gewicht

Schätzfehler



Beispiel: Finde Hauspreis (\mathbf{y}) abhängig von der Hausgröße (\mathbf{x}), vereinfacht weil multidimensional, z.B. Hauslage, Hausalter, Hauszustand

Ziel: Suche gute Schätzungen für \mathbf{w} und \mathbf{b}

TensorFlow-Programmcode in der Programmiersprache Python

```
import tensorflow as tf
x = tf.placeholder(shape=[None],
                  dtype=tf.float32,
                  name='x')

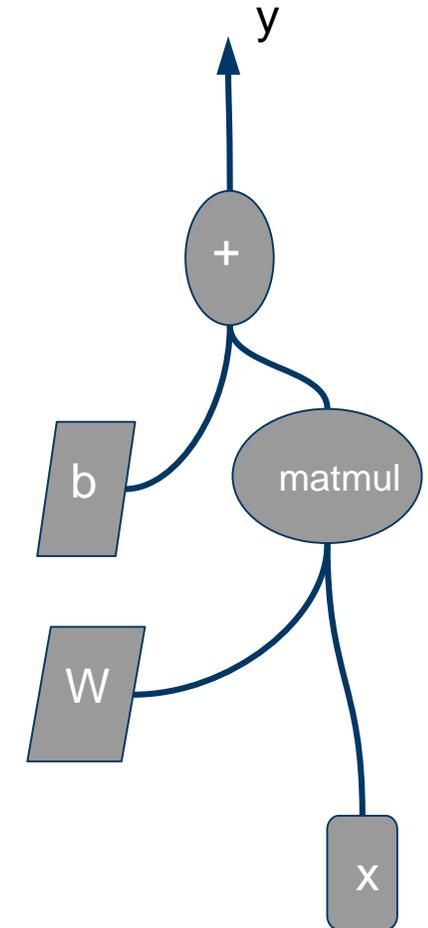
W = tf.Variable(tf.random_normal([1], name="W"))
b = tf.Variable(tf.random_normal([1], name="b"))
y = W * x + b
```

```
with tf.Session() as sess:

    sess.run(tf.initialize_all_variables())

    print(sess.run(y, feed_dict={x: x_in}))
```

Aufbau des Graphmodells



Start der Lernumgebung

Initialisierung der Variablen

Start des Trainings

Klassifikation von drei Schwertlilienarten durch ein TensorFlow-Modell

```
import tensorflow as tf
import numpy as np

# Data sets
IRIS_TRAINING = "iris_training.csv"
IRIS_TEST = "iris_test.csv"

# Load datasets.
training_set = tf.contrib.learn.datasets.base.load_csv_with_header(
    filename=IRIS_TRAINING,
    target_dtype=np.int,
    features_dtype=np.float32)
test_set = tf.contrib.learn.datasets.base.load_csv_with_header(
    filename=IRIS_TEST,
    target_dtype=np.int,
    features_dtype=np.float32)

# Specify that all features have real-value data
feature_columns = [tf.contrib.layers.real_valued_column("", dimension=4)]

# Build 3 layer DNN with 10, 20, 10 units respectively.
classifier = tf.contrib.learn.DNNClassifier(feature_columns=feature_columns,
                                          hidden_units=[10, 20, 10],
                                          n_classes=3,
                                          model_dir="/tmp/iris_model")

# Fit model.
classifier.fit(x=training_set.data,
              y=training_set.target,
              steps=2000)

# Evaluate accuracy.
accuracy_score = classifier.evaluate(x=test_set.data,
                                    y=test_set.target)["accuracy"]
print('Accuracy: {0:f}'.format(accuracy_score))

# Classify two new flower samples.
new_samples = np.array(
    [[6.4, 3.2, 4.5, 1.5], [5.8, 3.1, 5.0, 1.7]], dtype=float)
y = list(classifier.predict(new_samples, as_iterable=True))
print('Predictions: {}'.format(str(y)))
```

Sepal Length	Sepal Width	Petal Length	Petal Width	Species
6.4	2.8	5.6	2.2	2
5	2.3	3.3	1	1
4.9	2.5	4.5	1.7	2
4.9	3.1	1.5	0.1	0
5.7	3.8	1.7	0.3	0
4.4	3.2	1.3	0.2	0
5.4	3.4	1.5	0.4	0
6.9	3.1	5.1	2.3	2
6.7	3.1	4.4	1.4	1
5.1	3.7	1.5	0.4	0
5.2	2.7	3.9	1.4	1
6.9	3.1	4.9	1.5	1
5.8	4	1.2	0.2	0
5.4	3.9	1.7	0.4	0



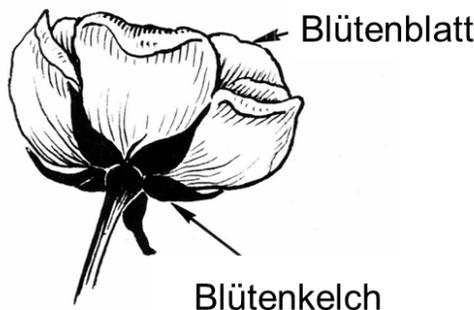
Iris setosa (0)



Iris versicolor (1)

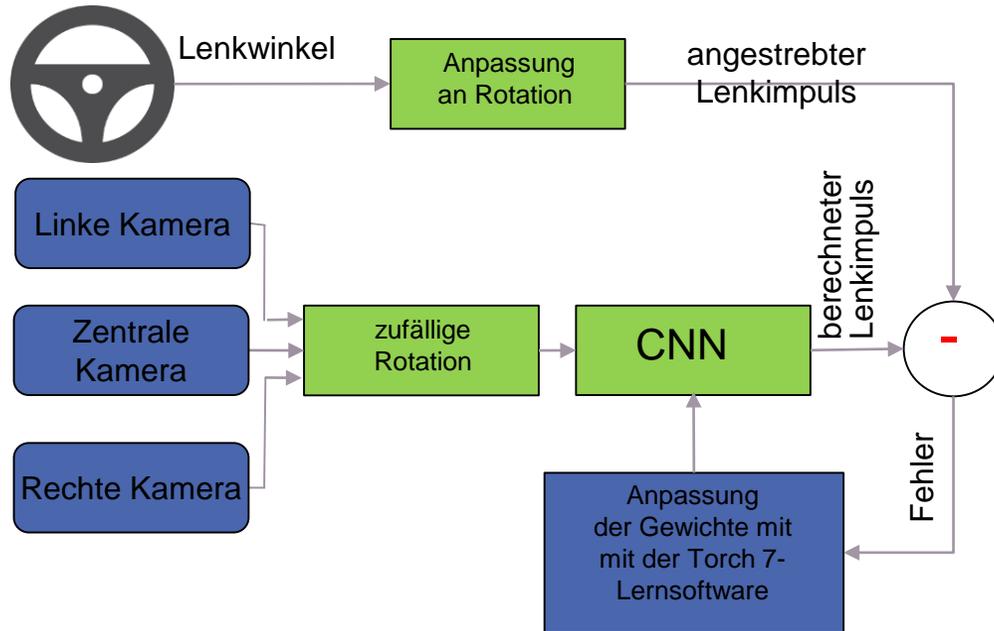


Iris virginica (2)



/

DAVE2 von NVIDIA: End-to-End CNN-Lernen für Autopilotfunktion



Training des Neuronalen Netzwerks



Das trainierte Netzwerk

72 Stunden Videos (10 Bilder pro Sekunde) mit Lenkwinkel als Trainingsdaten (auch bei Regen, Schnee, Nebel, Sonnenblendung)

Lernen eines CNN-Modells mit:

- 5 Verdeckten Schichten
- 27 Millionen Verbindungen
- 250.000 Parameter

16 km auf Landstrasse 100% autonom, durchschnittlich 98% autonom

Trend: Durchgängige End-to-End-Lernsysteme

Verzicht auf Merkmalsextraktion und Problemdekomposition:

Lernen einer **direkten Abbildung** von Eingabemustern auf die angestrebte Ausgabe mit ***Konvolutionalen Neuronalen Netzen (CNN)***

Beispiele für erste Erfolge:

1. Autonomes Fahren: Kamera-Pixel → Lenkbewegung
2. Übersetzung: Buchstabenfolge in Quelltext → Zieltext
3. Domänenspezifische Dialogsysteme: Frage → Antwort

Einige offene Probleme beim maschinellen Lernen

- Erfolgreiches Lernen bei sehr wenigen Trainingsdaten
- Verständliche Erklärung und Begründung der Lernergebnisse für den Endanwender
- Robustheit gegenüber geringfügigen Transformationen über Trainingsdaten
- Aufwandsreduktion zur Datenannotation für das überwachte Lernen
- Überanpassung durch zu lange Trainingsdauer



Imitationslernen



Im April 2017 waren bereits 4700 Teilnehmer eingeschrieben. In 3 Kurswochen bieten Wissenschaftler, Vertreter aus Unternehmen, Entwickler und Anwender in insgesamt 38 Videos Orientierungswissen für das maschinelle Lernen.

MOOC.HOUSE <https://mooc.house/courses/machinelearning-2016>

Das Paradoxon der Künstlichen Intelligenz

In der KI-Forschung gilt: **Schwere** Probleme sind **leicht**,
leichte Probleme sind **schwer**.

Expertenintelligenz

Kognitive und wissensintensive Fähigkeiten
Spätes Evolutionsstadium

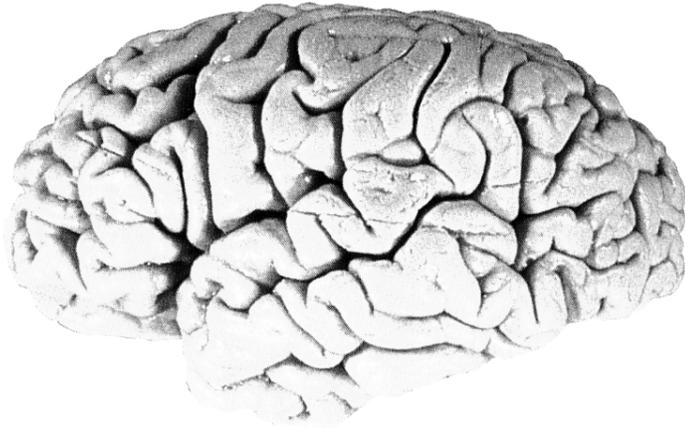
- Fehler im Computer-Chip finden
- Schachmeister besiegen
- Stahlproduktion optimieren

Alltagsintelligenz

Sensomotorische & sozioemotionale Fähigkeiten
Frühes Evolutionsstadium

- SIM-Karte wechseln
- Witz verstehen
- Kind trösten

Vergleich der Informationsverarbeitungsleistung: Mensch-Computer



Menschliches Gehirn

10.000 Teraflops

ca. 1400 g schwer

Energietagesbedarf: ca. 9.000 KJ



Weltschnellster Supercomputer Sunway

93.000 Teraflops

mehr als 100 Tonnen schwer

Energietagesbedarf: 73.983.041 KJ

Die Bandbreite menschlicher Perzeption

Sensor system	Gesamte Bandbreite (Bit/Sek.)	Bewußt wahrgenommene Bandbreite (Bit/Sek.)
 <p>Sehen</p>	10.000.000	40
 <p>Hören</p>	100.000	30
 <p>Tasten</p>	1.000.000	5
 <p>Schmecken</p>	1.000	1
 <p>Riechen</p>	100.000	1

nach: R. Kay 2001

Künstliche Intelligenz versus menschliche Intelligenz



versus



Dimensionen der Intelligenz



Sensomotorische Intelligenz

+

++



Kognitive Intelligenz

++

+



Emotionale Intelligenz

-

++



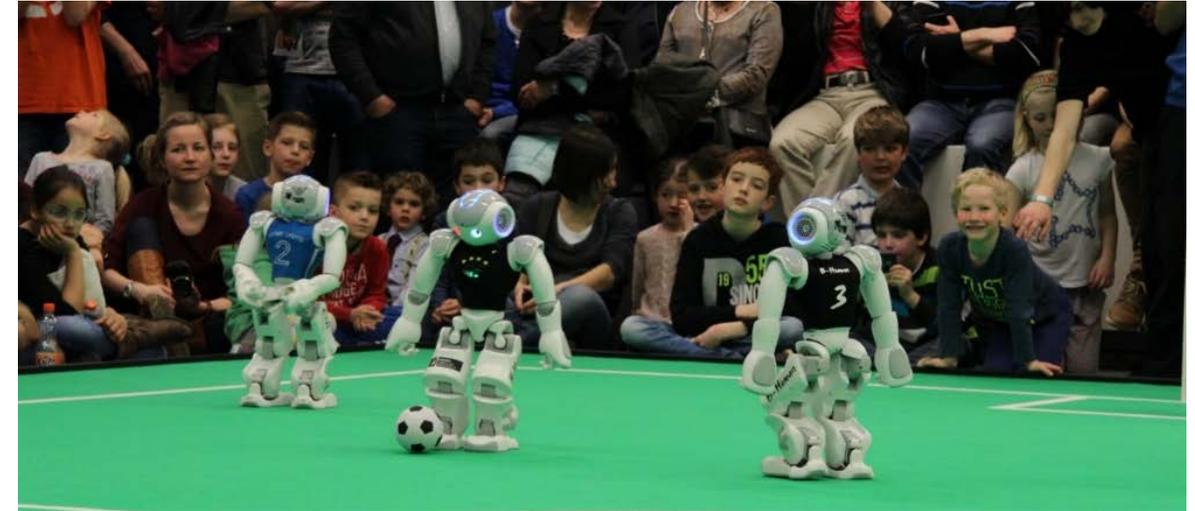
Soziale Intelligenz

-

++

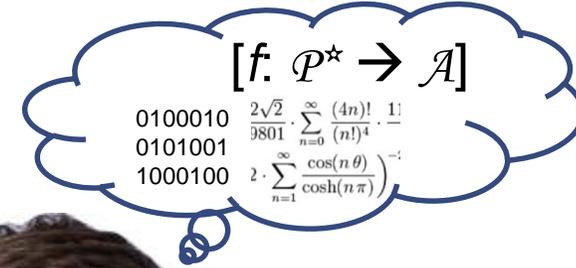
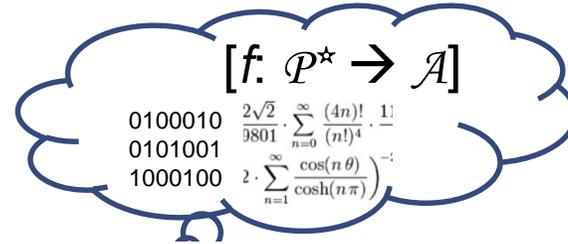
Sensormotorische und Soziale Intelligenz für das Teamplay im Roboterfußball

Das DFKI-Team B-Human ist seit Juli 2016 zum fünften Mal Weltmeister.



- Die Roboter geben viel zu selten ab und wollen lieber selbst die Tore schießen.
- Der Doppelpass und die Abseitsfalle sind bisher nur über aufwändige Softwaresysteme zu realisieren.

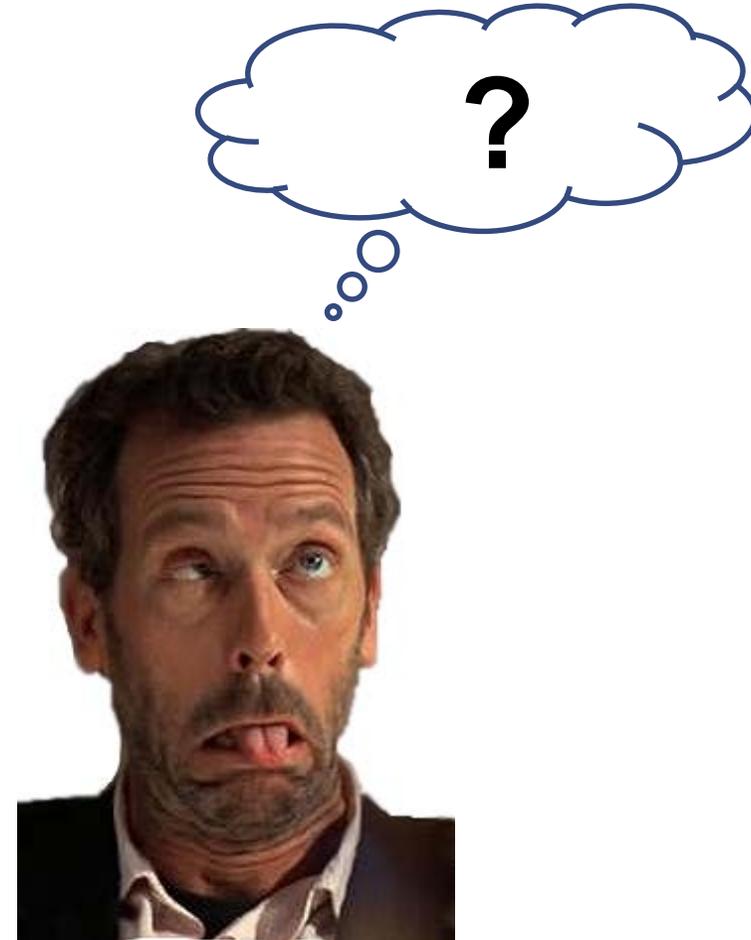
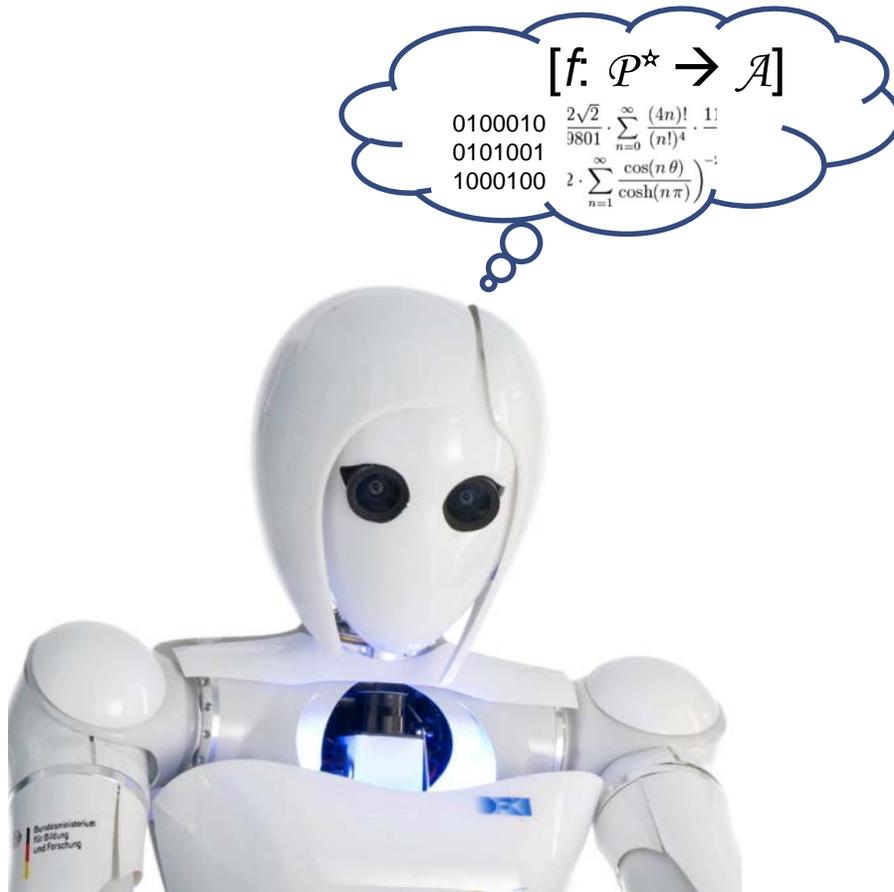
Künstliche Intelligenz besser als menschliche Intelligenz?

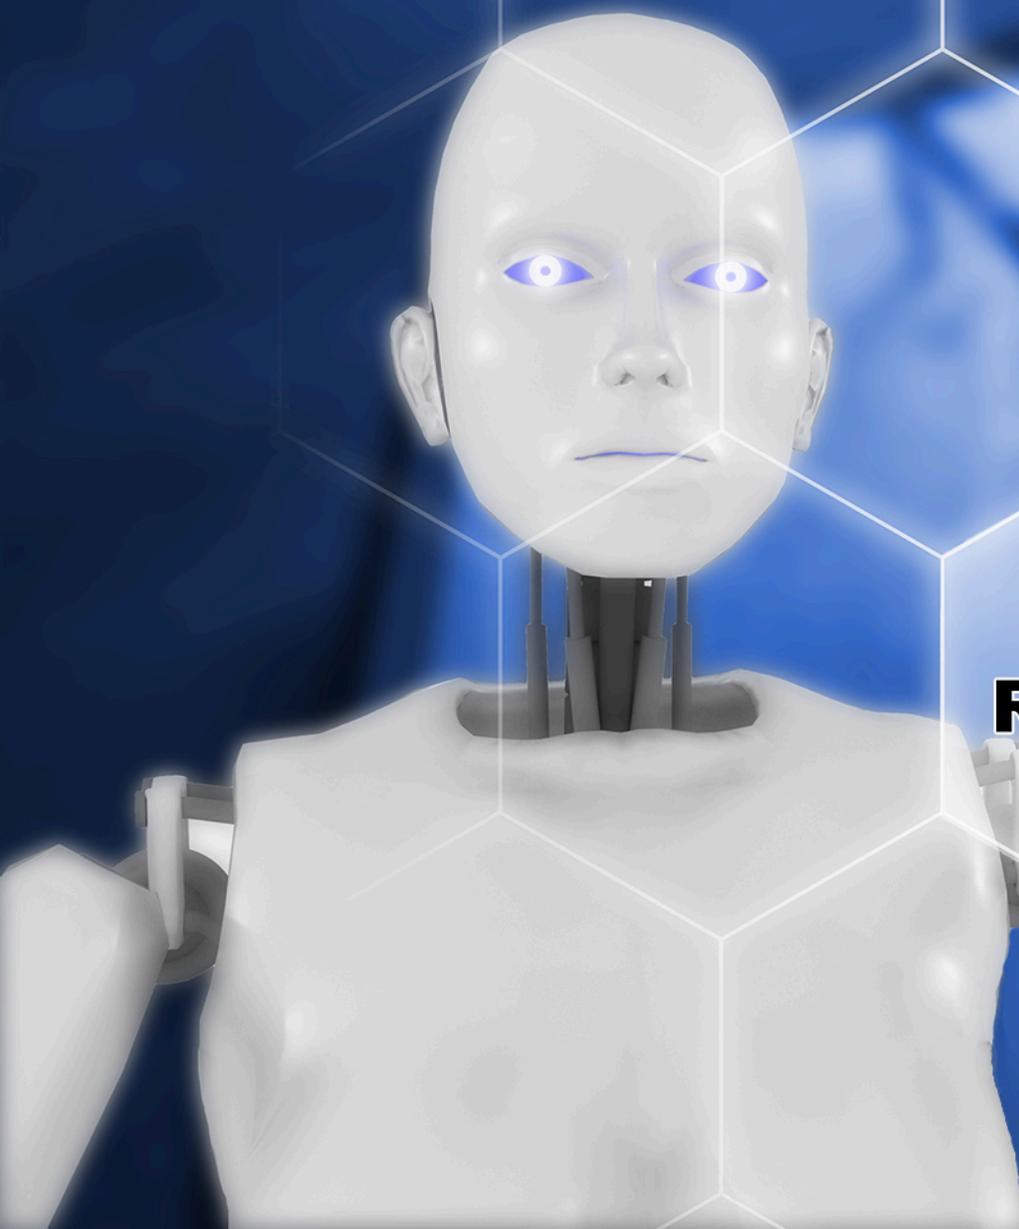


Antwort : Noch lange nicht !

Aber:

Künstliche Intelligenz ist besser als natürliche Dummheit.





LERNENDE
MASCHINEN
02.05.2017

**INDUSTRIE
4.0**

**SPRACH-
DIALOGE
09.05.2017**

KÜNSTLICHE
INTELLIGENZ

KI

**BIG
DATA**

**TEAM-
ROBOTIK**

**AUTONOME
SYSTEME**

**ALTERS-
ASSISTENZ**

**SMART
SERVICE**

**SICHER-
HEIT**

**EMOTION &
VERHALTEN**

Vielen Dank für Ihre Aufmerksamkeit

