

Prof. Dr. Klaus Henselmann

Lehrstuhl für Rechnungswesen
und Prüfungswesen

„Künstliche Intelligenz“ als Allheilmittel?

Melanom | Künstliche Intelligenz erkennt Hautkrebs besser als Ärzte

Medizindaten

Datenexperte de Witte: KI wird die Medizin revolutionieren


Milchanlieferung

Arla: Künstliche Intelligenz sagt Milchmenge voraus

Künstliche Intelligenz

Intelligente Fertigung mit künstlicher Intelligenz

Smart Predictive Maintenance zum frühzeitigen Erkennen von Fehlerquellen



Agenda

1. Was ist künstliche Intelligenz?
2. „Überleben“ – Maschinelles Lernen im Beispiel
3. Übertragung auf Kreditvergabe
4. Ethik und Recht bei KI-Modellen
5. Textverarbeitung
6. Bildverarbeitung
7. Fehlerhafte KI-Modelle?
8. Fazit

1. Was ist künstliche Intelligenz?

Marvin Minsky 1966:

„Künstliche Intelligenz liegt vor, wenn Maschinen Dinge tun, für deren Ausführung man beim Menschen Intelligenz unterstellt.“

Formen

- *starke / generelle / kognitive KI:*
Generelle Fähigkeit zum Lösen von Aufgaben (unabhängig von deren Art)
- *schwache / enge KI:*
Nur Lösungen in vordefinierten engen Aufgabengebieten
(z.B. Schach spielen, Röntgenbilder auf Krebsanzeichen auswerten, Quizfragen beantworten, Kreditanträge beurteilen ...)

Erstellung von KI

- durch Programmierung = die Regeln werden vorgegeben durch Menschen
- „Maschinelles Lernen“ (ML) = Regeln induktiv aus Erfahrungen ableiten

2. „Überleben“ – Maschinelles Lernen im Beispiel

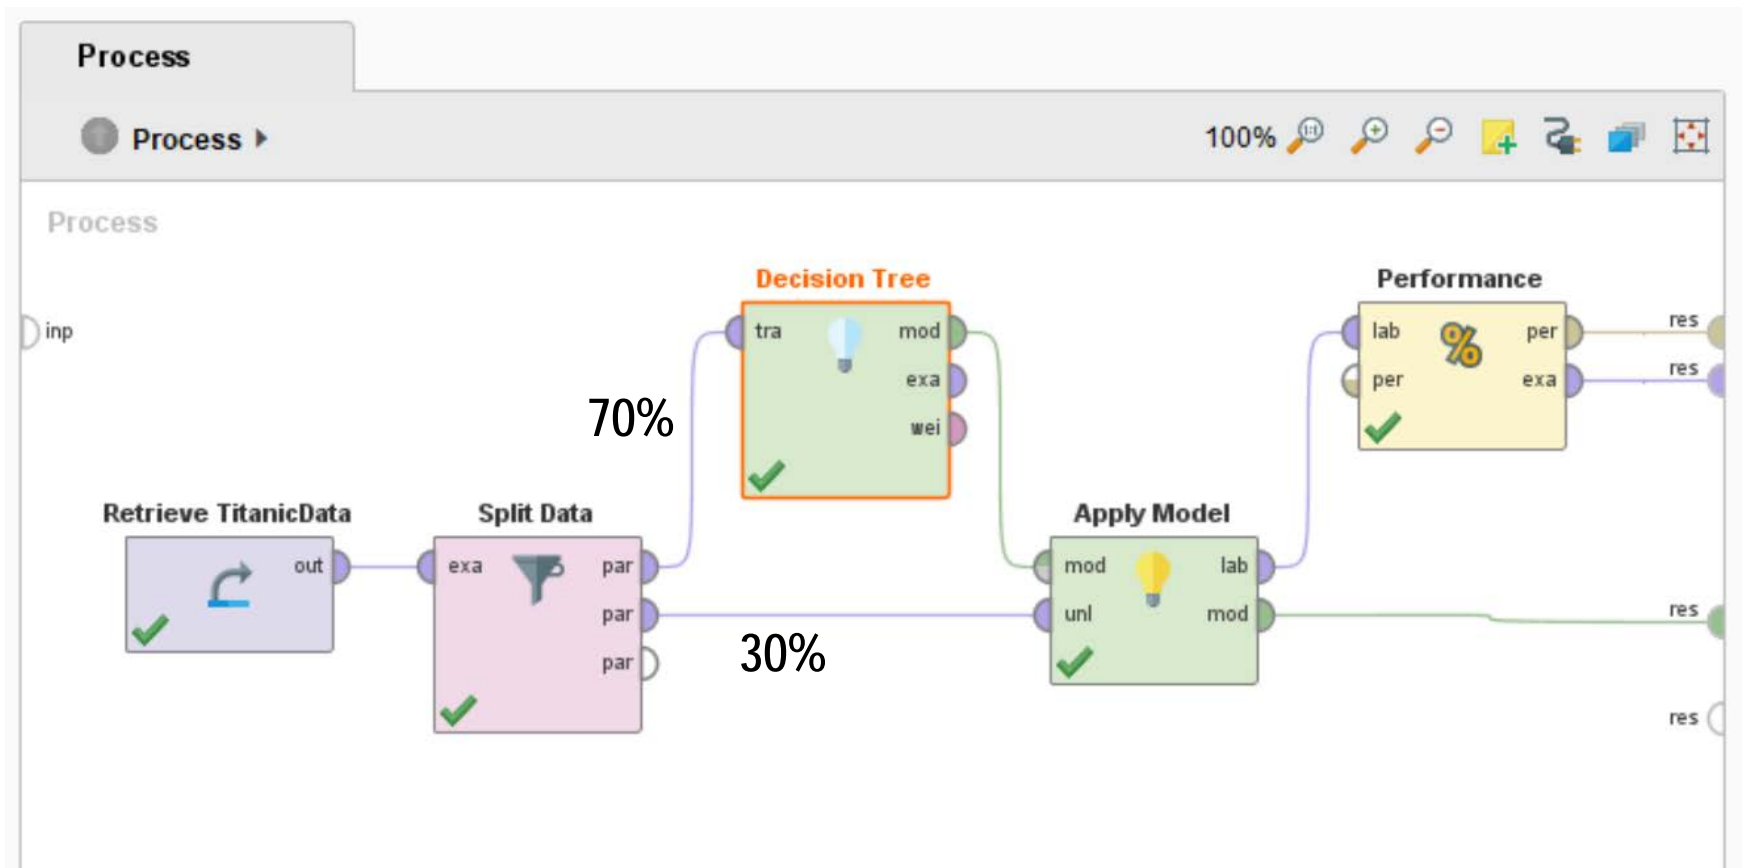
Titanic [VIDEO](#)

Row No.	Name	Sex	Age	No of Parents ...	No of Siblings...	Passenger Class	Passenger Fare	Survived
1	Allen, Miss. Elisabeth Walton	Female	29	0	0	First	211.338	Yes
2	Allison, Master. Hudson Trev...	Male	0.917	2	1	First	151.550	Yes
3	Allison, Miss. Helen Loraine	Female	2	2	1	First	151.550	No
4	Allison, Mr. Hudson Joshua ...	Male	30	2	1	First	151.550	No
5	Allison, Mrs. Hudson J C (Be...	Female	25	2	1	First	151.550	No
6	Anderson, Mr. Harry	Male	48	0	0	First	26.550	Yes
7	Andrews, Miss. Kornelia The...	Female	63	0	1	First	77.958	Yes
8	Andrews, Mr. Thomas Jr	Male	39	0	0	First	0	No
9	Appleton, Mrs. Edward Dale ...	Female	53	0	2	First	51.479	Yes
10	Artagaveytia, Mr. Ramon	Male	71	0	0	First	49.504	No
11	Astor, Col. John Jacob	Male	47	0	1	First	227.525	No
12	Astor, Mrs. John Jacob (Mad...	Female	18	0	1	First	227.525	Yes
13	Aubart, Mme. Leontine Pauli...	Female	24	0	0	First	69.300	Yes
14	Barber, Miss. Ellen "Nellie"	Female	26	0	0	First	78.850	Yes
15	Barkworth, Mr. Algernon Hen...	Male	80	0	0	First	30	Yes
16	Baumann, Mr. John D	Male	?	0	0	First	25.925	No

ExampleSet (1,309 examples, 0 special attributes, 12 regular attributes)

Grundstruktur – mit Modelltyp „Decision Tree“

Trainingsdaten → Modell → Testdaten → Performance?



Screenshots aus Rapidminer (<https://rapidminer.com>)

Decision Tree – Wie gut ist das Modell?

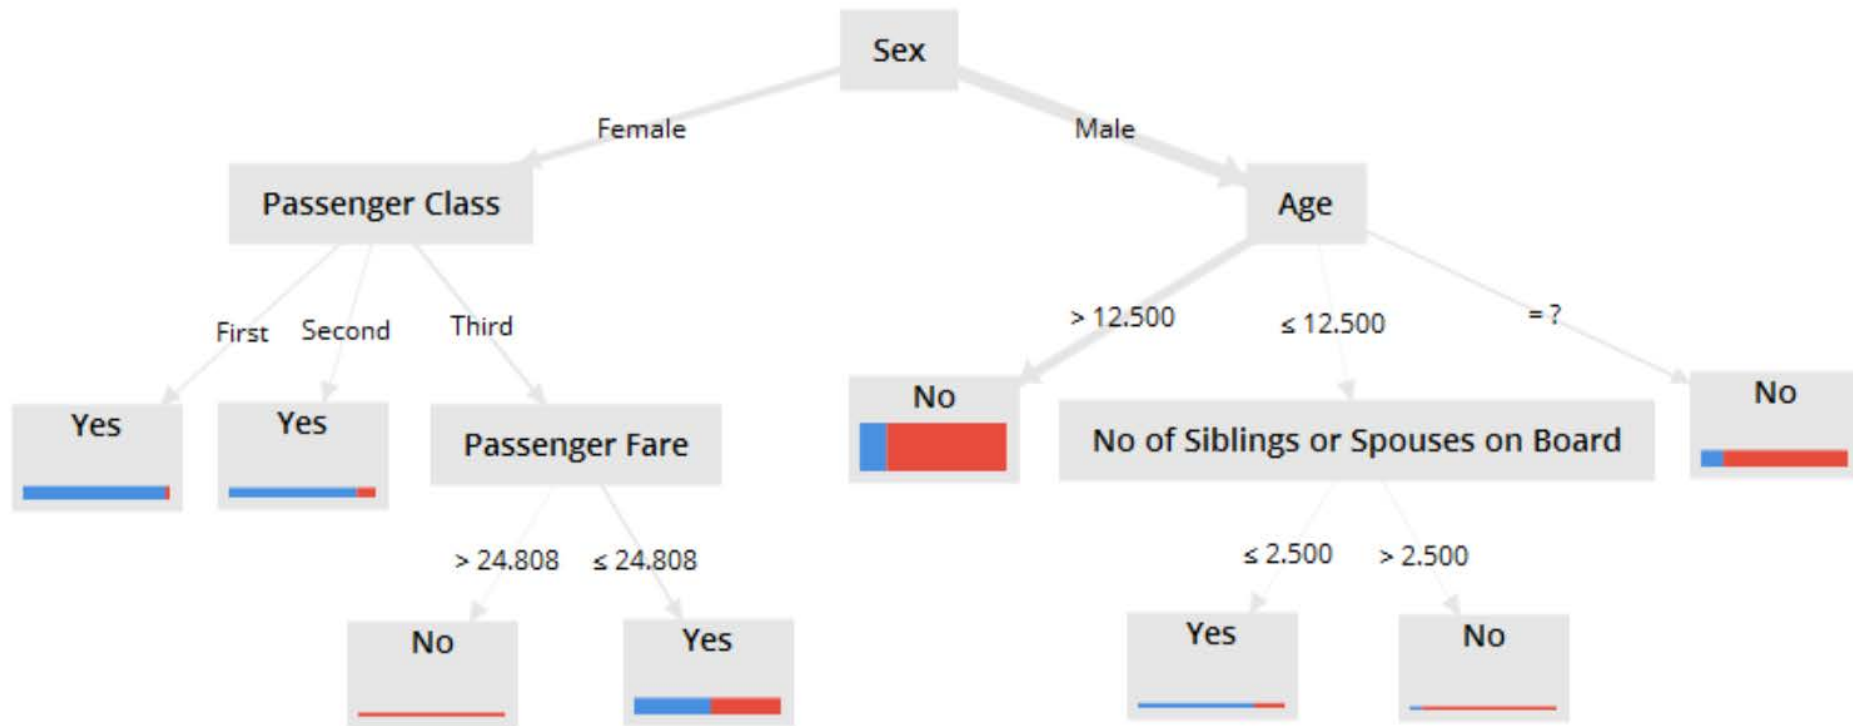
Güte bei unbekannten Fällen

durch Anwendung des Modells auf Testdaten (d.h. den 30% Rest)

accuracy: 83,72%

	true Yes	true No	class precision
pred. Yes	112	26	81.16%
pred. No	38	217	85.10%
class recall	74.67%	89.30%	

Decision Tree – Darstellung des entstandenen Modells



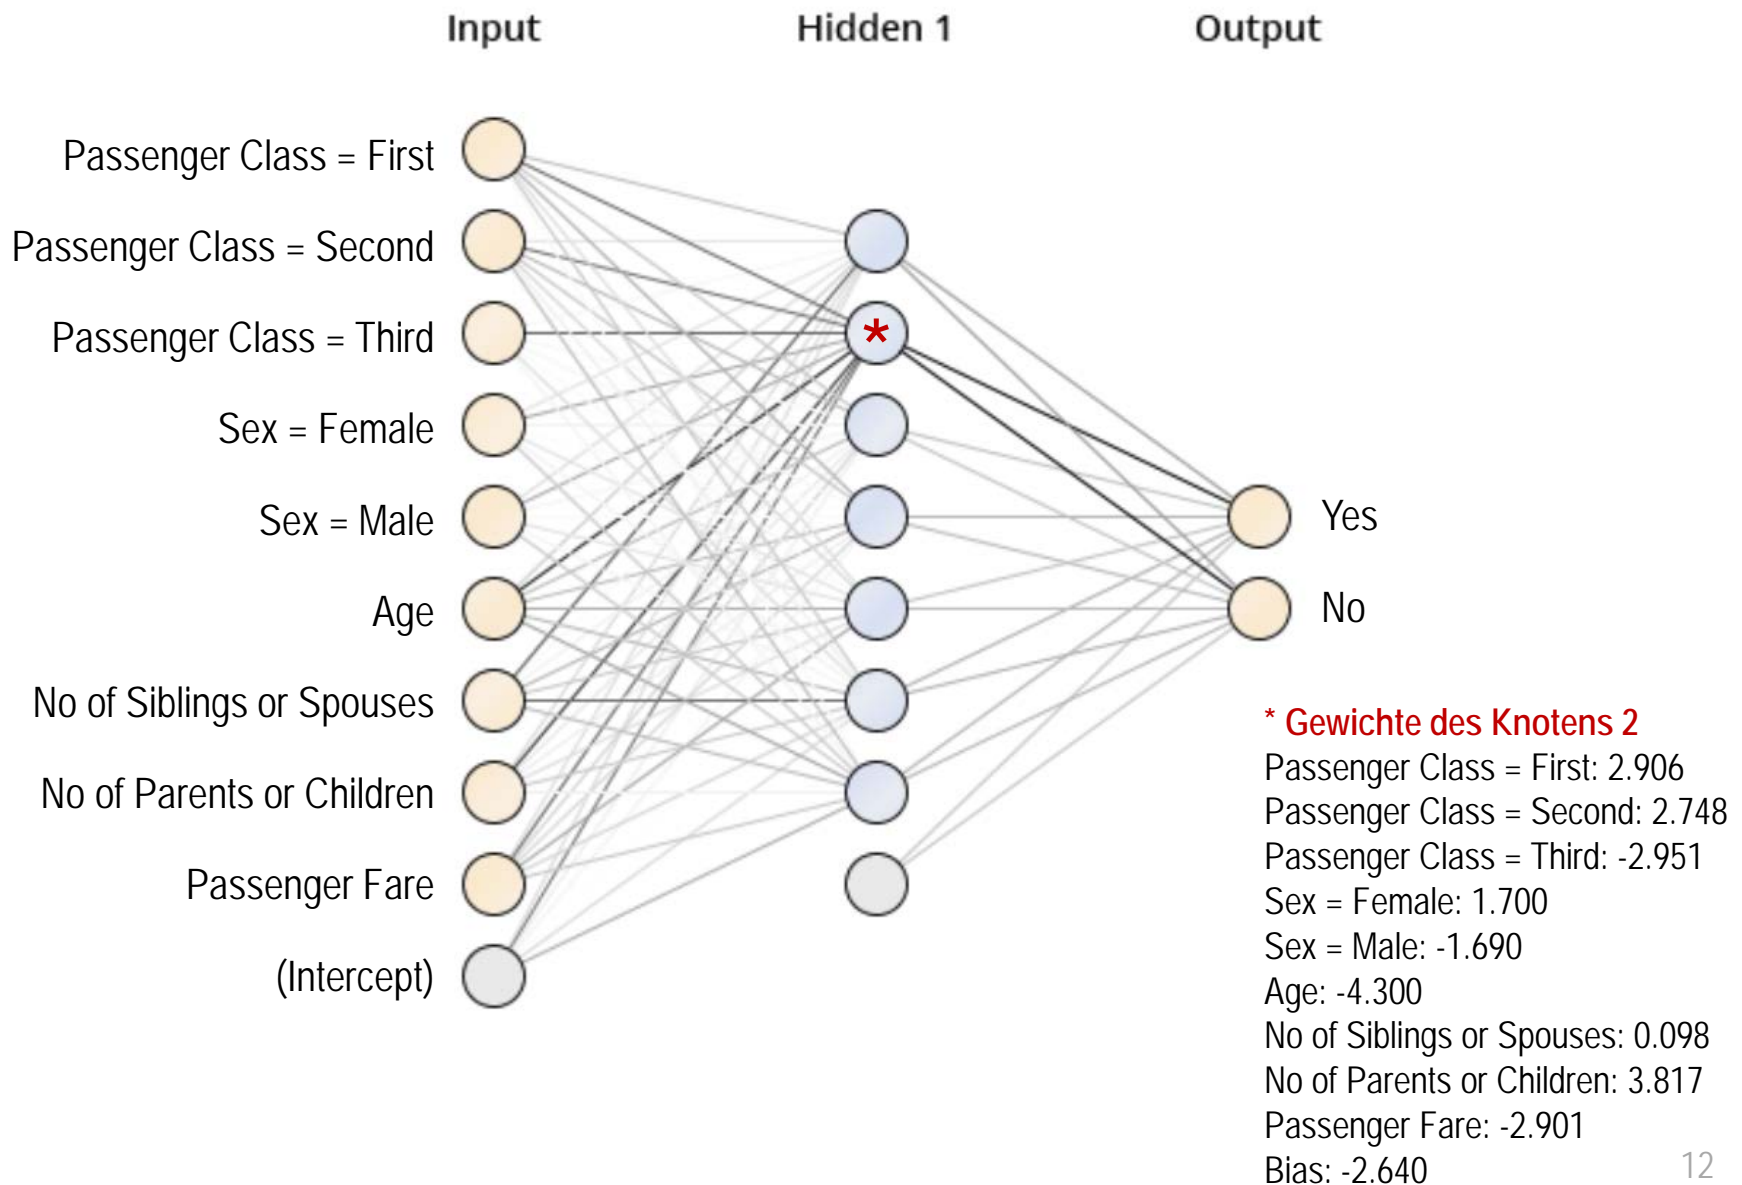
Darstellung alternatives Modell: Naïve Bayes

Attribute	Parameter	Yes	No
Passenger Class	value=First	0.417	0.166
Passenger Class	value=Second	0.225	0.176
Passenger Class	value=Third	0.357	0.657
Sex	value=Female	0.663	0.160
Sex	value=Male	0.337	0.839
Age	mean	29.288	30.764
No of Siblings or Spouses on Board	mean	0.437	0.514
No of Parents or Children on Board	mean	0.406	0.332
Passenger Fare	mean	49.986	23.120

Darstellung alternatives Modell: Logistische Regression

Attribute		Coefficient
<i>Passenger Class</i>	<i>First</i>	
Passenger Class	Second	1.022
Passenger Class	Third	1.950
<i>Sex</i>	<i>Female</i>	
Sex	Male	2.496
Age		0.041
No of Siblings or Spouses on Board		0.368
No of Parents or Children on Board		0.102
Passenger Fare		-0.004
Intercept (Achsenabschnitt)		-3.556

Darstellung alternatives Modell: Neuronales Netz



Vergleich der Ergebnisse

Unsere Modelle:

- Decision Tree accuracy: 83.72%
- Naïve Bayes accuracy: 78.88%
- Logistische Regression accuracy: 79.90%
- Neuronales Netz accuracy: 81.79%

„Prediction“ ← „Confidence(Yes)“

Survived	Prediction	Confidence(Yes)	Class	Sex	Age	Siblings	Parents	Fare
Yes	Yes	0.727	First	Male	0.9167	1.0	2.0	151.55
No	Yes	0.969	First	Female	2.0	1.0	2.0	151.55
No	No	0.161	First	Male	71.0	0.0	0.0	49.50
Yes	Yes	0.944	First	Female	24.0	0.0	0.0	69.30
No	Yes	0.7014	First	Male	24.0	0.0	1.0	247.52
Yes	Yes	0.908	First	Female	50.0	0.0	1.0	247.52
Yes	Yes	0.926	First	Female	32.0	0.0	0.0	76.29
No	Yes	0.534	First	Male	25.0	0.0	0.0	26.00
No	No	0.345	First	Male	45.0	0.0	0.0	35.50
Yes	Yes	0.949	First	Female	30.0	0.0	0.0	164.86
Yes	Yes	0.800	First	Female	60.0	0.0	0.0	76.29
Yes	Yes	0.914	First	Female	41.0	0.0	0.0	134.5

3. Übertragung auf Kreditvergabe

Titanic	Ratingsystem einer Bank
Fragestellung: Überleben der Passagiere?	Fragestellung: Erfüllte Kreditverträge?
Daten als <u>Zahl</u> : Age, Passenger Fare, No. of Siblings, No. of Children	Daten als <u>Zahl</u> : EK-Quote, Kapitalrendite, Jahre seit Gründung, ...
Daten als <u>Kategorie</u> : Sex, Passenger Class	Daten als <u>Kategorie</u> : Branche, Planungsrechnung, Nachfolgeregung, ...

4. Ethik und Recht bei KI-Modellen

Im Titanic-Beispiel:

- Modell hat gelernt, Frauen haben geringeres Risiko zu sterben

Für ein Ratingsystem einer Bank:

- ANNAHME: Modell hat gelernt (fiktiv!) von Frauen geführte Unternehmen haben eine höhere Insolvenzwahrscheinlichkeit
- Was wäre die Konsequenz?
 - *Preisdifferenzierung* = Frauen wird ein Kredit c.p. nur zu einem höherem Zins angeboten als Männern (zur Kompensation des sachlich gegebenen höheren Ausfallrisikos)
 - Oder doch den *gleichen Zins*, unabhängig vom Geschlecht?
 - Handelt „die KI“ sonst unethisch?

Nicht „die KI“ handelt ...

Modell lernt nur statistische Zusammenhänge zwischen verschiedenen Größen


Unternehmerische Entscheidung:

- Soll das Merkmal „Geschlecht“ überhaupt als Variable für das Training des Modells verwendet werden?
 - ggf. korreliert „Geschlecht“ aber mit weiteren Variablen ...
- Falls das Merkmal „Geschlecht“ verwendet wird und es gemäß dem Modell relevant ist:
 - für Preisdifferenzierung nutzen?

Grenzen unternehmerischer Entscheidung durch Gesetze und Rechtsprechung.

5. Textverarbeitung

„Akdj alsd lakda alfka feasöfd iuozut rgt dogd slgiö.
Isdgädsl -2% gedslog fürth alsd lägfde. Sasd guds lgdisle
wsdolg alsd dlsa +5% edsilgösd gedslog sdfasf guds
msfsöaf. Suf pasf as fosaf soi ösardf. Päsa fafuärt ...“



- Wortvektor

Wort	alsd	gedslog	guds	festzhqa	...
Anzahl	9	3	17	5	...
	<i>Besserung</i>	<i>gut</i>	<i>mäßig</i>	<i>befriedigend</i>	

- Statistiken WordsPerSentence = 5,18; Bad/Good = 1,4
- bestimmte Inhalte Preissteigerung = „+5%“
- Bedeutungsvektor (z.B. Word2Vector)

Beispiele (!) für Auswertungsfragen

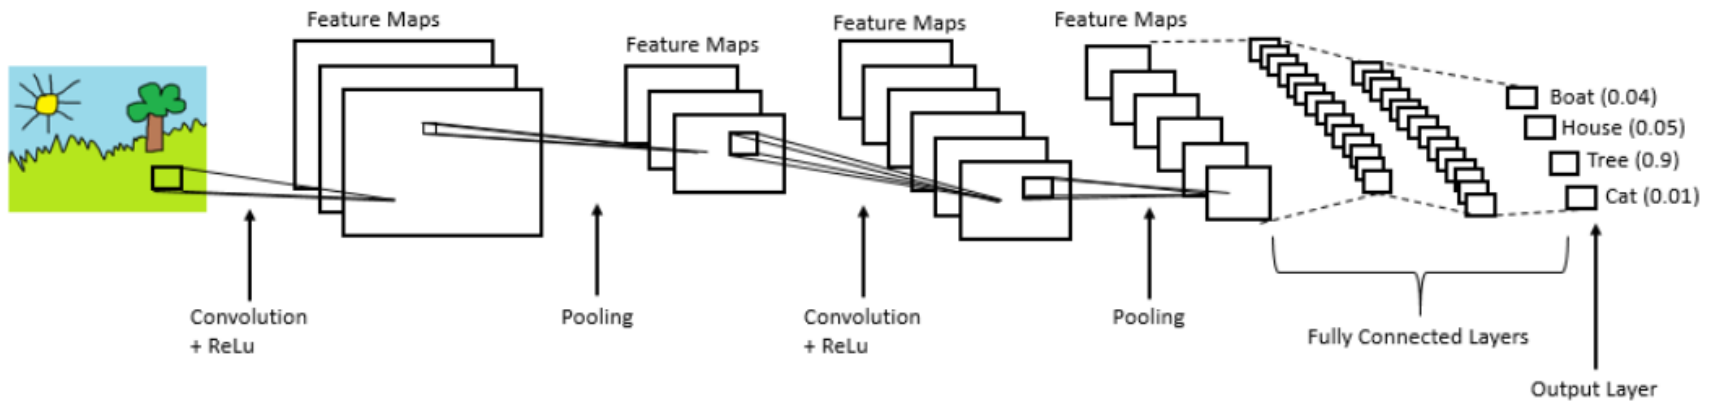

- Sprachtendenzen erheben (z.B. positiv – negativ)
Henselmann/Hering: Form 10-K Textual Analysis and Future Stock Returns, 41st European Accounting Association Annual Congress 2018, Mailand
- Texte in vorgegebene Kategorien einordnen
Evert/Heinrich/Henselmann/Rabenstein/Scherr/Schmitt/Schröder: Combining Machine Learning and Semantic Features in the Classification of Corporate Disclosures, in: Journal of Logic, Language and Information 2019
Henselmann/Seebeck: Was deutsche Abschlussadressaten vom neuen Bestätigungsvermerk erwarten können – Eine empirische Analyse von Key Audit Matters in Großbritannien, WPg 2017
- Themen in Texten erkennen (z.B. genannte Risiken)
Dressel (Masterarbeit): Semantic Analysis of Risk Factors in Financial Reports, 2019
- bestimmte Inhalte aus Texten extrahieren
Pusch/Hering/Henselmann: Information Extraction from Current Reports on Form 8-K and the Value-Relevance of Corporate Events on Financial Markets, 41st European Accounting Association Annual Congress 2018, Mailand
Henselmann u.a.: DIPCAT, Case “Digitalization in Auditing”, Analyse der Inhalte von Mietverträgen



Erasmus+

6. Bildverarbeitung

Durch aufeinander folgende Verarbeitungsschichten



Quelle (mit Anleitung, wie man selbst ein Netzwerk trainiert, das Katzen und Hunde unterscheidet):

<https://towardsdatascience.com/image-classifier-cats-vs-dogs-with-convolutional-neural-networks-cnns-and-google-colabs-4e9af21ae7a8>

7. Fehlerhafte KI-Modelle?

Zahlreiche populäre Beispiele für Fehler!

Lernbedingungen (und deren Transparenz)?

- „falsches“ Verhalten als Trainingsdaten (z.B. menschliche Personalauswahl war voreingenommen)
- „Nebensächliches“ wird modellrelevant (z.B. Vegetation, Schienen, ...)
- Training unter Idealbedingungen – im Einsatz aber Störungen (z.B. bei Verkehrszeichen: Schmutz, Zweige, Aufkleber, Nebel, Regen, Gegenlicht)

Gibt es eine Transparenz der fertigen Modelle?


- für „bloßen“ Nutzer: z.B. Entscheidungsbäume versus Neuronale Netze

Modellanwendung:


- autonome Systeme versus Assistenzsysteme?

8. Fazit

- Überschätzt: Möglichkeit einer generellen KI
 - selbst wenn KI-System sich „intelligent“ verhält, vermutlich wenig Gemeinsamkeiten mit Menschen:
 - Bewusstsein und eigener Wille?
 - Gefühle wie Freude, Angst, Liebe, Hass ... ?
(aber entsprechendes Verhalten kann simuliert werden)
 - Unterschätzt: Möglichkeiten von engen KI
 - bessere Leistungen mit mehr Training
 - zunehmend Dichte an Insellösungen
- Assistenzsysteme oder zur autonomen Entscheidung?



V I E L E N D A N K



Was läuft eigentlich in unseren Zukunftslaboren?

Quelle: Greser & Lenz, Witze für Deutschland, www.greser-lenz.de