

B2 – AI-ML in Engineering – basics and application examples

Randolf Isenberg, Frank Peters, Roland Schröder-Kroll, Juntang Darboe,
Michael Staniszewski

Präsentiert auf

Zweiter Online-Konferenz zum Digitalen Wandel im Produktionsmanagement

HAW-Hamburg – Institut Produkt- und Produktionsmanagement

Hamburg, 12.1.2021

Inhalt

1. Introduction

1. KI Winter und Sommer
2. ML Übersicht

2. Federated Machine Learning

3. Vertrauen erhöhen durch transparentes Data-Mining mit ML Algorithmus

1. Data Mining – CRISP - Data Check
2. Decision Tree
3. Konzept – Produktionsszenario mit Supply Chain Bezug
4. Random Forest auf Basis von nachvollziehbaren Daten

4. Chat-Bots

5. AI in Learning

6. Zusammenfassung

Transparenz hilft Vertrauen aufzubauen insbesondere für Management Entscheidungen wichtig.

1

Quelle / Fußnote

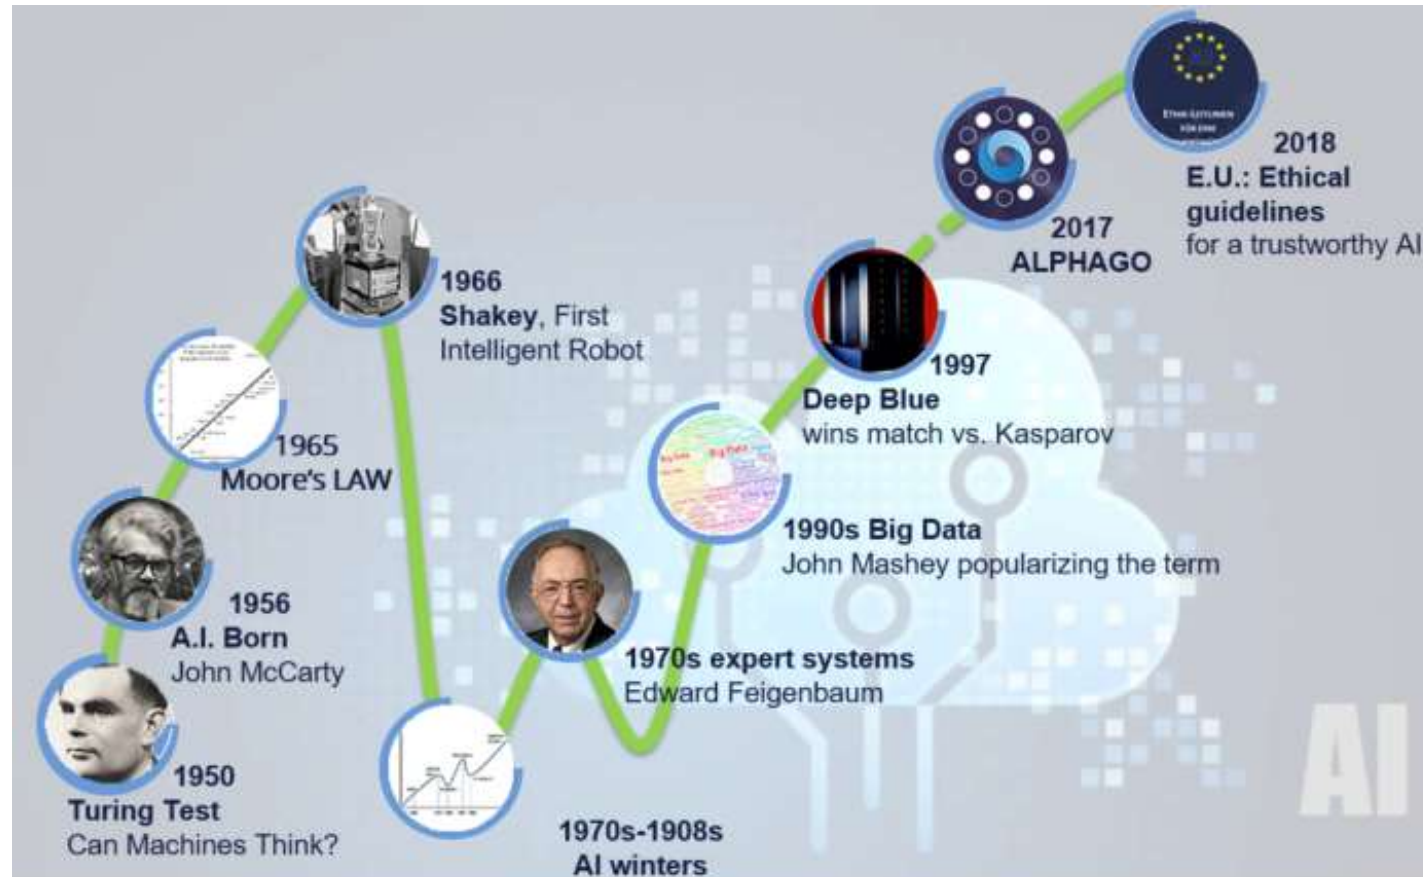
AI-ML in Engineering – Basics and Application Examples

Zweite Online-Konferenz der HAW Hamburg zum Digitalen Wandel im Produktionsmanagement, 12.1.2021

R. Isenberg, F. Peters, R. Schröder-Kroll, J. Darboe, M. Staniszewski

AI Timeline

AI winters and summers – Now stable summer



China und EU starten in diesem stabilen Sommer durch und setzen Schwerpunkte

Isenberg, R., 2020. AI in Engineering - Keynote. (Slide F. Peters)

AI-ML in Engineering – Basics and Application Examples

Zweite Online-Konferenz der HAW Hamburg zum Digitalen Wandel im Produktionsmanagement, 12.1.2021

R. Isenberg, F. Peters, R. Schröder-Kroll, J. Darboe, M. Staniszewski

Von der starken zum Super-KI

Vom überwachten zum verstärkenden Lernen

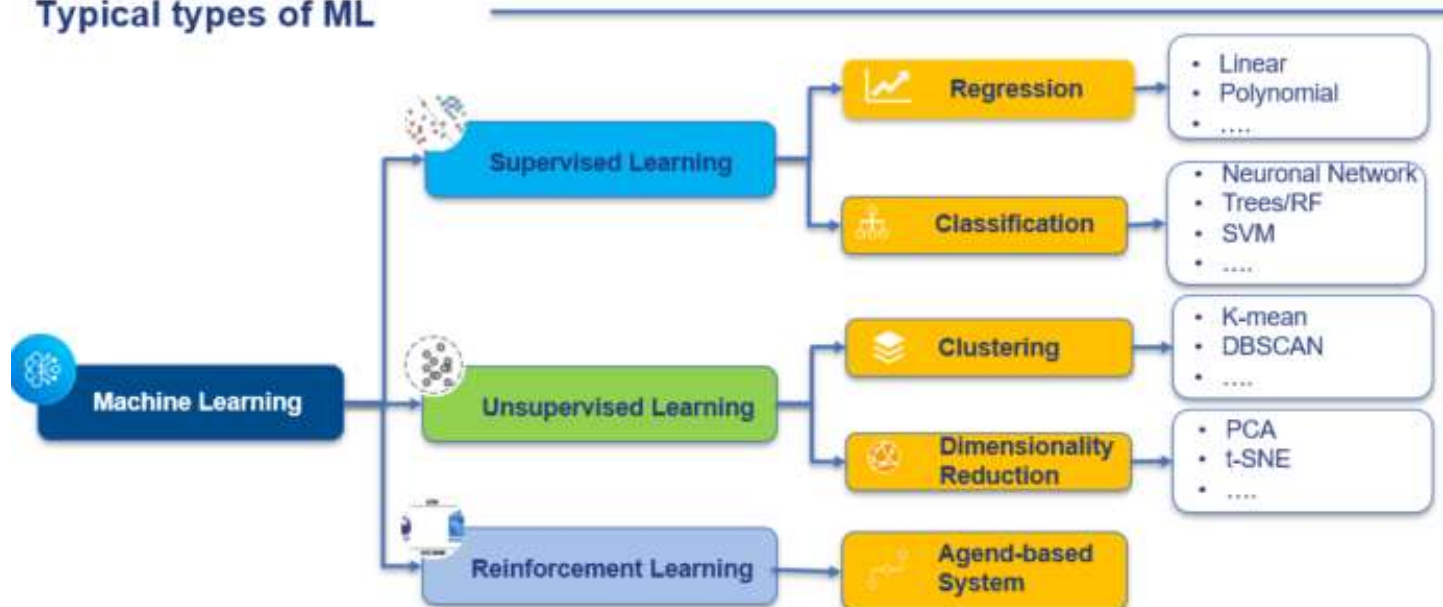


(<https://vincentlauzon.com/2015/09/16/strong-ai-existential-risks/>)

- **Weak AI** is nowhere near matching human intelligence, and it isn't trying to.
- We don't yet have **strong AI** in the world; it exists only in theory
- Of the types of AI, **super AI** is the one most people mean when they talk about robots taking over the world.

So far, we've only achieved the first of the three types of AI — **weak AI**.

Typical types of ML



(thinkautomation.com)

Autors: R. Isenberg, F. Peters, P. Schneider, J. Darboe, R. Schröder-Kroll

Machine Learning als Teil der KI teilt sich nach der Verfügbarkeit der Targets und der Art des Lernens

Inhalt

1. Introduction

1. KI Winter und Sommer
2. ML Übersicht

2. Federated Machine Learning

3. Vertrauen erhöhen durch transparentes Data-Mining mit ML Algorithmus

1. Data Mining – CRISP - Data Check
2. Decision Tree
3. Konzept – Produktionsszenario mit Supply Chain Bezug
4. Random Forest auf Basis von nachvollziehbaren Daten

4. Chat-Bots

5. AI in Learning

6. Zusammenfassung

Transparenz hilft Vertrauen aufzubauen insbesondere für Management Entscheidungen wichtig.

4

Quelle / Fußnote

AI-ML in Engineering – Basics and Application Examples

Zweite Online-Konferenz der HAW Hamburg zum Digitalen Wandel im Produktionsmanagement, 12.1.2021

R. Isenberg, F. Peters, R. Schröder-Kroll, J. Darboe, M. Staniszewski

Risiken im Supply Chain Management - Datenaustausch: Potentiale, Hinderungsgründe

Verbesserung des Supply Chain Managements durch Firmen-übergreifenden Datenaustausch

Potentiale


1. Verbesserung der Prognosen
2. Risikoreduzierung
 - Z.B. Peitscheneffekt (bullwhip effect)

Hinderungsgründe

- Unternehmen zögern, sensible Daten weiterzugeben
 - Datenschutz
 - Befürchtete Wettbewerbsnachteile

Ein Ansatz

- Federated Machine Learning



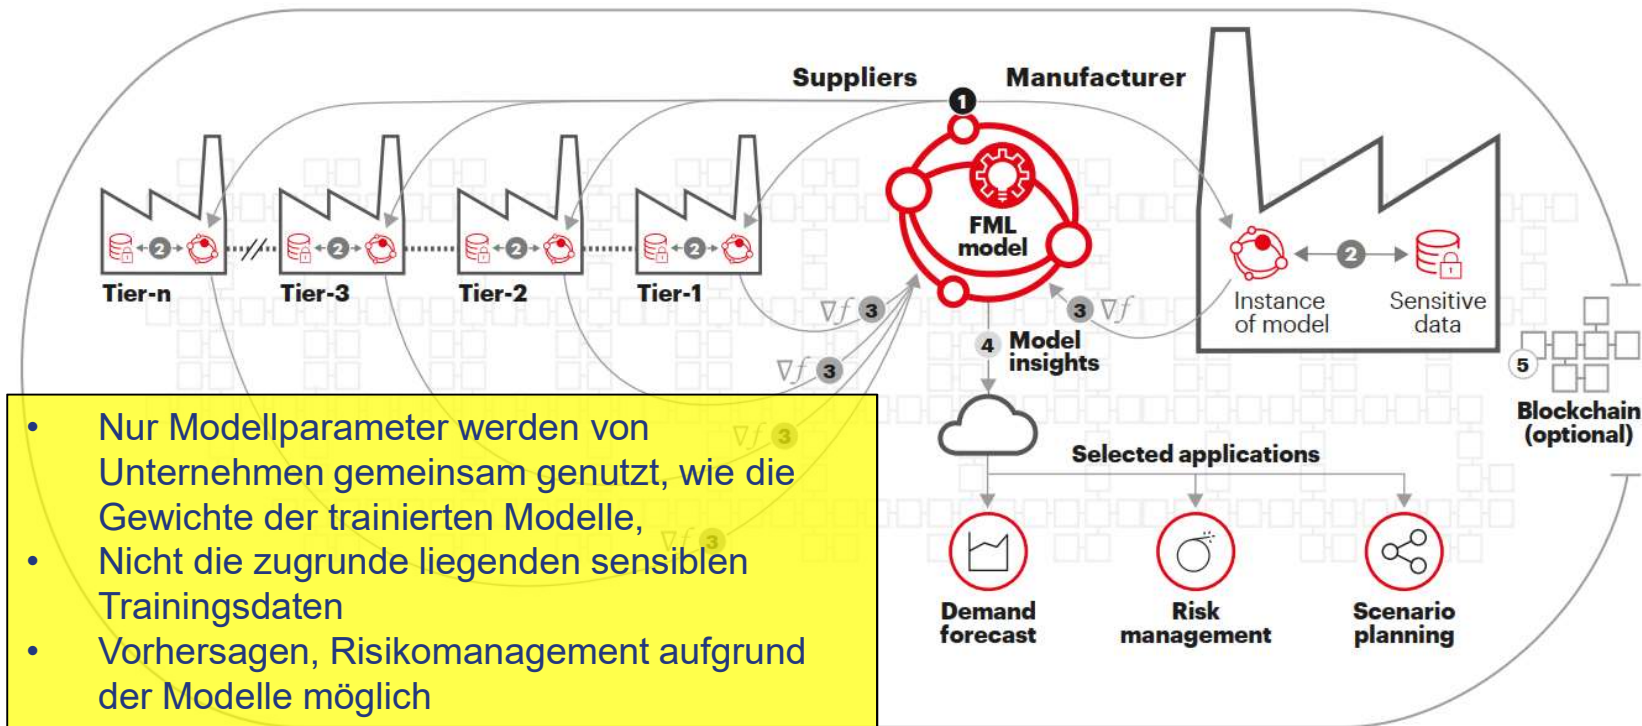
Supply-Chain-Management (2020). In: Wikipedia.
<https://de.wikipedia.org/w/index.php?title=Supply-Chain-Management>
(Abruf 8.1.2021).

Datenaustausch als Chance zur Risikoreduzierung in der Supply Chain.
Dabei: Federated Machine Learning als Ansatz zum Datenschutz.

5

Produktion und Supply Chain Management - Datenschutz, Federated Machine Learning

Figure 2: The federated machine learning process



- Nur Modellparameter werden von Unternehmen gemeinsam genutzt, wie die Gewichte der trainierten Modelle,
- Nicht die zugrunde liegenden sensiblen Trainingsdaten
- Vorhersagen, Risikomanagement aufgrund der Modelle möglich



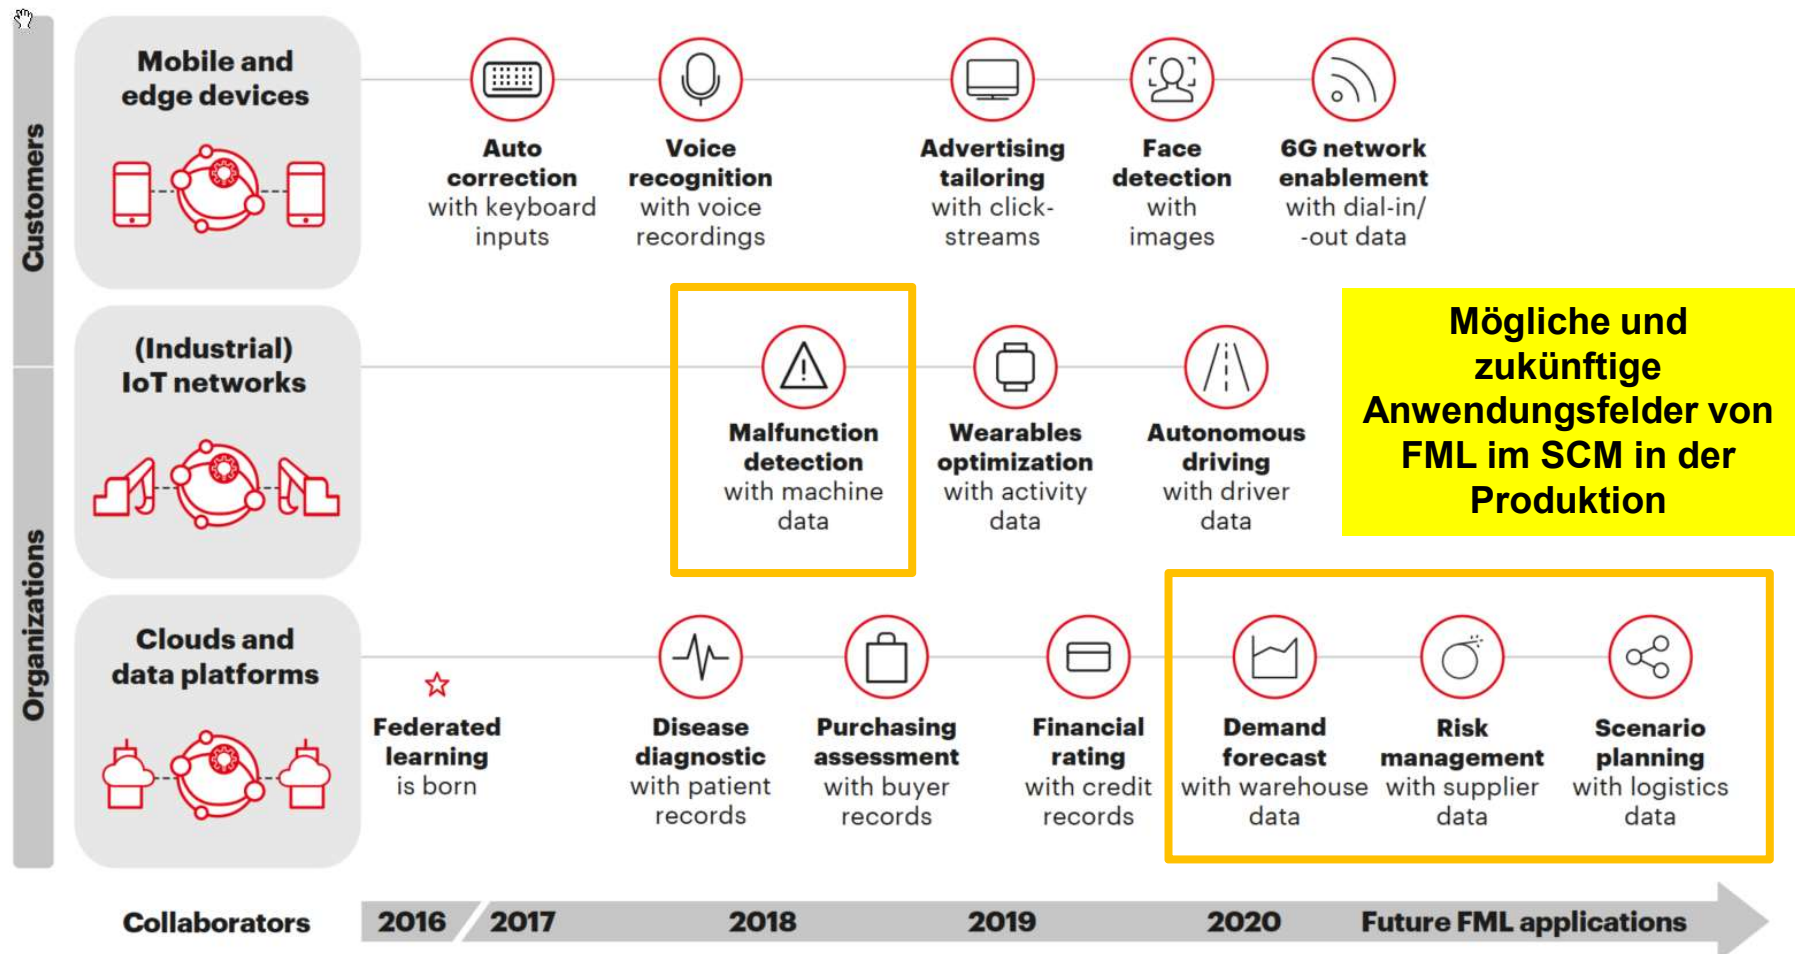
Maria Kuper; Lukas Wuttke (2020): Federated machine learning - Unlock the value of shared supply chain data without actually sharing that data. Accenture. https://view.publitas.com/p222-16229/10_federated-machine-learning/page/4%2F5 (accessed 27.10.2020)

AI-ML in Engineering – Basics and Application Examples

Zweite Online-Konferenz der HAW Hamburg zum Digitalen Wandel im Produktionsmanagement, 12.1.2021
R. Isenberg, F. Peters, R. Schröder-Kroll, J. Darboe, M. Staniszewski

Produktion und Supply Chain Management - Anwendungsfelder für Federated Machine Learning

Figure 4: The federated machine learning time line



Maria Kuper; Lukas Wuttke (2020): Federated machine learning - Unlock the value of shared supply chain data without actually sharing that data. Accenture. https://view.publitas.com/p222-16229/10_federated-machine-learning/page/4%2F5 (accessed 27.10.2020)

AI-ML in Engineering – Basics and Application Examples

Zweite Online-Konferenz der HAW Hamburg zum Digitalen Wandel im Produktionsmanagement, 12.1.2021

R. Isenberg, F. Peters, R. Schröder-Kroll, J. Darboe, M. Staniszewski

Inhalt

1. Introduction

1. KI Winter und Sommer
2. ML Übersicht

2. Federated Machine Learning

3. **Vertrauen erhöhen durch transparentes Data-Mining mit ML Algorithmus**

1. Data Mining – CRISP - Data Check
2. Decision Tree
3. Konzept – Produktionsszenario mit Supply Chain Bezug
4. Random Forest auf Basis von nachvollziehbaren Daten

4. Chat-Bots

5. AI in Learning

6. Zusammenfassung

Transparenz hilft Vertrauen aufzubauen insbesondere für Management Entscheidungen wichtig.

8

Quelle / Fußnote

AI-ML in Engineering – Basics and Application Examples

Zweite Online-Konferenz der HAW Hamburg zum Digitalen Wandel im Produktionsmanagement, 12.1.2021


R. Isenberg, F. Peters, R. Schröder-Kroll, J. Darboe, M. Staniszewski

Data Mining nach dem CRISP-DM Kreislauf und später ASUM-DM

CRISP-DM - (CRoss-Industry Standard Process for Data Mining).

CRISP-DM is the leading methodology used by data miners in the industry. and analysis project, from business requirements to the final deployment phases and everything in between.

(... Survey - KDNuggets machine learning)



- CRISP-DM divides the ML Analytics process into **six phases**. (VDMA 2020)
- 2015 new ASUM-DM adds project management features)

Authors: AG, NCR Corporation and OHRA, an insurance company CRISP-DM was conceived in 1996 and became a European Union project under the ESPRIT funding initiative in 1997. The project was led by five companies: Integral Solutions Ltd (ISL), Teradata, Daimler

Sarkar,D, Bai,R, and Ghosh,T (2018) Hands-on Transfer Learning with Python, Packt Publishing Ltd.)

Autors: R. Isenberg, E.Peters, P. Schneider, J. Darboe, R. Schröder-Kroll

Daten werden das Gold der Zukunft

- aber sie müssen systematisch verstanden werden -

9

AI-ML in Engineering – Basics and Application Examples

Zweite Online-Konferenz der HAW Hamburg zum Digitalen Wandel im Produktionsmanagement, 12.1.2021

R. Isenberg, F. Peters, R. Schröder-Kroll, J. Darboe, M. Staniszewski

Typische Datenprüfungen im Rahmen des Data-Mining

Check your DATA:

Although there are some good practices in this matter, there is **no fixed set of steps** to prepare (pre-process) your data set in order to develop an in-depth learning solution, and in most cases the steps to be taken depend on the available data, the algorithm to be used, and other features of the study.



IMPORTANT TO CHECK:

1. **How much data** is required
 - "dependent on model type – NN/RF"
2. **Understand** fundamental structures of Data
 - Is the effect we find really **causal**?
3. **Remove irrelevant** features
 - „Is the hair color a distinction between men and women“"
4. **Check for missing** values
5. **Search for outliers**
6. **Check for class imbalance:**
 - A class imbalance occurs if the class names are not equally represented in the target characteristic

A common **buzzword** among consultants and large data solution providers is that once your data analysts and data scientists have received **enough data**, they will be able to **find actionable insights**. This is a common trap among business people and data **novices**: the idea that if we inspect some data long enough, these actionable insights **will magically appear**.

...
(Analytical Skills for AI and Data Science by Daniel Vaughan)

**Nicht Quantität sondern
Quantität und Qualität sind notwendig!**

10

Decision Tree – Machine learning to start of

Decision Tree (classification)

- We flip the expert system.
- Not: Human designs rules based on interviews
- BUT: AI builds rules based on set of labeled features.

Our Data

- We measure animals in height (cm) X[0] and weight (kg) X[1].
- We measure only one dog, two cats and one horse.

Our Python Code:

1. We use the class tree from Scikit-learn
2. Define features, labels (10 dog, 20 cat, 30 horse)
3. Use the tree classifier
4. Train your classifier
5. Predict labels from unknown features:
Cm/weight 20/3 53/33, 110/92, 400/4000
Result: 20 10 30 30

cat, dog, horse, horse

Start today use Google Colab in your browser, open a new jupyter notebook and type:

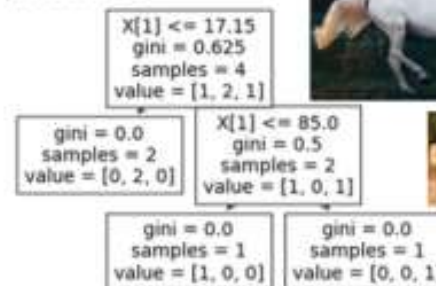
```
import sklearn # ML framework Scikit-learn
from sklearn import tree

features = [[56, 30], [23, 4], [21, 4.3], [500, 140]] # height X[0], weight
labels = [10, 20, 20, 30] # 10 dog, 20 cat, 30 horse

classifier = tree.DecisionTreeClassifier()
classifier = classifier.fit(features, labels)
tree.plot_tree(classifier)

print(classifier.predict([[20, 3], [53, 33], [110, 92], [400, 4000]]))
```

[20 10 30 30]



Pictures from
<https://www.pexels.com>

Think about the result

Was im Training fehlt, kann nicht vorhergesagt werden.

- Der Elefant wird zum Pferd -

11

ML – Vertrauen aufbauen

- Ein eigenes Szenario als Start -

Produktionsproblem:

- **hohe Durchlaufzeit, Ausschuss, Terminverzögerung**

Vermutungen:

1. Fertigungsinseln: Zu hoher Work-In-Process, also Arbeitsinhalt, führt zu langen Durchlaufzeiten.
2. Nachtschichten haben die Fehlerrate beim Menschen erhöht und dadurch den Ausschuß.
3. Neue Lieferanten im Netzwerk führen zu Auftragsverzögerungen?

Ansatz mit KI – Vertrauen schaffen

Wir wollen einen Random Forest Algorithmus mit einer eindeutigen Datenlage versehen, so dass die Ergebnisse bekannt sind. Danach wird die Datenlage variiert.

Heute Schritt 1:

Wir betrachten mehrere Tage mit jeweils einem Mix aus:

1. Work-In-Prozess (Prozent)
2. Nachtschichtvorfall (1=Tag 2=Nacht)
3. Lieferantentyp (1=Alt 2=Neu)

Wir beobachten die Wirkung auf (Targets/Label):

1. Risiko-Durchlaufzeit
2. Risiko-Ausschuß
3. Risiko-Verspätung

Wir bauen uns dazu:

1. eigene DataFrames in Pandas mit
2. Python und
3. Numpy und als
4. ML-Algorithmus aus sklearn den Classifier für supervised Learning Random Forest.

Blindes KI Vertrauen reicht nicht – Manager sollten die Basics hinterfragen können!

12

ML – Vertrauen aufbauen

- Ein eigenes Szenario als Start -

Sie wissen nicht was ein Random Forest Algorithmus ist?

Siehe z.B. (Simplilearn, 2018)

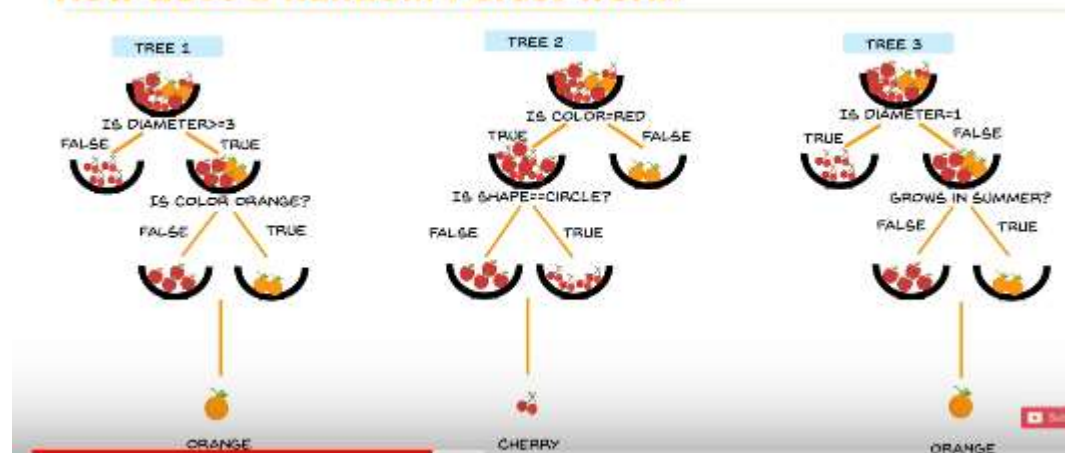
Prinzip RF:

- Wähle einen Mehrheitsentscheid aus mehreren geschickt erzeugten Decision Trees zu einem Datenset.
- Entropy-Reduktion in gesplitteten Knoten führt zu Information Gain

Vorteile RF

1. Fehlertoleranter als Decision Trees
2. Wenig Overfitting („Algorithmus lernt nicht auswendig“)
3. Schnell auch bei großen Datenbasen

How does a Random Forest work?



Wie ein Random Forest Algorithmus einen schwarzen Apfel (Datenfehler) doch erkennt (Simplilearn, 2018)

KI Blindes Vertrauen reicht nicht – Manager sollten die Basics hinterfragen können!

13

ML – Vertrauen aufbauen

- Ein eigenes Szenario als Start -

So geht es los:

- 1-2 Features = Unser Input
Targets = Unsere Output
- 4 Import des ML Algorithmus von sklearn
- 5 Import Pandas (für komplexe Datenstrukturen)
- 6 Import numpy (für komplexe Arrays)
- 7 Import Markdown (damit unser Ausdruck besser lesbar ist – „Usability“)



```
randomForest-RIS.ipynb
Datei Bearbeiten Anzeige Einfügen Laufzeit Tools Hilfe Alle An...
+ Code + Text
1 # Production Example
2 # Features: 1WIP, 2Night1DayShift, 2New1OldSupplier
3 # Targets: 0Risk-ThroughputTime, 1Risk-Scrap, 2Risk-DueDate
4 from sklearn.ensemble import RandomForestClassifier
5 import pandas as pd
6 import numpy as np
7 from IPython.display import Markdown, display
8 def printmd(string):
9     display(Markdown(string))
```

**Wir laden die ML Algorithmen
– alles auf Basis von Python**

14

ML – Vertrauen aufbauen

- Ein eigenes Szenario als Start -

Jetzt bauen wir unsere sehr einfache Datenstruktur als Dictionary (key, value)

10-29 Daten - Features, List Typ mit 3 Werten:

- WIP in Prozent
- 1 Tag- , 2 Nacht-Schicht
- 1 Alter , 2 Neuer Supplier

30-35 – Targets

- 0 Risk Throughput Time
- 1 Risk Scrap
- 2 Risk DueDate

36-37 – Target-Names ... Klarnamen

38 Feature_names ... Klarnamen

```
10 dataDic = {'data': [[70, 1, 1], [30, 2, 1], [30, 1, 2],
11                    [70, 1, 1], [30, 2, 1], [30, 1, 2],
12                    [70, 1, 1], [30, 2, 1], [30, 1, 2],
13                    [70, 1, 1], [30, 2, 1], [30, 1, 2],
14                    [70, 1, 1], [30, 2, 1], [30, 1, 2],
15                    [70, 1, 1], [30, 2, 1], [30, 1, 2],
16                    [70, 1, 1], [30, 2, 1], [30, 1, 2],
17                    [70, 1, 1], [30, 2, 1], [30, 1, 2],
18                    [70, 1, 1], [30, 2, 1], [30, 1, 2],
19                    [70, 1, 1], [30, 2, 1], [30, 1, 2],
20                    [70, 1, 1], [30, 2, 1], [30, 1, 2],
21                    [70, 1, 1], [30, 2, 1], [30, 1, 2],
22                    [70, 1, 1], [30, 2, 1], [30, 1, 2],
23                    [70, 1, 1], [30, 2, 1], [30, 1, 2],
24                    [70, 1, 1], [30, 2, 1], [30, 1, 2],
25                    [70, 1, 1], [30, 2, 1], [30, 1, 2],
26                    [70, 1, 1], [30, 2, 1], [30, 1, 2],
27                    [70, 1, 1], [30, 2, 1], [30, 1, 2],
28                    [70, 1, 1], [30, 2, 1], [30, 1, 2],
29                    [70, 1, 1], [30, 2, 1], [30, 1, 2]]], #60 Data elements
30     'target': [0, 1, 2, 0, 1, 2, 0, 1, 2, 0, 1, 2,
31                0, 1, 2, 0, 1, 2, 0, 1, 2, 0, 1, 2,
32                0, 1, 2, 0, 1, 2, 0, 1, 2, 0, 1, 2,
33                0, 1, 2, 0, 1, 2, 0, 1, 2, 0, 1, 2,
34                0, 1, 2, 0, 1, 2, 0, 1, 2, 0, 1, 2,
35                ],
36     'target_names': ["0Risk-ThroughputTime", "1Risk-Scrap",
37                     "2Risk-DueDate"],
38     'feature_names': ["ProzWIP", "2Night1DayShift", "2New1OldSupplier"]}
```

Sehr einfache Kopplung z.B. hohe WIP 70% ergibt Target 0 = Risk-ThroughputTime

15

ML – Vertrauen aufbauen

- Ein eigenes Szenario als Start -

```
39 dfProd = pd.DataFrame(dataDic['data'],
40                       columns=dataDic['feature_names'],
41                       index=np.arange(100, 100+len(dataDic['data'])))
42 dfProd['Risk'] = dataDic['target']
43 targetList = dataDic['target']
44 dtype = pd.CategoricalDtype(dataDic['target_names'], ordered=True)
45 dfProd['RiskName'] = pd.Categorical.from_codes(codes=targetList, dtype=dtype)
46 dfProd['is_train'] = np.random.uniform(0,1,len(dfProd)) <= 0.9 # .75
47 train, test = dfProd[dfProd['is_train']==True],dfProd[dfProd['is_train']==False]
```

Jetzt

39-41 Wir definieren ein Pandas DataFrame aus unserem Data Dictionary durch Aufruf mit key

- den Daten – data
- den Klarnamen – Feature_names
- wir erzeugen einen Index mit numpy arange in der Länge des Dictionaries

42 Zusätzliche Spalte mit Risks (int)

43-45 Erzeugen Kategorie Datentyp und erzeugen Spalte mit Klarnamen der Risiken.

46 Trennung Trainings- Testdaten – dazu numpy Random Funktion nutzen für gleichverteilte Zufallszahlen zwischen 0 und 1 und daraus Boolesche Werte in der Spalte erzeugen.

47 Generierung von 2 Dataframes je einer für Train und Test und Extraktion der Targetwerte (y)

Zuerst alles Daten in einem DataFrame dann Split in Train und Test Daten

16

ML – Vertrauen aufbauen

- Ein eigenes Szenario als Start -

```
49 y = train['Risk']
50 clf = RandomForestClassifier (n_jobs=2, random_state=0)
51 cfit= clf.fit(train[features], y)
52 cptest= clf.predict(test[features])
53 cprob = clf.predict_proba(test[features])
54 preds = pd.Categorical.from_codes(codes=clf.predict(test[features]), dtype=dtype)
55 crosstab1 = pd.crosstab(test['RiskName'], preds, rownames=['Actual Risks'],
56                        colnames=['Predicted Risks'])
57
```

49 Extraktion der Targetwerte (y)

50 Random Forest Classifier durch Parameter anpassen (z.B. Seed für Random setzen zur Vergleichbarkeit)

51 Daten FIT ... das eigentlich Training –

52 Vorhersage mit Test Daten - Werte : 0, 1, 2

53 Vorhersage mit Test Daten – Werte : Wahrscheinlichkeiten 0 bis 1

54 Vorhersage mit Test Daten – Werte : Features der Testdaten

55 Kreuz-Tabelle: Targets der Test-Daten gegenüber Geschätzten Targets der Test-Daten

**Der meiste Aufwand steckt in der Daten-Manipulation –
die Intelligenz des Fitting steckt in einer Zeile**

17

ML – Vertrauen aufbauen

- Ein eigenes Szenario als Start -

```
57 printmd('# Test data and their labels')
58 display(test)
59 printmd('# Rf Risks estimated for Test data')
60 display(cptest) # Schätzung des Target
61 display(preds)
62 printmd('# RF Risk Probabilities estimated for Test Data')
63 display(cprob) # Wahrscheinlichkeit je Target
64 printmd('# Cross tabulation of Original and Estimated Labels for Test Data')
65 display(crosstab1)
```

57 gut lesbare Ausgabe eines Titels mittels printmd

58 Ausgabe Test Daten (pandas DataFrame)

59-65

- Schätzdaten in 0, 1,2 Codierung
- Schätzdaten in Klarnamen – Risk-WIP etc.
- Schätzdaten als Wahrscheinlichkeit je Target
- Kreuztabelle – Wieviele Targets wurden richtig je Targettyp erkannt.

Displayfunktionen sind wichtig, damit Tabellen gut lesbar dargestellt werden.

18

ML – Vertrauen aufbauen

- Ein eigenes Szenario als Start -

Test data and their labels

	ProzWIP	2Night1DayShift	2New1OldSupplier	Risk	RiskName	is_train
100	70	1	1	0	0Risk-ThroughputTime	False
106	70	1	1	0	0Risk-ThroughputTime	False
107	30	2	1	1	1Risk-Scrap	False
113	30	2	1	1	1Risk-Scrap	False
119	30	2	1	1	1Risk-Scrap	False
124	70	1	1	0	0Risk-ThroughputTime	False
126	30	1	2	2	2Risk-DueDate	False
153	30	1	2	2	2Risk-DueDate	False
155	30	2	1	1	1Risk-Scrap	False

Rf Risks estimated for Test data

```
array([0, 0, 1, 1, 1, 0, 2, 2, 1])
['0Risk-ThroughputTime', '0Risk-ThroughputTime', '1Risk-Scrap', '1Risk-Scrap', '1Ri
Categories (3, object): ['0Risk-ThroughputTime' < '1Risk-Scrap' < '2Risk-DueDate']
```

RF Risk Probabilities estimated for Test Data

```
array([[1., 0., 0.],
       [1., 0., 0.],
       [0., 1., 0.],
       [0., 1., 0.],
       [0., 1., 0.],
       [1., 0., 0.],
       [0., 0., 1.],
       [0., 0., 1.],
       [0., 1., 0.]])
```

Cross tabulation of Original and Estimated Labels Data

Predicted Risks	0Risk-ThroughputTime	1Risk-Scrap	2Risk-DueDate
Actual Risks			
0Risk-ThroughputTime	3	0	0
1Risk-Scrap	0	4	0
2Risk-DueDate	0	0	2

Links: Test-Daten – Spalte Risks zeigt die „Targets“ / Darunter: Geschätzte Daten – codiert und Klarnamen
 Rechts: Geschätzte Daten – Wahrscheinlichkeit je Target je Datenelement
 Rechts: Kreuztabelle - erwartungsgemäß sind alle Targets richtig erkannt.

Nicht nur die Endergebnisse prüfen – auch die Wahrscheinlichkeiten und je Targettyp die Genauigkeit

Inhalt

1. Introduction

1. KI Winter und Sommer
2. ML Übersicht

2. Federated Machine Learning

3. Vertrauen erhöhen durch transparentes Data-Mining mit ML Algorithmus

1. Data Mining – CRISP - Data Check
2. Decision Tree
3. Konzept – Produktionsszenario mit Supply Chain Bezug
4. Random Forest auf Basis von nachvollziehbaren Daten

4. Chat-Bots

5. AI in Learning

6. Zusammenfassung

Transparenz hilft Vertrauen aufzubauen insbesondere für Management Entscheidungen wichtig.

20

Quelle / Fußnote

AI-ML in Engineering – Basics and Application Examples

Zweite Online-Konferenz der HAW Hamburg zum Digitalen Wandel im Produktionsmanagement, 12.1.2021

R. Isenberg, F. Peters, R. Schröder-Kroll, J. Darboe, M. Staniszewski

Inhalt - Chatbots

1. Was hat KI mit Chatbots zu tun?
2. Welche Methoden werden dafür eingesetzt?
3. Was haben wir bereits umgesetzt?
4. Welche Einsatzmöglichkeiten in der Industrie?

**Eine kurze Einführung in die Welt der Chatbots mit
Künstlicher Intelligenz**


21

1. Was hat KI mit Chatbots zu tun?

Welche Neuerungen bringt die KI
im Vergleich zu herkömmlichen, regelbasierten Systemen ?


Sprachverständnis – Chatbot verarbeitet Sprache in Text und analysiert

➔ Wort wird erkannt, trotz: Individueller Aussprache, Umgangssprache, Variation Satzbau



Textverständnis – möglichste Intention wird aus Summe von Wörtern errechnet

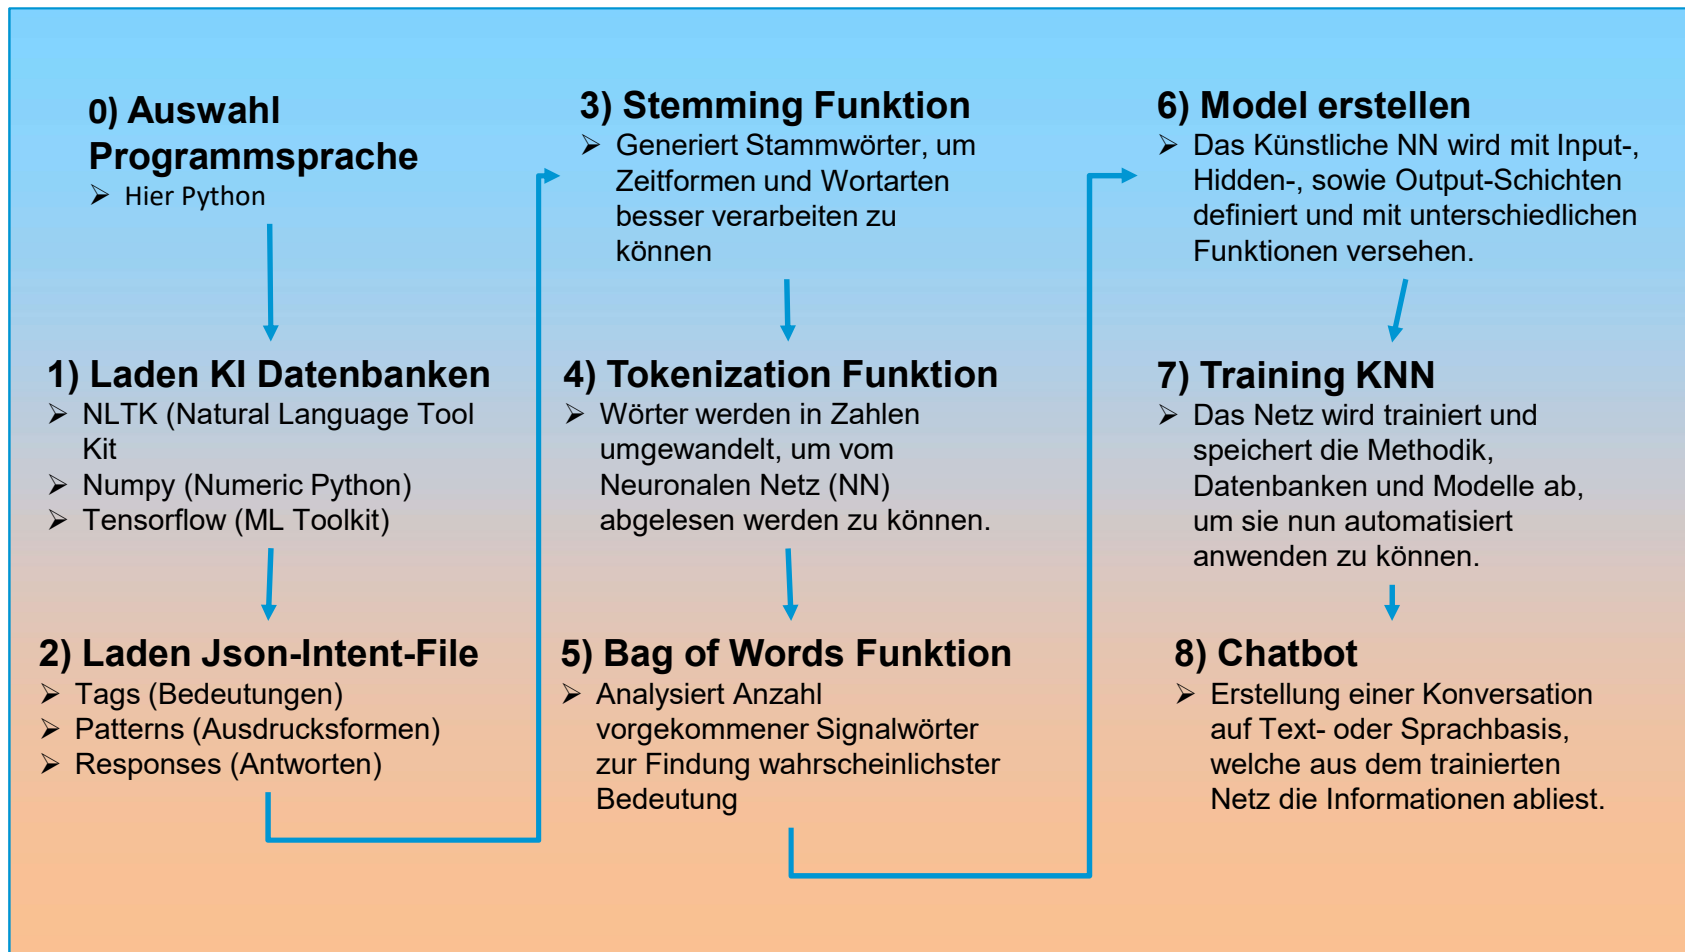
➔ versteht Kontext, trotz: Homonymen, Schreibfehlern, unbekanntem Vokabular,



Auch nicht definierte Aufforderungen können erkannt werden.

22

2. Welche Methoden werden dafür eingesetzt – 8 Schritte ?



Durch Vorbereitung, Training und Speicherung des Künstlichen Neuronalen Netzes ist der Chatbot direkt einsatzbereit.

23

3. Was haben wir bereits umgesetzt?

DigiTeam Helfer Chatbot - Version 1.0 - beantwortet Fragen z.B. zur einer Online Konferenz - Er lernt gerade, Synonyme, Deklinationen & und Konjunktionen erkennen zu können.

```
Hallo, hier ist der DigiTeam Helfer. Wie kann ich Ihnen helfen? (gebe 'Ende' zum Verlassen ein)
Sie: Zahlt man für die OK?
DigiTeam Helfer: Die Teilnahme der Online Konferenz ist kostenlos.Wir freuen uns auf Ihren Besuch!
```

```
"patterns": [
  "Wie viel kostet die Teilnahme?",
  "Kosten?",
  "Bezahlt man dabei?",
  "ist Sie kostenlos?"
]
```

„k **Stemming** : Umgang mit unterschiedlichen Konjunktionen wird vereinfacht

```
Sie: Was für Präsentationen werden stattfinden?
```

```
DigiTeam Helfer: Auf HAW Website ganzes Programm sehen:https://www.haw-hamburg.de/detail/news/news/show/online-konferenz-digitaler-wandel-im-produktionsmanagement/
```

```
"Wie ist das Programm?",
"Welche Themen werden vorgestellt?",
"Was passiert dort?",
"Was gibt es dort?",
"Welche Schwerpunkte werden dort behandelt?",
"Programm"
```

Natural Language Tool Kit (nltk) : lernt Umgangssprache durch Training aus Literatur, Chatverläufen, Datenbanken und kann somit Synonyme aus Zusammenhängen erkennen.

```
Sie: Also kostenlos und diese Super Themen? Da will ich doch gerne mitmachen!
```

```
DigiTeam Helfer: Zugangsdaten erhalten Sie nach einer Bewerbung unter HAW-HH-onlinekonferenz@outlook.de.
```

```
"tag": "Teilnahme",
"patterns": [
  "Ich will mitmachen",
  "Wie dabei sein?",
  "Ich möchte auch!",
  "Sind noch Plätze frei?"
]
```

Tokenization & Bag of Words : bei Signalwörtern aus mehreren möglichen Intents kann das Neuronale Netz durch die Umwandlung von Wörtern in Zahlen & berechnen der Wahrscheinlichkeiten des Tags, aus der Summe der Wörter, die passende Antwort finden.

Risiken

1. **Mis-Stemming**: Änderungen des Sinnes durch Kürzen (z.B. (Organ, organisieren) = organ)
2. **Beeinflussbare Datenbanken**: Manipulation der Lernenquellen des KNN durch Masseninput
3. **KI Kompetenz –Nötig**: Know-How, viele „saubere“ Daten oder ist abhängig von „Datenkraken“

Je mehr Trainingsdaten man einpflegt, desto „kreativer“ wird der Chatbot

24

4. Welche Einsatzmöglichkeiten von KI in der Industrie?

Produktion vorhanden

Porsche stellt Mitarbeitern
Corona Chat Bot zur Verfügung

- AI@Porsche - Kein langes Suchen nach der Anleitungen oder Dokumenten



Tiedemann, Y. 2020
Bild: Porsche

ODER – Startup BOTfriends

- Praktikanten von Porsche mit Produkt

TEAM

DANIEL RÖSCH
Geschäftsführer | Co-founder

KEVIN DEES
Geschäftsführer | Co-founder

TOBIAS GANSLER
Head of Development | Co-founder

MICHELLE SKODOWSKI
Head of Marketing | Co-founder

CHATBOTS – AI AUS WÜRZBURG, Lexa, C., 2018

Idee Chatbots

1. Bestandsanalyse-Bot

- **Ziel:**
Man fragt Chatbot nach einem Werkzeug/Bauteil und durch Sensoren, sowie Bilderkennung, nennt er den nächsten Zugriffort.
- **Beispielfrage/Intent:**
Wo haben wir noch Kneifzangen? / Meine Kneifzange ist kaputt!
- **Antwort:**
Ecke B7 im Werkzeugkasten sind noch 7 Kneifzangen. Bitte die Entnahme unterschreiben.

M. Staniszeswik 2021

Automobilindustrie profitiert bereits von Chatbots

Vortragstitel, Referent

Online-Konferenz HAW Hamburg, 12.01.2021, Prof. Dr.-Ing. Randolph Isenberg, Prof. Dr.-Ing. Henner Gärtner
Neue Wissensgebiete für das Produktionsmanagement - Knowledge-Chunks für das Online-Learning im digitalen Wandel

4. Welche Einsatzmöglichkeiten von Chatbots?

Gesundheit vorhanden

- Problem: Gesundheitsdienste stehen nicht allen Menschen zur Verfügung
- 2011 Ada in Berlin Kreuzberg
- Jetzt London, New York, Munich, Berlin, 200 MA
- KI + Ärzten + Wissenschaftler
- Nutzerbasis 10 Mio, weltweit
- Symptome in Minuten verstehen



Daniel, Claire und Martin eröffnen unser Büro in Berlin Kreuzberg 2011

Ada, 2021 - Health.
Powered by Ada.

Idee Chatbots

2. Sprachbasierter Diagnose-Chatbot



- **Ziel:**
Handlungsempfehlungen aus Datenbank von Studien wird abgeleitet
- **Status:**
Patient geht zur Arzt und braucht eine Diagnose. Der Arzt nimmt Symptome auf und pflegt Sie in das System
- **Antwort:**
KI Chatbot durchsucht aktuellste Schnittstellen, sowie erfolgreichste Behandlungsmethoden und ergänzt somit den Arzt beratend.



M. Staniszeswik 2021



- **Maschinenbau- und Gesundheitsindustrie profitieren bereits von Chatbots**

Vortragstitel, Referent

Online-Konferenz HAW Hamburg, 12.01.2021, Prof. Dr.-Ing. Randolph Isenberg, Prof. Dr.-Ing. Henner Gärtner
Neue Wissensgebiete für das Produktionsmanagement - Knowledge-Chunks für das Online-Learning im digitalen Wandel



Inhalt

1. Introduction

1. KI Winter und Sommer
2. ML Übersicht

2. Federated Machine Learning

3. Vertrauen erhöhen durch transparentes Data-Mining mit ML Algorithmus

1. Data Mining – CRISP - Data Check
2. Decision Tree
3. Konzept – Produktionsszenario mit Supply Chain Bezug
4. Random Forest auf Basis von nachvollziehbaren Daten

4. Chat-Bots

5. AI in Learning

6. Zusammenfassung

Transparenz hilft Vertrauen aufzubauen insbesondere für Management Entscheidungen wichtig.

27

Quelle / Fußnote

AI-ML in Engineering – Basics and Application Examples

Zweite Online-Konferenz der HAW Hamburg zum Digitalen Wandel im Produktionsmanagement, 12.1.2021

R. Isenberg, F. Peters, R. Schröder-Kroll, J. Darboe, M. Staniszewski

AI arrives in universities as course and support

Ongoing: AI is finding its way into typical engineering courses

- E.g. 2020 in HAW-Hamburg – Mechanical Eng./Production
 - Fully restructured for Digitization with study courses
 - such as Digital engineering and mobility /Robotics / Artificial intelligence / Digital production



Universal Robots (n.d.). Robotiq Wrist Camera. (Retrieved: 26.11.2020)

But can AI directly support teaching to solve e.g. these problems:

- Problem - low staff-student ratio
 - Staff-student ratio in engineering at universities of applied sciences 1 to 49 at universities 1 to 104 (Germany, 2016) Maaz, K., Reif, S., Boomkamp-Dahmen, S. (2020) Bildung in Deutschland 2018. (Retrieved: 24.11.2020)



- AI allows “personal teacher” by adapt learning content to individual skills/ interests of students
- independent of staff-student ratio

- Problem - high dropout rates
 - Dropout rate in engineering about 35 % (Germany, 2018) Maaz, K., Reif, S., Boomkamp-Dahmen, S. (2020) Bildung in Deutschland 2020. (Retrieved: 24.11.2020)



- Prediction algorithms to identify high-risk students in early semesters to avoid later dropout.

URWing (n.d.). Artificial intelligence AI icon. (Retrieved: 26.11.2020)

Darboe 2021

28

AI for education – chances in online scenario

Interesting approaches from Whitepaper “Künstliche Intelligenz in der Hochschulbildung” (2020)

Learning Analytics

- Graphical **learning progress for students** representation in dashboards
- **Drop-out** analysis for individual support

Personalized learning

- Consideration of individual learning goals, personal skills and student preferences
- Attention to **different learners** and **learner types**
- Development of an adapted and optimized learning strategy

Recommendation systems

- E.g. supporting students with the module selection
("Students who were interested in this module were also interested in ...")

Chatbots as

- Virtual **training** partner
- Moderators in forums

→ **AI supports constructivism: learners get into focus and design the learning process more and more by themselves**



Schulz, M. (2020). What makes a chatbot human-like and how can you build one?. (Retrieved: 24.11.2020)

de Witt, C.; Rampelt, F.; Pinxwart, N. (Hrsg.) (2020). Künstliche Intelligenz in der Hochschulbildung. Whitepaper. Berlin, KI-

Chatbot as possible Trainer?

Darboe, 2021

29

AI-ML in Engineering – Basics and Application Examples

Zweite Online-Konferenz der HAW Hamburg zum Digitalen Wandel im Produktionsmanagement, 12.1.2021

R. Isenberg, F. Peters, R. Schröder-Kroll, J. Darboe, M. Staniszewski

4 Kernaussagen:

B2 – AI-ML in Engineering – basics and application examples

Randolf Isenberg, Frank Peters, Roland Schröder-Kroll, Juntang Darboe, Michael Staniszewski

Präsentiert auf 2ter Online-Konferenz Produktionsmanagement
HAW-Hamburg – Institut Produkt- und Produktionsmanagement
Hamburg, 12.1.2021

1. **FML Federated Machine Learning** - ML kann gerade in der Supply Chain – typische Entscheidungs-fallen wie den Peitschen-Effekt aufdecken und Datensorgen reduzieren.
2. **DataMining** und ML Algorithmen brauchen Transparenz – damit sie vom Management genutzt werden können
Konzept zur Transparenz: Produktionsproblematik RandomForest Algorithmus nachvollziehbarem eigenem Datenpool.
3. **Chatbots** – nutzen Neuronale Netze – Startups können schon große Nutzergruppen nachweisen in Produktion und Medizin.
4. **Lernen** „VON und DURCH“ KI-ML ist keine Utopie mehr.

Vielen Dank für Ihre Aufmerksamkeit!

Referenzen

- Isenberg, R. (2020) 'AI in Engineering - Keynote', in. *AI in Engineering*, Online - Hamburg: CAE-Forum - ARIC e. V. - Virtual Dimension Center. Available at: <https://www.ai-engineering.technology/wp-content/uploads/2020/12/AI-in-Engineering-Keynote-R-Isenberg-HAW-Hamburg-2020-12-02.pdf>.

Random Forest

- Simplilearn (2018) *Random Forest Algorithm - Random Forest Explained | Random Forest in Machine Learning | Simplilearn*. Available at: <https://www.youtube.com/watch?v=eM4uJ6XGnSM&t=5s> (Accessed: 12 January 2021).

Chatbot

- Tiedemann, Y., n.d. Porsche stellt Mitarbeitern Corona-Chatbot zur Verfügung [WWW Document]. Branchen-News für Top-Entscheider der Automobilindustrie. URL <https://www.automotiveit.eu/menschen/porsche-stellt-mitarbeitern-corona-chatbot-zur-verfuegung-253.html> (accessed 1.10.21).
- Lexa, C., 2018. Chatbots - AI aus Würzburg, geschaffen von den BOTfriends! [WWW Document]. Gründen@Würzburg. URL <https://gruenden.wuerzburg.de/chatbots-ai-aus-wuerzburg-geschaffen-von-den-botfriends/> (accessed 1.11.21).
- Ada, 2021 - Health. Powered by Ada. [WWW Document], n.d. . Ada. URL <https://ada.com/> (accessed 1.11.21).
- FML
- Maria Kuper; Lukas Wuttke (2020): Federated machine learning - Unlock the value of shared supply chain data without actually sharing that data. Accenture. https://view.publitas.com/p222-16229/10_federated-machine-learning/page/4%2F5 (accessed 27.10.2020)
- Supply-Chain-Management (2020). In: Wikipedia. <https://de.wikipedia.org/w/index.php?title=Supply-Chain-Management> (Abruf 8.1.2021).

References from Keynote Presentation

- AAAI. (2020). AAI-21 Keywords. Retrieved November 13, 2020, from <https://aaai.org/Conferences/AAAI-21/aaai21keywords/>
- Airbus. (2020). Skywise: Airbus open data platform. Retrieved November 13, 2020, from <https://skywise.airbus.com/>
- Airbus (2017) <https://www.airbus.com/newsroom/news/en/2016/03/Pioneering-bionic-3D-printing.html> , retrieved 2020-10-27
- Autodesk (2017) <https://www.autodesk.de/customer-stories/airbus> , retrieved 2020-10-27
- Baker, B.; Kanitscheider, I.; Markov, T.; Wu, Y.; Powell, G.; McGrew, B.; Mordatch, I. (2020): Emergent Tool Use From Multi-Agent Autocurricula. In: arXiv:1909.07528 [cs, stat].
- Bernijazov, R.; Foullois, M. (2020): Künstliche Intelligenz im Engineering - SElive Webinar Vol.2. Online: Fraunhofer IEM, Heinz Nixdorf Institut - Universität Paderborn. <https://www.youtube.com/watch?v=J8PQm1hgYXI> (Retrieved 26.10.2020).
- Chui, M. (2017). Artificial intelligence the next digital frontier?. McKinsey and Company Global Institute, 47, 3-6.
- Covariant. (2020). Solutions. Retrieved November 13, 2020, from <https://covariant.ai/solutions>
- de Witt, C., Rampelt, F., Pinkwart, N. (Hrsg.) (2020). Künstliche Intelligenz in der Hochschulbildung. Whitepaper. Berlin: KI-Campus.
- Grebner, Robert, Prof. (2020) translated from KI Podcast <https://kipodcast.de/podcast-archiv/12>
- IBM, „AI for engineering requirements | IBM Watson IoT,“ (2020) [Online]. Available: <https://www.ibm.com/internet-of-things/learn/ai-for-engineeringrequirements/index.html?chapter-05>. [retrieved August 21, 2020].
- Isenberg, R. and Huebner, M. (1988) A workcell controller using a knowledge-based simulation model for real-time production planning in the electronics industry IMACS Transaction on Sc. Computing, 12th IMCAS World Congress 1988, Paris ISSN 1012-2435
- Isenberg, R. (1987) Comparison of BB1 and Kee for Building a production planning expert system, 3rd Int. Expert Systems Conference, London, June 2-4, 1987
- Kuper, M.; Wuttke, L (2020): Federated machine learning - Unlock the value of shared supply chain data without actually sharing that data. Accenture. https://view.publitas.com/p222-16229/10_federated-machine-learning/page/4%2F5 (Retrieved 27.10.2020)
- Ladwig, P.; Pech, A.; Geiger, C. (2020): Auf dem Weg zu Face-to-Face-Telepräsenz Anwendungen in Virtual Reality mit generativen neuronalen Netzen. In: Weyers, B.; Lürig, C.; Zielasko, D. (Hrsg.): GI VR / AR Workshop. Gesellschaft für Informatik e.V. <http://dl.gi.de/handle/20.500.12116/33423>.

References from Keynote Presentation

- Maaz, K., Reh, S., Boomkamp-Dahmen, S. (2020). Bildung in Deutschland 2018. Tab. F3-6web. In: Nationaler Bildungsbericht. <https://www.bildungsbericht.de/de/datengrundlagen/daten-2018> (Retrieved: 24.11.2020).
- Maaz, K., Reh, S., Boomkamp-Dahmen, S. (2020). Bildung in Deutschland 2020. Tab. F4-7web. In: Nationaler Bildungsbericht. <https://www.bildungsbericht.de/de/datengrundlagen/daten-2020> (Retrieved: 24.11.2020).
- Nagy, D., Zhao, D., & Benjamin, D. (2018). Nature-based hybrid computational geometry system for optimizing component structure. In Humanizing Digital Reality (pp. 167-176). Springer, Singapore.
- Noor, Ahmed K. (2017) 'AI and the Future of the Machine Design Artificially Intelligent Systems Are Learning How to Develop New Products and Design. What Does That Leave the Engineers to Do?' Mechanical Engineering 139, no. 10 (1 October 2017): 38–43. <https://doi.org/10.1115/1.2017-Oct-2>.
- Oh,S.; Jung,Y; Kim,S. Lee,I.; und Kang,N.; (2019) „Deep Generative Design: Integration of Topology Optimization and Generative Models,“ Journal of Mechanical Design, Nr. 141,p. 1,
- Palantir. (2020). Skywise. Retrieved November 13, 2020, from <https://www.palantir.com/solutions/skywise/>
- Sarkar,D; Bali,R; and Ghosh,T (2018) Hands-on Transfer Learning with Python, Packt Publishing Ltd.
- Schmid, Helmut (2020) Universal Robots, translated from <https://kipodcast.de/podcast-archiv/12>
- Schulz, M. (2020): What makes a chatbot human-like and how can you build one? In: Medium. <https://chatbotsjournal.com/what-makes-a-chatbot-human-like-and-how-can-you-build-one-3a9a9aef90be> (Retrieved: 24.11.2020).
- Seeberg, Peter (2020) Translated from <https://kipodcast.de/podcast-archiv/12>
- Turing, A. M. (2009). Computing machinery and intelligence. In Parsing the turing test (pp. 23-65). Springer, Dordrecht.
- UXWing (n.d.). (2020) Artificial Intelligence AI icon. <https://uxwing.com/artificial-intelligence-ai-icon/> (Retrieved: 24.11.2020).
- Universal Robots (n.d.). (2020) Robotiq Wrist Camera. <https://www.universal-robots.com/plus/urplus-components/vision/robotiq-wrist-camera/> (Retrieved: 26.11.2020).
- VDMA (2020) Quick Guide Machine Learning im Maschinen- und Anlagenbau
- Vaughan, Daniel (2020) Analytical Skills for AI and Data Science, O'Reilly Media, Inc.
- Westkämper, E.; Spath, D.; Constantinescu, C.; Lentjes, J. (Hrsg.) (2013): Digitale Produktion. Berlin, Heidelberg: Springer Berlin Heidelberg.
- Yang, Q.; Liu, Y.; Chen, T.; Tong, Y. (2019): Federated Machine Learning: Concept and Applications. In: ACM Transactions on Intelligent Systems and Technology 10, S. 12:1–12:19.