

DIDAKTIK DER INFORMATIK

DATA SCIENCE UND BIG DATA

IN DER BERUFLICHEN BILDUNG –

KONZEPTION UND ERPROBUNG EINES
PROJEKTKURSES FÜR DIE SEKUNDARSTUFE II

27. BAG-FACHTAGUNG 11. – 13.03.2019 SIEGEN

Simone Opel & Michael Schlichtig

Agenda

Data Science und Big Data und berufliche Informatikbildung

Das Projekt ProDaBi

Der Projektkurs zu ProDaBi

Weiterentwicklung

Fazit

Data Science und Big Data in der beruflichen Informatikbildung

- Data Science, Big Data und Künstliche Intelligenz sind keine integralen Bestandteile verschiedener Lehrpläne
- **Aber:**
 - Bedeutung nimmt im Alltag immer mehr zu
 - Beruflicher Einsatz wird immer wichtiger
- **KMK – Handreichung 2011:**
 - „Die Förderung und der Erwerb einer umfassenden Handlungskompetenz stehen damit im Mittelpunkt des pädagogischen Wirkens.“ (S. 11)
 - „Damit befähigt die Berufsschule die Auszubildenden [...] zur nachhaltigen Mitgestaltung der Arbeitswelt und der Gesellschaft in sozialer, ökonomischer, ökologischer und individueller Verantwortung.“ (S. 10)

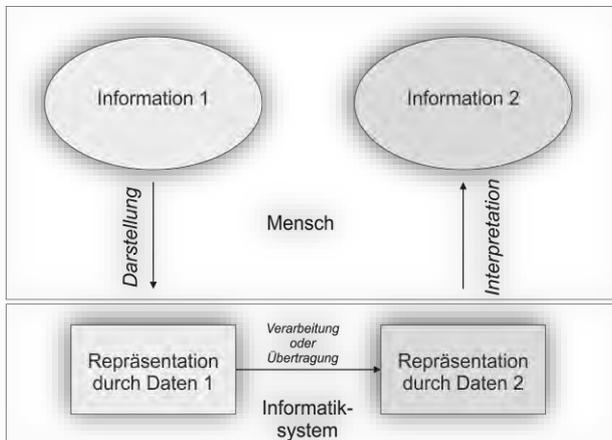


Bildquellen: vdi-nachrichten.de, amazon.de

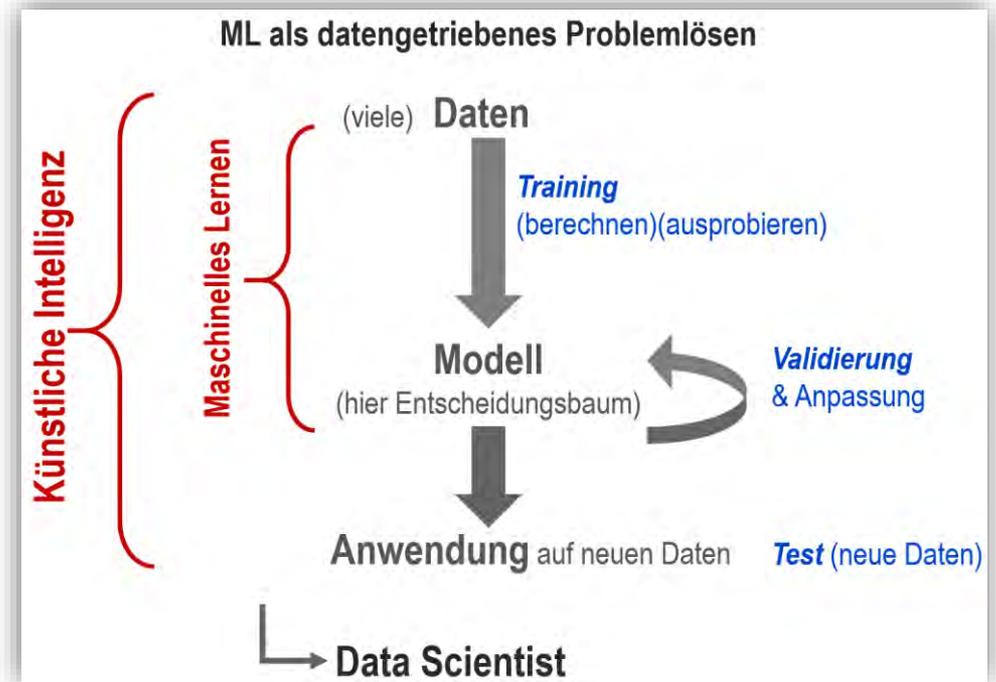
Das Projekt ProDaBi - Data Science und Big Data in der Schule



Daten als Basis



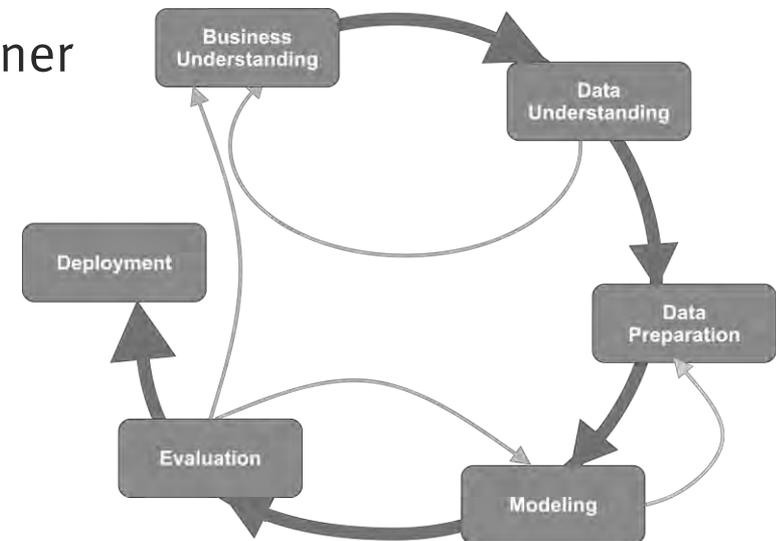
Information und Daten nach GI



Ergebnis einer Arbeitsphase
während des Projektkurses

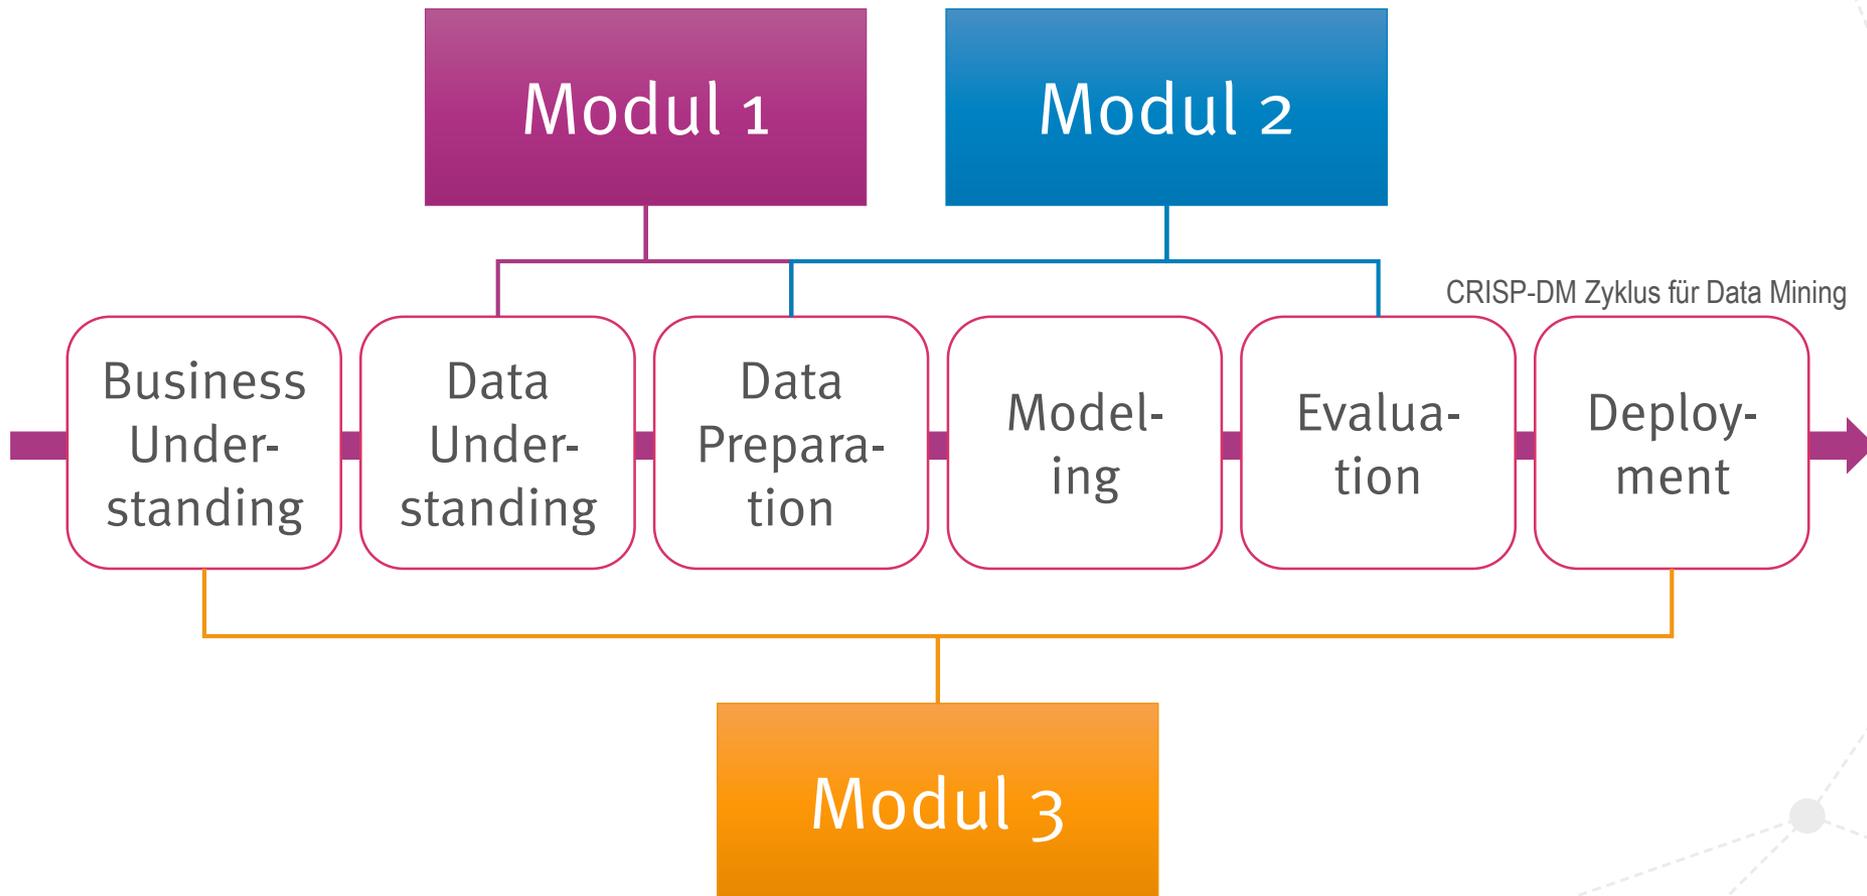
Der Projektkurs „Data Science“ – Planung

- Basis des Kurses ist der **CRISP-DM Zyklus**
- Entwicklung von einer algorithmen- zu einer datengetriebenen Sicht
- **Modularer Aufbau:**
 - **Modul 1:**
Daten verstehen, aufbereiten und präsentieren – Datendetektive
 - **Modul 2:**
Modelle erstellen und evaluieren – Maschinelles Lernen
 - **Modul 3:**
Anwenden des Wissens auf eine konkrete Fragestellung - Projektmodul



CRISP-DM Zyklus für Data Mining
nach Berthold et al. (2010)

Der Projektkurs „Data Science“ im Datenzyklus



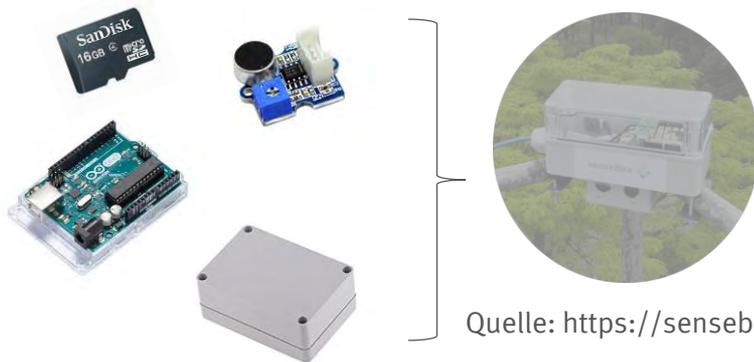
Rahmen der Erprobung

- Kooperation mit 2 paderborner Gymnasien
 - Projektkurs – Ersatz zu Facharbeit
 - 2 Schülerinnen, 17 Schüler der Q2
-
- Wöchentlich 3 Unterrichtsstunden (Montag 16:00 – 18:30)
 - 25 Wochen (September 2018 – April 2019)
-
- Lehr-Lern-Labor *PIN-Lab* der Informatikdidaktik der Uni-Paderborn
 - Aufzeichnung durch Raumkameras und Bildschirmaufzeichnung
 - Beobachtung des Unterrichts durch 2 Personen



Modul 1: Datendetektive

- Ziel: Entwicklung von Datenkompetenz
- **Baustein 1:** Einführung in Data Science
 - Analyse von Akustikdaten
 - Erfassung mittels „Sensebox“
 - Verwendung von Jupyter Notebook und Python



Quelle: <https://sensebox.de>



Jupyter Notebook

Sucht euch eine der folgenden CSV-Dateien aus und erstellt ein entsprechendes DataFrame:

1. DATALOG_1.csv
2. DATALOG_2.csv
3. DATALOG_3.csv
4. DATALOG_4.csv
5. DATALOG_5.csv

```
In [1]: #Hier euer Code

import csv
import pandas as pd

with open('DATALOG.CSV', 'r') as file, open('newFile.csv', 'w+') as newFile:
    newFile.write("Zeit,Wert\n")
    csv_reader = csv.reader(file, delimiter='\n')
    for row in csv_reader:
        s = row[0]
        if ':' in s:
            a = s.split(':')
            #print(a[0]+' '+a[1]+\n')
            newFile.write(a[0]+' '+a[1]+\n')

df = pd.read_csv('newFile.csv')
```

Daten ausgeben:

Wenn ihr diesen Befehl eingibt

```
print(df)
```

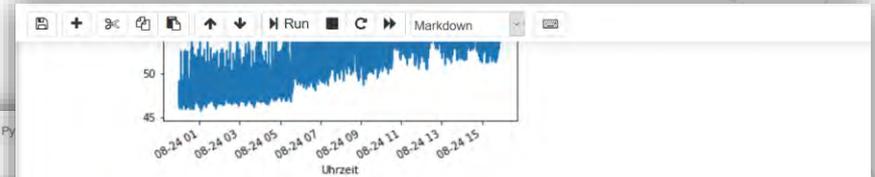
werden die Daten eures DataFrames ausgegeben.

`print()` ist eine spezielle Python-Funktion die den Inhalt der Klammer auf der Konsole ausgibt. Oft finden sich diese Funktion auch in den importierten Methoden wieder.

Also muss `print()` nicht immer angegeben werden.

```
In [2]: #Hier euer Code
print(df)
```

	Zeit	Wert
0	0	53.27
1	0	55.69
2	0	57.00
3	0	57.91
4	0	58.51
5	1	58.95
6	1	59.29
7	1	59.54
8	1	59.76
9	1	59.94



Zusammenfassen der Akustikdaten:

Bis jetzt sind in unseren Graphen meist mehrere Werte pro Sekunde. Dadurch ist der Graph sehr überfüllt und schwer zu vergleichen. Um die Daten noch übersichtlicher zu machen, können wir die Daten zusammenfassen. So gewinn ich hinsichtlich des Lautstärkeprofils dieses Standortes.

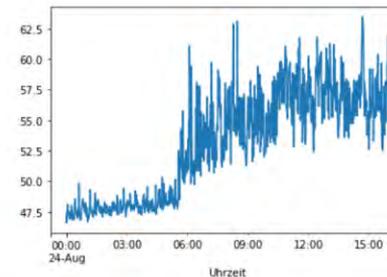
Hier können zwei Befehle nützlich sein: `resample()` und `mean()`:

```
df_Tag_zusammengefasst = df_Tag.resample('1Min').mean()
```

Das `'1Min'` steht hier für einen Zeitraum von 1 Minuten, für den die Daten zusammengefasst werden. Das Zusammenfassen ist eine Mittelwertberechnung. Ihr könnt damit mal ein bisschen rumprobieren und andere Zeiten wählen, und gucken, was das für ein Ergebnis bringt. Z. B. `'30Min'`, `3H` oder `'2D'`

```
In [15]: #Hier euer Code zum Zusammenfassen und anschließenden Zeichnen
df_Freitag_zsm = df_Freitag.resample('1Min').mean()
print(df_Freitag_zsm.Wert.plot())
```

AxesSubplot(0.125,0.125;0.775x0.755)



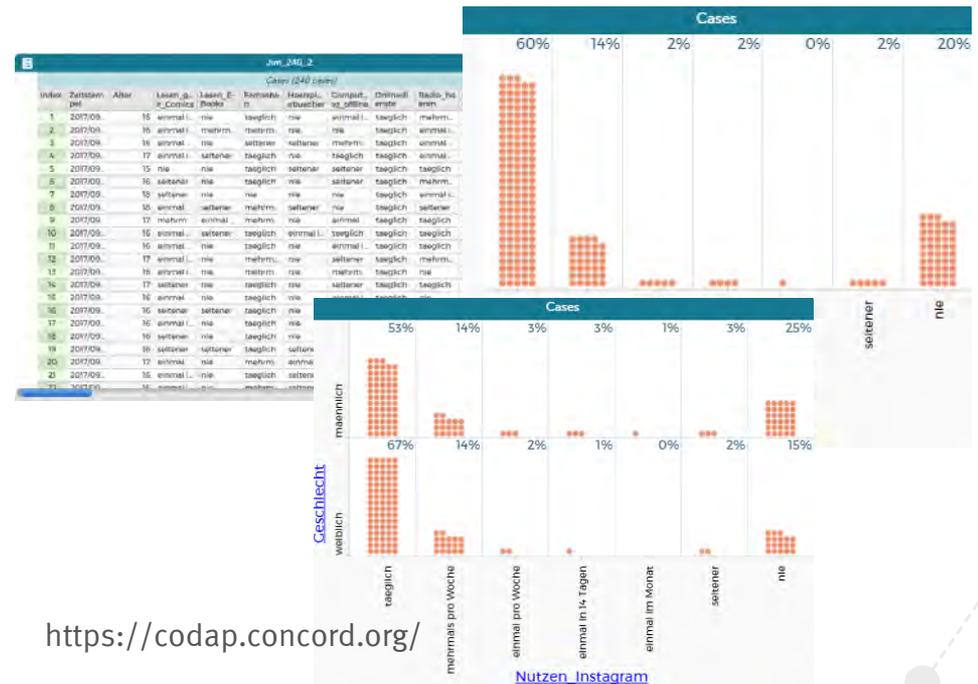
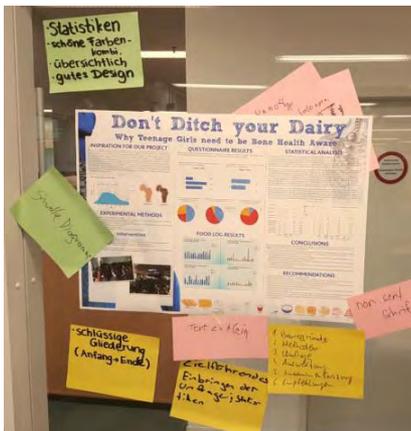
Überblick

Ihr habt nun eine Reihe an Funktionen kennengelernt, wie ihr mit den Akustikdaten arbeiten könnt.

Hier noch einmal ein Überblick über die benutzten Methoden:

Modul 1: Datendetektive

- **Baustein 2:** Einführung in die explorative Datenanalyse
 - Analyse des JIM-Datensatzes
 - Verwendung von CODAP
 - Multivariate Datenanalysen
 - Anwenden statistischer Konzepte
 - Analyse von Datenplakaten

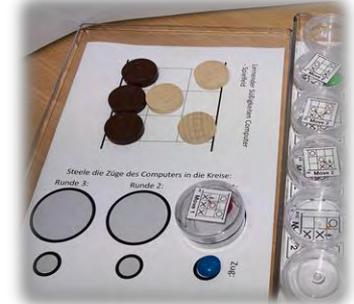


<https://codap.concord.org/>

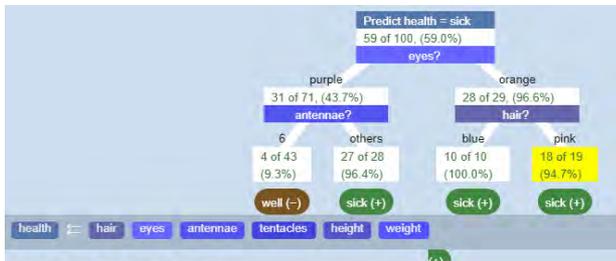
Nutzen Instagram

Modul 2: Einstieg in Maschinelles Lernen

- **Ziel:** Kennen von Grundkonzepten Künstlicher Intelligenz und Maschinellen Lernens
- **Baustein 1:** Einführung in Maschinelles Lernen mit Entscheidungsbäumen
 - LAC-H (Lernender Analoger Computer für Hexapawn)
 - Decision Trees (Entscheidungsbäume) mit CODAP (Treetool) und Jupyter Notebook u.a. mit

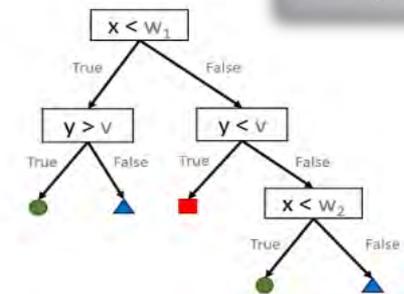
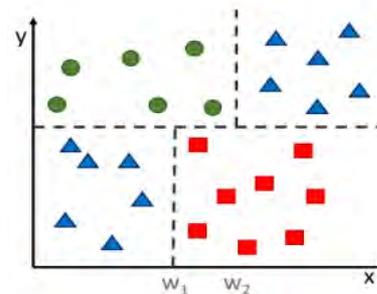


JIM-Datensatz



TP = 55, TN = 39, FP = 2, FN = 4

<https://tinyurl.com/ydhn7fqm>



Modul 2: Einstieg in Maschinelles Lernen

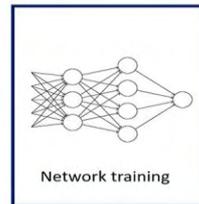


Baustein 2: Maschinelles Lernen mit Künstlichen Neuronalen Netzen

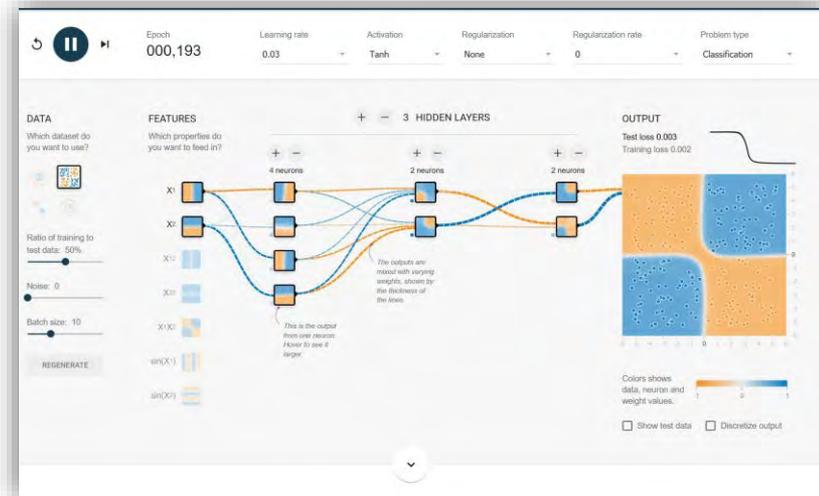
- Einstieg durch Unplugged-Aktivität „Brain in the Bag“
- Erkennen der Parameter und Kenngrößen durch Training von Netzen mit „Playground TensorFlow“
- Modellierung eigener Netze



- MNIST-Datenbank zur Erkennung handschriftlicher Ziffern
- Python und Jupyter Notebook
- Eigene Ziffern zur Validierung

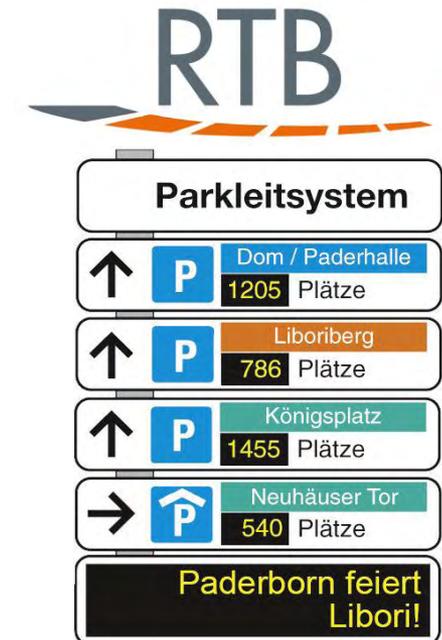


0
1
2
3
4
5
6
7
8
9



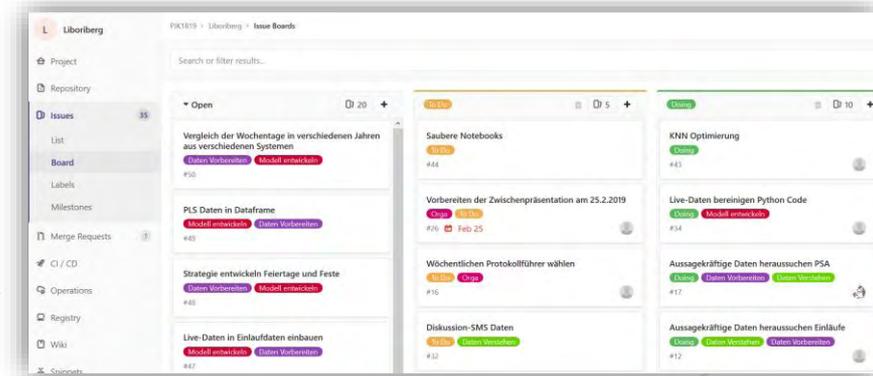
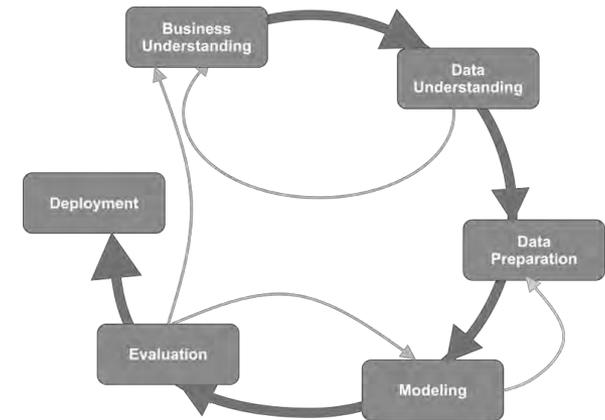
Modul 3: Wissen anwenden – Projektmodul

- Kooperation mit: Abfall- und Entsorgungsbetriebe Paderborn (ASP, Parkraumbewirtschaftung) und Fa. RTB
- **Aufgabenstellung:**
 - *Erstellung einer **Prognose** über die Belegung verschiedener bewirtschafteter Parkmöglichkeiten zu einem zukünftigen Zeitpunkt*
 - *Können die jeweiligen Belegungen – abhängig von verschiedenen Parametern – für einen zukünftigen Zeitpunkt mit einer hinreichend guten Genauigkeit **vorhergesagt** werden?*
- **Verfügbare Daten:**
 - Daten des Parkleitsystems (Induktionsschleifen)
 - Daten aus Parkautomaten und Kassensystemen



Modul 3: Wissen anwenden - Projektmodul

- **Projektgruppe 1:** Parkhausbelegung – Erfassung Parkdauer bei Bezahlung
- **Projektgruppe 2:** Parkplatzbelegung – Erfassung der geplanten Parkdauer
- **Vorgehen:**
 - Orientierung am **CRISP-DM Zyklus**
 - Arbeitsorganisation angelehnt an agilen Methoden
- **Werkzeuge:**
 - Jupyter Notebook mit Python
 - Git als Repository und Issue-Tool
- Abschlusspräsentation 1. April 2019



Weiterentwicklung des Projekts

Curriculum

Entwicklung für Sek II
allgemein

Design Based Research-
Ansatz wird vertieft

Konzentration auf
gesellschaftliche Aspekte

Projektkurs

Stärkere Verzahnung des
Projekts mit
Theoriemodulen

Neues Modul zu
Gesellschaftlichen
Auswirkungen von Big
Data und Künstlicher
Intelligenz

Unterrichtsmaterial

... Bausteine als gesamter
Projektkurs

... Stand-Alone Bausteine
mit minimalem
Programmieranteil

Evaluation und
Weiterentwicklung in
enger Verzahnung mit
Lehrkräften

Geplanter Ablauf im Folgekurs

