



Technische Hochschule Georg Agricola

INDUSTRIEAUTOMATION

DATA SCIENCE IN DER PRODUKTION

Bochum

Prof. Dr.-Ing. Lars N. Josler

AGENDA



1. Einordnung von Data Science für Ingenieure
2. Datenspeicherung in Datenbanken
3. Datenverarbeitung in Python
4. Machine Learning Basics
5. Ablauf einer Machine Learning Pipeline
6. Anwendungsbeispiel im Ingenieurskontext

AGENDA



- 1. Einordnung von Data Science für Ingenieure**
2. Datenspeicherung in Datenbanken
3. Datenverarbeitung in Python
4. Machine Learning Basics
5. Ablauf einer Machine Learning Pipeline
6. Anwendungsbeispiel im Ingenieurskontext

DATEN IM INGENIEURSKONTEXT



■ Produktionslinien

- Maschinendaten
- Fertigungsdaten

■ Sensordaten

- (Autonome) Fahrzeuge
- Wearables
- VR/AR
- IoT
- ...

■ Kundendaten


- Adressen
- Bestellungen
- ...



WO ENTSTEHEN IN EINEM UNTERNEHMEN DATEN?




- Daten entstehen in vielen Bereichen des Unternehmens
- Hohe Variation der Daten innerhalb der Ebenen in:
 - Aggregationslevel
 - Frequenz
 - Informationsgehalt
 - Etc.
- **5 V's von Big Data**
 - Velocity
 - Variety
 - Veracity
 - Value
 - Volume



EINLEITUNG MASCHINELLES LERNEN

MACHINELLES LERNEN VS. BIG DATA



HOW BIG IS BIG DATA?



■ Beispiel LFF



$$10 \frac{MB}{\text{Maschine} \cdot \text{Tag}} \cdot 365 \frac{\text{Tage}}{\text{Jahr}} \cdot 10 \text{ Maschinen} \approx 40 \text{ GB/Jahr}$$




■ Beispiel Energieversorger (z.B. Smart-Meter Daten)

$$5 \frac{MB}{\text{Kunde} \cdot \text{Tag}} \cdot 365 \frac{\text{Tage}}{\text{Jahr}} \cdot 40000 \text{ Kunden} \approx 73000 \frac{GB}{\text{Jahr}}$$



■ Beispiel Social Media Website

$$100 \cdot 10^6 \frac{\text{Fotos}}{\text{Tag}} \cdot 365 \frac{\text{Tage}}{\text{Jahr}} \cdot 1 \frac{MB}{\text{Foto}} \approx 36500000 \frac{GB}{\text{Jahr}} = 36.5 \text{ PB (Petabyte)}$$



Quellen:
PC
Server
Amazon
Snowmobile

LEAN / 5S BEI DATEN



- | | | |
|-------------------------------------|---|--|
| ■ Seiri ([Aus-]Sortieren) | ↔ | Nur relevante Daten betrachten |
| ■ Seiton (Systematisieren) | ↔ | Datenkonsistenz (Bsp: Eindeutige ID) |
| ■ Seiso (Säubern) | ↔ | Entferne fehlerhafte Werte |
| ■ Seiketsu (Standardisieren) | ↔ | übergreifenden Standards schaffen |
| ■ Shitsuke (Selbstdisziplin) | ↔ | manuelle (Betriebs-)Daten korrekt eingeben (Störungen, Fehler etc.) |

DATA SCIENCE LEBENSZYKLUS




- **Team Data Science-Prozess von Microsoft (TDSP)**
 - Beschreibt verschiedene Phasen der Datenanalyse
 - Kein statischer Verlauf; Iterationszyklen
 - Alle Modelle beinhalten 4 zentrale Phasen:
 1. Business Understanding
 2. Datenerzeugung und Datenverständnis
 3. Modellbildung
 4. Nutzung
- **Weitere Modelle:**
 - CRISP-DM (Cross Industry Standard Process for Data Mining)
 - KDD (Knowledge Discovery in Databases)



VERSCHIEDENE PHASEN VON DATA SCIENCE



- **Fokus der Vorlesungsreihe auf den Bereichen des Data-Engineering und der Data-Analysis**



- **Data Acquisition & Understanding:**

- Was ist eine sinnvolle Art die Daten zu speichern?
- Wie werden die Daten bereitgestellt?
- Wie können die Daten verarbeitet werden?
- Wie müssen die Daten aufbereitet werden?

- **Modeling:**

- Welche Frage möchte ich beantworten? / Welches Problem möchte ich lösen?
- Welche (historischen) Daten stehen zur Verfügung?
- Wie sehen meine Daten aus?
- Welche Modellierungsart eignet sich?

AGENDA




1. Einordnung von Data Science für Ingenieure
- 2. Datenspeicherung in Datenbanken**
3. Datenverarbeitung in Python
4. Machine Learning Basics
5. Ablauf einer Machine Learning Pipeline
6. Anwendungsbeispiel im Ingenieurskontext

STATUS QUO



DIGITALE FABRIK



https://de.wikipedia.org/wiki/Datei:Python_logo_and_wordmark.svg

<https://rapidminer.com>

<https://www.tableau.com/de-de>

<https://www.knime.com/knime-analytics-platform/>

<http://mqtt.org/>

<https://new.siemens.com/global/de/produkte/automatisierung/industrielle-kommunikation/opc-ua.html>

PRO & CON VON STATUS QUO



Status Quo:

■ Pros

- Infrastruktur schon vorhanden
- Know-How/ Kompetenzen schon vorhanden
- „Das haben wir schon immer so gemacht“

■ Cons

- Keine zentrale Datenspeicherung
- Eingeschränkte Data Governance
- Eingeschränkte Vernetzung der Produktionssysteme/ in der gesamten Organisation
- Kein Backups von Daten
- Prinzipien für der Datenhaltung werden häufig nicht eingehalten

Digitale Fabrik:

■ Pros

- Regelmäßige Backups und dezentraler Datenzugriff möglich
- Steuerung + Regelung der Produktionsprozesse
- Übersicht über bestehende Datenbasis der Produktionslinie/ des Unternehmens
- Auseinandersetzung mit bestehenden Daten fördert Prozesswissen
- Grundlage für jeden Data Science Use-Case

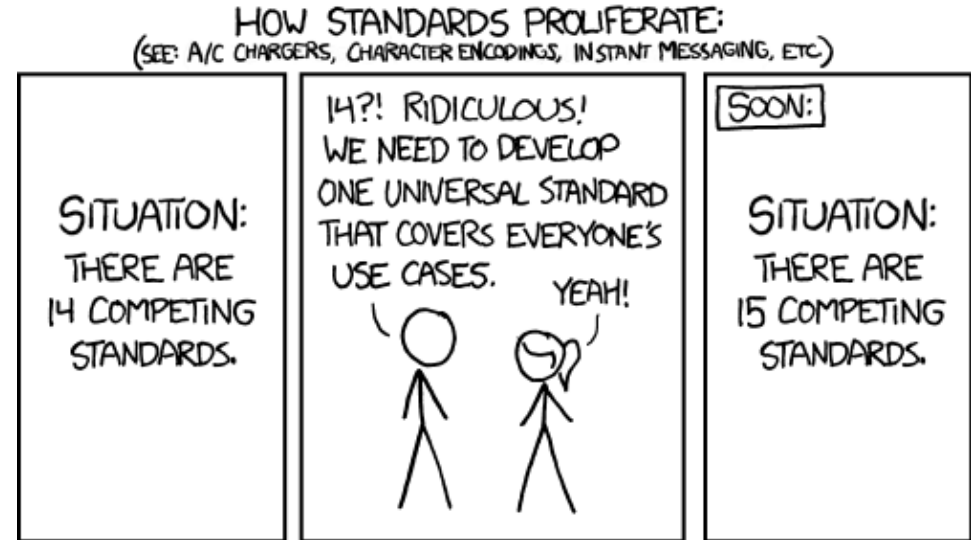
■ Cons

- Zusätzliche Hardware / Know-How/ Wartung notwendig
- Zusätzliche Wartung der IT notwendig
- Komplexe Einbindung in bestehende Systeme und Prozesse



- **Realweltdaten sind „hässlich“**

- Oftmals keine Standardisierung vorhanden
- Dezimaltrennzeichen 23,4 vs. 23.4 (z.B. in einem System verbaute EU- und US-Sensoren)
- NaN – Not a Number
- Unterschiedliche wissenschaftliche Notation: $1.5832e^{-5}$ vs. $1.5832E^{-5}$
- Encodings und Decoding (utf-8, Ascii etc.)
- Zeitzonen (UTC, CET) / Zeitstempel (UNIX)
- Hohe Aggregation z.B. Messwert: 23.1 cm Abweichung jedoch in μm wichtig.
- Inkonsistenzen (Adresse ohne Geokoordinate; Keine Eindeutigkeit in IDs)



WARUM KEIN EXCEL ZUR SPEICHERUNG?



Status Quo: Viel in Excel

Pros

- GUI-Interface
- In jeder Firma auf jedem Computer verfügbar
- Für jeden zugänglich und weit verbreitet
- Automatisierung mit VBA

Cons

- Nicht für „große“ Datenmengen ausgelegt (>1.000.000 Zeilen)
- Speicherung und Berechnung der Daten sind nicht getrennt
- Verwaltung von Zugriffsrechten aufwändig
- Geringe Skalierbarkeit und Verlostsicherheit

Datenbank als Alternative

Pros

- Skalierbarkeit
- Trennung von Speicherung und Berechnung
- Verwaltung von Zugriffsrechten und Backup der Daten
- Verteilte Datenhaltung möglich

Cons

- Schwer zugänglich, hohe Lernkurve
- In der Regel kein GUI-Interface
- Nicht auf jedem System verfügbar
- SQL als Sprache weniger einfach zugänglich als Excel Formeln

DATENTYPEN



Standard Datentypen

Name	Beispiel Beschreibung	Beispiel Eintrag
Bool (Binär)	Maschine an/aus	True oder False
Integer (Ganzzahl)	Anzahl an Schrauben	42
Float (Gleitkommazahl)	Stromstärke	15.732 mA
Char/String (Zeichenkette)	Name Bearbeiter	Hans Müller
Datetime (Datum)	Zeitstempel Bearbeitung	2018-17-11 17:37:25

SQL-
Datenbanken
→
Strukturierte
Daten

Komplexe Datentypen

- Audiodateien
- Bilder/Video
- Geometrien
- Objekte
- CAD-Dateien
- ...

No-SQL
Datenbanken
→ Nicht
strukturierbare
Daten

KONKRETES BEISPIEL TABELLE



Zeitstempel	Maschinen- name	Maschinen ID	Stromstärke Motor [mA]	Maschine an	Werkzeug ID	Produkt ID
2018-17-11 17:25:11:25	Fz12	2385	17.35	1	2357	67800
2018-17-11 17:25:11:50	Fz12	2385	17.78	1	2357	67800
...						
2018-17-11 17:37:00:00	Fz12	2385	0	0	2357	67800
...						
2018-17-11 17:40:00:00	Fz12	2385	18.50	1	9047	67800
Date	String	Integer	Float	Bool	Integer	Integer

DATENBANKEN BEGRIFFE



Attribut/Spalte/Feld

- **Tabelle/ Relation**

Primärschlüssel

Tupel/Zeile

<u>Spaltenname 1</u>	Spaltenname 2	Spaltenname 3

View

- **Datenbank**



- **Datenbanksystem**





- **Relation:** Tabelle von strukturierbaren Daten
- **Attribut/ Spalte/ Feld:** Spalte in einer Tabelle
- **Tupel:** Zeile in einer Tabelle
- **Primärschlüssel:** Wert zur eindeutigen Identifizierung einer Zeile → muss innerhalb der Tabelle eindeutig sein
- **View:** Subset von ausgewählten Spalten und Zeilen einer Relation
- **Relationale Datenbank:** Sammlung von einzelnen Relationen
- **Datenbanksystem:** Sammlung von relationalen Datenbanken

PRIMÄRSCHLÜSSEL – JA ODER NEIN



- **Primärschlüssel:** Wert zur eindeutigen Identifizierung einer Zeile → muss innerhalb der Tabelle eindeutig sein

Tabelle	Wert	JA	NEIN
Studenten	Name + Vorname + Geburtsdatum		
Studenten	Matrikelnummer		
Arbeitnehmer	Sozialversicherungsnummer		
Kraftfahrzeuge	Kennzeichen		
Kraftfahrzeuge	VIN-Nummer		

Kennzeichen

BOS738

B-OS-738

BO-S-738

PRIMÄRSCHLÜSSEL – JA ODER NEIN



- **Primärschlüssel:** Wert zur eindeutigen Identifizierung einer Zeile → muss innerhalb der Tabelle eindeutig sein

Tabelle	Wert	JA	NEIN	ES KOMMT DRAUF AN
Studenten	Name + Vorname + Geburtsdatum		x	
Studenten	Matrikelnummer	x		
Arbeitnehmer	Sozialversicherungsnummer	x		
Kraftfahrzeuge	Kennzeichen			x
Kraftfahrzeuge	VIN-Nummer	x		



Kennzeichen

BOS738

B-OS-738

BO-S-738

BEISPIELE FÜR DATENBANKSYSTEME



- **Kriterien für die Auswahl eines Datenbanksystems:**
 - Art der Daten (SQL vs. No-SQL)
 - Anzahl der Daten
 - Änderungsfrequenz der Daten (statisch vs. Dynamisch vs. Stream)
 - Budget (Open-Source vs. Proprietär)
 - Verwaltungsaufwand
 - Speicherort (lokal, Server, verteilt)
 - Anzahl an Nutzern



■ Informationen über Studierende:

- Allgemeine Informationen (Matrikelnummer, E-Mail Adresse, Name, Vorname, Geburtsjahr, Studienbeginn, Studiengang)
- Adresse (Straße, Hausnr., PLZ, Stadt)
- Ausweisinformationen (Ausweisnummer, Ausweisguthaben)
- Fächer (belegte Fächer, Anzahl an Versuchen, Note)
- Sonstiges (Semesterbeitrag bezahlt)

Welche Möglichkeiten gibt es, diese Informationen in einer Datenbank zu speichern?



Möglichkeit I: Alle Informationen in einer Tabelle speichern

Matr. Nr.	Name	Vorname	Adresse	Ausweis Nr.	Ausweisguthaben	Fach	Note
1001	Simpson	Homer	742 Evergreen Terrace	7777	0.70 €	Reaktorsicherheit	1.0
1001	Simpson	Homer	742 Evergreen Terrace	7777	0.35 €	Reaktorsicherheit	1.0
0001	Burns	Mr.	Am Reaktor 3	8567	10000000 €	Mechanik A	2.7
0001	Burns	Mr.	Am Reaktor 3	8567	10000000 €	Reaktorsicherheit	4.0
0001	Burns	Mr.	Am Reaktor 2	8567	10000000 €	Bachelor Arbeit	1.7
1003	Szyslak	Moe	15 Moe's Tavern	-	-	-	-

Probleme:

- Redundanzen
- Unübersichtlich
- Probleme beim Löschen/ Updaten/ Einfügen von Informationen

NORMALFORMEN



Möglichkeit II: Mehrere Tabellen anlegen, die in Normalform sind

Normalform: Tabelle befindet sich in einer Form, die keine vermeidbaren Redundanzen enthält

Studierende

<u>Matr. Nr.</u>	Name	Vorname	Adresse
1001	Simpson	Homer	742 Evergreen Terrace
0001	Burns	Mr.	Am Reaktor 3
1003	Szyslak	Moe	15 Moe's Tavern

0001

<u>Fach</u>	Note
Mechanik A	2.7
Reaktorsicherheit	4.0
Bachelor Arbeit	1.7

Ausweis

<u>Ausweis Nr.</u>	Matr. Nr.	Ausweisguthaben
7777	1001	0.70 €
8567	0001	10000000 €


Reaktorsicherheit

<u>Matr. Nr.</u>	Note
1001	1.0
0001	4.0

JOINS



- Kombinieren von mehreren Tabellen für einfache Berechnungen



LIVE DEMO JOIN



■ Structured Query Language

- Sprache zur Handhabung von relationalen Datenbanken → Erstellung, Veränderung und **Durchsuchen** und Rechteverwaltung von Datenbanken
- Wird von jeder (SQL-) Datenbank unterstützt und ist weitestgehend einheitlich definiert
- Deklarative Programmiersprache → Lesbar und an die englische Sprache angelehnt
- Von Nutzern von Datenbanken am häufigsten verwendete Funktionalitäten
 - Auswahl/ Filterung
 - Sortieren von Ergebnissen
 - Basic Rechenoperationen (Summen, Durchschnitt, Median, Standardabweichung, Zählen, Min, Max)
 - Join Operation (Kombinieren von Informationen aus mehreren Tabellen)
 - Group-By Operation (Anwendung von Aggregation auf Gruppen von Elementen)

AGENDA



1. Einordnung von Data Science für Ingenieure
2. Datenspeicherung in Datenbanken
- 3. Datenverarbeitung in Python**
4. Machine Learning Basics
5. Ablauf einer Machine Learning Pipeline
6. Anwendungsbeispiel im Ingenieurskontext

WARUM KEIN EXCEL ZUR BERECHNUNG?



Status Quo: Alles in Excel

■ Pros

- GUI-Interface
- In jeder Firma auf jedem Computer verfügbar
- Für jeden zugänglich und weit verbreitet
- Erweitertes Programmieren mit VBA

■ Cons

- Geringe Skalierbarkeit
- Zahlen sind sichtbar, aber Formeln versteckt
- Eingeschränkte Toolboxes
- Code kann nicht in Repositories verwaltet werden

Wissenschaftliches Rechnen als Alternative

■ Pros

- Skalierbarkeit auf große/ sehr große Daten
- Trennung von Speicherung und Berechnung
- Open-Source Gedanke weit verbreitet
- i.d.R. ein größeres „Ökosystem“ an verfügbaren Toolboxes
- Umsetzung komplexer Softwareprojekte möglich

■ Cons

- Erfordert grundsätzliches Wissen über Programmierung
- Nicht standardmäßig auf jedem System verfügbar
- Standardmäßig kein GUI-Interface → weniger zugänglich



Kompiliert

- Kompiliert: Quellcode → Compiler → ausführbare Datei
- C, C++, C#, Java, Fortran
- Effiziente und schnelle Ausführung
- Sehr low-level, schwierig zu debuggen

```
/* Hello World in C++ */  
#include <iostream>  
using namespace std;  
int main() {  
    cout << "Hello, World!";  
    return 0;  
}
```

Interpretiert

- Interpretiert: Quellcode → Interpreter → Ausführen
- Python, Matlab, R, JavaScript
- Einfache Handhabung/ Debugging
- Speicherineffizient und „langsam“

```
# Hello World in Python  
print("Hello, World!")
```


Wissenschaftliches Rechnen

- Programmierschnittstelle zwischen interpretierter und kompilierter Sprache für Nicht-Programmierer
- Interface in interpretierter Sprache und „Heavy-Lifting“ in kompilierter Sprache



Python


- Interpretierte, high-level, open-source Programmiersprache
- Fokus auf Lesbarkeit und klarer Syntax
- In den letzten Jahren zu einer der populärsten Programmiersprachen geworden
- Enorm große Community und viele Erweiterungen
- **Python für Wissenschaftler und Ingenieure:**
 - **Numpy/ Scipy** für wissenschaftliches Rechnen
 - **Matplotlib/ Bokeh/ Altair** für Plotting
 - **Pandas** für Tabellen/Datenbank Kalkulation
 - **Scikit-Learn/ Tensorflow/ PyTorch** für Machine- und Deep Learning
 - **Anaconda** als Paket Manager
 - **Jupyter** für wiederverwendbare Dokumente mit Text und Code



NUMPY ARRAY



- **Numerical Python**
 - BLAS (**B**asic **L**inear **A**lgebra **S**ystem) für Python
 - Vektor/Matrix als Basisobjekt → Numpy n.d array
 - **Deutlich** speichereffizienter und performanter als „normales“ Python
 - Verknüpfung von mathematischen Operationen und Matrizenrechnung
 - Alle Einträge eines Vektors/ einer Matrix müssen den gleichen **Datentyp** haben
 - Schnelles und effizientes **Indexing**
 - Basis für viele weitere Software-Pakete innerhalb Pythons Ökosystem



1	4	-1
3	6	8
8	3	8
-2	19	-9



- **Pandas**
 - Sehr effiziente **Datenanalyse** und **Datenmanipulation** in Python
 - Lesen und Schreiben in verschiedene Datenformate (CSV/Excel-files/ Datenbanken)
 - Unterstützt **TimeSeries** und **Indexing** Features
 - Ausführen von **Datenbankoperationen** (Joins/Group-Bys)
 - Verarbeitung von fehlenden Datenpunkten
 - De-facto Standard Datenverarbeitungspaket im Data Science Bereich für das Python Ökosystem
 - In der Industrie und der akademischen Welt weit verbreitet



PANDAS DATENTYPEN




	sex	age	fare	class	survived
0	male	22.0	7.2500	Third	0
1	female	38.0	71.2833	First	1
2	female	26.0	7.9250	Third	1
3	female	35.0	53.1000	First	1
4	male	35.0	8.0500	Third	0
...	...	...	Series ...		...
886	male	27.0	13.0000	Second	0
887	female	19.0	30.0000	First	1
888	female	NaN	23.4500	Third	0
889	male	26.0	30.0000	First	1
890	male	32.0	7.7500	Third	0

Index

DataFrame

Numpy Array

DEVELOPMENT STACK



WEITERES MATERIAL



- [Code Academy SQL](#)
- [Database Fundamentals](#)
- [Data School Pandas Basics](#)
- [Introduction to Analytics with Python](#)
- [Data Science Handbook](#)