

Dr. rer. nat. Valentin Khaydarov  
Professur für Prozessleittechnik & Arbeitsgruppe Systemverfahrenstechnik

# Machine Learning II

Vorlesung 3, Lehrveranstaltung Simulation und Optimierung, WS 2021/2022

# Gliederung – Vorlesung II

- Wiederholung des Materials der letzten Vorlesung
- Einzelne Schritte des Vorgehensmodells
- MLOps

# Wiederholung der letzten Vorlesung

# Zusammenfassung

A computer program is said to learn from **experience E** with respect to **some task T** and **some performance measure P**, if its performance on T, as measured by P, improves with experience E.


Je nach Typ der Zielvariable: **Regressionsaufgabe** (Kardinalskala), **Klassifikation** oder **Clustering** (Ordinal- oder Nominalskala)

Aufgaben:


	<b>Erfahrung</b>	<b>Aufgabe</b>
<b>Überwachtes Lernen</b>	Input-Variablen und Ziel-Variablen für alle Datenpunkte	Prädiktion Ziel-Variablen
<b>Unüberwachtes Lernen</b>	Nur Input-Variablen	Erkennung Muster in Input-Variablen
<b>Semiüberwachtes Lernen</b>	Input-Variablen und Ziel-Variablen für begrenzte Anzahl Datenpunkte	Prädiktion Ziel-Variablen für Datenpunkte ohne Labels im Datensatz
<b>Bestärkendes Lernen</b>	Agent und Umgebung	Entwicklung optimaler Strategie für Agent zum Umgang mit Umgebung

# Zusammenfassung


- Regression




- Support-Vektor-Maschine(und Regression)



- Entscheidungsbäume




- K-Means-Clustering

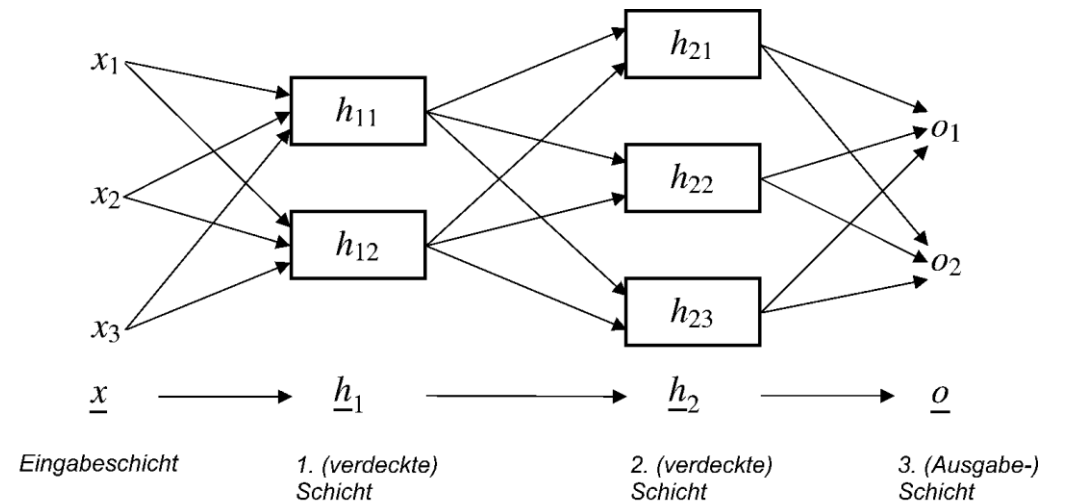


# Zusammenfassung


- Hauptkomponentenanalyse (PCA)



- Neuronale Netze



# Vorgehensmodell nach Amershi



- Data collection – Bereitstellung des Datensatzes: Datenimport oder –gewinnung
- Data cleaning – Aufbereitung des Datensatzes
- Data labelling – Markierung von Daten (Überwachtes Lernen)
- Feature engineering – Auswahl von Features und deren Aufbereitung für das Training
- Model training – Trainieren, Optimierung von Modell- und Training-Hyperparametern
- Model evaluation – Testen des Modells mit einem Testdatensatz, Berechnung von Metriken, Auswahl eines Modells für den Einsatz in der Produktion
- Model deployment – Aufbau Runtime-Umgebung für Modell-Inference, Einsetzen des Modells
- Model monitoring – Evaluation des Modells im Betrieb, Sammlung Daten für Verbesserung
- Model maintenance – Aktualisierung des Modells (z.B. nach Erweiterung/Anpassung des Training-Datensatzes)

M. Haakman, L. Cruz, H. Huijgens, and A. van Deursen, "AI lifecycle models need to be revised: An exploratory study in Fintech," *Empir. Softw. Eng.*, vol. 26, no. 5, pp. 1–30, 2021, doi: 10.1007/s10664-021-09993-1.

# Schritt 1: Model requirements (inkl. Business understanding)

# Formulierung der Problemstellung

Nach diesem Schritt sollen Antworten auf folgende Fragen gegeben werden:

- **Zielstellung** der zu entwickelnden Anwendung
- **Verfügbarkeit von Daten? Was genau enthalten die Daten? Wie wurden sie aufgenommen?**
  - **Daten verstehen**
- **Anforderungen** und relevante **Metriken**: Performance, Robustheit, Skalierbarkeit, Erweiterbarkeit, Echtzeitfähigkeit, Sicherheit, Ressourcenaufwand usw.
- **Minimale Anforderungen an die ML-Anwendung**
- Falls sie existieren: Wie funktionieren aktuell bestehende Lösungen? (**Baseline**)
- **Annahmen** und deren Validierung (falls möglich)
- **Wie** wird die Anwendung eingesetzt (online, offline)?
- Ist eine Modelldegradation zu erwarten und deshalb eine **Modellwartung** erforderlich?

# Formulierung der Problemstellung

**Das Modell ist in der Regel nur ein Teil der Anwendung und dessen Performance ist nicht immer entscheidend**

Für die Modullauswahl relevante Anforderungen:

- Gehören Eingangsvariablen Kardinal-, Ordinal- oder Nominalskala? Sind die Daten eine Sequenz (Zeitreihe) oder unabhängige Messungen?
- Zielvariablen: Vorhanden? Kardinal-, Ordinal- oder Nominalskala? Vollständig und zuverlässig annotiert?
- Umfang vorhandener Daten
- Ist Expertenwissen vorhanden?
- Modellgüte bzw. Zielfunktion sowie weitere relevanten Metriken

Output: **vorläufiger ML-Versuchsplan**

# Typische Problemstellungen in der Prozessindustrie

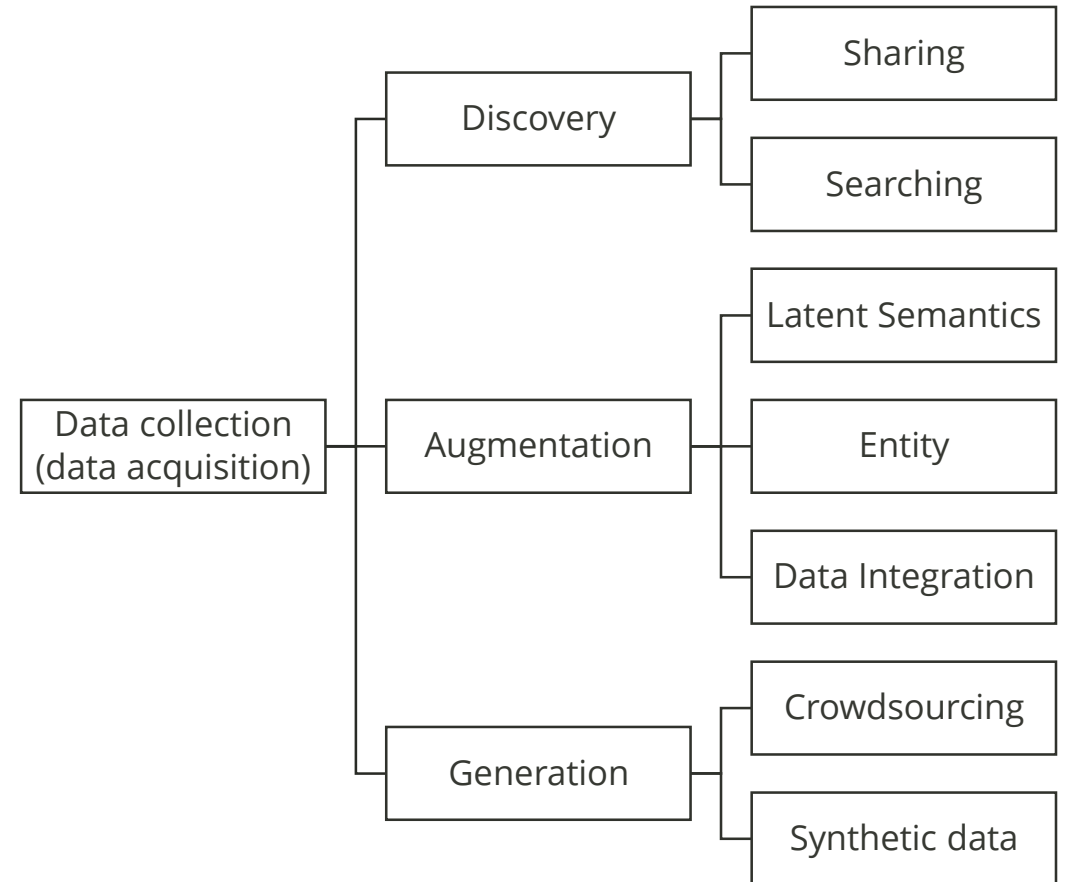
- Bewertung einer Prozessvariablen, die sich nicht direkt messen lässt → Softsensor
  - Regression oder Klassifikation
- Prädiktion des weiteren Zeitverlaufs → Prädiktive Wartung
  - Regression
- Erkennung eines Prozesszustandes oder einer bestimmten Störung
  - Klassifikation
- Anomalie-Erkennung
  - Clustering, Klassifikation
- Prozessregelung
  - Reinforcement-Learning

# Schritt 2: Data collection

# Data collection

Datengewinnung umfasst eine Vielfalt an Methoden zur **Beschaffung** von Daten, die weiterhin bei dem **Modelltraining** verwendet werden.

- Bis zu 90% aller Zeitaufwände bei der Entwicklung von ML-Anwendungen ist die Arbeit mit Daten
- Modellqualität hängt unmittelbar von der Datenqualität ab
- Neue Modellierungsansätze zur Abbildung komplexen Verhaltens (z.B. DeepNN) erfordern proportional mehr Daten für das Training



Y. Roh, G. Heo, and S. E. Whang, "A Survey on Data Collection for Machine Learning: A Big Data - AI Integration Perspective," *IEEE Trans. Knowl. Data Eng.*, pp. 1-1, 2019, doi: 10.1109/TKDE.2019.2946162.

# Industrielle Daten

Datentypen:

- **Prozessdaten von Sensoren sowie Signalgebern**, die primär für Prozessüberwachung, -optimierung und Regelung eingesetzt werden
  - Temperatur, Druck, Füllstand, Stoffeigenschaften, Sollwerte usw. in der Regel Daten der Kardinal- oder Ordinalskala (analoge und binäre Signale) als Zeitreihen
  - Verfügbar über das Prozessleitsystem und archiviert in einem Prozesshistorian oder offline als Protokoll
- **Diskrete Ereignisse** wie Prozessphase oder Rezeptschritt, Operatoreingriffe, Alarme der Nominalskala
  - In der Regel unstrukturiert und teilweise manuell aufgenommen
- **Engineeringdaten zur Anlage**
  - Meistens statische und **unstrukturierte** Daten
  - In der Regel in der Form von Dokumentation zur Produktionsanlage wie R&I-Fließbild, Konstruktionsdokumente, aktuelle Anlagekonfiguration, Regelungskreise, Rezepte usw.
  - Liefert sehr nützliche Kontextinformation für besseres Verständnis von Daten
- **Rohdaten von Analysegeräte (z.B. Spektroskopie, Chromatographie, Laserbeugung), Bild- und Videodaten**
  - Integriert mit relativ komplexen Preprocessing- und Datenauswertung-Algorithmen
  - Gekapselt in von dem SPS entkoppelten Systemen (z.B. Edge-Node-Konzept)

# Besonderheiten und Herausforderungen industrieller Daten

## Datenvarianz je nach Betriebsweise der Anlage:

- Batch-Betrieb: Varianz zwischen Chargen durch Änderungen im Startbedingungen und Wiederholungen
- Konti-Betrieb: Varianz ist in der Regel nur bedingt aussagekräftig → Data-rich-but-information-poor (DRIP)-Daten
- Daten sind in der Regel nicht nach Klassen bilanziert

## Fluch der Dimensionalität:

- Enorme Anzahl diverser und möglicher Datenquellen: Dutzende oder Hunderte Sensoren und Signalgeber

## Zeit:

- Je nach der Prozessskala können Messwerte fein ausgelöst sein (Millisekunden-Bereich)
- Datenaufnahme verschiedener Sensoren in der Regel nicht synchronisiert (s. OPC UA)
- Time-Sampling kann im Laufe der Zeit variieren (ms-Bereich im Betrieb und Min-Bereich im Prozesshistorian)

# Besonderheiten und Herausforderungen industrieller Daten

## Big-Data:

- Prozesse können bis zu vielen Tagen dauern:
  - ein Parameter, eine Messung pro Sekunde, eine Woche lang:  $60 \times 60 \times 24 \times 7 = 604800$  Messpunkte

## Einbindung von Kontextinformation:

- Normen schreiben Anlagenbauern und -betreibern die Durchführung einer sehr umfangreichen Anlagendokumentation vor
- Verwendung dieser Information zur ausführlichen Meta-Beschreibung von Datensätzen

Weitere spezifische datenbezogene Herausforderungen werden weiter in den Abschnitten „Data cleaning“ und „Data labeling“ betrachtet

# Data discovery

Methoden für das **Teilen** und die **Wiederverwendung** von bestehenden Datensätzen.

Allererster Schritt - Suche nach relevanten Datensätzen (lokal und global).

Voraussetzung ist die Erfüllung der FAIR-Prinzipien:

- **Findable:** Eindeutiger und dauerhafter Identifikator vorhanden und Metadaten erlauben die Findung
- **Accessible:** Standardisierte Protokolle für Datenzugriff
- **Interoperable:** Daten sind in einer (Computer-) lesbaren und interpretierbaren Form
- **Reusable:** Daten sind zusammen mit ausführlicher Beschreibung und Lizenzbedingungen zur Verfügung gestellt

Mehr auf <https://www.go-fair.org/fair-principles/>

# Data discovery: Datasheet for Dataset

Abschnitte:

- Motivation
- Composition
- Collection
- Preprocessing/Cleaning/Labeling
- Uses
- Distribution
- Maintenance

Quelle: Gebru, T., Morgenstern, J., Vecchione, B., Vaughan, J. W., Wallach, H., Iii, H. D., & Crawford, K. (2018). Datasheets for datasets. ArXiv.

corinna.kroeger@mailbox.tu-dresden.de\_1

valentin.khaydarov@tu-dresden.de\_2

This document is based on *Datasheets for Datasets* by Gebru *et al.* [?]. Please see the most updated version [here](#).

## MOTIVATION

**For what purpose was the dataset created?** Was there a specific task in mind? Was there a specific gap that needed to be filled? Please provide a description.  
The dataset is created to solve a problem of an image-based classification task of the flow regime identification in bioreactors.

**Who created this dataset (e.g., which team, research group) and on behalf of which entity (e.g., company, institution, organization)?**  
The dataset was captured by Corinna Kröger within her diploma project at Technische Universität Dresden.

**What support was needed to make this dataset?** (e.g.who funded the creation of the dataset? If there is an associated grant, provide the name of the grantor and the grant name and number, or if it was supported by a company or government agency, give those details.)  
The authors acknowledge the financial support by the Federal Ministry of Economic Affairs and Energy of Germany in the project KEEN (project number 01MK20014T).

**Any other comments?**

## COMPOSITION

**What do the instances that comprise the dataset represent (e.g. documents, photos, people, countries)?**

**Does the dataset contain all possible instances or is it a sample (not necessarily random) of instances from a larger set?** If the dataset is a sample, then what is the larger set? Is the sample representative of the larger set (e.g., geographic coverage)? If so, please describe how this representativeness was validated/verified. If it is not representative of the larger set, please describe why not (e.g., to cover a more diverse range of instances, because instances were withheld or unavailable).

**What data does each instance consist of?** Raw data (e.g., unprocessed text or images) or features? In either case, please provide a description.  
Each instance includes an image file and an associated json file with metadata and label (flow regime) to the image.

**Is there a label or target associated with each instance?** If so, please provide a description.  
Labels indicate the observed flow regime.

**Is any information missing from individual instances?** If so, please provide a description, explaining why this information is missing (e.g., because it was unavailable). This does not include intentionally removed information, but might include, e.g., redacted text.  
No information is missing.

**Are relationships between individual instances made explicit (e.g., users movie ratings, social network links)?** If so, please describe how these relationships are made explicit.

**Are there recommended data splits (e.g. training**

# Data discovery: Datenrepositories

## Datenrepositories (Daten intern gespeichert):

Kaggle.com, Amazons opendata.aws, UCI ML Repository, Microsofts msropendata.com, EU Open Data Portal, OpenML

Die meistverwendeten sind direkt in Tools integriert: Matlab (s. Sample Data Sets), sklearn (s. Toy datasets) und tensorflow (s. Tensorflow-Datasets)

## Suchportale (Nur Verweise auf externe Quellen):

Google Datasets Search Engine

## Listen von Datenrepositories:

[https://en.wikipedia.org/wiki/List\\_of\\_datasets\\_for\\_machine-learning\\_research](https://en.wikipedia.org/wiki/List_of_datasets_for_machine-learning_research)

<https://github.com/awesomedata/awesome-public-datasets>

In der Regel nur Daten für allgemeine Zwecke (viel Bilddaten). **Prozessdaten sind kaum öffentlich verfügbar.**

# Prominente industrielle Datensätze

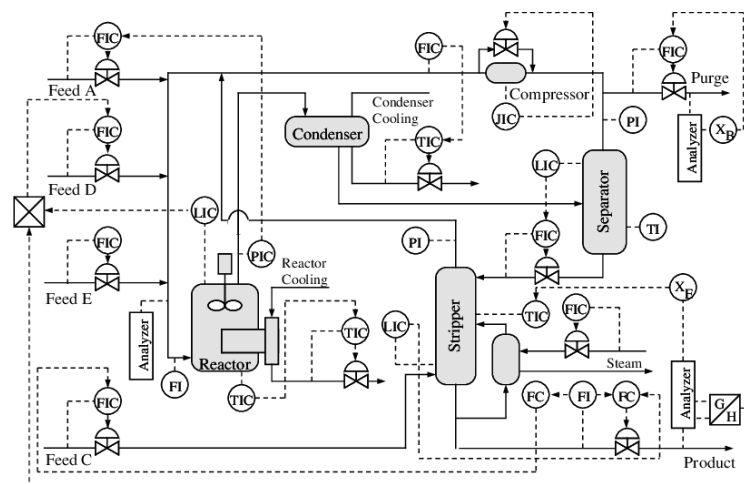
## Tennessee Eastman Process (TEP)

Down und Vogel, 1993

Open-Loop-Prozess mit 12 Regelventilen und 41 Messstellen

Als Challenge für Störungserkennung und dynamische Optimierung

Simulationsmodell und reale Datensätze auffindbar



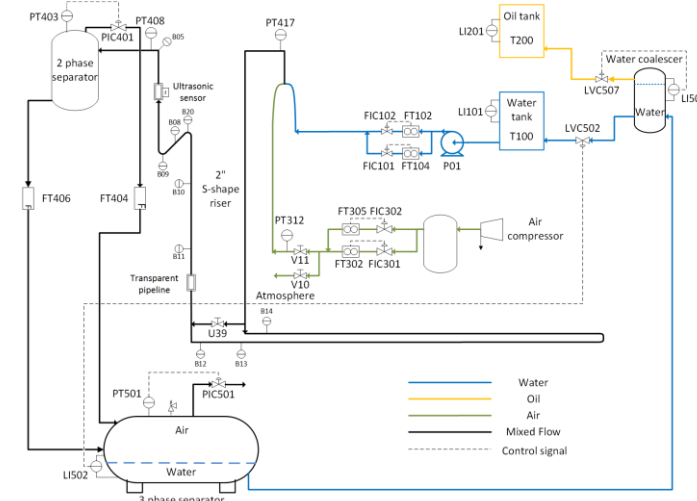
Kano u. a., „Contribution Plots for Fault Identification Based on the Dissimilarity of Process Data“.

## Multiphase flow facility (PRONTO)

Stief, Tan, Cao und Ottewill, 2019

Heterogene Datenquellen (Prozesswerte, Alarme, Logs, Hochfrequente Ultraschall- und Druckmessungen und Videodaten)

Multimodale und Multirate Störungserkennung und Anlagendiagnose




<https://doi.org/10.5281/zenodo.1341583>

# Data generation: Datenquellen




## Produktion

- Vollständig repräsentativ
- Große Menge
- Kleine Varianz
- Datenkosten niedrig
- Nur intern verfügbar



## Test-Umgebung

- Wenig repräsentativ
- Kleinere Datenmenge
- Höhere Varianz
- Datenkosten höher
- Dürfen veröffentlicht werden

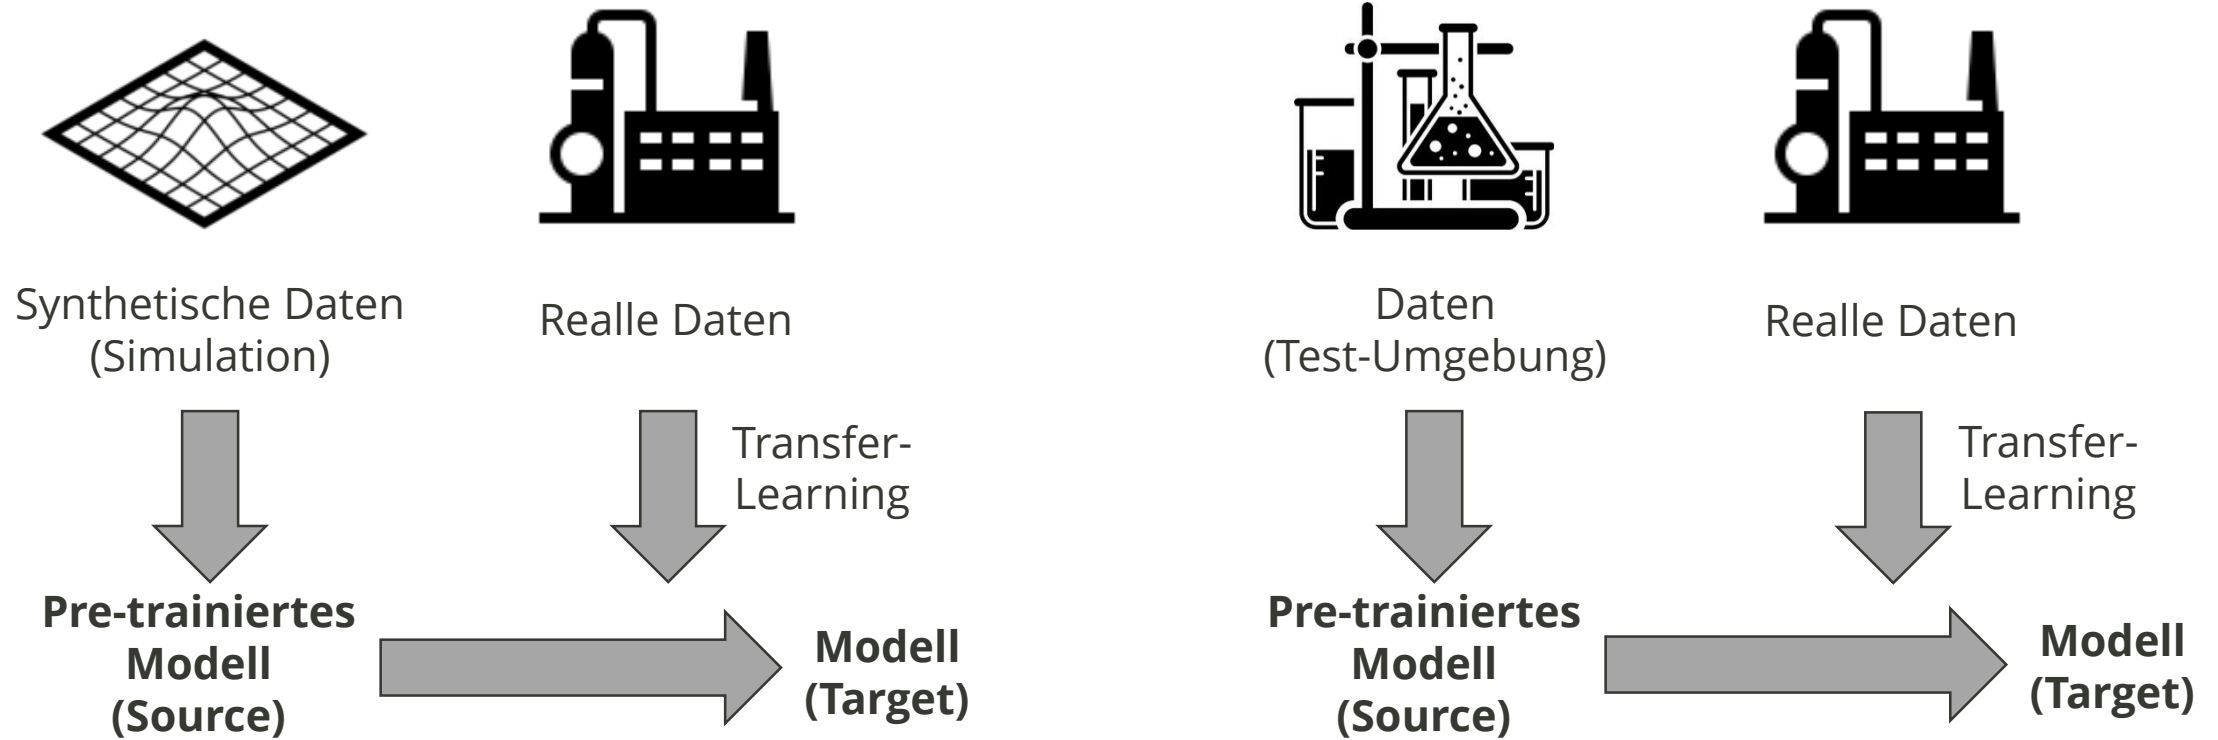


## Simulationsmodelle

- Bilden Modell ab
- So viel wie man will
- Beliebige Varianz
- Niedrige Kosten
- Grundsätzlich frei teilbar

**Transfer-Learning** ist der Einsatz Erfahrung auf ein ähnliches aber anderes Problem zu übertragen. Sehr beliebt und effektiv in Computer-Vision-Anwendungen.

# Data generation und Transfer learning



# Data exploration

Datenexploration ist ein Verfahren zur vorläufigen Analyse von Daten.

Datenexploration ist der allererste Schritt nach der Erwerbung von Daten.

Teilziele:

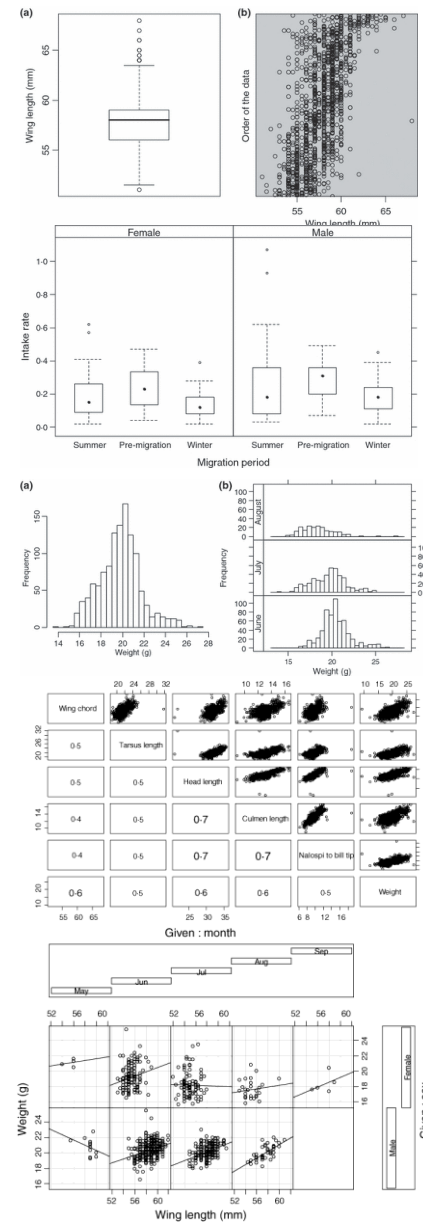
- **Formalisierung** Information über Variablen: Beschriftung, Typ, Einheit, Grenzen/Mögliche Werte
- Verschaffung eines **Überblicks** über und **Verständnis** von Daten
- **Initiale Analyse** von Mustern und Charakteristika der Daten
- Formulierung **initialer Hypothesen** für Modellierung
- **Vorplanung nächster Schritte** für Datenbereinigung, Datenaufbereitung, Featureauswahl sowie Vorauswahl geeigneter Modelltypen

# Protokoll für Datenexploration (Zuur, 2010)

1. Ermittlung von Ausreißern in X und Y: Box-Plot, Cleveland Dotplot, Multivariate Analysis
2. Annahme der Varianzhomogenität Y: Box-Plot für Gruppen
3. Normalverteilung von Y: Histogramm, Q-Q-Plot
4. Anteil von Nullen in Y: Frequenzhistogramm
5. Multikolarität von X: VIF, Corellogram, PCA
6. Zusammenhänge zwischen X und Y: Scatterplots, Box-Plot für Gruppen
7. Interaktionseffekt: Coplot
8. Unabhängigkeit von Y: ACF, Variogramm, Plot Y vs. Zeit/Ort

- Bei Anwendung von Modellen sollen Annahmen recherchiert werden.
- Die Reihenfolge lässt sich je nach Datensatz variieren.

Tools: Jupyter Notebook, Matplotlib, Plotly, Seaborn; Matlab Livescript



A. F. Zuur, E. N. Ieno, and C. S. Elphick, "A protocol for data exploration to avoid common statistical problems," *Methods Ecol. Evol.*, vol. 1, no. 1, pp. 3–14, Mar. 2010, doi: 10.1111/j.2041-210X.2009.00001.x.

# Schritt 3: Data cleaning

# Typische Probleme industrieller Daten

Allgemeines Vorgehen:

1. Identifikation möglicher Probleme
2. Suche nach Instanzen von Problemen
3. Korrektur von Fehlern
4. Dokumentierung von Fehlerpunkten
5. Anpassung der Routine zur Datenexploration

Typische Probleme:

- **Fehlende Werte**
  - Ausgefallene Geräte, Unterbrochene Verbindung
    - Datenimputation
- **Ausreißer**
  - Falsche Einstellung, zufälliger Sensorausfall
    - Korrektur/Entfernung
- **Datendrift**
  - Systematische Sensordegradation
    - Drift-Identifikation und Korrektur
- **Multikolarität**
  - Redundanz, Regelkreise
    - Manuelle Feature-Selection, PCA, PLS
- **Abtastrate und Verzögerungen**
  - Multi-rate-Modelle, Resampling

# Schritt 4: Data labeling

# Labels

Labels sind im Trainingsdatensatz erhaltene **Zielvariablen**, die dem Trainieren des Modells dienen.

Relevant nur für **Überwachtes Lernen**.

Labelling ist ein Verfahren in dem Labels für Datensatz **manuell, semi-automatisch** oder **automatisch** erhoben werden.

Labelling setzt **Wissensexpertise** oder **automatische Gewinnung** von bereits annotierten Daten voraus.

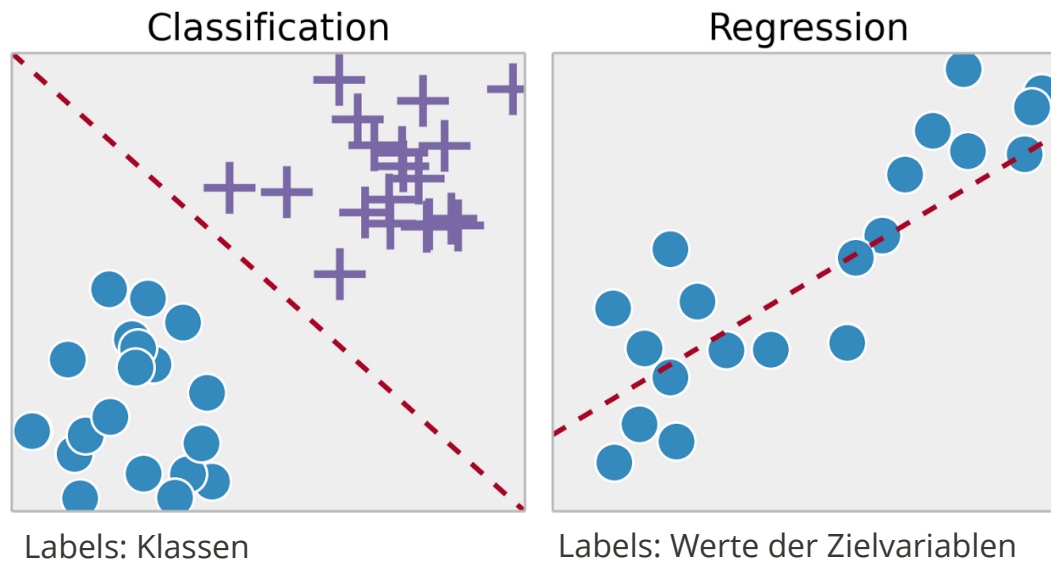
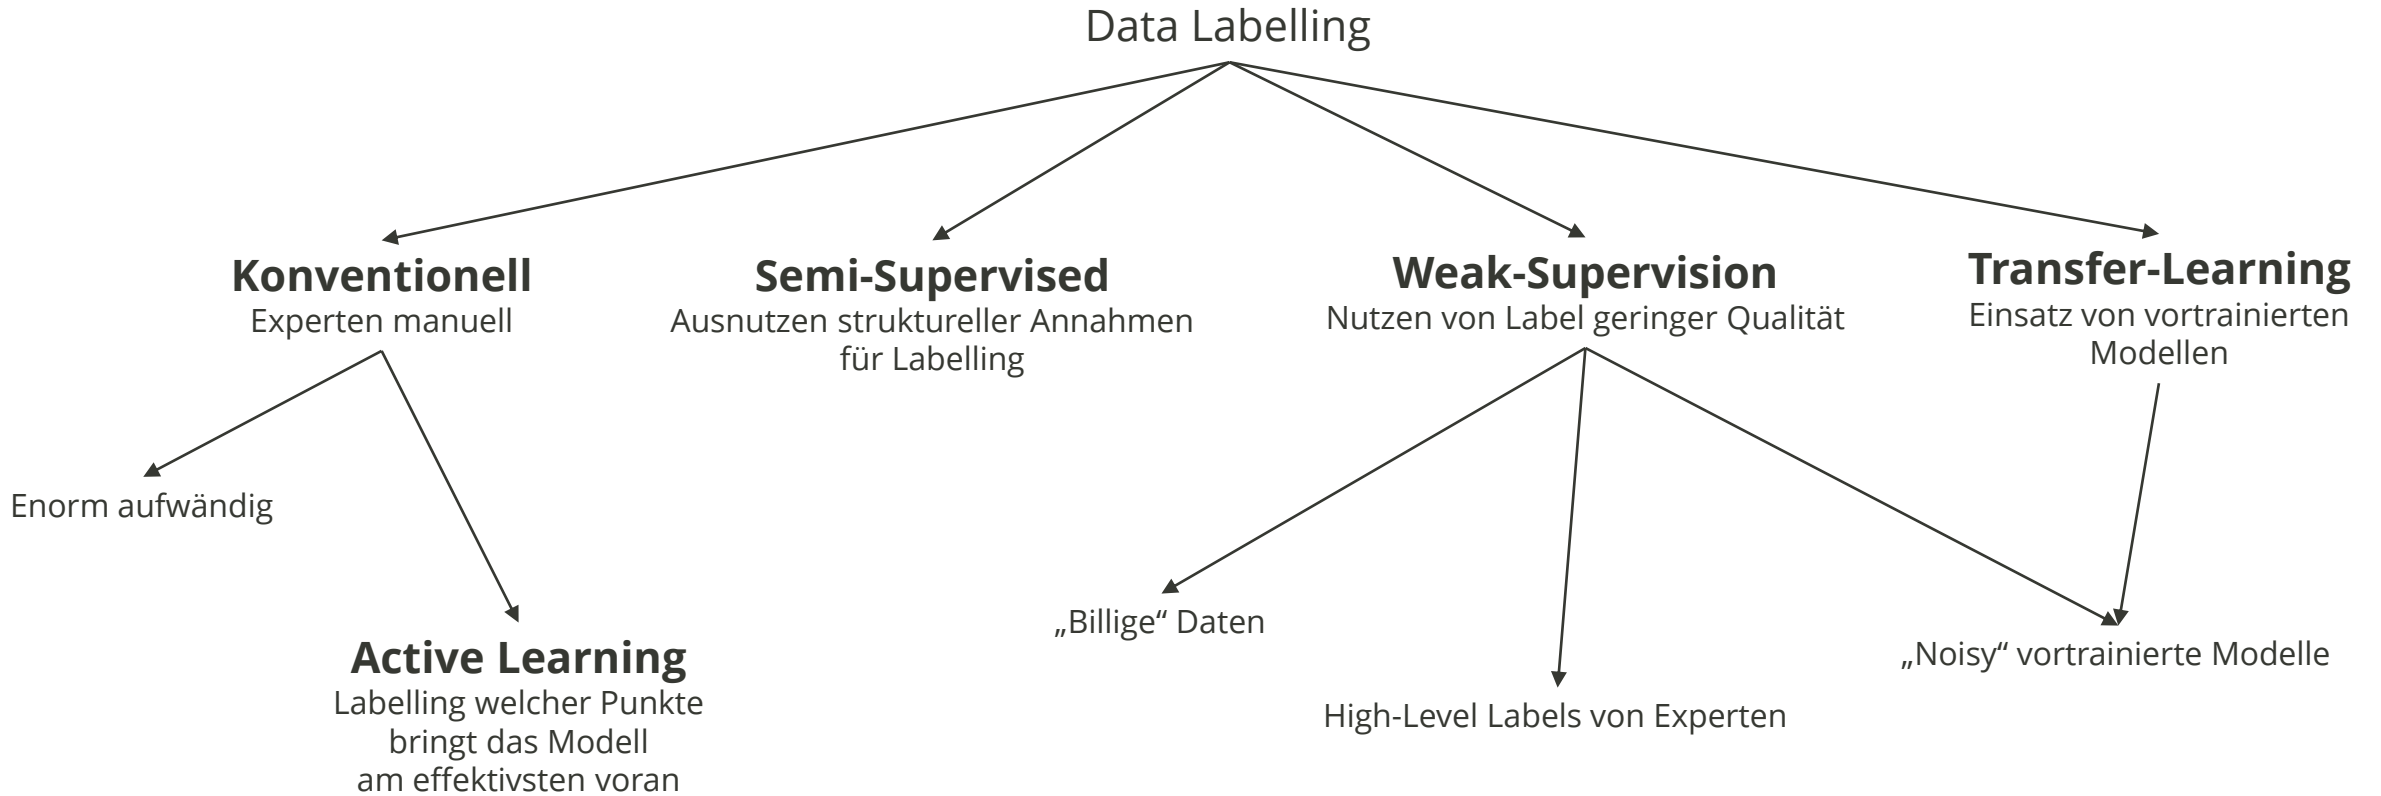


Bild: <https://towardsdatascience.com/supervised-vs-unsupervised-learning-14f68e32ea8d>

# Ansätze für Labelling



<http://ai.stanford.edu/blog/weak-supervision/>

# Semi-supervised learning

Motivation:


- Gewinnung von ungelabelten Daten ist mehrfach einfacher
- Labelling ist aufwändig

Grundidee:

- Nicht annotierte Daten liefern weitere nützliche Information für das Trainieren des Modells

Annahmen:

- **Glattheit:** wenn  $x_1$  und  $x_2$  nahe stehen, dann  $y_1$  und  $y_2$  sollen auch
- Entscheidungsgrenze liegt in der Region mit geringer Dichte
- Manifold-Annahme



J. E. van Engelen and H. H. Hoos, "A survey on semi-supervised learning," *Mach. Learn.*, vol. 109, no. 2, pp. 373–440, 2020, doi: 10.1007/s10994-019-05855-6.

# Schritt 5: Feature engineering

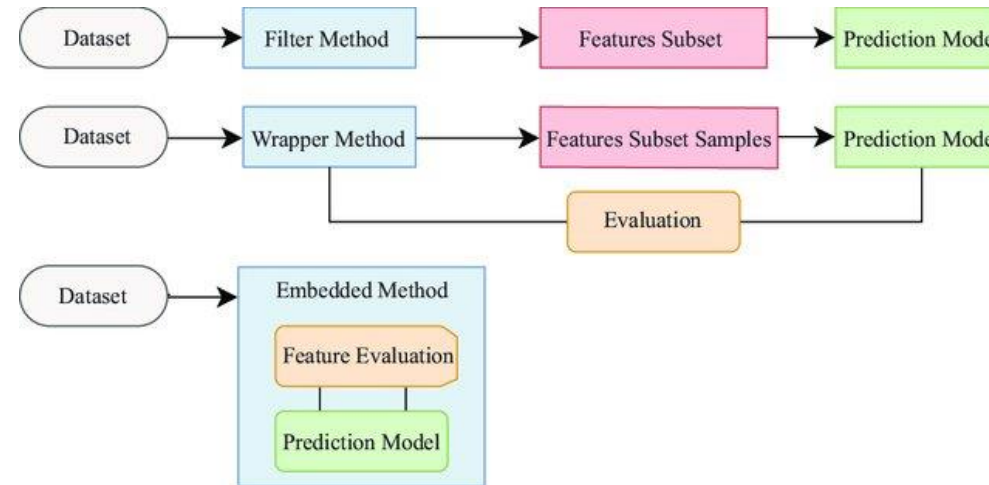
# Feature Engineering

Feature-Engineering ist ein Schritt im Rahmen der Vorbereitung eines Trainingsdatensatzes aus Rohdaten, in dem Eingangsvariablen **extrahiert**, **ausgewählt** und **transformiert** werden.

Mehrwert von effektiv ausgewählten Features – effektiveres Modell:

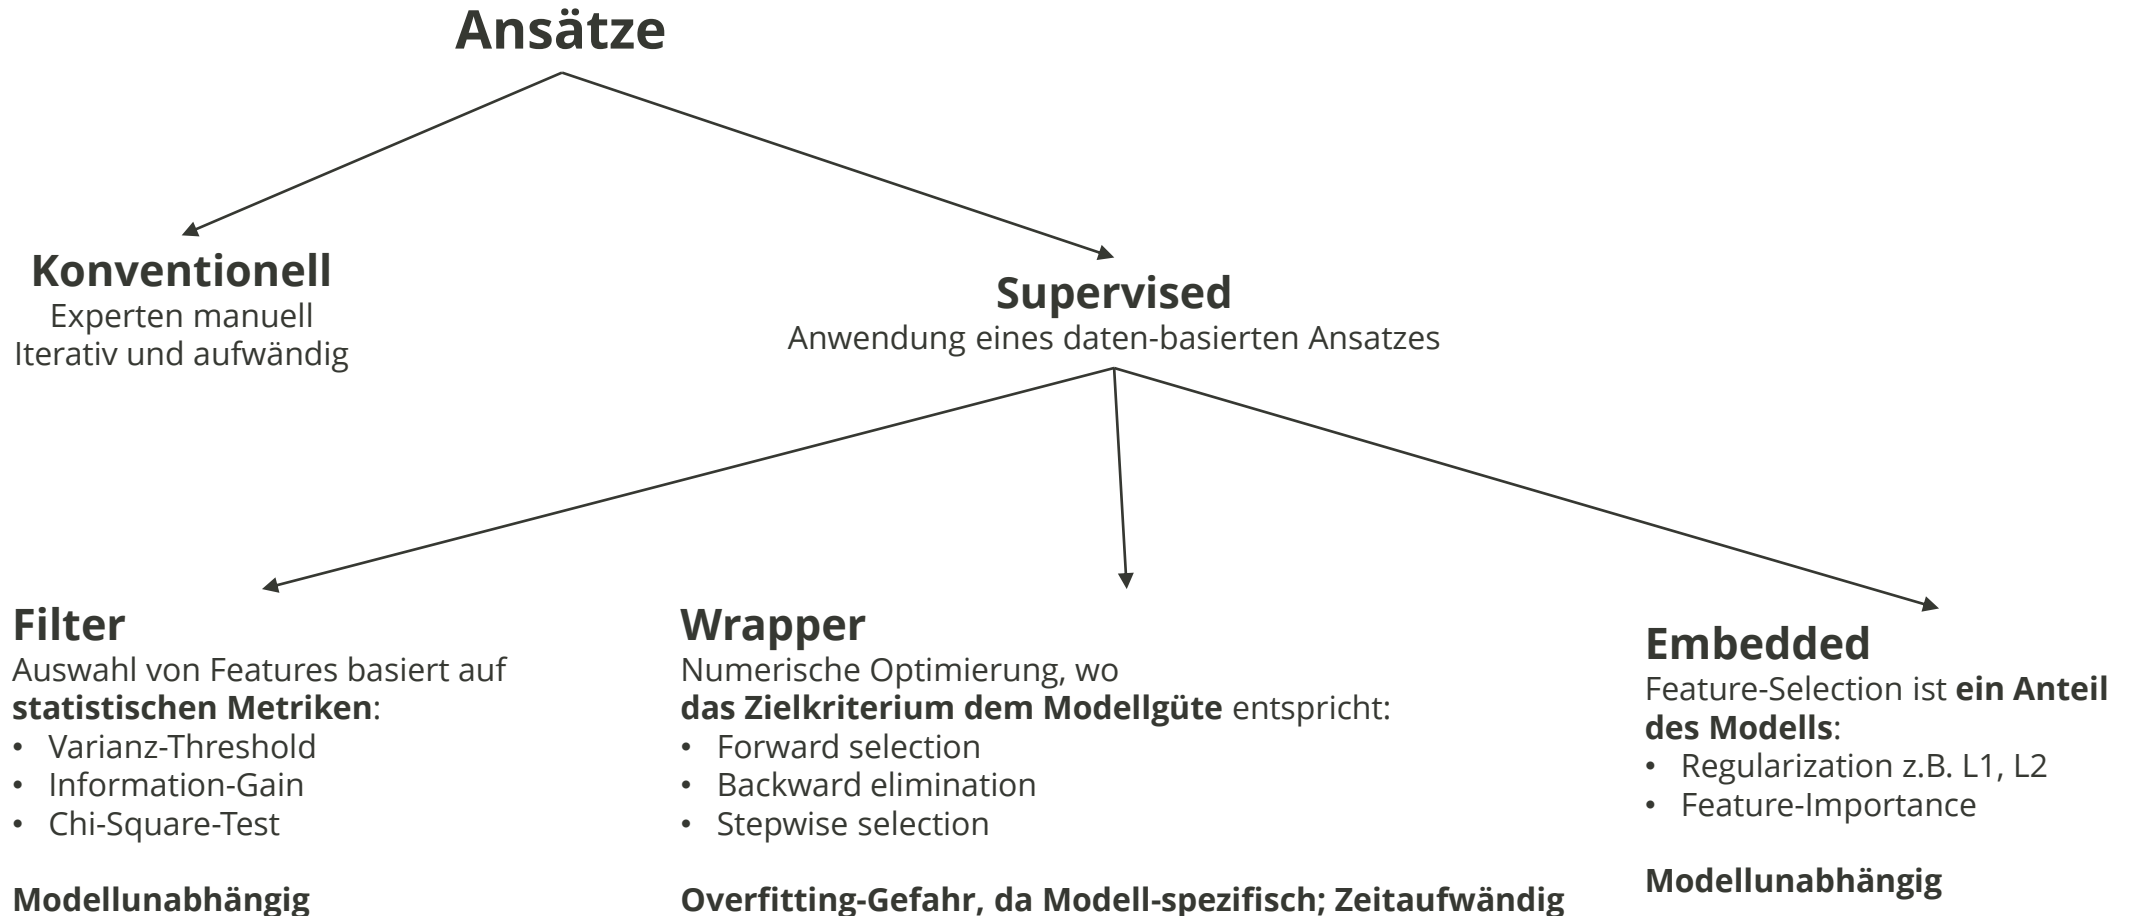
- Geringe Modellkomplexität
- Höhere Generalisierbarkeit und Reduzierung des Overfitting-Effekts
- Bessere Interpretierbarkeit
- Schnelles Modelltraining

# Feature Selection



M. BABIKER, E. KARAARSLAN, and Y. HOŞCAN, "A hybrid feature-selection approach for finding the digital evidence of webapplication attacks," *TURKISH J. Electr. Eng. Comput. Sci.*, vol. 27, no. 6, pp. 4102–4117, Nov. 2019, doi: 10.3906/elk-1812-18.

# Feature Selection



<http://ai.stanford.edu/blog/weak-supervision/>

# Feature Transformation und Skalierung

Feature Transformation - zielgerichtete Wandlung von Daten ohne Verlust von Information.

Mögliche Ansätze: Logarithmieren, Multiplikation von Inputvariablen und Darstellung als einzelnes Feature, Differenzieren, Wechsel des Koordinatensystems

Skalierung: MinMax, Standard-Scaler, MaxAbsScaler, Robust-Scaler, L1-, und L2-Normalizer

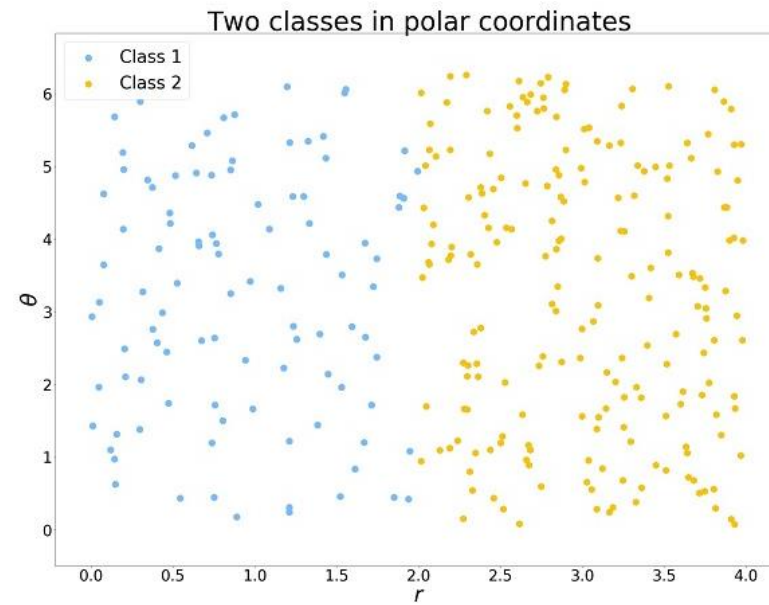
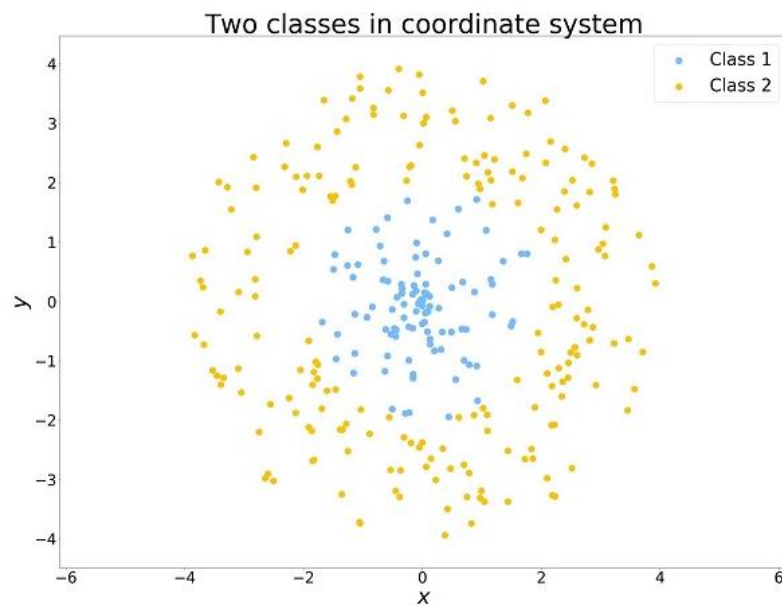


Bild: <https://www.kdnuggets.com/2018/12/feature-engineering-explained.html>

# Schritt 6: Model training

# Allgemeine Aspekte

**Modell-Training** ist das Lösen eines Optimierungsproblems zur Findung eines optimalen Sets von Modellparametern. Die Zielfunktion hängt dabei von dem Problemtyp ab.

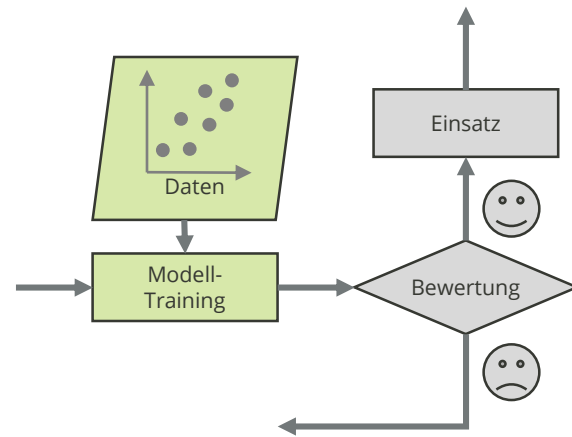
- Numerisch und iterativ (**Abstiegsverfahren** – sehr verbreitet)
- Zielfunktion ist Aufgabe- und Modelltypabhängig
- In der Regel Findung eines lokalen Optimums ausreichend

Frameworks:

- Scikit-Learn – Vielfalt an Modellen (Regression, Tree-based), aber nicht für DeepNN
- Tensorflow mit Keras – Fokus auf Modelle mit Schichte (kNN, CNN usw.)
- PyTorch (wenig populäre Alternative von Facebook)
- Matlab

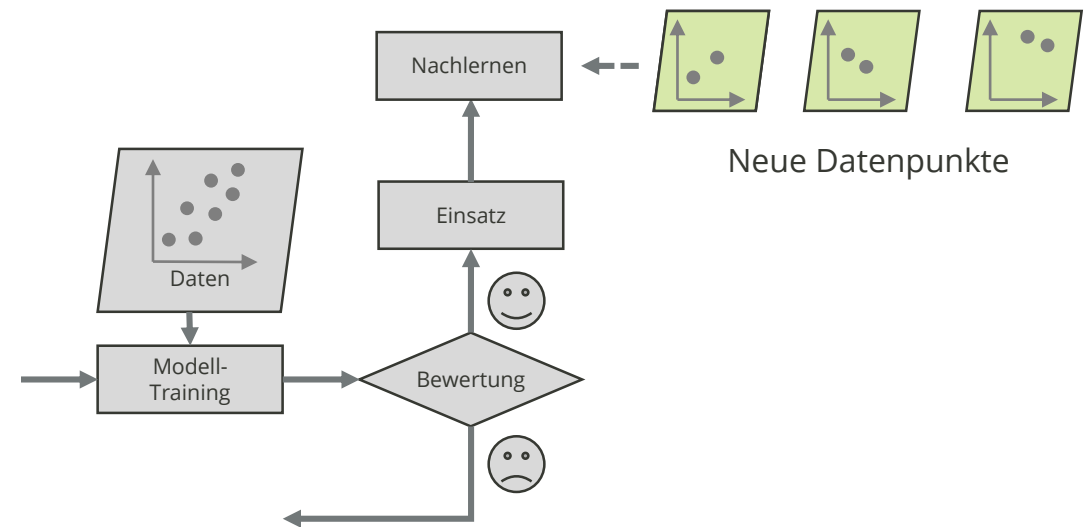
# Arten von Modelltraining

## Batch-Learning



Für initiales Training

## Online-Learning



Für echtzeitige Aktualisierung des Modells im Betrieb

Adaptiert aus A. Géron, Hands-on Machine Learning with Scikit-Learn, Keras, and TensorFlow. O'Reilly Media, 2019.

# Model Training

Abstiegsverfahren ist die Basis.

Das Modelltraining erfolgt iterativ, wobei Modellparameter durch das Lernen von Daten schrittweise in **Batches** aktualisiert werden.

Epoch enthält alle Datenpunkte des Datensatzes aber nur **einmal**.


Zwischen Epochen sollen Batches neu zufällig erstellt.

Batches:

- **Kompletter Datensatz** (= Epoch) – Gradient-Descent
- **Ein** zufällig ausgewählter Punkt – Stochastic GD
- **Mehrere** zufällig ausgewählte Punkte – Mini-batch GD

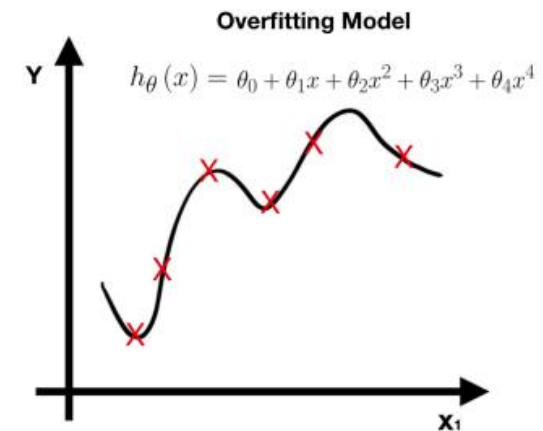
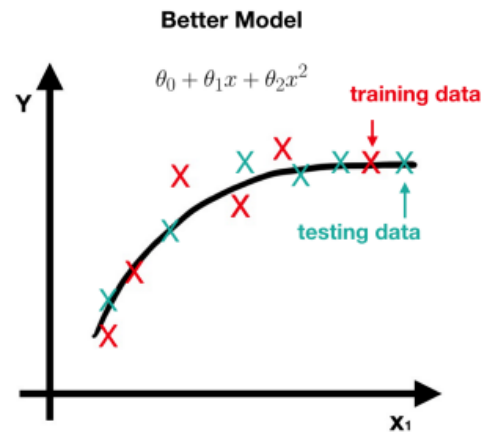
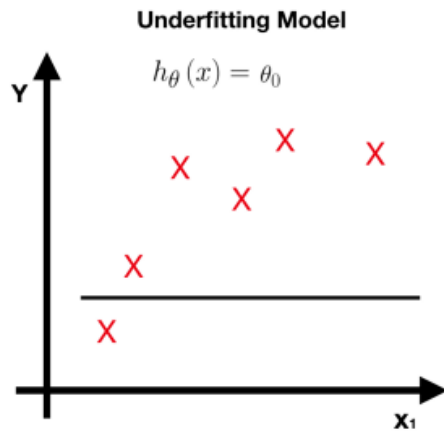


Training											
Epoch 1				Epoch 2				Epoch 3			
B1	B2	B3	B4	B1	B2	B3	B4	B1	B2	B3	B4

B1: Punkte 1, 4, 7, 11	B1: Punkte 1, 5, 12, 15	B1: Punkte ....
B2: Punkte 2, 5, 10, 14	B2: Punkte 2, 4, 10, 14	B2: Punkte ....
B3: Punkte 6, 9, 12, 16	B3: Punkte 3, 7, 13, 16	B3: Punkte ....
B4: Punkte 3, 8, 13, 15	B4: Punkte 6, 8, 9, 11	B4: Punkte ....



A. Géron, Hands-on Machine Learning with Scikit-Learn, Keras, and TensorFlow. O'Reilly Media, 2019.


# Bias, Variance und Overfitting



[https://de.wikipedia.org/wiki/Verzerrung-Varianz-Dilemma#/media/Datei:Bias\\_and\\_variance\\_contributing\\_to\\_total\\_error.svg](https://de.wikipedia.org/wiki/Verzerrung-Varianz-Dilemma#/media/Datei:Bias_and_variance_contributing_to_total_error.svg)

<https://medium.com/@qempil0914/courseras-machine-learning-notes-week3-overfitting-and-regularization-partii-3e3f3f36a287>

# Regularization



**Regularization** ist ein Ansatz zur künstlichen Einschränkung von wenig relevanten Modellelementen (z.B. Input-Features oder Neuronen), z.B. L2-Regularization

$$J(\theta) = \frac{1}{2m} \sum_{i=1}^m (h_{\theta}(x^{(i)}) - y^{(i)})^2 + \underbrace{\lambda \sum_{j=1}^n \theta_j^2}_{\text{Regularization Term}}$$

↑ Regularization Parameter      ← start at  $\theta_1$

Bilder: <https://medium.com/@qempil0914/courseras-machine-learning-notes-week3-overfitting-and-regularization-partii-3e3f3f36a287>

# Optimierung von Hyperparametern

Nachdem der Typ bzw. die Architektur des Modells definiert wurde, sollen **Modell- und Trainingsparameter** optimiert (andere Ebene der Optimierung als beim Modell-Training) werden.

Exemplarische Parameter:

- Ordnung des Regressors
- Art des Kernels im SVM
- Anzahl von Schichten und Neuronen in NN
- Beiwerte und Art der Regularisierung
- Learning-Rate des Abstiegsverfahrens

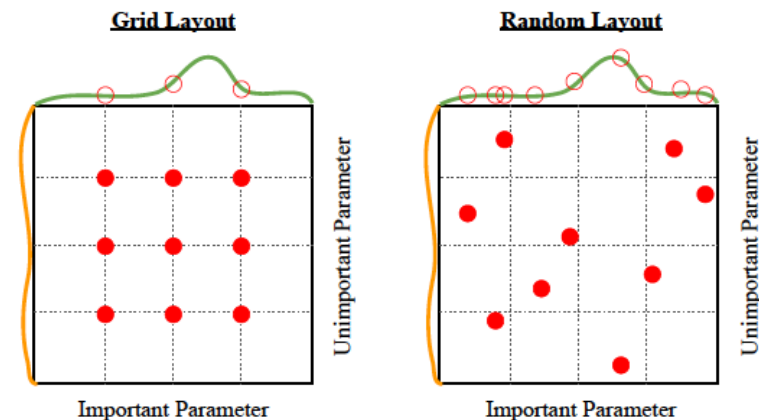
Direkte Verfahrens (Parallelisierung):

- **Grid search**

Alle mögliche Kombinationen von Parametern werden evaluiert

- **Random-Search**

Zufällig ausgewählte Kombination von Parametern



Iterative: **Bayesian, Gradient descent** usw.

Bild: [https://srdas.github.io/DLBook/DL\\_images/HPO1.png](https://srdas.github.io/DLBook/DL_images/HPO1.png)

# Schritt 7: Model evaluation

# Model testing

Modelltests dienen der Bewertung der Modellgüte hinsichtlich der Qualitätsmetriken (**nicht unbedingt dasselbe wie die Zielfunktion**).

Qualitätsmetriken – Problemtypabhängig:

- Regression: MSE, MAE
- Klassifikation: Accuracy, Confusion-Matrix, ROC, AUC

## Datenaufteilung:

- Training (70-80%) – Optimierung des Modells
- Validation (15-20%) – **unabhängige Bewertung** der Hyperparameteroptimierung
- Test (15%) – **unabhängige Bewertung** des resultierenden Modells (inkl. Hyperparameter-Tuning)

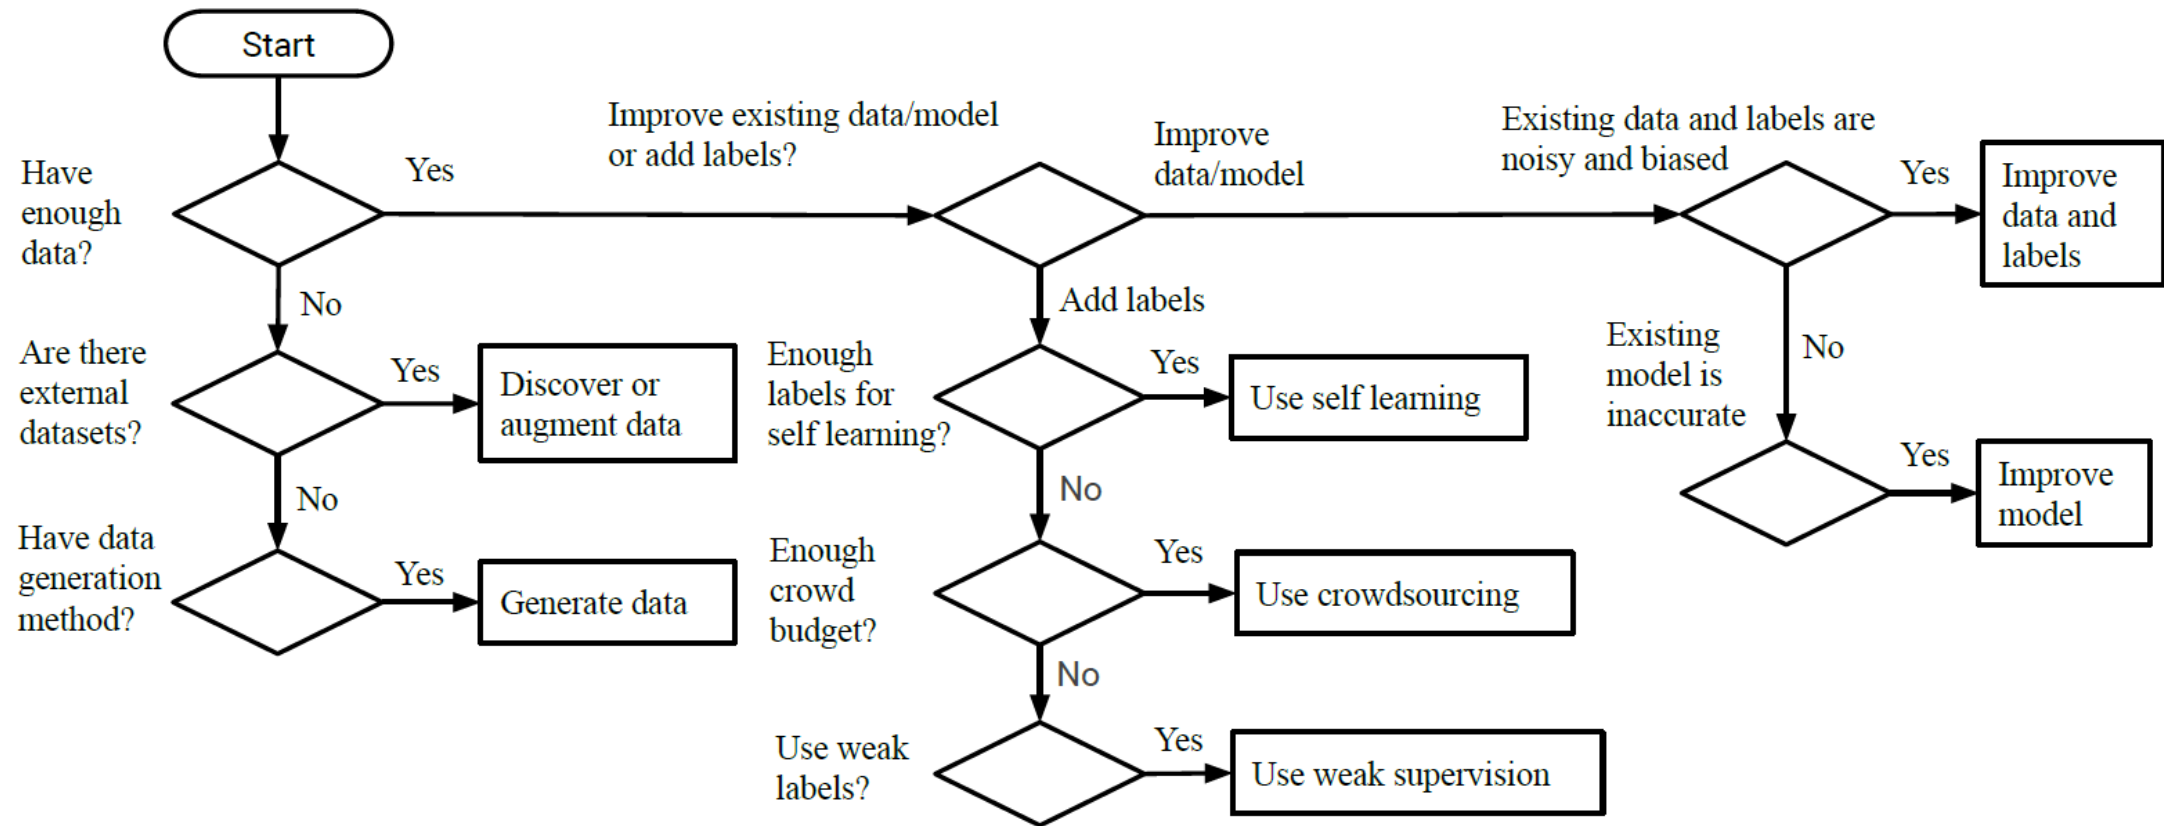


## k-fold Cross Validation:

- Aufteilung des Datensatzes auf k Anteile, die für Evaluation des Modells verwendet werden

Vorteil: kein separater Validerungsdatensatz erforderlich

# Allgemeiner Workflow




Y. Roh, G. Heo, and S. E. Whang, "A Survey on Data Collection for Machine Learning: A Big Data - AI Integration Perspective," *IEEE Trans. Knowl. Data Eng.*, pp. 1-1, 2019, doi: 10.1109/TKDE.2019.2946162.

# Datenzentrierte Paradigma in ML


## Modellzentrierter Ansatz

- Extensive Datengewinnung (je größer der Datensatz desto besser)
- Iterative Optimierung des Modells für bessere Performance steht im Fokus
- Datensatz wird als eine vorgegebene und unveränderbare Komponente betrachtet



## Datenzentrierter Ansatz

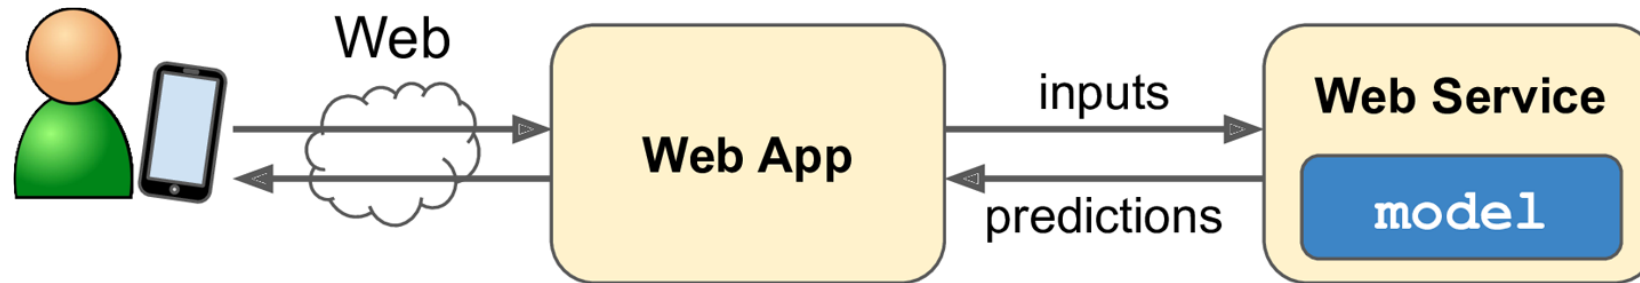
- Intensive Datengewinnung (Qualität statt Quantität)
- Datenkonsistenz und iterative Verbesserung der Datenqualität steht im Fokus
- Sobald gelungen, performen alle Modelle besser



Adaptiert von Andrew NG (2021), Link: <https://youtu.be/06-AZXmwHjo>

# Schritte 8 und 9: Model deployment und monitoring

# Model deployment



Technologien:

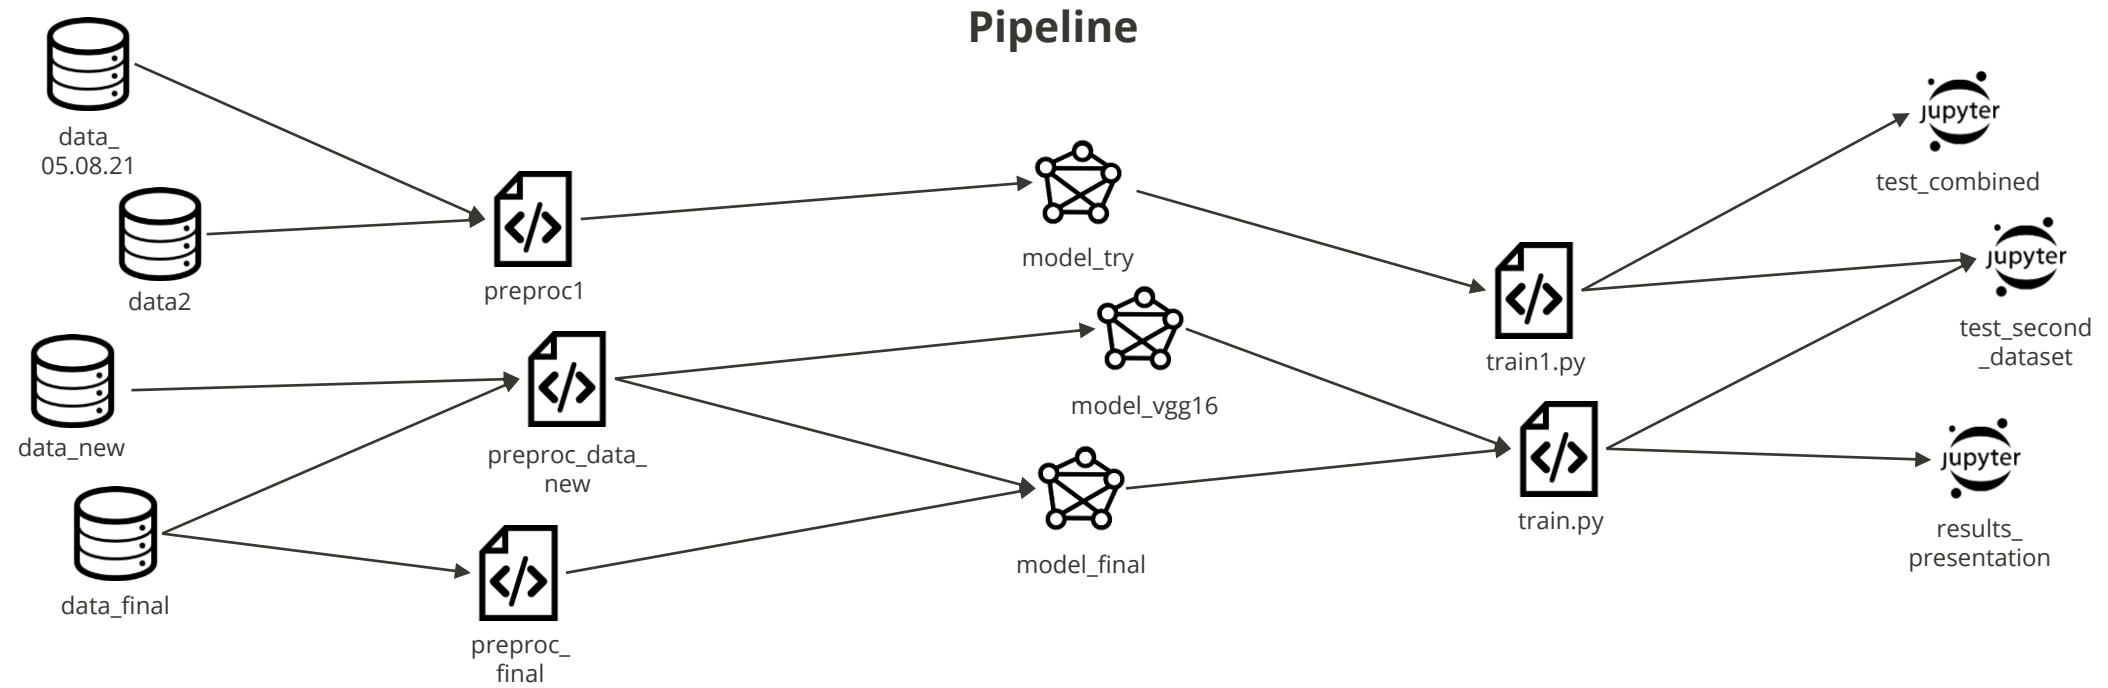
- RestAPI, GraphQL, MQTT
- OPC UA

Frameworks:

- Custom-Webserver mit Matlab, Python Flask oder Easy API
- Tensorflow Serving

# MLOPs

# ML Experiments



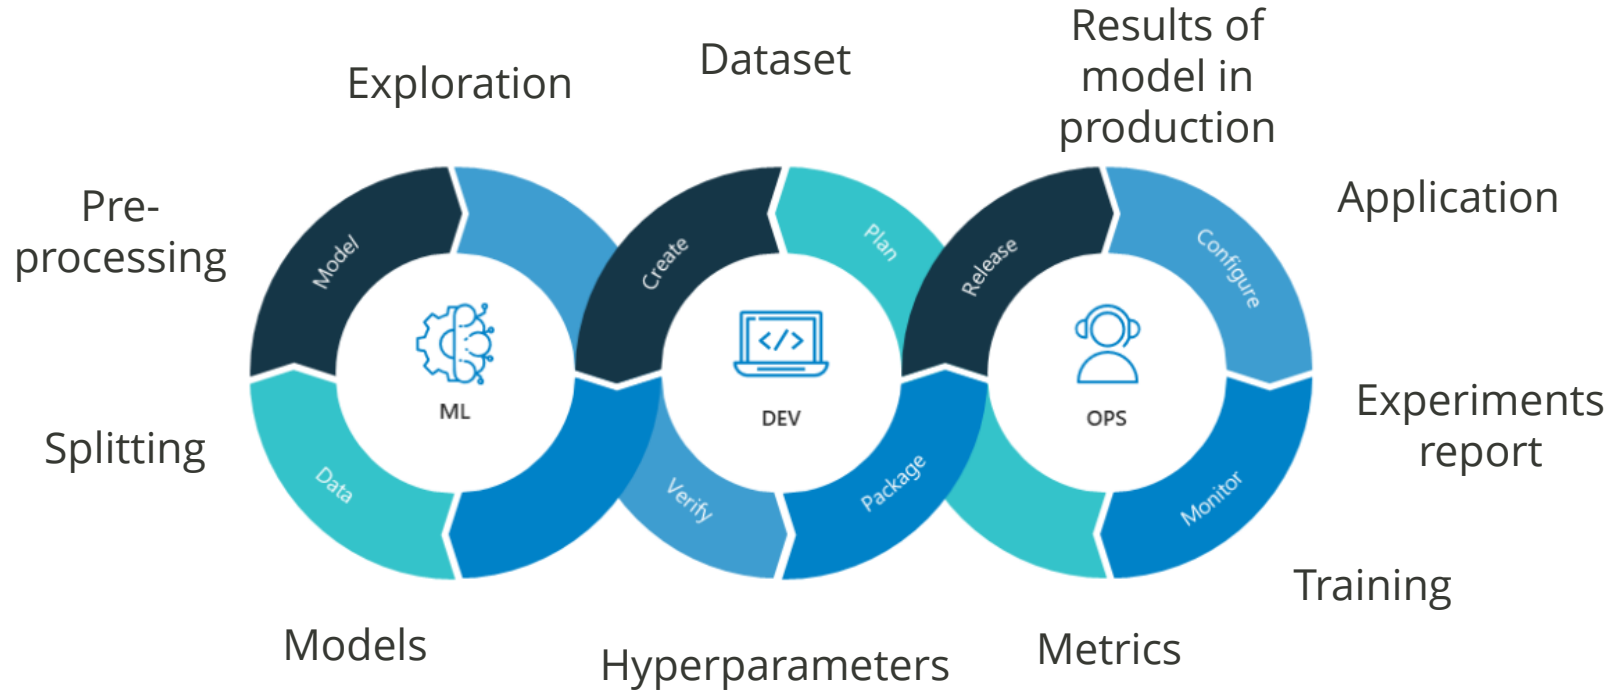
Versionierung



Überischt



# MLOps



**Automation**

**Continuous X**

**Versioning**

**Experiments tracking**


**Testing**

**Monitoring**

<https://blogs.nvidia.com/blog/2020/09/03/what-is-mlops/>

<https://ml-ops.org/content/mlops-principles>

# Zusammenfassung



# kaggle



**PROCESS CONTROL SYSTEMS** **PROCESS SYSTEMS ENGINEERING**

Dr. rer. nat. Valentin Khaydarov  
Email: [valentin.khaydarov@tu-dresden.de](mailto:valentin.khaydarov@tu-dresden.de)  
Telefon: 0351 463 33387

**Vielen Dank für Ihre Aufmerksamkeit!**