FH JOANNEUM
University of Applied Sciences

Von Daten zu Prognosen
Machine Learning mit Python

Maierbrugger, Raab

EINFÜHRUNG IN ML

FH JOANNEUM
University of Applied Sciences

Arten von Machine Learning

Supervised Learning

„Lernen mit Lehrer”

Zielgröße vorhersagen,

Regression oder Klassifikation

Unsupervised Learning

„Lernen ohne Lehrer”

Strukturen in Daten finden,

Clustering, Ausreißer erkennen

Reinforcement Learning

„Verstärkendes Lernen”

Agent lernt eine Strategie

Robotik, Spiele

Supervised Learning

- Ausgangslage: Daten mit beschreibenden Variablen („Features") x_i und bekannten Werten für die Zielgröße y („Labels")

Id	Position	Experience	Skill	Country	City	Salary (USD)
1	Developer	0	1	USA	New York	103100
2	Data Scientist	3	1	USA	Washington	146800
3	Accountant	8	1	USA	Los Angeles	124200
4	…					

- Ziel: auch für neue Datenpunkte eine Vorhersage für y treffen können

Id	Position	Experience	Skill	Country	City	Salary (USD)
173	Accountant	1	0	USA	Washington	???

Supervised Learning - Grundaufgaben

Klassifikation

- Vorhersage der zugehörigkeit zu einer Klasse
- oft: binäre Klassifikation (ja/nein, 0/1)
- Beispiel: Binäres Bildklassifikations-Problem „Muffin vs. Chihuahua”

https://www.kaggle.com/datasets/samuelcortinhas/muffin-vs-chihuahua-image-classification

Regression

- Vorhersage einer (praktisch) kontinuierlichen Größe
- Beispiel: Hauspreise vorhersagen anhand von Features wie Quadratmeter, Anzahl der Zimmer, Baujahr, Entfernung zur nächsten Stadt

https://www.kaggle.com/datasets/muhamedumarjamil/house-price-prediction-dataset

Unsupervised Learning

- Ausgangslage: Daten mit beschreibenden Variablen (Features) x_i, es liegen KEINE Werte einer Zielgröße vor
- Mögliche Ziele:
  - **Clustering**: Einteilung der Daten in Gruppen
  - **Dimensionsreduktion**: Darstellung vereinfachen, ursprüngliche Daten zu wenigen wichtigen reduzieren

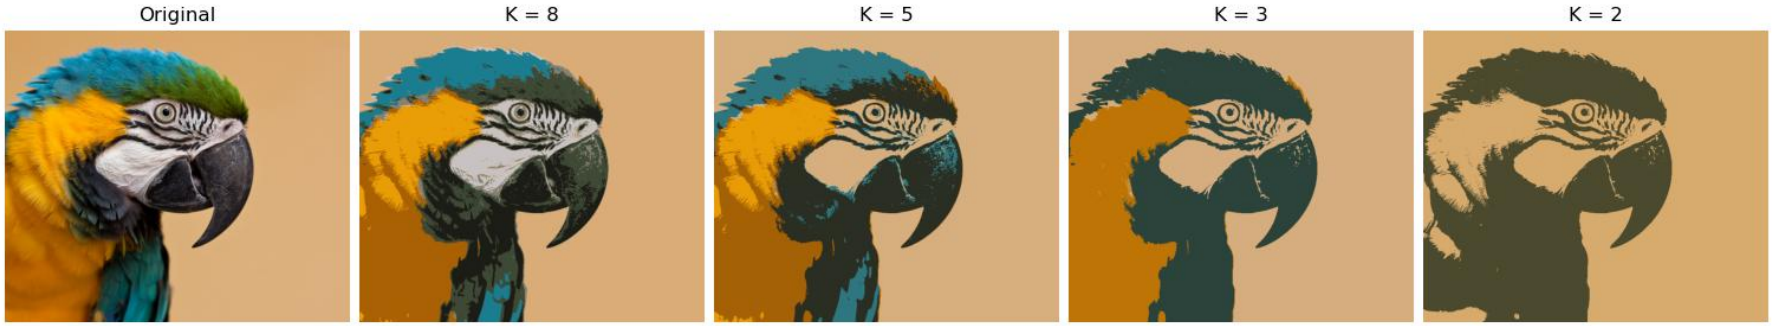

Reinforcement Learning

- Verstärkendes Lernen
  - Ein Agent kann in einer (simulierten) Umgebung („state“) Aktionen setzen
  - Agent bekommt einen „reward“ (positiv oder negativ)
  - Umgebung verändert sich
- Ziel des Agenten: rewards **langfristig** maximieren
- Aktuell: Deep Reinforcement Learning (DRL), mit Neuronalen Netzen

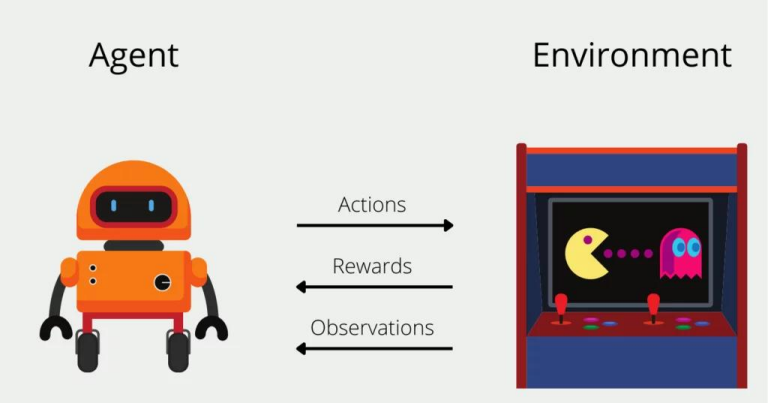

Image Source: https://databasecamp.de/en/ml/reinforcement-learnings

Modellierung

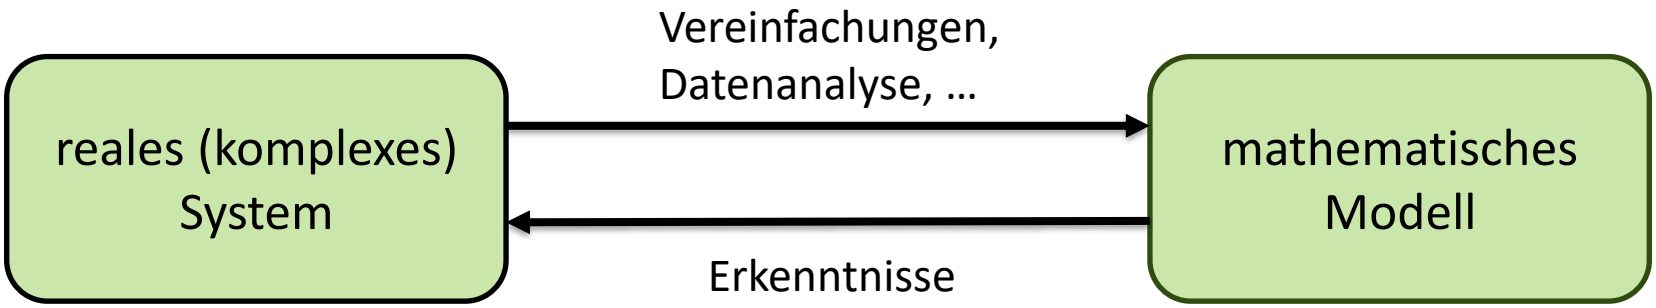

- Ist meist als Optimierungsaufgabe formuliert
- Ziel im Supervised Learning: Vorhersagefehler minimieren
  - dafür benötigt man sinnvoll definierte **Metriken**!
- Modellparameter
  - Werden aus den Daten ermittelt (Allgemeine Info aus den Daten)
- Hyperparameter
  - Nehmen Einfluss auf den Trainingsprozess, nicht im Modell sichtbar

Metriken für Regression

Situation: wir haben N labels y_i und N Modellvorhersagen $\hat{y}_i$

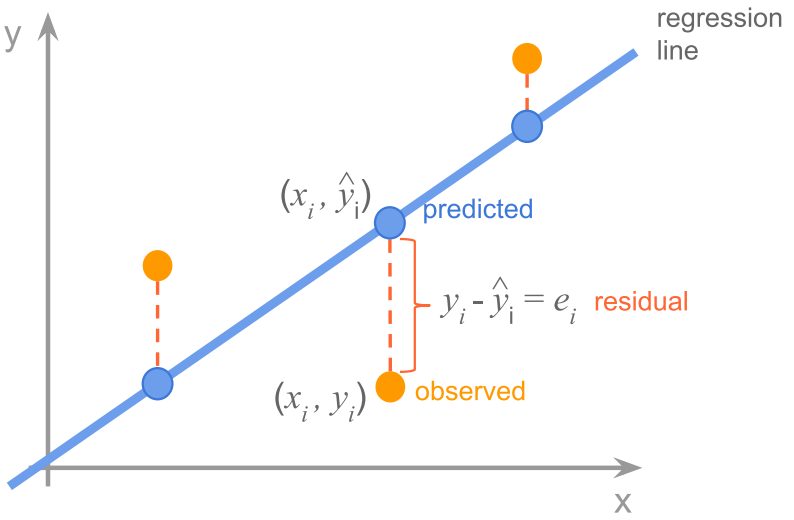

- **Mean Absolute Error (MAE)**
  - $MAE = \frac{1}{N} \cdot \sum_{i=1}^{N} |y_i - \hat{y}_i|$
- **Mean Squared Error (MSE)**
  - $MSE = \frac{1}{N} \cdot \sum_{i=1}^{N} (y_i - \hat{y}_i)^2$
  - "Bestraft" große Abweichungen stärker als MAE
- **Root Mean Squared Error (RMSE)**
  - $RMSE = \sqrt{\frac{1}{N} \cdot \sum_{i=1}^{N} (y_i - \hat{y}_i)^2}$
  - Gleiche Einheit wie die response Variable y

Metriken für Klassifikation

- Situation: Wir haben ein binäres Klassifikationsproblem
- Beispiel: Bewerber – Variable “Hired“ (Positive / Negative)
- Das Modell Klassifiziert jede Variable als *Positive* oder *Negative*
- Das Ergebnis der Vorhersage wird in einer **Confusion Matrix** dargestellt

		Predicted class: Positive	Predicted class: Negative
Actual class	Positive	TP	FN
	Negative	FP	TN

Metriken für Klassifikation

Die folgenden Metriken werden aus der Confusion Matrix abgeleitet.

Alle 4 Metriken nehmen Werte zwischen **0 (schlechtestes)** und **1 (bestes)** an.

Accuracy = $\frac{TP+TN}{TP+TN+FP+FN}$	Relative Häufigkeit der korrekten Klassifikationen
Precision = $\frac{TP}{TP+FP}$	Welcher Anteil der Fälle, die als positiv klassifiziert werden, sind tatsächlich positiv? Wenn FP problematisch sind (z.B. Spam-Filter)
Recall = $\frac{TP}{TP+FN}$	Welcher Anteil der tatsächlich positiven Fälle wurde erkannt? Wenn FN problematisch sind (z.B. Krebsdiagnose)
F1-Score = $\frac{2 \cdot precision \cdot recall}{precision+recall}$	Harmonisches Mittel von Precision und Recall

Modellkomplexität

wichtige Aufgabe beim Modellieren: Modellkomplexität „richtig" wählen

- zu einfaches Modell → wichtige Eigenschaften werden nicht wiedergegeben (zu starker **„bias"**)
- zu komplexes Modell → zu starke Anpassung an die Trainingsdaten (**„variance"**), Modell kann nicht mehr generalisieren
- → Bias-Variance-Tradeoff

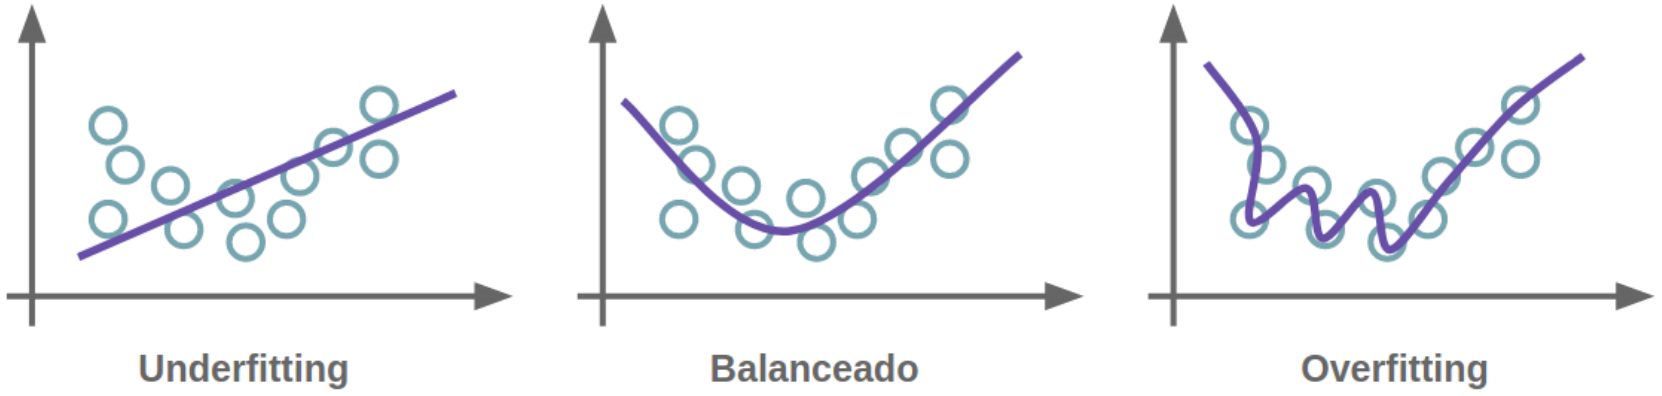

Image Source: https://commons.wikimedia.org/wiki/File:Underfitting_e_overfitting.png

Modellkomplexität

- Modelltraining → Optimierungsaufgabe → Suche nach Minimum des Fehlers
- Fehler auf Trainingsdaten vs. Fehler auf Testdaten
- Strategien zur Vermeidung:
  - Baseline Modell
  - Train-Test-Split
  - Kreuzvalidierung

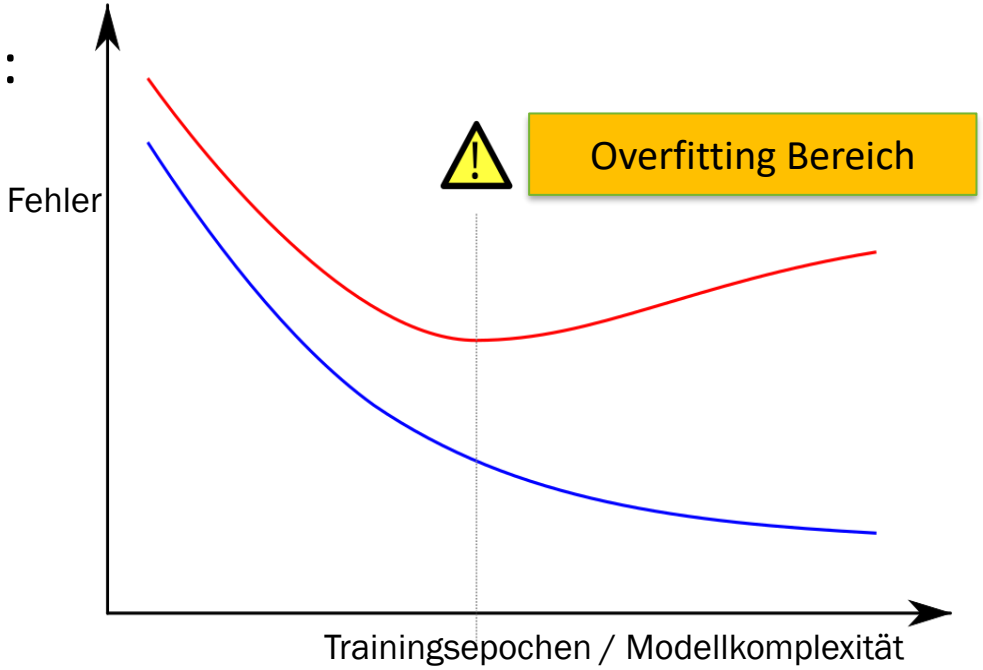

Kreuzvalidierung

SUPERVISED LEARNING METHODEN

Lineare Regression

- Einfache lineare Regression (ein Feature):
  - $\hat{y}_i = \alpha + \beta \cdot x_i$
  - α … intercept (Schnitt mit der y-Achse)
  - β … slope (Steigung)
- Multiple lineare Regression (mehrere Features):
  - $\hat{y}_i = \beta_0 + \beta_1 \cdot x_{i1} + \beta_2 \cdot x_{i2} + \ldots + \beta_p \cdot x_{ip}$
- Finden der Parameter:
  - Mithilfe der Least Squares Methode
  - S minimieren
  - Analytische Methode

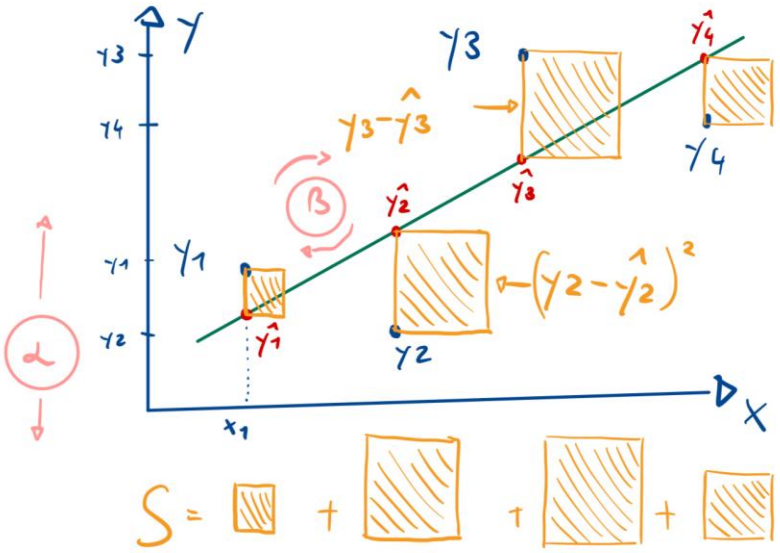

Decision Trees

- Für Klassifikation und Regression
- Kreiert wenn-dann Entscheidungen (binär)
- Splitted die Daten schrittweise auf (basierend auf Variablenwerten), wählt immer den Split, der die Variabilität in den folgenden Knoten minimiert
- Sehr gut interpretierbar
- Neigt zu Overfitting

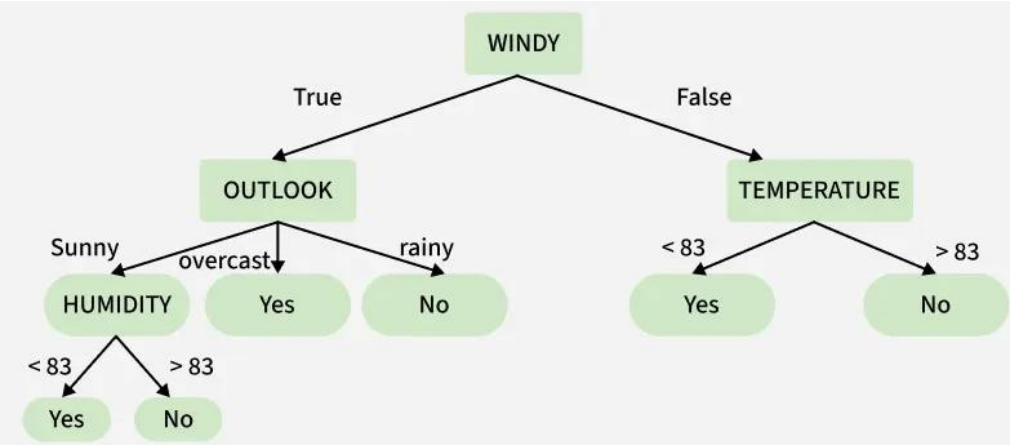

Img Source: https://www.geeksforgeeks.org/machine-learning/decision-tree-implementation-python/ (31/03/2026)

Random Forests

- Steigert die Vorhersagequalität und Robustheit gegenüber einzelner Decision Trees
- Man bildet zufällige Untermengen des Datensatzen, baut darauf einen DT
- Vorhersagen werden dann aggregiert (Mittelwert oder Mehrheitsvotum)
- Komplexere Beziehungen
- Weniger Overfitting
- Nicht leicht interpretierbar

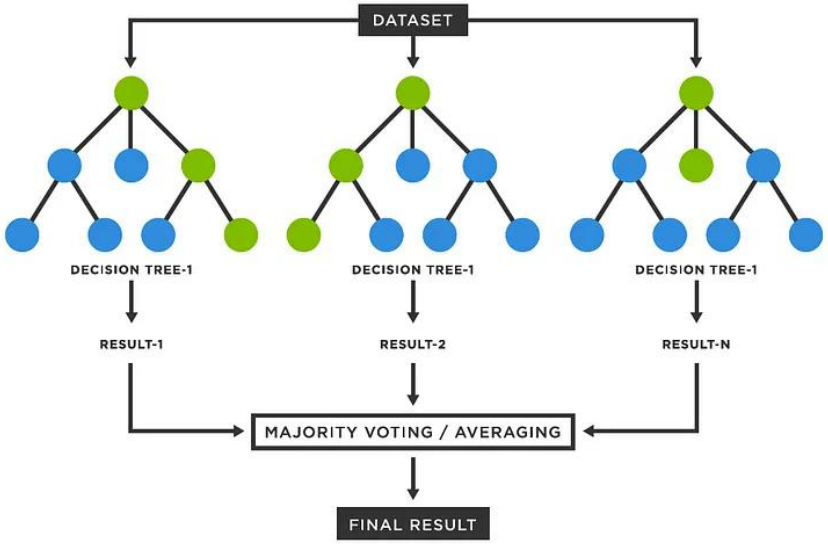

Img Source: https://www.displayr.com/what-is-a-decision-tree/ (11/12/2025)

Neuronale Netze

- Threshold Logic Unit (TLU) ist das einfachste Puzzleteil eines Artificial Neural Networks (ANN)
- Ein Perceptron ist ein Layer von TLUs
  - Fully connected
- Ein Multilayer Perceptron besteht aus
  - Input layer
  - Mehreren hidden layers
  - Output layer
- Viele hidden layers -> Deep Neural Network

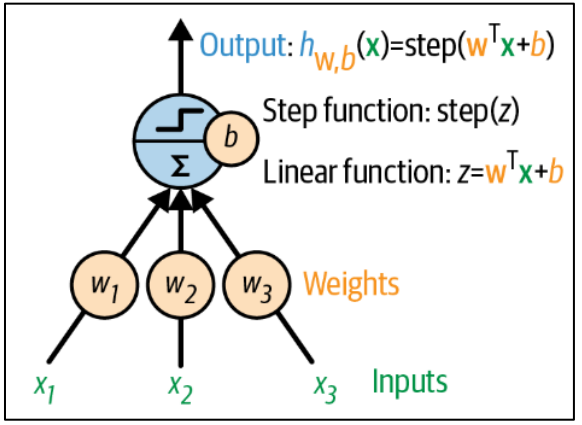

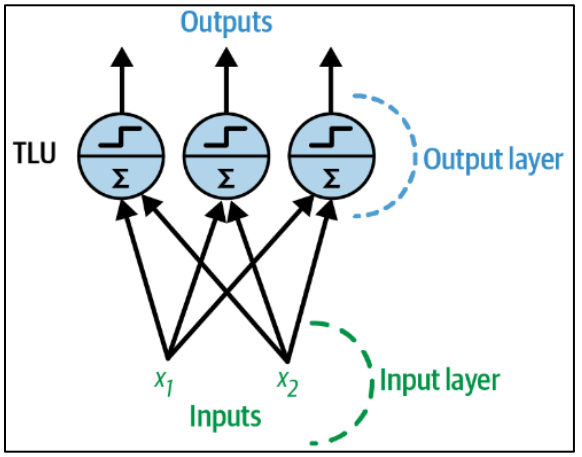

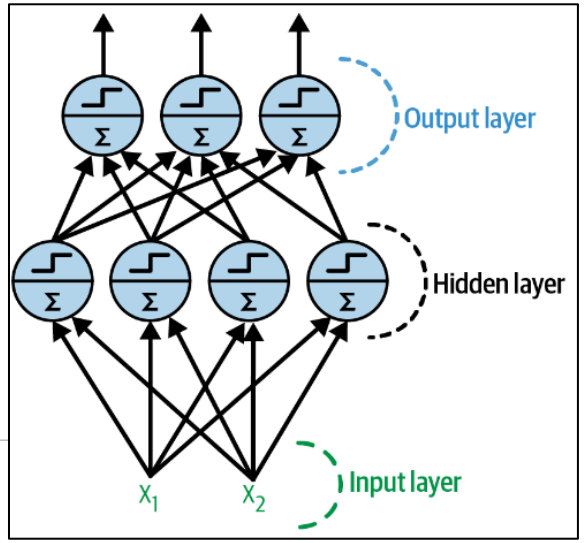

Neuronale Netze - Training

- 3 Trainingsschritte, die vielfach wiederholt werden
  1. Forward Pass
  2. Berechnung des Loss
  3. Backpropagation

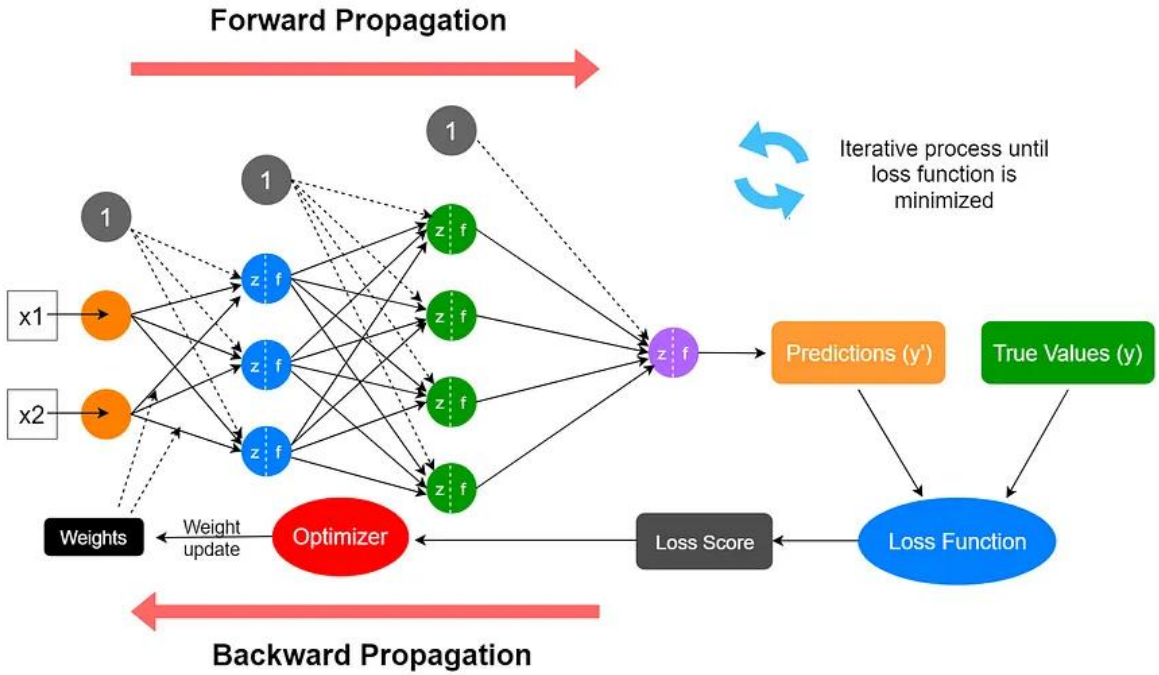

Neuronale Netze - Aktivierungsfunktionen

- **Activation functions:**
  - Bringen “non-linearity” in das Modell – sonst nur lineare Zusammenhänge abbildbar
  - Dadurch können NNs (fast) alles lernen

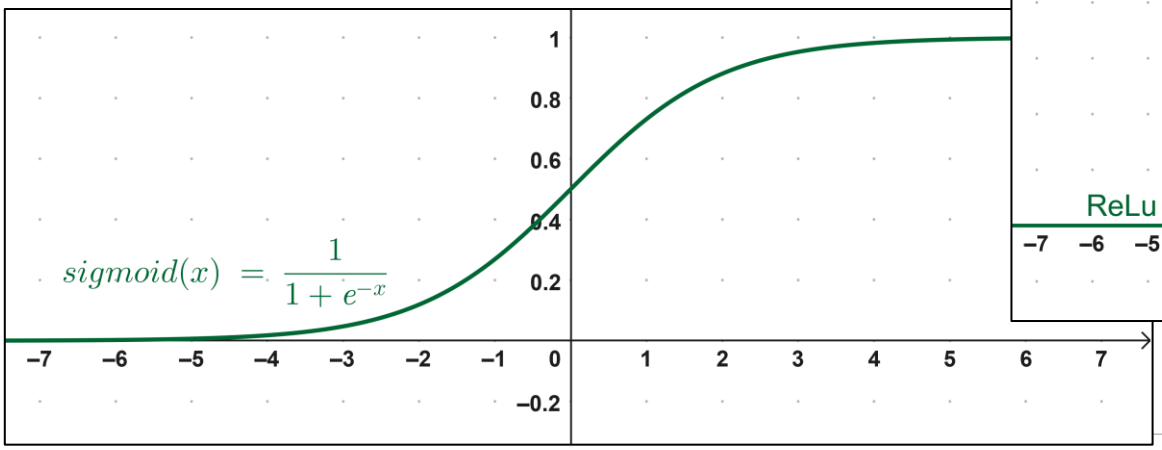

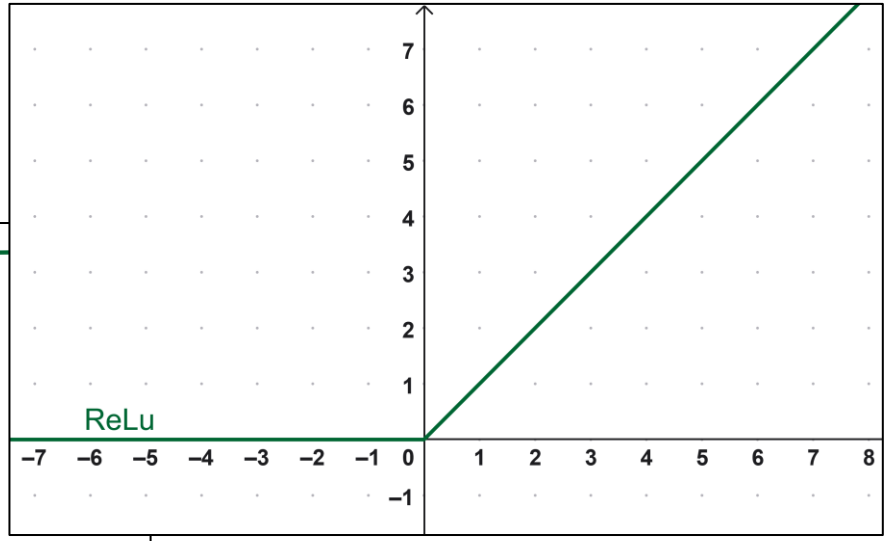

Convolutional Neural Networks (CNN)

- Klassische Aufgabe: Bildklassifizierung
- Wenn ein “normales” Neuronales Netz verwendet wird, muss das Bild dekonstruiert werden (flatten)
  - Wichtiger Kontext im Bild geht verloren
  - Bei großen Bildern sehr hohe Anzahl an input neuronen
- CNNs
  - Können lokale Strukturen oder Muster lernen
  - Verbindung zwischen benachbarten Elementen bleibt bestehen
  - Verwendet „partially connected layers“ um eine zu hohe Anzahl an Gewichten zu vermeiden

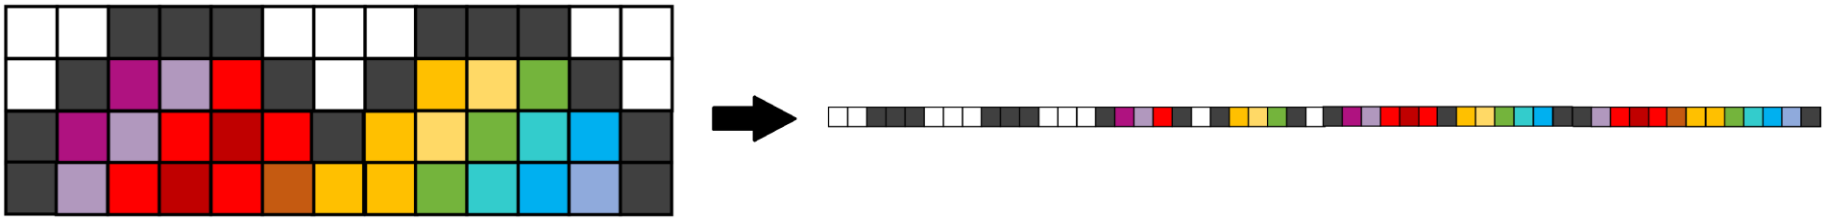

Convolutional Neural Networks (CNN)