

# DATA SCIENCE

## VORLESUNG 7 - INTRO

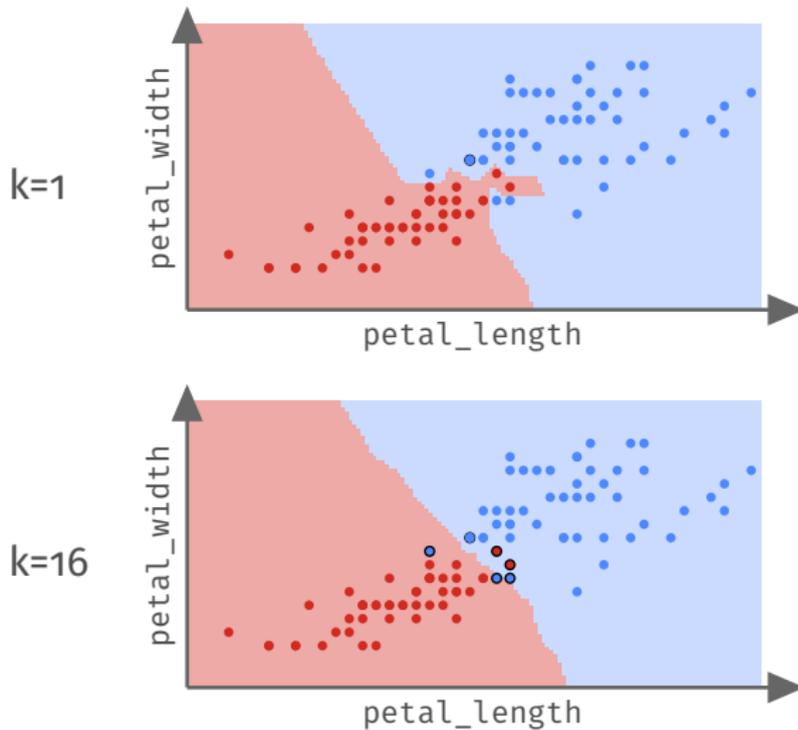
PROF. DR. CHRISTIAN BOCKERMANN

HOCHSCHULE BOCHUM

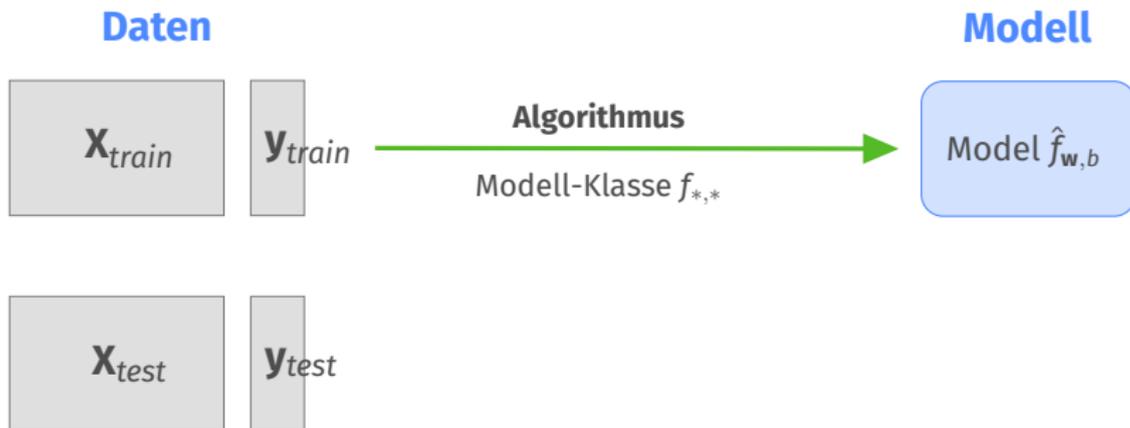
SOMMERSEMESTER 2021

## Was geschah zuletzt?

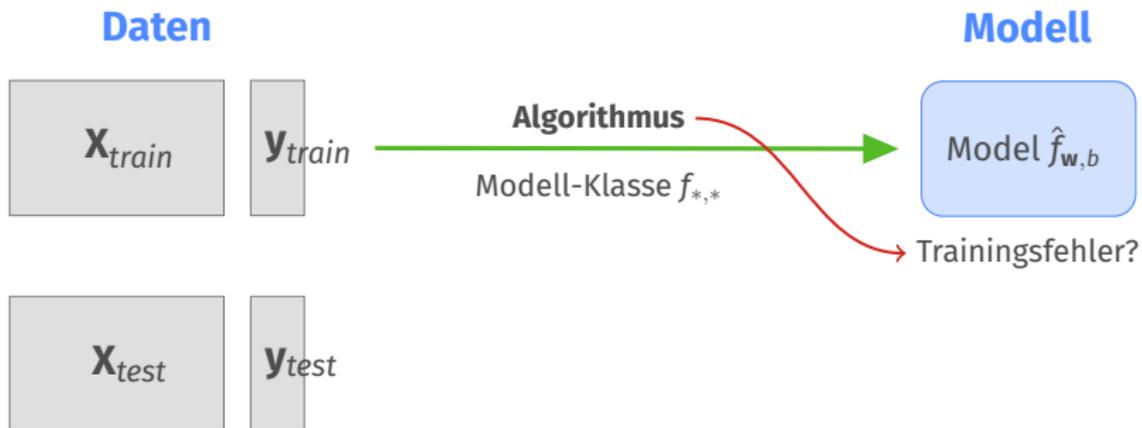
- Instanzbasiertes Lernen über Ähnlichkeit
- Distanz-Funktion auf Beispielen (eukl. Distanz)
- Normalisierung von Daten (Min/Max-, z-Normalisierung)
- $k$ -NN als Vorhersagemodell



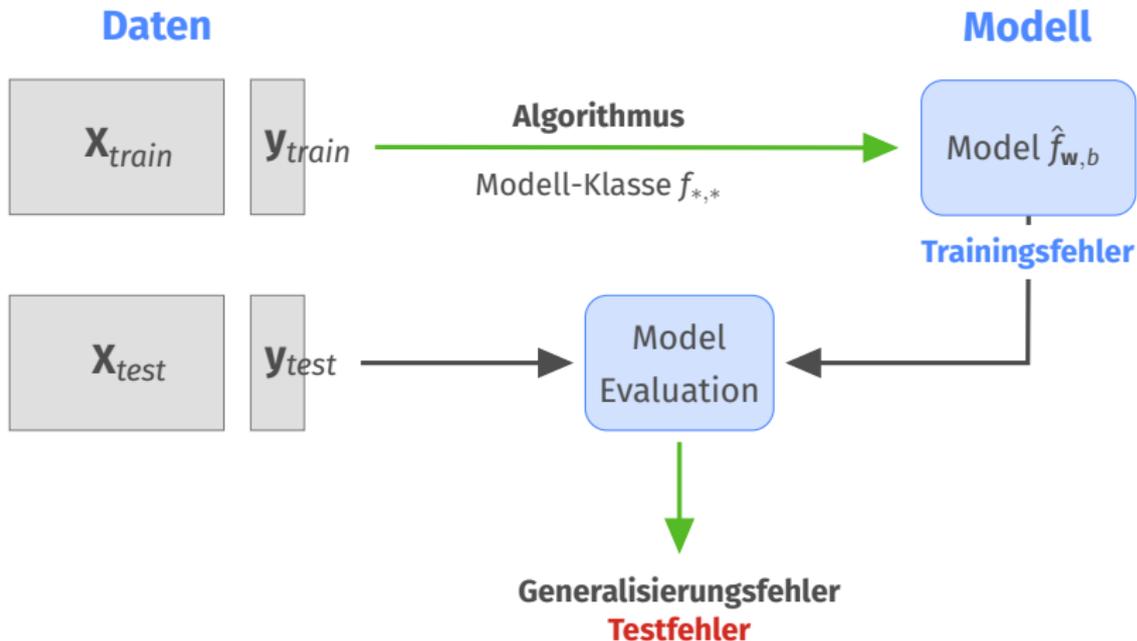
## Bewertung der Modell-Güte – Generalisierungsfehler



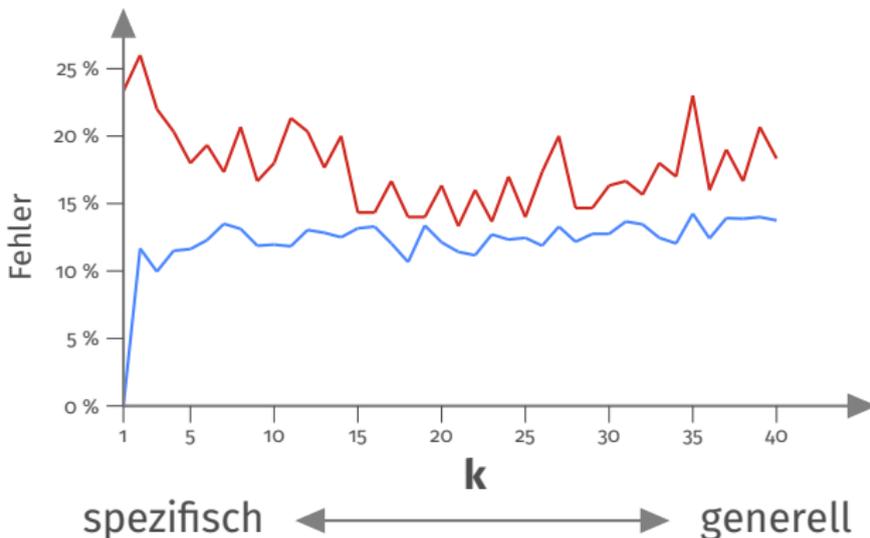
## Bewertung der Modell-Güte – Generalisierungsfehler



## Bewertung der Modell-Güte – Generalisierungsfehler



## Trainings- und Test-Fehler auf generiertem Datensatz (k-NN)



## Overfitting

“Das Modell passt nur zu den Trainingsdaten.”

## Overfitting

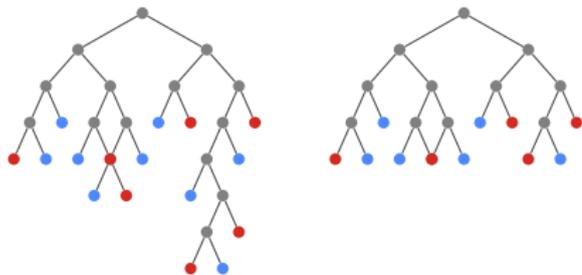
“Das Modell passt nur zu den Trainingsdaten.”

	Trainingsfehler klein	Trainingsfehler groß
Testfehler klein	Das sieht gut aus!	
Testfehler groß	<b>Overfitting!</b>	Das Modell lernt nicht!?

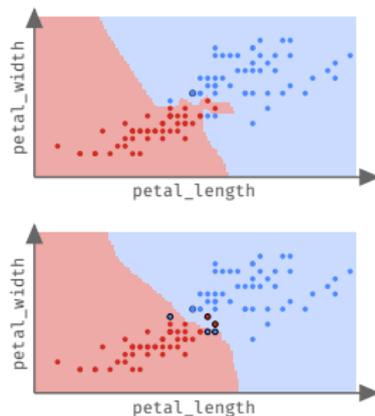
## Overfitting - zu spezifisches Modell

- Modell zu sehr an die Trainingsdaten angepasst
- Vorhersage auf unbekanntem Daten schlechter
- Modellkomplexität begrenzen (generelleres Modell)

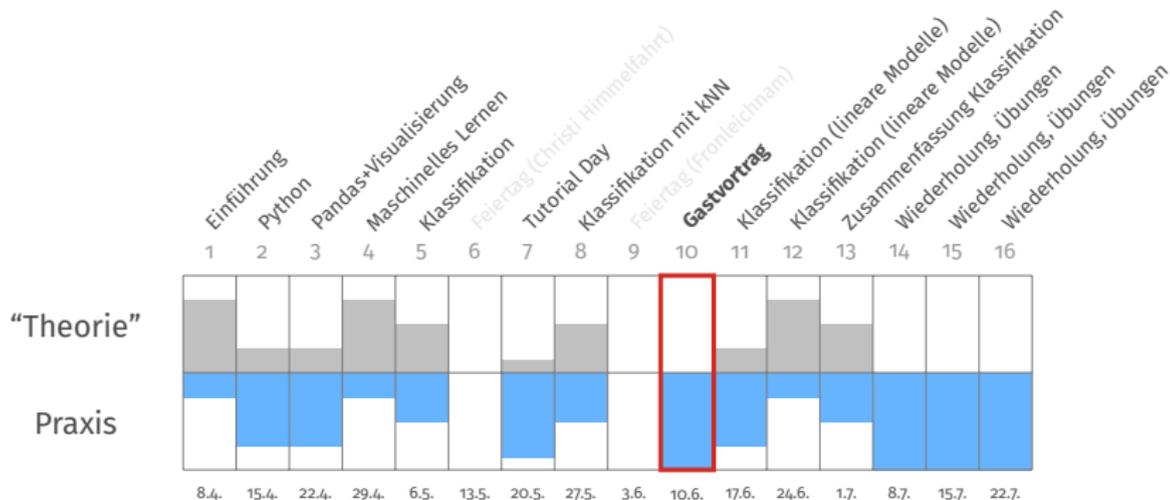
Tiefe bei Bäumen beschränken



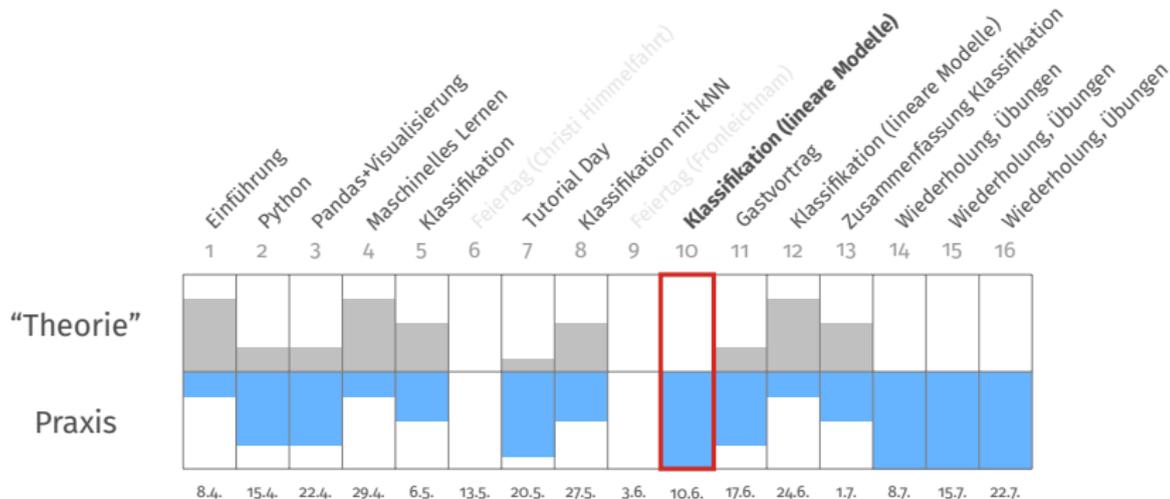
k bei k-NN erhöhen



## Wo sind wir heute (Vorlesung 7) ?



## Wo sind wir heute (Vorlesung 7) ?



## Gastvortrag auf 17.6. verschoben

- Leider kurzfristige Verschiebung des Gastvortrags
- Bereitstellung von Foliensatz 7 (lineare Modelle)
- Heute kurzer **Überblick über lineare Modelle**

## Gastvortrag auf 17.6. verschoben

- Leider kurzfristige Verschiebung des Gastvortrags
- Bereitstellung von Foliensatz 7 (lineare Modelle)
- Heute kurzer **Überblick über lineare Modelle**

## Hausarbeit

- **Vorstellung Test-Hausarbeit**
- Planung zum Zeitraum der Hausarbeit

## Gastvortrag auf 17.6. verschoben

- Leider kurzfristige Verschiebung des Gastvortrags
- Bereitstellung von Foliensatz 7 (lineare Modelle)
- Heute kurzer **Überblick über lineare Modelle**

## Hausarbeit

- **Vorstellung Test-Hausarbeit**
- Planung zum Zeitraum der Hausarbeit

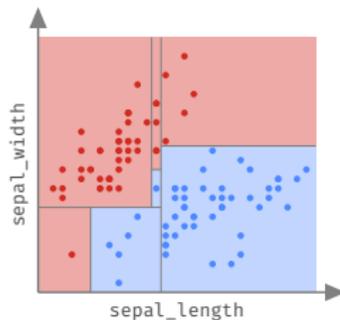
## Heutige Übung:

- Tutorial Blatt 2 (Python Listen)
- Falls gewünscht: Test-Hausarbeit Aufgabe 1

## Worum geht es im Foliensatz 7?

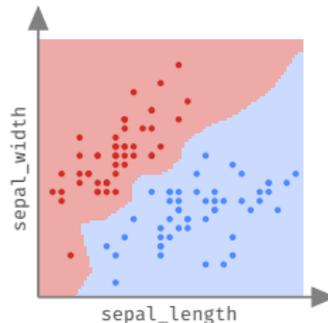
- 1 Daten im Vektorraum
- 2 Lineare Modelle
- 3 Hausarbeit (Test)

## Entscheidungsbäume, nächste Nachbarn



### Entscheidungsbaum

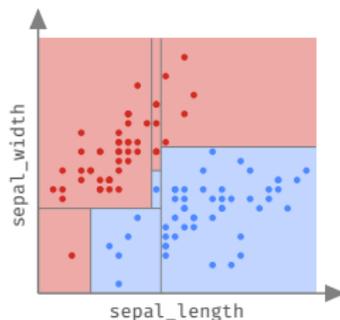
Trennung nach einzelnen Attributen, achsenparallel



### k-nächste Nachbarn

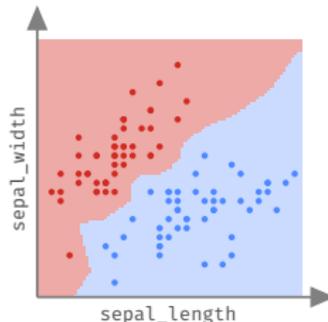
Trennung in Regionen, nach Distanz  
(Berechnung über alle Attribute)

## Entscheidungsbäume, nächste Nachbarn und lineare Modelle



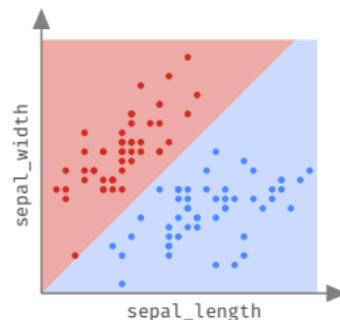
### Entscheidungsbaum

Trennung nach einzelnen Attributen, achsenparallel



### k-nächste Nachbarn

Trennung in Regionen, nach Distanz (Berechnung über alle Attribute)



### Lineare Modelle

Trennung mit linearer Funktion über alle Attribute

## Vektorraum: Iris-Daten im Vektorraum $\mathbb{R}^4$

sepal_length	sepal_width	petal_length	petal_width
4.700	3.200	1.300	0.200
6	2.200	4	1
4.600	3.100	1.500	0.200
7.600	3	6.600	2.100
6.300	2.900	5.600	1.800
5.400	3.900	1.700	0.400

$$\mathbf{x}_3 = \begin{pmatrix} 4.6 \\ 3.1 \\ 1.5 \\ 0.2 \end{pmatrix}$$

Vektor-Darstellung der  
Zeile 3 aus dem Datensatz

## Vektorraum: Iris-Daten im Vektorraum $\mathbb{R}^2$

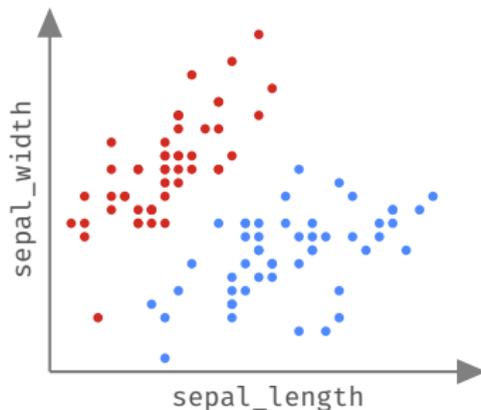
sepal_length	sepal_width
4.700	3.200
6	2.200
4.600	3.100
7.600	3
6.300	2.900
5.400	3.900

$$\mathbf{x}_3 = \begin{pmatrix} 4.6 \\ 3.1 \end{pmatrix}$$

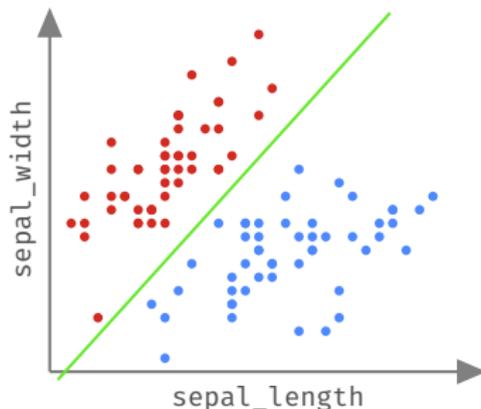
Vektor-Darstellung der  
Zeile 3 aus dem Datensatz

**Betrachten wir vereinfacht nur 2 Attribute!**

## Plot der beiden Attribute der Iris-Daten:

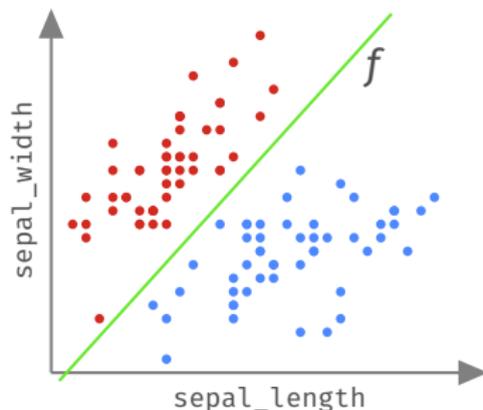


## Plot der beiden Attribute der Iris-Daten:



**Intuitiv lassen sich die beiden Klassen trennen.**

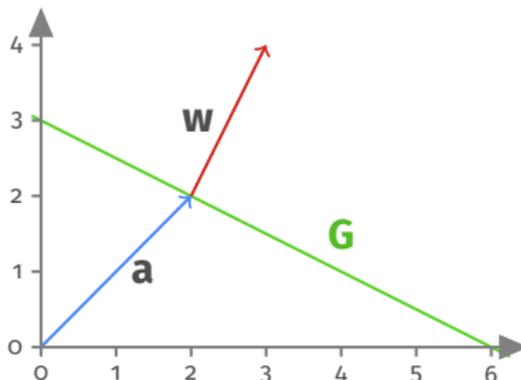
## Idee: Daten mit einer Geraden trennen



Geradengleichung (Schule) im 2-dimensionalen Raum ( $\mathbb{R}^2$ ):

$$f(x) = b \cdot x + c$$

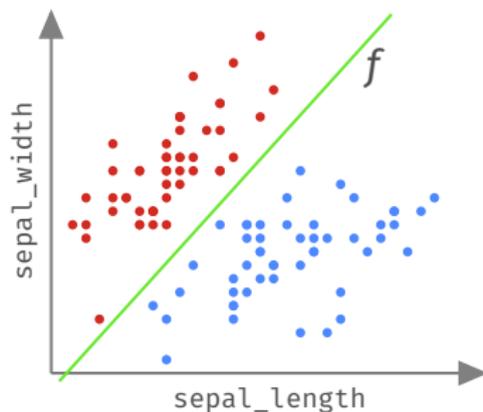
## Beispiel: Gerade im $\mathbb{R}^2$



Gerade ist definiert durch Stützvektor  $\vec{a} = \begin{pmatrix} 2 \\ 2 \end{pmatrix}$  und Normalenvektor  $\vec{w} = \begin{pmatrix} 1 \\ 2 \end{pmatrix}$

$$\mathbf{G} = \left\{ (x, y) \in \mathbb{R}^2 \mid 1 \cdot x + 2 \cdot y = 6 \right\}$$

## Beispiel: Gerade im $\mathbb{R}^2$



Wir müssen also nur die richtigen  $\mathbf{a}$  und  $\mathbf{w}$  finden!

## Allgemeine Form für **Hyperebenen** im $\mathbb{R}^d$

Hyperebene  $H$  definiert durch

$$H = \left\{ \mathbf{x} \in \mathbb{R}^d \mid \mathbf{w}^T \mathbf{x} + b = 0 \right\}$$

## Allgemeine Form für **Hyperebenen** im $\mathbb{R}^d$

Hyperebene  $H$  definiert durch

$$H = \left\{ \mathbf{x} \in \mathbb{R}^d \mid \mathbf{w}^T \mathbf{x} + b = 0 \right\}$$

**Parametrisierung** von  $f$  durch  $\mathbf{x}$  und  $b$ :

$$f(\mathbf{x}) = \mathbf{w}^T \mathbf{x} + b$$

**Modell-Training ist damit die Auswahl von  $\mathbf{w}$  und  $b$ !**

## Foliensatz 7 (zum weiteren Selbststudium)

- Geht auf Vektoren und Vektorräume ein
- Stellt einfaches Verfahren für lineares Modell vor
- Skizziert die Idee der Stützvektor-Methode (SVM)

## Foliensatz 7 (zum weiteren Selbststudium)

- Geht auf Vektoren und Vektorräume ein
- Stellt einfaches Verfahren für lineares Modell vor
- Skizziert die Idee der Stützvektor-Methode (SVM)

**Schauen Sie sich den Foliensatz an!**

Diskussion in der nächsten Woche (nach dem Gastvortrag)

# Hausarbeit (Test)

## Die Hausarbeit

- Datensatz zu (fiktivem) Anwendungsfall
- Wird als Jupyter-Notebook bearbeitet
- Besteht aus 3 Aufgaben

## Die Hausarbeit

- Datensatz zu (fiktivem) Anwendungsfall
- Wird als Jupyter-Notebook bearbeitet
- Besteht aus 3 Aufgaben

## Die Arten der Aufgaben:

1. Python-Funktionen schreiben
2. Daten lesen + erkunden (Statistiken → [Pandas](#))
3. Einfaches Modell für Vorhersage berechnen



## Verschiedene Bastelprojekte

- Python-Tools für RFID-Karten
- Open-Source MP3-Player Software
- Phoniebox: <http://phoniebox.de/>



Raspberry Pi



## Wie ist das Hör-Verhalten der Kinder?

- Welche Titel/Themen sind beliebt?
- Gibt es Zielgruppen mit bestimmten Vorlieben?

## Wie ist das Hör-Verhalten der Kinder?

- Welche Titel/Themen sind beliebt?
- Gibt es Zielgruppen mit bestimmten Vorlieben?

## Andere machen das auch:



Vorstellung:  
Test-Hausarbeit zu Kinder-Musikboxen

## Terminfindung Hausarbeit

- 1 Woche Bearbeitungszeit für die Hausarbeit
- Klausurphase W: 10.7. - 31.7.
- Vorschlag 0: 5.7. bis 12.7. (Mo bis Mo)
- Vorschlag 1: 23.7. bis 30.7. (Fr bis Fr)
- Vorschlag 2: 30.7. bis 6.8. (Fr bis Fr)
- Diskussion!

## Terminfindung Hausarbeit

- 1 Woche Bearbeitungszeit für die Hausarbeit
- Klausurphase W: 10.7. - 31.7.
- Vorschlag 0: 5.7. bis 12.7. (Mo bis Mo)
- Vorschlag 1: 23.7. bis 30.7. (Fr bis Fr)
- Vorschlag 2: 30.7. bis 6.8. (Fr bis Fr)
- Diskussion!

Vorschlag 2 nur mit verzögerter Korrektur möglich.