

# Big Data und Machine Learning

6. März 2018

## Begriffe

- Strukturierte Daten
- Unstrukturierte Daten
- Klassifikation
- Klassifikationsgüte
- Test- und Trainingsdaten
- Regression versus Klassifikation
- Regression and Classification Trees («CARTs»)

## Strukturierte versus unstrukturierte Daten

- Daten, die in irgendeiner Weise in **Tabellenform** vorliegen
  - Facebook Likes
  - Spotify-Playlist
  - ....
- Daten, die **nicht** in **Tabellenform** vorliegen
  - Bilder
  - Texte
  - ...

## Klassifikation versus Regression

Herangehensweise im EF:

- **Klassifikation** von strukturierten Daten
  - Zeichenerkennung (0,1,...,9) auf Grund Pixelfarben
  - ....
- Andere Fragestellung («**Regression**»): Vorhersage einer stetigen Grösse
  - Einkommen auf Grund Cumulus-Verhalten
  - Occassionsautopreis auf Grund Attributen (Grösse, Türen, Farbe, Hubraum, etc.)
  - ....

Quelle: <https://blogs.nvidia.com/blog/2016/07/29/whats-difference-artificial-intelligence-machine-learning-deep-learning-ai/>

## Klassifikationsgüte und -matrix

- Die **Klassifikationsgüte** kann als relative Anzahl richtig klassifizierter angegeben werden (siehe Wiki)
- Zusätzlich dazu, kann eine sogenannte **Konfusionsmatrix** angegeben werden:

0	26	0	1	0	0	0	1	0	0	0
1	0	8	0	0	1	0	0	0	0	0
2	0	0	15	0	0	0	1	0	0	0
3	0	0	1	4	0	0	0	0	2	0
4	0	0	0	0	4	0	0	0	0	0
5	0	0	0	1	0	4	0	0	0	0
6	0	0	0	0	0	0	8	0	0	0
7	0	0	0	0	0	0	0	8	0	0
8	0	0	0	0	0	0	0	0	4	0
9	0	0	0	0	0	0	0	0	0	11
	0	1	2	3	4	5	6	7	8	9

Wahre Ziffer

## Test- und Trainingsdaten (Klassifikation)

- Auf den **Trainingsdaten** wird ein Algorithmus «geschult». Diese Daten stehen dem Algorithmus als Datensatz von  $[X_i, Y_i]$  zur Verfügung.
- Auf den **Testdaten** stehen dem Algorithmus erstmals nur die **Features**  $X_i \in \mathbb{R}^k$  ohne die Klasse zur Verfügung. Zur Überprüfung des Algorithmus werden nachher die doch bekannten Klassen  $Y_i \in \mathbb{N}$  mit den Vorhersagen des Algorithmus verglichen.
- Im wahren Leben: Nur Attribute  $X_i$  und keine Klassen.

## Klassifikation und Regression

Bis jetzt: Nur **Klassifikation**.

Andere Fragestellung: Autopreis auf Grund von Attributen (Farbe, Hubraum, PS, etc.) vorhersagen. Die vorhergesagte Grösse ist keine **Klassifikation** sondern eine **Regression**. Es wird eine **stetige Grösse** (reelle Zahl) vorhergesagt.

## «Allerweltswaffe»: CARTs

Sogenannte **Classification and Regression Trees**:

Klassifikation: Beispiel Ziffern. Frage: Ziffer auf Grund Pixelbild vorhersagen



## «Allerweltswaffe»: CARTs

Sogenannte **C**lassification and **R**egression **T**rees:

Regression: Beispiel Autos. Frage: Preis auf Grund Attributen vorhersagen



## Viele Bäume: Zufallswald («random forests»)

- Anstelle eines Baumes werden viele Bäume («Wald», «forest») auf zufälligen («random») Teilmengen der Daten trainiert.
- Die abschliessende Meinung (Klassifikation, Regression) ist dann die Meinung (Mehrheit, Mittelwert) des Waldes.

