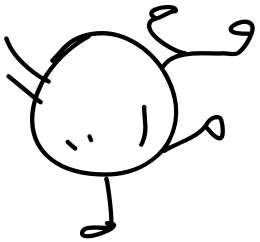

01 Einführung

Vorlesung 186.844

09.10.2014

TECHNISCHE
UNIVERSITÄT
WIEN
Vienna University of Technology

Sprache / Language

Ergebnis TUWEL-Abstimmung

120 Stimmen

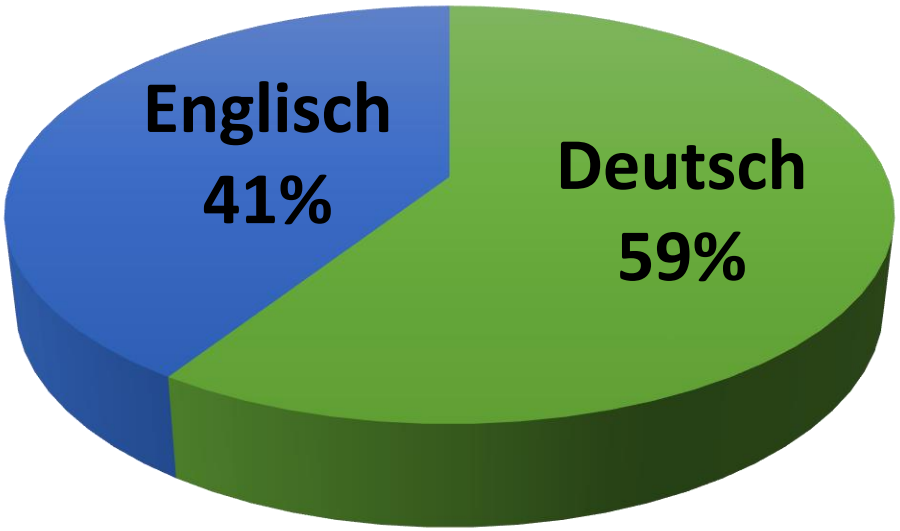

Entscheidung

- Vortrag und Folien in Deutsch
  - eBooks im TUWEL in Englisch
- Prüfung Deutsch und Englisch möglich

© Nicole M. Artner

Überblick

I. Arten von Mustererkennung (ME)

II. Design eines Mustererkennungs-systems (ME-System)

III. Anwendungen

© Nicole M. Artner

Arten von ME

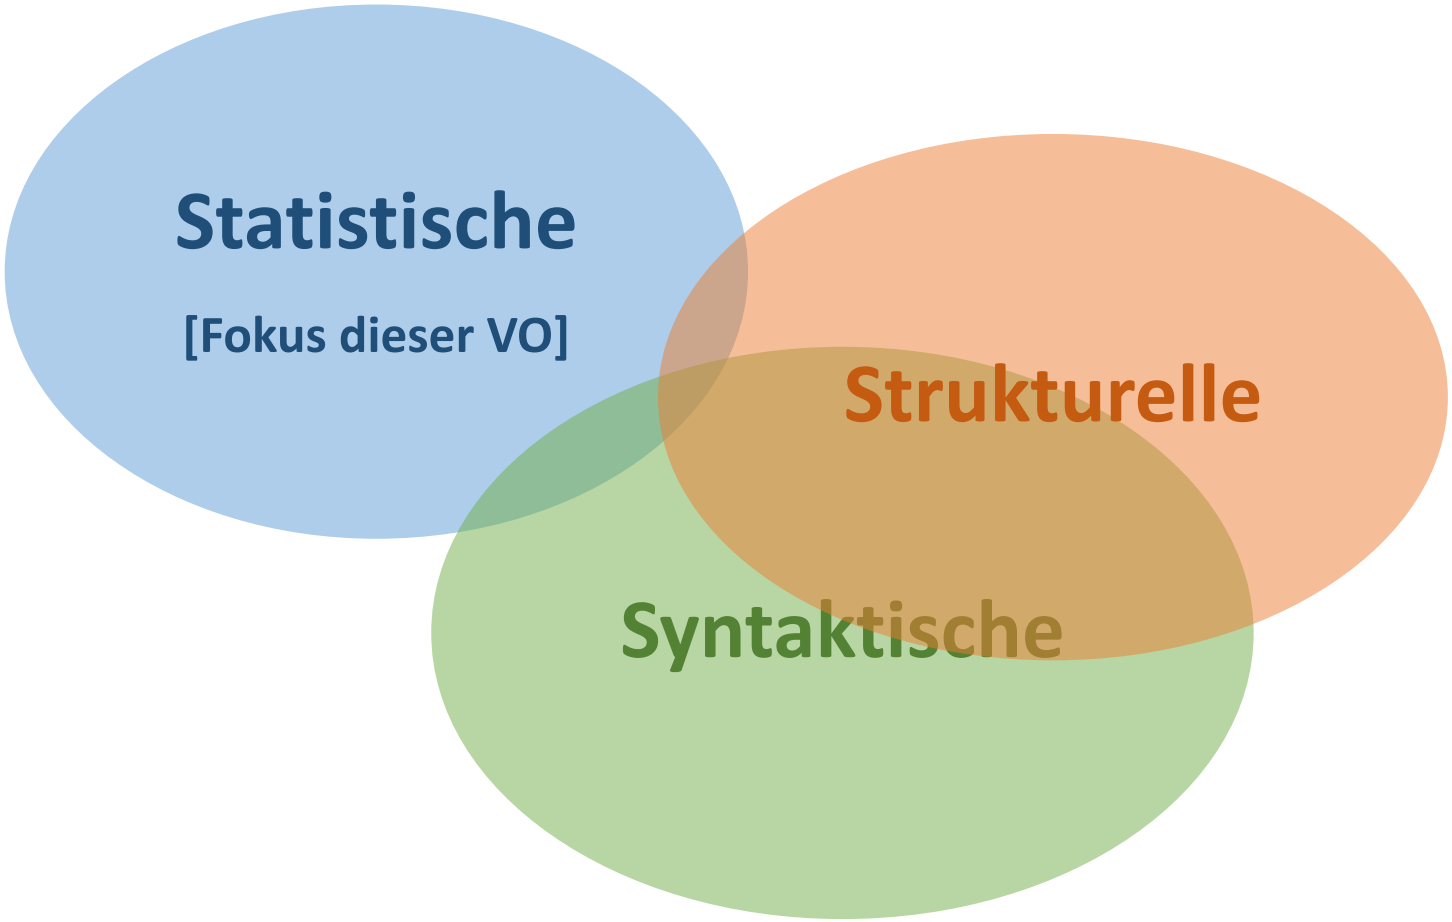

© Nicole M. Artner

Unterscheidung durch …

Musterrepräsentation

- wie wird das Muster beschrieben

Klassifikation

- wie werden die Muster Klassen zugeordnet

© Nicole M. Artner

Statistische ME

Musterrepräsentation

- Merkmalsvektoren

Klassifikation

- statistische Methoden
- e.g. Nearest Neighbor, Bayes Theorem, …

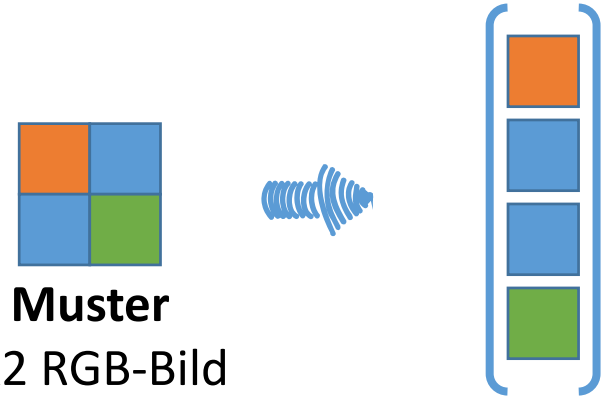

Muster
2x2 RGB-Bild

Vektor
Farbwerte im RGB-Farbraum

© Nicole M. Artner

Strukturelle ME

Musterrepräsentation

- durch Graphen oder Graph Pyramiden
- Merkmale: Knoten
- Beziehungen: Kanten

Muster
2x2 RGB-Bild

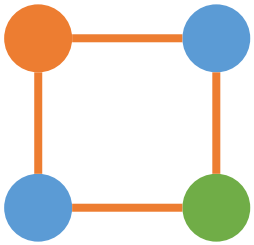

Graph
Knoten: RGB-Farbwerte
Kanten: 4er Nachbarschaft

© Nicole M. Artner

Strukturelle ME

Klassifikation

- Graph matching (exakt oder inexakt)
- Graph embedding
  - Graphen werden in Vektorraum abgebildet
  - dann können statistische Methoden angewandt werden

© Nicole M. Artner

Strukturelle ME

Mehr dazu …

- 183.280: VO Strukturelle Mustererkennung
- Golden Dome Präsentation von Horst Bunke, K.S. Fu Price Winner 2010, http://www.cse.nd.edu/Fu_Prize_Seminars/

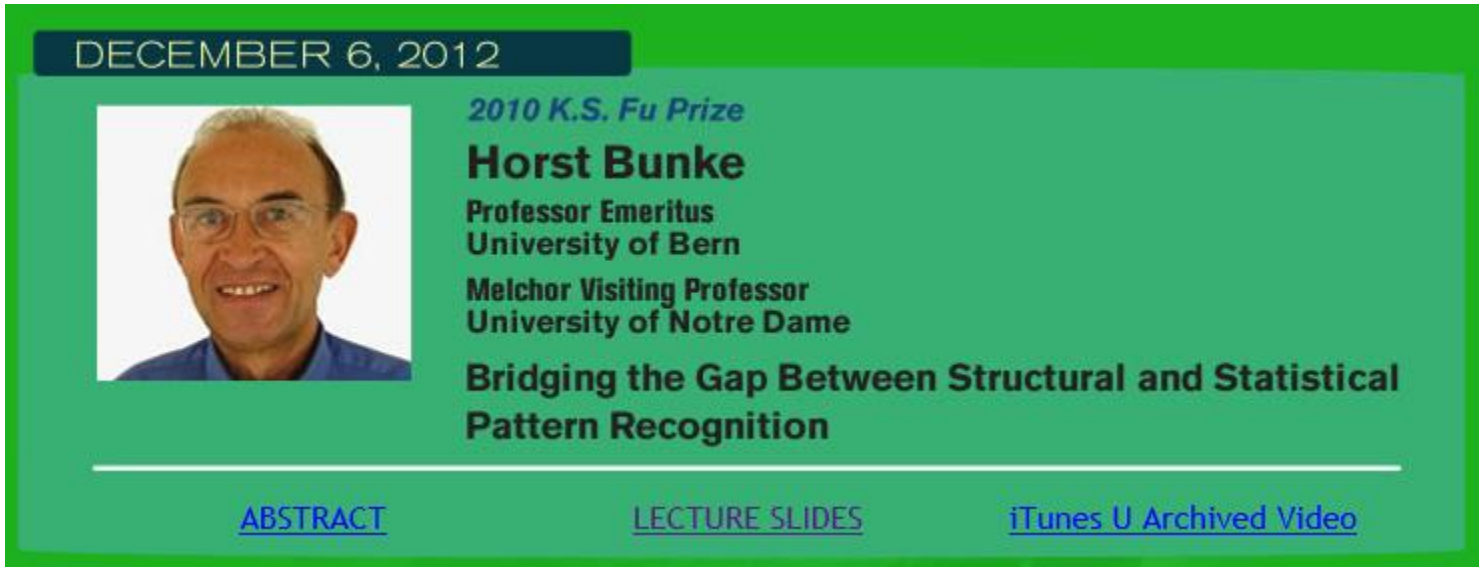

Syntaktische ME

Musterrepräsentation

- durch Primitive
- und Beziehungen/Verhältnisse zwischen Primitiven

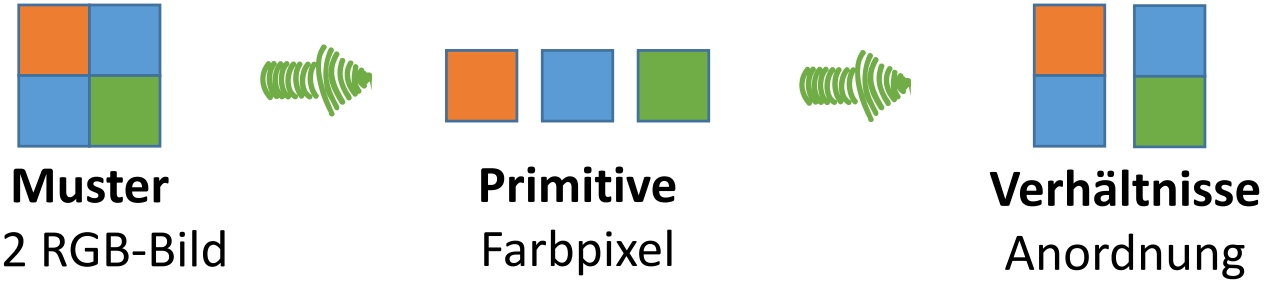

© Nicole M. Artner

Syntaktische ME

Klassifikation

- durch Grammatiken
  - Regeln wie man Muster aus Primitiven erstellen kann
  - jede Klasse von Mustern hat eigene Grammatik

Gültige Klassen:

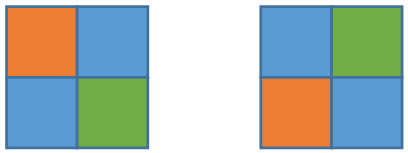

Klasse 1 **Klasse 2**

Ungültige Klassen:

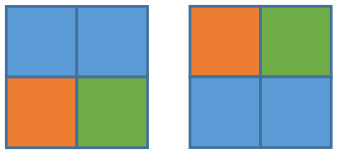

…

© Nicole M. Artner

Syntaktische ME

Mehr dazu …

- 183.280: VO Strukturelle Mustererkennung
- Forschung von Sanja Fidler und Ales Leonardis
  - Compositional, Multi-class Object Detection
  - see http://www.cs.utoronto.ca/~fidler/research.html

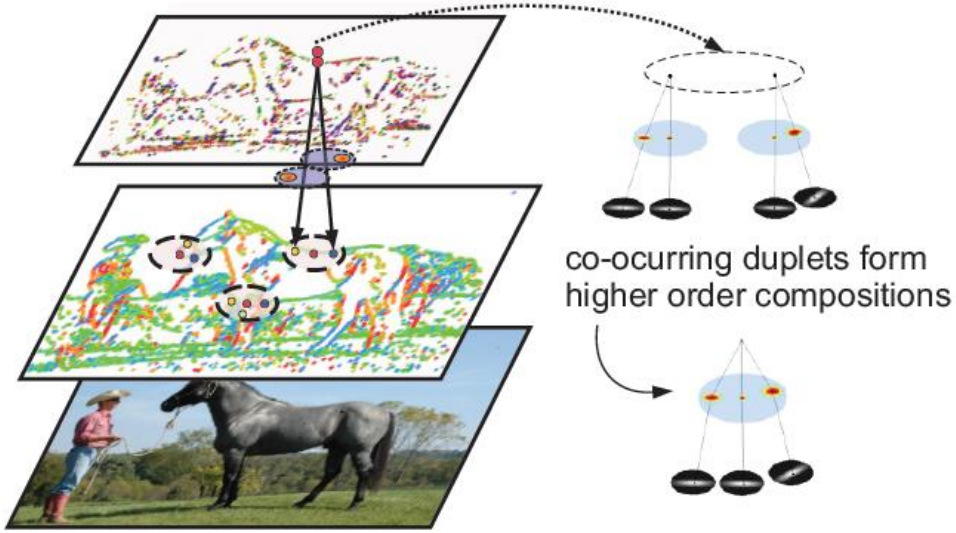

Bildquelle:
Sanja Fidler, Marko Boben, Ales Leonardis
Learning a Hierarchical Compositional Shape Vocabulary for Multi-class Object Representation
arXiv preprint arXiv:1408.5516, 2014

Design eines ME-Systems

… durch folgende Prozesse, die meist wiederholt werden müssen

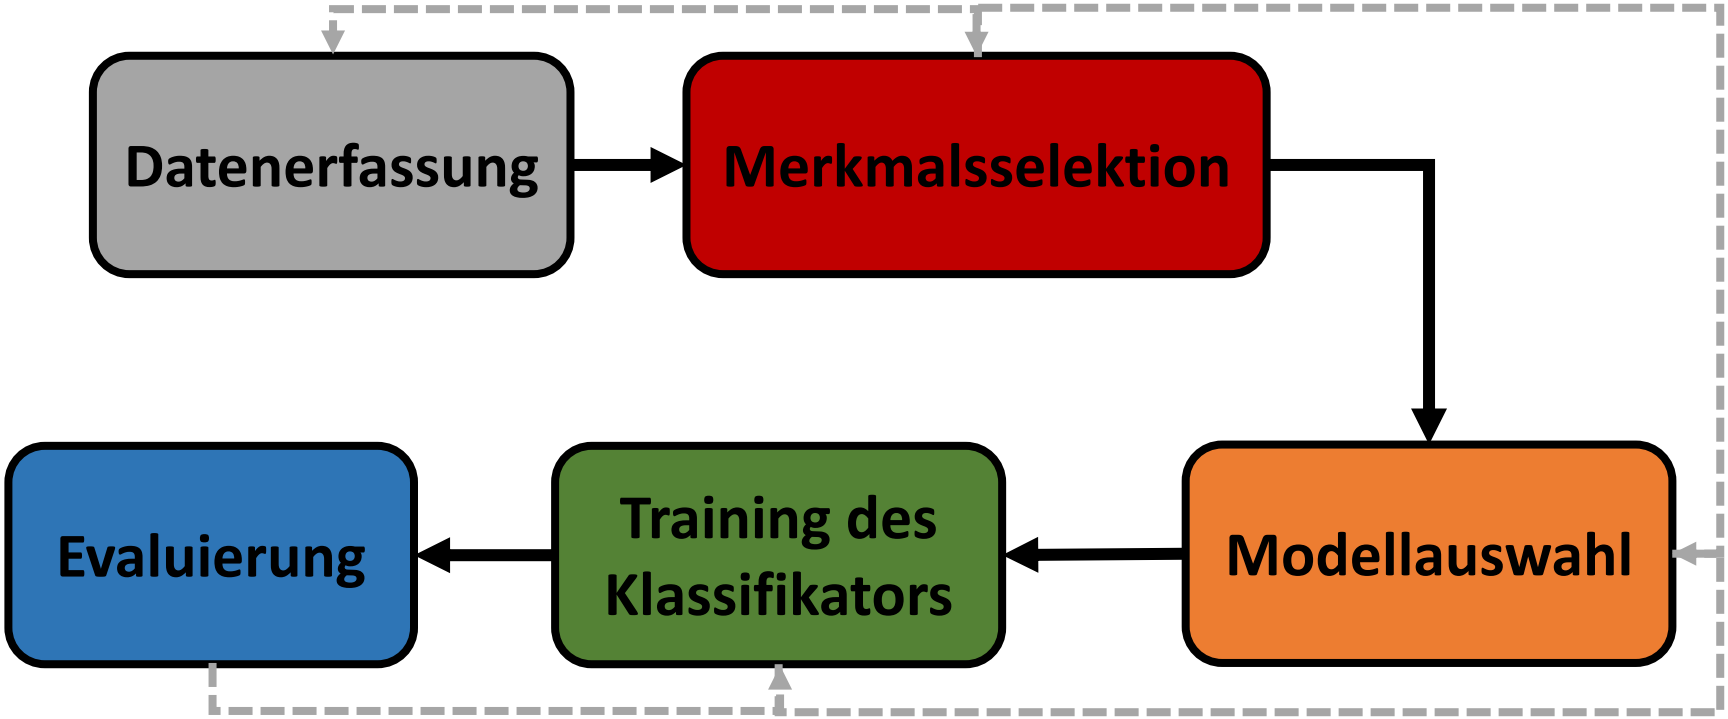

© Nicole M. Artner

Beispiel: Hund oder Katze?

ME-Aufgabe

Tierarzt hat vergessen in seinen Patientendaten zu vermerken, ob das Tier ein Hund oder eine Katze ist. Er will das jetzt automatisch nachtragen.

© Nicole M. Artner

Datenerfassung

© Nicole M. Artner

Daten für ME

… aus verschiedensten Gebieten

- Wirtschaft, Medizin, Informatik, Biologie, Sicherheitstechnik, Politik, …

… von unterschiedlichsten Sensoren

- Videokameras, Fotokameras, Infrarotkamera, High-Speed-Kamera, MRI, CT, Mikroskop, Ultraschallgerät, Mikrophon, Bewegungssensoren, …

… aus verschiedensten Medien

- Radio, TV, Internet, …

© Nicole M. Artner

„Big Data“

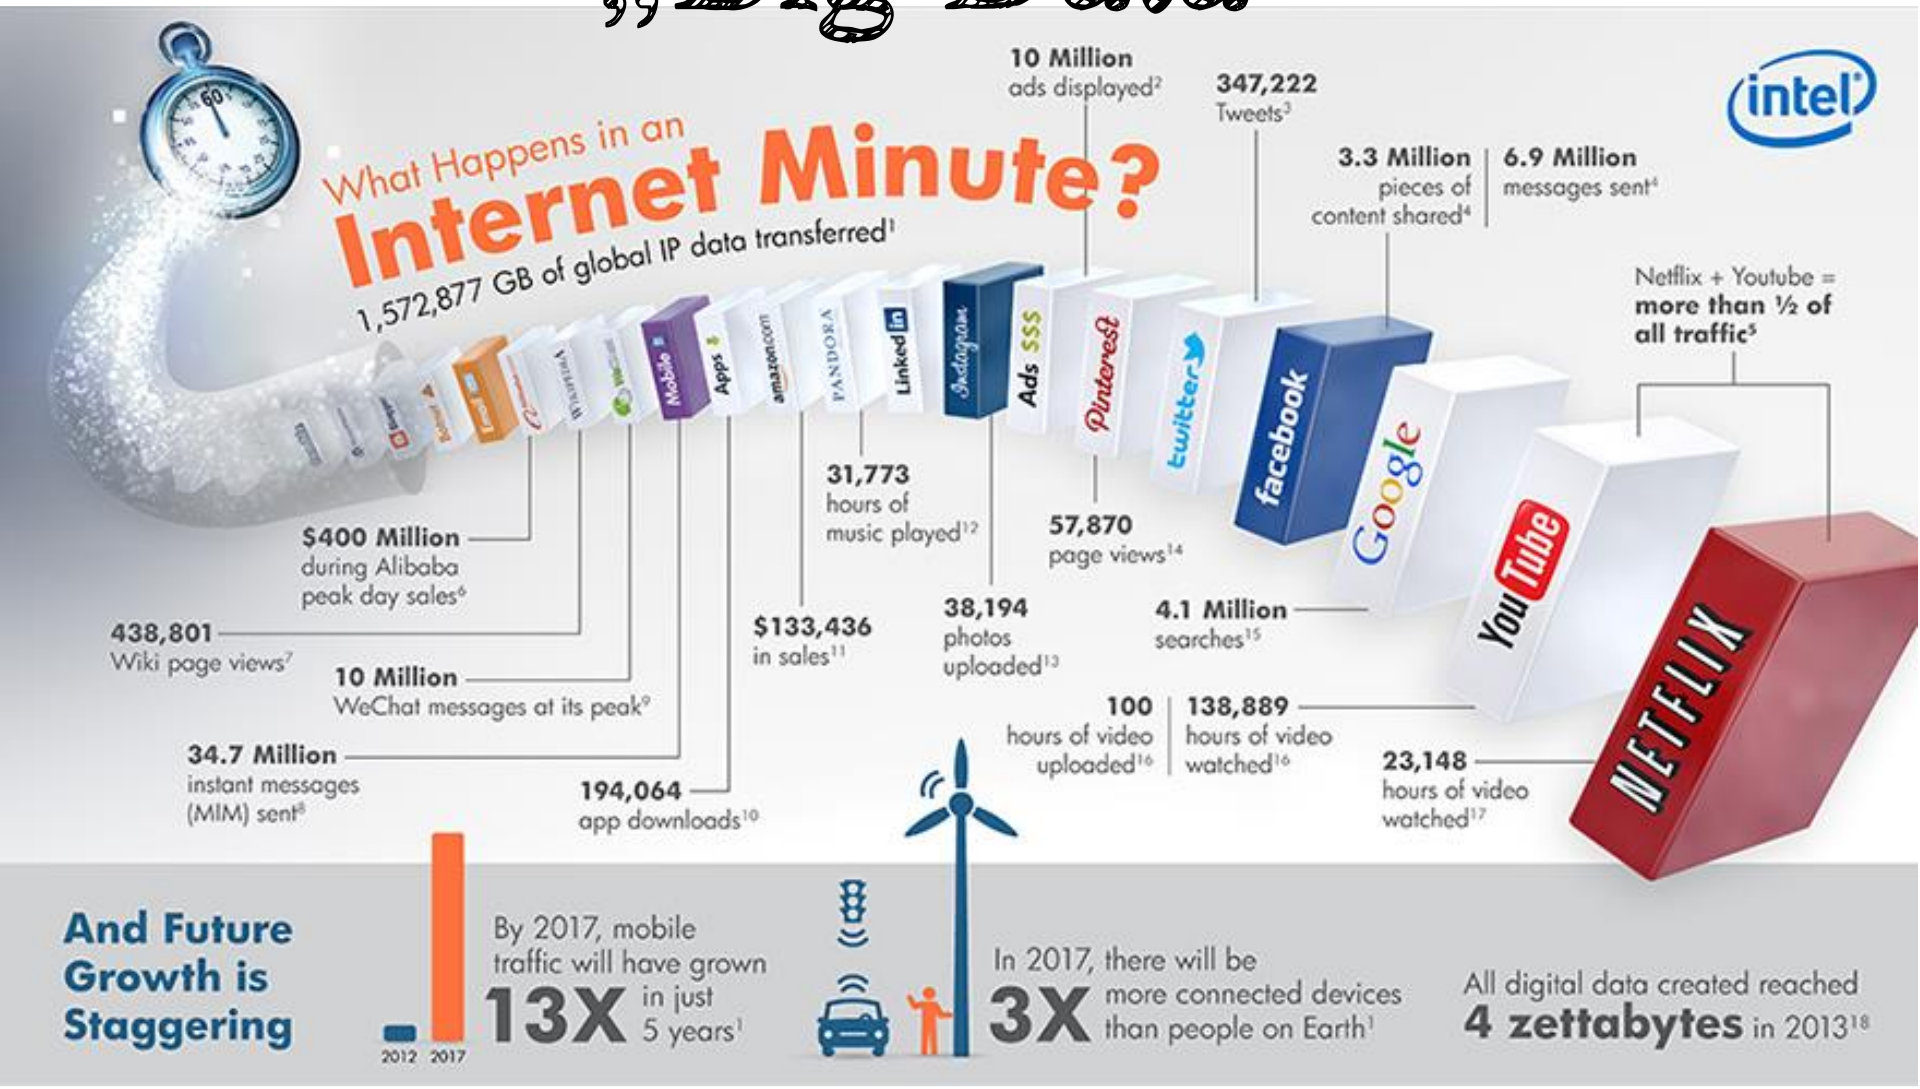

Quelle: http://www.intel.com/content/www/us/en/communications/internet-minute-infographic.html

Ground Truth

Die “wahre” Klasse eines Musters oder die “richtige” Ausgabe des Mustererkennungssystems.

→ **siehe Training des Klassifikators und Evaluierung**

Beispiele für GT:

GT: Klassenlabel und Position

GT: Identität

GT: Text

„Glühwein im Biergarten“

© Nicole M. Artner

Beispiel: Hund oder Katze?

Patient-Daten

- erfasst vom Arzt oder seinen Assistenten

- **Datensatz**
  - Qualitative Merkmale: Geschlecht, Fellfarben, Krankheiten, Impfungen, …
  - Quantitative Merkmale: Alter, Gewicht, Schulterhöhe, Körpertemperatur, Pulsfrequenz, Blutwerte, **…**

- **Ground Truth**
  - tatsächliche Tierklasse: Hund oder Katze

© Nicole M. Artner

Merkmalsselektion

© Nicole M. Artner

Grundlagen

Die Güte eines Merkmals hängt davon ab,

1. wie „**diskriminativ**“ es ist
   →wie gut es zwischen den Klassen unterscheiden kann
2. wie **einfach/schnell** es berechnet werden kann

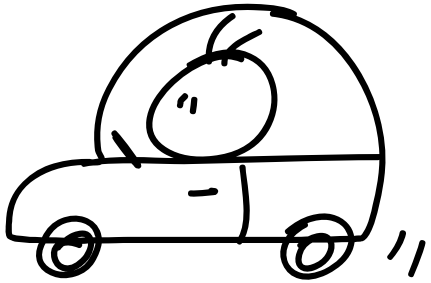

© Nicole M. Artner

Beispiel: Hund oder Katze?

Idee: „Hunde sind schwerer als Katzen.“

Merkmal: Gewicht

Um die Verteilung eines Merkmals für eine Klasse zu visualisieren, kann man ein Histogramm erstellen.

Histogramme zeigen wie häufig verschiedene Merkmalsausprägungen auftreten. Auf der Abszisse (x-Achse) trägt man die Merkmalsausprägungen ein und auf der Ordinate (y-Achse) die ihre Häufigkeit.

© Nicole M. Artner

Beispiel: Hund oder Katze?

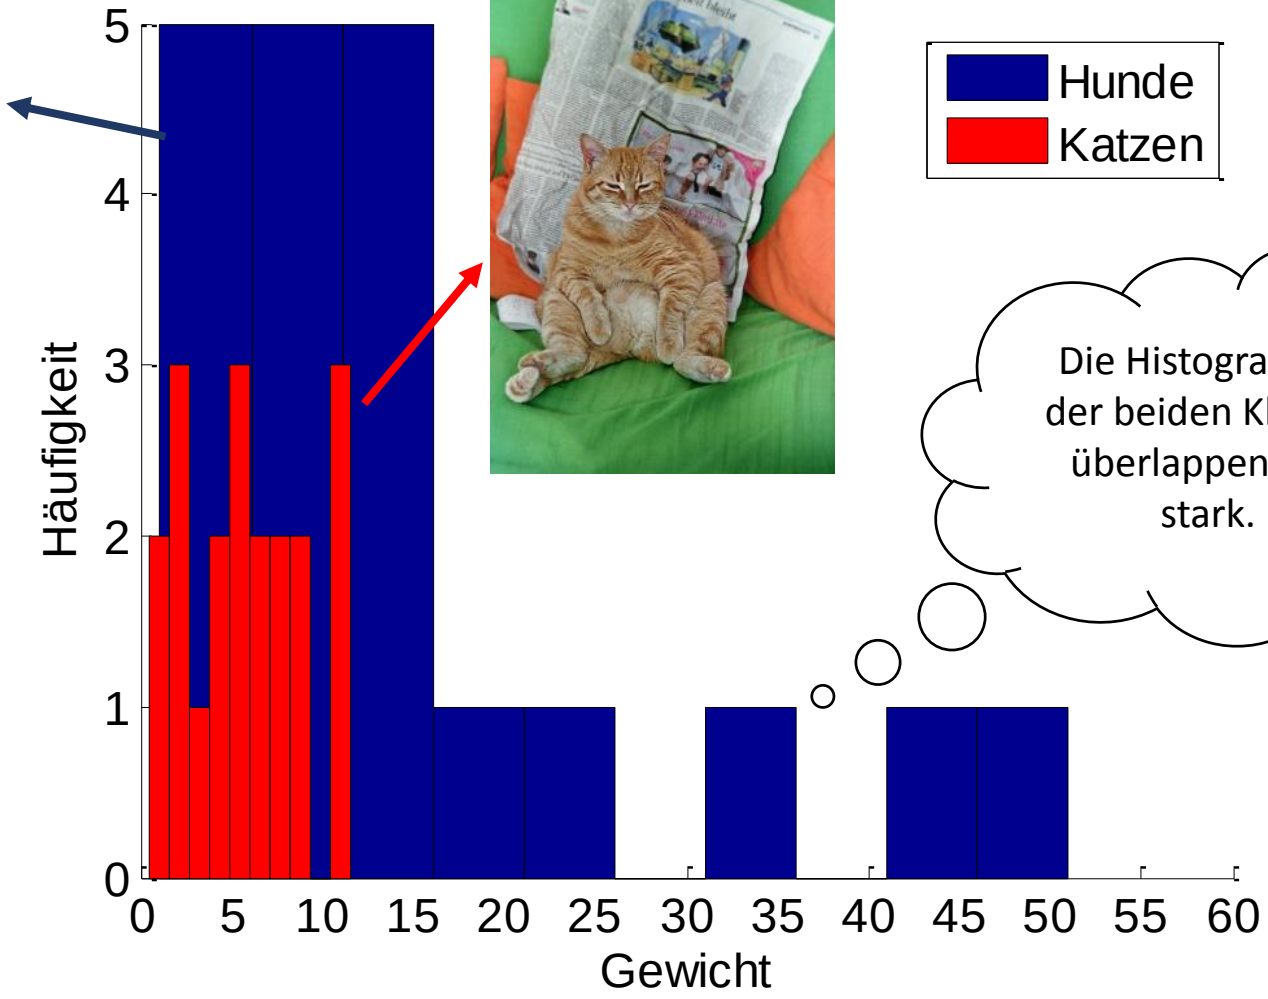

Die Histogramme der beiden Klassen überlappen sich stark.

© Nicole M. Artner

Beispiel: Hund oder Katze?

Im Idealfall findet man ein Merkmal dessen Histogramme beider Klassen nicht überlappen.

Weiter im Beispiel ….

Idee: „Katzen haben generell eine höhere Körper-temperatur als Hunde.“

Merkmal: Temperatur

© Nicole M. Artner

Beispiel: Hund oder Katze?

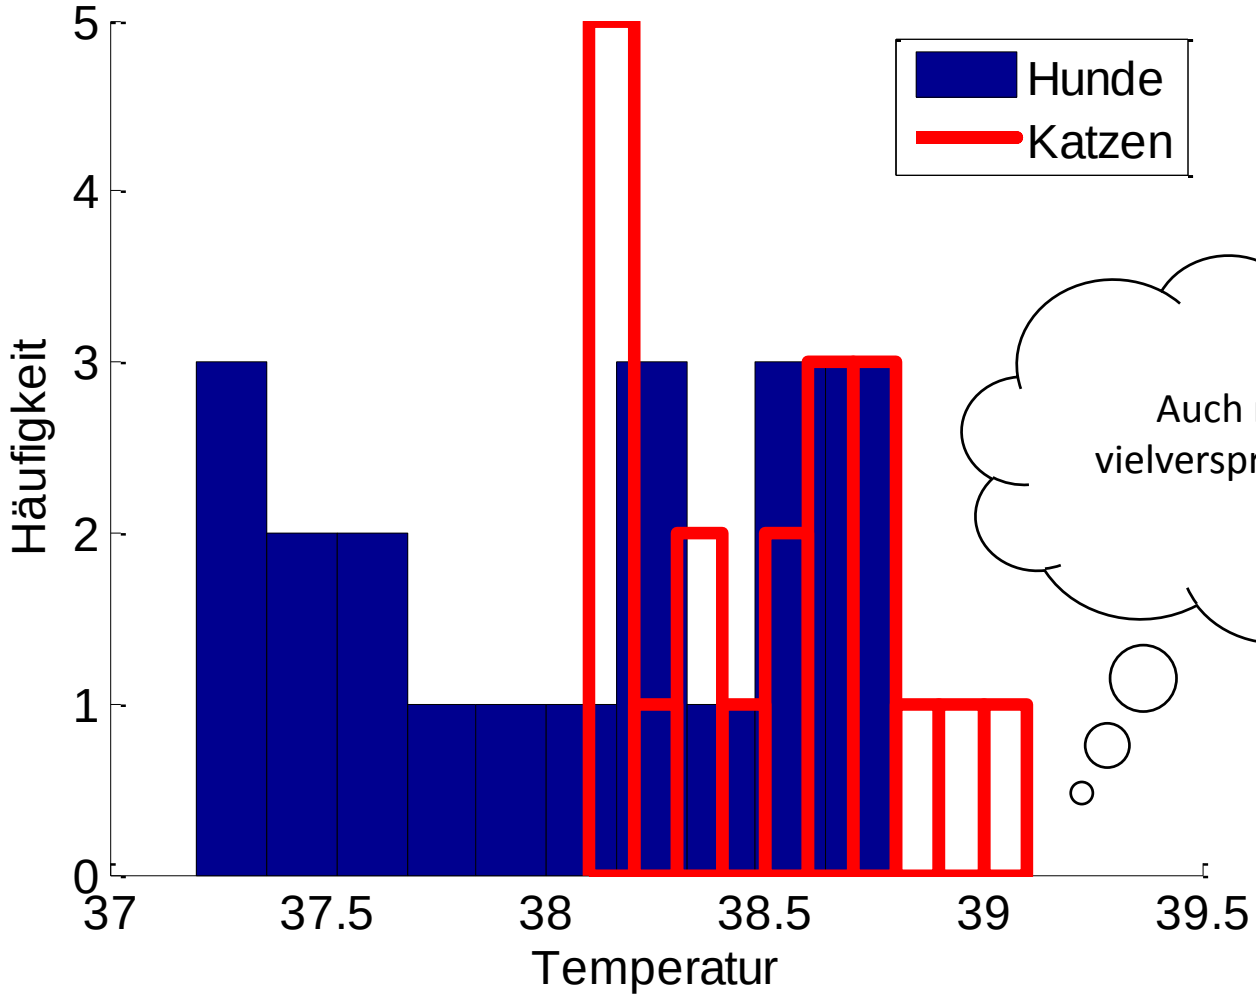

Beispiel: Hund oder Katze?

Kombination von zwei oder mehreren Merkmalen führt oft zu besseren Ergebnissen.

Mehr Merkmale sind aber nicht zwingend besser! Ungeeignete Merkmale oder eine unpassende Kombination kann zu schlechteren Ergebnissen führen, als ein einzelnes, sorgfältig ausgewähltes Merkmal.

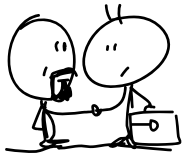

Weiter im Beispiel …

Idee: „Kombination von Gewicht und Temperatur.“

© Nicole M. Artner

Beispiel: Hund oder Katze?

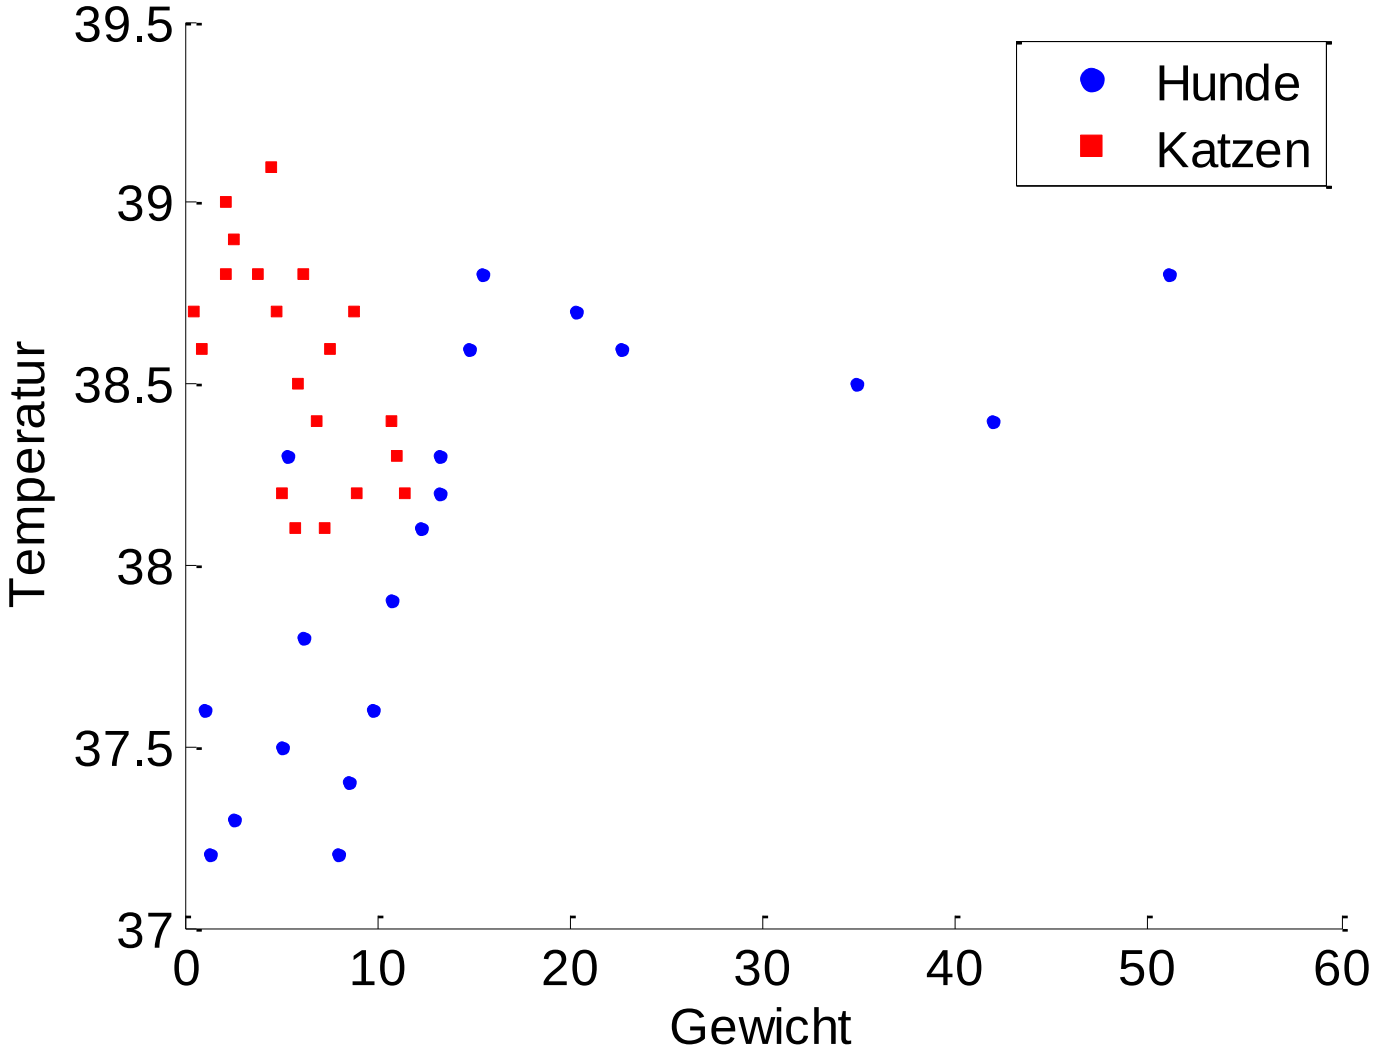

© Nicole M. Artner

Modellauswahl

© Nicole M. Artner

Die Qual der Wahl …

- eines geeigneten Modells / Klassifikators
- dieser Prozess arbeitet eng mit der Merkmalsselektion zusammen

Was macht einen guten Klassifikator aus?

1. Minimiert Fehler (= Muster wird einer falschen Klasse zugeordnet)
2. Besitzt hohe Generalisierungsfähigkeit

© Nicole M. Artner

Beispiel: Hund oder Katze?

lineares Modell

- Klassifikator ist nicht in der Lage das Trainingsset fehler-frei zu unterscheiden
- Lineare Entscheidungs-grenze ist ein zu einfach-es Modell
- „underfitting“

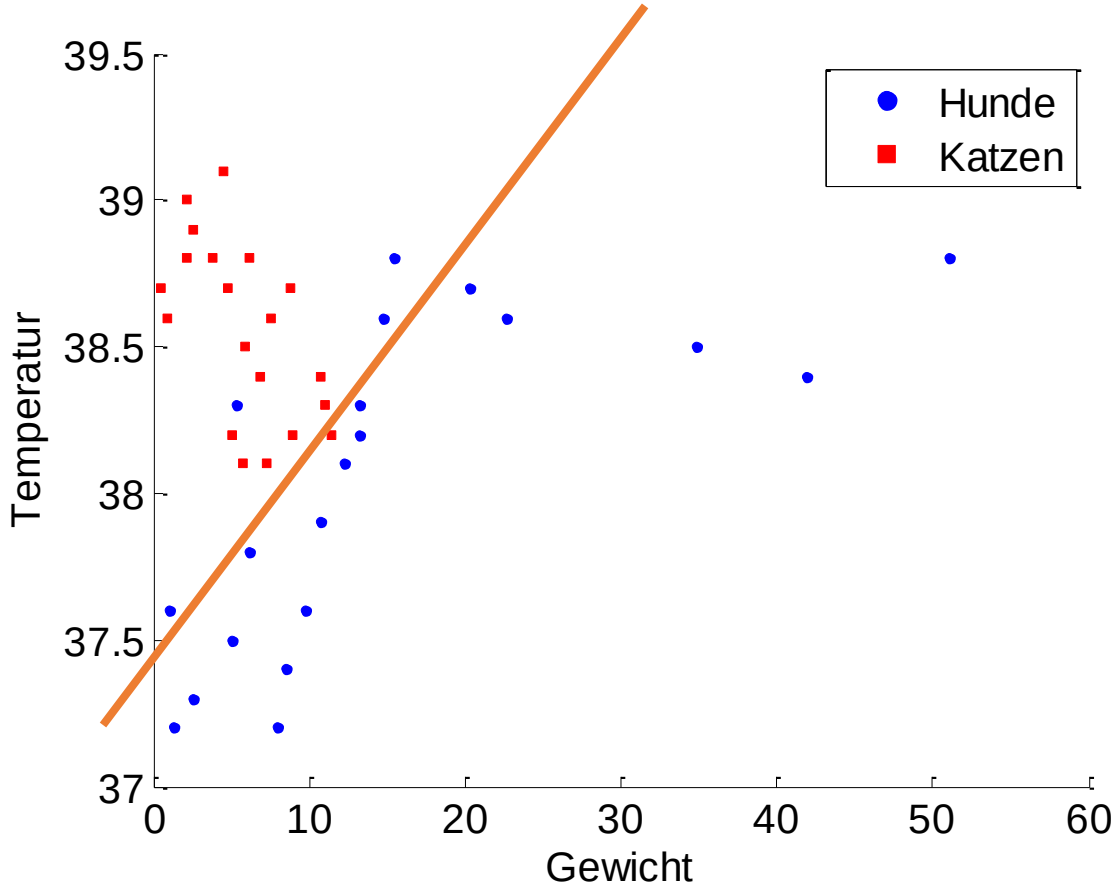

© Nicole M. Artner

Beispiel: Hund oder Katze?

komplexes Modell

- fehlerfreie Klassifikation auf Trainingsset
- komplexe Entscheidungsgrenze
- sehr schlechte Generalisierungsfähigkeit
- „overfitting“

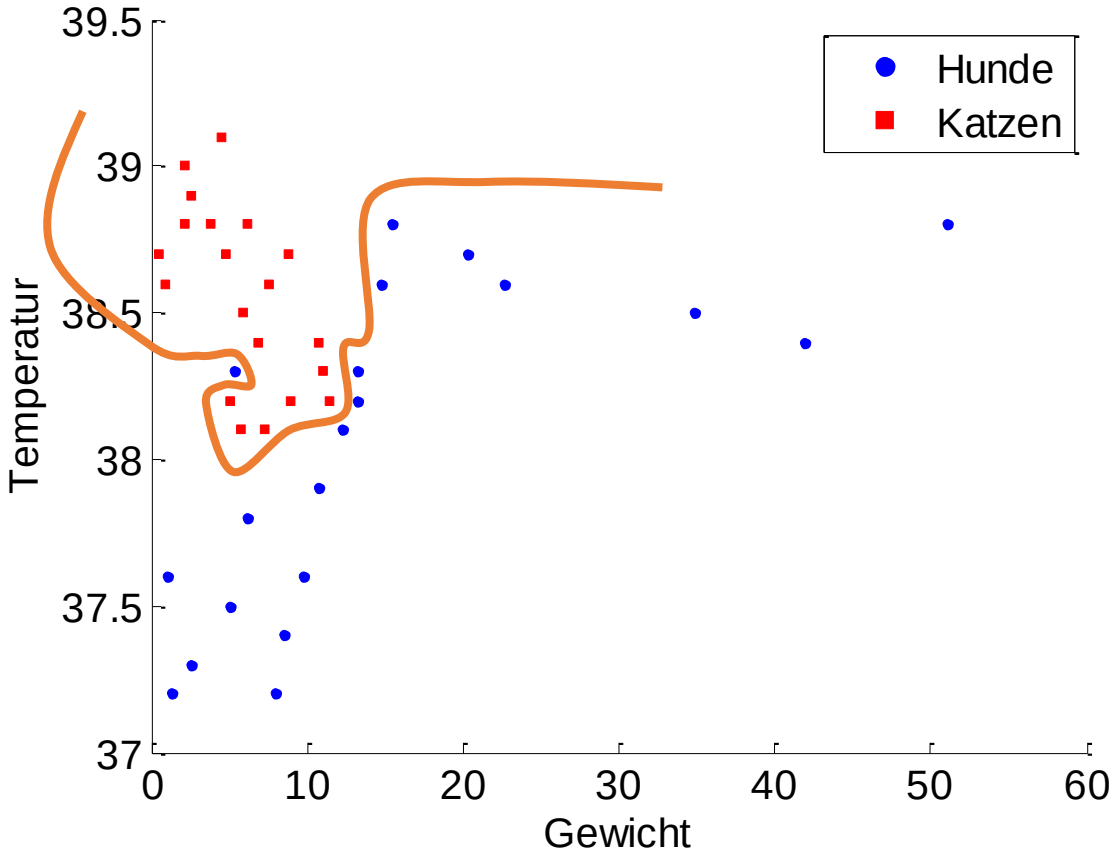

© Nicole M. Artner

Beispiel: Hund oder Katze?

Modell „mittlerer“ Komplexität

- Kompromiss zwischen Fehlerrate und Generalisierungsfähigkeit

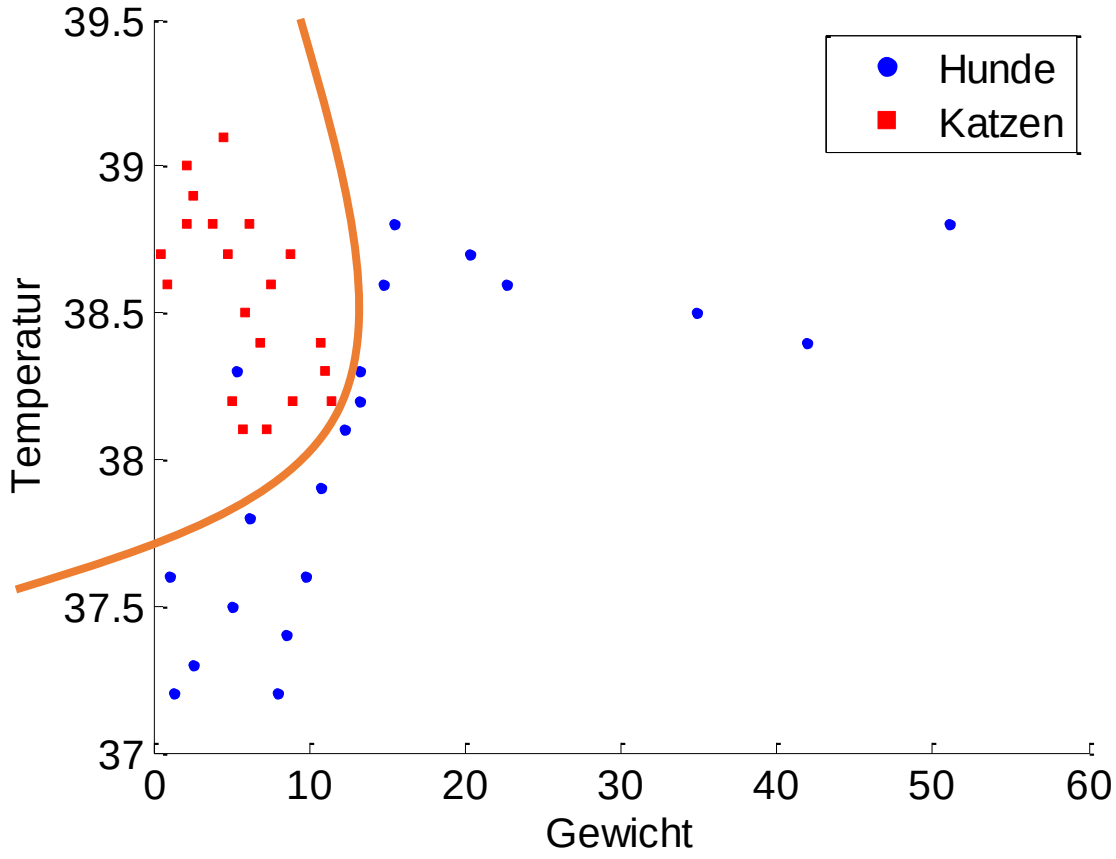

© Nicole M. Artner

Training des Klassifikators

© Nicole M. Artner

Was wird trainiert?

- Modelle/Klassifikatoren haben Parameter
- beim Training werden diese Parameter mit Hilfe des Trainingsets geschätzt/bestimmt

Training wird auch oft als "**Learning**" bezeichnet. Beim "Learning" werden die unbekannten Parameter des Modells "optimiert", sodass die Fehler im Trainingsset minimiert werden.

© Nicole M. Artner

Wie wird trainiert?

… oder gelernt

Supervised Learning: Klassenzugehörigkeit für jedes Muster im Trainingsset ist bekannt (→ Ground Truth).

Unsupervised Learning: Klassenzugehörigkeiten sind unbekannt. Das ME-System bildet sogenannte „Cluster“, um die Muster zu gruppieren / zu unterscheiden.

Zusätzlich gibt es noch „Mischformen“ (Reinforcement Learning, Semi-Supervised Learning).

© Nicole M. Artner

Beispiel: Hund oder Katze?

Supervised Learning

- für einen Teil seiner Patienten hat der Arzt Bilder von den Besitzern erhalten

- Trainingsset besteht aus 40 Mustern: 20 Hunde und 20 Katzen

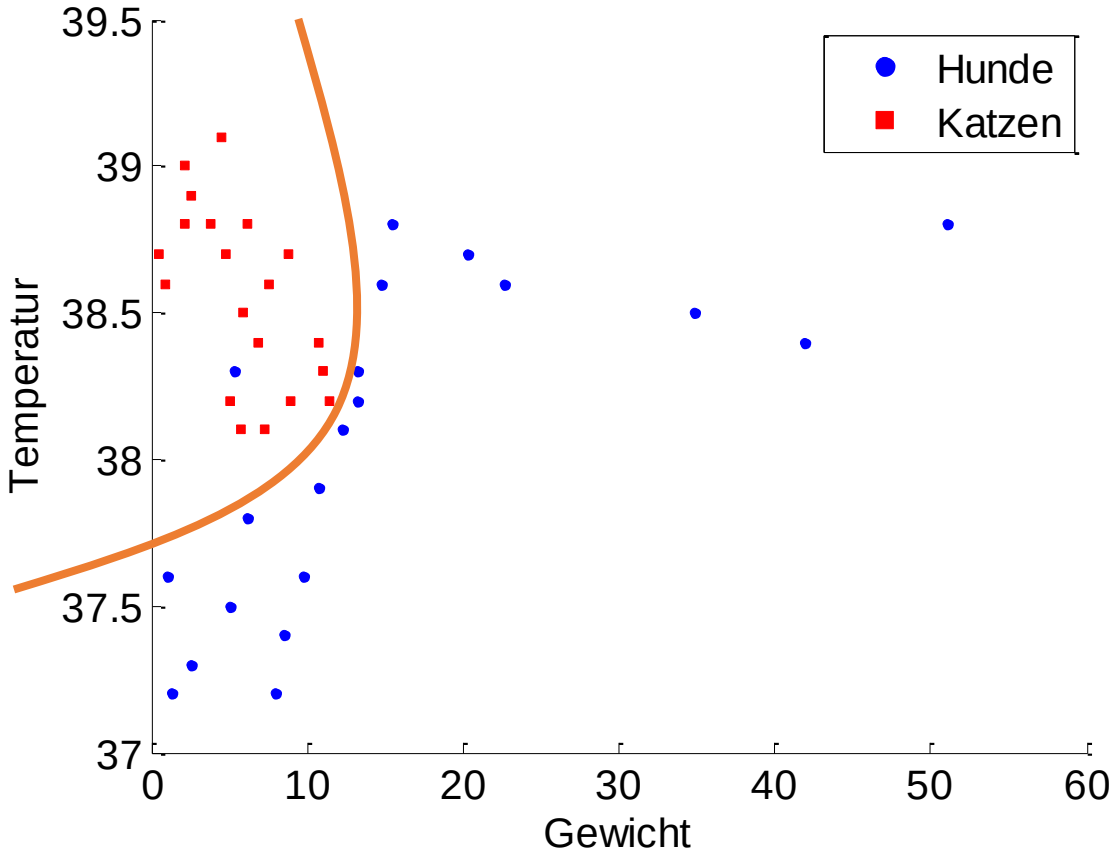

© Nicole M. Artner

Evaluierung

© Nicole M. Artner

Im Design Prozess …

… wird ständig evaluiert

- Eignung der Merkmale und ihre Kombination
- Fehlerrate und Generalisierungsfähigkeit des Modells
- Auswahl der Muster im Trainingsset
- Größe des Trainingssets
- etc.

© Nicole M. Artner

In der Anwendung …

… durch unbekannte Muster aus einem „Testset“.

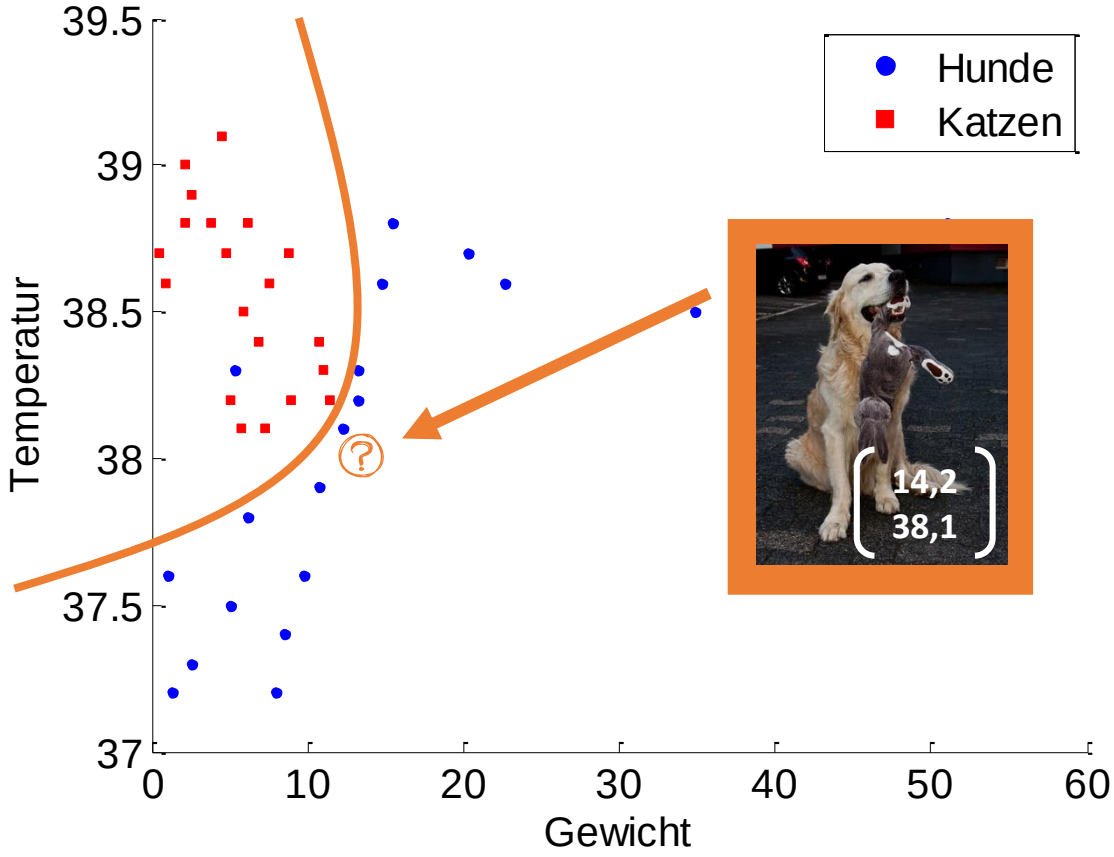

© Nicole M. Artner

Im Wettbewerb …

- PASCAL VOC: 2006
  20 Klassen

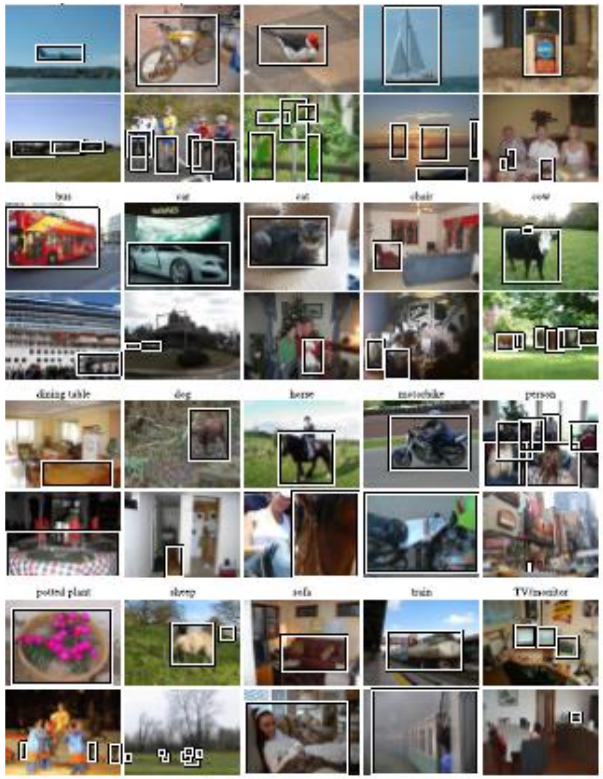

- Caltech256: 2006
  256 Klassen

© Nicole M. Artner

Im Wettbewerb …

- Imagenet: 2009 - heute
  21841 Klassen
  mehr als 14 Millionen Bilder

IMAGENET

Imagenet Challenge 2014

Quelle: http://image-net.org/challenges/LSVRC/2014/

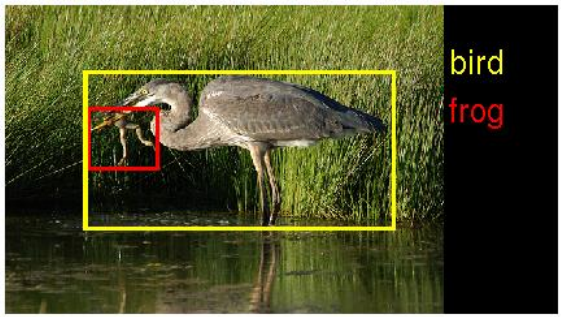

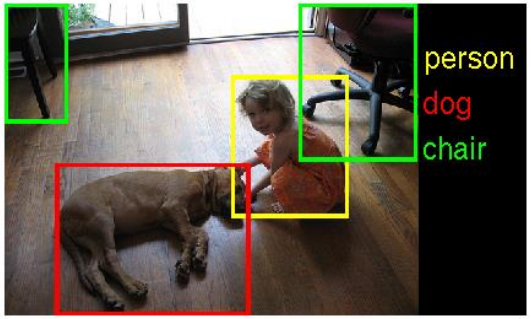

Herausforderung ME

- Menge und Verteilung der Daten
- „Clutter“ und „Noise“
- Anzahl der zu unterscheidenden Klassen
- Skalierbarkeit der Modelle
  - von 20 auf 20.000 Klassen?!?

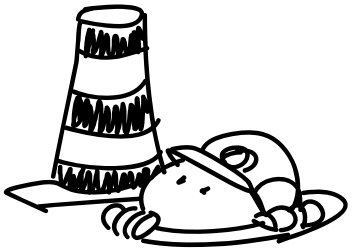

© Nicole M. Artner

Aktuelle Anwendungen von Mustererkennung

© Nicole M. Artner

Gesichtserkennung

- integriert in unseren Kameras, Handys, …
- tagging in Facebook, Google+, ...
- Viola-Jones Gesichtser-kennung implementiert in MATLAB

Quelle: https://vimeo.com/12774628

© Nicole M. Artner

Google Image Search

Bildsuche (Image Retrieval)

- Suchkriterien: meta tags, color distribution in images, region or shape attributes
- http://www.google.com/insidesearch/features/images/searchbyimage.html

Kinect v2

Microsoft Research: Vollautomatisches Hand-Tracking,
Quelle: https://www.youtube.com/watch?v=A-xXrMpOHyc