

# Mustererkennung

---

Prof. Dr.-Ing. habil. Jürgen Beyerer  
SS 2018



Karlsruhe Institute of Technology  
Universität Karlsruhe (TH)



Institut für Anthropomatik  
Lehrstuhl für Interaktive Echtzeitsysteme  
Vision and Fusion Laboratory



Fraunhofer-Institut für Optronik,  
Systemtechnik und Bildauswertung IOSB

### Forschung:

- **Bildgewinnung und -auswertung**
- **Automatische Sichtprüfung** und insbesondere **Deflektometrie**
- **Maschinelles Lernen**
- Formale **Weltmodelle** für intelligente Systeme

### Lehre:

- Automatische Sichtprüfung und Bildauswertung (Beyerer)
- Mustererkennung (Beyerer)
- Mehrdimensionale Signalverarbeitung und Bildauswertung mit Graphikkarten und anderen Mehrkernprozessoren (Perschke IOSB)
- Stochastische Planung (Huber Fa. Usu)
- Mensch-Maschine Interaktion (Geisler IOSB)
- Bildfolgenauswertung (Arens IOSB)
- Bild- und Signaldatenkompression (Pak IOSB)

# Fraunhofer IOSB

www.iosb.fraunhofer.de



Ettlingen



Karlsruhe



- Betriebs- u. Investitionshaushalt 2017 52 Mio €
- Stammpersonal 500
  - davon Wissenschaftler und Ingenieure 321
- Zusätzlich: Wissensch. Hilfskräfte ca. 180

Professur »Interaktive Echtzeitsysteme IES«, KIT

Professur »Optronik«, KIT

Professur »Energieeinsatzoptimierung«, TU Ilmenau

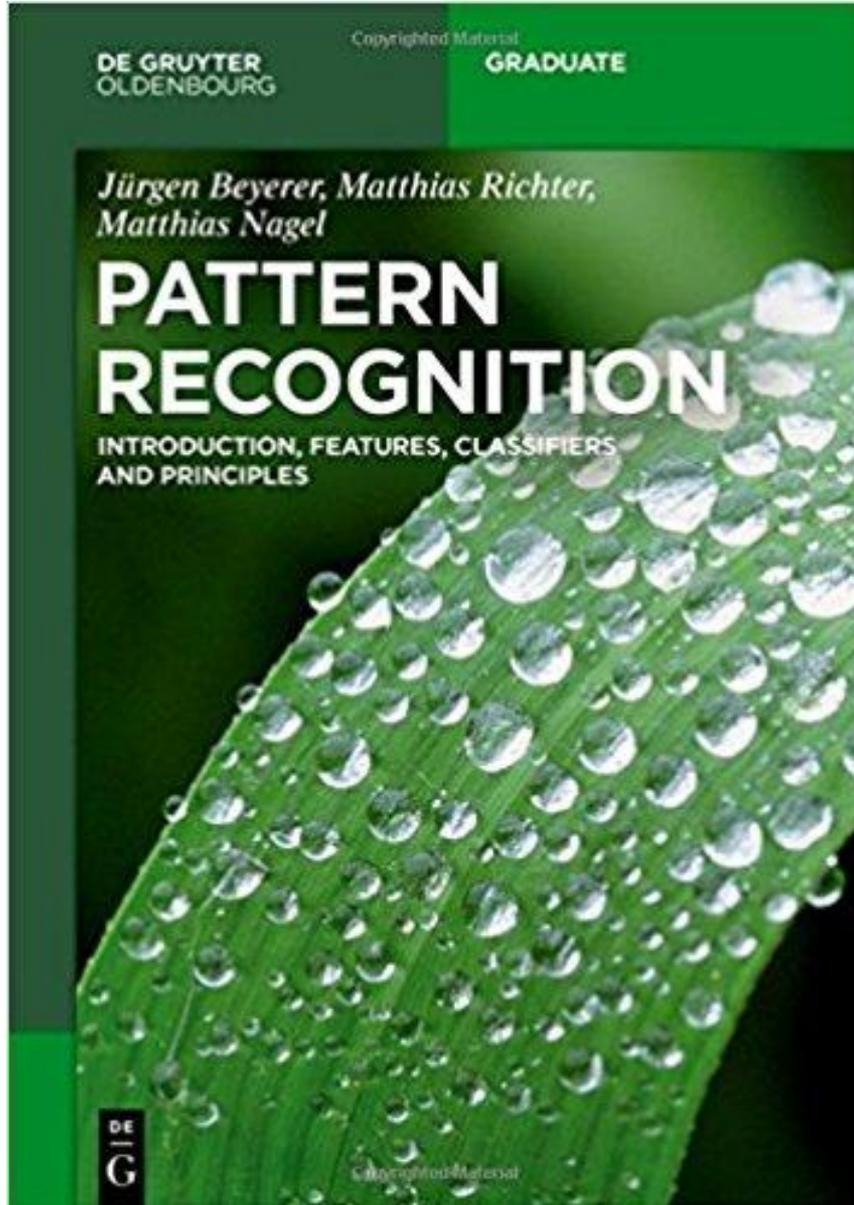
Professur »Kognitive Automation«, Universität Bielefeld (*Bewerbungsphase*)



---

# 1. Einleitung

# 1. Einleitung



Buch zur Vorlesung:  
De Gruyter Verlag 2018

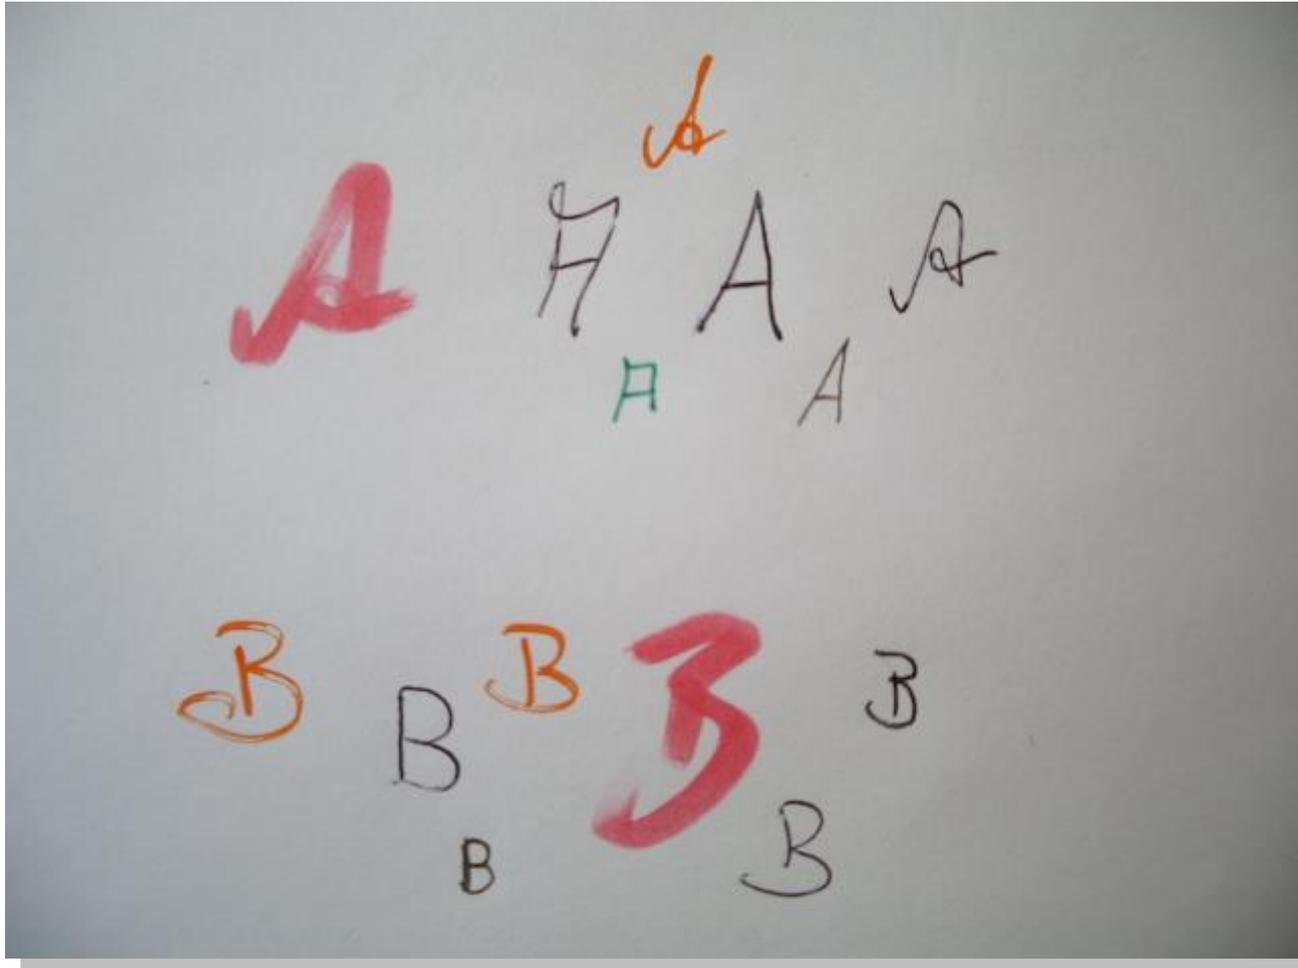
# 1. Einleitung

Künstliche Objekte, Beispiele:



# 1. Einleitung

Künstliche Objekte, Beispiel:



# 1. Einleitung

Natürliche Objekte, Beispiele:



# 1. Einleitung

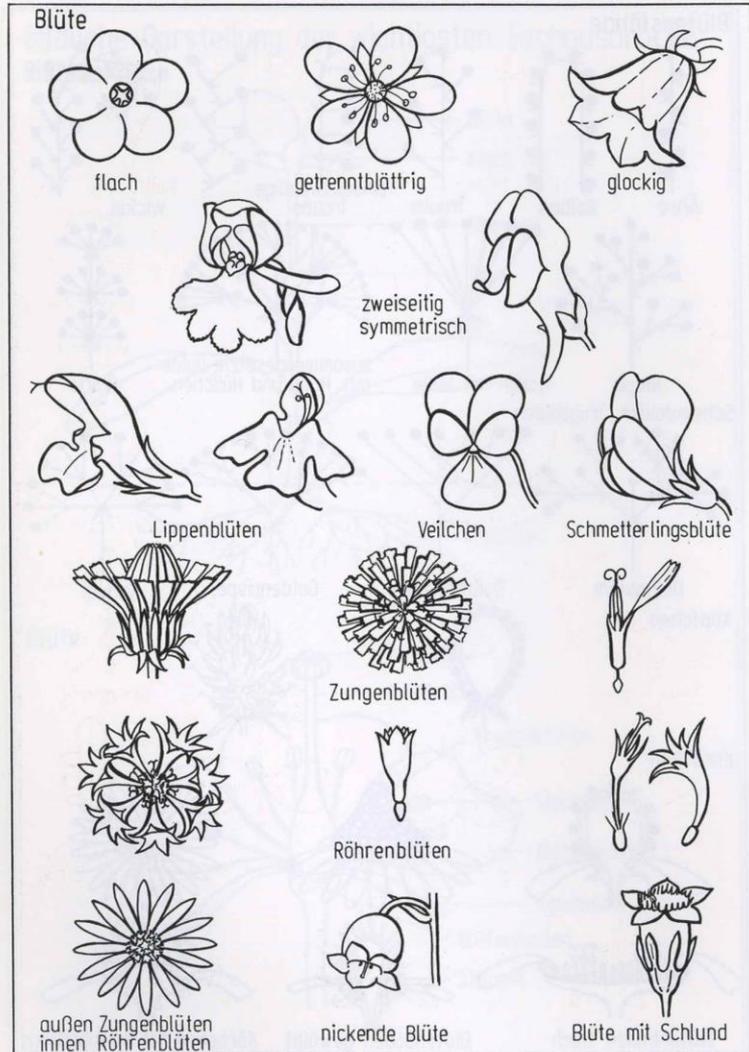
---

Natürliche Objekte, Beispiele:

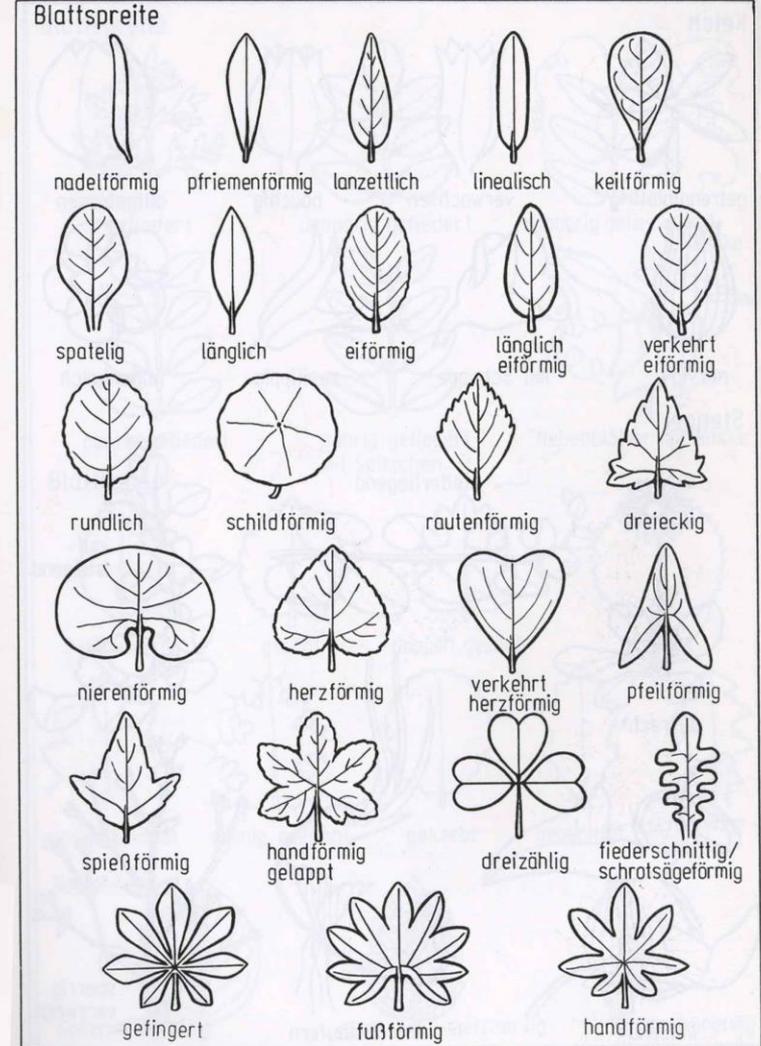


# 1. Einleitung

## Beispiel: Klassifikation von Blütenpflanzen 1



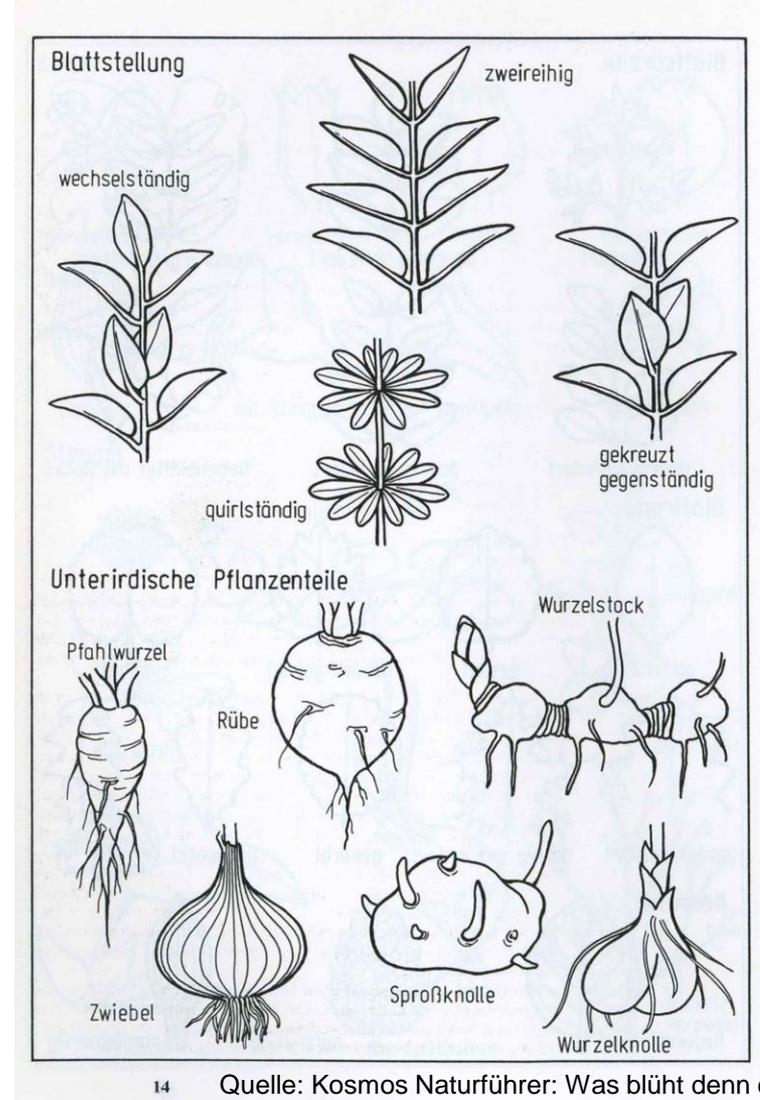
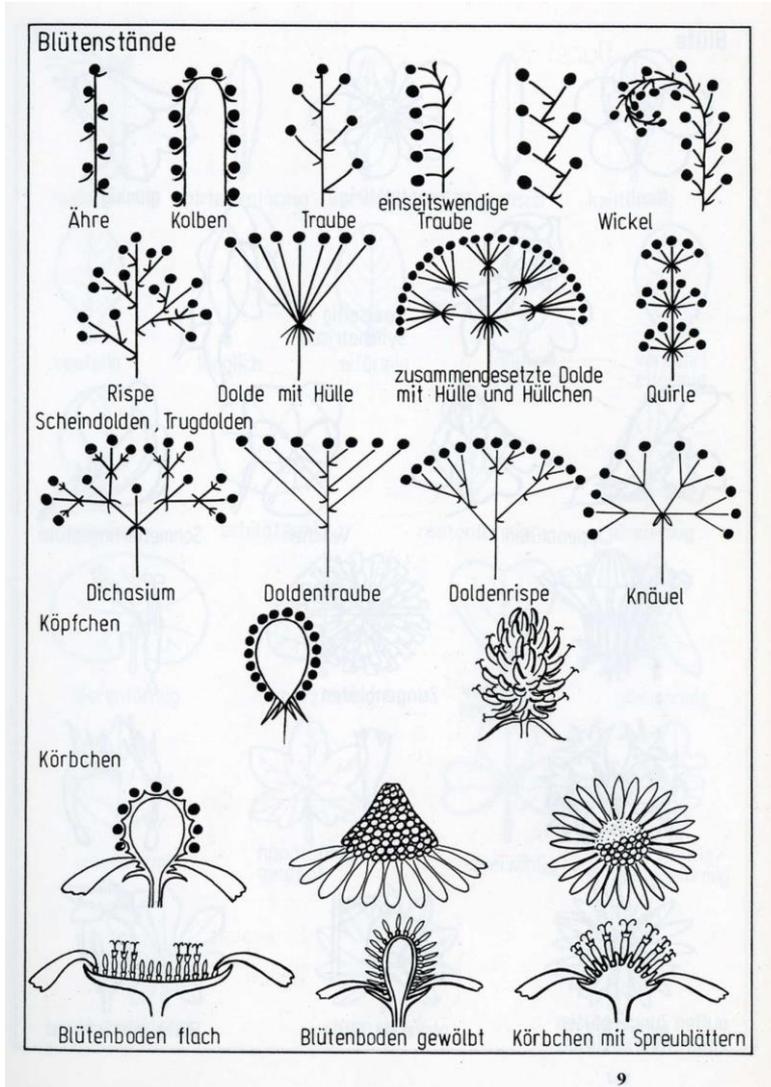
10



Quelle: Kosmos Naturführer: Was blüht denn da?

# 1. Einleitung

## Beispiel: Klassifikation von Blütenpflanzen 3



# 1. Einleitung

## Beispiel: Klassifikation von Schmetterlingen 1

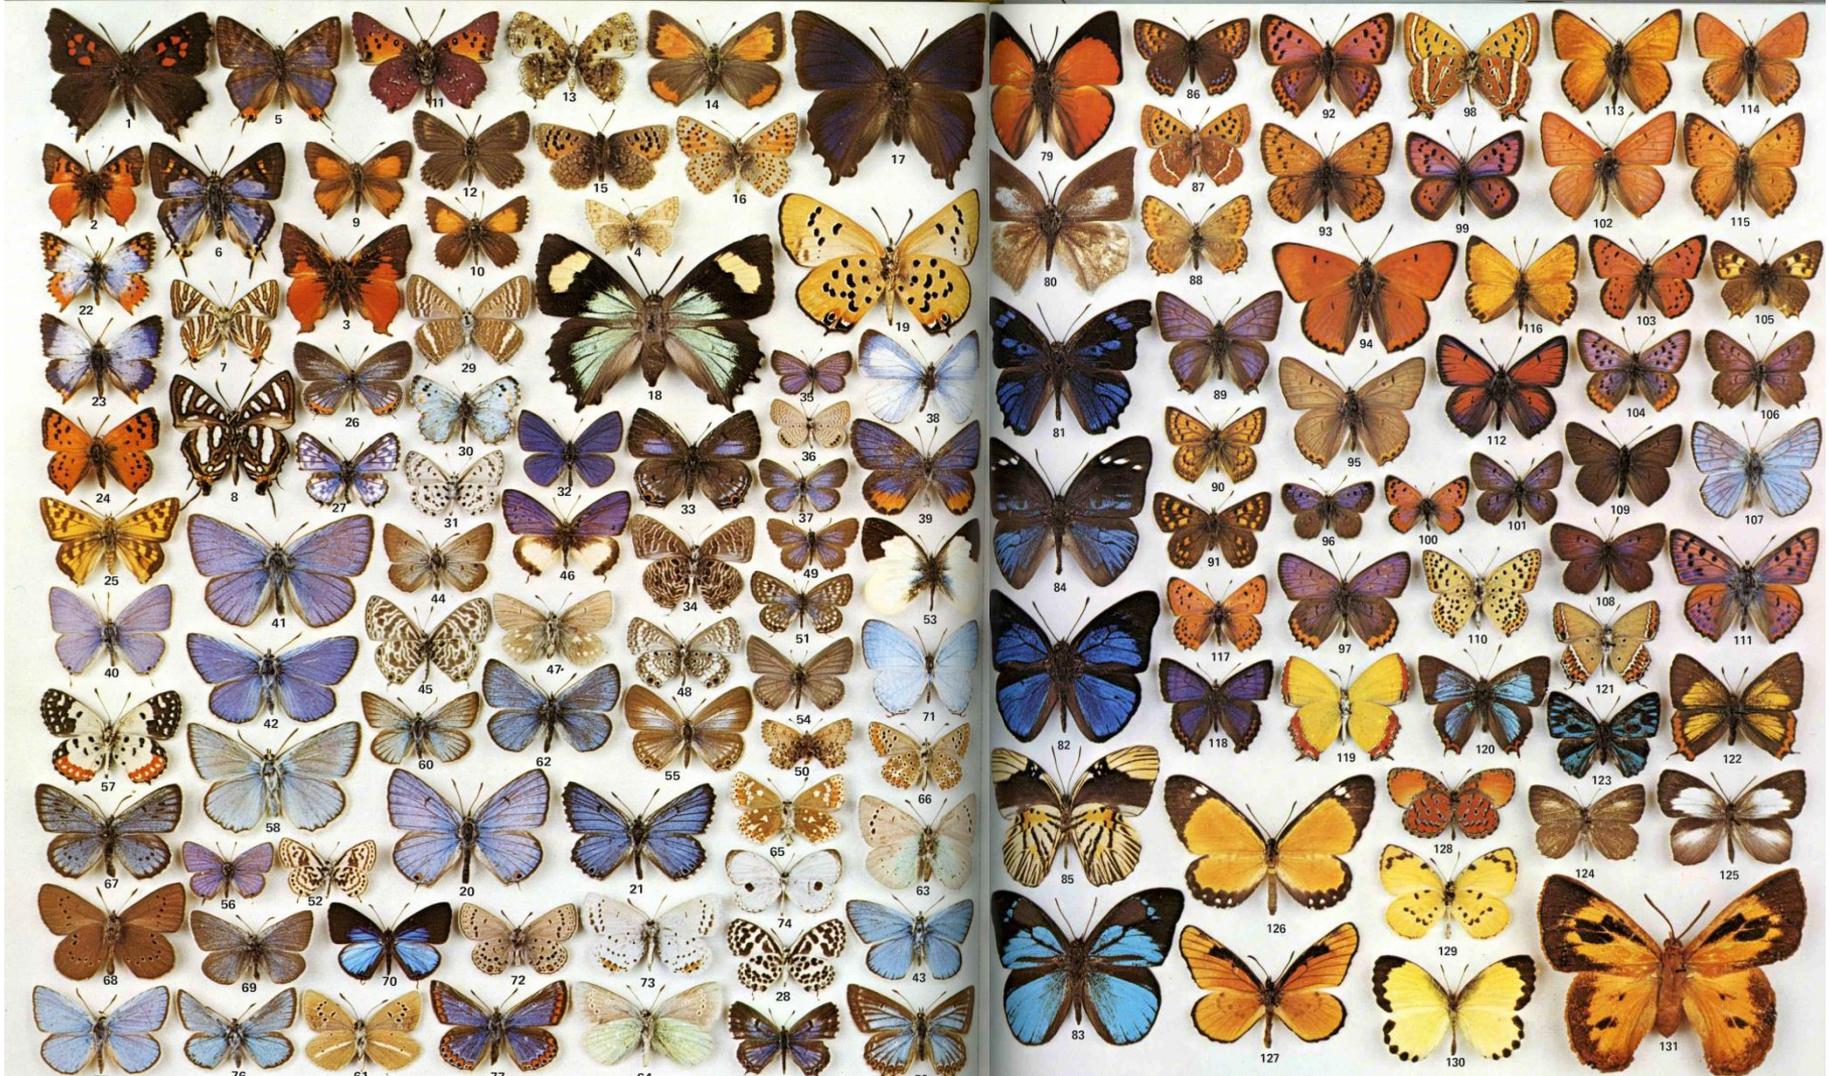
- > 150.000 Arten Schmetterlinge
- ca. 20.000 Tagfalterarten
- > 130.000 Nachtfalterarten



Quelle: Paul Smart, Enzyklopädie der Schmetterlinge

# 1. Einleitung

## Beispiel: Klassifikation von Schmetterlingen 3



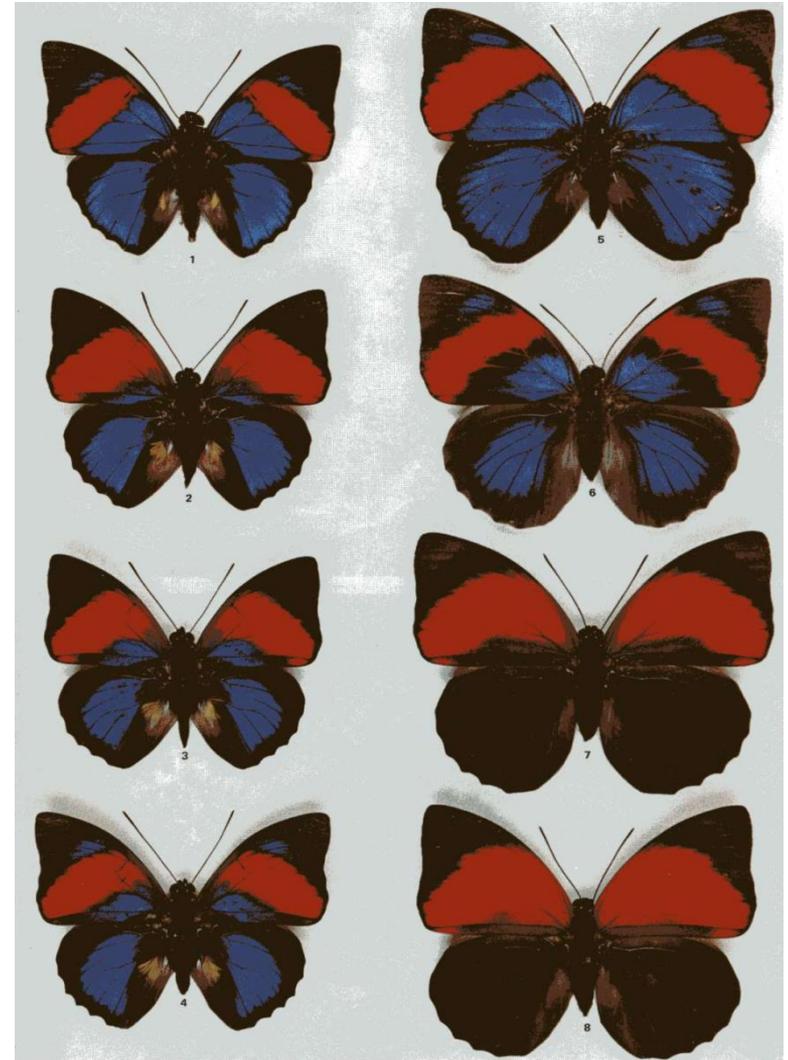
Quelle: Paul Smart, Enzyklopädie der Schmetterlinge

# 1. Einleitung

## Beispiel: Klassifikation von Schmetterlingen 4

Variationen innerhalb einer Art,  
Bsp.: *Agrias aedon*, Südamerika

♂ linke Spalte ♀ rechte Spalte



Quelle: Paul Smart, Enzyklopädie der Schmetterlinge

# 1. Einleitung

## Beispiel: Klassifikation zur Schüttgutsortierung 1

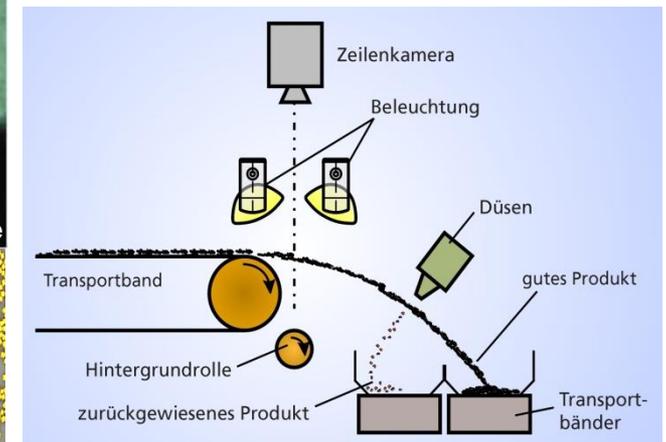


Quelle: Fraunhofer-IOSB Karlsruhe



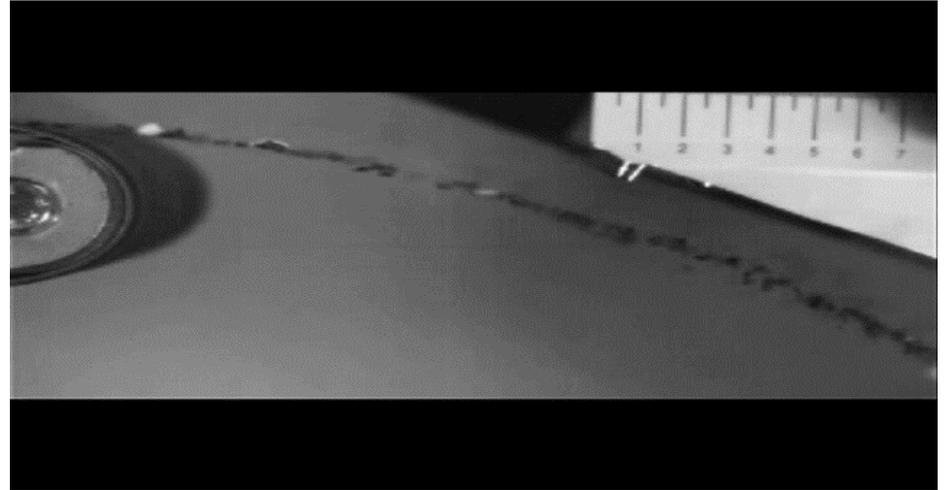
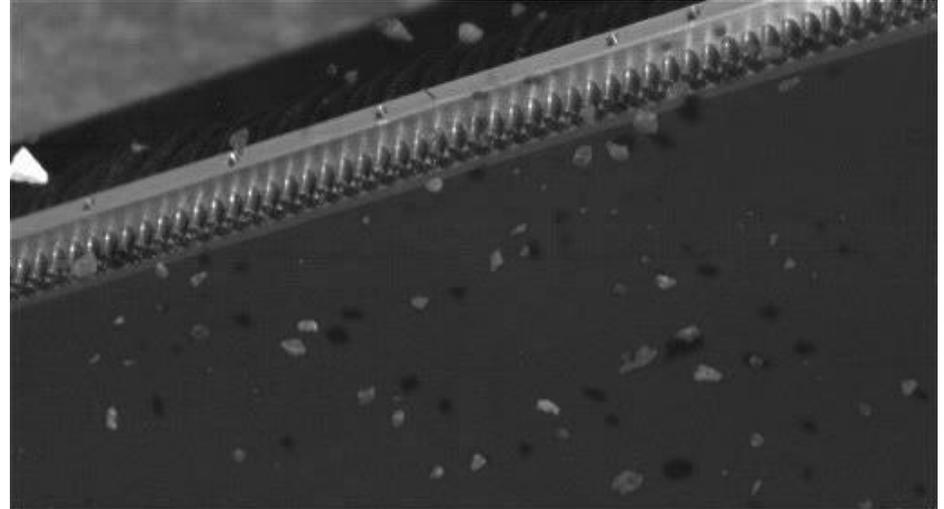
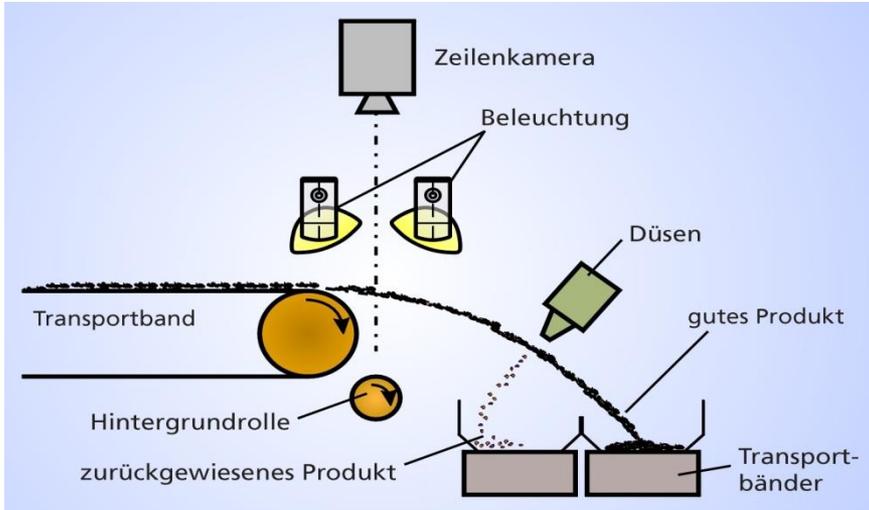
### Bsp. für Schüttgüter:

- Mineralien
- Pflanzenteile
- Granulate
- Glasscherben
- Diamanten
- Müll usw.



# 1. Einleitung

## Beispiel: Klassifikation zur Schüttgutsortierung 2



Förderung des Schüttgutes

Trennvorgang in Zeitlupe

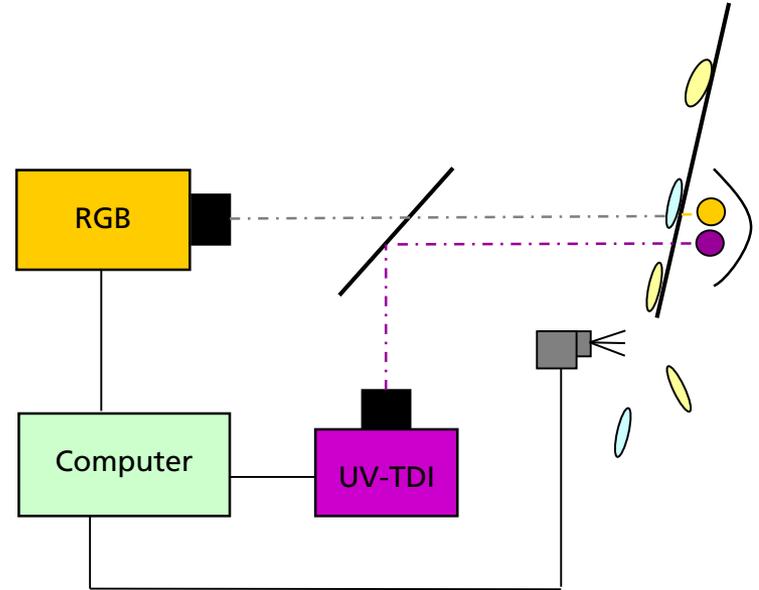
# 1. Einleitung

## RGB/UV sensor fusion for sorting out heat-resistant glass



Glass for Recycling

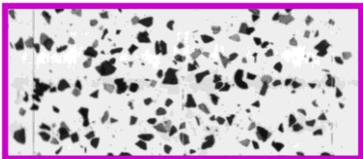
Problems through heat-resistant glass



Quelle: Fraunhofer-IOSB Karlsruhe

## Industrial Sensor System: Austrian State Award for Innovation 2010

VIS-RGB

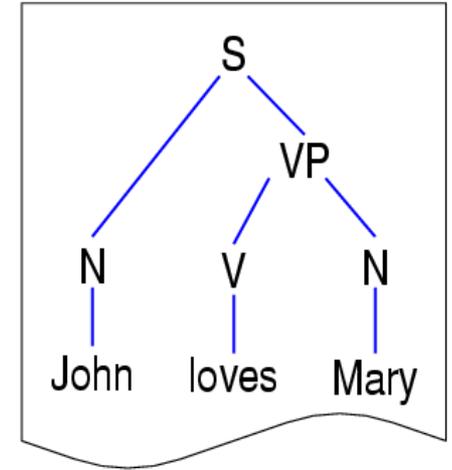
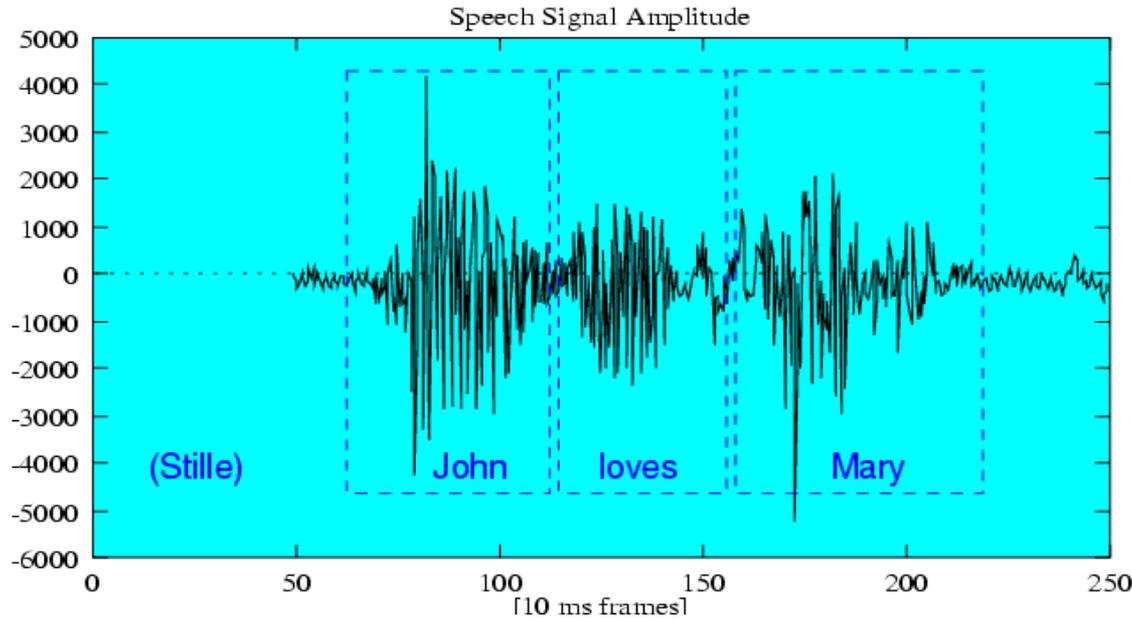


UV



# 1. Einleitung

## Beispiel: Erkennung von Sprache und Schrift



Vorlesung Mustererkennung: E.G. Schukat Talamazzini

Schrift-  
erkennung



Schrifterkennung

# 1. Einleitung

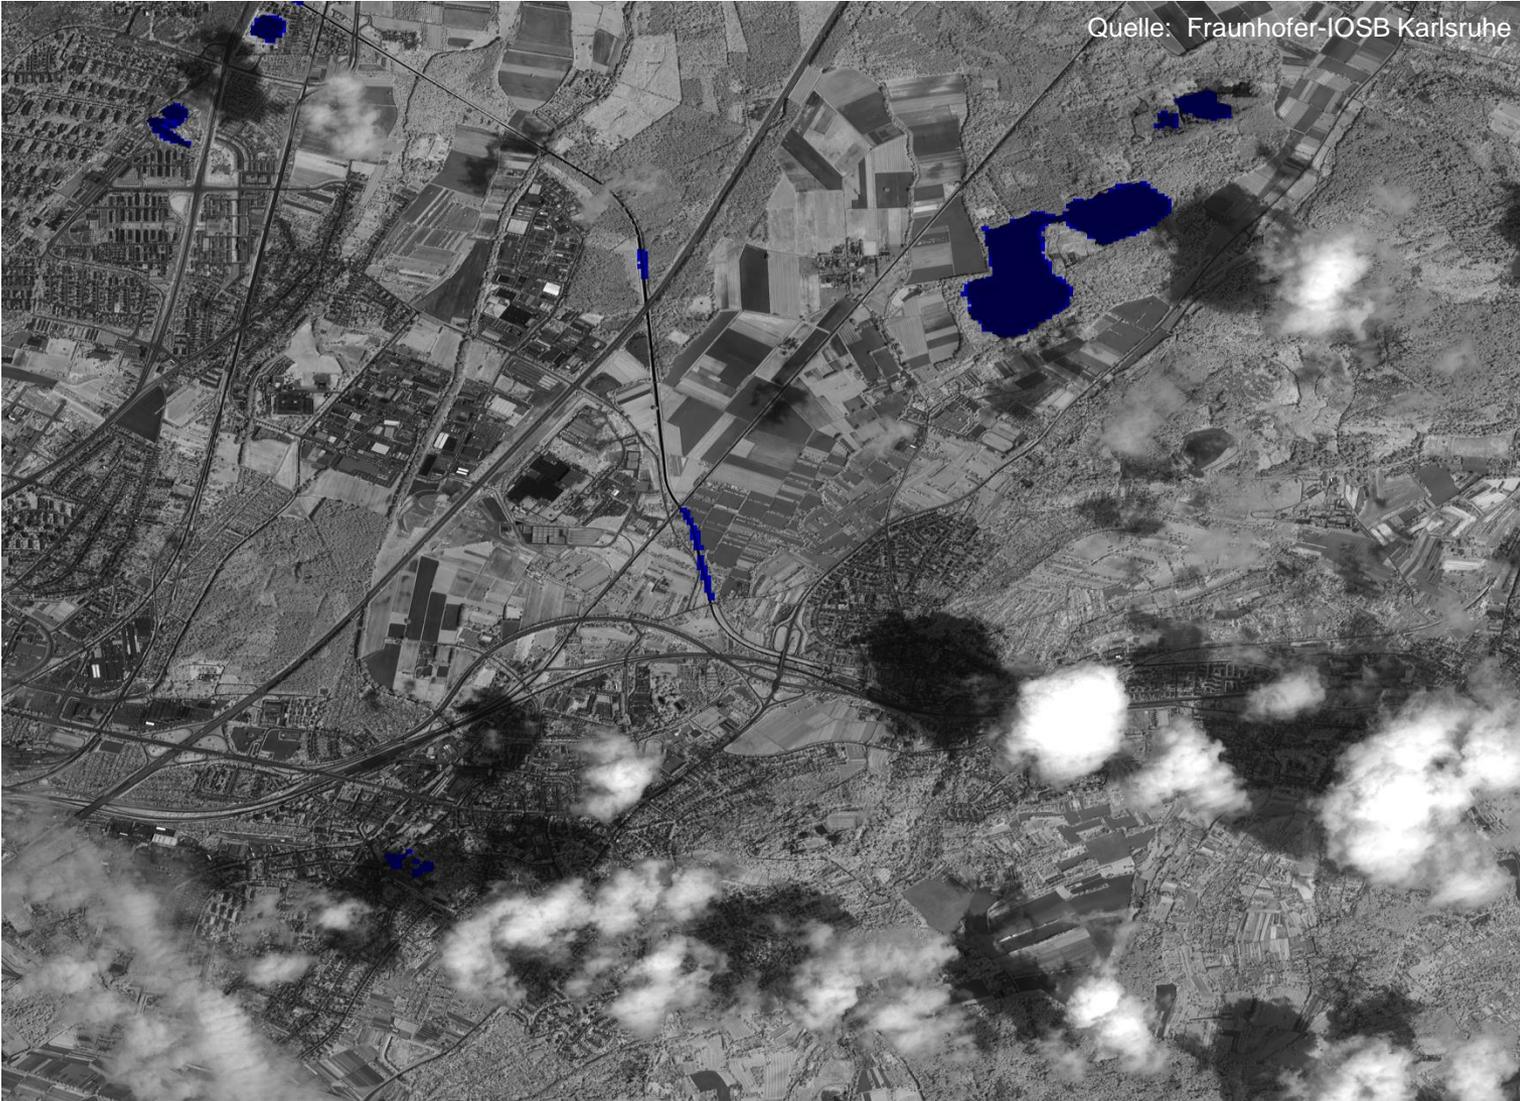
## Beispiel: Luftbildauswertung 1: Detektion von Bäumen



Quelle: Fraunhofer-IOSB Karlsruhe

# 1. Einleitung

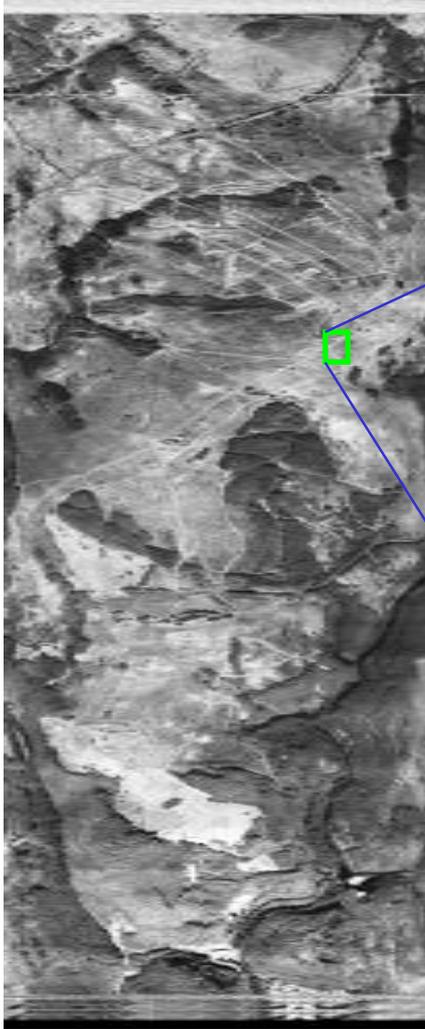
## Beispiel: Luftbildauswertung 2: Detektion von Gewässern



© 2018 Lehrstuhl für Interaktive Echtzeitsysteme, KIT, alle Rechte einschließlich Kopier- und Weitergaberechte bei uns.

# 1. Einleitung

## Beispiel: Luftbildauswertung 3: Automatisches Screening großer Bilder



12.000 × 240.000 Pixel



Quelle: Fraunhofer-IOSB Karlsruhe

© 2018 Lehrstuhl für Interaktive Echtzeitsysteme, KIT, alle Rechte einschließlich Kopier- und Weitergaberechte bei uns.

# 1. Einleitung

## Beispiel: Intelligente Gemüsewaage

Automatische Klassifikation von Frucht- und Gemüsesorten im Supermarkt

Herausforderungen:

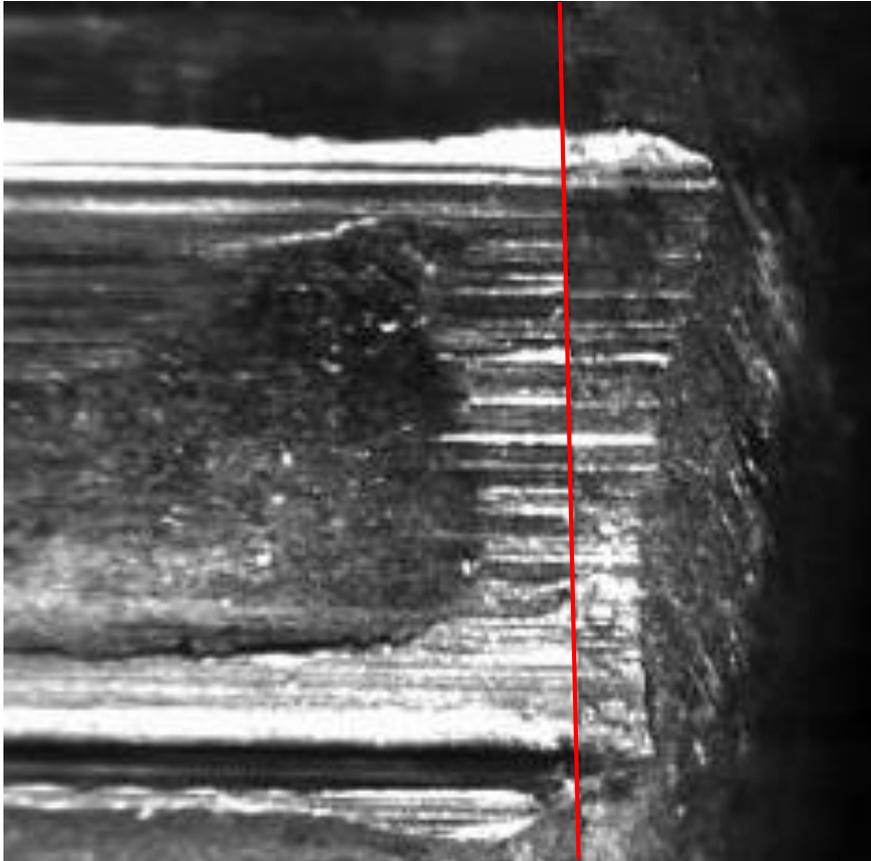
- Variable Lichtverhältnisse
- Variationsvielfalt und Ähnlichkeit der Zielobjekte
- Verpackung (milchige Tüten, etc.)
- Kundeninteraktion (u.a. auch Betrug)



# 1. Einleitung

## Beispiel: Kriminaltechnik 1

- Vergleich von Schusswaffenspuren



Schusswaffenprojektil



Patronenhülse

# 1. Einleitung

## Beispiel: Künstliche Hand – Klassifikation von Griffsituationen



Quelle: Forschungszentrum Karlsruhe, Institut für Angewandte Informatik, KIT, Prof. Dr.-Ing. G. Bretthauer

# 1. Einleitung

Beispiel: Suchen verwandter Bilder anhand von Bildbeispielen



Search template

<http://simba.informatik.uni-freiburg.de/cgi-simba/SIMBA.cgi>



0.992850



0.732900



0.692550



0.679800



0.658300



0.645725



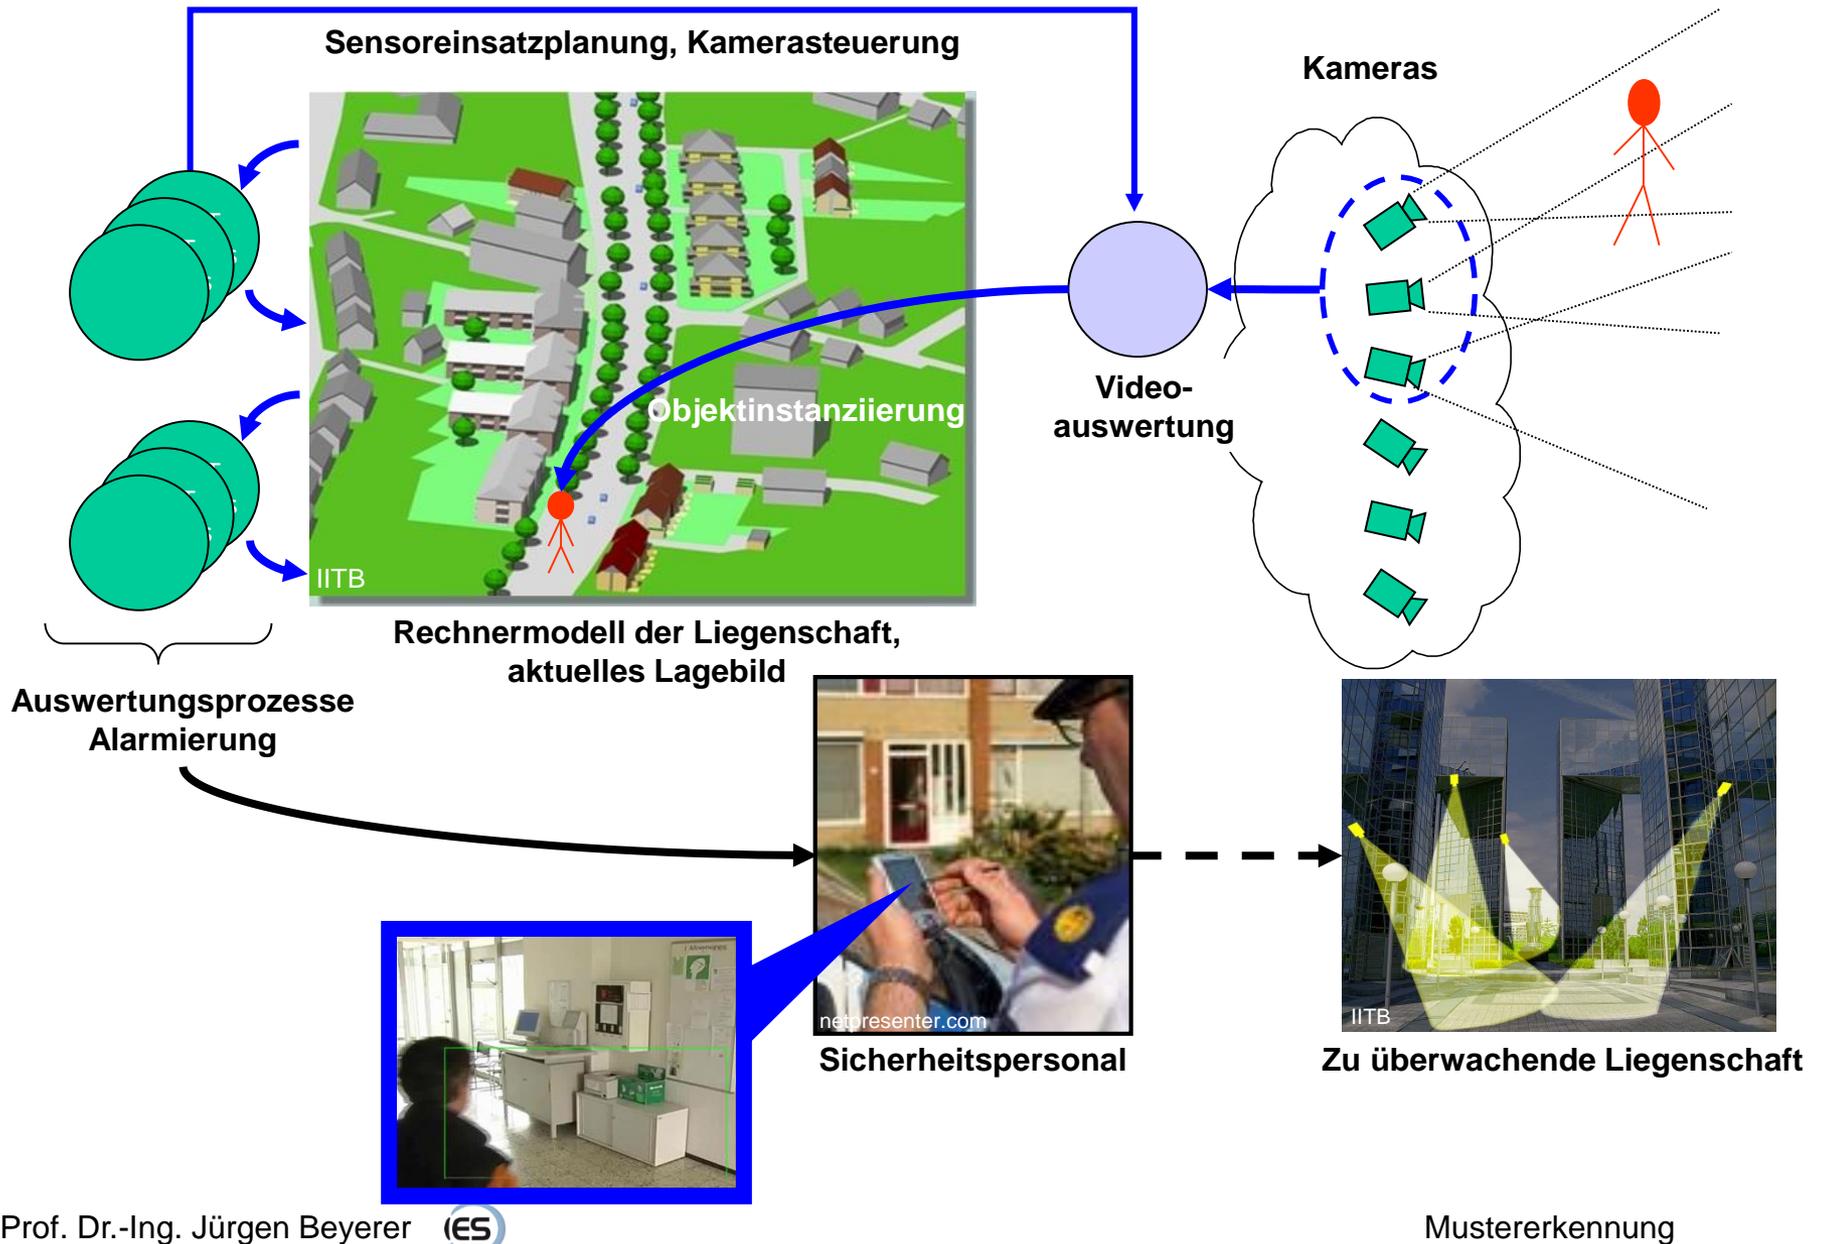
0.640700

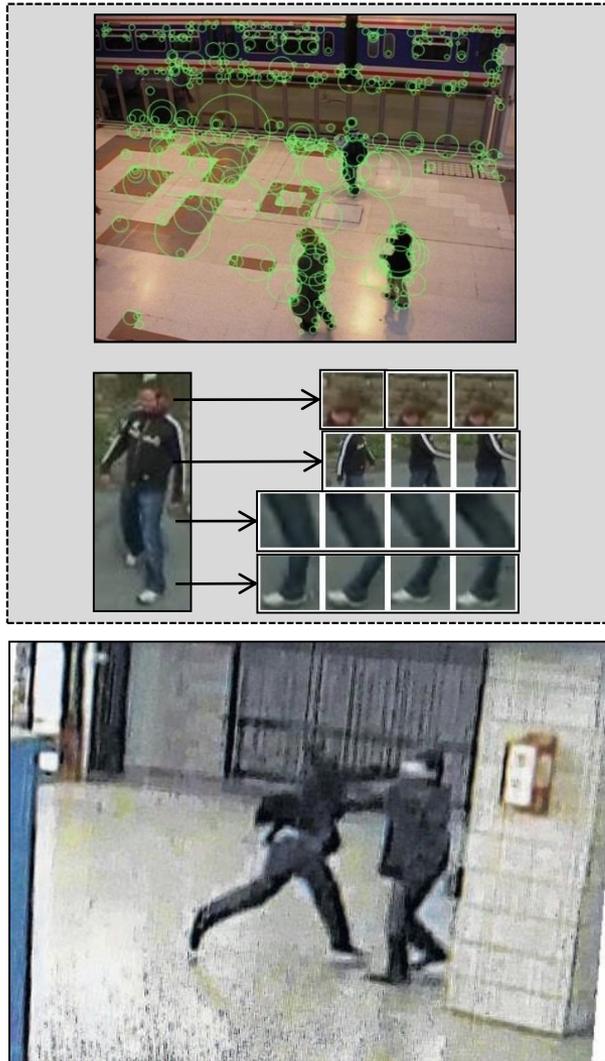


0.639350

# 1. Einleitung

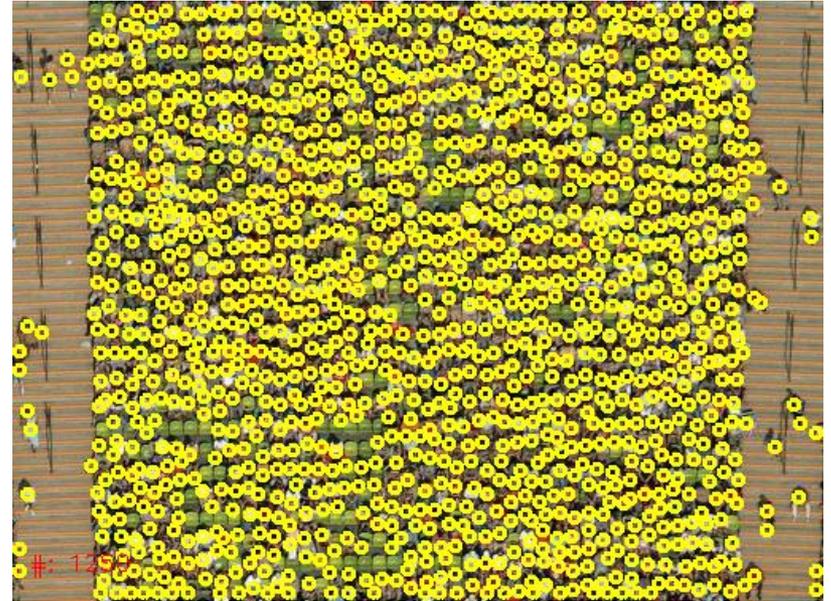
# Beispiel: Videoüberwachung





# 1. Einleitung

## Beispiel: Luftbildauswertung – Personenzählung



- Luftbild: 510 x 383 Pixel
- Persongröße ca. 9 x 12 Pixel

Gezählt: 1250 Personen

# 1. Einleitung

## Beispiel: Luftbildauswertung – Personenzählung



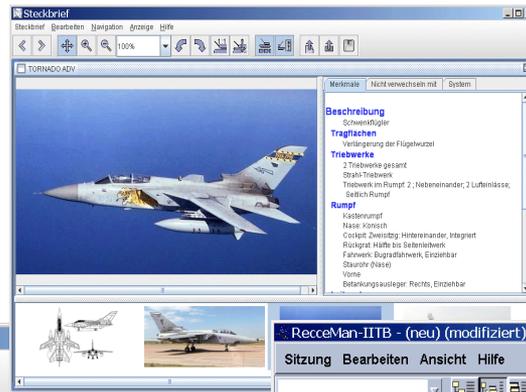
Eine Szene von „Stuttgart 21“ – Gezählte Personen: 11594

# 1. Einleitung

Bsp.: Interaktive Assistenz für Bildauswerter bei der Objekterkennung

Zur Erkennung von:

- Landfahrzeugen
- Flugzeugen
- Schiffen



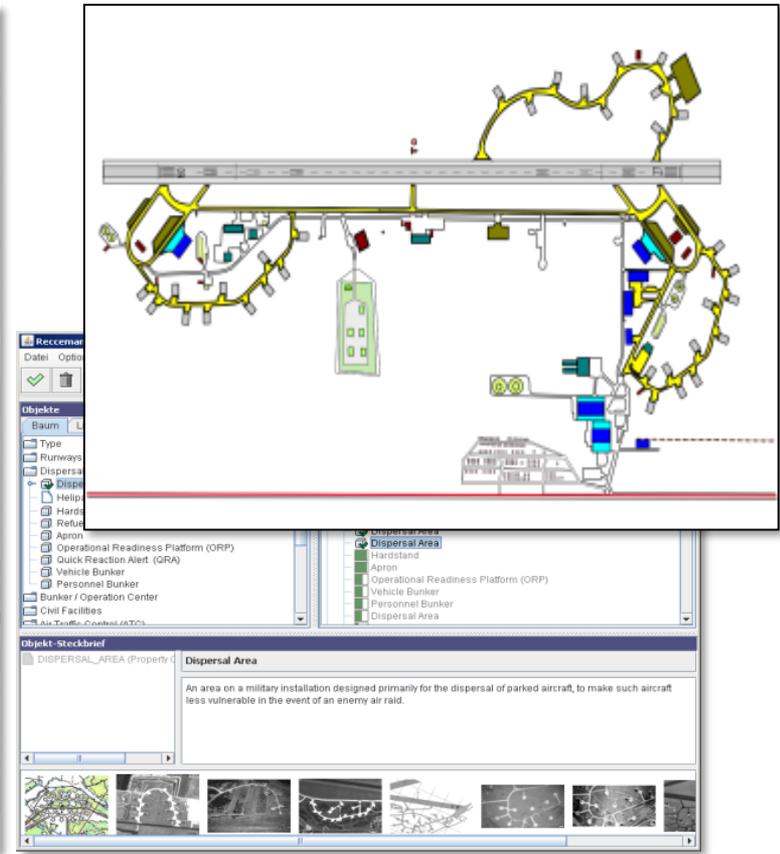
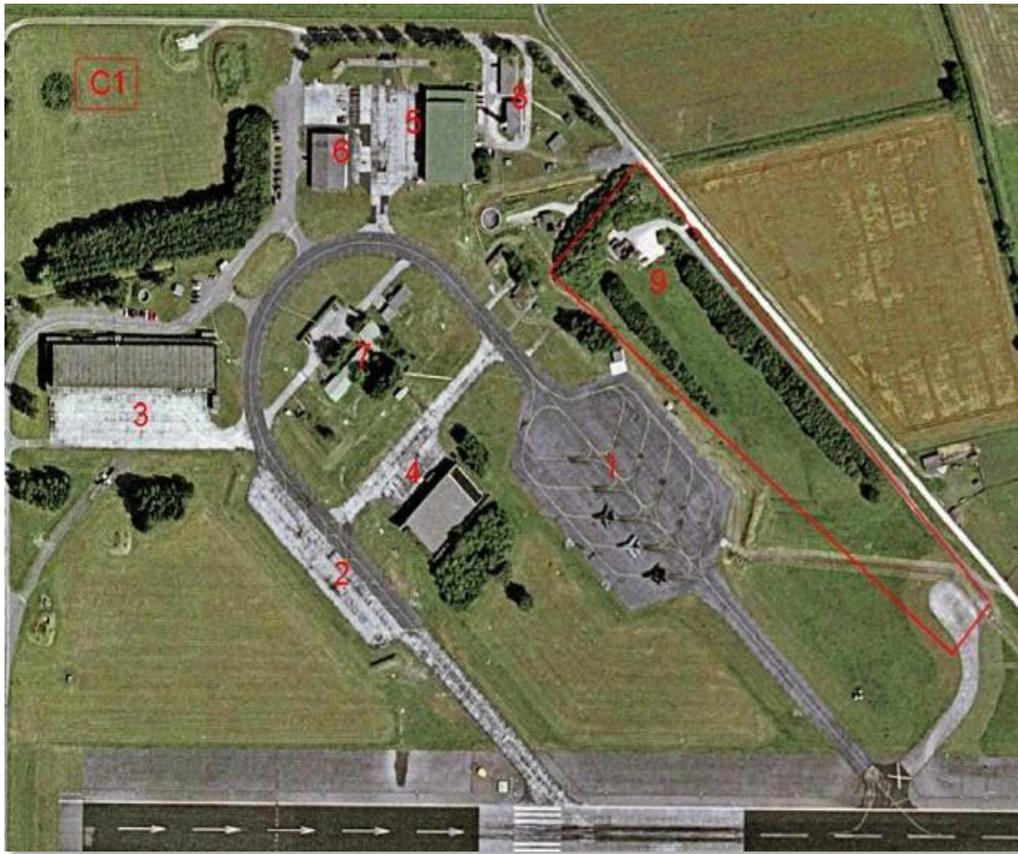
Objekte	Treffer	Klasse	Bilder
	1/1	TU-95 BEAR	
	1/1	U-2 S	
	1/1	VP-3 A ORION	
	0/1	A-109.A HIRUNDO	
	0/1	A-109.A II HIRUNDO	

Seit 2009 im Einsatz bei der Bundeswehr



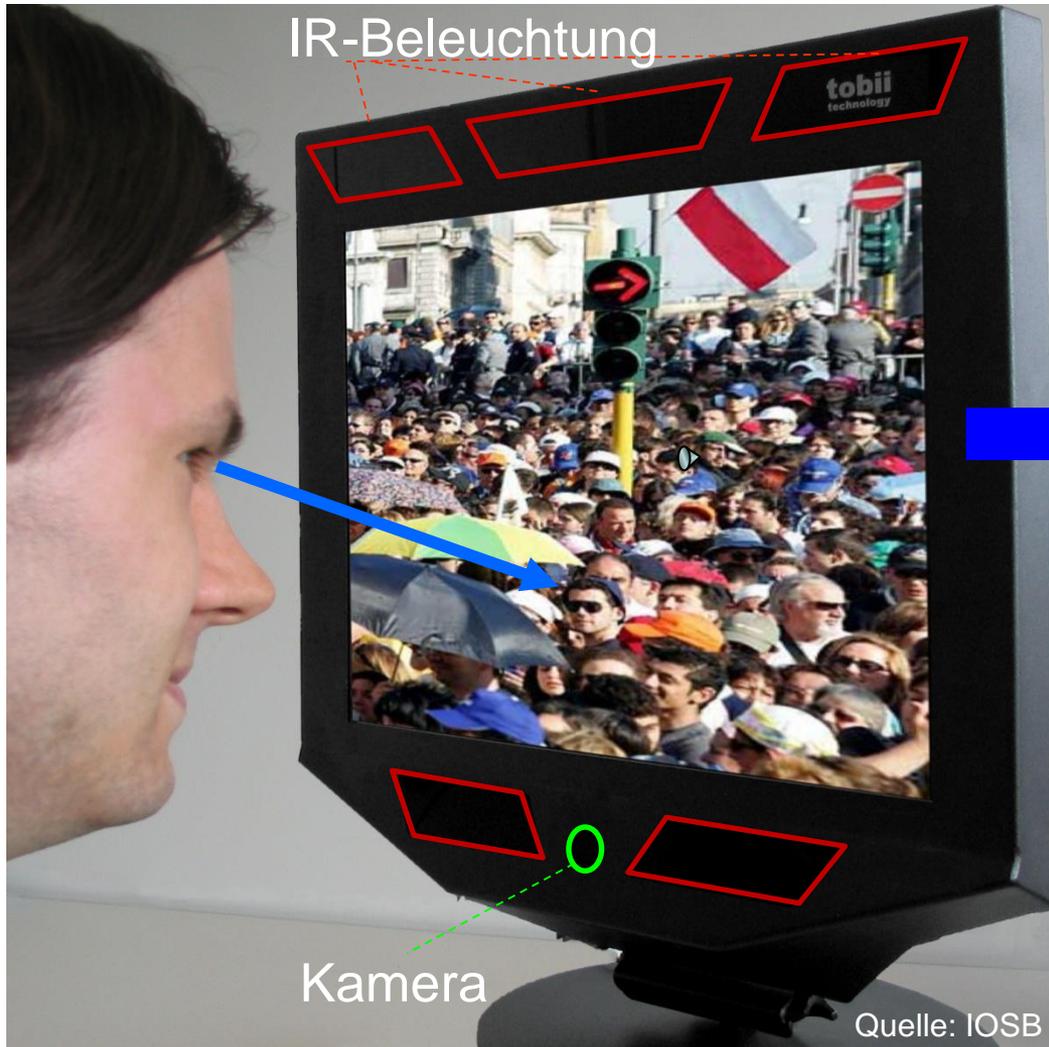
# Interaktiver Erkennungsassistent »RecceMan«

Wissensbasierte Assistenz für Bildauswerter  
zur **Analyse von Infrastruktur**: Flugplätze, Häfen und Industrieanlagen



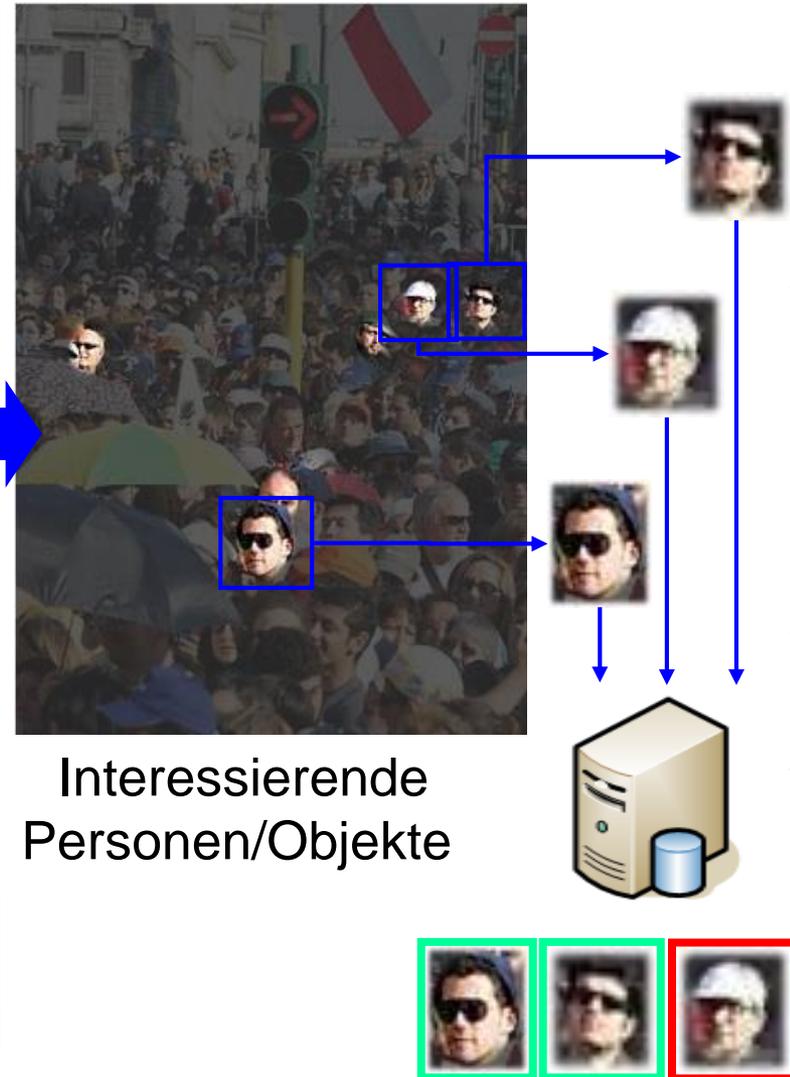
# 1. Einleitung

## Beispiel: Blickinduzierte Objektauswahl



Quelle: IOSB

### Bildschirm mit integrierter Blickverfolgung

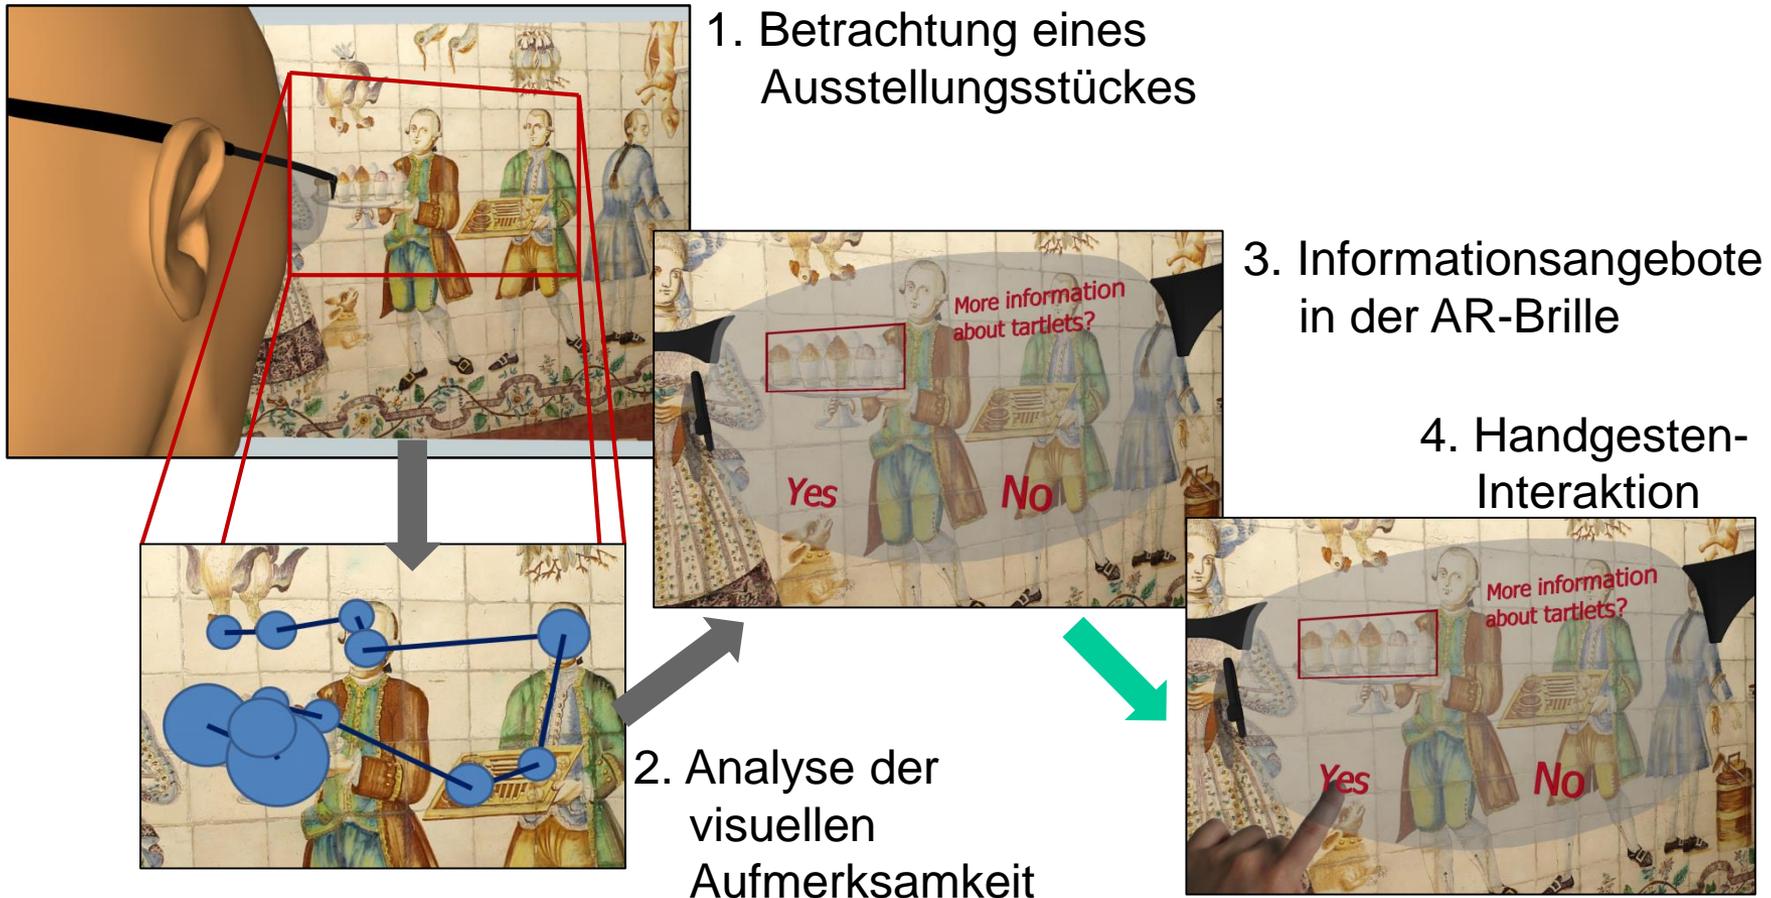


Interessierende  
Personen/Objekte

Mustererkennung

# Adaptive Augmented Reality (AR) mit instrumentierten Brillen

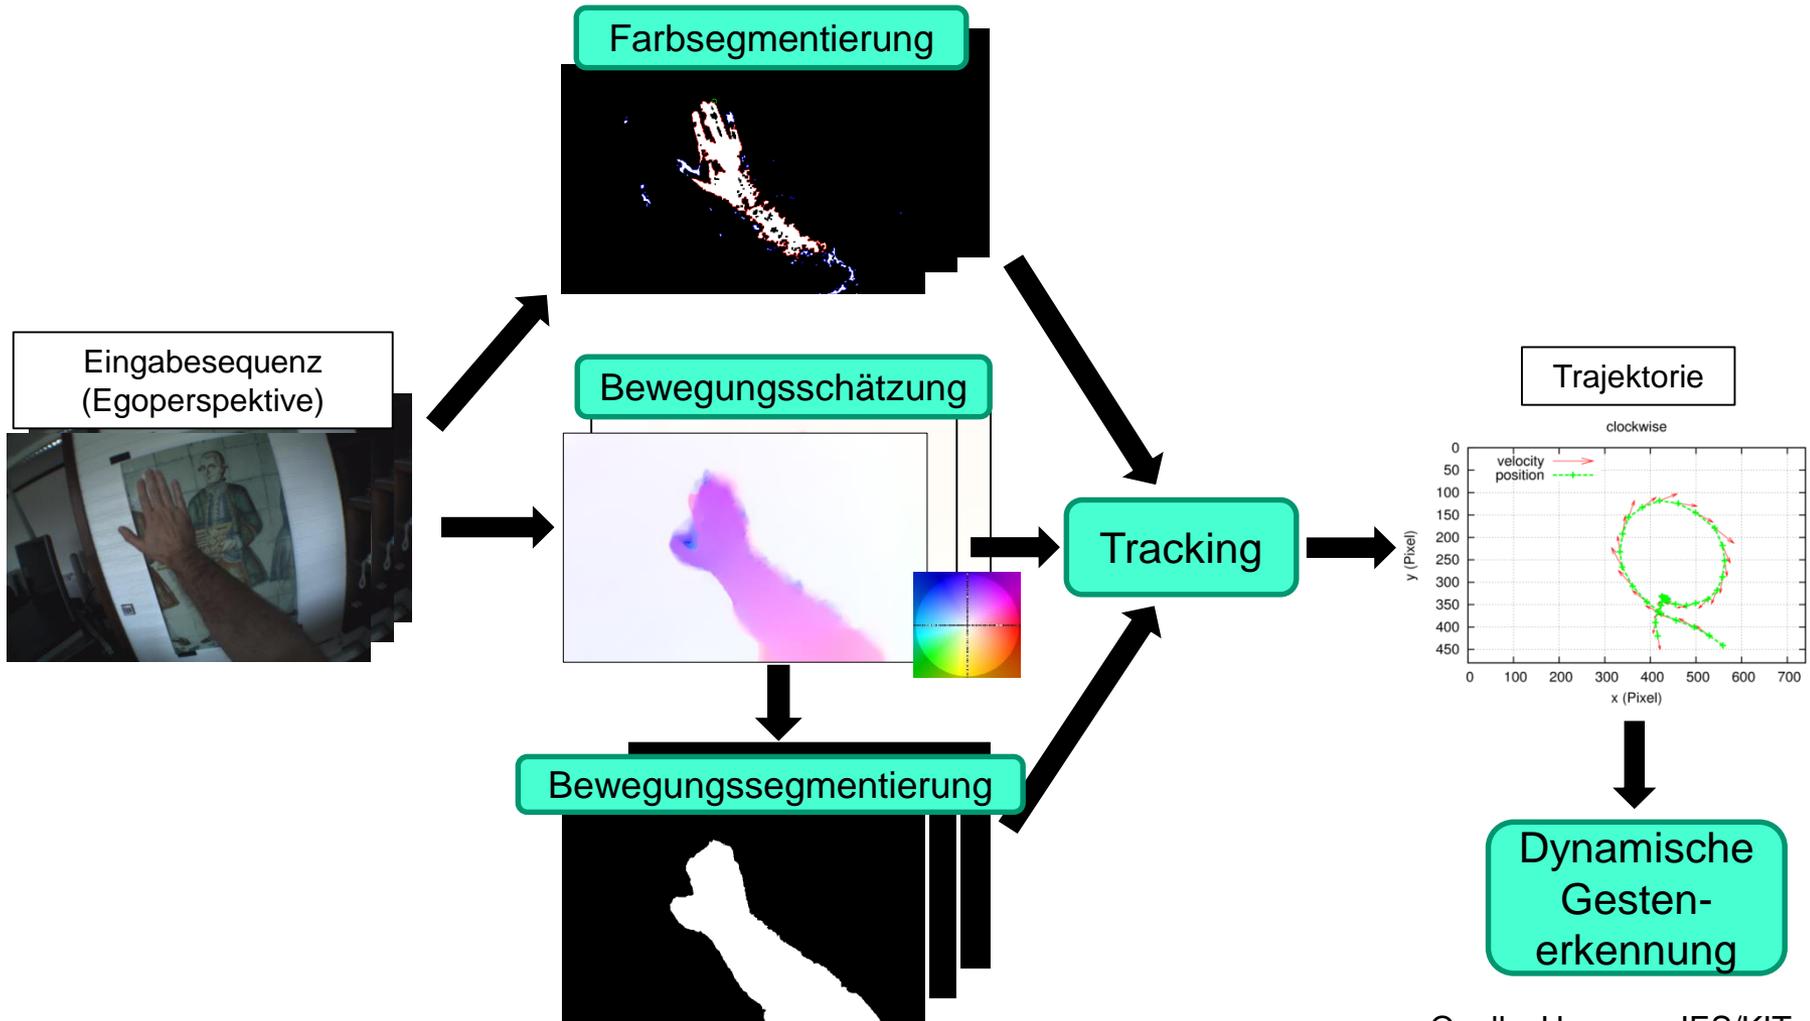
## Anwendungsfall: Museum



Quelle: Hammer, IES/KIT

# 1. Einleitung

## Handgesten-Interaktion aus Ego-Perspektive



Quelle: Hammer, IES/KIT

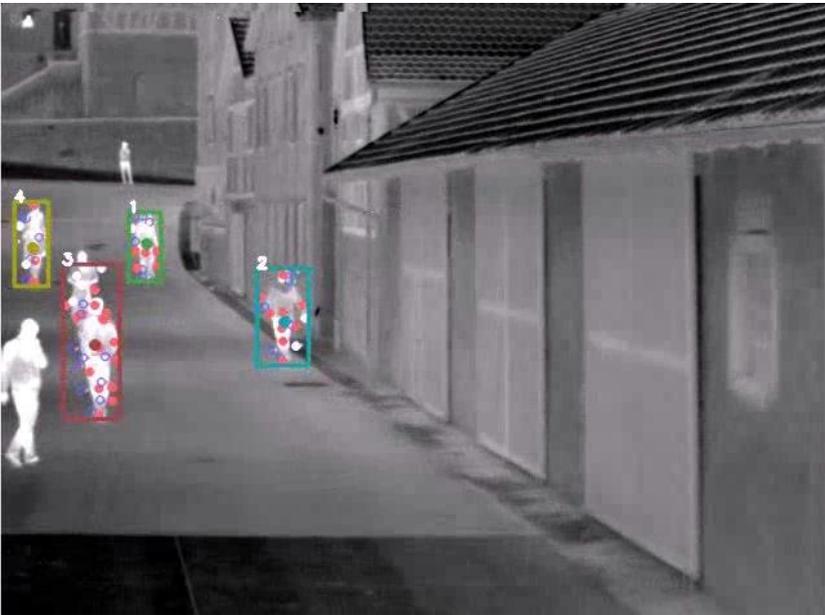
# 1. Einleitung



*Implicit Shape Model (ISM)*  
basierte Lokalisierung  
anatomischer Landmarken

- Personendetektion + Posenschätzung  
auf Basis desselben ISM- Modells
- Neue Voting-Verfahren

Quelle: Dr. Brauer, IOSB

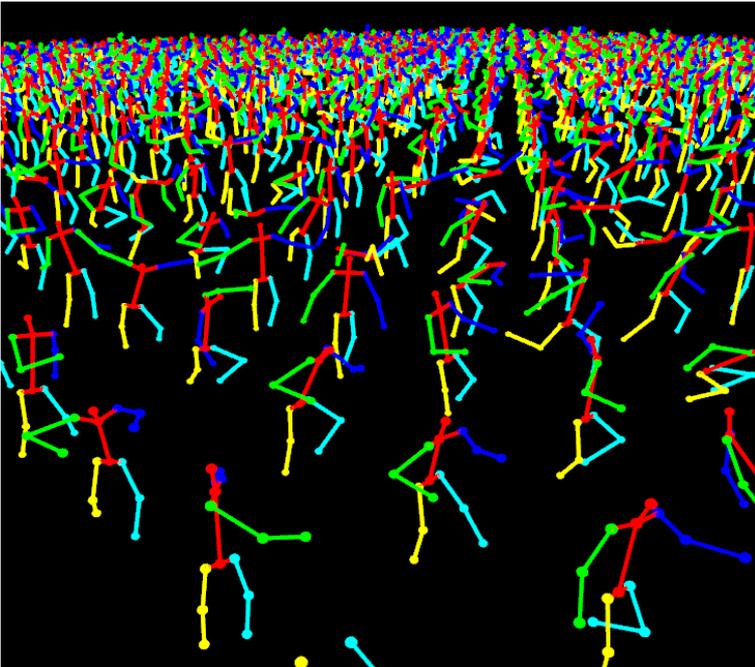


# 1. Einleitung

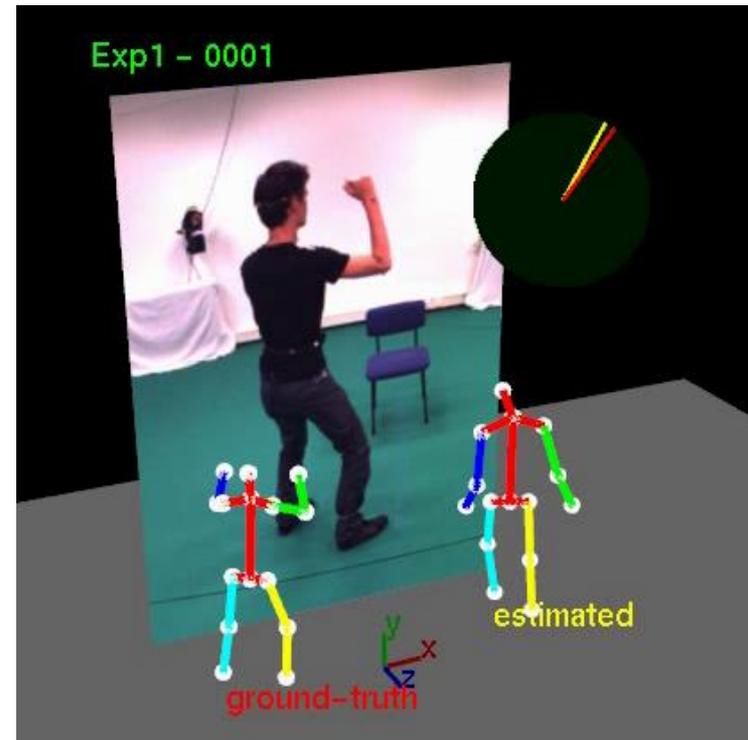
## 3D-Posenschätzung auf Basis von Voteverteilungen

- Projektion von 3D-Landmarkenhypothesen auf die Landmarken-Vote-Verteilungen + Partikel-Schwarm-Optimierung
- Sehr schneller Vergleich mittels Integralbildern  
→ Vergleich mehrerer Millionen von 3D-Modellposen mit einem Bild pro Sekunde

Posenvorwissen in Form von 3D-Beispielposen



## Monokulare, Einzelbildbasierte 3D-Posenschätzung



Quelle: Dr. Brauer, IOSB  
Mustererkennung

# 1. Einleitung

## Beispiel: Modellgestützte Objekterkennung 1

Digitale Luftaufnahme  
(Frankfurter Flughafen)



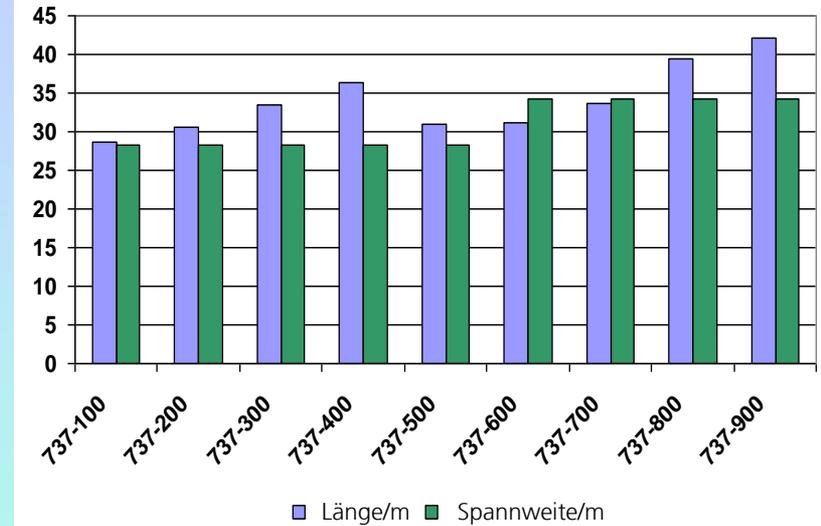
ca. 18.000 x 18.000 Pixel

Bodenauflösung: ca. 16 cm pro Pixel

Bildausschnitt



Boeing 737 Varianten



Quelle: Fraunhofer-IOSB Karlsruhe, Prof. Dr. A. Laubenheimer

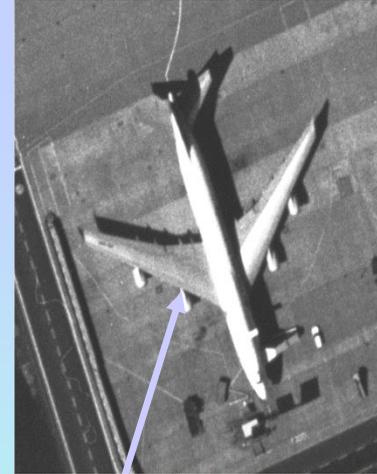
# 1. Einleitung

## Beispiel: Modellgestützte Objekterkennung 2

Eigenbeschattung

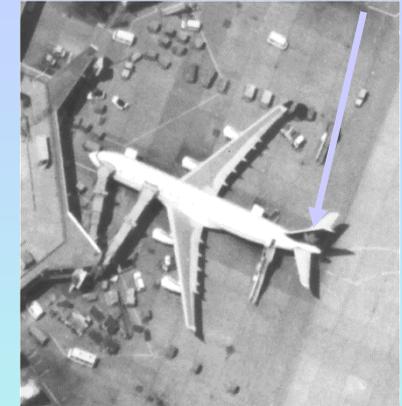


Gangways und Fahrzeuge in der Nähe des Flugzeugs



Unterschiedliche Bemalungsschemata

Perspektivische Verzerrungen

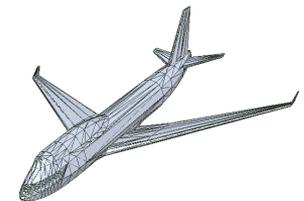


Komplexe Szene im Außenbereich

Bodenauflösung: ca. 16 cm pro Pixel

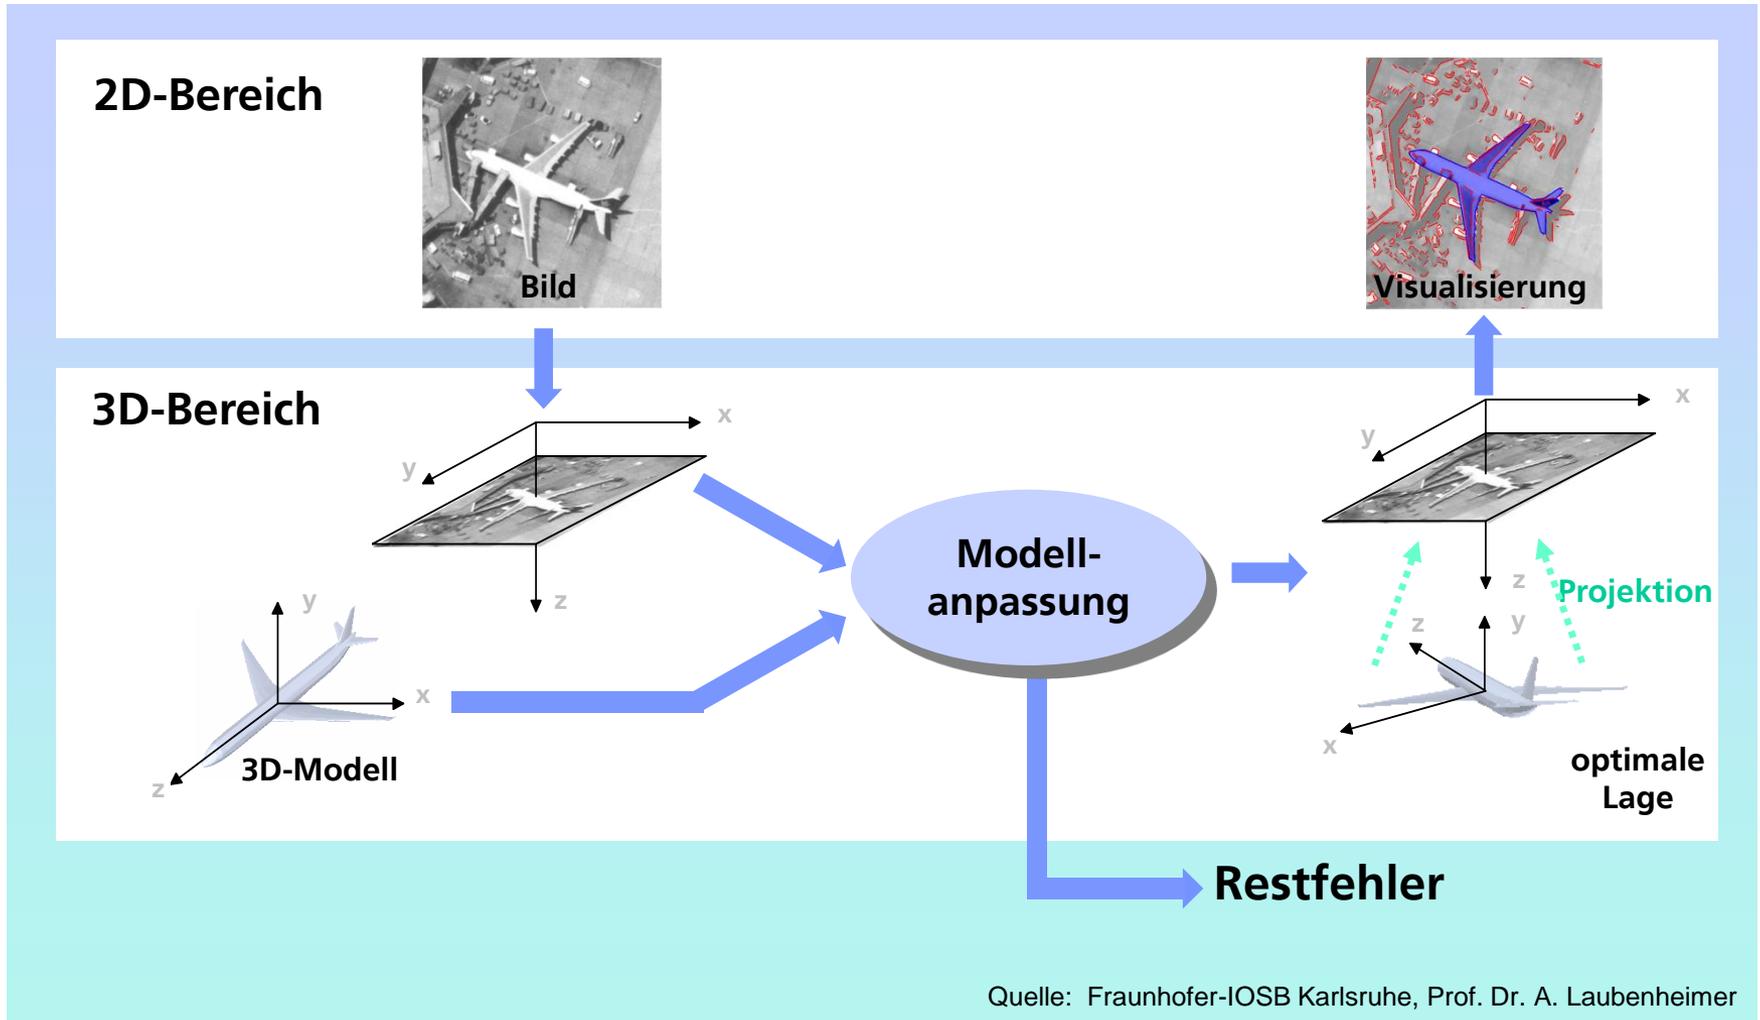
Quelle: Fraunhofer-IOSB Karlsruhe, Prof. Dr. A. Laubenheimer

Strategie: Szenenwissen in Form von 3D-Modellen



# 1. Einleitung

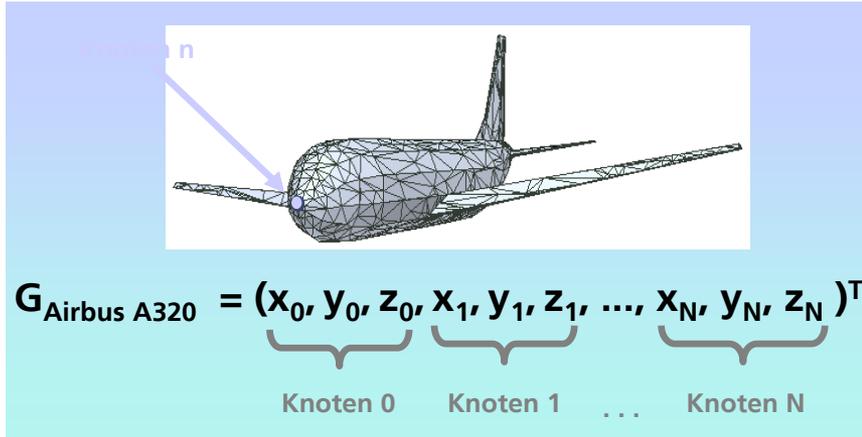
## Beispiel: Modellgestützte Objekterkennung 3



## Typerkennung durch Modellanpassung

# 1. Einleitung

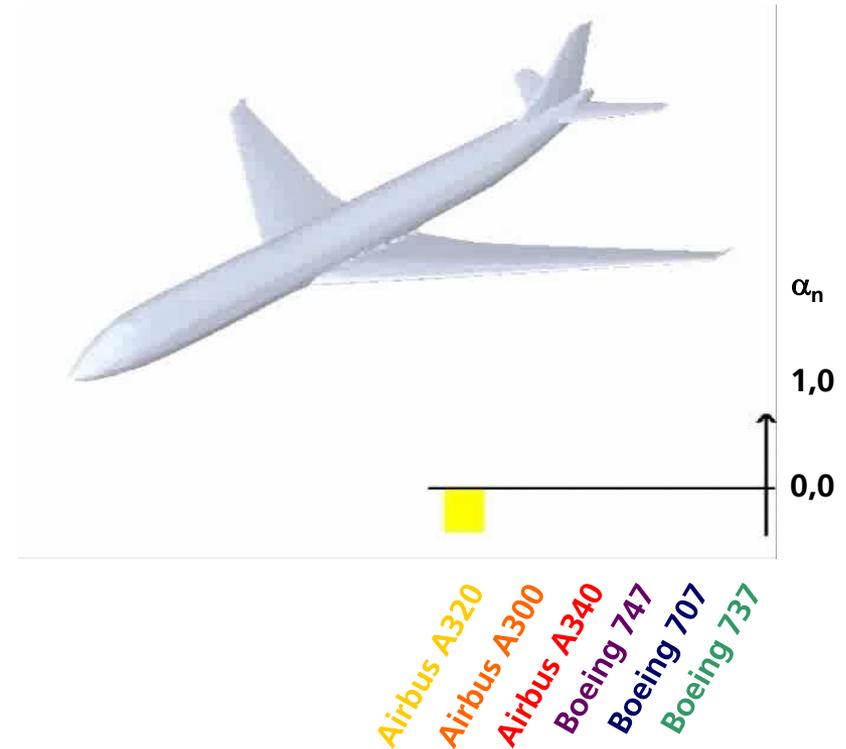
## Beispiel: Modellgestützte Objekterkennung 4



$$G_{\text{aktuell}} = \alpha_1 * G_{\text{Airbus A320}} + \alpha_2 * G_{\text{Airbus A300}} + \alpha_3 * G_{\text{Airbus A340}} + \alpha_4 * G_{\text{Boeing 747}} + \alpha_5 * G_{\text{Boeing 707}} + \alpha_6 * G_{\text{Boeing 737}}$$



Quelle: Fraunhofer-IOSB Karlsruhe



# 1. Einleitung

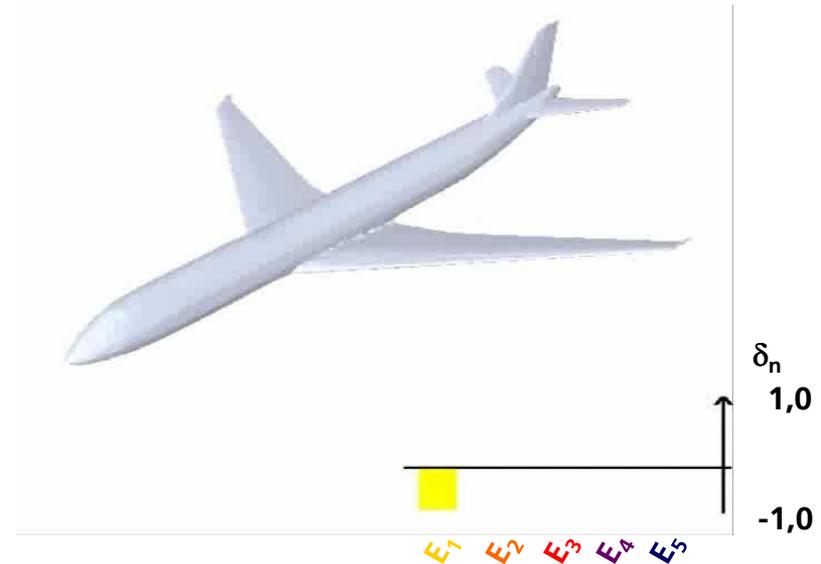
## Beispiel: Modellgestützte Objekterkennung 5

### Hauptkomponentenanalyse

Quelle: Fraunhofer-IOSB Karlsruhe

$$\begin{aligned} \mathbf{G} = & \mathbf{G}_{\text{mean}} + \delta_1 * \mathbf{E}_1 \\ & + \delta_2 * \mathbf{E}_2 \\ & + \delta_3 * \mathbf{E}_3 \\ & + \delta_4 * \mathbf{E}_4 \\ & + \dots \end{aligned}$$

↑      ↑  
Parameter    Orthogonale  
                 geometrische  
                 Realisierungen  $\mathbf{E}_n$



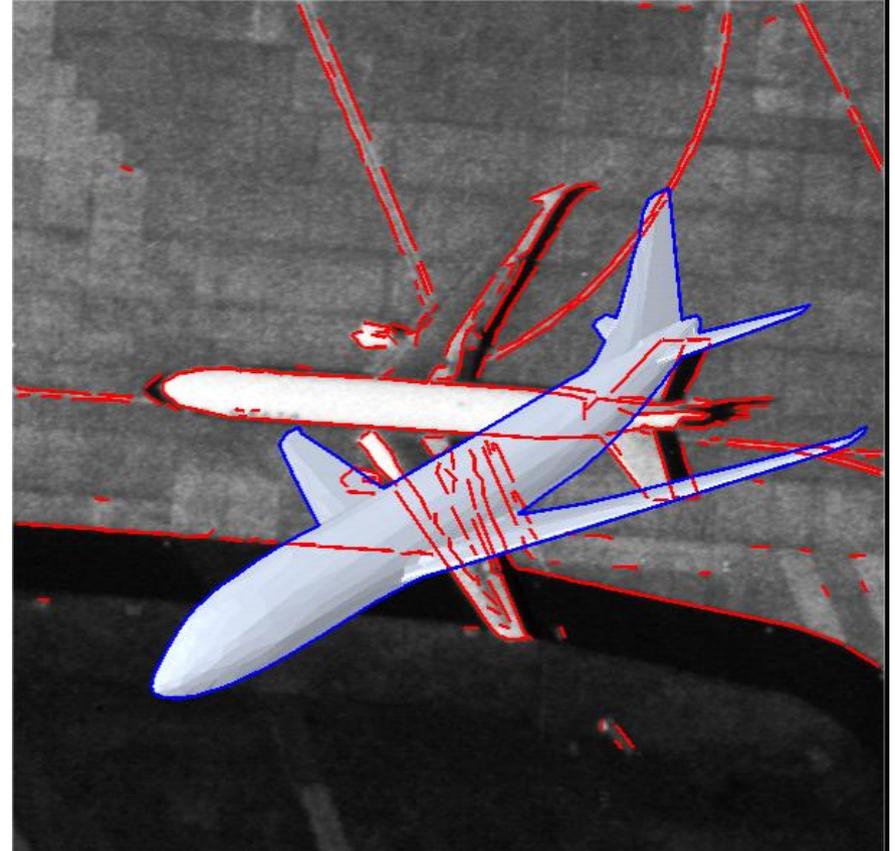
Die Modellparameter sind ihrer Relevanz entsprechend sortiert!

# 1. Einleitung

## Beispiel: Modellgestützte Objekterkennung 6

Ablauf:

- Binärbild: Grobe Segmentierung.
- Initialisierung: Kantenbasierte Schätzung von Lage und Form auf dem Binärbild.
- Optimierung auf Originalbild: Kantenbasierter robuster Schätzer.



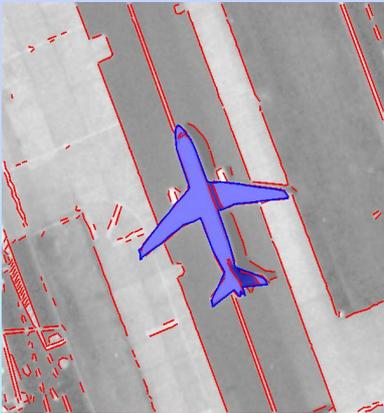
Quelle: Fraunhofer-IOSB Karlsruhe, Prof. Dr. A. Laubenheimer

# 1. Einleitung

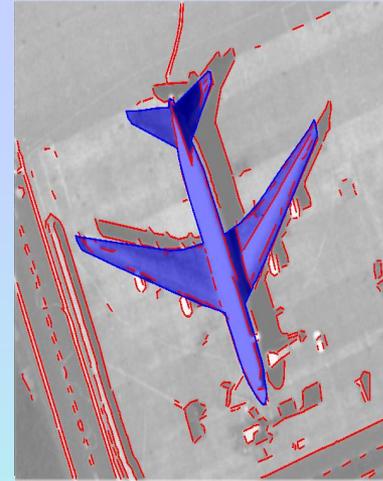
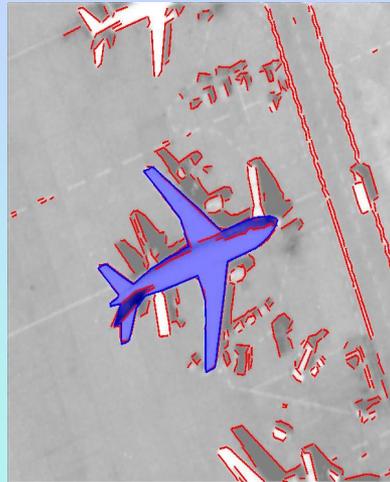
## Beispiel: Modellgestützte Objekterkennung 7

### Resultate

**Eigenbeschattung**

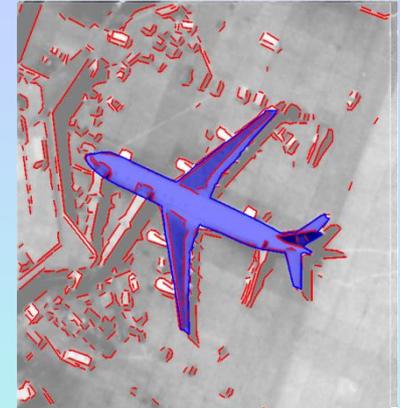


**Gangways und Fahrzeuge in der Nähe des Flugzeugs**



**Unterschiedliche Bemalungsschemata**

**Perspektivische Verzerrungen**



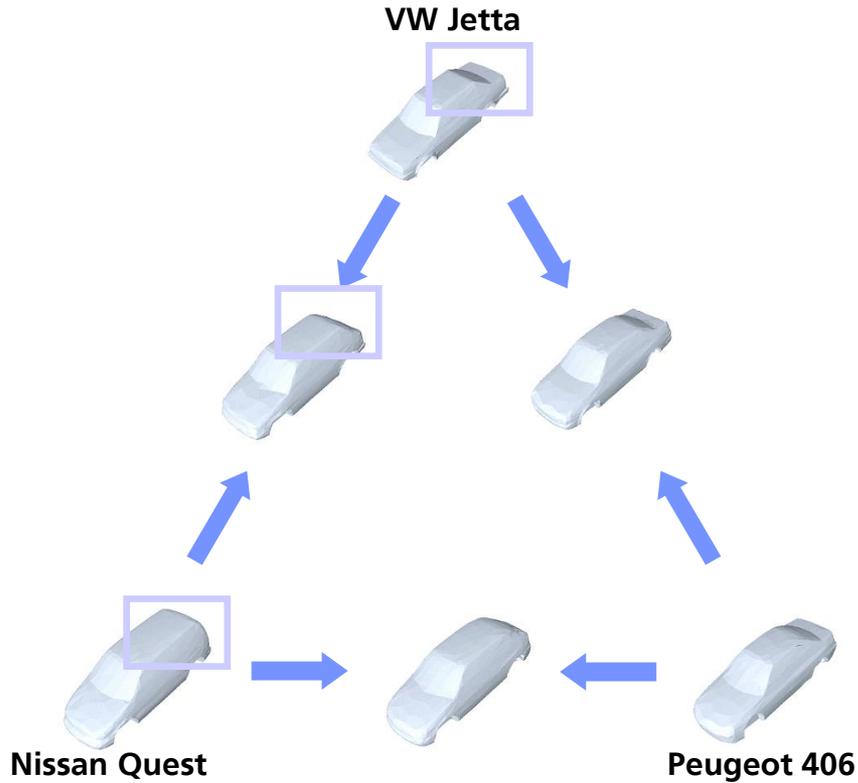
**Komplexe Szene im Außenbereich**

**Bodenauflösung: ca. 16 cm pro Pixel**

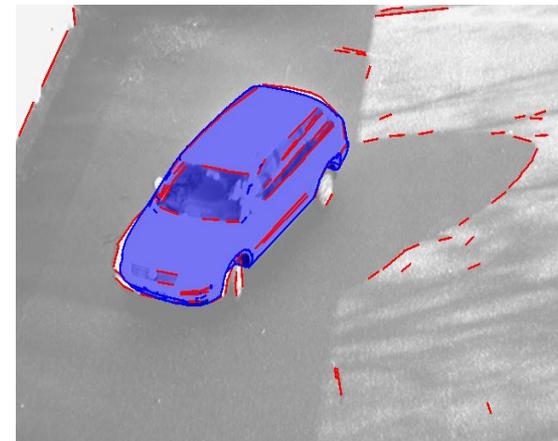
Quelle: Fraunhofer-IOSB Karlsruhe, Prof. Dr. A. Laubenheimer

# 1. Einleitung

## Beispiel: Modellgestützte Objekterkennung 8

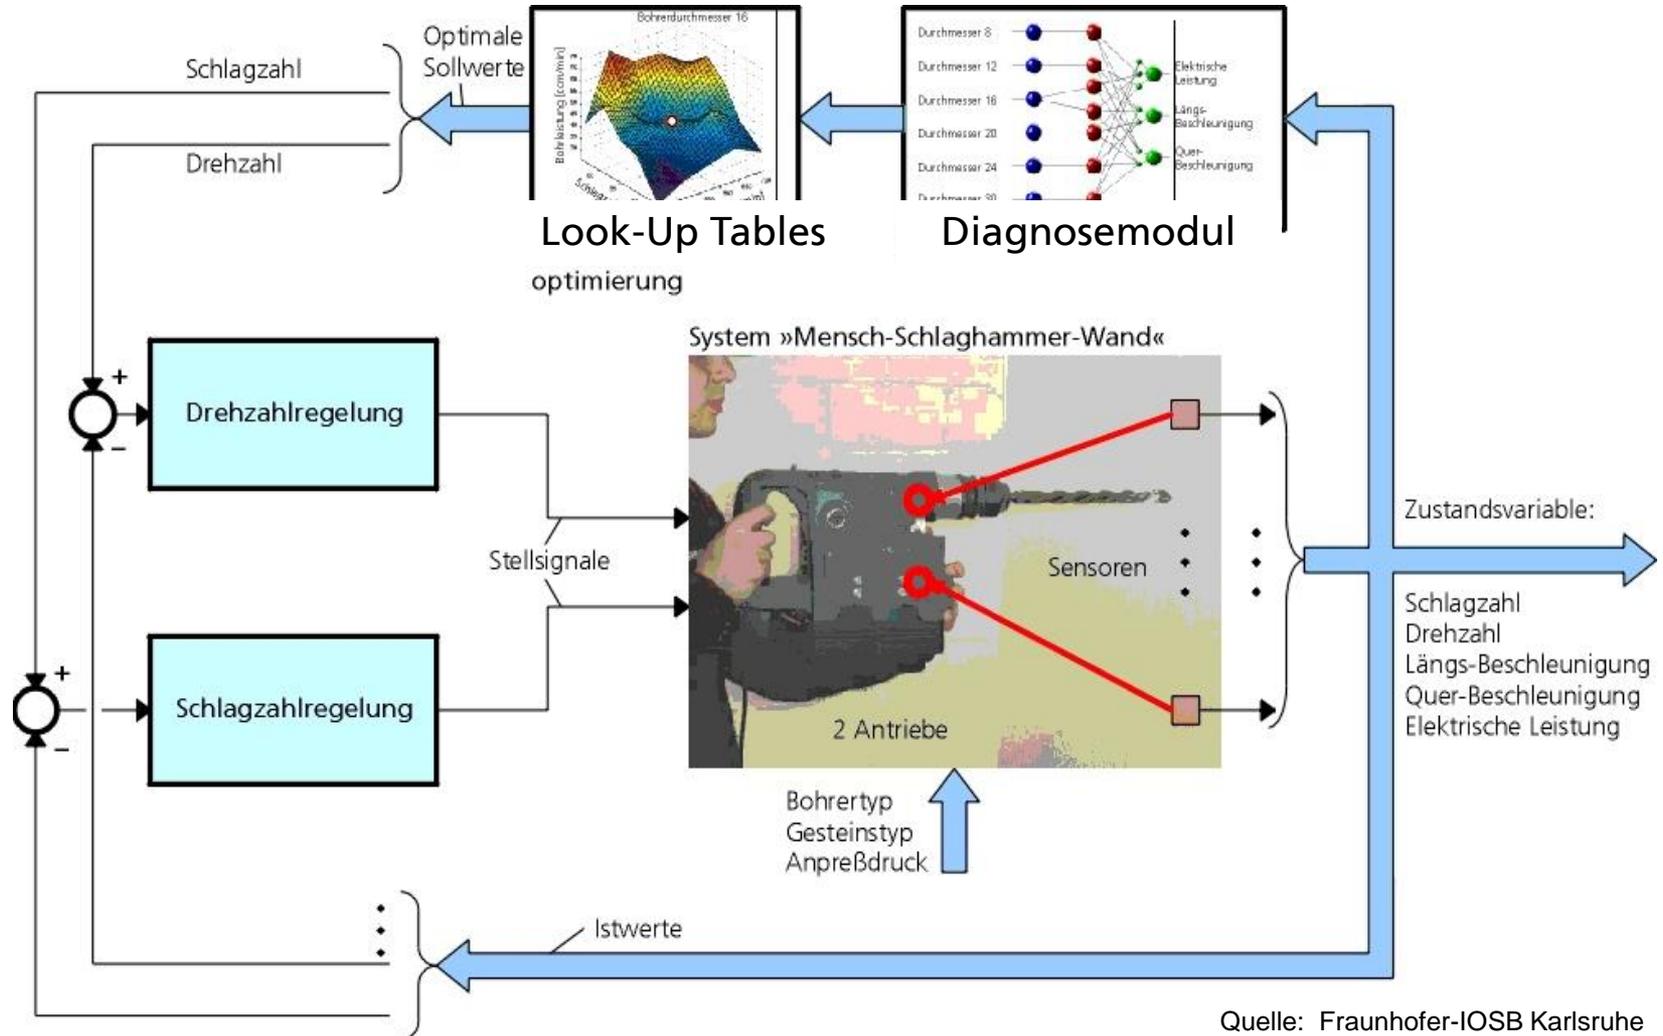


Quelle: Fraunhofer-IOSB Karlsruhe, Prof. Dr. A. Laubenheimer



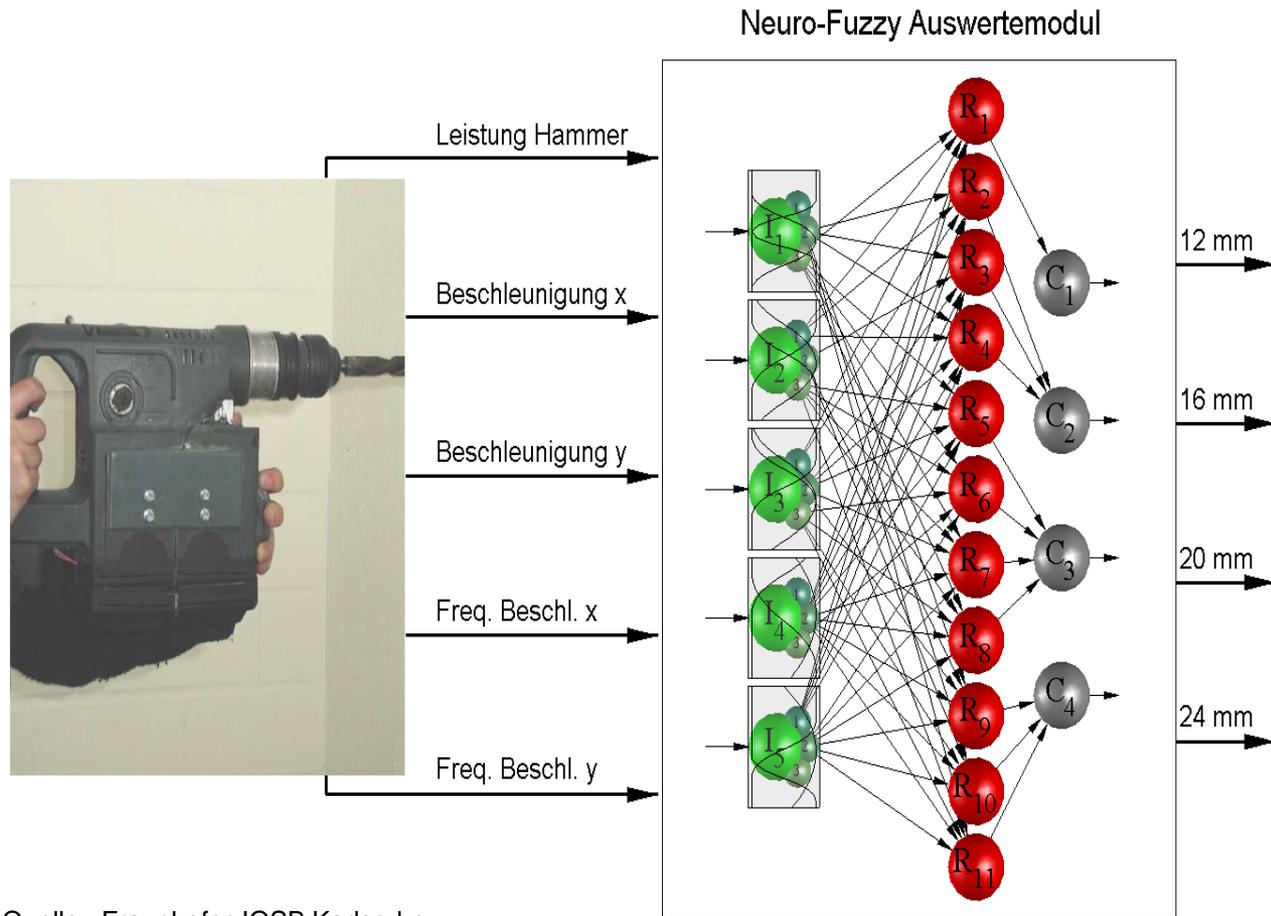
# 1. Einleitung

## Beispiel: Intelligenter Bohrhämmer - Regelkreis



# 1. Einleitung

## Beispiel: Intelligenter Bohrhammer - Klassifikationsaufgaben

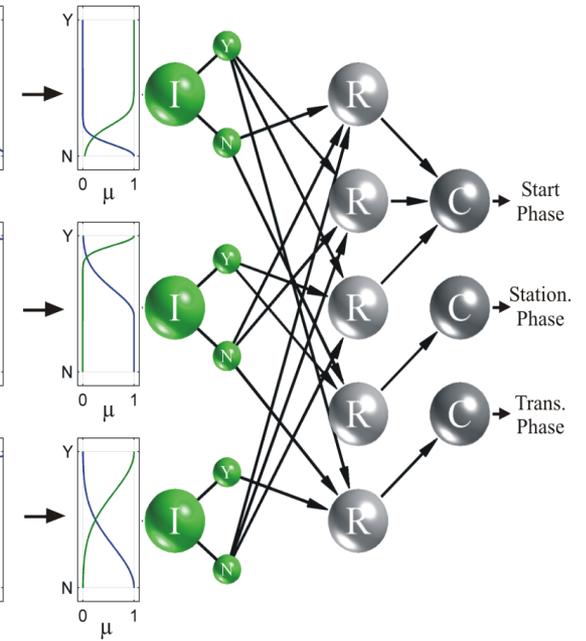
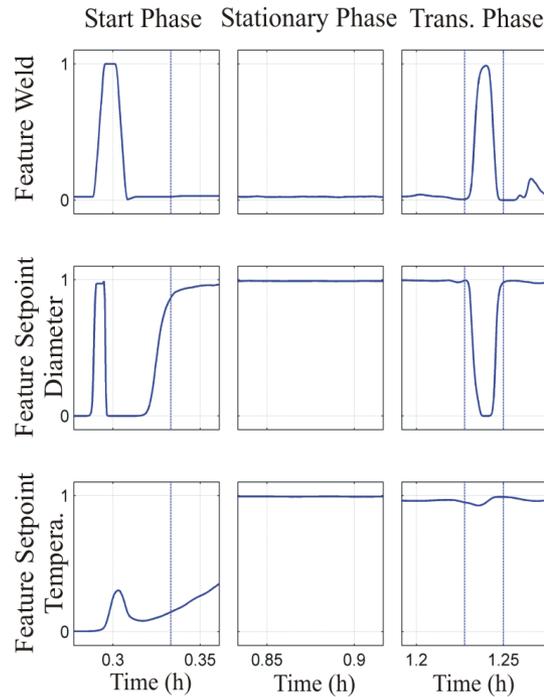
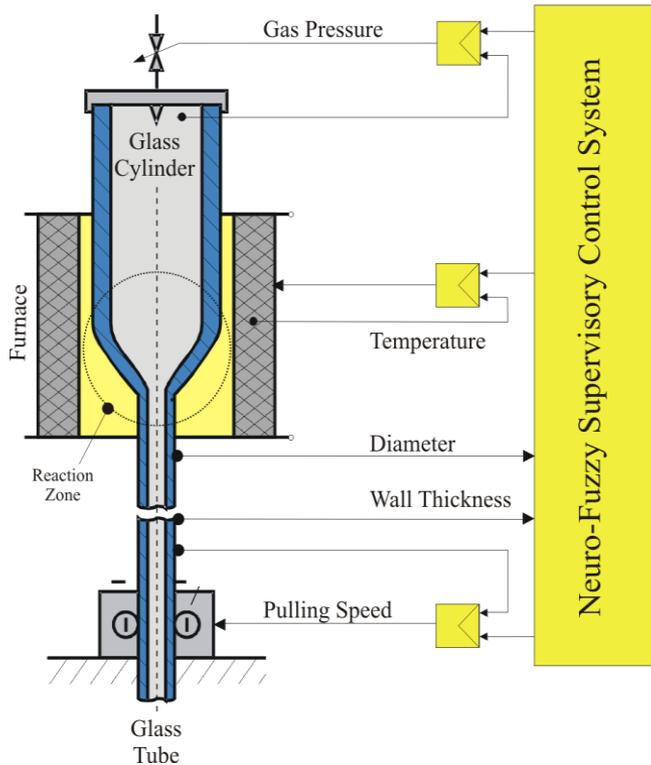


Quelle: Fraunhofer-IOSB Karlsruhe

Analoger Ansatz: Klassifikation des Wandmaterials und Schätzung der mechanischen Impedanz des Bedieners

# 1. Einleitung

## Beispiel: Prozessphasenerkennung bei der Herstellung von Glasröhren



Quelle: Fraunhofer-IOSB Karlsruhe

# 1. Einleitung

---

## Begriffe und ergänzende Bemerkungen:

### Mustererkennung dient zur Klassifikation von:

- Objekten
- Zuständen
- Situationen
- Zusammenhängen

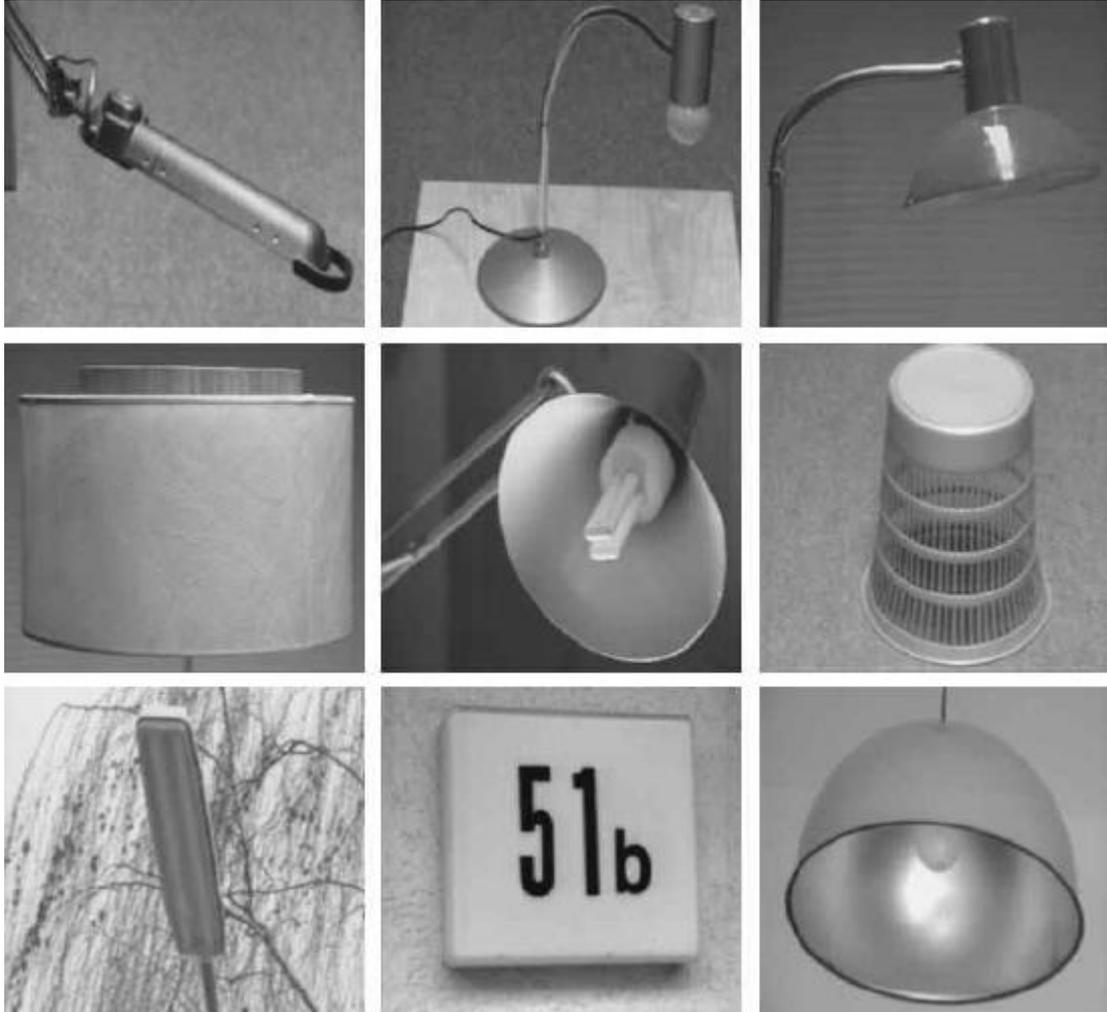
### Mustererkennung bei Mensch und Maschine:

	Assoziative und kognitive Fähigkeiten	Kombinatorische und präzise Fähigkeiten
Mensch	++	-
Maschine	0	++

Skala: ++ + 0 - --

# 1. Einleitung

Abstraktionsfähigkeit des Menschen (nicht alle Gegenstände sind Lampen)



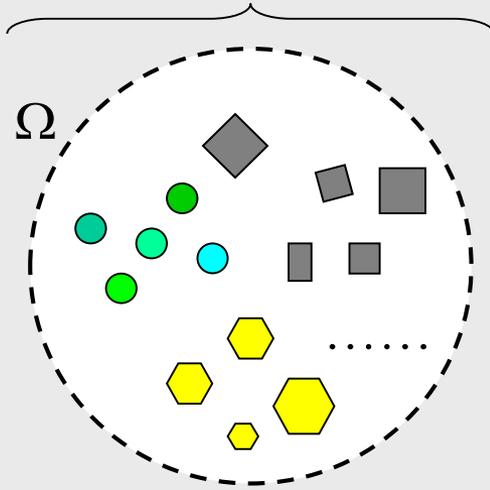
## Anwendungsbeispiele:

- Qualitätsprüfung (Fehlererkennung und -klassifikation, ...)
- Erkennung von Betriebszuständen (Anlagendiagnose, Fehlerfrüherkennung, ...)
- Objekterkennung (Werkstücke, Fahrzeuge, Fußgänger, abgestellte Gegenstände, ...)
- Spamerkennung
- Intrusionserkennung
- Spracherkennung
- Musikerkennung
- Personenidentifikation (Gesichter, Fingerabdrücke, Iris, Handschrift, ...)
- Zeichenerkennung (gedruckt und handgeschrieben)
- Situationserkennung (automatischer Feueralarm, Airbagauslösung, Bremsassistent, ...)
- Medizintechnik (Klassifikation und Zählung von Blutpartikeln, EKG-, EEG-Auswertung, ...)
- USW.

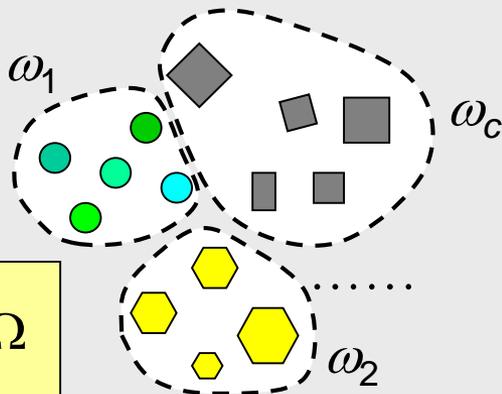
# 1. Einleitung

Domäne  $\subseteq$  Welt

Objekte  $\Omega$



Partition: Äquivalenzklassen  $\omega_i$



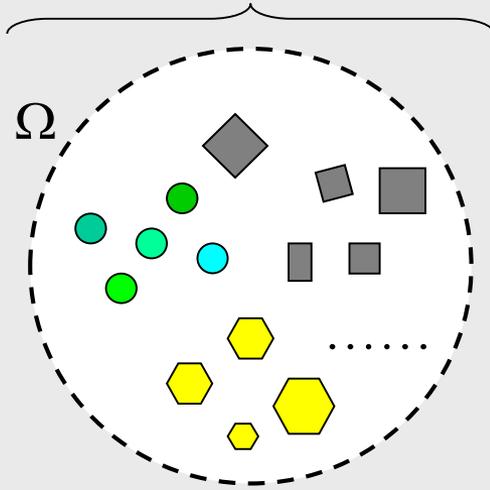
$$\bigcup_{i=1}^c \omega_i = \Omega$$

$$\omega_i \cap \omega_j = \emptyset \quad \text{für} \quad i \neq j$$

# 1. Einleitung

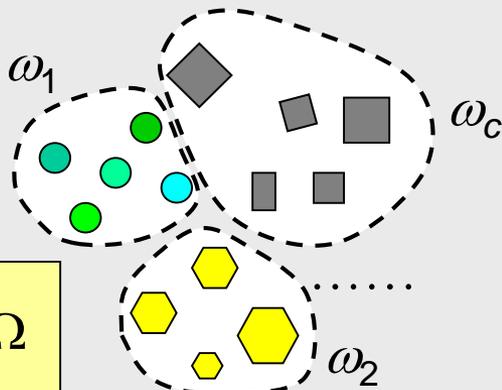
Domäne  $\subseteq$  Welt

Objekte  $\Omega$



Beobachten,  
messen,  
beschreiben:  
Objekt  $\alpha$   $\mathbf{m}$

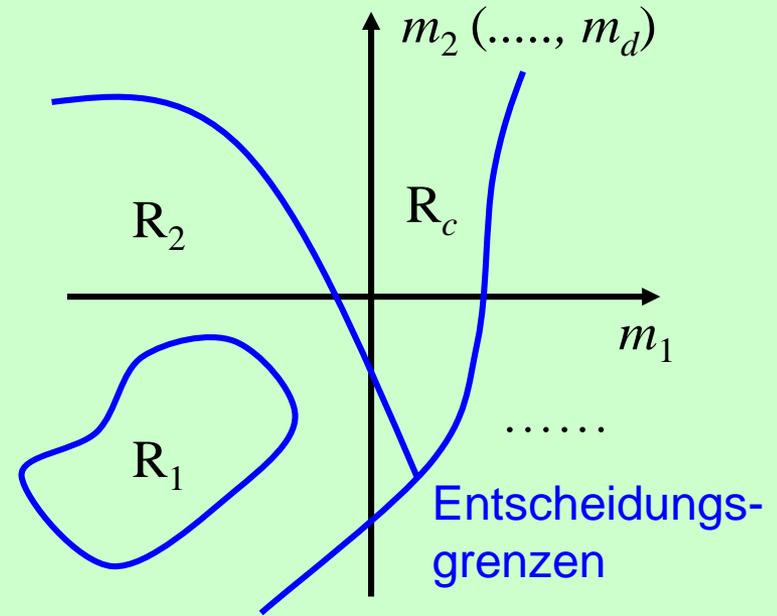
Partition: Äquivalenzklassen  $\omega_i$



$$\bigcup_{i=1}^c \omega_i = \Omega$$

$$\omega_i \cap \omega_j = \emptyset \quad \text{für} \quad i \neq j$$

Merkmalsraum  $\mathbb{M}$



Partition von  $\mathbb{M}$ :

$$R_i \cap R_j = \emptyset \quad \text{für} \quad i \neq j$$

$$\bigcup_{i=1}^c R_i = \mathbb{M}$$

Merkmalsvektor:

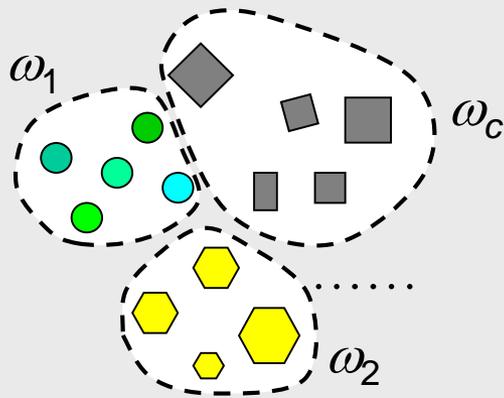
$$\mathbf{m} := (m_1, \dots, m_d)^T \in \mathbb{M}$$

Klassifikation:

$$\mathbf{m} \in R_j \rightarrow \hat{\omega} := \omega_j$$

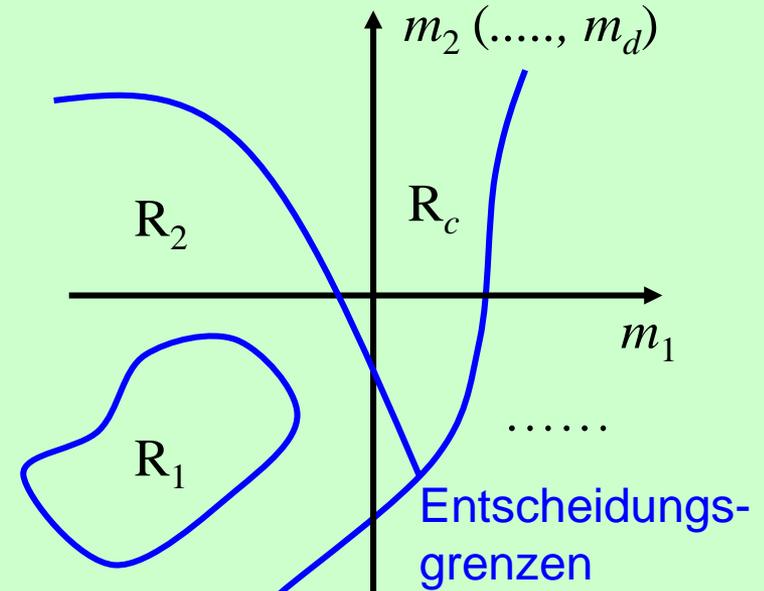
# 1. Einleitung

Menge der Objekte  $\Omega$   
Partition  $\{\omega_i | i = 1, \dots, c\}$



Beobachten,  
messen,  
beschreiben:  
Objekt  $\alpha$   $\mathbf{m}$

Merkmalsraum  $\mathbb{M}$   
Partition  $\{R_i | i = 1, \dots, c\}$

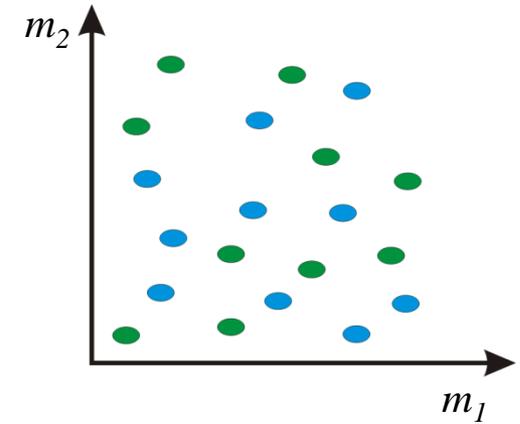
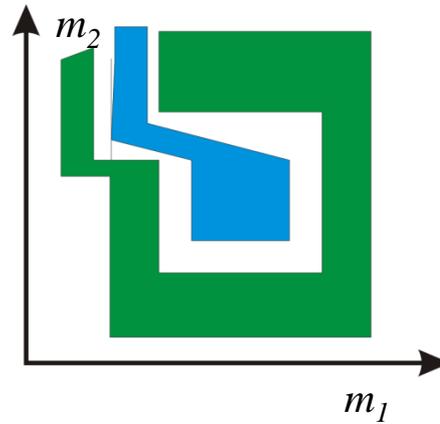
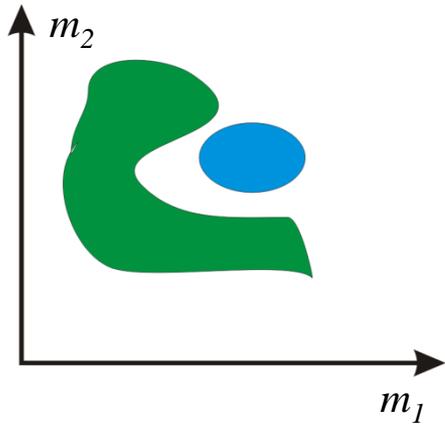
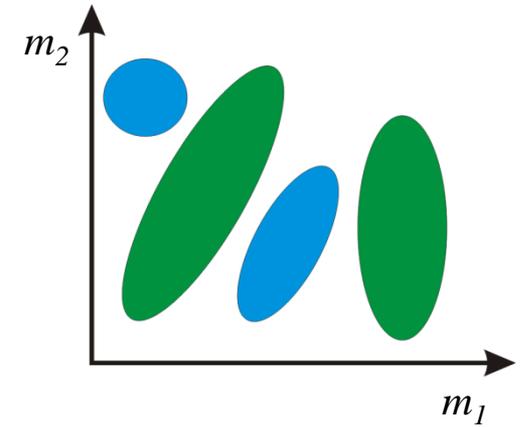
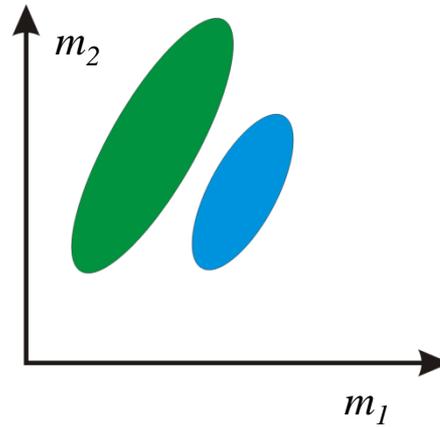
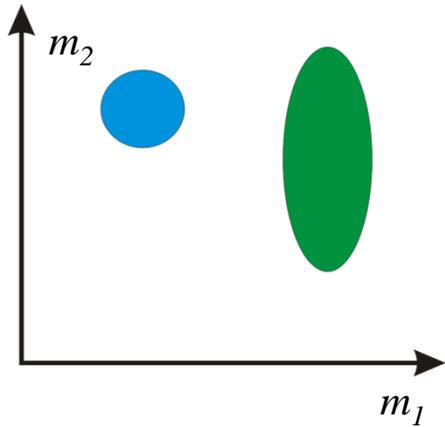


Im Allgemeinen gilt: **Objekt  $\in \omega_i \not\Leftrightarrow \mathbf{m}(\text{Objekt}) \in R_i$**  wegen:

- (1)  $\mathbf{m}$  kann  $\{\omega_i | i = 1, \dots, c\}$  nicht trennen:  
überlappende Klassen, ungeeignete Merkmale
- (2) Partition  $\{R_i | i = 1, \dots, c\}$  wird anhand endlich vieler, u.U. nicht repräsentativer Beispiele gelernt.  $\Rightarrow$  Entscheidungsgrenzen fehlerhaft.

# 1. Einleitung

**Problem:** Topographie der Klassen im Merkmalsraum



 Klasse 1  
 Klasse 2

# 1. Einleitung

**Mustererkennung** ist die Theorie der bestmöglichen Zuordnung eines unbekanntes Musters zu einer **Äquivalenzklasse**  $\omega_i$

Äquivalenzklassen entsprechen Bedeutungsklassen.

Eine **Äquivalenzrelation** ist eine binäre Relation mit den Eigenschaften:

1. Reflexivität:  $\mathbf{x} \sim \mathbf{x}$

2. Symmetrie:  $\mathbf{x} \sim \mathbf{y} \Rightarrow \mathbf{y} \sim \mathbf{x}$

3. Transitivität:  $(\mathbf{x} \sim \mathbf{y}) \wedge (\mathbf{y} \sim \mathbf{z}) \Rightarrow \mathbf{x} \sim \mathbf{z}$

Eine **Äquivalenzrelation** auf einer Menge  $\Omega$  induziert eine **Partition** von  $\Omega$  und umgekehrt.

## Begriffe und ergänzende Bemerkungen:

**Muster:** Gesamtheit der beobachteten/gemessenen Werte einer einzelnen Stichprobe (eines einzelnen Objektes).

**Erkennung:** (Wieder)erkennen von etwas, was bereits schon bekannt ist.

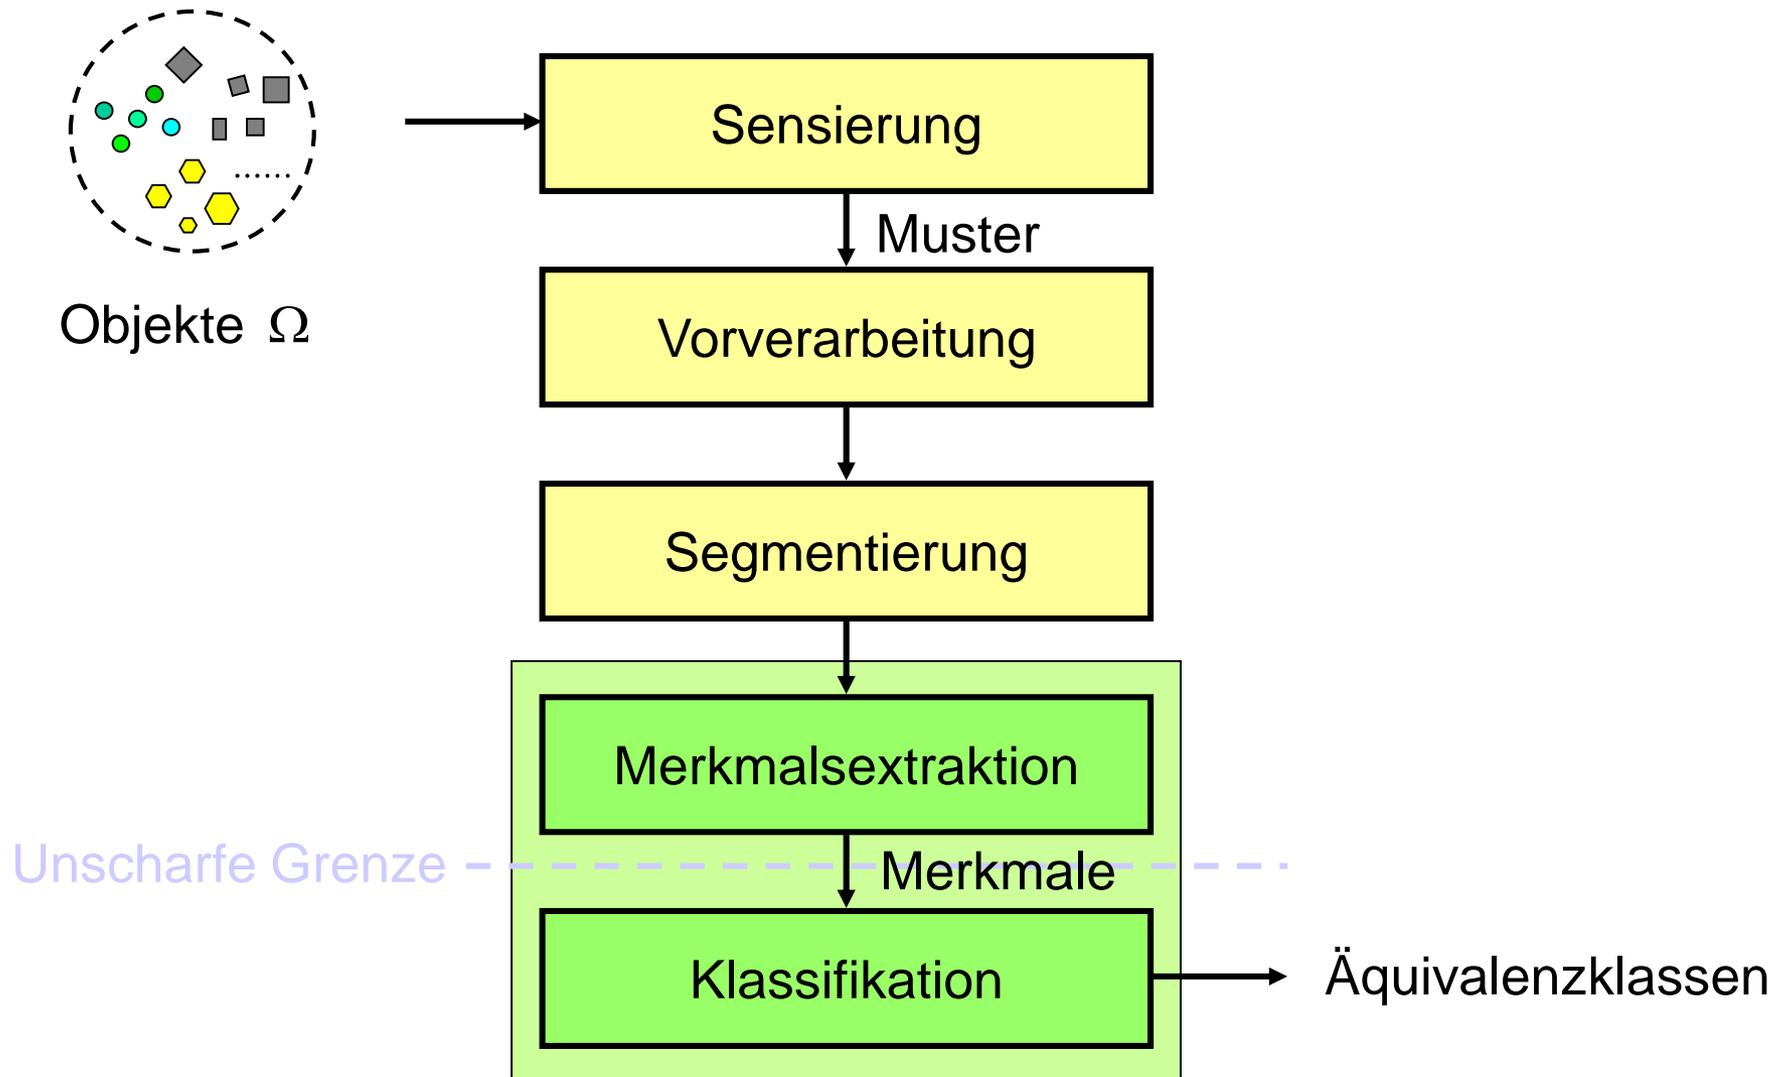
## Ziele der Mustererkennung:

- Identifikation
- Klassifikation

**Merkmale:** eruierbare, charakteristische Eigenschaften, die als Basis für die Unterscheidung von Mustern dienen sollen.

# 1. Einleitung

## Mustererkennungssystem:



# 1. Einleitung

## Ausgangssituation bei einer Mustererkennungsaufgabe:

### Gegeben:

Typischerweise ist eine Mustererkennungsaufgabe durch eine Menge  $S$  von **vorklassifizierten Beispielen** gegeben

→ überwachtes Lernen.

$S$ : Gesamtstichprobe (Menge aller gegebenen Beispiele mit bekannter Klassenzugehörigkeit)

Die **Klassenstruktur**  $\{\omega_i, i = 1, \dots, c\}$  ist Teil der Aufgabenstellung.

Ggf. Wissen über die **Auftrittswahrscheinlichkeiten**  $P(\omega_i)$  der Klassen.

Ggf. Wissen über **Kosten** bei Entscheidung für  $\omega_i$ , obwohl  $\omega_j$  vorliegt.

### Gesucht:

Verfahren, das **unbekannten Objekten** die zugrundeliegende (wahre) Klasse zuweist, diese also **richtig klassifiziert**.

# 1. Einleitung

S: **Gesamtstichprobe** → Zerlegung in drei disjunkte Teilmengen:

D: **Lernstichprobe** (Zur Auswahl der Merkmale und zum Training des Klassifikators)

V: **Validierungsstichprobe** (Zur Festlegung von Tuningparametern des Klassifikators)

T: **Teststichprobe** („In den Tresor!“ Nur zur finalen Leistungsmessung)

$$S = D \cup V \cup T \quad \text{mit} \quad D \cap V = D \cap T = V \cap T = \emptyset$$

Gängige Aufteilung; es gibt hier allerdings keine allgemeingültige Regel:

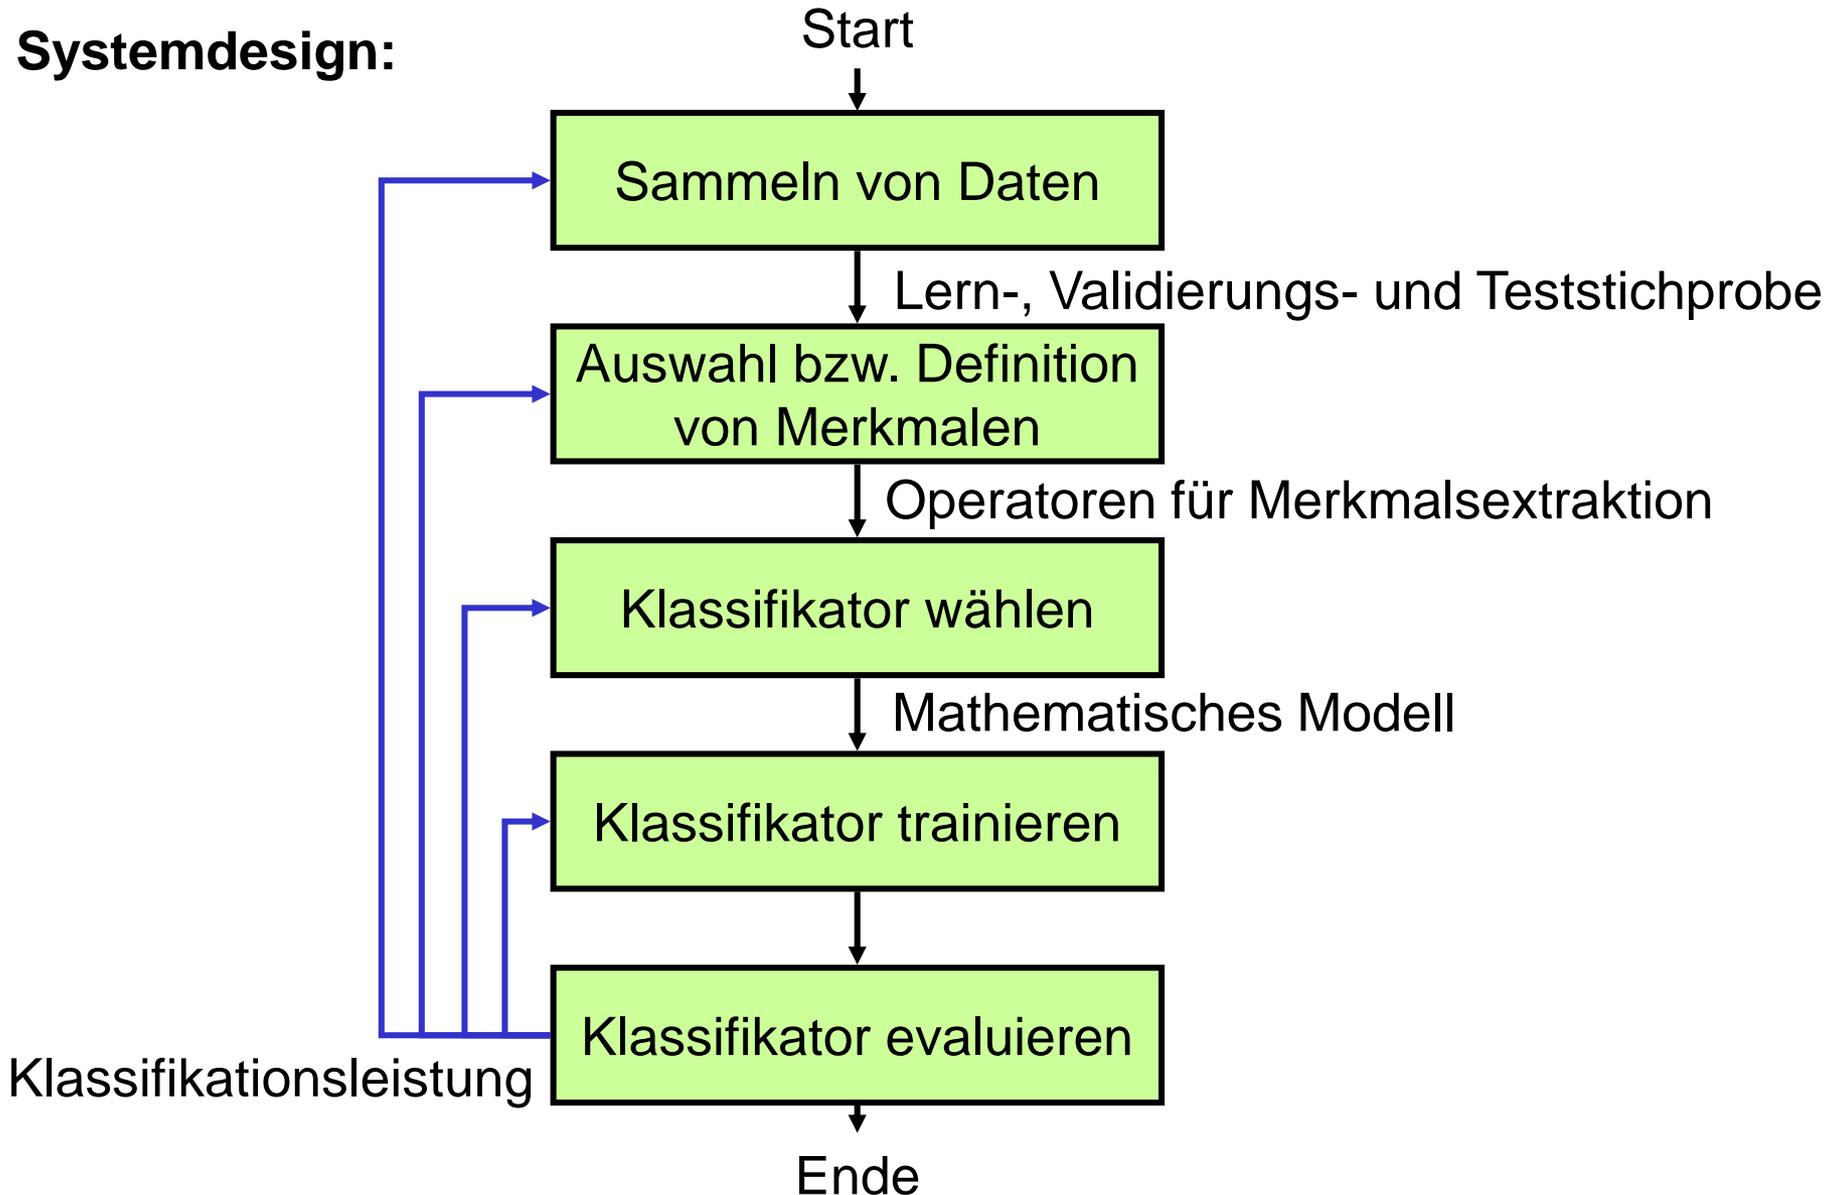
Lernen 50%

Validierung 25 %

Test 25%

# 1. Einleitung

## Systemdesign:



1. Einleitung
2. Merkmale
  - 2.1. Merkmalstypen
  - 2.2. Sichtung des Merkmalsraumes
  - 2.3. Transformation der Merkmale
  - 2.4. Abstandsmessung im Merkmalsraum
  - 2.5. Normalisierung
  - 2.6. Auswahl und Konstruktion von Merkmalen
    - 2.6.1. Deskriptive Merkmale
    - 2.6.2. Modellparameter als Merkmale
    - 2.6.3. Konstruktion invarianter Merkmale
  - 2.7. Reduktion der Dimension des Merkmalsraumes
    - 2.7.1. Hauptkomponentenanalyse (HKA, PCA)
    - 2.7.2. Nichtlineare Hauptkomponentenanalyse (*Kernelized PCA*)
    - 2.7.3. Independent Component Analysis (ICA)
    - 2.7.4. Multiple Discriminant Analysis
    - 2.7.5. Dimensionsreduktion durch Merkmalsauswahl

- 3. Bayes'sche Entscheidungstheorie
  - 3.1. Allgemeine Überlegungen zur Klassifikation
  - 3.2. Bayes'sche Entscheidungstheorie
  - 3.3. Normalverteilte Merkmale
  - 3.4. Gauß'sche Mischverteilungen
- 4. Parameterschätzung
  - 4.1. Maximum-Likelihood Schätzung
  - 4.2. Bayes'sche Bestimmung der AP-Klassenwahrscheinlichkeiten
  - 4.3. Bayes'sche Parameterschätzung
- 5. Parameterfreie Methoden
  - 5.1. Parzen Fenster
  - 5.2.  $k_N$  - Nächste Nachbarn WDF Schätzung
  - 5.3. Nächster Nachbar Klassifikator
- 6. Allgemeine Problemstellungen
  - 6.1. Dimension des Merkmalsraumes
  - 6.2. Overfitting

## 7. Spezielle Klassifikatoren

- 7.1. Lineare Diskriminanzfunktionen
- 7.2. Perzeptron
- 7.3. Klassifikation mittels linearer Regression
- 7.4. KNN
- 7.5. SVM
- 7.6. Matched-Filter
- 7.7. Klassifikation von Sequenzen
- 7.8. Klassifikation mit Rückweisung

## 8. Klassifikation bei nominalen Merkmalen

- 8.1. Entscheidungsbäume
- 8.2. String Verfahren
- 8.3. Grammatiken

## 9. Klassifikatorunabhängige Prinzipien

- 9.1. Lernen
- 9.2. Empirische Leistungsbestimmung von Klassifikatoren
- 9.3. Boosting

# Literaturempfehlungen

---

- [Bey94] Jürgen Beyerer. *Analyse von Riefentexturen*. Dissertation, VDI-Verlag, 1994
- [Bey99] Jürgen Beyerer. *Verfahren zur quantitativen statistischen Bewertung von Zusatzwissen in der Meßtechnik*. Habilitationsschrift, VDI-Verlag, 1999
- [Bis06] Christopher M. Bishop. *Pattern Recognition and Machine Learning*. Springer, 2006.
- [Bur79] Hans Burkhardt. *Transformationen zur lageinvarianten Merkmalgewinnung*. Habilitationsschrift, VDI-Verlag, 1979
- [CST01] N. Cristianini, J. Shawe-Taylor. *An introduction to Support Vector Machines: and other kernel-based learning methods*. Cambridge University Press, 2001
- [DHS01] Richard O. Duda, Peter E. Hart, Stork G. David. *Pattern Classification*. Wiley-Interscience, second edition, 2001

# Literaturempfehlungen

---

- [Fin03] G. A. Fink. *Mustererkennung mit Markov-Modellen*. Teubner, 2003.
- [Fuk97] K. Fukunaga. *Introduction to Statistical Pattern Recognition*. Academic Press, second edition, 1997.
- [HDB95] M. T. Hagan, H. B. Demuth, M. H. Beale. *Neural Network Design*. PWS Publishing Company, 1995.
- [Hof98] R. Hoffman. *Signalanalyse und -erkennung*. Springer, 1998.
- [MdS01] J. P. Marques de Sá. *Pattern Recognition*. Springer, 2001
- [MS00] T. K. Moon, W. C. Stirling. *Mathematical methods and algorithms for signal processing*. Prentice Hall, 2000

# Literaturempfehlungen

---

- [Nie90] H. Niemann. *Pattern analysis and understanding*. Springer, second edition, 1990
- [RMS91] H. Ritter, Th. Martinetz, K. Schulten. *Neuronale Netze*. Addison-Wesley, 1991
- [Sch96] J. Schürmann. *Pattern classification*. Wiley & Sons, 1996
- [SM95] H. Schulz-Mirbach. *Anwendung von Invarianzprinzipien zur Merkmalgewinnung in der Mustererkennung*. VDI Verlag, 1995

# Literaturempfehlungen

---

- [TK03] S. Theodoridis, K. Koutroumbas. *Pattern recognition*. London: Academic, 2003
- [Vap00] V. N. Vapnik. *The nature of statistical learning theory*. Springer, second edition, 2000
- [HTF08] T. Hastie, R. Tibshirani, J. Friedman. *The elements of statistical learning*. Springer, second edition, 2008

## Artikel:

- [BK97] J. Beyerer, D. Krahe. *A Parametric Method to Quantify the Balance of Groove Sets of Honed Cylinders*. Proceedings of SPIE, vol. 3203, 192-201, 1997
- [Wat65] S. Watanabe. *Une explication mathématique du classement d'objects*. In *Information and Prediction in Science*. S. Dockx, P. Bernays, Academic Press, 39-76, 1965
- [Wol94] D. H. Wolpert. *The relationship between PAC, statistical physics framework, the bayesian framework, and the VC framework*. In *The mathematics of generalization*. Addison-Wesley, 1994