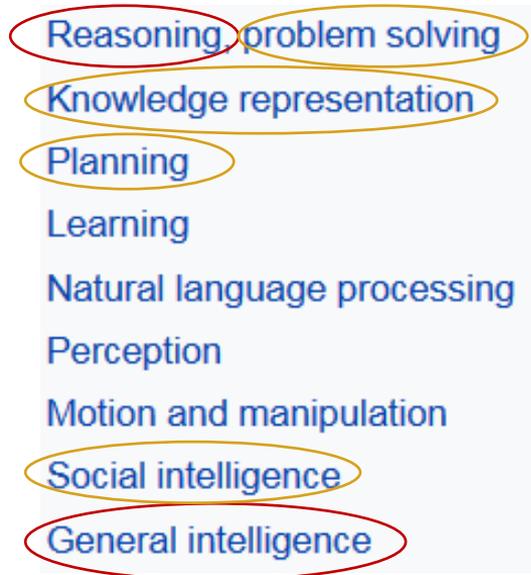


# Agenda

Die drei großen Bereiche des Machine Learning –  
dazu relevante Anwendungsbeispiele, sowie Einführung in die Funktionsweise

1. KI – Sichten
2. Supervised Learning: Image Classification mit Convolutional Neural Nets
3. Unsupervised Learning: Anomalieerkennung/Fraud Detection
4. Reinforcement Learning: Deep Q-Learning
5. KI - typische Missverständnisse
6. Projektmanagement-Aspekte

# KI – Forschungssicht



○ Spitzenforschung

○ Forschung in den Kinderschuhen

# KI – Anwendungssicht - Beispiele



## Semantische Bildanalyse

Objekterkennung  
Medizinische Diagnostik  
Schadenerkennung  
Handschrifterkennung  
u. v. m.



## Semantische Textanalyse

Themenextraktion  
Entity Extraktion  
Sentiment Analyse  
u. v. m.



## Prognosen

Kreditrisiko  
Schadenentwicklung  
Passagierauslastung  
u. v. m.



## Anomalieerkennung

Fraud Detection  
Kreditportfolioanomalien  
Intrusion Detection  
u. v. m.



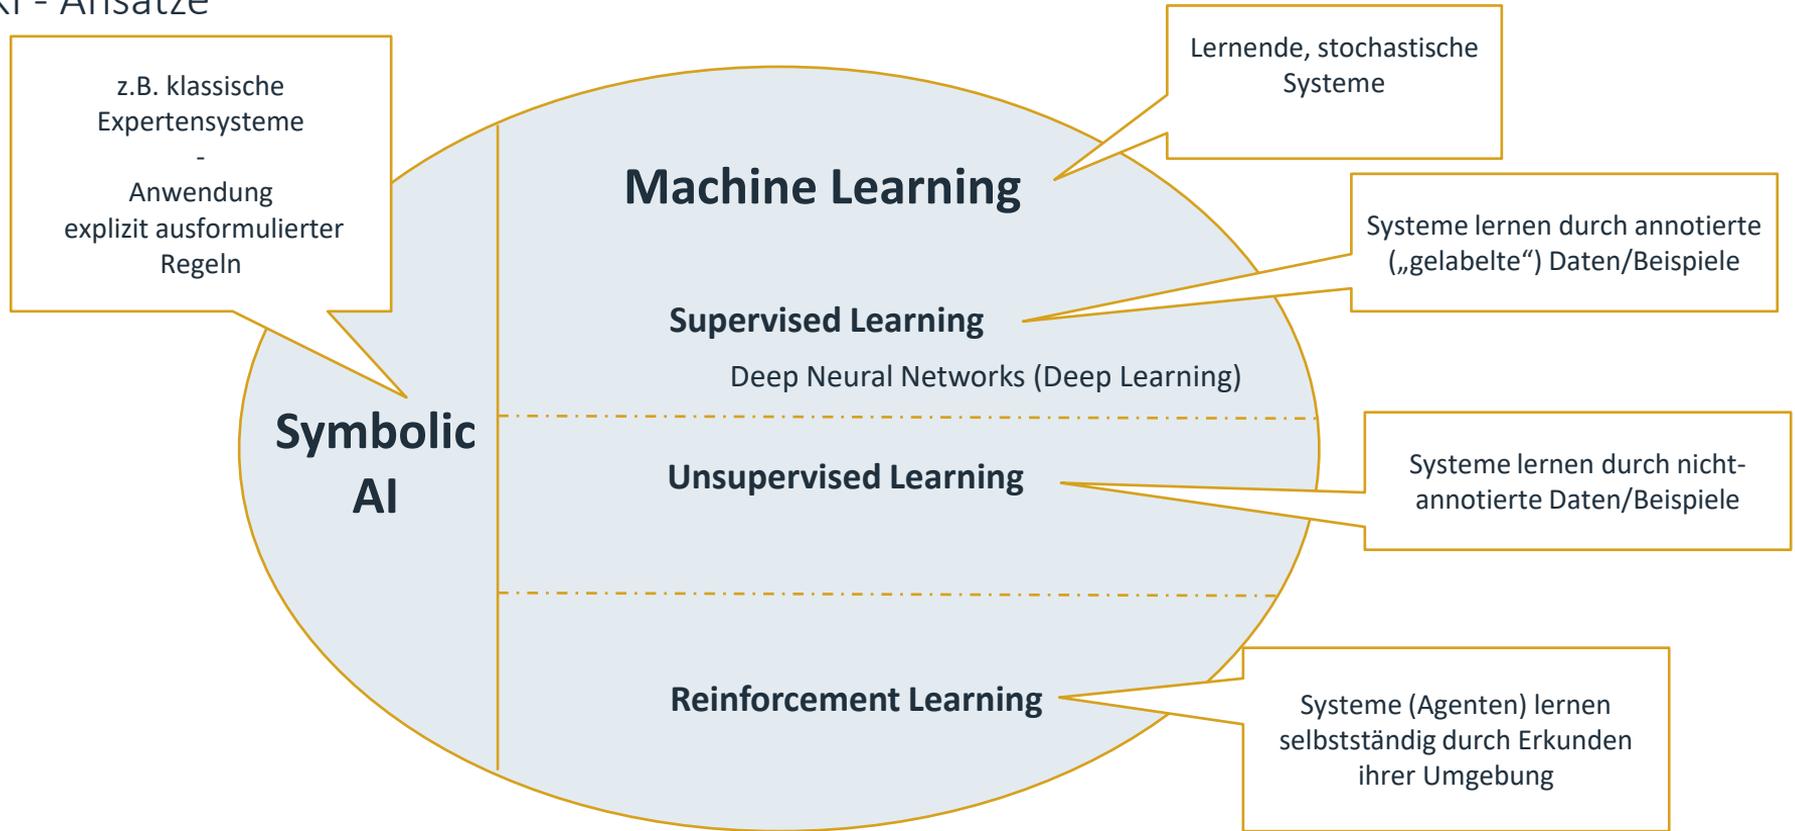
## AI-based BI

Visualisierung und  
Drilldown komplexer  
hochdimensionaler  
Datenräume

vgl. [www.bminformatik.de/themen/ki/](http://www.bminformatik.de/themen/ki/)

u.v.v.m wie Chatbots, Robo-Advisors, Robotics, Autonomes Fahren, Steuerungen ...

# KI - Ansätze



# Agenda

Die drei großen Bereiche des Machine Learning –  
dazu relevante Anwendungsbeispiele, sowie Einführung in die Funktionsweise

1. KI – Sichten
2. **Supervised Learning: Image Classification mit Convolutional Neural Nets**
3. Unsupervised Learning: Anomalieerkennung/Fraud Detection
4. Reinforcement Learning: Deep Q-Learning
5. KI - typische Missverständnisse
6. Projektmanagement-Aspekte

# Image Classification & Transfer Learning mit Convolutional Neural Nets

AI Info

Classify Image

## Response from Artificial Neural Network

You are connected with a ResNet50 instance.

General info:

- Description: ResNet50 trained on ImageNet dataset
- Origin: Deep learning benchmark by Kaiming He et.al.,2015
- Task type: Computer vision / single object image classification

Instance info:

- Scope: Animals (focus on cats and dogs), commodity items
- Target classes: 1000
- Training data: ImageNet.ILSVRC, 1.2M samples
- Input: (\*,224,224,3)-shaped tensor (normalized batch of RGB-images)

Architecture info:

- Type: Deep Residual Convolutional Neural Net (RNN/CNN)
- Number of residual blocks: 50
- Number of learnable parameters: 25.5M
- Number of hyperparameters: 53.1T
- Runtime: Keras with tensorflow backend

## Input Image



## Response from Artificial Neural Network

Image processed: true

Classification:

**ringlet** (probability:99.799%)  
great\_grey\_owl (probability:0.042%)  
bittern (probability:0.041%)  
lycaenid (probability:0.026%)  
sulphur\_butterfly (probability:0.009%)

W-keits  
Verteilung

# Image Classification & Transfer Learning mit Convolutional Neural Nets

AI Info

Classify Image

## Response from Artificial Neural Network

You are connected with a ResNet50 instance.

General info:

- Description: ResNet50 trained on ImageNet dataset
- Origin: Deep learning benchmark by Kaiming He et.al.,2015
- Task type: Computer vision / single object image classification

Instance info:

- Scope: Animals (focus on cats and dogs), commodity items
- Target classes: 1000
- Training data: ImageNet.ILSVRC, 1.2M samples
- Input: (\*,224,224,3)-shaped tensor (normalized batch of RGB-images)

Architecture info:

- Type: Deep Residual Convolutional Neural Net (RNN/CNN)
- Number of residual blocks: 50
- Number of learnable parameters: 25.5M
- Number of hyperparameters: 53.1T
- Runtime: Keras with tensorflow backend

## Input Image



## Response from Artificial Neural Network

Image processed: true

**Classification failed**

**No distinct/unique match for known classes**

**Best matches:**

racer (probability:19.781%)  
sports\_car (probability:19.045%)  
car\_wheel (probability:13.644%)  
convertible (probability:6.213%)  
pickup (probability:4.880%)

# Image Classification & Transfer Learning mit Convolutional Neural Nets

AI Info    Classify Image

## Response from Artificial Neural Network

You are connected with a modified ResNet50 instance.  
Specialization via transfer learning: Cars

General info:

- Description: ResNet50 trained on Stanford.Cars dataset
- Origin: Deep learning architecture by Kaiming He et.al.,2015
- Transfer learning adoption: Tom Stahl
- Task type: Computer vision / single object image classification

Instance info:

- Scope: Cars (American market up to 2013)
- Target classes: 196
- Training data: Stanford.Cars, 11286 samples
- Input: (\*,224,224,3)-shaped tensor (normalized batch of RGB-images)

Architecture info:

- Type: Deep Residual Convolutional Neural Net (RNN/CNN)
- Number of residual blocks: 50
- Number of transfer learning layers: 1
- Number of frozen layers during fit: 0
- Number of learnable parameters: 23.9M
- Number of hyperparameters: 53K
- Runtime: Keras with tensorflow backend

## Transfer Learning = Adaption auf andere Domäne

- **Wiederverwendung des „visuellen Cortex“**
- **Wesentlich weniger Samples nötig**
- **Wesentlich kürzere Trainingszeit**

# Image Classification & Transfer Learning mit Convolutional Neural Nets

AI Info

Classify Image

## Response from Artificial Neural Network

You are connected with a modified ResNet50 instance.  
Specialization via transfer learning: Cars

General info:

- Description: ResNet50 trained on Stanford.Cars dataset
- Origin: Deep learning architecture by Kaiming He et.al.,2015
- Transfer learning adoption: Tom Stahl
- Task type: Computer vision / single object image classification

Instance info:

- Scope: Cars (American market up to 2013)
- Target classes: 196
- Training data: Stanford.Cars, 11286 samples
- Input: (\*,224,224,3)-shaped tensor (normalized batch of RGB-images)

Architecture info:

- Type: Deep Residual Convolutional Neural Net (RNN/CNN)
- Number of residual blocks: 50
- Number of transfer learning layers: 1
- Number of frozen layers during fit: 0
- Number of learnable parameters: 23.9M
- Number of hyperparameters: 53K
- Runtime: Keras with tensorflow backend

## Input Image



## Response from Artificial Neural Network

Image processed: true

Classification:

**Dodge Challenger SRT8 2011** (probability:99.943%)

Dodge Charger SRT-8 2009 (probability:0.055%)

Rolls-Royce Phantom Sedan 2012 (probability:0.001%)

Chevrolet Camaro Convertible 2012 (probability:0.001%)

Jaguar XK XKR 2012 (probability:0.000%)

# Image Classification & Transfer Learning mit Convolutional Neural Nets

AI Info

Classify Image

## Response from Artificial Neural Network

You are connected with a modified ResNet50 instance.  
Specialization via transfer learning: Cars

General info:

- Description: ResNet50 trained on Stanford.Cars dataset
- Origin: Deep learning architecture by Kaiming He et.al.,2015
- Transfer learning adoption: Tom Stahl
- Task type: Computer vision / single object image classification

Instance info:

- Scope: Cars (American market up to 2013)
- Target classes: 196
- Training data: Stanford.Cars, 11286 samples
- Input: (\*,224,224,3)-shaped tensor (normalized batch of RGB-images)

Architecture info:

- Type: Deep Residual Convolutional Neural Net (RNN/CNN)
- Number of residual blocks: 50
- Number of transfer learning layers: 1
- Number of frozen layers during fit: 0
- Number of learnable parameters: 23.9M
- Number of hyperparameters: 53K
- Runtime: Keras with tensorflow backend

## Input Image



## Response from Artificial Neural Network

Image processed: true

Classification:

**Chevrolet Corvette Convertible 2012** (probability:82.123%)  
Mercedes-Benz 300-Class Convertible 1993 (probability:8.252%)  
Ferrari California Convertible 2012 (probability:5.712%)  
Ford GT Coupe 2006 (probability:2.870%)  
Plymouth Neon Coupe 1999 (probability:0.243%)

# Image Classification & Transfer Learning mit Convolutional Neural Nets

AI Info

Classify Image

## Response from Artificial Neural Network

You are connected with a modified ResNet50 instance.  
Specialization via transfer learning: Cars

General info:

- Description: ResNet50 trained on Stanford.Cars dataset
- Origin: Deep learning architecture by Kaiming He et.al.,2015
- Transfer learning adoption: Tom Stahl
- Task type: Computer vision / single object image classification

Instance info:

- Scope: Cars (American market up to 2013)
- Target classes: 196
- Training data: Stanford.Cars, 11286 samples
- Input: (\*,224,224,3)-shaped tensor (normalized batch of RGB-images)

Architecture info:

- Type: Deep Residual Convolutional Neural Net (RNN/CNN)
- Number of residual blocks: 50
- Number of transfer learning layers: 1
- Number of frozen layers during fit: 0
- Number of learnable parameters: 23.9M
- Number of hyperparameters: 53K
- Runtime: Keras with tensorflow backend

## Input Image



## Response from Artificial Neural Network

Image processed: true

**Classification failed**

**No distinct/unique match for known classes**

**Best matches:**

HUMMER H3T Crew Cab 2010 (probability:28.610%)

Bentley Mulsanne Sedan 2011 (probability:11.431%)

Acura ZDX Hatchback 2012 (probability:9.035%)

Jeep Liberty SUV 2012 (probability:8.209%)

Ferrari California Convertible 2012 (probability:7.326%)

## UseCases für Image Recognition mit Transfer Learning

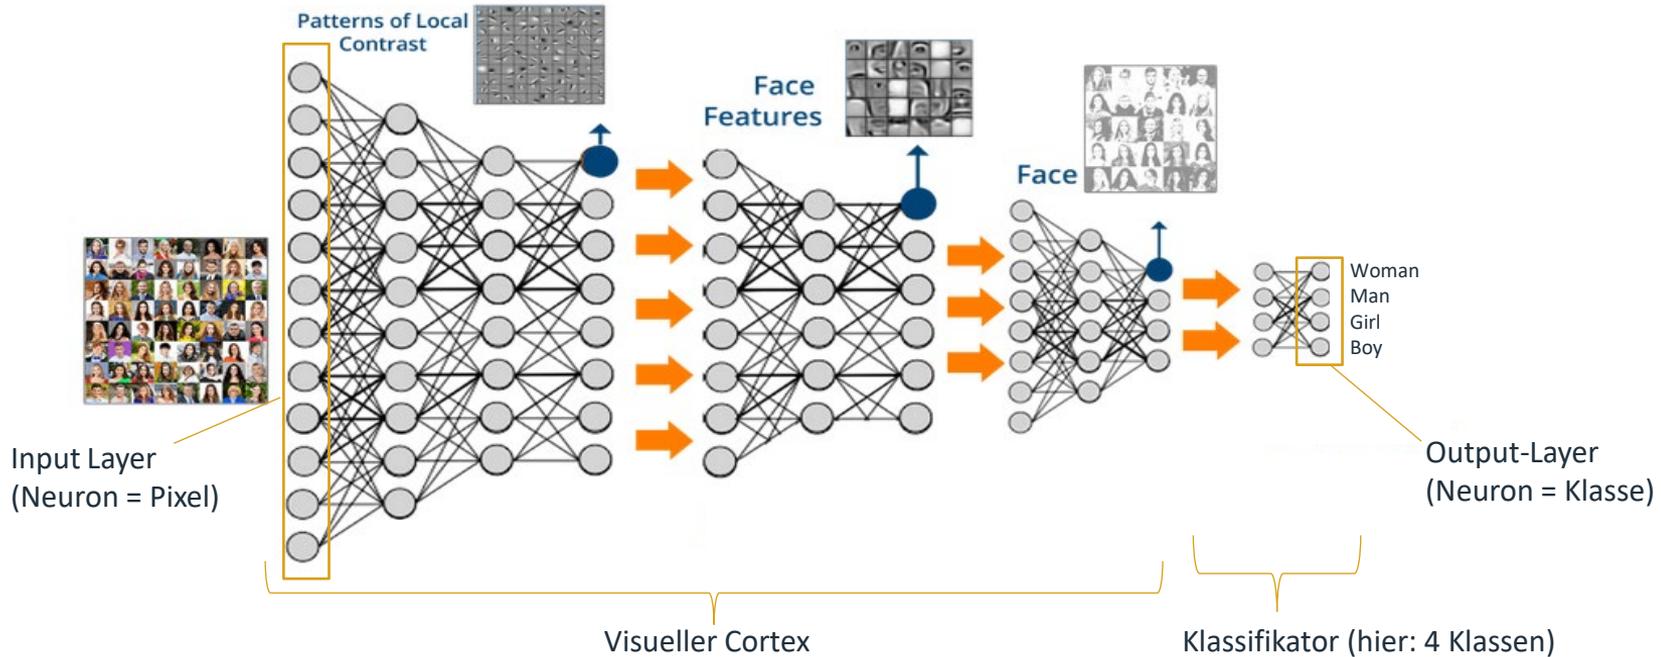
- Automatische Schadenklassifikation bei Versicherungen
- Medizinische Diagnostik
- Fehlerdiagnose in der industriellen Fertigung
- Umwelt(schutz) Überwachung durch Webcams o. Drohnen
- U.v.m.

# Convolutional Neural Nets – Beispiel: Face Classification

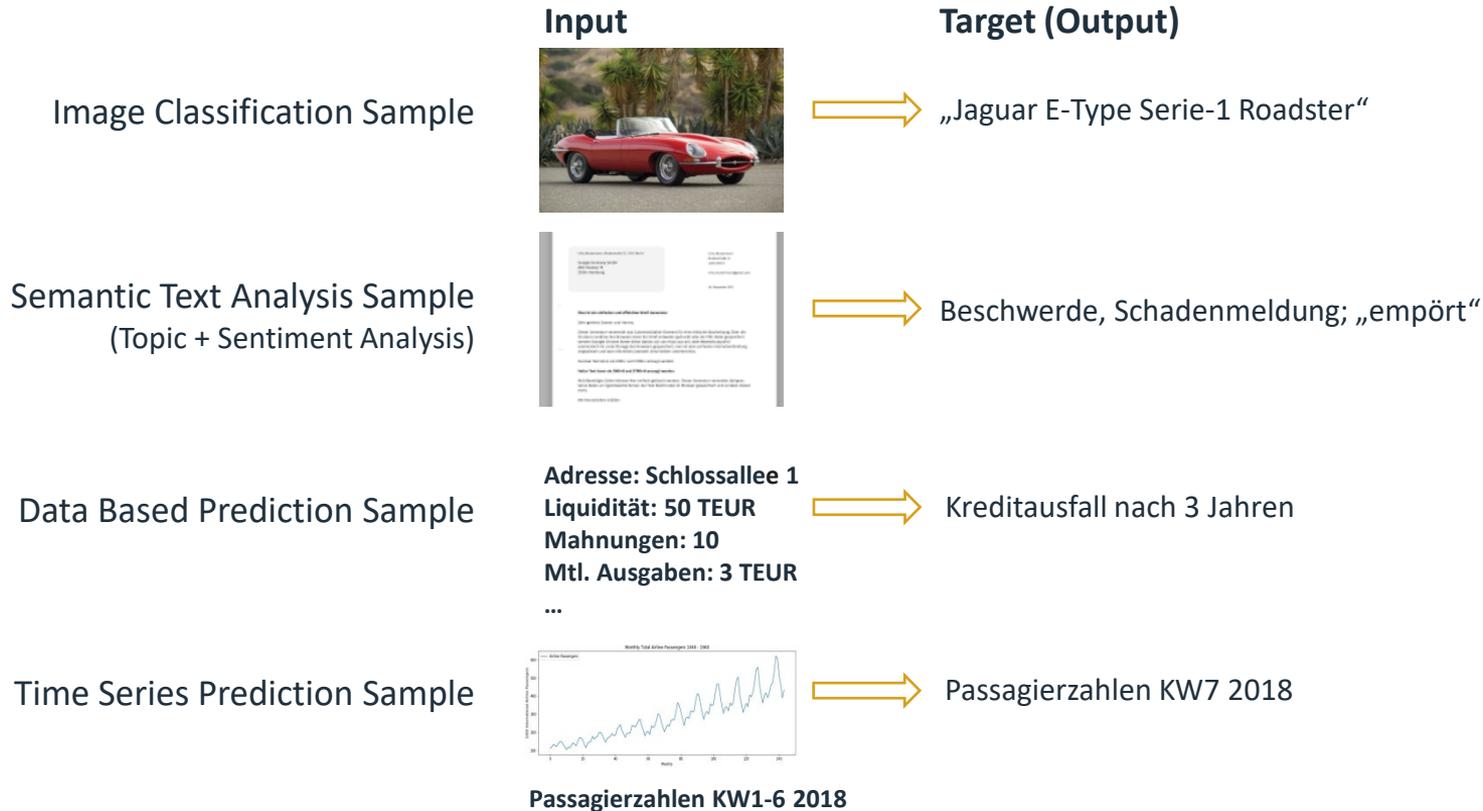


## Classification Output

Woman:	85%
Girl:	14,5%
Boy:	0,5%
Man:	0%



# Supervised Learning – Training and Validation: Samples



# Supervised Learning – Training and Validation: Sample Sets

## Samples

Min. ca. 8 Tsd.

Avg. ca. 80 Tsd.

Large ca. 1 Mio.

Very Large ca. 10 Mio.

Preprocessing



Data Augmentation



Validation

Training



# Agenda

Die drei großen Bereiche des Machine Learning –  
dazu relevante Anwendungsbeispiele, sowie Einführung in die Funktionsweise

1. KI – Sichten
2. Supervised Learning: Image Classification mit Convolutional Neural Nets
3. **Unsupervised Learning: Anomalieerkennung/Fraud Detection**
4. Reinforcement Learning: Deep Q-Learning
5. KI - typische Missverständnisse
6. Projektmanagement-Aspekte

## Data-Based Unsupervised Learning - Charakteristika

- Samples bestehen nur aus dem Input – es gibt keine Labels (Targets) (d.h. keine Zielvorgabe/Soll-Output).
- Das ML-Modell muss selbstständig Strukturen und Zusammenhänge in den Daten erkennen/lernen.
- Supervised Learning ist in der Regel genauer und führt direkter zum Ziel, dafür kann Unsupervised Learning verwendet werden, wenn das genaue Lernziel a priori noch unbekannt (Data-Mining) oder das Labeling der Trainingsdaten zu teuer/aufwändig ist.
  - ▶ Spezialfall Anomalieerkennung: Oftmals sind (fast) nur Daten verfügbar, die den Normalfall repräsentieren (Bsp. Server-Logs oder Bank-Transaktionen). Das Modell muss also lernen, diesen Datenraum zu „verstehen“. Anomalien sind dann (neue/unbekannte) Daten, die diesem Verständnis nicht entsprechen.

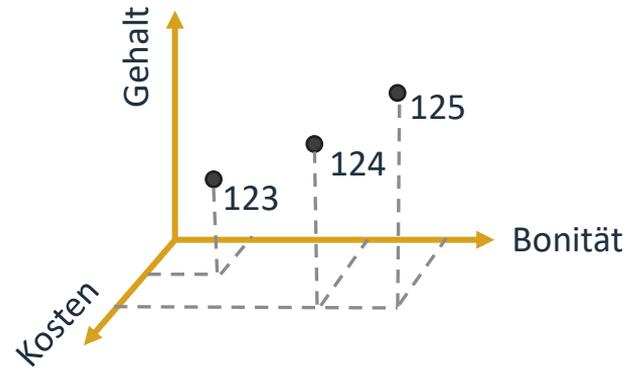
# AI/ML Grundlagen – Datenräume und Dimensionen

## Beispiel: Vereinfachter Kreditrating Datensatz

Identifikator + 3 Attribute

KdNr	Bonität	Gehalt	Kosten
123	5000	2000	1500
124	25000	2500	2000
125	30000	3000	2000

## 3dim Datenraum (math.: Vektorraum)



- Spalten/Tabellenüberschriften sind Dimensionen im Datenraum
- Eine Zeile/individueller Datensatz ist ein Punkt (Vektor) im Datenraum
- Der Wert einer Zelle ist ein Wert auf der entsprechenden Achse im Datenraum (Vektor-Komponente)

In der Praxis entstehen schnell hochdimensionale Datenräume, die daher nicht 1:1 visualisiert werden können

# Self Organizing Maps – Topology of the Human Brain

The human brain has two self organized cortical maps – i.e. 2-dim projections onto the surface of the brain of sensoric resp. motoric systems.

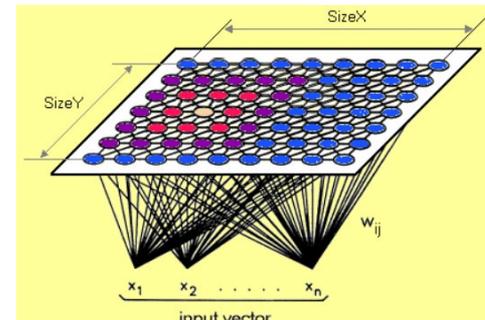
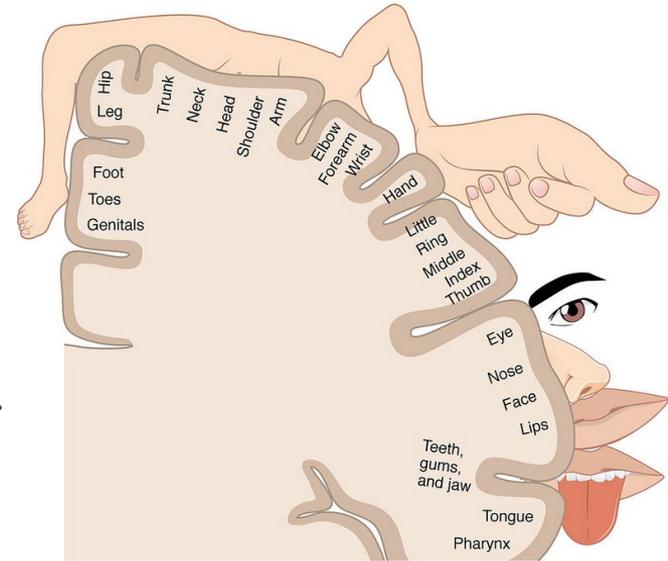
- Sensoric cortical map (right cerebral hemisphere)
- Motoric cortical map (left cerebral hemisphere)

These 2-dim maps preserve topological features of the 3-dim structures they represent – esp. nerve density.

The maps are plastic – i.e. adaptive (e.g. pianist vs. drummer).

## Artificial Self Organizing Maps (SOM)

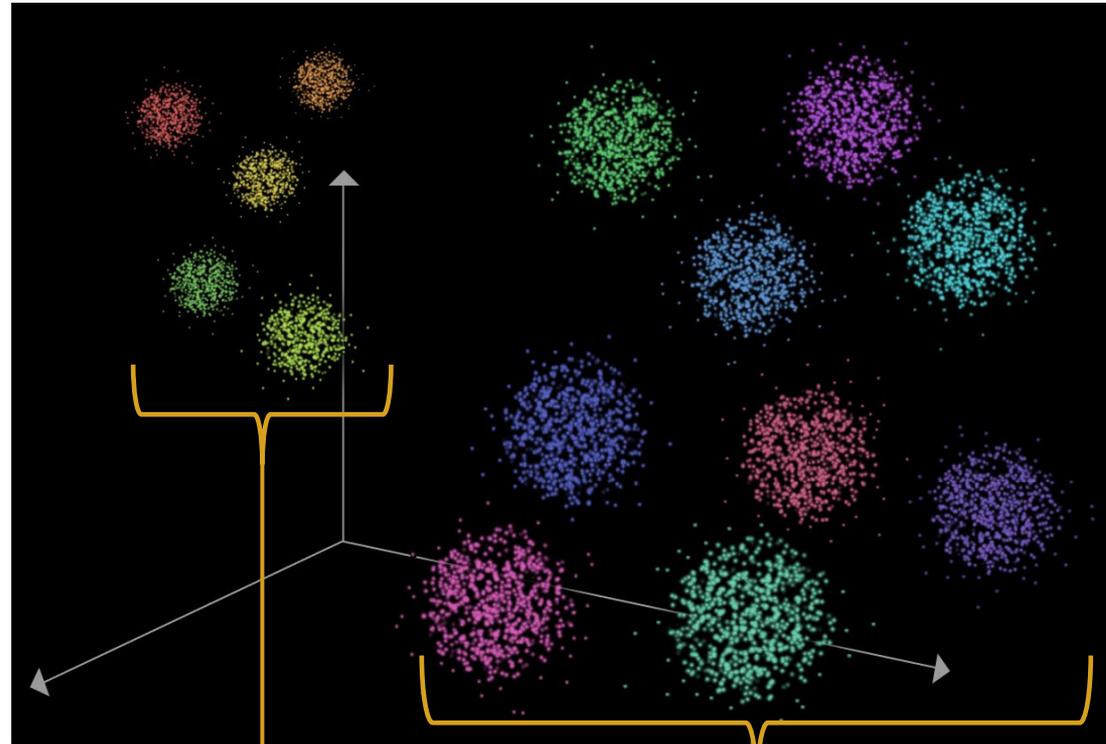
are a kind of Artificial Neural Network – quite different from standard ANN - inspired by these cortical models.



# Unsupervised Learning: SOM-Test

Generated points on disjoint hyperspheres in 14-dim abstract vector space.

Added gaussian noise to the distance from the sphere center for each point.

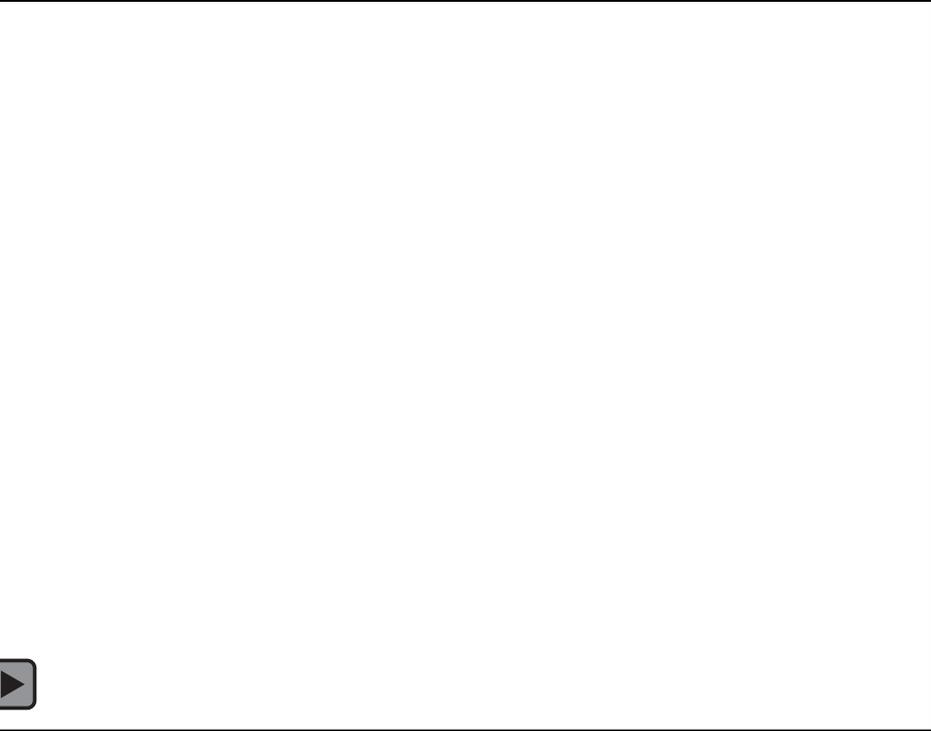


5 spheres in 5-dim subspace

9 spheres in 9-dim subspace

## Unsupervised Learning: SOM-Test

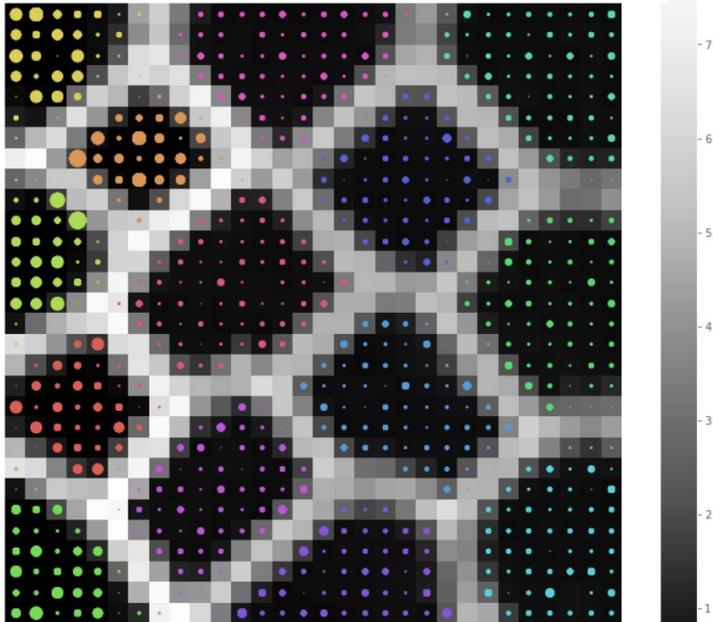
Self organized 2-dim map of 14-dim data space  
containing 14 noisy manifolds (hollow hyperspheres).  
Topological features are preserved.



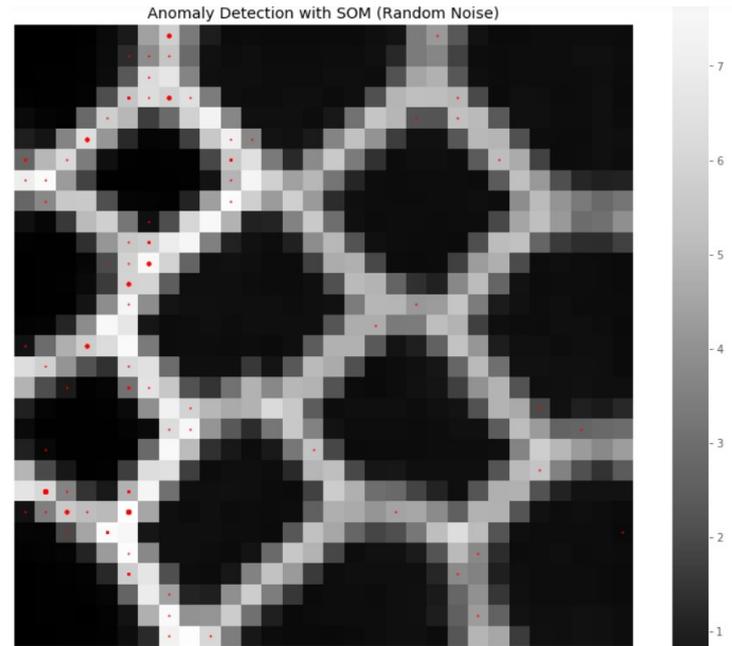
# Unsupervised Learning: SOM-Test

Self organized 2-dim map of 14-dim data space containing 14 noisy manifolds (hollow hyperspheres). Topological features are preserved.

9 large spheres in 9-dim subspace, 5 smaller spheres in 5-dim subspace.  
Bright neurons = large SOM-“distance“ (i.e. cluster borders)



Anomaly detection based on trained SOM: Random noise (100 data points) is basically Mapped onto „bright“ neurons – i.e. anomalies.



## ShowCase: Anomalie-Erkennung mit Self Organizing Map (SOM)

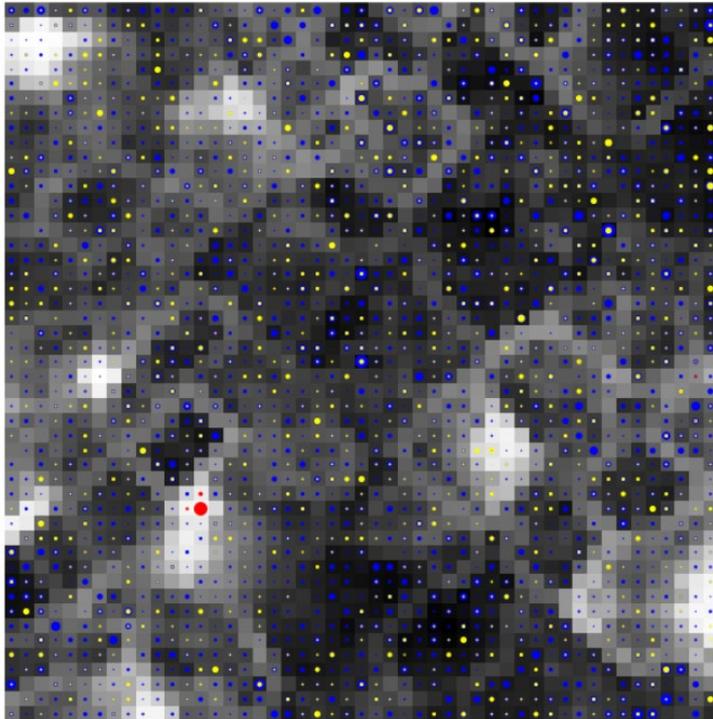
**Aufgabe: Erkennung von Anomalien (Betrugsfällen) mittels Unsupervised Learning - d.h. das Modell wird ausschließlich mit normalen Tx trainiert und muss lernen, diesen Datenraum zu „verstehen“**

Trainingsdaten: 10000 normale Tx aus dem **28-dim** Basisdatensatz. Validierung: ca. 1500 normale Tx und ca. 500 Betrugsfälle

# ShowCase: Anomalie-Erkennung mit Self Organizing Map (SOM)

**Aufgabe: Erkennung von Anomalien (Betrugsfällen) mittels Unsupervised Learning - d.h. das Modell wird ausschließlich mit normalen Tx trainiert und muss lernen, diesen Datenraum zu „verstehen“**

Trainingsdaten: 10000 normale Tx aus dem **28-dim** Basisdatensatz. Validierung: ca. 1500 normale Tx und ca. 500 Betrugsfälle



## Ergebnis (Visualisierung der SOM)

- Dunkle Neuronen -> enge Nachbarschaft im Datenraum
- Helle Neuronen -> Nachbar Neuronen liegen „weit entfernt“ im Datenraum
- Blau: Trainierte, normale Tx
- Gelb: Nicht-trainierte, normale Tx (Validierung)
- Rot: Nicht-trainierte Betrugsfälle/Anomalien (Validierung)

=> **Normale Tx liegen in dunklen Bereichen**

=> **Betrugsfälle werden von hellen Neuronen „angezogen“**

=> **Das unsupervised entstandene Modell kann als Klassifikator für zukünftige Transaktionen verwendet werden!**

Metriken:

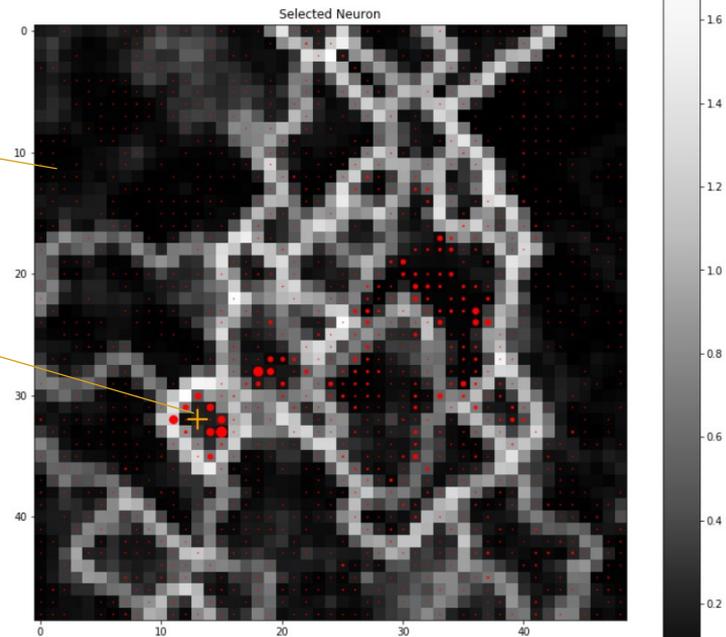
train recall (false negatives critical)	= 93.62%
validation recall (false negatives critical)	= 94.23%
validation accuracy (true positives/negatives critical)	= 93.00%
validation precision (false positives critical)	= 96.26%
validation f1-score (balanced recall and precision)	= 95.24%

BI-Aspekte: Data-Visualization, -Analytics, -Mining im Kontext von ML

**AI-Systeme werden mittels ML hergestellt.**

**Manche ML-Methoden/Verfahren stellen darüber hinaus bzw. als Nebeneffekt nützliche Zwischenergebnisse für eine fachliche Interpretation bereit („AI based BI“):**

- **Visualisierungstechniken**  
z.B. Clustering
- **Drill-Down / Trace-Back**  
z.B. Identifikation gehäufter Kreditrisiken im Datenraum  
(hier keine Anomalien)
- **Mining**  
z.B. Identifikation von Potenzial für Umsatzsteigerung



# ShowCase: Anomalie-Erkennung mit Parametric t-SNE und Clustering

## Aufgabe:

Erkennung von Anomalien (Betrugsfälle bei Kreditkarten-Transaktionen) mittels Unsupervised Learning - Das Modell wird ausschließlich mit normalen Tx (d.h. Nicht-Betrugsfällen) trainiert und muss lernen, diesen Datenraum zu „verstehen“. Dieser ist 28-dimensional und enthält 10000 normale Transaktionen

## Modell:

Ein Dimensionsreduzierer (28 -> 3), dem ein neuronales Netz „injiziert“ wurde. Somit können auch neue, dem Modell nicht bekannte Daten verarbeitet werden.

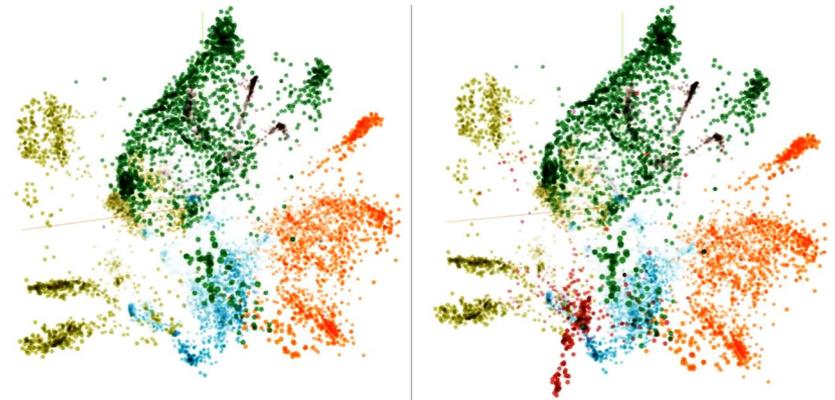
## Ergebnis:

Der trainierte Normalfall enthält 5 Cluster.  
Die Betrugsfälle bilden ein neues Cluster, das mathematisch separiert werden kann.

**Somit ist eine Prognose für zukünftige Transaktionen möglich.**

## Metriken:

train recall (false negatives critical)	= 97.13%
validation recall (false negatives critical)	= 96.91%
validation accuracy (true positives/negatives critical)	= 93.10%
validation precision (false positives critical)	= 94.00%
validation f1-score (balanced recall and precision)	= 95.43%

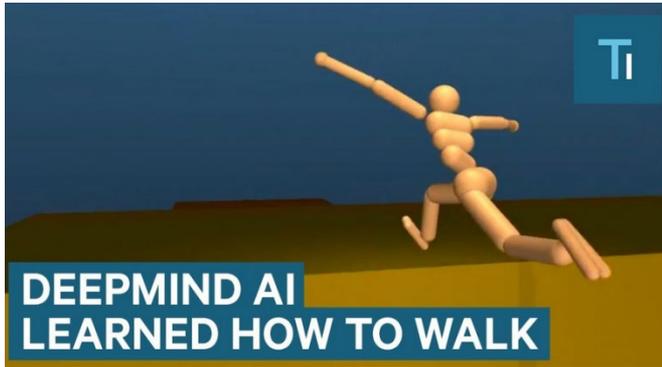


# Agenda

Die drei großen Bereiche des Machine Learning –  
dazu relevante Anwendungsbeispiele, sowie Einführung in die Funktionsweise

1. KI – Sichten
2. Supervised Learning: Image Classification mit Convolutional Neural Nets
3. Unsupervised Learning: Anomalieerkennung/Fraud Detection
4. Reinforcement Learning: Deep Q-Learning
5. KI - typische Missverständnisse
6. Projektmanagement-Aspekte

# AI-Breakthroughs : Reinforcement Learning (RL) - Robotics



**Google Deepmind Runner**



**Boston Dynamics Atlas**

# AI-Breakthroughs : Reinforcement Learning (RL) – „Full Information Games“



Branching-Factor Schach  $\approx 20$   
Branching-Factor Go  $\approx 200$   
Mögliche Go Positionen  $\approx 10^{170}$   
Atome im sichtb. Universum  $\approx 10^{80}$



## AlphaGo Zero



# AI-Breakthroughs : Reinforcement Learning (RL) – „Incomplete Information Games “

## DotA (Defense of the Ancients) – Open AI Five vs. 5 Humans (Pro Gamer)



Open AI Five won against champion DotA pro team



### Challenges

- Long time horizons
- Partially-observed state
- High-dim continuous action space
- High-dim continuous observation space

Open-AI Five plays 180 years worth of games against itself every day

# AI – Research Benchmarks: Games

## Board Games (tief aber nicht visuell)



## Computer Games (visuell reichhaltig)



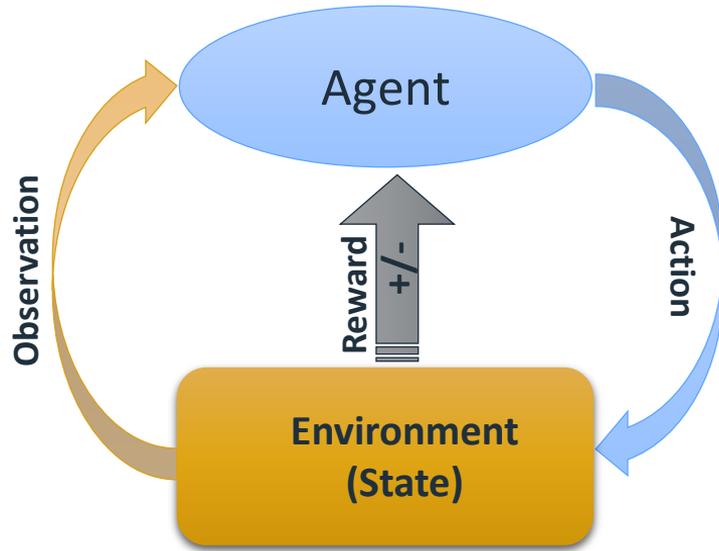
## Real World UseCases



Adobe Stock Datei-Nr.: 162980569 | Urheber: metamorworks

- Autonomes Fahren
- Robotics
- Steuerung von Industrieanlagen
- Intelligente Verkehrsleitung
- Geschäftsprozessoptimierung
- Proteinfaltung
- ...

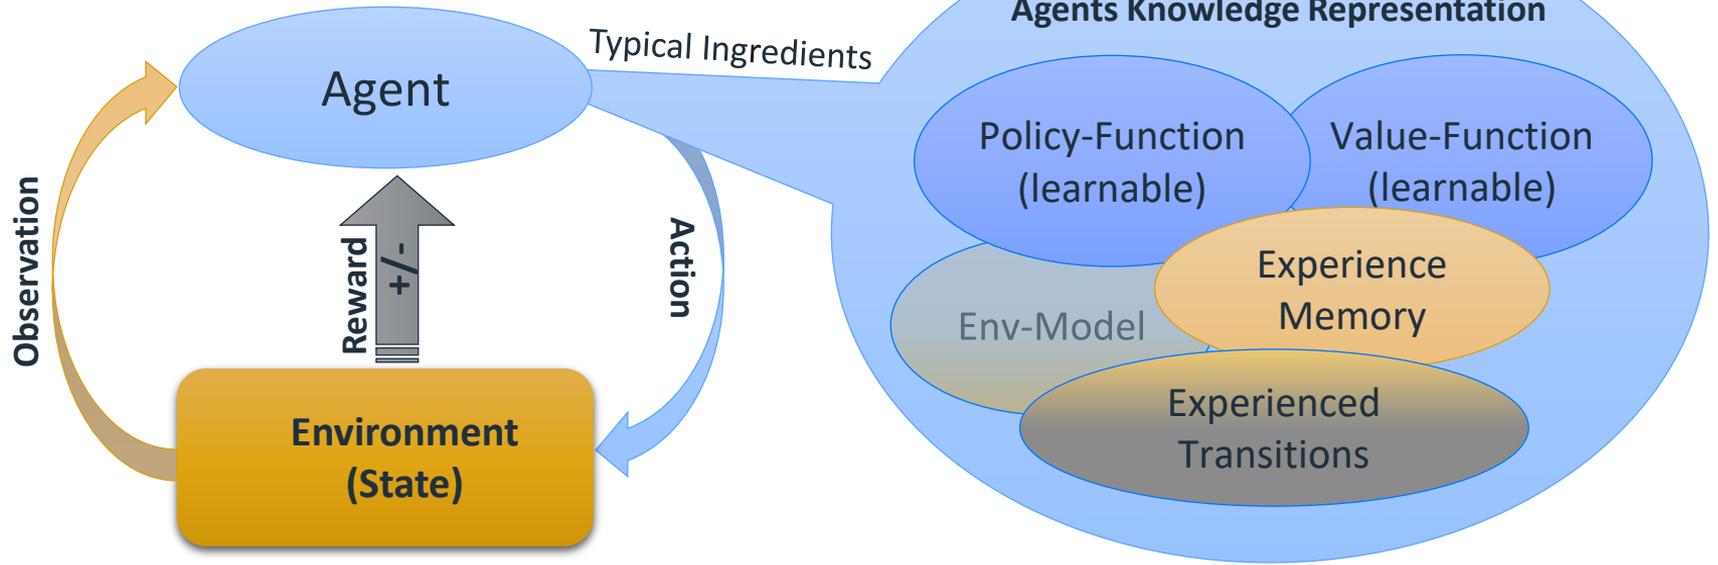
## Reinforcement Learning (RL)



**Observation:** (Observable part of) current state

**Reward:** Measure of „what is good“ or „bad“ (given by design)

# Reinforcement Learning (RL)



**Policy:** What to do next (learnable)

**Value:** Rating of a state based on reward prediction (learnable)

**Reward:** Measure of „what is good“ or „bad“ (given by design)

**Experience:** Past reaction of environment in a state to an action: reward + next obs.

**Env-Model:** Agents representation of Environment (optional, given or learnable)

# Agenda

Die drei großen Bereiche des Machine Learning –  
dazu relevante Anwendungsbeispiele, sowie Einführung in die Funktionsweise

1. KI – Sichten
2. Supervised Learning: Image Classification mit Convolutional Neural Nets
3. Unsupervised Learning: Anomalieerkennung/Fraud Detection
4. Reinforcement Learning: Deep Q-Learning
5. KI - typische Missverständnisse
6. Projektmanagement-Aspekte

## KI – typische Missverständnisse, Vorurteile und Irrtümer

- Der Fortschritt kommt durch den Hardware-Schub (Moore's Law) - neuronale Netze gibt es schließlich schon seit den 60er Jahren.
- KI kommt von den Tech-Giganten (Silicon Valley)
- KI = tiefe neuronale Netze (Deep Learning)
- KI benötigt (immer) Big Data
- KI ist heutzutage simpel – man nimmt einfach fertige Bausteine (LEGO-Prinzip)
- Die Mathematik ist nur theoretischer Hintergrund - um gute Systeme herzustellen muss man „nur“ gut coden können und die APIs kennen
- KI-Projekte sind genau wie herkömmliche Software-Projekte und benötigen keine weitere Adaption im Projektmanagement

# Agenda

Die drei großen Bereiche des Machine Learning –  
dazu relevante Anwendungsbeispiele, sowie Einführung in die Funktionsweise

1. KI – Sichten
2. Supervised Learning: Image Classification mit Convolutional Neural Nets
3. Unsupervised Learning: Anomalieerkennung/Fraud Detection
4. Reinforcement Learning: Deep Q-Learning
5. KI - typische Missverständnisse
6. **Projektmanagement-Aspekte**

# Klassische Software-Entwicklung vs. Supervised Machine Learning

- Eine AI ist „am Ende“ ein IT-System
- Solche Systeme entstehen auf eine ganz andere Art als klassische IT-Systeme

## Phasen/Zyklen/Tätigkeitsarten Klassisch



## Phasen/Zyklen/Tätigkeitsarten AI



## Charakter von KI-Projekten

### **KI-Projekte haben Gemeinsamkeiten mit der Modellbildung in den empirischen Wissenschaften**

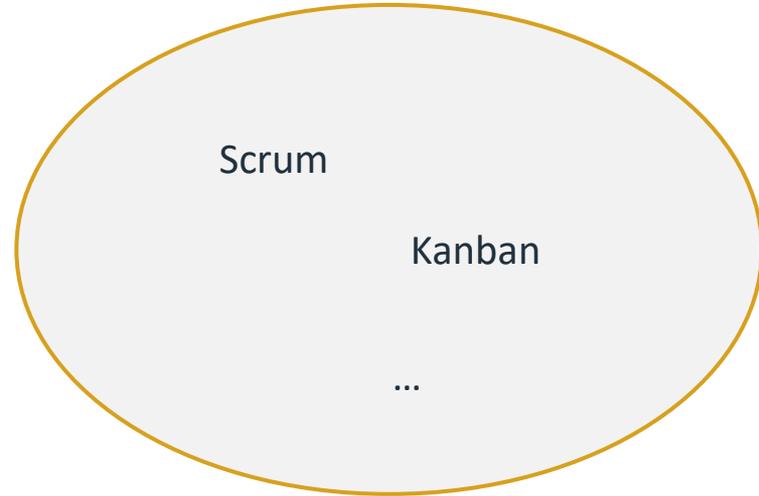
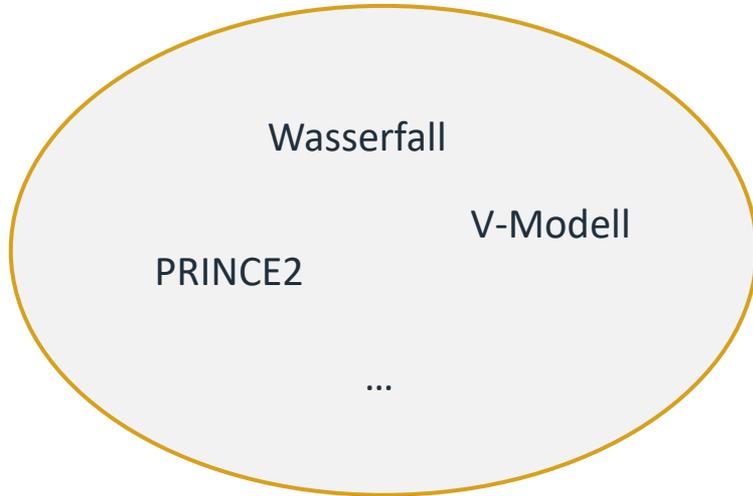
- These (Modell) und Validierung → Durchführung vieler, kleiner Experimente
- Erzielbares Ergebnis a priori nicht genau bekannt (hängt insb. z.B. von der Datenqualität ab)
- Mikro- und Makro-Zyklen (iterativ)
- Keine Fließbandarbeit („Fabrikmodus“)

# KI-geeignete Projektmanagement Methoden

## Klassisch



## Agil



# KI-geeignete Projektmanagement-Methoden

## **Contra klassische Methoden**

- Klassische Methoden sind zu starr und zu spezifikationszentrisch

## **Pro Kanban, contra Scrum**

- Feste Iterationslängen sind hinderlich. Ein kontinuierlicher Fluss von Aufgaben (statt Sprints) passt wesentlich besser zum Charakter von ML-Projekten
- Kanban ist flexibler als Scrum

## **Contra User-Stories**

- Eine Zerlegung in „Business-Features“ (User-Stories) ist im ML-Kontext i.d.R. sinnlos/nicht machbar (s. „Fabrikmodus“).  
Die Aufgaben müssen sich vom Schnitt/Typ an Data-Science- und ML-Tätigkeiten orientieren.

## b+m Informatik AG

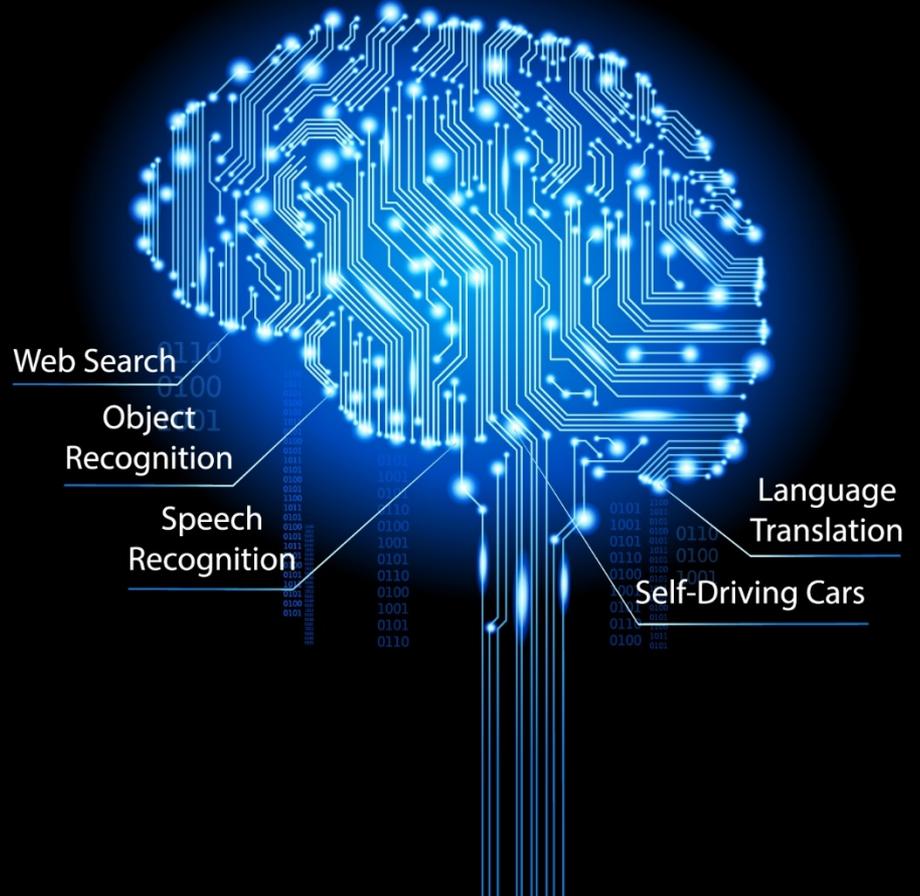
Rotenhofer Weg 20  
24109 Melsdorf

[www.bmiag.de](http://www.bmiag.de)

## Ihr Ansprechpartner

Thomas Stahl  
CTO  
Head of AI-Lab

[thomas.stahl@bmiag.de](mailto:thomas.stahl@bmiag.de)



# Artificial Neural Nets – Mathematischer Werkzeugkasten

Gradient Chain Rule:  $(f \circ g)'(c) = \nabla f(a) \cdot g'(c), a = g(c)$

## Optimizer

Backpropagation via SGD (Stochastic Gradient Descent), RMSProp (Root Mean Square Propagation), Adam (Adaptive Moment Estimation), ... (ca. 30+)

## Regularization

L2-Norm, L1-Norm, Dropout, ... (ca 20+)

SGD Iteration:  $w := w - \eta \nabla Q(w) = w - \eta \sum_{i=1}^n \nabla Q_i(w) / n$

Categorical Crossentropy:  $\mathcal{L}(\hat{\mathbf{y}}, \mathbf{y}) = -\frac{1}{N} \sum_i [y_i \log \hat{y}_i + (1 - y_i) \log(1 - \hat{y}_i)]$

## Loss Functions

MSE (Mean Squared Error), Binary Crossentropy, Categorical Crossentropy, ... (ca. 50+)

## Activation Functions

ReLU (Rectified Linear Unit), tanh (Tangens Hyperbolicus), SoftMax, Sigmoid, ... (ca. 20+)

Sigmoid:  $\text{sig}(t) = \frac{1}{1 + e^{-t}} = \frac{e^t}{1 + e^t} = \frac{1}{2} \cdot \left( 1 + \tanh \frac{t}{2} \right)$

Softmax:  $\sigma: \mathbb{R}^K \rightarrow \left\{ \sigma \in \mathbb{R}^K \mid \sigma_i > 0, \sum_{i=1}^K \sigma_i = 1 \right\} \quad \sigma(\mathbf{z})_j = \frac{e^{z_j}}{\sum_{k=1}^K e^{z_k}} \quad \text{for } j = 1, \dots, K.$

## Layer Types

Dense, Flatten, 1D/2D/3D-Convolutional, 1D/2D/3D-Max/Avg-Pooling, BatchNormalization, Recurrent, LSTM, Add, Upscaling, ... (ca. 50+)

## Architecture Pattern

Residual Block, Inception Block, Encoder, Bottleneck, Decoder, Long-Range Skip Connection, ... (ca. 100+)

## Architecture Types

Multilayer Perceptron (MLP), Convolutional (CNN), Recurrent (RNN), Long Short Term Memory (LSTM), Residual, Dense, Autoencoder, ... (ca. 50+)

## Reference Architectures

VGG16, ResNet50, InceptionV3, Xception, DenseNet, Unet, .. (ca. 50+)

# Datenschutz und ML: Endkundenspezifische oder Sensible Daten

Daten Vorverarbeitung (Input Preprocessing)

## Schema-Analyse

- Bestimmung ML-relevanter Attribute

## Vektorisierung

- Umwandlung kategorischer Attribute in numerische
- Ggf. Normierung, z.B. auf [-1, +1]

## Principal Component Analysis (PCA)

- Lineare Vektorraum Basistransformation
- Neue Attribute (Principal Components) sind stochastisch unabhängig
- PC1..n sind nach Varianz sortiert
- Abbildung ist ohne Kenntnis der Originaldaten/ Schemata nicht umkehrbar (Verschlüsselungsaspekt)
- Kein Informationsverlust =>ML-Modelle können auf den transformierten Attributen trainiert werden



Originaldaten

## b+m / Kunde

Gemeinsame Analyse und Vorverarbeitung

## b+m

Modellbildung und Validierung



## b+m / Kunde

Gemeinsame Schema-Analyse

vektorierte Daten

## b+m

Modellbildung und Validierung



## Kunde

Schema-Analyse, Vektorisierung, PCA

PCA-verschlüsselte Daten und Schemata

## b+m

Modellbildung Und Validierung

# Feature Engineering

## Feature Engineering

```
graph TD; FE[Feature Engineering] --- FC[Feature Construction]; FE --- FE_Ext[Feature Extraction]; FE --- FS[Feature Selection];
```

### Feature Construction

- Expand the dimensionality of the data by „handcrafted“ features (using stochastic methods)
- Purpose: Reveal hidden correlations to the model and
- Add knowledge to the model

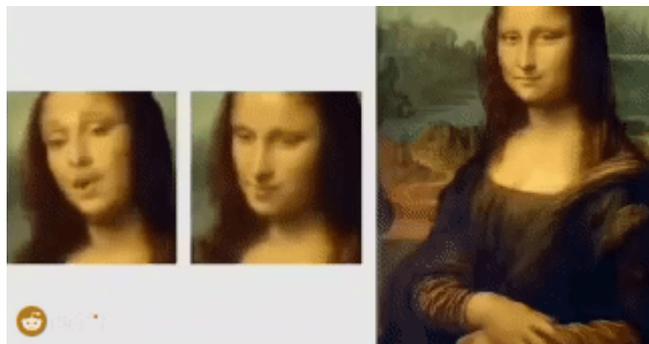
### Feature Extraction

- Make categorical and text information useable – aka „vectorization“
- Extract additional knowledge from data - typically via ML-methods like:
- Dimension reduction transformations and Manifold Learning

### Feature Selection

- A given data set is getting sparse exponentially when the number of features (dimensions) increases
- Feature Selection reduces data dimensionality
- Select features with the most explanatory power

## AI-Breakthroughs : Generative Adversarial Networks (GAN)



Animation Style Transfer from just one image !

Generate photorealistic images  
from textual description

this bird is red with white and has a very short beak



Deep Fake images and videos

# Generative Adversarial Networks (GAN) – Simplified Training Setup

Ian J. Goodfellow et. al

