



XAI

Sprechen Sie mit der Black Box





Geschichte und Entwicklung

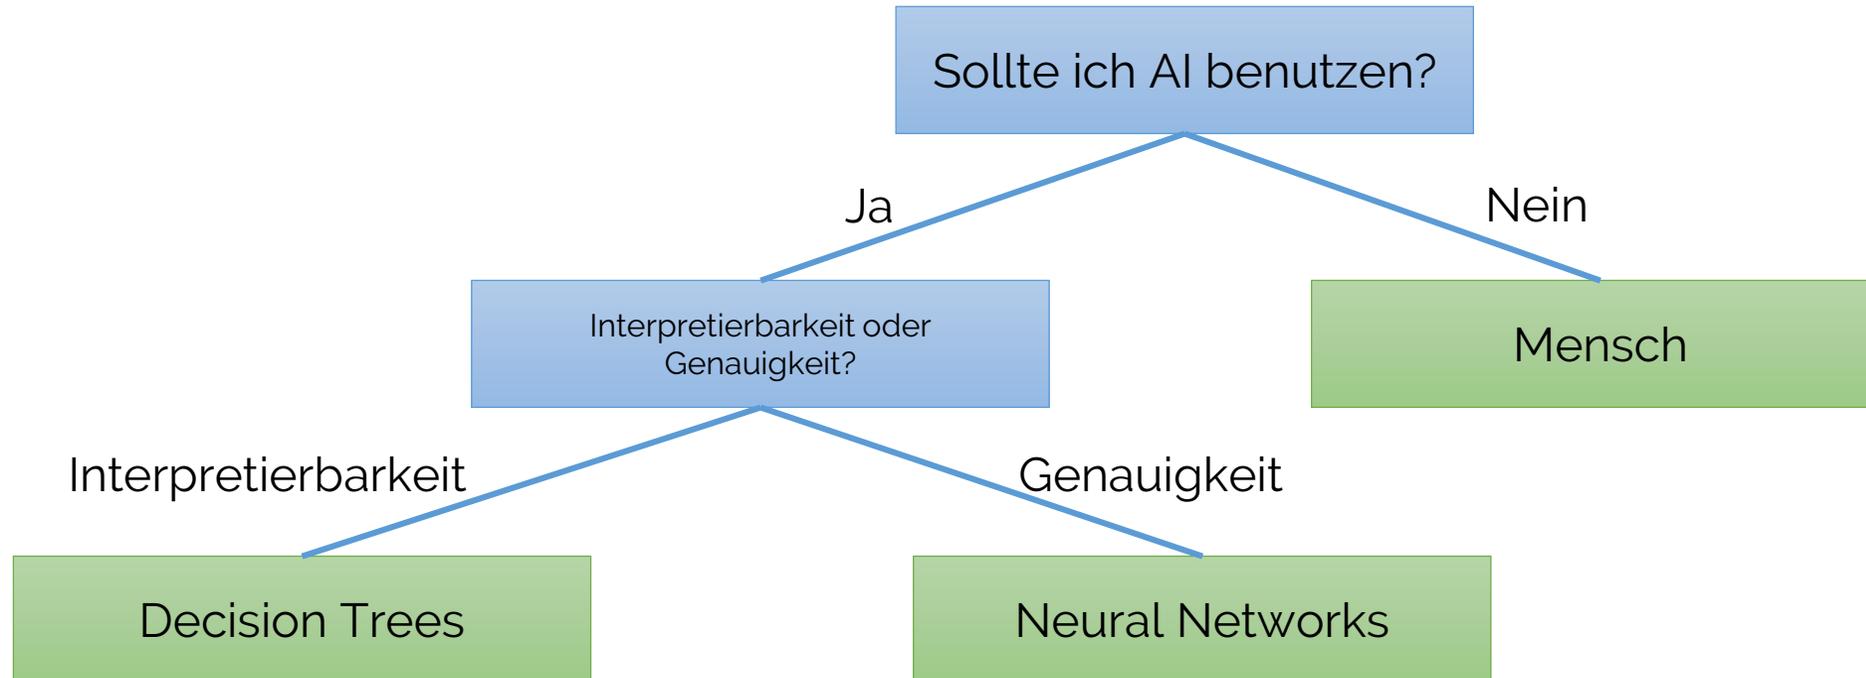
Von Entscheidungsbäumen zu tiefen Neuronalen Netzwerken

From Decision Trees to Deep Neural Networks



Decision Trees – Einfache Entscheidungen

Das interpretierbare Modelle zur Entscheidungsfindung



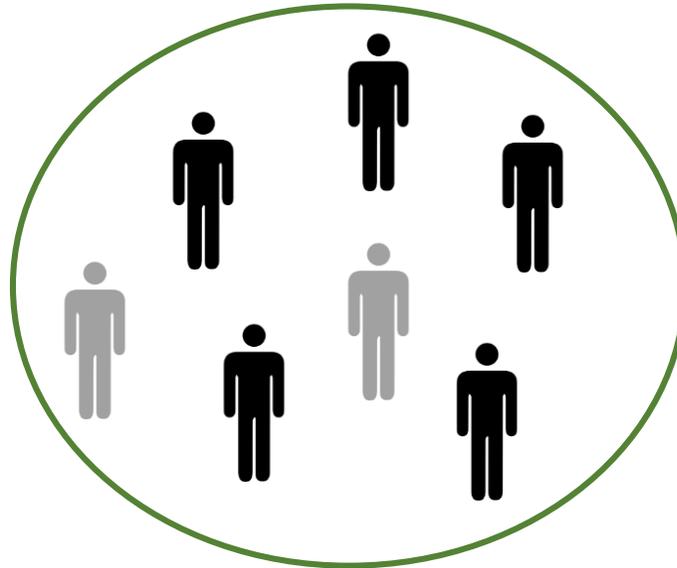


Random Forests – Vom Baum zum Wald

Mehrere Decision Trees führen zu besseren Ergebnissen – Wisdom of the Crowd Theorem



Entscheidung eines Experten
Decision Trees

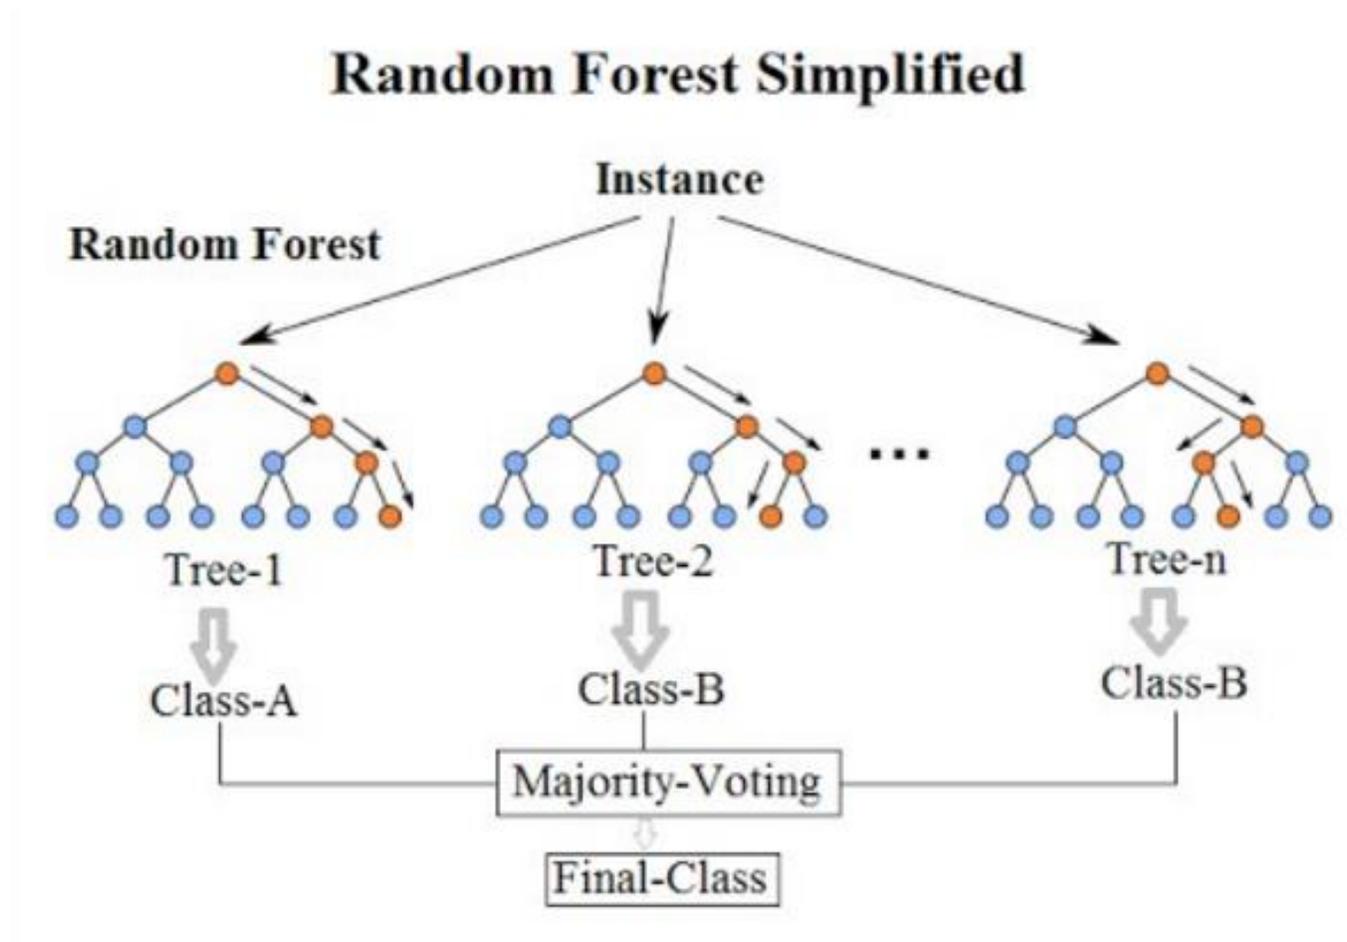


Entscheidung mehrerer Experten
und weiteren
Decision Trees Forest



Random Forests – Decision Forest

Höhere Genauigkeit – niedrigere Interpretierbarkeit



http://upload.wikimedia.org/wikipedia/commons/7/76/Random_forest_diagram_complete.png

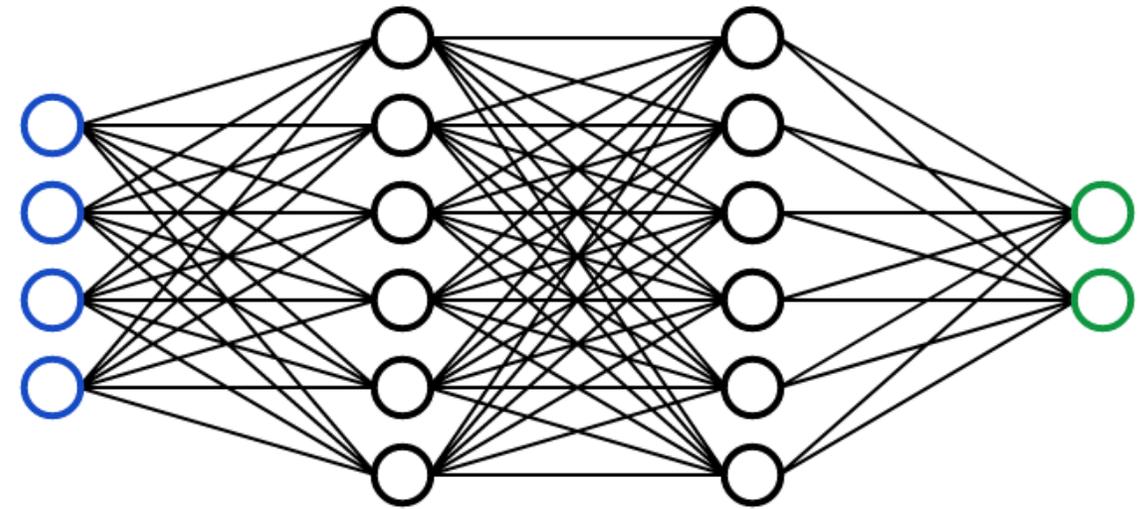


Neural Networks – Die nächste Stufe

Modellierung des menschlichen Gehirns - Geflecht aus Neuronen und Synapsen – **State-of-the-art Genauigkeit**



<https://i.pinimg.com/originals/4a/9c/78/4a9c78ba5228069fb30afe9e2e1bd559.jpg>



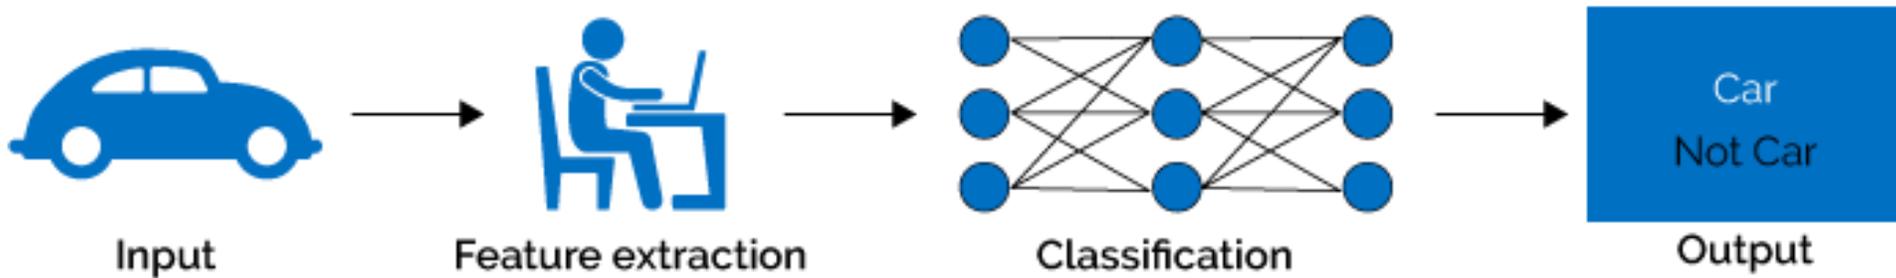
<https://victorzhou.com/media/nn-series/network.svg>



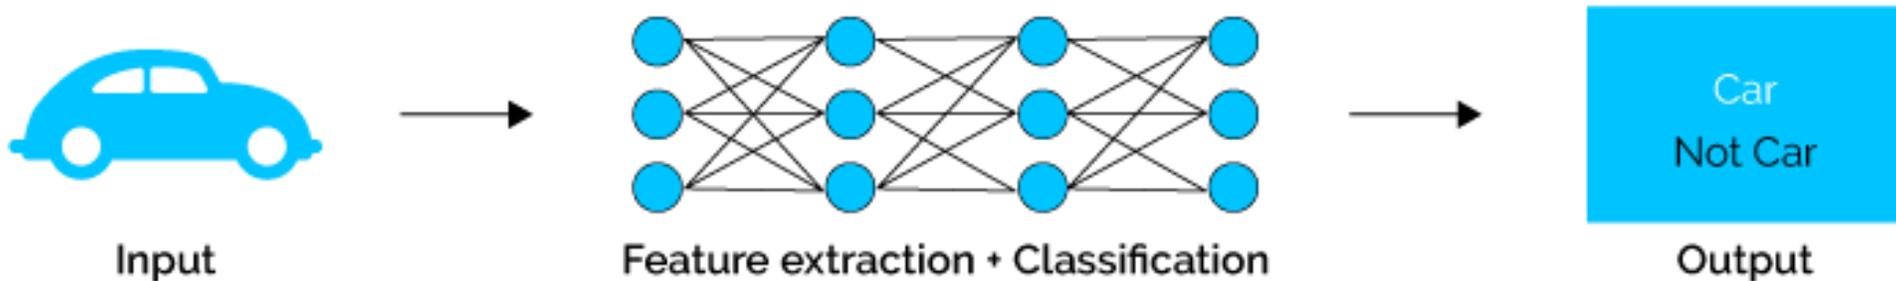
Deep Neural Revolution

Deep Learning ersetzt Domain Wissen und extrahierte Features des Menschen – Schwierige Interpretierbarkeit

Machine Learning



Deep Learning



<https://lawtomated.com/wp-content/uploads/2019/04/MLvsDL.png>



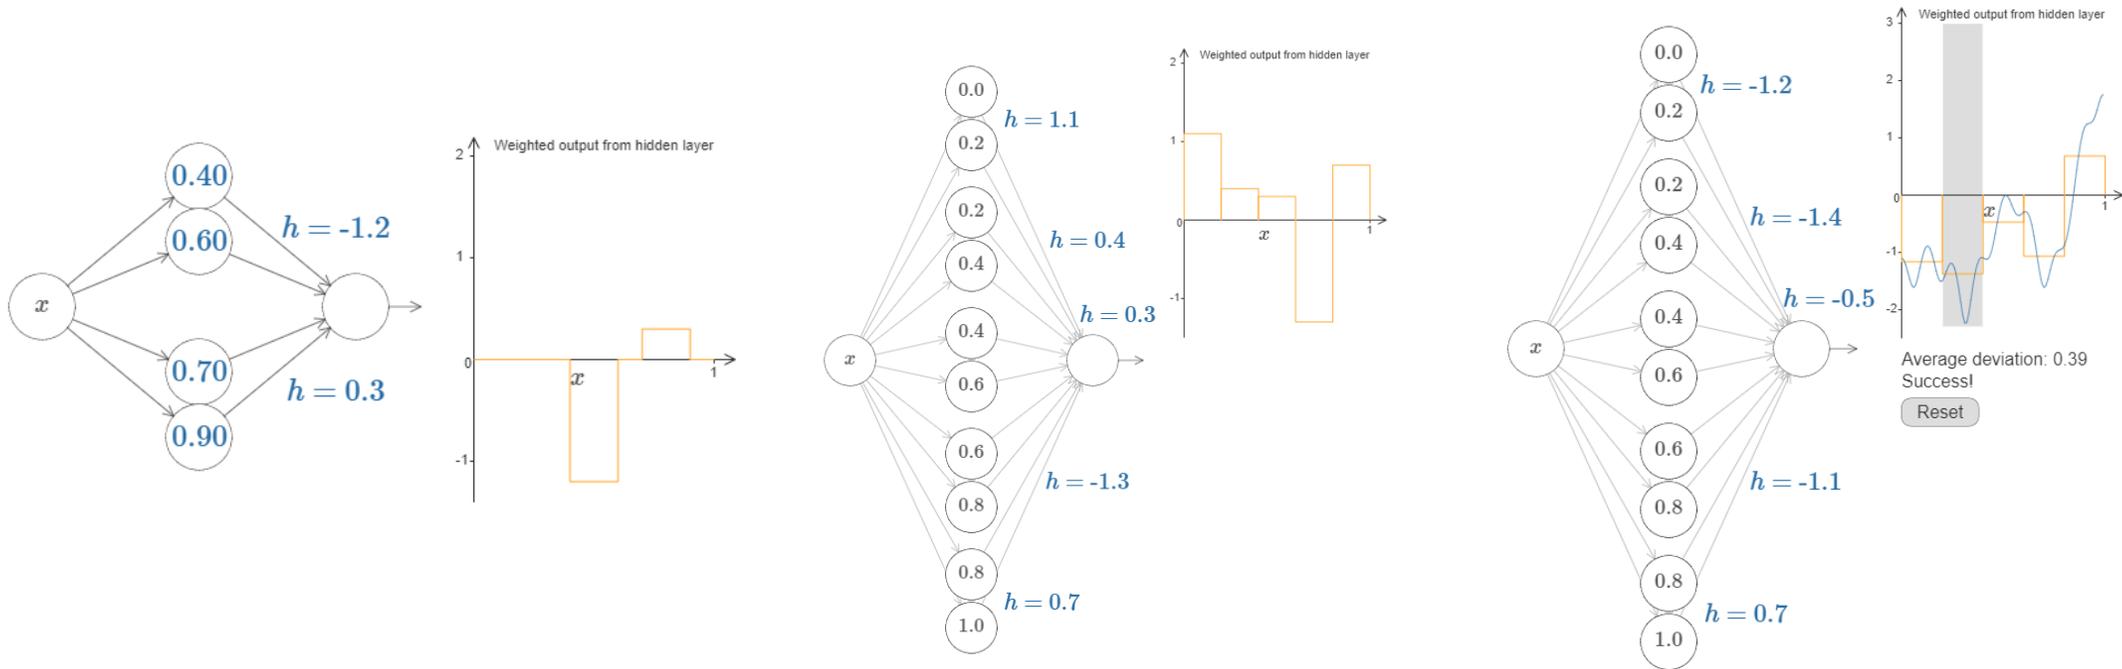
Von Erfolgen und Enttäuschungen

Deep Learning und dessen Probleme



Universal Function Approximator

Neural Networks können theoretisch jede Funktion abbilden – somit alles lernen und lösen – Die Hoffnung





Machine Translation

Traum des Menschen alle Sprachen zu verstehen und zu sprechen – Neural Networks als Hilfsmittel dazu



https://www.topbots.com/wp-content/uploads/2019/02/MT_feature_1600px.jpg



ALPAC Report

(Automatic Language Processing Advisory Committee) zeigt herbe Ernüchterung über AI und Neural Networks 1966
Dadurch nur wenige Forschungsgelder für AI in späteren Jahren

The ALPAC Report of 1966

“They concluded, in a famous 1966 report, that machine translation was more expensive, less accurate and slower than human translation.”



Photo: Eldon Lyttle,
https://commons.wikimedia.org/wiki/File:Computer-translation_Briefing_for_Gerald_Ford.jpg

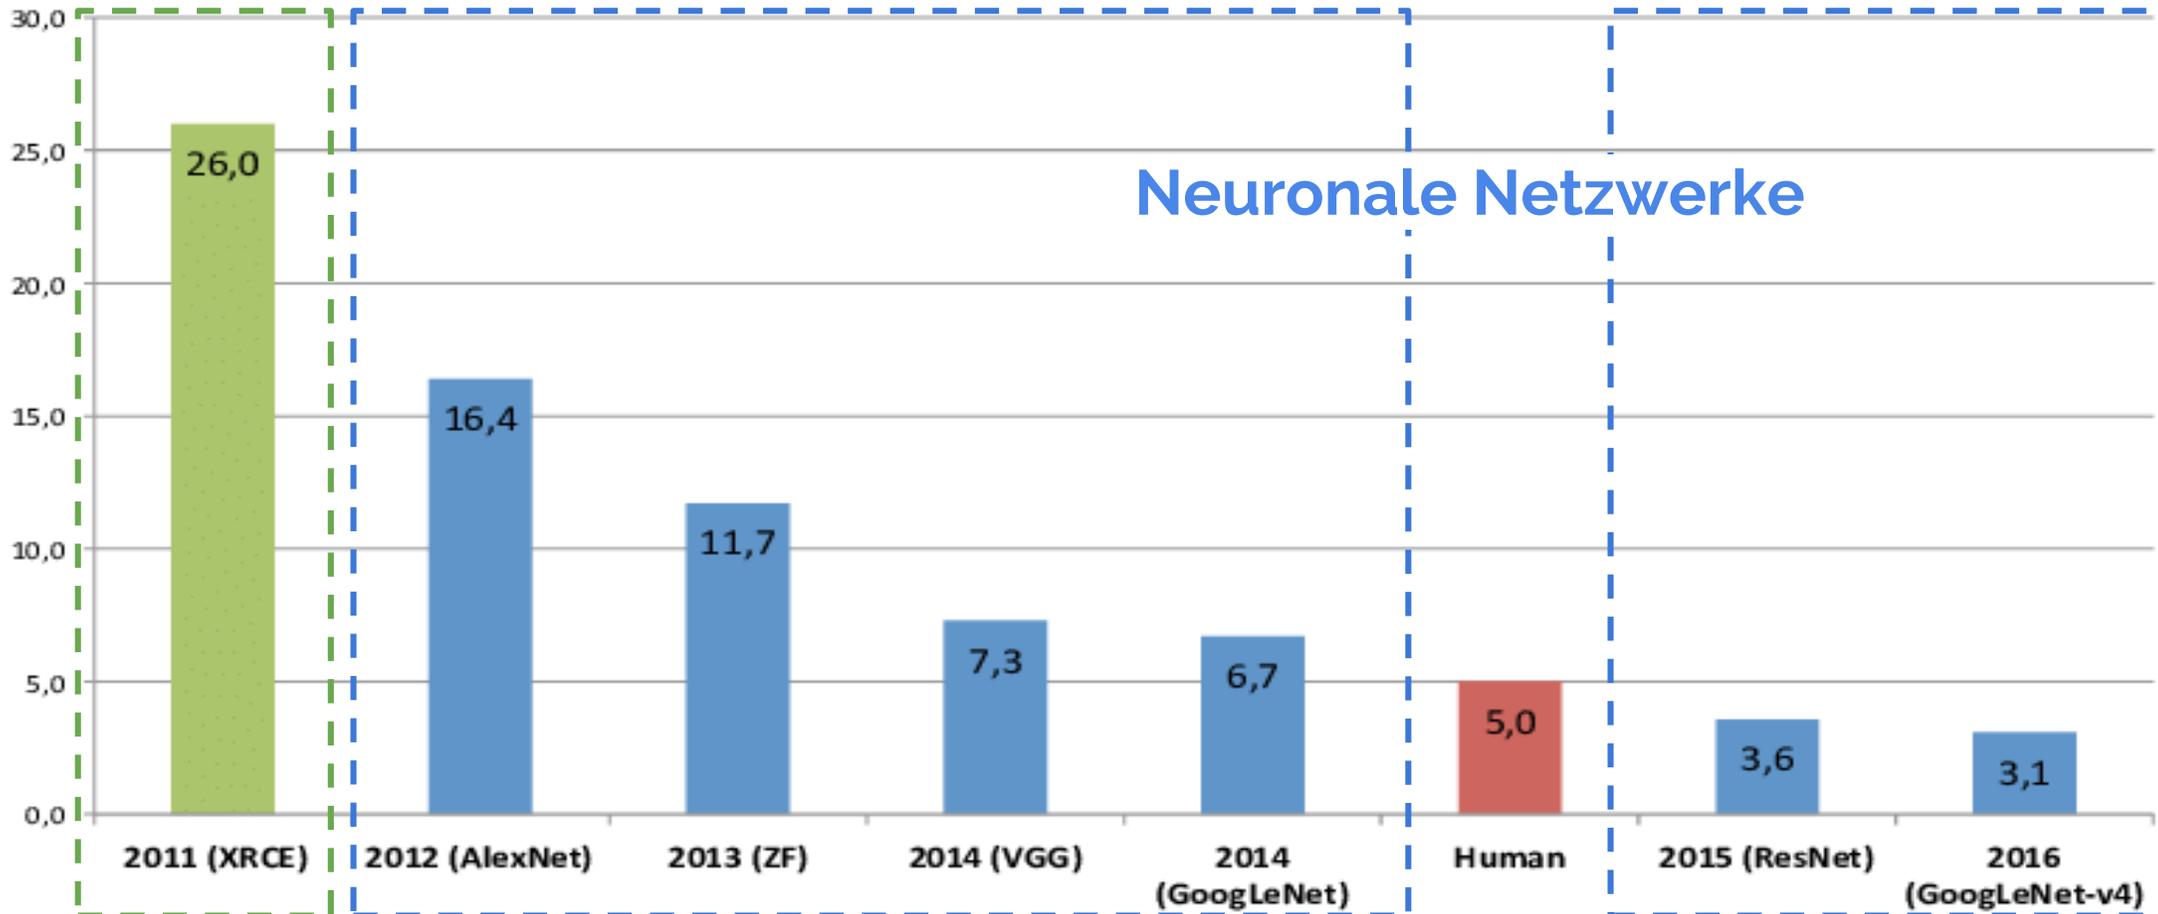
Nicht interpretierbar (Neural Networks)
Kostenintensive Analyse (Viel Computerleistung nötig)
Kostenintensive Forschung (Grundlagen fehlten)



Der Durchbruch von Deep Learning

Deep Learning schlägt traditionelle Machine Learning Verfahren in der Bildklassifizierung 2012

ImageNet Classification Error (Top 5)



https://www.researchgate.net/profile/Gustav_Von_Zitewitz/publication/324476862/figure/fig/AS:614545865310213@1523530560584/Winner-results-of-the-ImageNet-large-scale-visual-recognition-challenge-LSVRC-of-the.png



The ImageNet winner: AlexNet

Deep Learning gewinnt Bildklassifizierung 2012 mittels Big Data und GPUs

Bis 2012 nur **gewonnen von Menschen-extrahierten Features**

GPUs ermöglichen schnelles Trainieren der Neural Networks

Big Data stellt die Lernmittel bereit

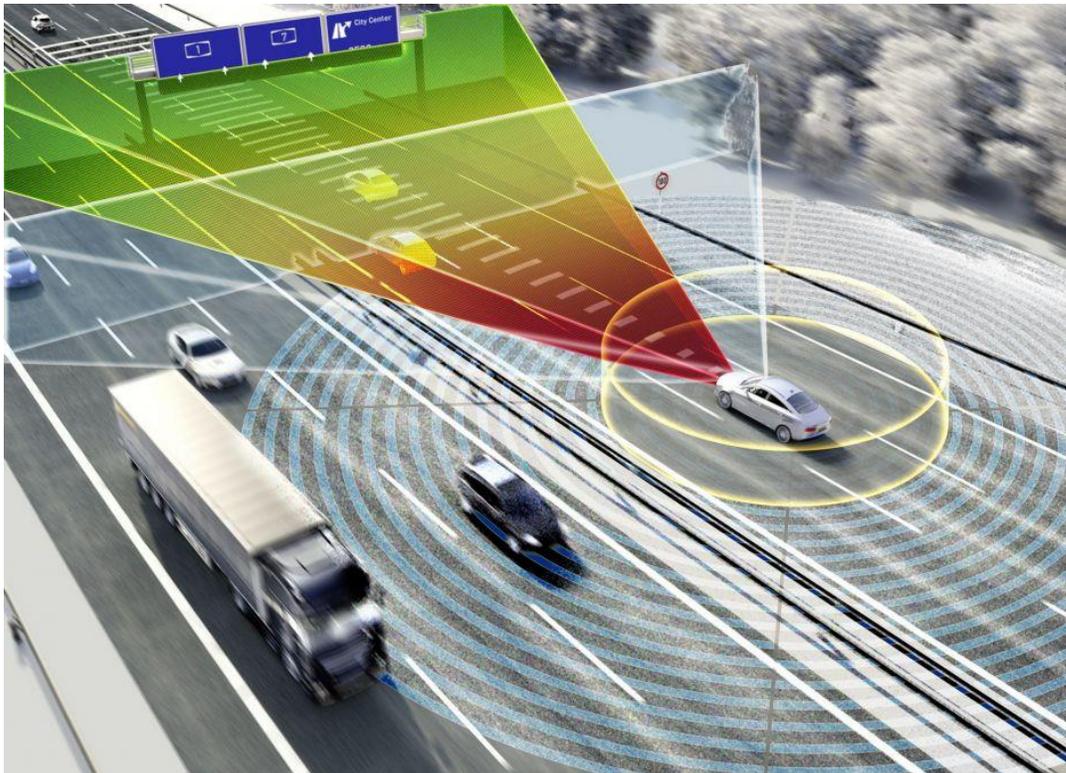


https://miro.medium.com/max/6328/1*WBLfNKon41AF18lpwBFv.png




The neural revolution

Nach dem Durchbruch von Neural Networks in Bildklassifizierung, Einzug in viele andere Felder



https://www.automobil-produktion.de/assets/images/hz/continental_pp_hfi_comprehensiveenvironmentmodel-d510755b.jpg



<https://www.youtube.com/watch?v=05VN56jMMVM>



Back to Machine Translation

Der Durchbruch in Machine Translation mit überzeugenden Ergebnissen

The screenshot shows the DeepL translation website interface. At the top right, there is a logo consisting of a grid of colored squares. Below it, the DeepL logo is displayed in a dark blue speech bubble, followed by the text "DeepL". In the top right corner of the interface, there is a red button that says "DeepL für Windows kostenlos" and a link for "Anmelden". The main navigation bar includes the DeepL logo, the text "Übersetzer", and "Linguee". Below the navigation bar, there are two buttons: "Text übersetzen" and "Dokumente übersetzen". The main content area has a header with "Übersetze beliebige Sprache" and "Übersetze nach Englisch (US)", along with a "Glossar" toggle switch. The central text area contains the following text: "Geben Sie den zu übersetzenden Text ein.", "Ziehen Sie Word- (.docx) und PowerPoint- (.pptx) Dateien hierhin, um sie mit unserem Dokumentenübersetzer zu übersetzen.", "Beliebt: Englisch-Deutsch, Französisch-Deutsch und Spanisch-Deutsch.", and "Weitere Sprachen: Portugiesisch, Italienisch, Niederländisch, Polnisch, Russisch, Japanisch und Chinesisch." At the bottom right of the interface, there are icons for copy, share, and download.



The novel problems

Mit neuem Erfolg kommen neue Probleme – Aktuelle Probleme die bisher unter den Tisch gefallen sind

- Fairness Kann AI **fair** entscheiden?
- Bias Kann AI **unvoreingenommen** entscheiden?
- Privacy Kann AI **private Daten** sicher verwahren?
- Robustness Kann AI **robust und zuverlässig** entscheiden?



Amazon Fairness / Bias

Neue Probleme schleichen sich in alle Bereiche mit ein

AI lernt auf Basis von
Amazon
Bewerbungsdaten

Problem:

Databias

(Mehr Jobs mit Männern
besetzt als Frauen)

Fairness nicht
berücksichtigt

Künstliche Intelligenz diskriminiert (noch)

Der Bewerbungsroboter von Amazon hat Frauen diskriminiert. Wie konnte das passieren? Und wie können Algorithmen geeignete Kandidaten für einen Job erkennen?

Von Felicitas Wilke, 18. Oktober 2018, 20:05 Uhr / [194 Kommentare](#)

<https://www.zeit.de/arbeit/2018-10/bewerbungsroboter-kuenstliche-intelligenz-amazon-frauen-diskriminierung>



Deep Fakes

Nicht nur Fairness Probleme treten auf – Fälschungen und Manipulation wird einfacher

**Gesichtsänderung
in Videos** mittels
Deep Learning

Beispiel Facebook-
Gründer
Mark Zuckerberg
der seinen
Datenklau zugibt





XAI als mögliche Lösung

Wie man künstliche Intelligenz erklären kann



Wie Menschen ihr Entscheidungen begründen

Menschen können Entscheidungen auf Basis von Argumenten begründen – Verbalisierung steht im Vordergrund



Das sind **Züge**. Man sieht es an den **Gleisen**.



http://xai.unist.ac.kr/static/img/event/ICCV_2019_VXAI_Samek_Talk.pdf



Das ist eine **Reiterin mit Pferd**. Man sieht es an dem **Pferd auf dem sie sitzt**.



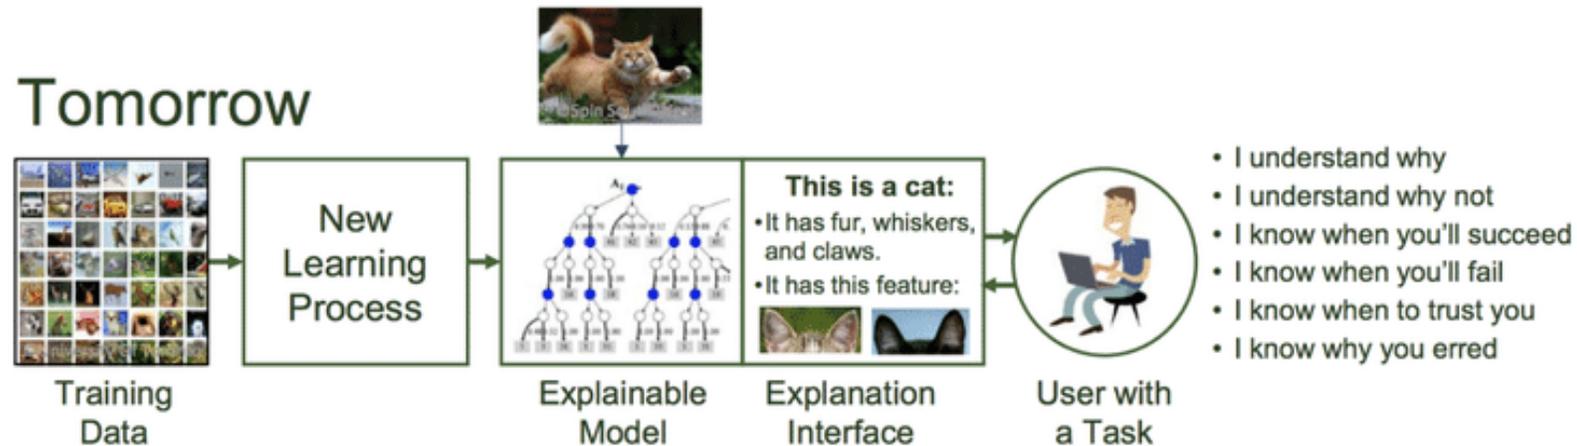
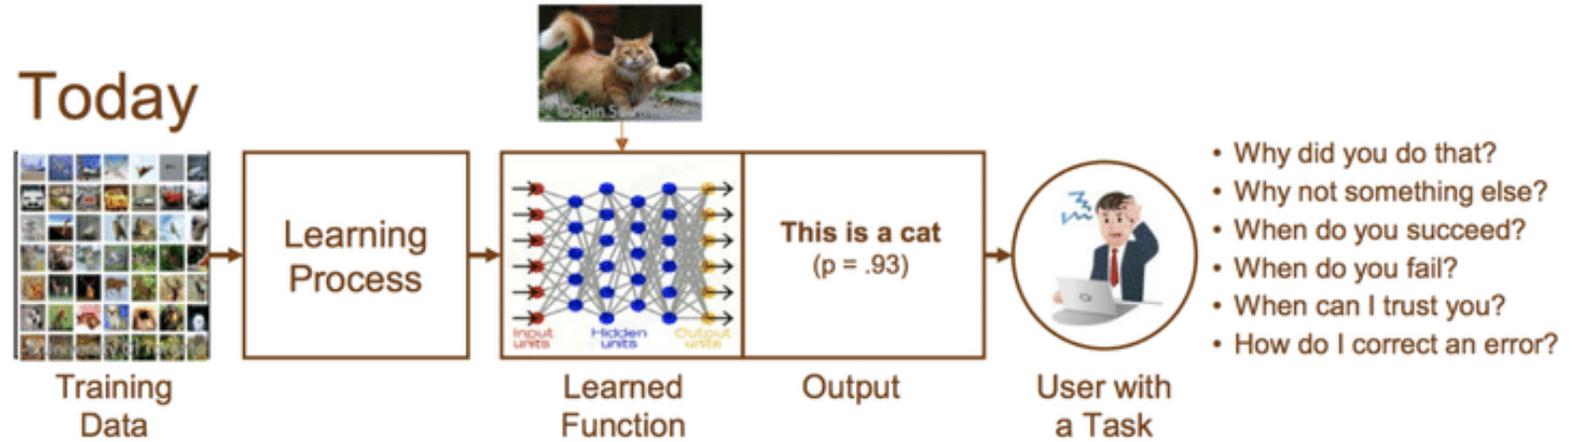
http://xai.unist.ac.kr/static/img/event/ICCV_2019_VXAI_Samek_Talk.pdf





Wie AI ihre Entscheidungen begründen

XAI heute und XAI bzw. AI als Wunsch in der Zukunft





XAI als Trust Building in Predictive Maintenance

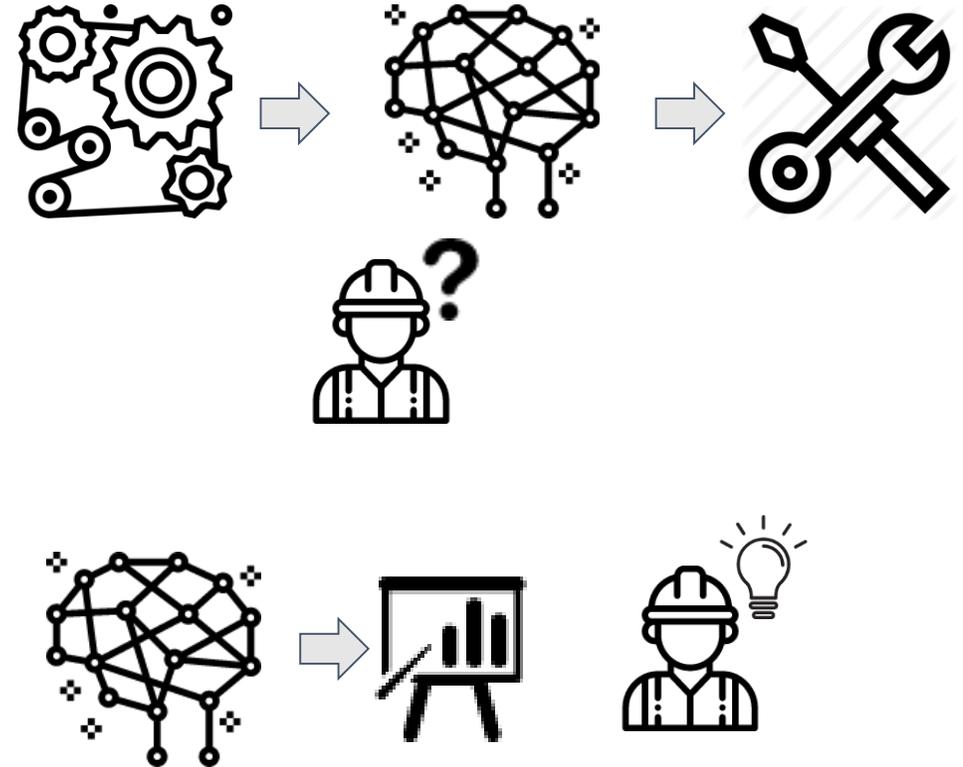
Predictive Maintenance als Beispiel für XAI

Predictive Maintenance um **vorherzusagen wann ein Motor gewartet werden muss**

Problem: **Wartungsarbeiten glauben der Vorhersage nicht**, da der Entscheidungsprozess nicht klar ist

Lösung: XAI Methoden um zu zeigen **auf welcher Basis die Entscheidung getroffen wurde**

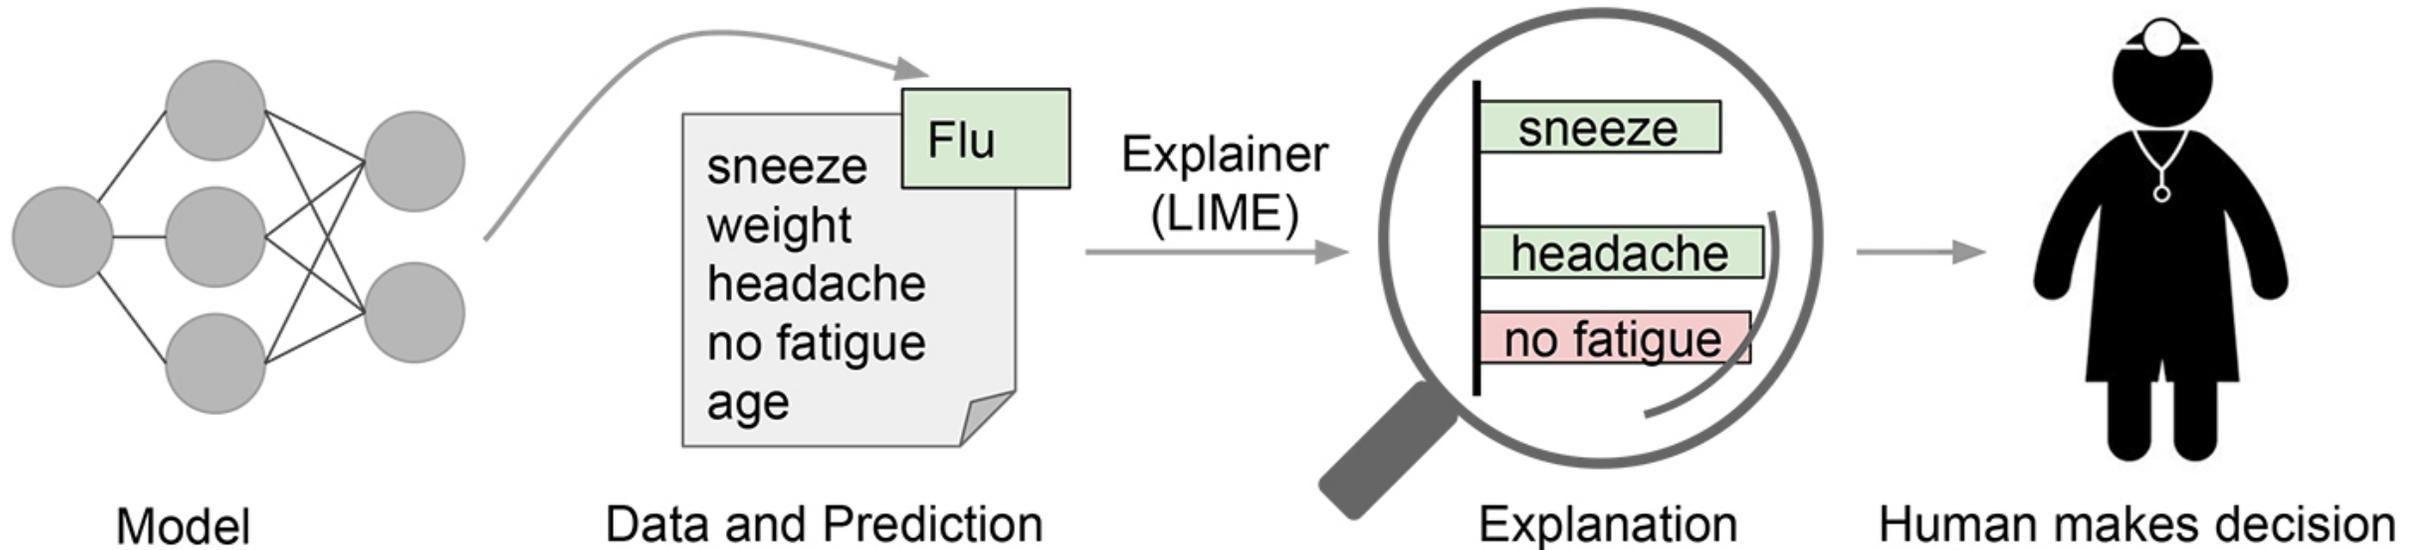
Ziel: **Wartungsarbeiten von der Vorhersage überzeugen**





XAI als Mittel zur Erklärbarkeit

XAI als Technik um Black Boxen zu erklären



<https://d3ansictav2wj.cloudfront.net/figure1-9533a3fb9bb9ace6ee96b4cdc9b6cb.jpg>



(a) Original Image (b) Explaining Electric guitar (c) Explaining Acoustic guitar (d) Explaining Labrador

Figure 4: Explaining an image classification prediction made by Google's Inception network, highlighting positive pixels. The top 3 classes predicted are "Electric Guitar" ($p = 0.32$), "Acoustic guitar" ($p = 0.24$) and "Labrador" ($p = 0.21$)



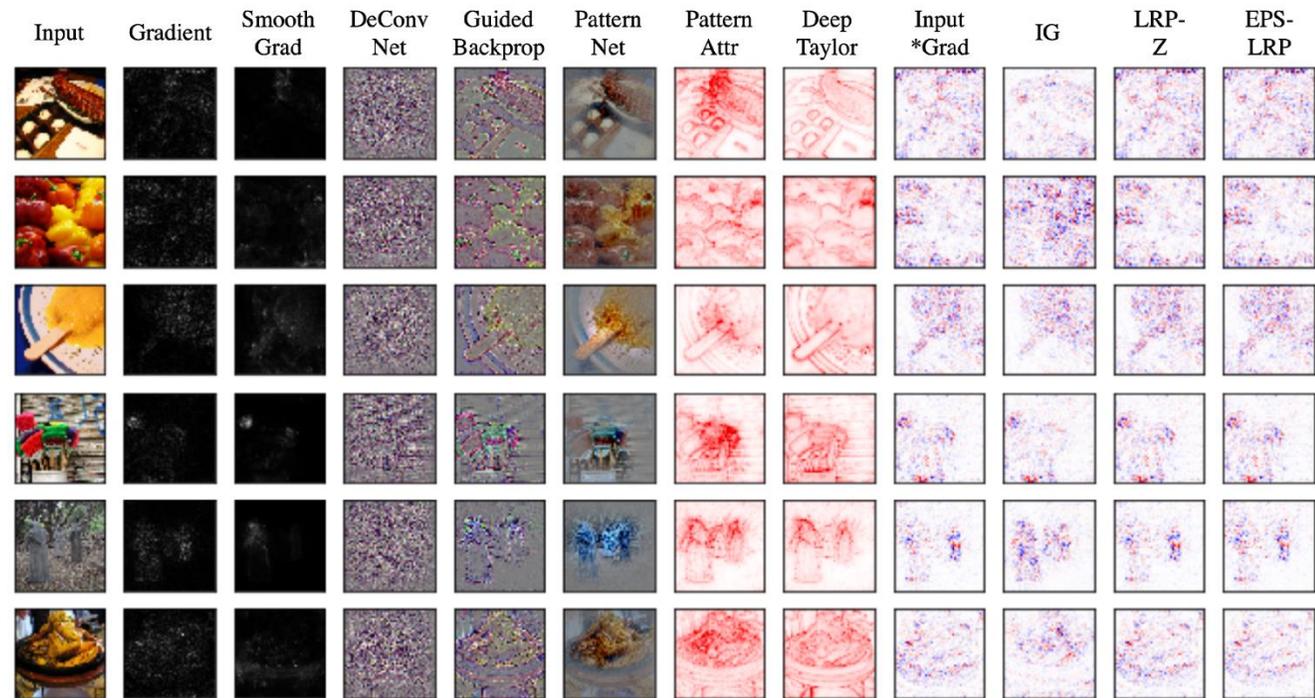
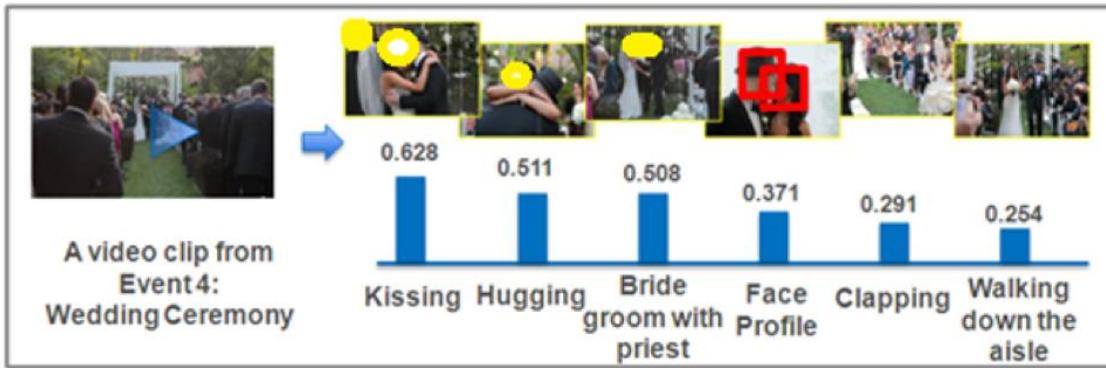


XAI State-of-the-art

XAIs derzeitige Lösung um die Entscheidungen von Neural Networks zu verstehen – Feature Attributions and Heatmaps



(a)



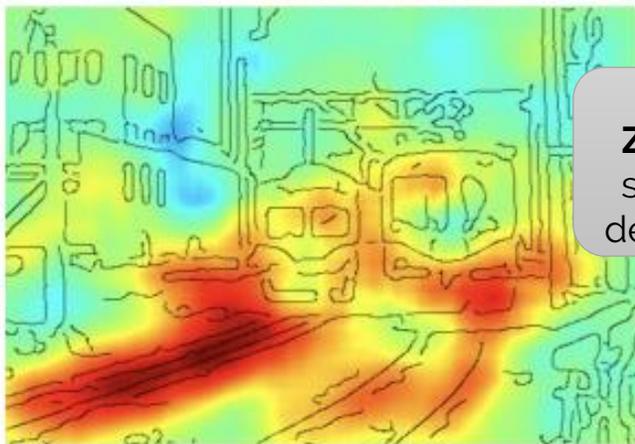
https://www.mdpi.com/jimaging/jimaging-06-00052/article_deploy/html/images/jimaging-06-00052-g003.png

https://miro.medium.com/max/2800/1*FvEBoTh2kyM-kfmXFEL2Q.png

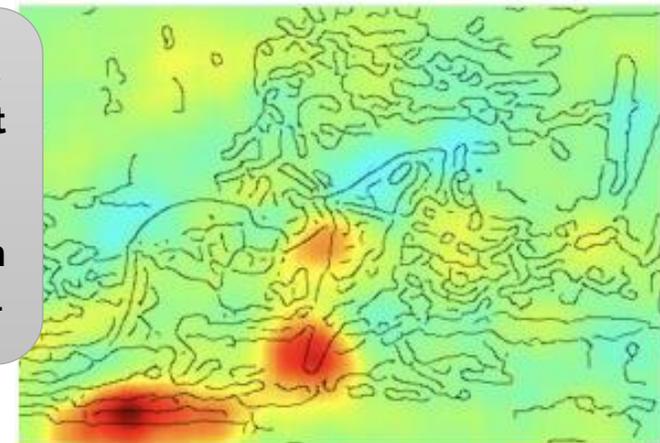


Wie XAI ihre Entscheidungen begründen

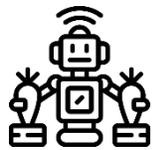
Heatmaps helfen AI Systeme zu verstehen – Jedoch lernen diese oft nicht das was gelernt werden soll



Das sind **Züge**. Man sieht es an den **Gleisen**.



Das ist eine **Reiterin mit Pferd**. Man sieht es an der **Caption unten links**.



http://xai.unist.ac.kr/static/img/event/ICCV_2019_VXAI_Samek_Talk.pdf

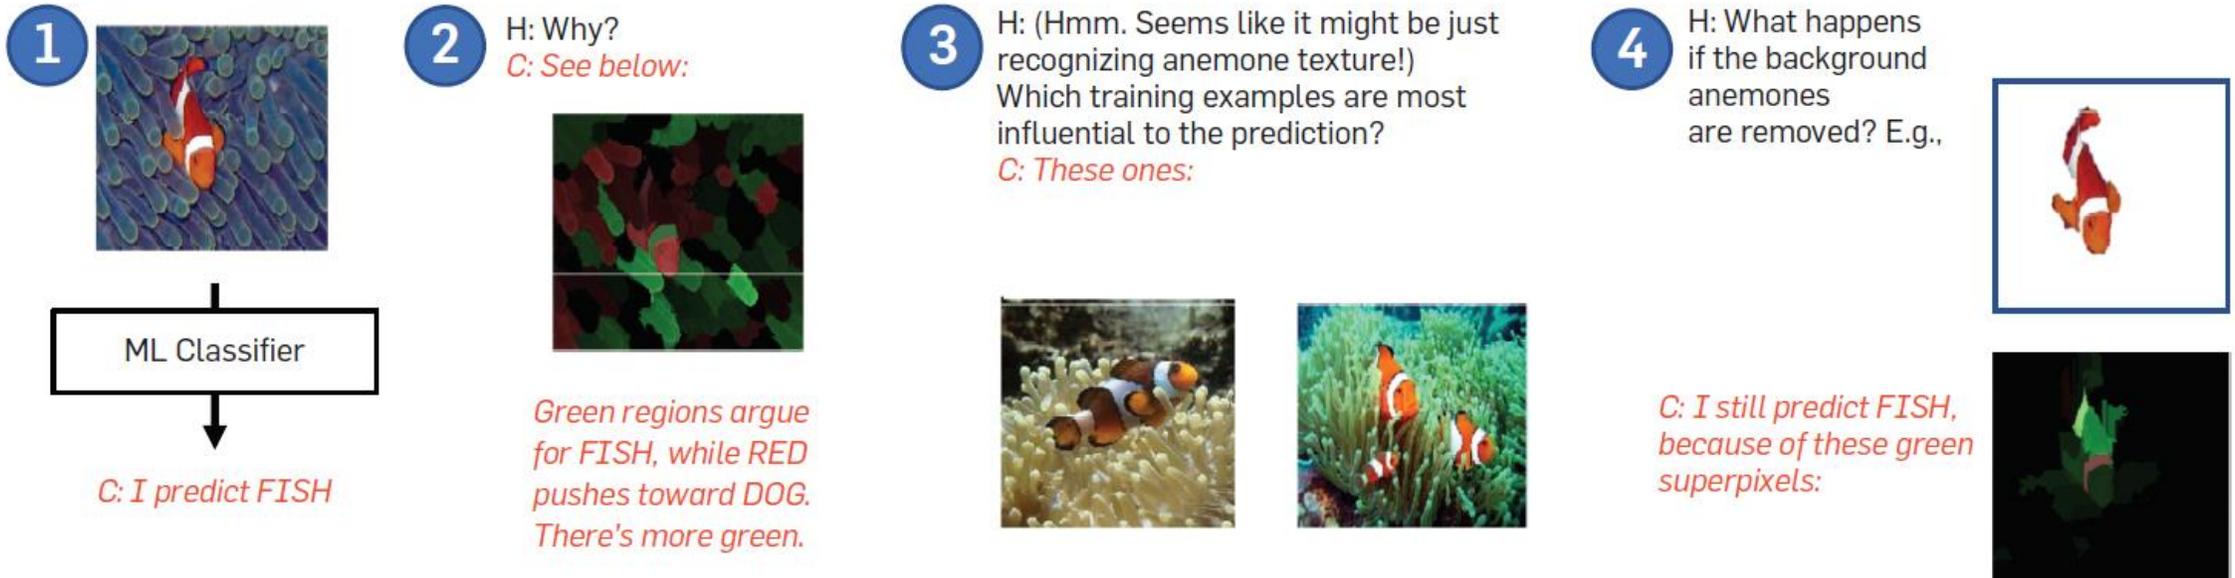
http://xai.unist.ac.kr/static/img/event/ICCV_2019_VXAI_Samek_Talk.pdf



Der Mensch als Vorbild für XAI (Zukunft)

Die Konversation mit der AI als System der Erklärbarkeit für die Zukunft

For illustration, the questions and answers are shown in English language text, but our use of a 'dialog' is for illustration only. An interactive GUI, for example, building on the ideas of Krause et al.,²⁰ would likely be a better realization.





Take Home Message

- XAI kann helfen **Fairness, Bias, Privacy, Robustness, Trust** und vieles weitere zu ermöglichen
- XAI ist jedoch noch in den **Kinderschuh**en (erste Paper 2004) Erklärungen über Heatmaps oder statistischen Werten
- XAI wird in **Zukunft immer wichtiger** (DSGVO, EU AI Law, DARPA US Research)



End



Udo Schlegel



- 2012 – 2016 B.Sc. Information Engineering
 - Interactive Support for Malware Classification
- 2016 – 2018 M.Sc. Computer and Information Science
 - Towards Crime Forecasting Using Deep Learning
- 2018 – 2022 Ph.D. Computer Science
 - Explainable AI for Time Series





Forschungsgebiete

- Explainable AI
- Visual Analytics
- Deep Learning
- Visualization
- Crime Forecasting (LKA NRW)
- Predictive Maintenance (Siemens)
- Dynamic Networks (Collective Behavior Cluster)





Kontakt

- <https://www.vis.uni-konstanz.de/mitglieder/schlegel/>
- <https://www.linkedin.com/in/udo-schlegel/>
- <http://merowech.github.io/>
- u.schlegel@uni-konstanz.de

Datenanalyse
und Visualisierung

Universitätsstraße 10
Universität Konstanz
Gebäude D, Raum 215

Postfach 78

Tel.: +49 (0) 7531 88-3583
Fax: +49 (0) 7531 88-3268





Backup Slides



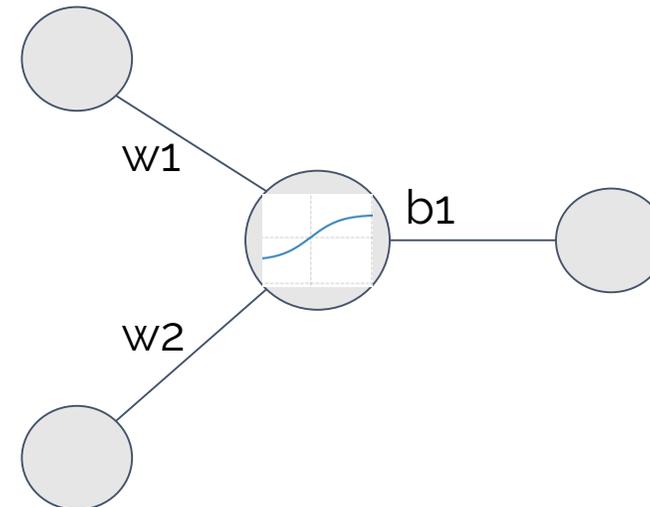
Was ist eine künstliche Synapse? (Perceptron)

Nachbau einer Synapse (Perceptron)

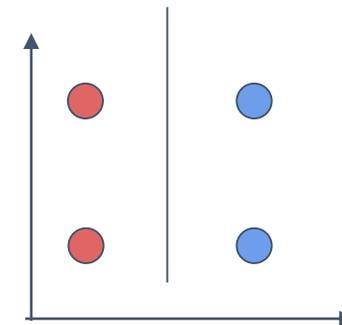
Zwei Eingänge

Eine Aktivierungsfunktion mit Schwellenwert

Ein Ausgang



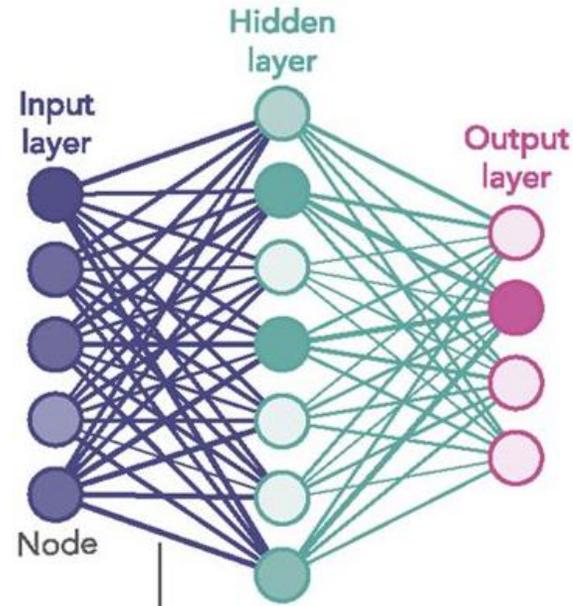
Technik zum linearen Separieren von Daten





Deep Neural Networks

1980S-ERA NEURAL NETWORK



Links carry signals from one node to another, boosting or damping them according to each link's 'weight'.

DEEP LEARNING NEURAL NETWORK

