


Vertrauenswürdige Künstliche Intelligenz Anforderungen und Umsetzungsmöglichkeiten

Ute Schmid

Kognitive Systeme
Otto-Friedrich-Universität Bamberg




Künstliche Intelligenz



- Teilgebiet der Informatik
 - erforscht, wie man Computer dazu befähigt, Dinge zu tun, die Menschen im Moment noch besser lösen können (Rich, 1983)
 - basiert auf der Annahme, dass alle (viele/wichtige) Aspekte menschlicher Intelligenz durch Algorithmen formalisierbar und entsprechend als Computerprogramme simulierbar sind (McCarthy, 1956)
- Digitale Transformation liefert Grundlage für die Anwendung von Algorithmen, auch KI-, speziell ML-Algorithmen

Künstliche Intelligenz

- Die meisten Computerprogramme basieren nicht auf KI-Methoden
- Sobald man KI-Methoden einsetzt gibt man Anforderungen an Korrektheit und Vollständigkeit an
- KI-Methoden machen Sinn, wenn ein Problem:
 - so komplex ist, dass (optimale) Lösung nicht effizient berechenbar ist → heuristische Methoden, Approximation
 - komplexes (Domänen-) Wissen und Schlussfolgerungen involviert → wissenbasierte Methoden
 - nicht (vollständig) beschreibbar ist → maschinelles Lernen
Ersetzen von expliziten Algorithmen durch aus Daten gelernte (black-box) Modelle





Deep Learning

- Beeindruckende Erfolge, vor allem bei bildbasierter Klassifikation
- Aber: hoher Aufwand um Daten in ausreichender Anzahl und Qualität zu gewinnen, vor allem in spezialisierten Bereichen

(garbage in – garbage out)

ImageNet Challenge



Convolutional Neural Network CNNs (LeCun, 1998)
Alex Krizhevsky, (PhD student of G. Hinton, 2012)

- 4 Mio Bilder
- 1000 Klassen
- × hand-labelled

NATURAL LANGUAGE PROCESSING
The 'Invisible', Often Unhappy Workforce That's Deciding the Future of AI




Generative KI – ChatGPT

- Von Open AI (sponsored by Microsoft), veröffentlicht 30.11. 2022, Januar 2023: mehr als 100 Mio Nutzende – *fastest growing consumer application to date*
- Basiert auf einer Transformer Network Architektur, die auf der NeurIPS 2017 von Google Brain vorgestellt wurde
- GPT-3: trainiert auf Hunderte von Milliarden von Wörtern, 175 Milliarden Parameter, 800 GB Speicherplatz, 2048 Token langer Kontext
- Es wird geschätzt, dass das Training von GPT-3 1.287 MWh verbraucht und 552 Tonnen CO2 emittiert hat!

Komponenten:

- Sprachmodell: GPT3 – self-supervised learning, alle „crawl“-baren Inhalte bis 2021, dann eingefroren – Übergangswahrscheinlichkeiten zwischen Worten/Tokens
- Überwachtes Lernen: Dialoggenerierung
- Überwachtes Lernen: Filtern toxischer Inhalte
- Human-in-the-loop Reinforcement Learning: Finetuning



Time, 18.Jan 2023


BUSINESS • TECHNOLOGY

Exclusive: OpenAI Used Kenyan Workers on Less Than \$2 Per Hour to Make ChatGPT Less Toxic

Vertrauenswürdige KI



<https://digital-strategy.ec.europa.eu/en/library/ethics-guidelines-trustworthy-ai>



Transparenz – Erklärbare KI (XAI)

- Erklärungen sind nicht pauschal hilfreich
→ Wem erkläre ich was für welchen Informationsbedarf
- **Für Modellentwickler:** overfitting, biases
- **Für Domänen-Expertinnen & -experten:**
Nachvollziehbarkeit von Entscheidungen für kalibriertes Vertrauen und *explain to revise*
- **Für Endnutzende:** Transparenz von datenbasierten Entscheidungen (recommender, Kreditvergabe, ...)



Volume 36, Issue 3-4


December 2022

Explainable AI

Issue Editors: Ute Schmid, Britta Wrede

Horse-picture from Pascal VOC data set


XAI kann helfen
Overfitting
zu erkennen



Source tag
present



Classified
as horse



No source
tag present



Not classified
as horse

Lapuschkin, Sebastian,
et al. "Unmasking
Clever Hans predictors
and assessing what
machines really learn."
Nature communications
10.1 (2019): 1096.

Aber: Erklärungen müssen modelltreu sein

Table 2: Jaccard Coefficient of the different superpixel methods

Superpixel method	Mean Value	Variance	Standard deviation
Felzenszwalb	0.85603243	0.03330687	0.18250170
Quick-Shift	0.52272303	0.04613085	0.21478094
Quick-Shift optimized	0.88820585	0.00307818	0.05548137
SLIC	0.96437629	0.00014387	0.01199452
Compact-Watershed	0.97850773	0.00003847	0.00620228

Schallner, Ludwig, et al. "Effect of superpixel aggregation on explanations in LIME—a case study with biological data." Machine Learning and Knowledge Discovery in Databases: International Workshops of ECML PKDD 2019, Würzburg, Germany, September 16–20, 2019, Proceedings, Part I. Springer International Publishing, 2020.




Fig. 4: LIME results for true positive predicted malaria infected cells

Explainability 2.0: Konzept-basierte Erklärungen






Fig. 2: Overview of our CoReX approach for explaining and evaluating CNN image classifications with concept- and relation-based explanations and constraints (concept masking and relational constraints).

Finzel, Hilme, Rabold, Schmid (u.r.), Rectifiable Concept- and Relation-based Explanations, MLJ

Example-based Explainable AI (XAI) Demonstrator



Unterstützt Domänenexperten, die Entscheidungsgrenzen des gelernten Modells zu verstehen und entsprechend durch neue Trainingsdaten zu korrigieren


Re-implementation of Kim, Khanna, Koyejo: Examples are not Enough – Learn to Criticize!
 Criticism for Interpretability, NeurIPS 2016

$$\text{MMD}^2(X, Y) := \frac{1}{|X|^2} \sum_{x_1, x_2 \in X} k(x_1, x_2) + \frac{1}{|Y|^2} \sum_{y_1, y_2 \in Y} k(y_1, y_2) - \frac{2}{|X| \cdot |Y|} \sum_{x \in X, y \in Y} k(x, y)$$

Herchenbach, Marvin, et al. "Explaining Image Classifications with Near Misses, Near Hits and Prototypes: Supporting Domain Experts in Understanding Decision Boundaries." Pattern Recognition and Artificial Intelligence: Third International Conference, ICPRAI 2022, Paris, France, June 1–3, 2022, Proceedings, Part II. Cham: Springer International Publishing, 2022.

Human-Centered AI Along the ML Life Cycle

Explain to revise



According to: [1] Decker et al., The Thousand Faces of Explainable AI Along the Machine Learning Life Cycle: Industrial Reality and Current State of Research, HCI INTERNATIONAL 2023

Take Away

Stuart Russell: *We never asked ourselves „what if it really works“ (2019)*

- Aktuelle KI-Methoden (Deep Learning, Generative KI) haben großes Potential für viele Anwendungsfelder (Medizin, Produktion, Verwaltung, Bildung, ...)
- Für eine Umsetzung in der Praxis sind Robustheit, Nachvollziehbarkeit und Korrigierbarkeit relevant
- Anforderungen für vertrauenswürdige KI sind Forschungstreiber: Methoden für XAI, Interaktives/human-in-the-loop Lernen, wissensinformiertes ML
- Für Klassifikation gibt es bereits zahlreiche Ansätze für Vertrauenswürdigkeit, für generative KI beginnt die Forschung dazu gerade
- Die Umsetzung des europäischen AI Acts ist jedoch nicht trivial (Zertifizierung)