



Erklärbare künstliche Intelligenz aus aktuarieller Perspektive

18. November 2024

DAV/DGVFM Herbsttagung

Dr. Guido Grützner (guido.gruetzner@quantakt.com)


- **Statistische Modelle**
- Warum braucht es Erklärbarkeit?
- Erklärbarkeitsmethoden
- Ergebnisse der AG
- Schlussbemerkungen

Welche Modelle sollen erklärt werden?

- Alle reden über KI, keiner über das Wetter! Warum?
- Es gibt zwei fundamental verschiedene Kategorien von Modellen

Naturwissenschaftlich-kausales Modell

- Beispiel Wetterprognose: Bestimmung der Niederschlagswahrscheinlichkeit morgen in Köln




- Temperatur
- Feuchtigkeit
- Luftdruck
-

$$\frac{\partial \mathbf{v}}{\partial t} + (\mathbf{v} \cdot \nabla) \mathbf{v} = -\frac{1}{\rho} \nabla \rho + \nu \Delta \mathbf{v} + f(\mathbf{x}, t)$$

Regen: 45%

Statistisches Modell

- Beispiel Unfallprognose: Bestimmung der Unfallwahrscheinlichkeit eines Fahrers



- Fahrzeug
- Wohnort
- Schadenklasse
-

$$\log \mu = \beta_0 + \beta_1 X_1 + \dots + \beta_d X_d \quad p = 0.1\text{‰}$$

■ Das Wettermodell

- Basiert auf Naturgesetzen,
- bildet kausale Zusammenhänge ab,
- Prognosen werden aus Daten durch Differentialgleichungen gewonnen.
- Zufall entsteht nur aus Messunsicherheit und Approximationsfehlern.

■ Das Unfallmodell

- Basiert auf beobachteten Daten,
- bildet statistische Assoziationen ab,
- Prognosen werden aus dem besten Fit an die Beobachtungen gewonnen.

Statistisch, Klassisch, Machine Learning

- Dieser Vortrag beschäftigt sich mit der Erklärbarkeit von statistischen Modellen
 - Praktisch alle aktuariellen Modelle sind von dieser Art
 - Machine Learning/Statistical Learning Modelle sind auch von dieser Art
- In diesem Vortrag unterscheide ich nicht zwischen «klassischen» und «Machine Learning» Modellen
 - Meiner Meinung nach gibt es keinen fundamentalen Unterschied
 - Den Unterschied machen Modellcharakteristika wie die Komplexität und das Einsatzgebiet des Modells
- Statistische Modelle haben grosse Vorteile gegenüber naturwissenschaftlich-kausalen Modellen
 - Man kann sehr gute Prognosen abgeben OHNE das man die zu Grunde liegenden Phänomene vollständig versteht oder abbildet
 - Sie sind im Allgemeinen viel einfacher zu erstellen und viel schneller zu berechnen als naturwissenschaftlich-kausale Modelle

Konsequenzen für die Erklärbarkeit

■ Erklärungen in einem Wettermodel

Ein umfangreiches und kräftiges Hochdruckgebiet erstreckt sich von der Nordsee über Deutschland und Polen bis zum Schwarzen Meer und bestimmt weiterhin unser Wetter. Während sich auf der Alpennordseite in der Grundschicht ein feuchter Kaltluftsee hält, ist die Luftmasse darüber trocken und mild.

MeteoSwiss, 6. November 2024

- Die kausale Abbildung der Zusammenhänge erlaubt kausale Erklärungen.
- Die internen Elemente des Modells stehen in einem unmittelbaren Zusammenhang mit der abgebildeten Wirklichkeit.

■ Statistisches Modell ???

Zitat des Tages

„Über die Gründe können wir nur spekulieren.“

Jörg Asmussen, Hauptgeschäftsführer des Branchenverbands GDV, zur geringeren Unfallhäufigkeit von E-Autos im Vergleich zu Verbrennern

Versicherungsmonitor vom 26. Oktober 2023

- Da ein statistisches Modell nur statistische Assoziationen abbildet sind keine kausalen Erklärungen möglich.
- Die internen Elemente des Modells (im vorigen Beispiel die Koeffizienten $\beta_0, \beta_1, \dots, \beta_d$ des GLM) haben keinen direkten Bezug zu Phänomenen der abgebildeten Wirklichkeit (im Beispiel die Unfallwahrscheinlichkeit).

- Statistische Modelle
- Warum braucht es Erklärbarkeit?
- Erklärbarkeitsmethoden
- Ergebnisse der AG
- Schlussbemerkungen

Erklärbarkeit und Nachvollziehbarkeit (Transparency)


- Es ist sinnvoll zwischen der Erklärbarkeit des Modells im engeren Sinne und der Nachvollziehbarkeit des Modellierungsprozesses insgesamt zu unterscheiden
- Nachvollziehbarkeit («Transparency» in [1]) umfasst unter anderem
 - Angemessenheit des Modells für den Einsatzzweck
 - Auswahl der Daten (aktuell, korrekt, repräsentativ, ...)
 - Technische Korrektheit der Implementierung
 - Dokumentation und Revisionsicherheit
- Ein juristisches «Recht auf Erklärung» bezieht sich sicherlich auf beide Aspekte also Erklärbarkeit und Nachvollziehbarkeit
- Die Unterscheidung ist aber dennoch sinnvoll, weil
 - Die auftretenden Probleme und dann nötigen Methoden zur Lösung sehr verschieden sind.
 - Die Methoden zur Nachvollziehbarkeit Anwendern aus regulierten Bereichen wohl vertraut und Routine(?) sind.
- Annahme im Folgenden: Nachvollziehbarkeit ist vollständig und lückenlos gegeben.
- Im Weiteren: Fokus auf Erklärbarkeit im engeren Sinne!

[1] EIOPA, 2021, «ARTIFICIAL INTELLIGENCE GOVERNANCE PRINCIPLES»

Braucht es denn Erklärbarkeit?

- Annahmen:
 1. Wir sind nur an guter Prognose interessiert.
 2. Die Qualität der Prognosen des Modells ist tipp-topp.
 3. Daten, Modell und Prozess drumherum sind perfekt nachvollziehbar.
- These: «Let the model speak for itself!»
 - Jeder Datensatz, der interessiert, kann ja in das Modell eingespeist werden.
 - Man erhält dazu die passende Prognose.
 - Schon weiss man alles über das Modell, was relevant ist.
- Wozu braucht man dann «Erklärungen»?
- Das Problem:
 - Egal wie gross der Datensatz ist: Er ist immer endlich
 - Egal wieviel man testet: Man kann nur endlich viele Kombinationen von Inputs prüfen
- Die Frage bleibt: Wie reagiert das Modell auf Daten, auf die es nicht kalibriert/getestet wurde?
- Das folgende Beispiel zeigt, dass auch sehr gute Modelle versagen können!

Adversarial examples – Klassifikation von Bildern



Zitat aus der Veröffentlichung:



We find that applying an imperceptible non-random perturbation to a test image, it is possible to **arbitrarily change the network's prediction**. These perturbations are found by optimizing the input to maximize the prediction error.

We term the so perturbed examples “**adversarial examples**”.

[2] Ian Goodfellow et. al. «Intriguing properties of neural networks», 2014

Nur zur Erinnerung!

Es gibt auch Adversarial Examples für biologische neuronale Netze!



[3] <https://michaelbach.de/ot/>

Fazit: Es braucht mehr als nur Prognose!

- Diese Beispiele beleuchten ein fundamentales Problem: Statistischen Modellen fehlen «Leitplanken» wie Naturgesetze oder logische Prinzipien
- Gute Qualität – sogar auf grossen Trainings- und Testdatensätzen – kann daher Fehlverhalten fernab dieser Daten nicht ausschliessen. Daher ist ein globales Verständnis des Modells erforderlich.
- Das Problem wird umso grösser je komplexer das Modell wird.
- Komplexität kann dabei gemessen werden durch
 - Die Dimensionalität des Inputraumes also z.B. der Anzahl der Input-Variablen.
 - Der Dimensionalität des Hypothesenraumes also z.B. der Anzahl der freien Parameter des Modells.
- Über diese fundamentale Notwendigkeit hinaus ist Erklärbarkeit aber auch nützlich
 - Zum Debugging/Test des Modells
 - Zur Selektion geeigneter Modelle und Inputdaten
 - Zur Unterstützung von Business-Cases
 - Bei rechtlichen Aspekten wie Haftung, Fairness, Aufsicht.

- Statistische Modelle
- Warum braucht es Erklärbarkeit?
- Erklärbarkeitsmethoden
- Ergebnisse der AG
- Schlussbemerkungen

Definitionen von Erklärbarkeit

■ Einige Definitionsversuche in der Literatur

- An **interpretable** system is a system where a user cannot only see but also study and **understand** how inputs are mathematically mapped to outputs. (Addadi und Berrada 2018)
- You could describe a model as **interpretable** if you can **comprehend** the entire model at once. (Lipton 2016)
- A model is **explainable** when its internal behaviour can be directly **understood** by humans (interpretability) or when **explanations** (justifications) can be provided for the main factors that led to its output." (European Banking Authority, 2020)

■ Diese Definitionen (und viele mehr) haben eins gemeinsam: Sie sind zirkulär!

- Ein undefinierter Begriff „interpretable/explainable“ wird ersetzt durch einen anderen undefinierten Begriff „understandable“ „comprehensible“ usw.

■ Es gibt keine allgemein anerkannte und praktikable Definition von erklärbar/interpretierbar!

■ Die Konsequenz: Unsicherheit

- Erklärbarkeit ist nicht messbar/operationalisierbar was faktenbasierte Diskussionen darüber schwierig macht.
- Wenn ein Gesetz oder eine Aufsicht «Erklärbarkeit» verlangt, ist völlig unklar, wie das zu erreichen ist.
- Für Hersteller und Verwender von statistischen Modellen ist nicht klar, welche Modelle wann als ausreichend erklärt gelten.

■ Konsequenz für den Vortrag (und evtl. Empfehlung für Anwender/Nutzer?): Beispielhaft und pragmatisch vorgehen!

- Beispiele geben für Methoden zur Erklärung.
- Auf natürliche Fragen und passende Antworten konzentrieren.
- Ein Modell gilt dann als ausreichend erklärt, wenn die Erklärung Kunden, Anwender oder Bundesrichter überzeugt.

Erklärbarkeitsmethode: Counterfactual explanations

Luca, 21 Jahre, Fliesenleger,
Will sich sein erstes Auto kaufen



Subaru BRZ 2.4 Sport, 172kW
Aber: Prämie Teilkasko CHF 1024 !

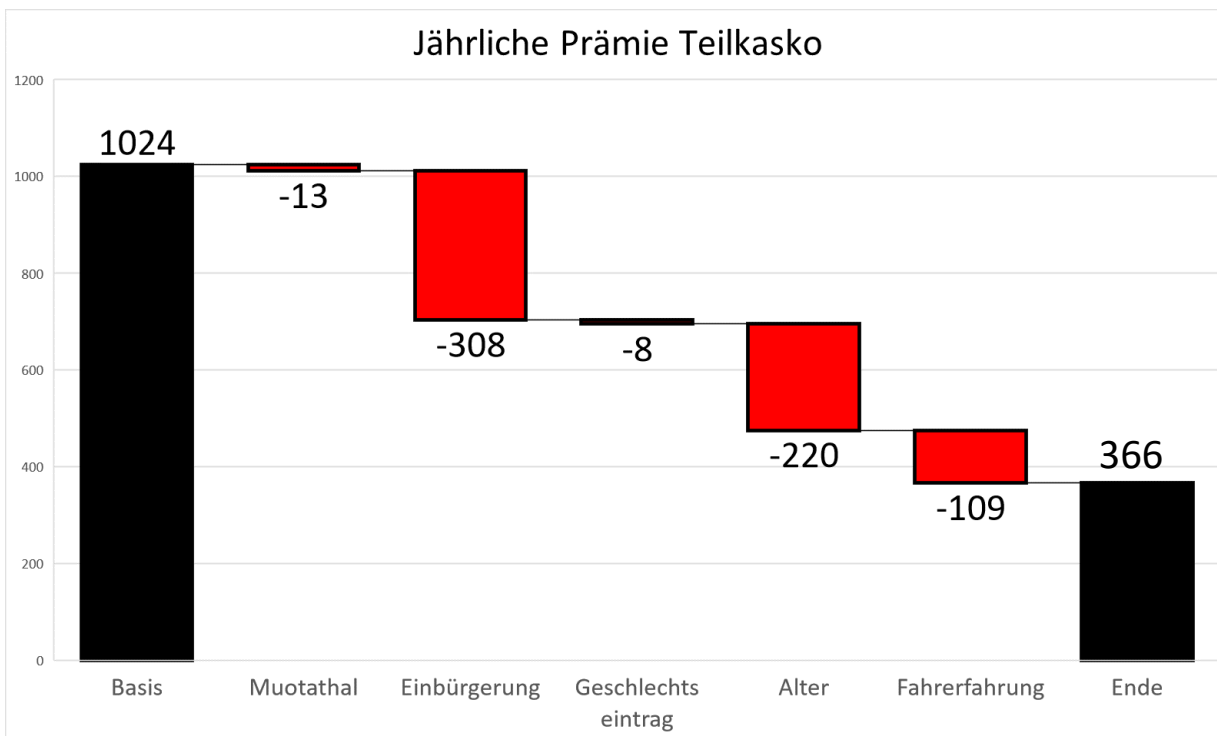


Lucas Erklärungsproblem bzw. seine naheliegende Frage:
Warum ist meine Prämie so hoch??

Erklärbarkeitsmethode Counterfactual Explanations

■ Sein Ansatz: Counterfactual Explanations oder «Was wäre wenn?»

- Er rechnet mit einem On-Line Tarifrechner einfach ein paar Varianten seiner Daten.



■ Seine (hypothetischen) Massnahmen

- Von 8051 Schwamendingen zur Oma nach 6436 Muotathal ziehen
- Endlich die Einbürgerung Albanien -> CH anpacken
- Geschlechtseintrag M -> F: Vielleicht doch nicht für CHF 8 ?
- Alter: von 21 auf 41 erhöhen
- Zeit seit Fahrprüfung: von 1 Jahr auf 21 Jahre erhöhen.

■ Counterfactuals sind eine lokale Methode

- Erklärt wird eine ganz bestimmte Prognose bzw. Modell-Entscheidung.

■ Für Counterfactuals braucht es nur die Modell-Outputs

- Die Interna des Modells können völlig verborgen bleiben (Blackbox-Ansatz)
- Es braucht sogar nur wenige Werte in der Nachbarschaft des relevanten Outputs.


Erklärbarkeitsmethoden - Übersicht

- Es gibt inzwischen ein Standard-Repertoire von (etwa einem Dutzend?) Erklärbarkeitsmethoden.
- Dies sind mathematische Verfahren/Berechnungen, die typischerweise liefern:
 - Visualisierungen, d.h. Teile eines hoch-dimensionalen Modells werden auf 2-D, 3-D Sichten projiziert.
 - «Variable Importance»: Kennzahlen, welche die «Wichtigkeit» der Inputs beschreiben sollen.
- Diese Standard-Methoden sind gut beschrieben
 - Christoph Molnar, «Interpretable Machine Learning» [4]
 - C. Lorentzen, M. Mayer «Peeking into the Black Box» [5]
 - Und natürlich die Notebooks und Ausarbeitungen unserer DAV-Arbeitsgruppe [6]
- Viele der Methoden sind Modell-Agnostisch.
 - D.h. eine bestimmte Methode funktioniert für alle Arten von Modellen.
 - Es gibt aber auch modellspezifische Ansätze, z.B. für baumbasierte Modelle.
- Erklärbarkeitsmethoden kommen inzwischen integriert in die Standardpakete für die jeweiligen Modelle.
 - Damit ist ein einfacher und niedrigschwelliger Zugang möglich.
 - Grundsätzlich kann die jeder sofort verwenden.

Erklärbarkeitsmethode: Varianzallokation

- Varianzallokation (Permutation Feature Importance, Sobol Index) beschreibt die Wichtigkeit der Inputvariablen für die Vorhersage.
 - Modell-agnostische Methode für Regressionsprobleme
 - Benötigt nur Vorhersagen des Modells keine interne Struktur
 - Praktikabel auch bei grossen Datenmengen und vielen Input-Variablen
- Grundidee: Ordne das R^2 bzw. den Mean Square Error des Modells den einzelnen Inputs zu.
 - Mit einem Schätzer bestimmt man, um wieviel sich das R^2 verschlechtert, wenn man jeweils einen bestimmten Input ignoriert.
 - Unter bestimmten Voraussetzungen sagt einem die Theorie dann, dass sich die einzelnen R^2 Werte zum Gesamtwert aufaddieren.
- Die Methode ist eine globale Erklärungsmethode.

Beispiel: Risikofaktoren eines internen Modells zur Solvenzberechnung.



Siehe

- [7] «Neuronale Netze treffen auf Least Squares Monte Carlo»
- [8] «Use Case SCR» der DAV-Arbeitsgruppe XAI

Kritik der standardisierten Erklärbarkeitsmethoden

- Standard-Erklärbarkeitsmethoden sind leicht anwendbar und hilfreich. In vielen Fällen reichen sie aber nicht aus!
 - Beispiel: Weder lokale noch globale Erklärungen sind brauchbar, wenn man sich für die 0.5% Tail-Prognosen seines Modells interessiert.
 - Die Methoden sind technisch. Ein echtes Verständnis der Ergebnisse erfordert daher fachliche Kenntnis der Anwender.
 - Die Voraussetzungen zur Anwendung der Methoden sind oft sehr restriktiv. Z.B. funktionieren manche Methoden problemlos nur mit stochastisch unabhängigen Inputs.
- Standard-Methoden können von problemspezifischen Ansätzen ablenken.
 - Im schlimmsten Fall: Alibi Effekt statt «Gehirn einschalten».
- Der Einsatz von Standard-Methoden scheint mir oft etwas schlampig zu sein. Es fehlt gelegentlich an «aktuarieller Sorgfalt» und wichtige Aspekte werden nicht berücksichtigt.
 - Was will ich mit der Erklärung erreichen?
 - Ist die Methode dokumentiert? Habe ich die Methode verstanden?
 - Sind die Voraussetzungen für den Einsatz der Methode erfüllt?
 - Wie kommuniziere ich die Ergebnisse und ihre Unsicherheit?

Kritik der standardisierten Erklärbarkeitsmethoden

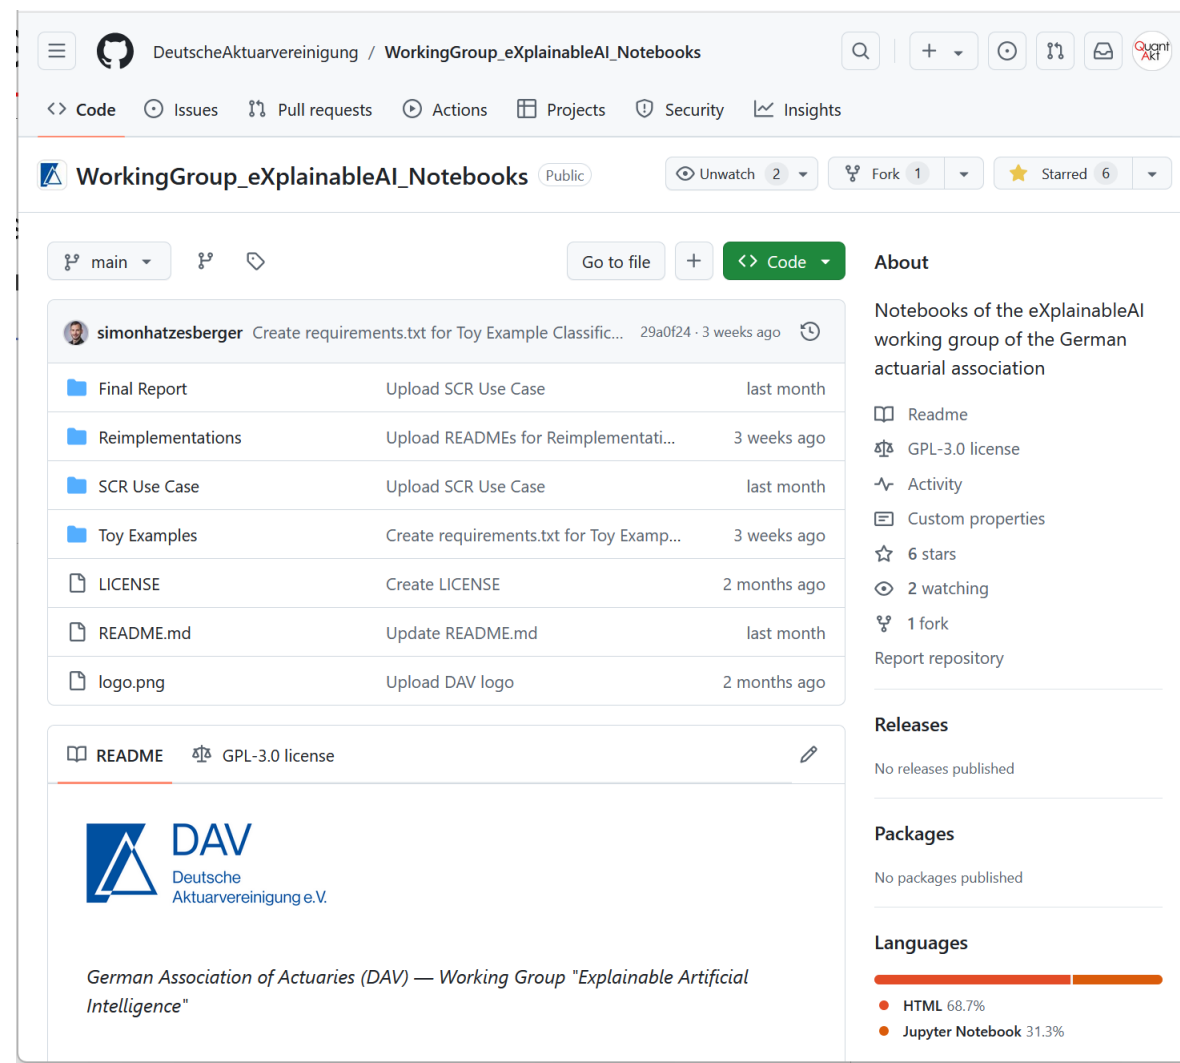
- Die Interaktion von Menschen mit statistischen Modellen ist kein mathematisches Problem, sondern ein psychologisch/soziales Phänomen.
 - Diese Interaktion («Human centred XAI») ist noch wenig untersucht
 - Es ist noch weitgehend unklar, wann und wie die verfügbaren Erklärbarkeitsmethoden Endanwendern helfen.
- Die Art der Erklärung und ihre Präsentation muss sich an den Bedürfnissen des Anwenders und der konkreten Anwendung orientieren.
 - Je nach Zielgruppe hat Erklärung einen anderen Zweck.
 - Entwickler: Test und Modellverbesserung
 - Entscheidungsträger: Zusammenhang der Erklärung mit der Entscheidung
 - Endanwender: Anfechtung einer Entscheidung oder Regressansprüche
 - Aufsicht: Einhaltung von Richtlinien
- Erklärbarkeitsmethoden können sogar «falsches Vertrauen» erzeugen und so die Qualität von Entscheidungen verschlechtern.
 - In einer Studie [9] bewirkten schlecht oder falsch verstandene Erklärungen, dass Anwender dem Modell vertrauten und Fehler des Modells übersahen.

[9] «Effect of Confidence and Explanation on Accuracy and Trust Calibration in AI-Assisted Decision Making», Zheng, Liao and Bellamy, Proceedings FACCT2020.

- Statistische Modelle
- Warum braucht es Erklärbarkeit?
- Erklärbarkeitsmethoden
- Ergebnisse der AG
- Schlussbemerkungen

Ergebnisse der AG

- Alle Ergebnisse der AG sind frei zugänglich auf dem Github Account der DAV
 - Github: Plattform für Kollaboration und Datenaustausch
 - Adresse: https://github.com/DeutscheAktuarvereinigung/WorkingGroup_eXplainableAI_Notebooks
- Ergebnistypen:
 - «Final Report»: Ergebnisbericht (Word Dokument)
 - Reimplementations, «Toy Examples» und «Use Cases»



The screenshot shows the GitHub repository page for 'WorkingGroup_eXplainableAI_Notebooks' under the organization 'DeutscheAktuarvereinigung'. The repository is public and has 1 fork and 6 stars. The main branch is selected. The file list includes:

File/Folder	Description	Time
Final Report	Upload SCR Use Case	last month
Reimplementations	Upload READMEs for Reimplementati...	3 weeks ago
SCR Use Case	Upload SCR Use Case	last month
Toy Examples	Create requirements.txt for Toy Examp...	3 weeks ago
LICENSE	Create LICENSE	2 months ago
README.md	Update README.md	last month
logo.png	Upload DAV logo	2 months ago

The README section shows the DAV logo (Deutsche Aktuarvereinigung e.V.) and the text: "German Association of Actuaries (DAV) — Working Group "Explainable Artificial Intelligence"".

On the right side, the 'About' section provides details: "Notebooks of the eXplainableAI working group of the German actuarial association", "Readme", "GPL-3.0 license", "Activity", "Custom properties", "6 stars", "2 watching", "1 fork", and "Report repository". The 'Releases' and 'Packages' sections show "No releases published" and "No packages published" respectively. The 'Languages' section shows a bar chart with HTML at 68.7% and Jupyter Notebook at 31.3%.

Ergebnisbericht «Explainable Artificial Intelligence»

- Der Ergebnisbericht bietet sowohl einen ersten Einblick als auch einen umfassenden Überblick über die Thematik der Erklärbarkeit.

Inhaltsverzeichnis

1. Einleitung	5
1.1. Motivation und Kontext	5
1.2. Ziele und Ergebnisse	7
2. Charakterisierung komplexer Modelle	8
2.1. Definitionen von künstlicher Intelligenz	8
2.2. Definitionen von maschinellem Lernen	9
2.3. Charakteristika von komplexen Modellen	10
3. Erklärbarkeit komplexer Modelle	16
3.1. Definitionen von Erklärbarkeit	16
3.2. Charakteristika von Erklärbarkeit	20
3.3. Erklärbarkeitsmethoden	22
3.4. Sorgfalt beim Einsatz von Erklärbarkeitsmethoden	24
4. Wann gilt ein Modell als hinreichend erklärt?	28
4.1. Kriterien an ein erklärbares Modell	28
4.2. Determinanten des erforderlichen Grades an Erklärbarkeit	29
5. Zusammenfassung und Fazit	34
Literaturverzeichnis	35

Notebooks

- Im Zuge der AG Arbeit sind etwa 20 Notebooks entstanden, welche typische Erklärungsmethoden und Anwendungsfälle demonstrieren.
- Notebooks verwenden entweder R oder Python
- Toy Examples
 - Fokus: Niedrigschwelliger Zugang und leichte Ausführbarkeit
 - Einfache Datensätze, grundlegende Fragestellungen
 - Geeignet zum «einfach mal ausprobieren»
- Reimplementations und Simulation Studies
 - Einzelne Methoden oder Fragestellungen werden im Detail beleuchtet
 - Reimplementation: Nachprogrammieren von Methoden und Vergleich mit Referenzbibliotheken
 - Simulation Study: Untersuchung spezifischer Fragestellungen durch gezielte Simulation und Vergleich mit theoretischen Ergebnissen.
- Use Cases: «Echte» Datensätze, typische Modelle
- Use Case «Insurance SCR»
 - Erklärungsmethoden für ein internes Solvency II-Modell
 - Detaillierte Analyse von «Variable Importance» durch Varianzanalyse
- Use Case «SOA GLTD»
 - Datensatz der Society of Actuaries zur Reaktivierung bei BU/EU
 - Über 20 Millionen polizenindividuelle Beobachtungen von monatlichen Reaktivierungen zusammen mit vielen weiteren Faktoren
 - Implementiert wurden mehrere Prognosemodelle auf die dann relevante Erklärungsmethoden angewandt werden.

- Statistische Modelle
- Warum braucht es Erklärbarkeit?
- Erklärbarkeitsmethoden
- **Schlussbemerkungen**

Rolle der Aktuare

- Aktuare haben ideale Voraussetzungen, statistische Modelle im Versicherungskontext zu verstehen und zu erklären.
 - Lange Tradition im Umgang mit Daten und statistischen Modellen.
 - Im Gegensatz zu Laien und Juristen haben sie ein mathematisches Verständnis.
 - Im Gegensatz zu reinen Machine Learning-Experten und Data Scientists verstehen sie das Fachgebiet.
- Durch ihre Ausbildung und Erfahrung können sie mehr als bloss Standard-Methoden aufrufen.
- Wichtige Aspekte rund um den Betrieb und Einsatz statistischer Modelle sind Aktuaren schon aus anderen Bereichen bekannt.
 - Z.B. Fragen und Anforderungen rund um die Nachvollziehbarkeit.
- Sie können (und sollten!) eine gewisse «aktuarielle Sorgfalt» in den Umgang mit statistischen Modellen einbringen.
 - Einordnen der Zweckmässigkeit von Modellen und Methoden,
 - Prüfen der Voraussetzungen und Grenzen,
 - Interpretation und Kommunikation der Ergebnisse.

Zusammenfassung

- Die Erklärbarkeit von statistischen Modellen wird immer ein schwieriges Thema sein.
- Diese Schwierigkeit ist kein Grund diese Modelle nicht zu verwenden.
- Erklärbarkeit ist nur ein Aspekt von vielen rund um den Einsatz von statistischen Modellen.
- Standardisierte Erklärungsmethoden sind hilfreich. Sie werden aber nicht alle Probleme lösen.
- Die Interaktion zwischen Menschen, Modellen und die Rolle der Erklärung dabei ist noch wenig verstanden.
- Aktuarien sind dazu prädestiniert, statistische Modelle im Kontext ihrer Verwendung zu erklären.

- Letztendlich muss und kann man Grenzen der Erklärbarkeit akzeptieren. Denn was ist die Alternative?
 - Das menschliche Gehirn ist auch (momentan noch?) eine Blackbox.
 - Menschen sind notorisch **schlecht/gut** darin, sich selbst und anderen Gründe für ihr Handeln zu nennen.
 - Wir haben gelernt, auch damit umzugehen.

Links zu Referenzen

- [1] https://www.eiopa.europa.eu/eiopa-publishes-report-artificial-intelligence-governance-principles-2021-06-17_en
- [2]: https://www.youtube.com/watch?v=ClfsB_EYsVI
- [3]: <https://michaelbach.de/ot/>
- [4]: <https://christophm.github.io/interpretable-ml-book/>
- [5]: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=3595944
- [6]: https://github.com/DeutscheAktuarvereinigung/WorkingGroup_eXplainableAI_Notebooks
- [7]: <https://aktuar.de/unsere-themen/big-data/anwendungsfaelle/Seiten/anwendungsfall2.aspx>
- [8]: https://github.com/DeutscheAktuarvereinigung/WorkingGroup_eXplainableAI_Notebooks/tree/main/SCR%20Use%20Case
- [9]: <https://arxiv.org/abs/2001.02114>

Mitglieder der DAV-Arbeitsgruppe «Erklärbare KI»

■ Mitglieder

- Anja Schmiedt (Leitung)
- Benjamin Müller
- Corinna Walk
- Florian Walla
- Guido Grützner
- Janusch Rentenatus
- Martin Hüttemann
- Simon Hatzensberger
- Simon Steinbach
- Zoran Nikolić (Co-Leitung)

Fragen Bemerkungen Kommentare ???

Fragen im Nachgang auch gerne an:

guido.gruetzner@quantakt.com

Oder auf LinkedIn

<https://www.linkedin.com/in/guido-gruetzner>