Visuelle Erklärungen hochdimensionaler und zeitabhängiger Prozesse[1]

Andreas Hinterreiter[2]

Abstract: Erkenntnisgewinn aus Daten ist die Hauptmotivation sowohl für Forschung im Bereich der Datenvisualisierung als auch im maschinellen Lernen. Die Mittel, mit denen dieses Ziel erreicht werden soll, unterscheiden sich jedoch erheblich zwischen diesen Feldern. Während das maschinelle Lernen in der Regel versucht Entscheidungen zu automatisieren, rückt die Visualisierung den Menschen in den Mittelpunkt. Eine Kombination dieser unterschiedlichen Ansätze kann Nutzer:innen dabei unterstützen, effektive Einblicke in Daten zu erhalten. Diese Dissertation fasst die Ergebnisse aus fünf Arbeiten zusammen, in denen Visualisierung und maschinelles Lernen kombiniert werden – mit Fokus auf zeitliche und/oder hochdimensionale Prozesse. Dabei spannen diese Arbeiten den Bogen von Visualisierungen zur Modellanalyse bis hin zur Datenverarbeitung für Visualisierung.

1 Einführung

In seinem 1962 erschienen Positionspapier *The Future of Data Analysis* beschrieb der Statistiker John Tukey seine Vision einer neuen Disziplin, die er *data analysis* taufte. Darunter verstand er „sämtliche Prozeduren zum Analysieren von Daten, Techniken zum Interpretieren der Ergebnisse solcher Prozeduren [...] sowie sämtliche Maschinerie und Ergebnisse (mathematischer) Statistik, welche zum Analysieren von Daten angewandt werden“ [Tu62, p. 2].

Tukeys facettenreiche Vision der Datenanalyse stellte sich als Katalysator für die sogenannte „Wiedergeburt der Datenvisualisierung“ (engl. *rebirth of data visualization*) heraus. Unter diesem Titel fasste der Psychologe Michael Friendly eine Reihe von Entwicklungen zusammen, die im Zeitraum zwischen 1950 und 1975 dazu führten, dass die Datenvisualisierung aus ihrem jahrzentelangen Dornröschenschlaf erwachte [Fr08]. Interessanterweise leisteten Wissenschaftler im selben Zeitraum Pionierarbeit im Bereich des maschinellen Lernens (ML). So stellte zum Beispiel Rosenblatt 1958 das Perzeptron vor [Ro58] und Werbos führte 1974 die Fehlerrückführung ein [We74]. Die Entwicklungen in den beiden Bereichen der Datenvisualisierung und des maschinellen Lernens zu dieser Zeit waren durch ein gemeinsames Ziel getrieben, nämlich ein besseres Verständnis dafür, wie aus Daten Erkenntnisse gewonnen werden können.

Obwohl sich beide Disziplinen seither rasant weiterentwickelt haben, bleibt dieses Ziel des Erkenntnisgewinns aus Daten ihr gemeinsamer Nenner. Die Mittel, die in den beiden

[1] Englischer Titel der Dissertation: „Visual Explanations of High-dimensional and Temporal Processes“

[2] Institut für Computergrafik, Johannes Kepler Universität Linz, andreas.hinterreiter@jku.at

CC BY SA

Feldern angewandt werden, unterscheiden sich jedoch erheblich. Datenvisualisierungen sind visuelle Repräsentationen von Datensätzen, die *Menschen* beim Durchführen verschiedener Aufgaben unterstützen sollen [Mu14]. Maschinelles Lernens konzentriert sich eher auf die Entwicklung prädiktiver Modelle, um die Lösung bestimmter Aufgaben möglichst zu *automatisieren* [Ng22].

Im Laufe der letzten Jahrzehnte wurde immer deutlicher, dass der auf den Menschen ausgelegte Ansatz der Visualisierung nicht mit den auf Automatisierung fokussierten Methoden des ML in Konkurrenz stehen muss. Vielmehr birgt eine Kombination der unterschiedlichen Ansätze ein enormes Potential. In der Literatur werden Arbeiten, die aus dem Zusammenspiel von Visualisierung und ML entstehen, eingeteilt in *ML4Vis* and *Vis4ML* – je nachdem welche Disziplin im konkreten Fall der anderen zuträglich ist.

2 Forschungsfrage

Die hier zusammengefasste Dissertation [Hi22a] beschäftigt sich mit der Betrachtung hochdimensionaler und zeitabhängiger Prozesse im Grenzbereich zwischen Visualisierung und maschinellem Lernen. Die Relevanz sowohl hochdimensionaler als auch zeitabhängiger Daten lässt sich aus der Beziehung der beiden Disziplinen herleiten.

In der Literatur finden sich bereits mehrere Übersichtsarbeiten, in denen die Forschungslandschaft für ML4Vis und Vis4ML kartographiert wird [Ch20; En17; Ho18; Wa22]. Ein Klasse von Methoden, die sogenannte Dimensionsreduktion (DR), sticht in diesen Übersichtsarbeiten heraus. DR bezeichnet Verfahren, die hochdimensionale Daten mit möglichst geringem Informationsverlust in einen niedrigdimensionalen Raum überführen. DR wird sowohl als Beispiel für ML4Vis als auch für Vis4ML genannt, da sie von beiden zugrundeliegenden Disziplinen – Visualisierung und ML – vereinnahmt wurde und jeweils zur Unterstützung von Methoden der anderen Disziplin verwendet wird. Die Ausnamhestellung von DR ist Resultat der Wichtigkeit hochdimensionaler Prozesse und deren notwendiger Vereinfachung im Grenzbereich zwischen Visualisierung und ML.

Moderne Visualisierungssysteme sind keine statischen Schaubilder, sondern laden die Nutzer:innen ein, sich durch Interaktion direkt am Prozess der Datenanalyse zu beteiligen. Hierdurch ergeben sich komplexe Wechselwirkungsschleifen, in denen Nutzer:innen ihr geistiges Modell der Daten zeitlich voranschreitend verfeinern. Diese Rückkopplungsschleifen, welche bereits in verschiedenen Modellen formalisiert wurden [En17; Li17; Sa14; Sa17], unterscheiden sich konzeptuell wenig von Optimisierungsprozessen für Modelle des ML. Die Zeitabhängigkeit sowohl der Modelloptmierung im ML als auch der visuellen Analyse legt nahe, Prozesse zeitlich aufgelösten zu betrachten.

Die Forschungsfrage, die sich aus den obigen Überlegungen ergibt und welche im Rahmen der Dissertation aus verschiedenen Perspektiven betrachtet wurde, lautete:

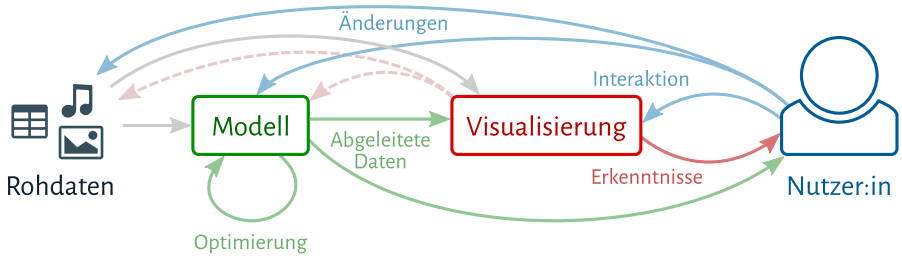

Abb. 1: Prozessmodell für die interaktive Analyse hochdimensionaler und/oder zeitlicher Daten, basierend auf Keim et al. [Ke10].

> Wie können Visualisierung, maschinelles Lernen und Dimensionsreduktion verknüpft werden, um Nutzer:innen zu einem besseren Verständnis von hochdimensionalen und zeitlichen Prozessen zu verhelfen?

In der Dissertation werden mehrere Systeme und Techniken als Antworten vorgestellt. Jede Arbeit lässt sich dabei anhand des in Abb. 1 gezeigten Modells formal in den größeren Zusammenhang der Dissertation einordnen. In diesem Prozessmodell werden Rohdaten in ein ML-Modell eingespeist. Durch das Modell und dessen Optimierung entstehen abgeleitete Daten, die – gegebenenfalls gemeinsam mit Rohdaten – visualisiert werden. Die Nutzer:innen gewinnen durch Interaktion mit der Visualisierung Erkenntnisse über die zugrundeliegenden Daten und können diese in der Folge direkt oder indirekt aktualisieren.

3 Ergebnisse

Fünf Arbeiten, die auch jeweils eigenständig publiziert wurden, bilden den Kern der Dissertaion. Sie beantworten die gemeinsame Forschungsfrage aus verschiedenen Perspektiven und werden nachfolgend kurz vorgestellt.

3.1 ConfusionFlow

Wie bereits erwähnt handelt es sich bei der Optimierung von ML-Modellen, unter denen Klassfizierungsmodelle zu den meistgenutzten gehören, um einen zeitlichen, inkrementellen Prozess. Bestehende Methoden zur visuellen Modellanalyse konzentrieren sich meist auf den Endzustand des Modells. So bleiben interessante Informationen und zeitliche Entwicklungen, die zu diesem Endzustand geführt haben, verborgen. Eine ganzheitlichere Analyse von Klassifizierungsmodellen erfordert also auch eine Darstellung des zeitlichen Verlaufs des Trainings.

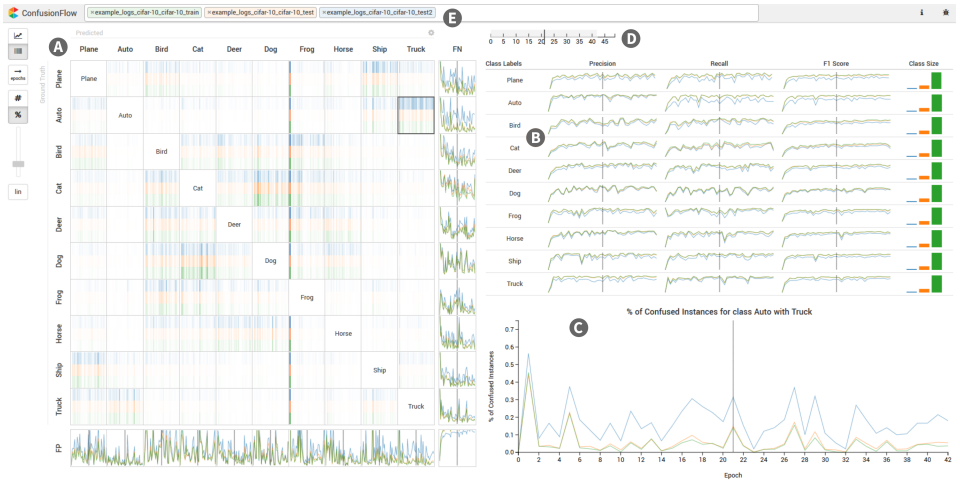

Abb. 2: Anwendungsoberfläche von ConfusionFlow [Hi22b]: (A) adaptierte Konfusionsmatrix; (B) Liniendiagramme weiterer Qualitätsmetriken; (C) interaktive Detailansicht; (D) Epochenregler; und (E) Bedienelement zur Datenauswahl.

ConfusionFlow [Hi22b] ermöglicht den Entwicklern von ML-Modellen eine zeitliche und vergleichende Analyse auf der Klassenebene. ConfusionFlow basiert auf der traditionellen Konfusions- oder Verwechslungsmatrix, die angibt, wie oft Instanzen einer bestimmten Klasse einer anderen Klasse zugeordnet wurden. Dabei erweitert die ConfusionFlow-Matrix die klassische Konfusionsmatrix um eine Zeitachse, sodass statt einzelner Einträge in den Zellen der Matrix nun kompakte Visualisierungen erscheinen, die den zeitlichen Verlauf der Verwechslungen darstellen. Durch überlagerte Liniendiagramme oder übereinander gestellte Heatmaps wird so auch das Vergleichen der Ergebnisse mehrerer Klassifizierungsmodelle unterstützt. Diese adaptierte Matrix ist das Kernstück von ConfusionFlow (siehe Abb. 2). Ergänzt wird sie um verknüpfte Visualisierungen weiterer klassenbezogener Qualitätsmetriken (Precision, Recall, F_1-Score) sowie um eine interaktive Detailansicht.

In Bezugnahme auf des Prozessmodell in Abb. 1 visualisiert ConfusionFlow die Sequenzen von Konfusionsmatritzen als abgeleitete Daten, die aus dem Optimierungsprozess entstehen. Nutzer:innen erhalten so ein besseres Verständnis des zeitlichen Verlaufs der Optimierung, welches sie zum Verbessern des Modells oder der zugrundeliegenden Daten verwenden können. Die Nützlichkeit von ConfusionFlow wird in der Dissertation im Rahmen mehrerer Anwendungsfälle gezeigt.

3.2 InstanceFlow

Wie im vorherigen Abschnitt beschrieben, zielt ConfusionFlow auf eine Analyse von zeitlichen Klassifizierungsdaten ab, die auf der Klassenebene aggregiert sind. Mit Confusi-

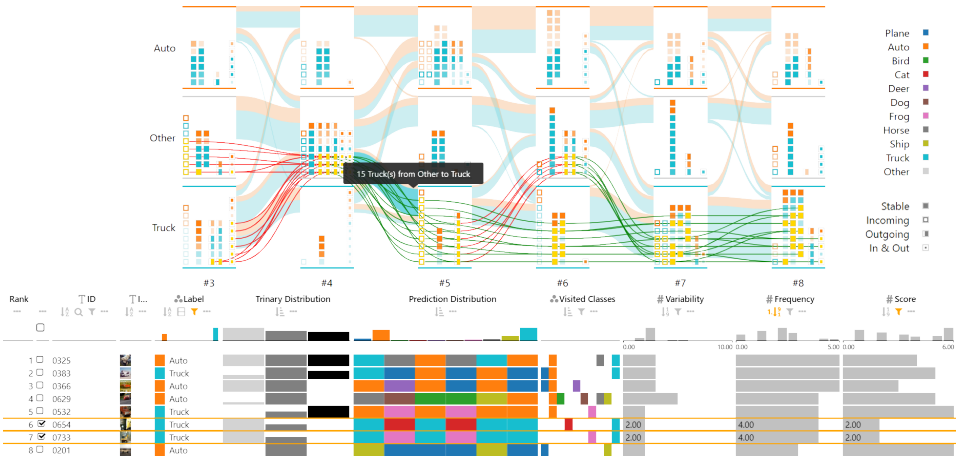

Abb. 3: Anwendungsoberfläche von InstanceFlow [PHS20]. Oben: Flussdiagramm mit aktivierten Glyphen und Pfaden für ausgewählte Instanzen. Unten: tabellarische Ansicht zum Suchen, Filtern und Auswählen relevanter Instanzen.

onFlow alleine können sich Modellentwickler deshalb zwar eine guten Überblick verschaffen (vor allem bei Problemen mit unausgeglichenen Datensätzen oder besonders schwierigen Klassenpaaren), aber für ein tieferes Verständnis des Klassifizierungsprozesses ist es nötig, den Detailierungsgrad auf einzelne Instanzen zu erhöhen.

InstanceFlow [PHS20] wurde entwickelt, um eine solche zeitliche Analyse von Klassifizierungsmodellen auf Instanzebene zu erlauben. Dazu wird der „Fluss“ einzelner Instanzen durch die verschiedenen Klassen über die Zeit visualisiert. Eine Instanz „fließt“ dabei von einer Klasse A in eine andere Klasse B, wenn das Modell für sie in einem Zeitschritt der Optimierung die Klasse A voraussagt und im darauffolgenden Zeitschritt die Klasse B. Daraus ergibt sich ein übersichtliches Flussdiagramm sämtlicher Instanzen, das auf Wunsch der Nutzer:innen um detaillierte Informationen zu einzelnen Instanzen erweitert werden kann. In der vollsten Detailstufe wird jede Instanz durch eine Glyphe repräsentiert und die Pfade der einzelnen Instanzen werden über dem Flussdiagramm angezeigt (siehe Abb. 3). Zum effizienten Auffinden relevanter Instanzen wird das Flussdiagramm um eine tabellarische Ansicht aller Instanzen ergänzt.

Ähnlich wie bei ConfusionFlow handelt es sich bei InstanceFlow um eine Visualisierung abgeleiteter Klassifizierungsdaten, durch deren Analyse Nutzer:innen das Modell oder die Ausgangsdaten verstehen lernen und dann entsprechend verbessern können.

3.3 Projection Path Explorer

ConfusionFlow und InstanceFlow sind als spezialisierte Visualisierungen auf abgeleitete Daten aus Modelloptimierungsprozessen beschränkt. Diese Daten können allerdings ganz generell als Sequenz hochdimensionaler Zustände betrachtet werden, die aus komplexen Prozessen resultieren. Es stellte sich die naheliegende Frage, ob es für diese Daten nicht auch eine generellere Darstellungsform gibt, die unabhängig von der Datenherkunft ist. Insbesondere sollte diese Darstellungsform geeignet sein, sehr viele Prozesse auf einen Blick vergleichend zu analysieren, was durch ConfusionFlow nur in bedingtem Ausmaß ermöglicht wurde.

Der *Projection Path Explorer* [Hi21] entstand als Antwort auf diese Frage. In vielen Prozessen führen bewusste Entscheidungen oder algorithmische Vorschriften dazu, dass ein System von einem Zustand in den nächsten übergeführt wird. Die resultierende Trajektorie durch den hochdimensionalen Zustandsraum kann mit Hilfe von Dimensionsreduktion veranschaulicht werden. Bisherige Ansätze haben sich dabei auf die Selbstähnlichkeit einzelner Trajektorien konzentriert. Im Unterschied dazu ist der Projection Path Explorer eine Visualisierung mit Fokus auf generalisierbare Muster, die aus der gleichzeitigen Betrachtung *vieler* eingebetteter (bzw. projizierter) Trajektorien entstehen. Zusätzlich zu den Trajektorien können Nutzer:innen visuelle Zusammenfassungen der Ausgangsdaten

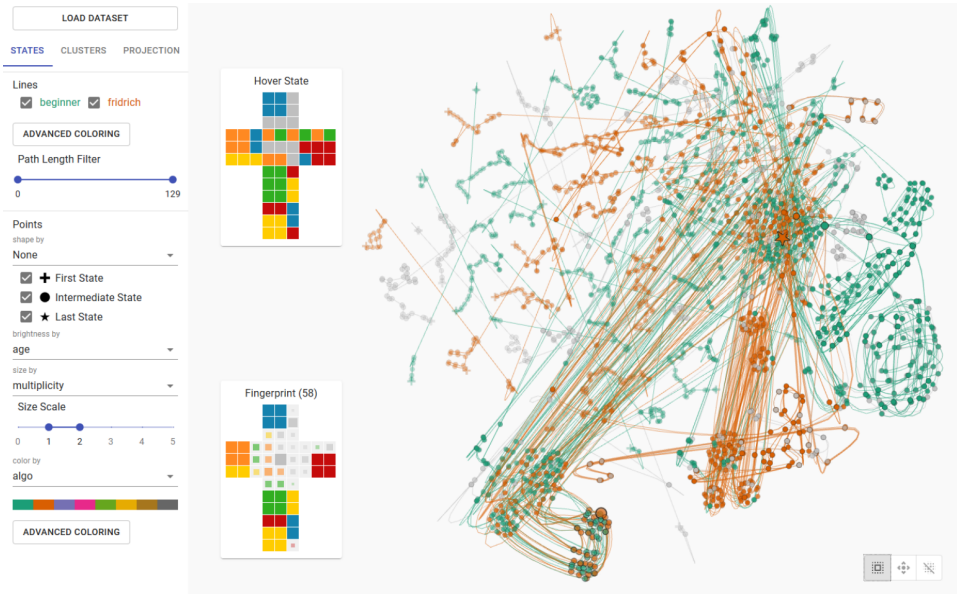

Abb. 4: Anwendungsoberfläche des Projection Path Explorers [Hi21]. Rechts werden die projizierten Trajektorien hochdimensionaler Prozesse angezeigt. In der Mitte zeigt der sogenannte „Fingerprint“, eine kompakte Repräsentation der ursprünglichen Daten bzw. deren Ähnlichkeit.

abrufen, die einen Zusammenhang zwischen niedrig- und hochdimensionalen Datenräumen herstellen. In der Dissertation werden die möglichen visuellen Muster ausführlich dargelegt. Die Nützlichkeit des Projection Space Explorer wird anhand verschiedener Datentypen gezeigt.

Im Prozessmodell aus Abb. 1 stellt der Projection Space Explorer eine Visualisierung dar, die Ergebnisse einer Dimensionsreduktion, also eines Modells des unbeaufsichtigten ML, für Nutzer:innen zugänglich macht. So gewinnen Nutzer:innen nicht nur ein besseres Verständnis für die zugrundeliegenden Daten, sondern auch für den DR-Prozess selbst.

3.4 Projective Latent Interventions

Der Projection Path Explorer beruht auf einer Beobachtung der niedrigdimensional eingebetteten Repräsentationen hochdimensionaler Daten. Diese Beobachtung ist zwar interaktiv, aber passiv in dem Sinne, dass der Prozess, aus dem die Daten stammen, nicht direkt manipuliert werden kann. Im Gegensatz dazu sollen mit sogenannten *Projective Latent Interventions* (PLIs) [HSK20] aktive Manipulationen hochdimensionaler Prozesse auf Basis der niedrigdimensionalen Visualisierungen möglich werden. Gleichzeitig sollen die PLIs das Verständnis des Zusammenhangs zwischen ML-Modell und projektionsbasierter Visualisierung stärken.

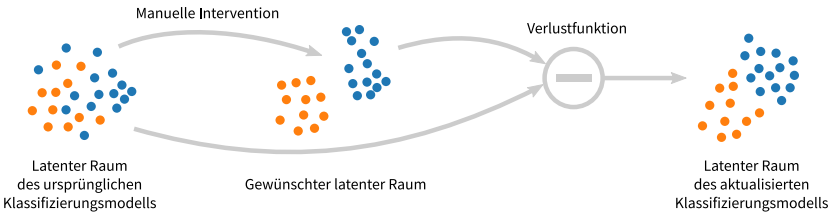

Abb. 5: Das Konzept hinter Projective Latent Interventions [HSK20]: Nutzer:innen manipulieren die niedrigdimensionale Repräsentation des latenten Raumes eines ML-Modells; danach wird das Modell so neu trainiert, dass der latente Raum dem Nutzer:innenvorschlag möglichst gut entspricht.

Zu Beginn des PLI-Ablaufs werden den Nutzer:innen Punktdiagramme des projizierten latenten Raumes eines ML-Modells gezeigt. Die Anwender:innen definieren nun sogenannte Interventionen – etwa Verschiebungen und/oder Kontraktionen von Klassen-Gruppen. Danach wird das ML-Modell auf eine Art neu optimiert, die sicherstellen soll, dass der neue projizierte latente Raum dem vorgeschlagenen möglichst gut entspricht (siehe Abb. 5). Um die Interventionen vom niedrigdimensionalen Raum auf das ursprüngliche Modell „zurückrechnen“ zu können, bedurfte es parametrisierter (auf neuronalen Netzwerken basierender) Varianten bekannter Dimensionsreduktionsverfahren, die im Rahmen der Dissertation implementiert wurden. Durch die Anwendung von PLIs kann in vielen Fällen die Genauigkeit eines Klassifizierungsmodell zielgerichtet erhöht werden. Auch wenn keine Erhöhung der Genauigkeit möglich ist, können PLIs Nutzer:innen abschätzen lassen, wie

stark die niedrigdimensionale Repräsentation des latenten Raumes mit der Wirkungsweise des Modells korreliert. In Bezugnahme auf Abb. 1 stellen PLIs also eine Aktualisierung des Modells direkt über die Visualisierung dar.

3.5 ParaDime

Wie oben erwähnt waren für die Umsetzung von Projective Latent Interventions parametrisierte Versionen etablierter Dimensionsreduktionsverfahren nötig. Ein weiterer Vorteil parametrisierter Modelle ist, dass neue Daten zu bestehenden Einbettungen problemlos hinzugefügt werden können. Damit kann Dimensionsreduktion effizient auf sehr große Datensätze oder auf laufend aktualisierte Datensätze angewendet werden.

ParaDime [Hi23] ist inspiriert von Ähnlichkeiten bestehender Algorithmen zur Dimensionsreduktion. Es vereinheitlicht parametrisierte Versionen dieser Algorithmen und macht sie in einer gemeinsamen Programmierschnittstelle für Endnutzer:innen leicht zugänglich. Die ParaDime-Grammatik, die in der Dissertation ausführlich beschrieben wird, definiert, wie Nutzer:innen personalisierte DR-Verfahren spezifizieren können. ParaDime legt also den Fokus auf die Entwicklung von DR-Modellen, die im weiteren Verlauf die Basis für allgemeine Analyseprozesse wie in Abb. 1 bilden können.

4 Fazit

Visualisierung und maschinelles Lernen werden von der gemeinsamen Motivation getrieben, Erkenntnisse aus Daten zu gewinnen. Die Methoden der beiden Disziplinen unterscheiden sich jedoch – Visualisierung rückt den Menschen in den Mittelpunkt, während ML auf Automatisierung setzt. Die verschiedenen Arbeiten, die den Kern dieser Dissertation bilden, kombinieren auf unterschiedliche Weise Methoden der beiden Disziplinen. Die Synergien reichen dabei von relativ simplen Visualisuerungen für die Analyse von Modelloptimisierungsprozessen bis hin zu komplexen Interventionsmethoden, in denen Visualisierung, Dimensionsreduktion und ML eng verwoben sind. Die Arbeiten zeigen allesamt, wie eine Kombination der gegensätzlich scheinenden Ansätze von Visualisierung und ML Nutzer:innen dabei unterstützen kann, hochdimensionale und zeitabhängige Prozesse besser zu verstehen.

Literaturverzeichnis

[Ch20] Chatzimparmpas, A.; Martins, R. M.; Jusufi, I.; Kerren, A.: A survey of surveys on the use of visualization for interpreting machine learning models. Information Visualization 19/3, S. 207–233, Juli 2020.

[En17] Endert, A.; Ribarsky, W.; Turkay, C.; Wong, B. W.; Nabney, I.; Blanco, I. D.; Rossi, F.: The State of the Art in Integrating Machine Learning into Visual Analytics: Integrating Machine Learning into Visual Analytics. Computer Graphics Forum/, März 2017.

[Fr08] Friendly, M.: A Brief History of Data Visualization. In (Chen, C.-h.; Härdle, W.; Unwin, A., Hrsg.): Handbook of Data Visualization. Springer, Berlin, S. 15–56, 2008, ISBN: 978-3-540-33036-3.

[Hi21] Hinterreiter, A.; Steinparz, C. A.; Schöfl, M.; Stitz, H.; Streit, M.: Projection Path Explorer: Exploring Visual Patterns in Projected Decision-Making Paths. ACM Transactions on Interactive Intelligent Systems 11/3–4, Article 22, 2021.

[Hi22a] Hinterreiter, A.: Visual Explanations of High-dimensional and Temporal Processes, Diss., Johannes Kepler University Linz, 2022, URL: https://epub.jku.at/obvulihs/id/8248358.

[Hi22b] Hinterreiter, A.; Ruch, P.; Stitz, H.; Ennemoser, M.; Bernard, J.; Strobelt, H.; Streit, M.: ConfusionFlow: A Model-Agnostic Visualization for Temporal Analysis of Classifier Confusion. IEEE Transactions on Visualization and Computer Graphics 28/2, S. 1222–1236, 2022.

[Hi23] Hinterreiter, A.; Humer, C.; Kainz, B.; Streit, M.: ParaDime: A Framework for Parametric Dimensionality Reduction. Computer Graphics Forum (EuroVis '23) 42/3, 2023.

[Ho18] Hohman, F.; Kahng, M.; Pienta, R.; Chau, D. H.: Visual Analytics in Deep Learning: An Interrogative Survey for the Next Frontiers. IEEE Transactions on Visualization and Computer Graphics 25/8, S. 2674–2693, 21. Jan. 2018.

[HSK20] Hinterreiter, A.; Streit, M.; Kainz, B.: Projective Latent Interventions for Understanding and Fine-tuning Classifiers. In (Cardoso, J. et al., Hrsg.): Interpretable and Annotation-Efficient Learning for Medical Image Computing. Proceedings of the 3rd Workshop on Interpretability of Machine Intelligence in Medical Image Computing (iMIMIC 2020). Bd. 12446. Lecture Notes in Computer Science, Springer, S. 13–22, 2020, Best Paper Award at iMIMIC 2020.

[Ke10] Keim, D. A.; Bak, P.; Bertini, E.; Oelke, D.; Spretke, D.; Ziegler, H.: Advanced visual analytics interfaces. In: Proceedings of the International Conference on Advanced Visual Interfaces - AVI '10. ACM Press, S. 3, 2010, Stand: 16. 09. 2022.

[Li17] Liu, S.; Maljovec, D.; Wang, B.; Bremer, P. T.; Pascucci, V.: Visualizing High-Dimensional Data: Advances in the Past Decade. IEEE Transactions on Visualization and Computer Graphics 23/3, S. 1249–1268, März 2017.

[Mu14] Munzner, T.: Visualization Analysis and Design. CRC Press, Taylor & Francis Group, 2014, ISBN: 978-1-4665-0891-0.

[Ng22] Ngo, Q. Q.; Dennig, F. L.; Keim, D. A.; Sedlmair, M.: Machine learning meets visualization – Experiences and lessons learned. it - Information Technology 64/4, S. 169–180, 26. Aug. 2022.

[PHS20] Pühringer, M.; Hinterreiter, A.; Streit, M.: InstanceFlow: Visualizing the Evolution of Classifier Confusion at the Instance Level. In: 2020 IEEE Visualization Conference — Short Papers. IEEE, 2020.

[Ro58] Rosenblatt, F.: The perceptron: A probabilistic model for information storage and organization in the brain. Psychological Review 65/6, S. 386–408, 1958.

[Sa14] Sacha, D.; Stoffel, A.; Stoffel, F.; Kwon, B. C.; Ellis, G.; Keim, D. A.: Knowledge Generation Model for Visual Analytics. IEEE Transactions on Visualization and Computer Graphics 20/12, S. 1604–1613, Dez. 2014.

[Sa17] Sacha, D.; Zhang, L.; Sedlmair, M.; Lee, J. A.; Peltonen, J.; Weiskopf, D.; North, S. C.; Keim, D. A.: Visual Interaction with Dimensionality Reduction: A Structured Literature Analysis. IEEE Transactions on Visualization and Computer Graphics (InfoVis '16) 23/1, S. 241–250, 2017.

[Tu62] Tukey, J. W.: The Future of Data Analysis. The Annals of Mathematical Statistics 33/1, S. 1–67, 1962.

[Wa22] Wang, Q.; Chen, Z.; Wang, Y.; Qu, H.: A Survey on ML4VIS: Applying MachineLearning Advances to Data Visualization. IEEE Transactions on Visualization and Computer Graphics 28/12, S. 5134–5153, 2022.

[We74] Werbos, P.: Beyond Regression: New Tools for Prediction and Analysis in the Behavioral Science, Diss., Harvard University, 1974.

Andreas Hinterreiter ist Universitätsassistent im Visual Data Science Lab der Johannes Kepler Universität (JKU) Linz. Sein Forschungsschwerpunkt liegt auf dem Zusammenführen verschiedener Methoden der Visualisierung und des maschinellen Lernens. Er interessiert sich insbesondere für Dimensionsreduktion und Explainable AI.

Er erlangte seinen Masterabschluss in Technischer Physik an der JKU Linz, wo er an der strukturellen und chemischen Analyse von Oberflächen arbeitete. Nachdem er sich zunehmend für Visualisierung und maschinelles Lernen interessierte, entschied er sich dazu, für seine Dissertation in diesen Bereich zu wechseln.

Seine Doktorarbeit entstand im Rahmen einer Kollaboration mit dem Imperial College London, wo er ein Jahr in der Biomedical Image Analysis (BioMedIA) Gruppe verbrachte. Er promovierte im Dezember 2022 an der JKU mit der Dissertation „Visual Explanations of High-dimensional and Temporal Processes“.