

AdaProQ

Schlussbericht

Merantix Momentum GmbH

Verbundprojekt: Adaptive Prozessketten zur Steigerung der Produktionsqualität und -effizienz

Teilvorhaben: KI-Methoden für komplexe Prozessketten

Zuwendungsgeber: Bundesministerium für Wirtschaft und Klimaschutz
Zuwendungsnehmer: Merantix Momentum GmbH (im Folgenden kurz: Merantix)
Förderkennzeichen: 13IK006H
Laufzeit: 01.10.2021 - 31.12.2024



**Finanziert von
der Europäischen Union**

Gefördert durch:



aufgrund eines Beschlusses
des Deutschen Bundestages

Das diesem Bericht zugrundeliegende Vorhaben wurde mit Mitteln des Bundesministeriums für Wirtschaft und Klimaschutz unter dem Förderkennzeichen 13IK006H gefördert. Die Verantwortung für den Inhalt dieser Veröffentlichung liegt bei der Autorin/beim Autor.

I. Kurze Darstellung

1. Aufgabenstellung

Aufgrund des derzeitigen industriellen Wandels ist die deutsche Automobilindustrie besonderen Herausforderungen ausgesetzt. Diese betreffen insbesondere hochspezialisierte Zulieferer, welche nun vor der Herausforderung stehen, neue Produktlinien in kürzester Zeit aufzubauen und in Betrieb zu nehmen. Dazu müssen Unternehmen ihre Anpassungsmöglichkeiten erweitern und resiliente Produktionstechnologien etablieren. Die bauteilspezifische Qualitätssicherung erfolgt insbesondere bei hohen Stückzahlen bisher in aller Regel stichprobenartig, was bei der Fertigung von kundenspezifischen Produkten nur schwer umzusetzen ist. Der Ermittlung etwaiger Fehlerursachen und deren Gegenwirkung wird aufgrund der hohen Fertigungskomplexität oftmals heuristisch und/oder mit einem enormen personengebundenen Erfahrungswissen begegnet.

Methoden der Künstlichen Intelligenz ermöglichen die Erkennung von Mustern innerhalb der komplexen, multidimensionalen Lösungsräume der Prozessplanung sowie deren Ausführung. Zusammenhänge zwischen Eingangsparametern, Prozessqualität und finaler Bauteilqualität lassen sich bspw. mit Hilfe künstlicher neuronaler Netze analysieren. Aufbauend auf der Identifizierung relevanter Parameter lassen sich diese auch optimieren. Ziel von Merantix im Projekt war es daher, soweit möglich, generische Methoden zu entwickeln, die eine Vielzahl der Herausforderungen der Anwendungspartner abdecken. Durch die thematische Breite der Anwendungsfälle innerhalb von AdaProQ sind die Voraussetzungen geschaffen, im Konsortium Lösungen zu entwickeln, die auch über das Konsortium hinaus – auf Seiten der Fahrzeughersteller und Automobilzulieferer – zum Einsatz kommen können und zur Stärkung der Wettbewerbsfähigkeit des Industriestandortes Deutschland beitragen.

2. Voraussetzungen, unter denen das Vorhaben durchgeführt wurde

Das Teilvorhaben von Merantix wurde als Teil des Verbundprojekts AdaProQ in der Förderrichtlinie „Digitalisierung der Fahrzeughersteller und Zulieferindustrie“ im Förderrahmen „Zukunftsinvestitionen Fahrzeughersteller und Zulieferindustrie“ vom 16. März 2021 in Zusammenarbeit mit insgesamt 13 Projektpartnern durchgeführt. Im Verbundprojekt AdaProQ wurden mehrere konkrete Anwendungen unterschiedlicher Unternehmen einbezogen, die sich im Hinblick auf eine hohe Sicherheitsrelevanz der produzierten Bauteile, hohe Anforderungen an die Maßhaltigkeit sowie die starke Abhängigkeit von den Materialeigenschaften ähneln. Die fünf von den Anwendungspartnern beschriebenen Prozessketten decken ein breites Spektrum an Herausforderungen ab, denen im Kern eines gemein ist: Aufgrund der hohen Komplexität der ihnen zugrunde liegenden physikalischen Prozesse stellt die Identifikation relevanter Stellschrauben im Gesamtsystem und die Ableitung geeigneter Maßnahmen, um hohe Produkt- und Produktionsqualität bei hoher Produktionseffizienz zu erreichen, eine große Herausforderung dar.

3. Planung und Ablauf des Vorhabens

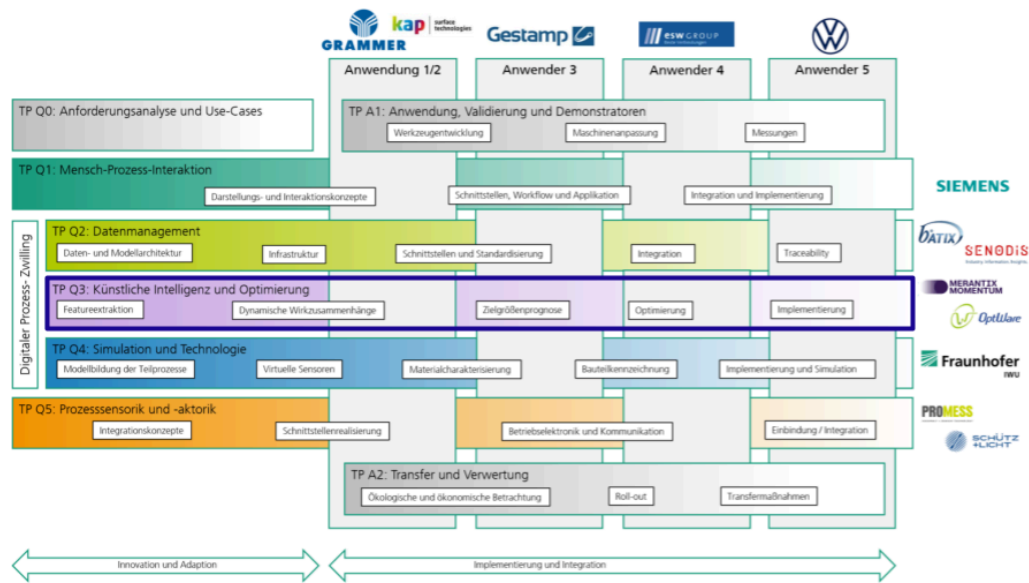


Abbildung: Verbundstruktur und Projektaufbau

Das Projekt wurde in einer Matrixstruktur geplant und durchgeführt. Vier Unternehmen der Automobil(zulieferer)industrie stellten insgesamt fünf Anwendungsfälle zur Verfügung. Diese wurden jeweils entlang der wesentlichen technischen Herausforderungen in fünf querschnittlichen technischen Arbeitspaketen bearbeitet. Der Hauptbeitrag von Merantix lag hierbei im TPQ3 (in der Grafik fett umrahmt), also dem Einsatz von Künstlicher Intelligenz und Optimierung.

4. Wissenschaftliche und technische Ausgangslage

Maschinelle Lernverfahren werden mit dem Ziel eingesetzt, das Verhalten eines Systems mit Datenanalyse und mathematischer Modellierung vorherzusagen. Maschinelles Lernen, insbesondere *Deep Learning*, hat große Erfolge in Bereichen wie Bildklassifizierung, Sprachverarbeitung oder sozioökonomische Analyse gezeigt, in denen Kausalzusammenhänge oft nur spärlich angegeben werden, aber große Datenmengen verfügbar sind. Gerade aber im Bereich strukturierter Daten wie Tabellen und Zeitreihen, wie sie in industriellen Prozessen häufig vorkommen, sind Deep Learning Methoden bisher unzureichend erforscht. In industriellen Anwendungen sind insbesondere interpretierbare Methoden aus dem Bereich *Explainable AI (XAI)* von Interesse, um menschliche Entscheidungen zu unterstützen oder Prozesswissen und andere Zusammenhänge aus Daten zu extrahieren. In Kombination mit neuen Lernmethoden des Deep Learnings gibt es neuartige Ansätze wie *Neural Additive Models*¹, welche bisher vor allem in medizinischen Anwendungen und ausschließlich für tabellarische Daten untersucht wurden.

¹ Agarwal, Rishabh, et al. "Neural additive models: Interpretable machine learning with neural nets." *Advances in Neural Information Processing Systems* 34 (2021): 4699-4711.

II. Eingehende Darstellung

1. Verwendung der Zuwendung und erzieltes Ergebnis im Einzelnen, mit Gegenüberstellung der vorgegebenen Ziele

Q0.3: Analyse / Anforderungen KI und Optimierung

Aufgrund der Komplexität und des Umfangs der im Projekt betrachteten Prozessketten war deren strukturierte Aufarbeitung bezüglich der Anforderungen an die querschnittlichen Methodenteilprojekte wesentlicher Gegenstand der Projektarbeit. Hierzu wurde in Zusammenarbeit mit den anderen Partnern des TP Q3 ein umfangreicher Fragebogen für die Anwendungspartner erarbeitet. Dieser hatte zum Ziel, die konkreten Ausgangsbedingungen und Anforderungen der Anwendungspartner bezüglich des Einsatzes von KI und Optimierung zu erheben und zu strukturieren. Merantix Momentum hat zur Erstellung des Fragebogens wesentliche Beiträge geleistet.

Zur Verfahrensoptimierung wurde die weitere Bearbeitung der Fragebögen in Zusammenarbeit mit den Anwendungspartnern unter den TP-Q3-Partnern aufgeteilt. Merantix Momentum hat federführend die Betreuung des Anwendungsfalls der Volkswagen AG übernommen. Basierend auf dem erarbeiteten Fragebogen wurden in mehreren intensiven Anwenderinterviews die relevanten Arbeiten strukturiert erarbeitet und bewertet. Darüber hinaus hat Merantix Momentum an den Interviews mit den anderen Anwendern (Grammer GTC & GAM, Autotech, ESW) teilgenommen.

Die so erhobenen Anforderungen wurden im Anschluss in Form eines innerhalb des Projekt standardisierten kombinierten Lasten- und Pflichtenheft-Templates aufbereitet. Im Zuge der Aufteilung der Anwendungsfälle auf die an TP Q3 beteiligten Partner war Merantix Momentum federführend an der Aufbereitung der KI-Anforderungen des VW-Anwendungsfalls (TP A1.VW) beteiligt.

Q3.1: Zielbildung und Modellierung

Ziel von Merantix Momentum im Rahmen dieses Arbeitspakets war die Überführung der im Rahmen von TP Q0.3 ermittelten Anforderungen in konkrete Zielbildungs- und Modellierungsanforderungen für KI-basierte Ansätze. Im Verlauf der ersten Projektmonate hat sich gezeigt, dass eine weitere Klärung von möglichen Anforderungen und auch möglichen Zielen des Einsatzes von KI in Zusammenarbeit mit den Anwendungspartnern zielführend ist. Hierzu hat Merantix Momentum einen "AI Crash Course" durchgeführt. Ziel dieses Workshops war es, die Erwartungshaltung der Projektpartner – sowohl der Anwendungs- als auch der anderen Technologieentwicklungspartner – an das Potenzial von KI und ML von diesen abzuholen, Fragen aufzugreifen und Einsatzmöglichkeiten aufzuzeigen. Merantix Momentum bietet dieses Format seinen eigenen Kunden als Dienstleistung für die o.g. Zwecke an, hat damit sehr gute Erfahrungen gemacht und hierfür durchgehend positives Feedback erhalten. Einen solchen Kurs in Kurzform (zeitlicher Umfang: halber Tag) hat Merantix Momentum für das AdaProQ-Konsortium vorbereitet, durchgeführt und im Workshop zu Beginn und zum Ende erhobene Einschätzungen der

Projektpartner zu ihrem Kenntnisstand im Nachgang ausgewertet. Der Workshop fand am 14.02.2022 statt und konnte – mit 38 Teilnehmenden – eine große Resonanz unter den Projektpartnern erzeugen.

Merantix Momentum hat im Nachgang des Workshops eine Befragung durchgeführt, wie sich der Wissensstand der Teilnehmer zum Thema KI (Antwortmöglichkeit war die Selbsteinschätzung auf einer Skala von 1 (schwach) bis 5 (stark)) durch den Kurs verändert hat. Bei den meisten Teilnehmenden konnte ein positiver Effekt erzielt werden.




Abbildung 1: Veränderung in der Selbstwahrnehmung der Teilnehmenden nach dem Workshop.

Im Workshop erhoben wurden auch Themenschwerpunkte, für die sich die Teilnehmenden einen weiteren vertieften fachlichen Austausch wünschen. Im Ergebnis zeigt sich ein großes Interesse im Hinblick auf das Kennenlernen weiterer Anwendungsbeispiele – um z.B. auf Seiten der Anwendungspartner weitere KI-Einsatzpotentiale ermitteln zu können – sowie die Beantwortung von Fragen im Hinblick auf für die Realisierung von KI-Lösungen notwendigen Datenmengen und -qualitäten. In Teilen hat Merantix Momentum diese Impulse aufgenommen und in den Projekttreffen kurze Impulsvorträge zu diesen Themen gehalten.




Abbildung 2: Bewertung von Themenschwerpunkten für den weiteren Austausch zum Thema KI im Rahmen der während des AI Crash Course durchgeführten Umfrage unter den Teilnehmenden.

Auf Basis des durch den AI Crash Course geschärften Verständnisses wurden anschließend im Projekt eine Vielzahl von Abstimmungen durchgeführt, mit der Zielstellung, das Optimierungsziel der jeweiligen Anwendungspartner zusammen zu definieren und erste Produktionsdatensätze zu validieren. Hierzu wurde ein intensiver, iterativer Austausch mit den Anwendungspartnern durchgeführt. Zunächst wurden in Zusammenarbeit mit den Anwendungspartnern und der Konsortialleitung der technische Ablauf der einzelnen

Anwendungsfälle detailliert. Aus diesen Abstimmungen resultieren zwei wesentliche Ergebnisse zu denen Merantix Momentum umfangreich beigetragen hat: ein detaillierter Katalog der jeweiligen Abläufe in den Anwendungsfällen inklusive der jeweiligen Mess-, Stell- und Zielgrößen (MSZ-Katalog) sowie eine grafische Kurzdarstellung dieses Kataloges.

Neben der Strukturierung der Prozessketten und der Identifikation der zu erwartenden Daten konnte durch diese Aufbereitung der einzelnen Anwendungsfälle die Definition von unterschiedlichen Formen der Adaptivität geschärft werden.

Darüber hinaus diente die strukturierte Darstellung dazu, die Anforderungen von TP Q3 im Allgemeinen und der durch Merantix Momentum angestrebten KI-Methodenentwicklung im Besonderen im weiteren Austausch mit den Anwendungspartnern sowie mit den anderen querschnittlichen Teilprojekten abzustimmen. Außerdem fanden mehrere Konversationen mit TP Q2 statt, um Anforderungen und Schnittstellen zur Implementierung der Datenbasis so zu gestalten, dass sie für die KI-Methodenentwicklung optimal nutzbar sind.

Schließlich konnte das so strukturierte Verständnis der Prozessketten genutzt werden, um in Zusammenarbeit mit dem Anwendungspartner AutoTech ein Datenglossar zu definieren und in Zusammenarbeit mit dem Anwendungspartner VW eine Versuchsplanung für die im weiteren Projektlauf geplanten Versuche aufzustellen, zu denen Merantix Momentum wesentlich beigetragen hat.

Als herausfordernd wurden die Komplexität einiger der betrachteten Prozesse sowie der Einflüsse auf die Qualität der Prozessergebnisse identifiziert. Weiterhin sind nicht in allen Anwendungsfällen Messungen für alle wichtigen Einflussgrößen vorhanden und es kommen teilweise Werkzeug- oder Materialwechsel vor, welche in den erhobenen Daten nicht widerspiegelt werden.

Bereits in den ersten Abstimmungen mit den Anwendungspartnern und folgend auf Basis der ersten zur Verfügung gestellten Daten hat sich gezeigt, wie wichtig ein klar strukturiertes Datenformat ist. Um hierauf positiv einzuwirken, wurden – federführend durch Merantix Momentum – die Anwendungspartner im Projekt für ein sogenanntes “Tidy Data“-Konzept sensibilisiert. Dieses stellt sicher, dass

- Zeiten der einzelnen Messungen untereinander synchronisiert und somit referenzierbar sind,
- Daten in einem einheitlichen Format wie CSV und mit einheitlichem Trennzeichen gespeichert werden,
- die Einheiten der Daten klar benannt und nicht als Teil der Werte abgelegt werden und
- die Daten in einem konsistenten Format wie UTF-8 kodiert sind.

Darüber hinaus wurden weitere wesentliche Dateneigenschaften festgelegt. Derart wurden die Voraussetzungen geschaffen, dass die Anzahl an Iterationsschleifen zur Überarbeitung von bereitgestellten Daten bzw. notwendige Zeit für deren Aufbereitung minimiert werden kann.

Q3.2–3.4: Methodenentwicklung, Training & Test

Auf Basis der in TP Q3.1 gewonnenen Erkenntnisse sowie der verfügbaren Daten der Anwendungspartner Grammer GTC sowie AutoTech wurden Datenanalysen und Methodenentwicklungen durchgeführt. Hierbei wurde bereits zu Beginn Wert gelegt auf eine geeignete und skalierbare Infrastruktur für das Training sowie die Evaluation der ML-Methoden. Nachfolgend werden die wesentlichen Erkenntnisse dieser Arbeitspakete zusammengefasst.

Anwendungspartner AutoTech (AT)

Für den Anwendungspartner AutoTech konnte auf Basis einer zunächst kleinen Menge von Datenpunkten eine explorative Datenanalyse (EDA) durchgeführt werden. Die zur Verfügung gestellten Daten bestanden im Wesentlichen aus zwei Teilen: ein Datensatz der gemessenen Kraftreihen pro Prototyp sowie ein Datensatz der gemessenen Schweißparameter pro Prototyp. Prinzipiell beschreiben die Datensätze Messvorgänge desselben Prozesses, nämlich dem Schweißen von drei Subbauteilen zu einem Prototypen. Komplettiert wird der Datensatz durch eine Geometrievermessung der Subbauteile sowie der fertigen Prototypen – entweder als vollständiger 3D-Scan oder als punktuelle Vermessung mittels einer Koordinatenmessmaschine.

Zunächst wurden die Anzahl und Vollständigkeit der Datenpunkte in den Datensätzen der Schweißanlagen sowie der Spannkraften untersucht. Die durchgeführten vertiefenden Analysen werden hier zusammenfassend aufgezählt:

- Kraftverläufe geordnet nach Kraftsensoren für alle vermessenen Teile
- Normalisierte, geglättete Zeitreihen während des Schweißens
- Darstellung der Kraftmessungen pro Teil auf einer gemeinsamen normierten Größenskala
- Auto- und Kreuzkorrelationsfunktionen der Kraftmessungen während des Schweißens
- Darstellung der Kraftmesszeitreihen während des Einspannvorgangs
- Darstellung der Variation der Spacerdaten der Prototypenteile Nr. 1–5
- Gleichgewichtszustand der Kräfte am Ende des Einspannprozesses
- Darstellung der ermittelten Gleichgewichtskräfte des Spannprozesses für unterschiedliche Spacer-Distanzen, welche einen qualitativ linearen Zusammenhang aufzeigen und die physikalische Intuition bestätigen
- Darstellung der Gleichgewichtskräfte während des Schweißens
- Normalisierte Darstellung der Zeitreihen bzgl. ihres Anfangswerts
- Lineare Regression der Messungen

Insgesamt wurde dem Anwendungspartner AutoTech eine 26-seitige Auswertung der zur Verfügung gestellten Daten übergeben sowie in mehreren Abstimmungsterminen erläutert. Die gewonnenen Erkenntnisse konnten im Rahmen eines Deep Dives genutzt werden, um gemeinsam mit anderen Projektpartnern, auch aus dem Bereich Simulation, zu erörtern, mit welchen Mitteln der mögliche Einsatz von Methoden des maschinellen Lernens für den AutoTech-Anwendungsfall potentiell verbessert werden kann. Hierfür waren die Erkenntnisse der durch Merantix Momentum durchgeführten Datenanalyse, welche auch die Einschränkungen in der vorliegenden Datenbasis aufzeigt, wesentlich.

In einer weiteren Iteration wurde der Zusammenhang der Spacer-Distanzen und der Zielgeometrie in enger Absprache mit AutoTech sowie der Konsortialleitung erweitert. Basierend auf einer Auswertung historischer Geometriedaten durch Fraunhofer IWU wurde eine Auswahl an Geometriefeatures bereitgestellt, die im Falle der neu vermessenen Prototypen signifikant von den historischen Werten abweichen. Die von Merantix Momentum bisher entwickelte Analyse wurde daraufhin mittels der neu hinzugekommenen Daten erweitert. Die Datenbasis wurde hierbei von 5 auf 18 geschweißte und vermessene Prototypen erweitert. Es stellte sich heraus, dass die bisher beobachteten linearen Zusammenhänge zwischen Spacer-Distanzen und Zielgeometriefeatures tatsächlich nicht-linear abhängig sind. Aufgrund der geringen Anzahl an Messdaten (lediglich 4 voll vermessene Prototypen) konnte jedoch keine weitere statistische Analyse durchgeführt werden. Dennoch wurde eine qualitative Auswertung basierend auf polynomiellen Interpolationen durchgeführt und AutoTech zur Verfügung gestellt, um die beobachteten Zusammenhänge mit der internen Prozessintuition abzugleichen.

Zunächst verglichen wir die Streuung in der Abweichung zur Zielgeometrie zwischen konstant vermessenen Prototypen und solchen, bei denen die Spacer Einstellungen variiert wurden. Um den Einfluss genauer zu untersuchen, wurden polynomielle Modelle gelernt, um die Zielgeometriedaten auf Basis der eingestellten Spacer-Einstellung anzunähern. Basierend auf den beiden oben untersuchten Stichproben können wir dasjenige Geometriefeature extrahieren, bei dem die Differenz der Standardabweichungen am höchsten ist.

Anwendungspartner Grammer GTC (GTC)

Als zweiter Anwendungsfallgeber konnte Grammer GTC umfangreich Daten zur Auswertung zur Verfügung stellen, welche in mehreren Versuchsterminen über den gesamten Projektverlauf hinweg erweitert werden konnten. Hierauf wurden Methoden des Maschinellen Lernens (ML) angewendet, mit dem Ziel, erste Erkenntnisse hinsichtlich der Tragfähigkeit dieses Lösungsansatzes zu erzielen. Für die vorliegenden Daten wurde eine neuartige Klasse von ML-Methoden verwendet, die sogenannten *Neural Additive Models* (NAMs). Im Dezember 2022 wurde von GTC ein dedizierter Versuchstag durchgeführt mit dem Ziel, möglichst diverse und aussagekräftige Daten zu sammeln. Merantix Momentum hat sich an der Versuchsplanung beteiligt und die Durchführung vor Ort begleitet. Weitere Versuchstage folgten in den Jahren 2023 und 2024.

NAMs sind eine Klasse von neuronalen Netzen, welche Zusammenhänge für Menschen nachvollziehbar darstellen und damit gleichzeitig vorbereitende Arbeiten für TP Q3.6 ermöglichen. Sie gehören zur Modellklasse der *Generalized Linear Models* innerhalb des Forschungsbereichs "Explainable AI". Die Interpretierbarkeit der Ergebnisse wird durch die Architektur des Netzes hergestellt, indem Eingabe-Features jeweils nur unabhängig voneinander weiterverarbeitet werden. Diese Netzarchitektur führt zur Nachvollziehbarkeit der einzelnen Einflüsse der Features auf die Zielgröße. Der Gesamteinfluss auf die Zielgröße ergibt sich schließlich als gewichtete Summe der einzelnen Beiträge für jedes separate Feature. Damit ist es einerseits möglich, die *globale* Wichtigkeit der jeweiligen Eingabe-Features für die Vorhersage einer Zielgröße zu bestimmen, zum anderen ergibt sich ein Graph, welcher den *lokalen* Beitrag eines jeden einzelnen Features zur Zielgröße im Detail beschreibt.

Als Zielgröße wurde von TP Q3 in Rücksprache mit Grammer unter Beteiligung von Merantix Momentum die mittlere Breite als Abweichung der gemessenen Geometrie von der Zielgeometrie an drei Punkten des Bauteils festgelegt und ausgewertet und visualisiert.

Diese Art der Darstellungen können für den Grammer GTC Anwendungsfall im Speziellen sowie AdaProQ-Anwendungsfälle im Allgemeinen sehr wertvolle Erkenntnisse liefern – sowohl in der Experimentier- und Designphase, sowie über mögliche Zusammenhänge von Einflussparametern der Prozesskette, die ggf. Expertenwissen ergänzen kann. Darüber hinaus sind interpretierbare Modelle wichtig, um Entscheidungen der KI nachvollziehbar zu machen und somit eine bessere Akzeptanz der Menschen, welche die Maschinen bedienen, herbeiführen. Darüber hinaus helfen interpretierbare Modelle grundsätzlich, ein besseres Prozessverständnis zu erlangen.

Des Weiteren untersuchten wir verschiedene Abhängigkeiten zwischen den Materialeigenschaften, insbesondere zwischen den Materialparametern Zugfestigkeit, Streckgrenze und Dehnung, auf Basis derer eine adaptive Prozessoptimierung und Qualitätsvorhersage getroffen werden soll. Die Ergebnisse (inklusive weiterer hier nicht gezeigter Details) wurden in digitaler Form mit dem Anwendungsfall-Partner sowie den TPQ3-Partnern geteilt.

Auf Basis der erweiterten Datenlage wurden die entwickelten Neural Additive Models stetig erweitert und verfeinert. Wie gemeinsam mit den Partnern in TPQ3 abgestimmt, werden jeweils die Werte der mittleren Breite aus den Materialeigenschaften sowie des Pressdrucks (UT) vorhergesagt. Um eine Vergleichbarkeit zu garantieren, verwenden alle TPQ3 Partner denselben Trainings-/Testdaten-Split. Die NAM-Modelle werden mit den Trainingsdaten trainiert, wobei wir auf einem kleinen Holdoutset eine Hyperparameteroptimierung durchführen (siehe auch die Arbeiten in TPQ3.5). Wir führen Versuche durch, bei denen zwischen drei verschiedenen Featuresets unterschieden wird:

1. Alle verfügbaren Features;
2. Ausschluss solcher, die nach dem Prozess gemessen werden (exkl. Werkstückdicke & -temperatur);
3. Ausschluss chemischer Eigenschaften des Materials.

Die berechneten Feature-Importances sind vergleichbar mit den vom Projektpartner OptWare separat über ein lineares Vorhersagemodell berechneten. NAMs erlauben darüber hinaus jedoch das Erlernen und Darstellen nichtlinearer Zusammenhänge über die sogenannten Shape-Functions. Die Shape-Funktion des unteren Totpunkts (UT), d.h. der direkte Beitrag des Features zur Vorhersage der Zielqualität, ermöglicht etwa die Erkennung von Nichtlinearitäten des Modells. Auch der Beitrag des Features Coildicke ist stark nichtlinear. In diesen Bereichen hat ein lineares Vorhersagemodell möglicherweise große Prädiktionsfehler.

Zusammengefasst liefern die entwickelten Neural Additive Models gute Ergebnisse, verglichen mit der Vorhersagequalität von Gradient Boosted Trees (XGBoost) oder K-Nearest-Neighbors, welche vom Projektpartner OptWare untersucht wurden. Dabei sind

NAMs interpretierbar und erlauben eine exakte Einsicht in die Modellvorhersage, ähnlich zu linearen Modellen. Gegenüber linearen Modellen haben NAMs jedoch den Vorteil, nichtlineare Zusammenhänge erlernen zu können, die evident im betrachteten Anwendungsfall beobachtet wurden. Die hier gezeigten Ergebnisse sowie weitere Auswertungen wurden mit dem Anwendungsfallpartner sowie den TPQ3-Partnern geteilt.

Des Weiteren wurde die Trainings- und Optimierungsinfrastruktur stetig weiter ausgebaut und verbessert. Insbesondere wurde untersucht, wie groß der Einfluss der Hyperparameter auf die Modellperformance ist. Zu diesem Zweck wurde zunächst eine leichtgewichtige Implementation mittels Optuna und dem Hydra Framework durchgeführt. Optuna führt hier eine *Bayesian Optimization* mittels *Tree-structured Parzen Estimator* durch, um so effizient den großen Hyperparametersuchraum zu verarbeiten. Bayesian Optimization Ansätze haben gegenüber einfacheren Methoden, wie *Grid Search* oder *Random Search* den Vorteil, Informationen bereits durchgeführter Trainings einzelner Konfigurationen zu Verwenden, um so ein statistisches Modell geeigneter Hyperparameter zu erlernen. Dies ermöglicht, insbesondere bei großen Suchräumen und komplexen Modellen, eine deutlich effizientere und schnellere Optimierung. Die mittels Hydra und Optuna durchgeführten Hyperparameter-Sweeps werden automatisiert und auf der Weights & Biases Plattform gespeichert und ausgewertet.

Auf Basis dieser Hyperparameter-Sweeps wird diejenige Konfiguration ausgewählt, welche auf einem Validierungsdatensatz die besten Vorhersageergebnisse liefert. Es zeigte sich eine teilweise recht starke Abhängigkeit der Performance von den gewählten Hyperparametern, wie es bei ML-Methoden und NAMs insbesondere zu erwarten ist. Aus diesem Grund wurde die zunächst leichtgewichtig implementierte Hyperparameteroptimierung (HPO) deutlich erweitert und mittels des Ray Frameworks, insbesondere Ray Tune, realisiert. Ray Tune bietet den großen Vorteil der Skalierung, da die individuellen HPO trials automatisiert auf individuellen Kubernetes Pods durchgeführt werden.

Die benötigte Kubernetes Infrastruktur wird dabei von Ray, innerhalb eines vorgegebenen Rahmens, automatisch den Bedürfnissen entsprechend skaliert. Darüber hinaus monitort Ray alle für eine HPO Studie notwendigen trials und startet diese beispielsweise bei unerwarteten Fehlern erneut, was bei der Skalierung zu einer deutlich erhöhten Robustheit im Vergleich zur vorherigen Hydra-basierten Lösung führt. Den aktuellen Status einer HPO Studie stellt Ray über ein Browser Dashboard zur Verfügung, die erzielten Ergebnisse wie Trainings und Validierungsloss werden direkt in Weights and Biases synchronisiert. Auch mittels Ray wird die eigentliche (Bayesian) Optimierung mittels Optuna und dem *Tree-structured Parzen Estimator* durchgeführt. Hierzu wird pro Modellkonfiguration ein Ensemble aus 10 NAMs mittels 5-facher Crossvalidation auf dem Trainingsatz trainiert und validiert. Die mittlere Crossvalidation Performance wird dann als Optimierungsziel für die Bayesian Optimierung verwendet.

In Anschluss an die durchgeführte HPO Studie wird automatisiert die am besten abschneidende Modelkonfiguration mit erweiterten Rechenressourcen auf dem vollständigen Datensatz trainiert – ebenfalls mittels eines Ensembles aus 10 NAMs – und das finale Model als Modelartefakt in *Weights and Biases* gespeichert. Mithilfe dieser skalierbaren Umsetzung kann nun innerhalb kurzer Zeit auf neue verfügbare Daten reagiert werden und Modelle

schnell und effizient trainiert, optimiert, evaluiert sowie gespeichert werden. Eine beispielhafte Darstellung der Performanceentwicklung einer HPO Studie ist in Abbildung 3 gezeigt. Gut zu erkennen sind die sich stetig verbessernde Validierungsmetrik und die beste Performance des finalen trainierten Modells (letzter Punkt in blau).




Abbildung 3: Darstellung des Crossvalidation Loss (*test_loss*) über die Zeit für eine beispielhafte HPO Studie mittels NAMS im Falle des GTC Anwendungsfalls. Jeder Punkt entspricht hierbei einer Modellkonfiguration, welche verteilt und automatisiert mittels des Ray Tune Frameworks auf der Kubernetes Infrastruktur trainiert und optimiert wird.

Darüber hinaus, auch mit dem Ziel, die Modellanalyse näher an die Anwendungspartner zu bringen, wurde eine Web-App entwickelt, welche ein interaktives Trainieren und Auswerten der Neural Additive Models ermöglicht ("NAM-App"). Durch die sich schnell verändernden Anforderungen der jeweiligen Anwendungsfälle ist es mühsam, Modelle manuell anzupassen und neu zu trainieren. Auch ist die Auswertung und Interpretation der Modelle für die Anwendungspartner nur schwer zugänglich. Um diesen Vorgang zu beschleunigen, entwickelten wir die NAM-App, welche das Training in der Compute-Cloud über ein Web-Interface ermöglicht. So können leicht verschiedene Parameter- und Zielgrößenkombinationen ausprobiert, trainiert und ausgewertet werden. Hierdurch lassen sich schnelle Iterationszyklen in enger Anbindung an die Anwendungspartner durchführen, wie dies erfolgreich im GTC-Use-Case demonstriert wurde: hier wurden iterativ die Erkenntnisse über wichtige Inputparameter und Datenlücken im Wechsel mit der NAM-App und den anderen TPQ3 Partnern beleuchtet und erweitert. Ein Screenshot eines Teils der App wird in Abbildung 4 gezeigt.

File: versuchstagsdaten.csv 99.4 KB [Download]

versuchs-id	werkstueck-variante	werkstueck-produktionstag	werkstueck-produ
1.1	rechts	06/12/22	00:00:00 AM
1.2	rechts	06/12/22	00:00:00 AM
1.3	rechts	06/12/22	00:00:00 AM
1.4	rechts	06/12/22	00:00:00 AM
1.5	rechts	06/12/22	00:00:00 AM
1.6	rechts	06/12/22	00:00:00 AM
2.1	rechts	06/12/22	00:00:00 AM
2.2	rechts	06/12/22	00:00:00 AM
2.3	rechts	06/12/22	00:00:00 AM
2.4	rechts	06/12/22	00:00:00 AM

Choose features

- versuchs-id
- werkstueck-variante
- werkstueck-produktionstag
- werkstueck-produktionszeit
- coil-abschnitt
- m-coil-streckgrenze
- m-coil-zugfestigkeit
- m-coil-dehnung
- m-coil-c
- m-coil-si
- m-coil-mn
- m-coil-p
- m-coil-s
- m-coil-cr
- m-coil-mo
- m-coil-ni
- m-coil-v
- m-coil-w
- m-coil-nb
- m-coil-ti
- m-coil-al
- m-coil-cu
- m-coil-temperatur
- m-werkstueck-temperatur

Abbildung 4: Bildschirmfotoausschnitt der entwickelten NAM-App. Die NAM Modelle können über das Web Interface mit den hier gezeigte Parameter- und Zielgrößen individuell in der Cloud trainiert und direkt interaktiv ausgewertet werden.

Für das Deployment einer Lösung beim Anwendungsfallpartner GTC wurde die NAM-App weiter abgewandelt, um durch den Fokus der Anzeige auf die finalen Vorhersagen und interpretierbaren Graphen des Modells in einer Web App im Shopfloor für den Werker an der Maschine zugänglich zu sein. Diese NAM-Visualizer-App (Details siehe Abschnitt zu TP Q3.5) wurde als Docker App gepackaged und auf den Servern der GTC deployed, welches eine Integration der Methoden in die Plattform des Anwendungsfallpartners erfolgreich demonstriert.

Anwendungspartnerübergreifende Arbeiten

Parallel zur Klärung von Anforderungen und der Modellbildung wurden während des Arbeiten zum Aufbau und Skalierung relevanter Infrastrukturen für das Training von ML-Modellen durchgeführt. Diese lieferte die Grundlagen für die bereits in den Erläuterungen zu TP Q3.2 – Q3.4 genutzten Darstellungen. Zielstellung war es hier vor allem, die Automatisierung der Entwicklungsumgebung zu erreichen sowie relevante Fragen zur Nutzung von Open-Source-lizenzierten Bibliotheken zu klären.

Für den Datenaustausch, die Überwachung und die Analyse des Trainings von Modellen und deren Speicherung wurde eine Infrastruktur basierend auf der Softwarelösung *Weights and Biases* (W&B) aufgesetzt. Diese ermöglicht es, sämtliche im Projektverlauf durch die Methodenentwicklung von Merantix Momentum gewonnenen Erkenntnisse strukturiert

aufzubereiten – auch live während des ML-Trainings – und Ansichten auf die aktuellen Ergebnisse für Diskussionen mit den Methoden- und Anwendungspartnern zu teilen. Die nachfolgende Abbildung 5 zeigt exemplarisch eine mögliche Darstellung von Ergebnissen.

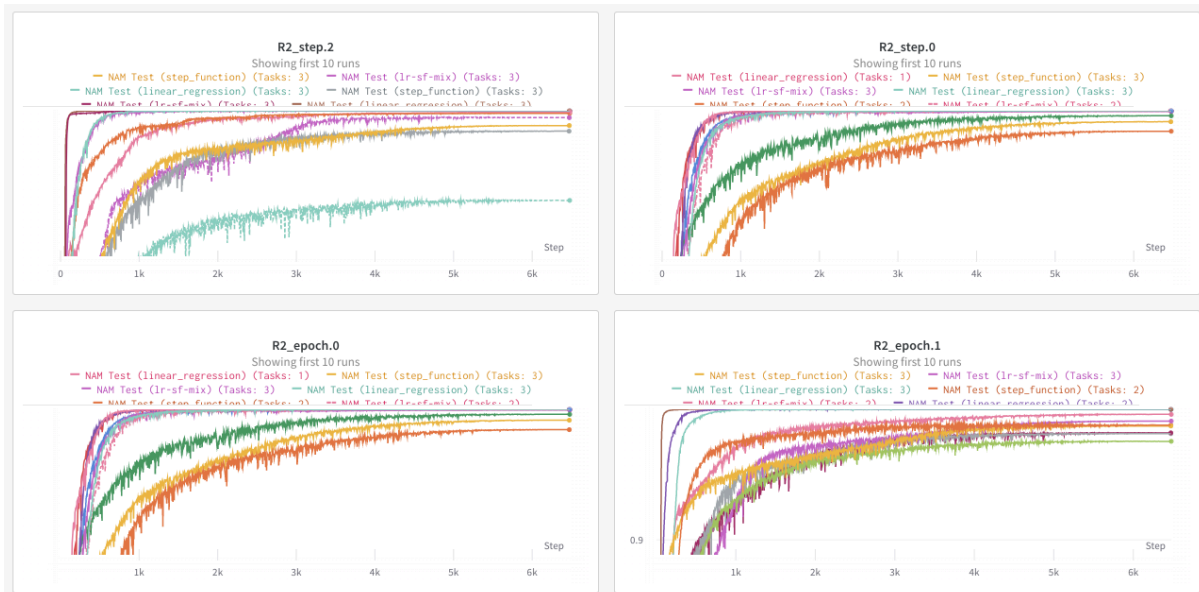


Abbildung 5: Exemplarische Live-Überwachung und Vergleich von Validierungsmetriken zwischen verschiedenen Modellen (in diesem konkreten Fall R2 score für ein Regressionsproblem) mit W&B.

Um einen hohen Datensicherheitsstandard zu gewährleisten, wurde die Lösung in die von Merantix Momentum eingesetzte Authentifizierungsinfrastruktur eingebunden und als nicht-öffentlicher Cloud-Service eingerichtet. Weiterhin wurde die Software mit *Terraform* integriert, welches von Merantix Momentum als *Infrastructure-as-Code*-Lösung eingesetzt wird, um einen reibungslosen Entwicklungsablauf zu gewährleisten.

Darüber hinaus wurde eine effiziente Infrastruktur zum Code-Management sowie des Lizenzmanagements für eingesetzte Software aufgebaut. Hierfür wurde ein monolithisches Repository zum schnellen Teilen von Code und zur verbesserten internen Zusammenarbeit umgesetzt. Auf Seiten von Merantix Momentum wird der Ansatz verfolgt, sämtliche notwendige Recheninfrastruktur ebenfalls als Teil des Codes zu verwalten (“Infrastructure as Code”). Hierzu wurden vordefinierte Terraform-Module (node pools) erstellt, sodass bei Bedarf Rechenressourcen dynamisch angefordert werden können (z.B. virtuelle Maschine mit GPU, virtuelle Maschine mit vielen CPUs und erhöhtem RAM). Weiterhin wurden passende *Kubernetes*-Manifeste erstellt, um diese Maschinen ansteuern zu können. Zur Sicherstellung der Codequalität wurden automatische Integrations-Tests umgesetzt, sodass Code automatisch auf die internen Standards (z.B. Dokumentation, Formatierung) hin überprüft und ggf. angepasst oder eine Fehlermeldung generiert wird. Außerdem werden automatisch Docker-Images erzeugt, die alle notwendigen Komponenten enthalten, um den Code in der Cloud auszuführen. Für die Optimierung der oben besprochenen Neural Additive Models (NAMs) wurden *Hydra-Core* Konfigurationen eingesetzt, welche das automatisierte Trainieren von Modellen mit unterschiedlichen Hyperparametern ermöglichen. Für die Auswahl und Optimierung der Hyperparameter wurde zunächst das *Optuna* Framework eingesetzt.

Q3.5: Implementierung

Merantix Momentum hat an einer Reihe von Abstimmungen mit TP Q2 zur Definition der Datenaustauschformate sowie zur Vorstellung der geplanten Datenarchitektur teilgenommen. Für das durch TPQ2 zur Verfügung gestellte, mit Beispieldaten gefüllte Datenmodell (Linkedfactory, Postman) wurde eine Anbindung geschaffen, welche durch geeignete Abfragen der Graphdatenbank (SPARQL) und die Aufbereitung der Ergebnisse diese in einer für ML-Methoden geeigneten Darstellung (Pandas DataFrames) zur Verfügung stellt. Eine Übersicht der entwickelten Anbindung ist in Abbildung 6 gezeigt.

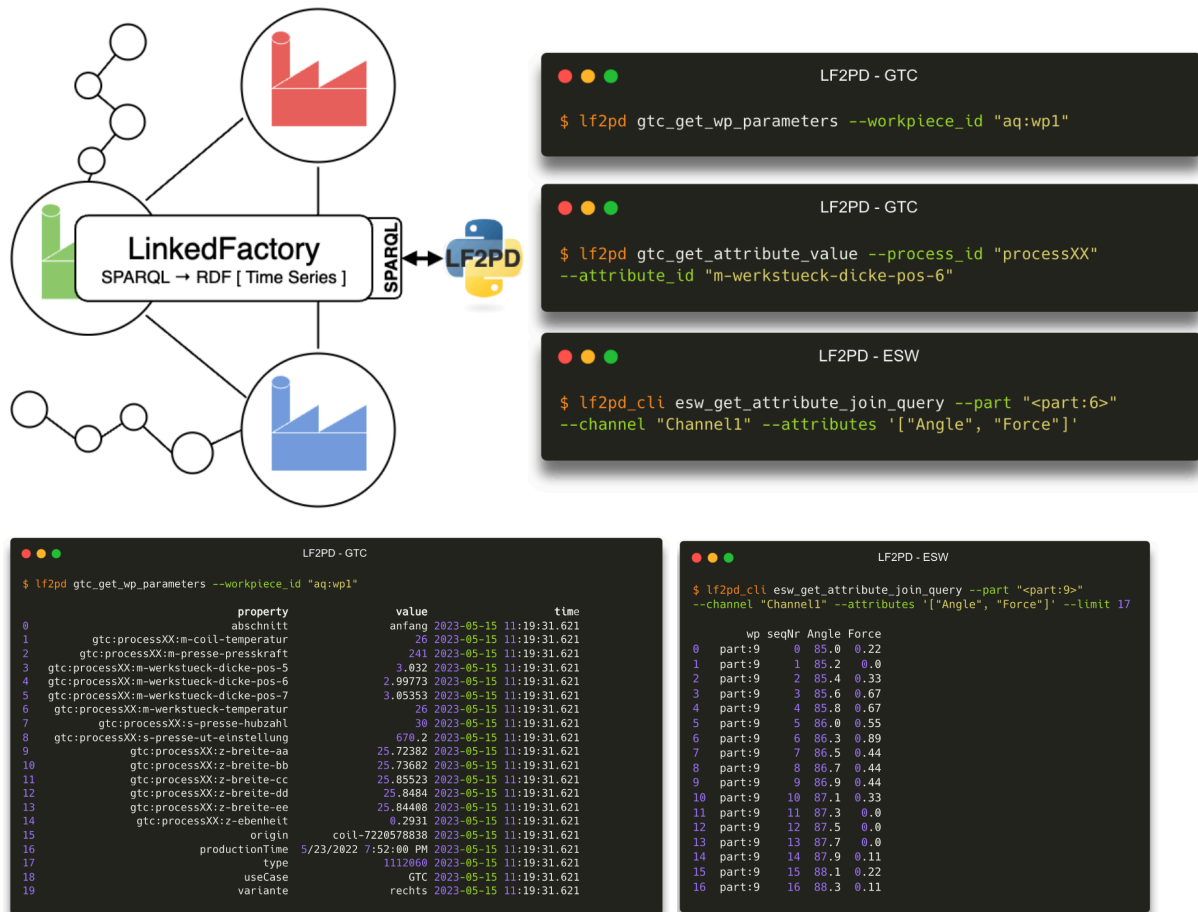


Abbildung 6: Schematische Übersicht der Anbindung "lf2pd" an das von TPQ2 entwickelte Datenmodell LinkedFactory (oben) am Beispiel des GTC Anwendungsfalls (unten, links) sowie der Beispieldaten im ESW Anwendungsfall (unten, rechts).

Zur Visualisierung der trainierten Neural Additive Models entwickelte Merantix Momentum eine spezielle Web-App (NAM-Visualizer App). Die App visualisiert die trainierten Modelle basierend auf den sog. Shape Functions und Feature Importances, wie sie im Falle des GTC Anwendungsfall für fiktive Daten in Abbildung 7 beispielhaft dargestellt sind. Die Shape Functions visualisieren darüber hinaus den aktuellen Zustand der Maschine und der Materialparameter. Diese Darstellung erlaubt es dem Werker, die Maschine zielgenau auf die für das Einhalten der Zielgeometrie notwendigen Parameter einzustellen. Die Shape Functions zeigen dabei den Beitrag einer jeden Eingangsgröße (entlang der x-Achse) zur Zielgröße (entlang der y-Achse) in Einheiten der Zielgröße an. Die NAM-Visualizer App zeigt somit die Wirkzusammenhänge der Empfehlung auf und ermöglicht es dem Werker, die Vorhersagen zu interpretieren und ergänzend zum Fachwissen einzusetzen. Darüber hinaus

visualisiert die App die der Prädiktion zugrundeliegende Datendichte und Unsicherheit des Modells. In Regionen geringer Dichte kann der Werker die Empfehlung der App also ggf. mit erhöhter Umsicht einsetzen als in Regionen hoher Datendichte und daraus resultierender geringer Modellunsicherheit.

Die entwickelte App wurde als Docker Image containerisiert und zu Testzwecken auf den Servern des GTC Anwendungspartners deployed.

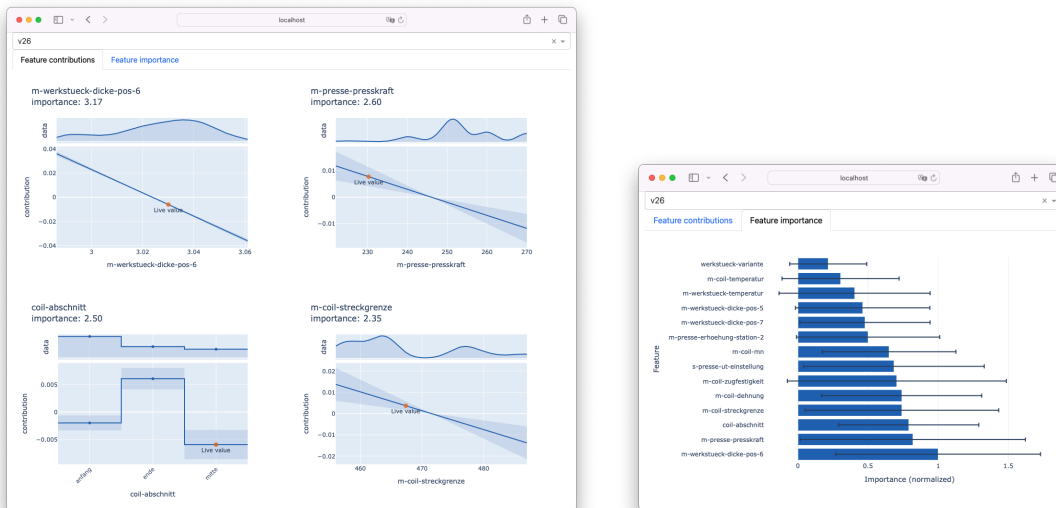


Abbildung 7: Screenshot der NAM-Visualizer App zur Darstellung der trainierten NAM Modelle. Die App visualisiert die erlernten *Shape Functions* zusammen mit der zugrundeliegenden Trainingsdatendichte (links), sowie die aggregierten *Feature Importances* (rechts). Die Website ist scrollbar und hier ist nur ein Ausschnitt von 4 der 14 erlernten Funktionen gezeigt.

Q3.6: Ergebnisaufbereitung, Erklärung und Sensitivitätsanalysen

Die wesentlichen Ergebnisse dieses Arbeitspakets sind bereits im Abschnitt zu TPQ3.3–3.5 dargestellt worden. Generell wurden alle erzielten Ergebnisse für die Anwendungsfallpartner in geeigneter Form aufbereitet, beispielsweise in Form von PowerPoint Folien oder PDF Reports, und mit den Anwendungspartner und TP Q3 Partnern geteilt und diskutiert.

Für alle Deep Learning-basierten Verfahren wurden Hyperparameteroptimierungen durchgeführt sowie Unsicherheitsabschätzungen basierend auf Modelensemblestatistiken durchgeführt. Durch die mittels der NAM-Visualizer App dargestellten *Shape Functions* (vgl. Abbildung 7) ergibt sich eine natürliche Sensitivitätsanalyse und Interpretierbarkeit der Ergebnisse: die Beiträge eines jeden Eingangsfeatures zur Zielgröße, sowie die Sensitivität der Zielgröße in Abhängigkeit des Eingangsfeatures sind direkt in den natürlichen Einheiten der Zielgröße visualisiert. Die Ableitung, also die lokale Steigung der Shape Function an einem bestimmten Arbeitspunkt, ist dabei ein Maß für die Sensitivität der Zielgröße in Abhängigkeit vom Eingang.

Q3.7: Generalisierung und Ableiten von Empfehlungen

Basierend auf den Erkenntnissen die aus den Feature-Contributions der trainierten Neural Additive Models gewonnen wurden, könnte die Datenbasis und Messtechnik im GTC

Anwendungsfall iterativ verbessert werden, wie im Abschnitt zu TP Q.3.2 dargelegt wurde. Die entwickelten Methoden wurden – neben den GTC-Daten – auf eine Reihe weiterer öffentlich verfügbarer Datensätze angewendet, um initiale, positive Aussagen zur Generalisierbarkeit zu erhalten und Vergleichbarkeit mit dem aktuellen Stand der Forschung herzustellen.

Der Fokus lag hierbei insbesondere auf Vorhersagen mittels tabellarisch strukturierter Daten, wie sie beispielsweise im GTC Anwendungsfall vorkommen. In einigen Anwendungsfällen in der Fertigungsindustrie treten allerdings vor allem sequenzielle Daten (oder kombinierte tabellarische und sequenzielle Daten) wie Zeitreihen oder andere Messreihen auf. So zum Beispiel beim Anwendungspartner ESW, hier werden in der Prozessreihe Kräfte in Abhängigkeit von Winkeln vermessen, oder im Fall Grammer GAM, wo neben tabellarischen Maschinen- und Materialparameter auch Kraftzeitreihen vermessen werden. Aufgrund der beschränkten Datenlage in diesen Use Cases konnten keine praktischen Weiterentwicklungen des untersuchten Neural Additive Model Ansatzes verfolgt werden. Auch ist die Verallgemeinerung von interpretierbaren Modellen wie NAMs auf sequenzielle Daten wie Zeitreihen noch ein offenes Thema in der Forschungscommunity.

Prinzipiell bieten sich jedoch verschiedene Möglichkeiten an, NAMs und andere Generalized Additive Models mit Zeitreihen und/oder Kombinationen aus Tabellen und Zeitreihen zu verwenden:

1. Mittels manuellem oder (semi-)automatischem Feature-Engineering werden tabellarische Features aus einer (oder mehreren) Zeitreihe extrahiert. Diese werden dann, ggf. zusammen mit weiteren tabellarischen Features des Problems, mittels NAMs zur Prädiktion verwendet. Als (semi-)automatisches Feature-Engineering können öffentlich zur Verfügung stehende Bibliotheken, wie beispielsweise *tsfel* oder andere benutzt werden, welche eine Vielzahl statistischer Features (Energie, Min, Max, Mittelwert, etc.), sowie zeitlicher Features (Autokorrelation, Nulldurchgangsrate, mittlere Abweichung, etc.) und spektraler Features (mittlere Frequenz, min./max. Frequenz, Bandbreite, Wavelet Entropie, etc) berechnet.

Der Vorteil dieses Ansatzes ist, dass die aus den Zeitreihen extrahierten Features inherent interpretierbar sind, sei es statistisch, zeitlich oder spektral. Die per NAM gelernten Featurebeiträge und/oder Shape Functions können also direkt zur Interpretation des Prädiktionsergebnisses herangezogen werden und, wie im rein tabellarischen Fall, zur Experimentiteration oder Expertenvalidierung benutzt werden. Der Nachteil besteht vor allem in dem entweder manuellen Extraktionsaufwand relevanter Features bzw. der großen Anzahl automatisch generierter Features. Beispielsweise extrahiert *tsfel* per default 67 skalare features pro Zeitreihe. Dies ist schon bei einer Zeitreihe eine vergleichsweise hohe Anzahl an Input-Features für Modelle wie NAMs, insbesondere da davon auszugehen ist, dass viele Features keine prädiktive Signifikanz für die Zielvariable aufweisen. Dieses Problem wird umso stärker, je mehr (zeitsynchrone) Zeitreihen betrachtet werden. Bekannte Techniken, dieses bekannte Problem tabellarischer Prädiktoren zu mildern sind beispielsweise *sparsity-based* Regularisierer (z.B. L1-Regularisierung), iteratives Feature Pruning oder moderne Ansätze wie Concurvity Regularisierung.

2. Alternativ können Feature Maps aus den Zeitreihen per ML Verfahren wie Convolutional Neural Nets oder Recurrent Neural Networks erlernt werden. D.h. jede Zeitreihe wird auf einen gelernten hochdimensionalen Vektor abgebildet. Dieses Zeitreihen-Embedding kann dann, zusammen mit weiteren Embeddings anderer Zeitreihen oder weiteren tabellarischen Features) als Input für ein NAM benutzt werden. Der Vorteil dieses Ansatzes liegt darin, dass kein manuelles Feature Engineering notwendig ist und dass pro Zeitreihe nur ein Feature Vektor extrahiert wird. Der Nachteil liegt darin, dass diese Feature Vektoren nicht inherent interpretierbar sind. D.h. den Einfluss der betrachteten Zeitreihe auf eine mittels NAM gewonnene Prädiktion kann zwar global errechnet werden (die sog. Feature Importance), der präzise, lokale Einfluss, wie es bei tabellarischen Features mit NAMs möglich ist, kann jedoch nicht bestimmt werden, da die Eingangsgröße (das Feature Embedding) nicht interpretierbar ist. Je nach Anwendungsfall kann dies dennoch ein möglicherweise sinnvollen Kompromiss gegenüber dem oben genannten Ansatz 1 sein.
3. Ggf. lässt sich Ansatz 2 so erweitern, dass die erlernten Feature Embeddings inherent interpretierbar sind. Ist dies der Fall, so ist auch das finale NAM interpretierbar. Es ist jedoch offen, wie diese Interpretierbarkeit erreicht werden kann. Dies ist Teil aktueller, sich noch im frühen Stadium befindlicher Forschung.

A2.1: Begleitende wirtschaftliche Betrachtung

Die im Projekt untersuchten und weiterentwickelten Neural Additive Models bieten großes Einsatzpotential in Kundenprojekten von Merantix, insbesondere im Bereich der industriellen Fertigung. Aus diesem Grund wurde bei der Implementierung der innerhalb dieses Projekts entwickelten Methoden stets auf hohe Qualitätsstandards und Wiederverwendbarkeit Wert gelegt. So ist in diesem Zuge eine Merantix-interne Python Bibliothek entstanden, welche die von Merantix in AdaProQ entwickelten Methoden implementiert und das Trainieren von NAMs und anderen interpretierbaren Modellen für tabellarische Daten in wenigen Zeilen Code ermöglicht. Auch die in TP Q3.3 entwickelte Implementierung einer hochskalierbaren Hyperparameteroptimierung mittel des Ray Frameworks ist in internes tooling integriert worden, sodass diese, auch Modell-unabhängig, in Zukunft in Kundenprojekten eingesetzt werden kann. Ray wurde bei Merantix nun schon erfolgreich in Kundenprojekten verwendet. Die Implementierungszeit (und damit verbundene Iterationsgeschwindigkeit insbesondere bei Prototypen oder Proofs of Concept) kann hiermit drastisch reduziert werden und erhöht die Effizienz bei der Arbeit von Merantix im Kundengeschäftsalltag. Die entwickelte NAM-Visualizer App ist ebenfalls so gestaltet und containerisiert worden, dass die funktionellen Komponenten in der bereits erwähnten internen Python Bibliothek implementiert sind und die Visualisierungskomponenten sich mit wenigen Änderungen über Hydra Config Dateien an neue Anwendungsfälle anpassen lässt. Somit eignet sich beispielsweise auch die Web-App für eine schnelle Prototypenentwicklung im Kundengeschäft.

2. Wichtigste Positionen des zahlenmäßigen Nachweises

Das Gros des Budgets entfiel auf Personalkosten, die etwa 99% der verausgabten Gesamtkosten ausmachen. Die restlichen Aufwände waren bedingt durch Reisekosten (<1%) sowie Aufwendungen für Cloud-Rechenleistung (<1%).

3. Notwendigkeit und Angemessenheit der geleisteten Arbeit

Die durchgeführten Forschungsarbeiten im Verbundprojekt AdaProQ sowie die dafür aufgewandten Ressourcen waren notwendig und angemessen, da sie der im Projektantrag formulierten Planung entsprechen und alle wesentlichen im Arbeitsplan vorgesehenen Arbeiten erfolgreich bearbeitet wurden.

Die durch Merantix Momentum erbrachten Arbeiten und erzielten Ergebnisse hätten ohne die bereitgestellte Förderung nicht durchgeführt werden können, da nur dadurch der umfassende Austausch mit den Projektpartnern im Konsortium ermöglicht wurde.

4. Voraussichtlicher Nutzen und Verwertbarkeit des Ergebnisses im Sinne des fortgeschriebenen Verwertungsplans

Im Projekt wurde im Kern eine Komponente entwickelt, die es mittels Neural Additive Models (NAMs) erlaubt, die Einflüsse von verschiedenen Parametern im Fertigungsprozess zu erkennen, darzustellen und zu interpretieren. Die Komponente wurde entsprechend den Projektzielen möglichst generisch ausgelegt und lässt sich so auf eine Vielzahl von ähnlichen Projekten anwenden. Die wesentlichen Möglichkeiten hierzu wurden in Kap. II.1 bereits in den Abschnitten Q3.7 und A2.1 dargestellt.

5. Während der Durchführung des Vorhabens bekannt gewordene Fortschritte auf dem Gebiet des Vorhabens bei anderen Stellen

Während des Projektzeitraums hat Merantix Momentum intensiv den wissenschaftlichen Fortschritt im Bereich des Maschinellen Lernens gemonitort und die identifizierten relevanten Arbeiten in die Konzeption der eigenen Forschungsansätze einfließen lassen. Wesentliche Quellen hierfür waren öffentliche Publikationsplattformen. Die gewonnenen Erkenntnisse bildeten die Grundlage für die geleisteten Arbeiten, welche in Kap. II ausführlich dargestellt wurden.

6. Erfolgte und geplante Veröffentlichungen des Ergebnisses

Eine Veröffentlichung der in A2.1 erwähnten Python Bibliothek als Open Source Framework wird angestrebt.