

Gemeinsamer Schlussbericht zum Verbundprojekt **AIMM – Artificial Intelligence for Material Models**

Autoren und Zuwendungspartner

Pauline Böhringer, Dr. Joachim Sprave, Dr.-Ing. Said Jamei, Dr. Norbert Dölle
Mercedes-Benz AG (Konsortialführer)

Dr.-Ing. David Koch, Christian Ilg, Hon.-Prof. Dr.-Ing. André Haufe
DYNAmore Gesellschaft für FEM Ingenieurdienstleistungen mbH

Thomas Haase, Thomas Soot
Fraunhofer-Institut für Kurzezeitdynamik, Ernst-Mach-Institut, EMI

Julian Kleih, Dr.-Ing. Gabriele Gorbach
ElringKlinger AG

Daniel Sommer, Dominik Platzer, Prof. Dr.-Ing. Peter Middendorf
Universität Stuttgart, Institut für Flugzeugbau (IFB)

Dr. Celalettin Karadogan, Univ.-Prof. Dr.-Ing. Dr. h. c. Mathias Liewald MBA
Universität Stuttgart, Institut für Umformtechnik (IFU)

Dr. Markus Stoll, Dr. Stefan Suwelack
Renumics GmbH

Laufzeit
vom 01.01.2021 bis 31.12.2023

Das diesem Bericht zugrundeliegende Vorhaben wurde mit Mitteln des Bundesministeriums für Wirtschaft und Klimaschutz unter dem Förderkennzeichen 19|20024 gefördert. Die Verantwortung für den Inhalt dieser Veröffentlichung liegt beim Autor.

Inhaltsverzeichnis

I	Kurze Darstellung	4
1	Aufgabenstellung	4
2	Voraussetzungen, unter denen das Vorhaben durchgeführt wurde	5
3	Planung und Ablauf des Vorhabens	11
4	Wissenschaftlicher und technischer Stand	13
5	Zusammenarbeit mit anderen Stellen	19
II	Eingehende Darstellung	20
1	Verwendung der Zuwendung und erzielte Ergebnisse	20
1.1	DYNAmore	20
1.2	ElringKlinger	35
1.3	Fraunhofer EMI	40
1.4	IFB	50
1.5	IFU	83
1.6	Mercedes-Benz	94
1.7	Renumics	111
2	Wichtigste Positionen des zahlenmäßigen Nachweises	112
2.1	DYNAmore	112
2.2	ElringKlinger	112
2.3	Fraunhofer EMI	112
2.4	IFB	112
2.5	IFU	112
2.6	Mercedes-Benz	113
2.7	Renumics	113
3	Notwendigkeit und Angemessenheit der geleisteten Arbeit	113
3.1	DYNAmore	114
3.2	ElringKlinger	114
3.3	Fraunhofer EMI	115
3.4	IFB	115
3.5	IFU	116

3.6	Mercedes-Benz	116
3.7	Renumics	117
4	Voraussichtlicher Nutzen und Verwertbarkeit der Ergebnisse im Sinne des fortgeschriebenen Verwertungsplans	117
4.1	DYNAmore	117
4.2	ElringKlinger	117
4.3	Fraunhofer EMI	118
4.4	IFB	119
4.5	IFU	119
4.6	Mercedes-Benz	120
4.7	Renumics	121
5	Während der Durchführung des Vorhabens dem ZE bekannt gewordenen Fortschritte auf dem Gebiet des Vorhabens bei anderen Stellen	121
6	Erfolgte und geplante Veröffentlichungen der Ergebnisse	122
III	Abbildungsverzeichnis	124
IV	Literaturverzeichnis	128

I Kurze Darstellung

1 Aufgabenstellung

Der Auslegungsprozess von automobilen, leichten Strukturbauteilen wird stark durch den digitalen Entwicklungsprozess vorangetrieben und beeinflusst. Hauptziel des Projektes AIMM ist es, die langwierige, oft erfahrungsgetriebene und fachgebietsspezifische Materialmodellierung durch eine alternative, automatisierte und datengetriebene Materialmodellierung zu ersetzen. Durch die Etablierung von Methoden des maschinellen Lernens (ML) in der simulationsgestützten Auslegung von Trag- und Crash-Strukturen in der modernen Fahrzeugentwicklung sollen aktuell aufwendige Modellierungsprozesse zukünftig vereinfacht werden. Dies führt zu einer Verkürzung der Entwicklungszeiten und erweitert die digitale Funktionsabsicherung und macht diese einem größeren Anwenderkreis zugänglich. Auf diese Weise können langfristig Rechenzeiten im Zusammenhang mit statischer und dynamischer digitaler Absicherung solcher Strukturen reduziert werden, da durch den Einsatz von ML-Modellen die iterative Lösung von Materialgleichungen vermieden werden kann. Damit wird es zukünftig möglich sein, alternative Struktur- und Crashkonzepte mit weniger Computerleistung und Charakterisierungsaufwand in kürzerer Zeit berechnen und bewerten zu können.

Gleichzeitig werden in AIMM neuartige Versuchskonzepte zur Ermittlung von Werkstoffdaten moderner Blechwerkstoffe und Kunststoffe entwickelt. Insbesondere werden Teilumfänge sowohl der Versuchsdurchführung als auch der Auswertung automatisiert, da nur durch eine hochgradige Automatisierung der Charakterisierungsversuche die notwendige Datenmenge zum Training von neuen Werkstoffmodellen basierend auf maschinellem Lernen generierbar ist.

Vor dem Hintergrund des Einsatzes neuer und komplexer Werkstoffe sollen die Grenzen der konventionellen Materialcharakterisierung und -modellierung überwunden werden, so dass eine deutlich effizientere, sogar präzisere Materialbeschreibung für neue Blechwerk- und Kunststoffe möglich wird. Letzteres kann durch das vollständige Ersetzen klassischer Modellannahmen auf Seiten der Werkstoffmodelle erreicht werden; diese sogenannten holistischen Werkstoffmodelle werden bei ausreichender Verfügbarkeit von Trainingsdaten in der Lage sein, das vollständige Werkstoffverhalten für die anvisierte Applikation abzubilden.

Die vorgestellten Aspekte sind neu und insbesondere in Kombination von automatisierter, umfassender Versuchsdurchführung und anschließendem Training mit holistischen ML-Modellen für die rechnergestützte Entwicklung (CAE) von disruptivem Charakter.

2 Voraussetzungen, unter denen das Vorhaben durchgeführt wurde

Das Verbundvorhaben AIMM wurde im Forschungsschwerpunkt „Innovative Fahrzeuge“ im Rahmen des Förderprogramms „Neue Fahrzeug- und Systemtechnologien“ des BMWK gefördert. Um das Ziel des Verbundvorhabens „die klassische Materialmodellierung durch eine alternative datengetriebene und damit digitale Materialmodellierung zu ergänzen oder zu ersetzen“ zu erreichen, bedurfte es einer Vielzahl von Kompetenzen, die in der erforderlichen Zusammensetzung bei keinem der Verbundpartner alleine vorhanden sind.

Die **DYNAmore GmbH** hat sich seit ihrer Gründung im Jahr 2001 als führender Anbieter für die numerische Lösung nichtlinearer Problemstellungen etabliert. Als weltweit agierendes Ingenieurbüro und Softwarehaus bietet die DYNAmore seinen Kunden ein breites Portfolio an Dienstleistungen auf diesem Gebiet an. Dies umfasst den Vertrieb und Support des Finite-Elemente-Simulationsprogramms LS-DYNA sowie der erforderlichen IT-Infrastruktur, FEM-Berechnungsdienstleistungen, allgemeine Beratung und unterstützende Funktionen bei strukturdynamischen Herausforderungen. Des Weiteren ist DYNAmore aktiv in der Durchführung von Schulungen und der Materialcharakterisierung am Material Competence Center involviert.

Es ist charakteristisch für DYNAmore, stets an vorderster Front bei der Entwicklung neuer Methoden und Techniken in der Simulationstechnologie zu stehen. Das Thema des maschinellen Lernens beschäftigt das Unternehmen bereits seit geraumer Zeit, so war DYNAmore bereits Partner im Forschungsprojekt AIAX [Ebe21]. In diesem Zusammenhang wurden Vorarbeiten geleistet, die als Grundlage für AIMM dienen.

Angesichts der Tatsache, dass nahezu alle unsere Kunden von den Fortschritten auf diesem Gebiet profitieren würden, ist das Thema maschinelles Lernen von erheblicher Relevanz für das Unternehmen. Dies unterstreicht die Bedeutung, die wir den erarbeiteten Themen über die Projektlaufzeit hinaus beimessen.

ElringKlinger AG

Die Kernkompetenzen der ElringKlinger AG als weltweit tätiger Entwicklungspartner und Erstausrüster für Zylinderkopf- und Spezialdichtungen, thermoplastische Gehäusemodule und Strukturbauteile sowie Abschirmteile für Motor, Getriebe und Abgasanlagen liegen in den Hauptbereichen Kunststoffspritzguss, Stanzen, Umformen und Fügen. Im Geschäftsbereich Leichtbau / Elastomertechnik kann ElringKlinger auf eine große Kompetenz im Bereich der Fertigung von Spritzgießwerkzeugen, der werkzeuggerechten Bauteilkonstruktion und -simulation sowie der Prozessentwicklung zurückgreifen. Das hohe Maß an Gestaltungsfreiheit bei der Konzeptionierung, dem Design, der Methodenplanung und der Produktion im eigenen Haus

ermöglicht die Herstellung technologisch hochentwickelter Produkte und garantiert somit die Marktfähigkeit der Bauteile. Für die Entwicklung und Produktion von Leichtbau-Bauteilen und von Hybridbauteilen aus unterschiedlichen Werkstoffen wie zum Beispiel aus Kunststoffen, Aluminium und Organoblechen besitzt die ElringKlinger AG ein großes Erfahrungspotenzial und eine hohe Methodenkompetenz.



Abbildung 1: Strukturbauteile als Metall-Kunststoff-Hybride in der Kombination von Innenhochdruckumformen (IHU) und Spritzgießen (© ElringKlinger)

Im vom BMWi geförderten und vom PTKA betreuten Verbundprojekt FuPro [Kup17] „Bauweisen- und Prozessentwicklung für funktionalisierte Mehrkomponentenstrukturen mit komplex geformten Hohlprofilen“ untersucht ElringKlinger eine mögliche Anwendung des IHU-Verfahrens für die Funktionalisierung von endlosfaserverstärkten thermoplastischen Hohlkörperprofilen mit thermoplastischem Kunststoff.

Weiterhin besitzt ElringKlinger vertiefte Erfahrung bei der Herstellung von Bauteilen aus endlosfaserverstärkten thermoplastischen Halbzeugen (Organobleche), die mit thermoplastischem Spritzguss funktionalisiert werden. Diese thermoplastischen Hybride zeichnen sich durch eine hohe Festigkeit aufgrund der integrierten Glas- oder Kohlenstofffasergewebe aus. Die Bauteilsteifigkeit wird durch eine gezielte Verrippung durch thermoplastischen Spritzguss erhöht, siehe Abbildung 1.



Abbildung 2: Thermoplastische Hybride in der Kombination von thermoplastischen Halbzeugen (Organobleche) mit thermoplastischem Spritzguss (© ElringKlinger)

Im abgeschlossenen Förderprojekt ReLei [ReLei] „Fertigungs- und Recyclingstrategien für die Elektromobilität zur stofflichen Verwertung von Leichtbaustrukturen in Faserkunststoffverbund-Hybridbauweise“ war ElringKlinger für die Werkzeugkonstruktion und Bauteilauslegung eines hybriden thermoplastischen Demonstratorbauteils zuständig. In diesem Projekt wurde die Herstellung von funktionalen Sandwichstrukturen mit hochporösen Schaumstrukturen und Decklagen aus Organoblechen untersucht, siehe Abbildung 2.



Abbildung 3: Thermoplast-Sandwichstrukturen aus recycelten C-Fasern (© ElringKlinger)

Die Erkenntnisse aus den aktuellen Entwicklungsprojekten und den bereits bei ElringKlinger getätigten Vorarbeiten zum Thema Leichtbau sind direkt in die Bearbeitung des Förderprojektes eingeflossen. Die von ElringKlinger bereits im Bereich Leichtbau durchgeführten Vorarbeiten und Entwicklungsprojekte ermöglichen die fachlich qualifizierte Bearbeitung der Aufgabenstellungen, die im Rahmen des Förderprojektes zu lösen sind. Durch die Kompetenz im Bereich der Werkzeugkonstruktion, Werkzeugfertigung und der Prozessoptimierung in Kombination mit

einer starken Vorentwicklung sowie der Produktentwicklung im Haus können komplexe Aufgabenstellungen gelöst und neue Entwicklungen erfolgreich bis hin zur Serienreife geführt werden.

Am **Fraunhofer EMI** existieren umfangreiche Prüfeinrichtungen mit modernstem Mess-equipment zur mechanischen Charakterisierung von Materialien und Einzelkomponenten bis hin zu Gesamtfahrzeugen. Ein Fokus des Instituts liegt dabei auf der Untersuchung dynamischer Vorgänge. Im Rahmen von AIMM ist hier im Besonderen die Prüfung von Werkstoffen und Bauteilen bei anwendungsnahen, hohen Dehnraten relevant, wie sie beispielsweise beim Fahrzeugcrash auftreten. In diesem Zusammenhang werden am EMI ebenfalls neue Prüfmethoden entwickelt. Ein Beispiel aus dem Bereich der Kunststoffprüfung ist ein IGF-Forschungsvorhaben, in dem das Verformungs- und Versagensverhalten von nicht-faserverstärkten Kunststoffen unter Schubbelastung untersucht wurde [FAT21]. Die dabei erarbeiteten Methoden können im Rahmen des AIMM-Projekts genutzt und weiterentwickelt werden.

Neben den experimentellen Arbeiten gehört ebenfalls die Formulierung neuer klassischer Materialmodelle für unterschiedliche Werkstoffe (Metalle, Kunststoffe, Gewebe) seit langer Zeit zu den Arbeitsgebieten des Instituts. Die am EMI vorhandene Expertise im Bereich der Kontinuumsmechanik ist relevant für ein Projekt wie AIMM, in dem die Entwicklung neuartiger ML-Modelle und damit verbundener experimenteller und numerischer Methoden ein zentraler Bestandteil ist.

Das **Institut für Flugzeugbau der Universität Stuttgart (IFB)** bringt seine über 20-jährige Erfahrung in Leichtbau- und Fertigungstechnologien in das Projekt AIMM ein. In den letzten Jahren konnte bereits ein Fokus auf die Verwendung von KI und Roboterautomatisierung in der Materialmodellierung gelegt werden. Mit einer umfassenden Kompetenz in der Simulation von Leichtbaustrukturen und einer Kombination aus experimentellen Untersuchungen und numerischer Modellierung, hat das Institut bereits in Projekten wie DigitPro [Dit19] und FlexiSpan [Fra19] seine Fähigkeiten in der effektiven Datenverarbeitung und Softwareentwicklung demonstriert. Die Erfahrungen in der Automatisierung, belegt durch die Beteiligung an Projekten wie LowFlip [Cor22a] und EffiComp [Cor22b], zeigen die Expertise des Instituts in der Implementierung von robotergestützten Fertigungsprozessen.

Darüber hinaus hat das Institut durch die Entwicklung eigener Prüfverfahren und Maschinen zur Werkstoffcharakterisierung, insbesondere bei Kunststoffen und deren Faserverstärkungen, beigetragen. Die Anwendung künstlicher neuronaler Netze zur Effizienzsteigerung und Kosten-

senkung in der Materialprüfung stellt einen weiteren Schwerpunkt der Forschung dar. Im Projekt DigiBody [Los23] wird die Anwendung von maschinellem Lernen für die Modellierung von Klebstoffen untersucht, was die fortschrittliche Nutzung von KI in der Materialwissenschaft unterstreicht. Die Verwendung digitaler Bildkorrelation und neuronaler Netze zur Erstellung von Materialkarten und zur Optimierung von Materialmodellen verdeutlicht das Bestreben des Instituts, Forschung und Anwendung zu verbinden.

Diese Aktivitäten und Vorarbeiten verdeutlichen die Relevanz und Angemessenheit der Forschungsausrichtung des Instituts im Projekt AIMM, das darauf abzielt, die Materialmodellierung und Fertigungsverfahren durch den Einsatz von KI und Roboterautomatisierung weiterzuentwickeln.

Aufgrund der hohen Kosten für die Herstellung von Großwerkzeugen für die Blechumformung und somit auch für die von großflächigen Karosseriebauteilen wird das Formänderungsvermögen moderner Blechwerkstoffe im Vorfeld einer Fahrzeugproduktion sorgfältig geprüft. Hierfür werden heute weltweit Finite-Elemente-Simulationen eingesetzt. Um eine möglichst genaue Simulation durchführen zu können, sind präzise Materialkennwerte des jeweiligen Blechwerkstoffes erforderlich, die dessen elasto-plastisches Materialverhalten definieren. Das **IFU (Institut für Umformtechnik, Universität Stuttgart)** stellt auf dem Gebiet der Materialcharakterisierung seit vielen Jahren einen wichtigen akademischen Partner für die Industrie dar und beschäftigt sich zudem mit der Entwicklung von Strategien zur Beschleunigung derartiger Charakterisierungsprozesse. In der Regel sind heute für jene Blechwerkstoffe, die bereits seit langem in Karosseriestrukturen verwendet werden, validierte Materialmodelle verfügbar. Für jede neue Fahrzeugproduktion ist daher allenfalls eine Feinabstimmung der Materialparameter erforderlich, um die Umformsimulationen von Karosserieanbauteilen möglichst zuverlässig durchführen zu können. In der Automobilindustrie werden aufgrund von Umwelt- und Sicherheitsanforderungen an die Fahrzeuge ständig neue Blechwerkstoffe entwickelt und in reduzierten Blechdicken eingesetzt. Die Modellierung des entsprechenden Materialverhaltens stellt dabei eine Herausforderung dar, da jeder neue Blechwerkstoff in Abhängigkeit von seiner Mikrostruktur individuell betrachtet werden muss. Es ist daher heute notwendig, zunächst geeignete numerische Materialmodelle aus einer Vielzahl auszuwählen und dessen Parameter möglichst präzise anzupassen. Die Validierung von Materialmodellen stellt somit eine wichtige Voraussetzung eines effizienten Einsatzes neuer Blechwerkstoffe für moderne Fahrzeugkarosserien dar. Es liegt daher auf der Hand, dass unter Berücksichtigung heutiger Crash-Anforderungen an Fahrzeugstrukturen zuverlässige Ergebnisse aus Crashberechnungen für die belastungs-

gerechte Konstruktion von Bauteilen sehr bedeutsam sind, zumal sich nachträgliche Konstruktionsänderungen der Fahrzeugkarosserie direkt auf die Entwicklungskosten des Fahrzeugs oder der Baureihe auswirken. Es wird somit seitens der Automobilhersteller mit Vehemenz angestrebt, neuartige Ansätze zu finden, die den Zeitverlust einer umfangreichen und präzisen Charakterisierung neuer Blechwerkstoffe zu kompensieren in der Lage sind. Die Verwendung von Machine-Learning-Materialmodellen als Ersatz für klassische Materialmodelle können heute als eine universelle Lösungsmethode für dieses Problem angesehen werden. Das mathematische Modell für die mathematische Beschreibung des Materialverhaltens der modellierten Blechwerkstoffe bleibt bei der Verwendung solcher ML-Modelle unberührt. Dies bringt einen weiteren wichtigen Vorteil in Bezug auf die Charakterisierung des Materialverhaltens mit sich, um die Werte der gesuchten Materialmodellparameter zu finden: durch die Verwendung eines universellen, etablierten Materialmodells können die Routinen zur konventionellen Charakterisierung standardisiert und beibehalten werden, ohne auf den jeweiligen Fall zugeschnitten werden zu müssen. Es stellt sich daher die interessante wissenschaftliche Frage, ob ein universelles Materialmodell in Form eines maschinellen Lernmodells gefunden werden kann und wie eine zukünftige Strategie zur Charakterisierung seiner Modellparameter auf der Grundlage standardisierter mechanischer Tests aussehen könnte.

Im Fahrzeugentwicklungsprozess der **Mercedes-Benz AG** steigt aufgrund hoher Variantenvielfalt und kürzerer Produktzyklen die Bedeutung der digitalen Absicherung weiter an. Die simulative Bewertung erfolgt zentral für alle Baureihen mit vereinheitlichten Berechnungsmethoden. So können die im Rahmen des Projekts AIMM entwickelten ML-basierten Modelle auf alle Entwicklungsprojekte in allen Baureihen angewendet werden und haben damit einen wesentlichen Beitrag bei der Verkürzung der Entwicklungszeiten im Rahmen eines beschleunigten Entwicklungsprozesses. Nahezu alle Produktentwickler der Mercedes-Benz AG würden durch eine Erhöhung der Iterationsgeschwindigkeit dank schnellerer Berechnung und hochautomatisierter Berechnungsbewertung profitieren. Dies hat direkten Einfluss auf die Entwicklungskosten. Hierdurch kann nicht nur die Relevanz der Aufgabenstellung projektbegleitend überprüft werden, sondern auch die Verwertbarkeit der Arbeiten über das Vorhabenende hinaus sichergestellt werden. Die Vorarbeiten zur Unterstützung des Produktentstehungsprozesses in diesen Bereichen dienen als Basis für die Arbeiten in AIMM.

Renumics

Die Renumics GmbH hat sich als Technologieführer in der Anwendung von Deep Learning Technologien im Engineering etabliert. Sie zeichnet sich durch umfangreiche Erfahrung und

Expertise in datengetriebener Automatisierung von ingenieurtechnischen Prozessen aus. Diese Kompetenzen kommen insbesondere in der Anwendung typischer Simulationsszenarien in der Automobilindustrie zum Tragen.

Die Forschungsbemühungen von Renumics beinhalten die Erkennung komplexer geometrischer Merkmale und die Optimierung von Trainingsworkflows mittels ML-Modellen. Ein besonderer Schwerpunkt liegt auf dem Pre- und Post-Processing ingenieurtechnischer Simulationen. Außerdem ist die Entwicklung von Tools für Training und Evaluation von ML-Modell eine Kernkompetenz.

Ein wichtiger Fokus von Renumics liegt im Bereich der MLOps, das die einfache Integration und systematische Entwicklung von ML-Modellen ermöglicht. Dieser Ansatz ermöglicht es, maschinelles Lernen effizient in bestehende IT-Infrastrukturen zu integrieren und dabei gleichzeitig die Qualität und Geschwindigkeit der Modellentwicklung und -implementierung zu gewährleisten.

Eine zusätzliche Stärke von Renumics liegt in der Erfahrung mit der Visualisierung komplexer Daten. Durch die Nutzung fortschrittlicher Visualisierungstechniken kann Renumics komplexe Datensätze und Modelle auf intuitive und verständliche Weise darstellen. Diese Fähigkeit verbessert nicht nur den Trainingsworkflow, sondern erleichtert auch die Evaluation von generierten ML-Modellen.

3 Planung und Ablauf des Vorhabens

Das Projekt wurde im Zeitraum vom 01.01.2021 bis zum 31.12.2023 gemäß dem beantragten Zeitplan durchgeführt. Allerdings waren Verlängerungen einzelner Arbeitspakete notwendig, um die geplanten Ziele zu erreichen. Diese Verzögerungen sind in Abbildung 4 orange markiert. Die Gründe für die Verlängerungen wurden während der Projektlaufzeit kontinuierlich mit dem Projektträger kommuniziert. Hauptsächlich waren das Ausscheiden der TU Berlin aus dem Projektkonsortium sowie die Übernahme ihrer Aufgaben durch das IFB und eine Unterbeauftragung von Renumics dafür verantwortlich.

[illegible]

4 Wissenschaftlicher und technischer Stand

Digitale Auslegungsmethoden stellen heutzutage die zentralen Werkzeuge in der Produktentwicklung dar. Hierzu existieren bereits realitätsnahe Simulationsmodelle zur Prozesssimulation (z.B. Spritzgusssimulation) und Struktursimulation (z.B. NVH- und Crashsimulation), welche physikalische Phänomene präzise abbilden, und damit virtuelle Versuche ermöglichen. Mittels Topologieoptimierung ist es heute möglich, materialeffiziente Leichtbaulösungen in einem hochautomatisierten Prozess zu finden. Neueste Algorithmen in kommerziellen Simulationsprogrammen sind zusätzlich in der Lage, auch verschiedene Materialien optimal einzusetzen. Die Grundlage der Simulationen bilden Materialmodelle, welche die spezifischen Materialeigenschaften wie Plastizität, Anisotropie und Schädigung erfassen. Die Individualität von Leichtbaumaterialien wie faserverstärkte Kunststoffe, Aluminiumlegierungen oder hochfeste Stähle führen dazu, dass ständig neue Modelle entwickelt und in kommerzielle Simulationsprogramme implementiert werden müssen.

Aktuelle Projekte und Ansätze

Das Online-Tool „NeuroCAD“, entwickelt vom Fraunhofer-Institut für Produktionstechnik und Automatisierung, ist in der Lage, durch den Einsatz künstlicher Intelligenz Bauteile anhand verschiedener Eigenschaften zu bewerten. Beispielsweise können Bauteile aus Schüttgut hinsichtlich ihrer Vereinzelbarkeit analysiert und kategorisiert werden. Das Tool ist auf die Analyse von bestehenden Teilen ausgelegt und bietet nicht die Möglichkeit, aus diesen Daten konkrete Optimierungsvorschläge zu liefern. Das vom BMBF geförderte Projekt AIAx bewegt sich ebenfalls wie AIMM im KI-Umfeld. Vorrangig sollen dort Pre- und Postprocessing von CAE-Simulationen unterstützt werden. Im Post-Processing wird die KI auf die Qualitätsbewertung von CAE-Modellen bzw. deren FE-Elementen ausgelegt und unterstützt damit die Robustheit von CAE-Simulationen. Im Post-Processing sollen Simulationsergebnisse durch die KI automatisch bewertet werden, um den Konstrukteuren die Interpretation dieser Ergebnisse zu erleichtern. Der eigentliche Konstruktionsprozess wird nur passiv durch die Interpretation der Simulationsergebnisse unterstützt, es erfolgt kein aktiver Eingriff in den Produktentstehungsprozess. Diesem Konzept folgen auch weitere bereits erfolgreich abgeschlossene Projekte der Konsortialpartner. Dazu gehört beispielsweise die automatisierte Bewertung von FE-Netzen, die Klassifikation von Schwingformen für die NVH-Analyse oder die Erkennung von Anomalien in der Crashsimulation. Im Projekt DigiBody [Los23] wurden Grundlagen zur Anwendung von KI-Materialmodellierung für ausgehärtete Klebstoffe vorrangig von auch hier beteiligten Projektpartnern unter-

sucht. Dabei wurden verschiedene, rein simulative Wege zur KI-Materialbeschreibung aufgezeigt. Die Ergebnisse dieser Grund- und Voruntersuchungen sind in AIMM eingeflossen und für Kunststoffe und Metalle erweitert worden.

Ziel der online Plattform MaterialDigital [PMD] und der begleitenden Projekte ist die Entwicklung einer nachhaltigen Plattform, die die Interessenten aus dem industriellen, wie aus dem akademischen Bereich nachhaltig bei der Umsetzung von Digitalisierungsaufgaben für Materialien zusammenführt und unterstützt. Parallel werden Werkzeuge entwickelt, mit denen die Digitalisierung der Materialien und deren Charakterisierung auch praktisch umgesetzt werden kann und die als Mehrwert die Voraussetzung für ein nachhaltiges Geschäftsmodell die wirtschaftliche Anschlussfähigkeit der Plattform MaterialDigital untermauern. Die Konzepte und Ziele der PMD sollen auch in AIMM berücksichtigt werden, ein Austausch kann über Fachtagungen erfolgen.

KI in der rechnergestützten Entwicklung, Simulation und Materialmodellierung

In der jüngsten Vergangenheit kam es zu einem enormen Fortschritt auf Seiten der Werkstofftechnik. Modernste Aluminiumlegierungen und höchstfeste Stähle weisen aufgrund von komplexen Wärmebehandlungszyklen spezifische Materialeigenschaften auf, die zuvor unerreichbar für metallische Werkstoffe schienen. Zugleich wurden Kunststoffe durch den Einsatz von Partikel- und Faserverstärkungen sowie mittels modernster Prozesstechnik konkurrenzfähig für den Serieneinsatz in tragenden Fahrzeugstrukturen. Die Entwicklung neuer Werkstoffe war stets begleitet durch den Fortschritt im Bereich der numerischen Materialmodellierung. Auf Seiten der metallischen Werkstoffe wurden in diesem Zusammenhang zahlreiche anisotrope Fließkriterien (vgl. [Hil48] oder [Bar03]) entwickelt, sowie die Beschreibung des Verfestigungsverhaltens schrittweise erweitert, um Phänomene wie die kinematische Verfestigung [Cha89] oder Stagnationseffekte im Bereich der Kaltumformung zu beschreiben [Yos02]. Der kostspielige und hochgradig komplexe Entwicklungsprozess physikalisch motivierter Modelle, wie das HAH-Modell [Bar14], hat neue Bestrebungen innerhalb der Forschungsgemeinschaft ins Leben gerufen, um Methoden des maschinellen Lernens in die Materialmodellierung einzubinden. Unter diesem Gesichtspunkt wurden zahlreiche Arbeiten sowohl im Bereich der hybriden als auch der holistischen Materialmodelle durchgeführt.

Jenab et al. [Jen16] beschreiben die Fließkurve eines Aluminiums 5182-O in Abhängigkeit der Dehnung, Dehnrage und Belastungsrichtung mithilfe eines shallow neural networks und erzielen damit eine höhere Genauigkeit im Vergleich zu etablierten Modellen. Li et al. [LiX19] ersetzen gezielt einzelne Ausschnitte des Verfestigungsgesetzes durch Elemente des maschinellen Ler-

nens, um die Wechselwirkung zwischen Dehnrates und Temperatur in Bezug auf das Verfestigungsverhalten von Dualphasenstählen akkurat abzubilden. Darauf aufbauend erweitern Pandya et al. [Pan20] die KI unterstützte Modellierung der elastoplastischen Materialantwort, um die Beschreibung der Versagensinitiierung für eine Aluminium-7075-Legierung für die Anwendung im Hot-Stamping-Prozess. Dabei gelingt es, die negative Dehnratenabhängigkeit (Portevin-Le-Chatelier-Effekt) sowie die nicht-lineare Einflussnahme der Temperatur auf die Duktilität des Werkstoffs erfolgreich vorherzusagen, was mithilfe konventioneller Materialmodellierung nicht abzubilden wäre. Auf Seiten der Schädigungsmodellierung für metallische Werkstoffe gibt es ebenfalls erste Vorstöße. Zur Vorhersage der lokalen Einschnürung ersetzen Greve et al. [Gre19] das Marciniak–Kuczynski Modell durch ein Feedforward Neural Network, was sich insbesondere durch eine deutlich gesenkte Berechnungsdauer auszeichnet. Abbassi et al. [Abb13] setzen auf ein neuronales Netz zur Identifikation der Schädigungsparameter des Gurson-Tvergaard-Needleman Modells und gelangen hierdurch zu einer schnelleren Materialcharakterisierung verglichen mit dem traditionellen Vorgehen mittels inverser Identifikation.

Ähnliche Bestrebungen gibt es auch für weitere Materialklassen. Furukawa und Yagawa [Fur98] sahen schon früh das Potential zur Beschreibung der Konstitutivgleichungen für viskoplastisches Materialverhalten mithilfe von Methoden des maschinellen Lernens. So nutzen zum Beispiel Jordan et al. [Jor19] die Vorhersagekraft neuronaler Netze zur Beschreibung der temperaturabhängigen, viskoplastischen Materialantwort von Polypropylen. Weitere Beispiele lassen sich im Bereich von Klebstoffen bzw. allgemein von Polymeren finden [Zgo12]. Sowohl Zhang und Friedrich [Zha03] als auch El Kadi [ElK06] liefern eine Übersicht über die Anwendungen des maschinellen Lernens für polymere Verbundwerkstoffen. Feedforward Neural Networks wurden in der Vergangenheit unter anderem dazu genutzt, um die Versagensdehnung, den Verschleiß sowie die Ermüdungslebensdauer abzuschätzen. Einen Versuch, die Konstitutivgesetze zu ersetzen, unternahmen bisher unter anderem Bessa et al. [Bes17], zur Abbildung des Deformationsverhaltens einer zufälligen, zweidimensionalen Realisierung eines Verbundwerkstoffs aus hyperelastischen Materialien, sowie Man und Furukawa [Man11] mit der konkreten Anwendung des maschinellen Lernens zur Beschreibung des anisotropen Verhaltens von kohlenstofffaserverstärkten Kunststoffen. Der Herausforderung der zyklischen Beanspruchungen stellten sich beispielsweise Yun et al. [Yun12] für viskoplastische Werkstoffe sowie Lefk and Schrefler [Lef03] anhand von elastoplastischen Materialien.

Diese ersten Versuche, KI-Modelle in dem Feld der Materialmodellierung zu etablieren, beruhen meist auf der Verwendung einfachster Techniken und Methoden aus dem Bereich des maschinellen Lernens. Aufgrund des Bestrebens nach einem allgemeingültigen Modell, das einen

gegebenen Werkstoff für alle möglichen Belastungspfade hinreichend genau beschreibt, steigen die Anforderung an die KI-gestützten Modelle. Vor dem Hintergrund von arbiträren nichtlinearen Deformationen ist es wichtig, dass zu jedem Zeitpunkt der inkrementellen Berechnung der Materialantwort nicht nur aktuelle Informationen über die gewünschten Größen vorliegen, sondern auch die Belastungsvorgeschichte bekannt ist. Dies ist bei gewöhnlichen Feedforward Neural Networks nicht gegeben und forciert so den Fokus auf die Anwendung von sogenannten Recurrent Neural Networks (RNN). Dies ist der Oberbegriff einer Modellfamilie, die es aufgrund ihrer internen Architektur ermöglichen, Geschichtsvariablen, ähnlich wie in der klassischen Materialmodellierung, abzuspeichern und in jedem inkrementellen Schritt abzurufen und zu verändern. In der jungen Vergangenheit fanden diese bereits in mehreren Bereichen Anwendung. So modellieren Mozaffar et al. [Moz19] metallische und polymere Verbundwerkstoffen unter nichtlinearen Belastungspfaden mithilfe von RNN. Zopf und Kaliske [Zop17] stützen Ihre Beschreibung von viskoplastischem Naturkautschuk auf RNNs. Des Weiteren demonstrieren Gorji et al. [Gor20] das Potential von RNN zur Beschreibung des elastoplastischen Materialverhaltens für nichtlineare multiaxiale Belastungspfade.

Bonatti und Mohr [Bon22] entwickelten ein spezifisches rekurrentes neuronales Netz zur Beschreibung des Materialverhaltens, welches sich in der Anzahl der Zustandsvariablen und der Berechnung dieser im Laufe des Trainings von den konventionellen rekurrenten Modellen unterscheidet.

Gleichzeitig entsteht zunehmend das Bestreben die Bausteine der Neuronalen Netze basierend auf physikalischen Grundprinzipien zu designen, um eine grundlegende Konsistenz und einen physikalischen Bezug zu gewährleisten. Liu et al. [Liu19] gestalten ihre Netzwerkarchitektur aus Elementen basierend auf analytischen Homogenisierungsansätzen. Mithilfe einer Generalisierung in 3D [Liu19a] demonstrieren sie die Vorhersagekraft der Netzwerke in Bezug auf den Spannungs-Dehnungs-Verlauf anhand von hyperelastischen Verbundwerkstoffen, polykristallinen Materialien sowie kohlenstofffaserverstärkten Kunststoffen. Gajek et al. [Gaj20] bewiesen in einer darauf aufbauenden Arbeit, dass ein solches Netzwerk thermodynamisch konsistent ist, solange alle einzelnen Phasen dies sind.

Trotz der Tatsache, dass bereits in vielen Bereichen der Materialmodellierung erste vielversprechende Ergebnisse in Bezug auf die Verwendung von Techniken des maschinellen Lernens vorliegen, stellt die Erstellung eines allgemeingültigen Materialmodells für beliebige Lastpfade mit ausreichender Robustheit wie es in Hinblick auf eine erfolgreiche Anwendung der ML-Materialmodelle in FE-Simulationen notwendig ist nach wie vor eine große Herausforderung dar.

Automatisierung von Versuchstechnik

Mit der Entwicklung der datenbasierten Materialmodellierung ist die erforderliche Menge an experimentellen Daten deutlich gestiegen. In diesem Zusammenhang ist die manuelle Durchführung von Experimenten nicht mehr praktikabel, um die notwendige große Menge an experimentellen Daten je Werkstoff zu erzeugen. Zur erfolgreichen Automatisierung der experimentellen Untersuchungen ist es daher ratsam, eine Fokussierung auf einzelne Werkstoffeigenschaften voranzustellen. Im Projekt AIMM sollte dies das Deformationsverhalten unter statischer und dynamischer Belastung sein. Die Prozesskette für eine entsprechende Charakterisierung eines Werkstoffs umfasst daher in der Regel Versuchsplanung und Probengestaltung, Probenherstellung und -präparation, Logistik, Prüfung, Inline-Messung von integralen oder verteilten (lokalen) zeit- bzw. deformationsabhängigen Größen meist an entkoppelten Systemen. In diesem Prozessablauf kommen die Datenaufbereitung und -fusion sowie letztlich auch Simulationen der Experimente zur inversen Bestimmung von Materialparametern auf der Grundlage von Vergleichen zwischen Simulationen und Messwerten hinzu. Die automatisierte Ermittlung der Werkstoffantwort mit dem Ziel des Trainings von datenbasierten Modellen auf Basis reiner Messdaten erfordert eine Automatisierung dieser gesamten Prüfprozesskette. Dies erfordert das Zusammenwirken der einzelnen Hardware- und Softwarekomponenten entlang der Prüfkette, die notwendige Software-Interoperabilität sowie Probenlogistik und Probenrückverfolgung für die gesamte Prozesskette.

Mit Heberling [Heb93] findet sich eine erste, nunmehr zum Teil überholte, Publikation von Experten der Prüfmaschinenhersteller und F&E-Einrichtungen. Es werden die Vorteile, Probleme und Ansätze im Zusammenhang mit der Automatisierung mechanischer Prüfsysteme aufgezeigt. Die verschiedenen Stufen der Automatisierung werden in Daten aus der *Vergangenheit, Gegenwart und Zukunft* kategorisiert. Der Schwerpunkt liegt auf den Bausteinen der verwendeten Automatisierung, d.h. ob und wie entschieden werden kann, welcher Automatisierungsgrad für eine Anwendung angemessen wäre.

Michopoulos et al. [Mic11] stellten die Erfassung massenhafter, experimenteller Daten von geprüften Verbundwerkstoffproben durch automatisierte, mechatronische Materialprüfsysteme vor, die in der Lage sind, multiaxiale Belastungen aufzubringen. Die konstitutive Charakterisierung von Materialien wird durch die Minimierung des Unterschieds zwischen experimentell gemessenen und analytisch berechneten Systemantworten erreicht, wie sie durch Oberflächendehnungs- und Dehnungsenergiedichtefelder beschrieben werden.

Mit der Zunahme der Anzahl der erforderlichen Tests in den letzten Jahren stehen nun in gewissem Umfang kommerzielle Testsysteme für Anforderungen an Test- und Systembetrieb zur

Verfügung, [Heg01] und [Zwi01]. Bei diesen Automatisierungssystemen werden die zu prüfenden Proben manuell z.B. in Magazine einsortiert. Die Automatisierung erfolgt in der Regel ab diesem Zeitpunkt, bis hin zur Sortierung der Probenreste für eine eventuelle Prüfung. Das Herzstück dieser Anlagen besteht in der Regel aus einem Handling-System auf Industrieroboterbasis. Ziel der Automatisierung ist jedoch bis dato, die Qualitätssicherung z.B. bei der Herstellung von Polymergranulaten sicherzustellen. Eine lokale Auswertung der typischerweise geprüften Zugstäbe, z.B. mittels DIC, findet nicht statt. Ziel ist im Gegenteil die Automatisierung einer Reihe von Probenversuchen selbst. Die Integration und Synchronisierung von optischen Messsystemen zur Erfassung von Vollfeld-Verformungsdaten ist noch nicht vollständig in solche Automatisierungssysteme eingebettet. Darüber hinaus ist die automatisierte Kommunikation mit der Simulationsumgebung, die die Aufgabe einer automatischen Parameteroptimierung übernimmt, ein unverzichtbarer Bestandteil von datengetriebenen Materialmodellen.

Automatisierung in der Modellerstellung

Ziel von AIMM war das Training von ML-basierten Werkstoffmodellen auf Basis von Versuchsdaten. Dazu müssen in einem ersten Schritt Messdaten automatisiert aufgenommen, ausgewertet und bereitgestellt werden. Im nächsten Schritt erfolgten dann ein automatisiertes Training und die Validierung des Modells.

Die Automatisierung der experimentellen Umfänge sowie die Auswertung und Bereitstellung der entsprechenden Messdaten sind neue Software-Komponenten zu schreiben, die eine Ansteuerung der Handling- und Prüfmaschinen, die Auswertung der Messzeuge und die Bereitstellung der gesammelten Daten in einem zu definierenden Format erlaubt. Nach Kenntnis der Antragsteller war hierbei kein Industriestandard definiert. Zwar kann steuerungsseitig auf aktuelle Industriestandards aufgebaut werden, das Speichern, Bearbeiten und Zugänglichmachen der Messdaten in spezifischen Formaten war jedoch in Teilen Neuland. Aus aktueller Sicht bestünde eine Option darin, auf HDF5 als Datenformat auszuweichen und für das Training der neuronalen Netze ein entsprechendes Interface (Python, C++ etc.) zu entwickeln, das eine reibungslose Anbindung an das NN erlaubt. Vorarbeiten in dieser Richtung, insbesondere solche, die das Handling von großen Datenmengen aus DIC zum Gegenstand haben, waren den Autoren nicht bekannt. Jedoch bestand innerhalb des Konsortiums aus den Vorgängerprojekten z.B. VMAP bzw. DigiBody und DigitPro Erfahrungen im Umgang mit HDF5-Containern. Die Weiterverwendung der entsprechenden Schreibe- und Lese-Routinen schien sinnvoll, das Datenformat wird innerhalb und außerhalb der VMAP-Community stark propagiert, so dass davon auszugehen ist, dass mittelfristig gute Voraussetzungen für einen Industriestandard zur Daten-

ablage von Werkstoffdaten gegeben sein wird. An dieser Stelle muss darauf hingewiesen werden, dass insbesondere das öffentlich geförderte Projekt VMAP die Interoperabilität von Werkstoffdaten für CAE zum Projektziel hat (bzw. hatte). Der Projektpartner DYNAmore konnte auf die entsprechenden Arbeitsergebnisse zurückgreifen und in AIMM einbringen.

Der Lebenszyklus von ML-Softwareprodukten unterscheidet sich erheblich von klassischer Software [Ash19]. Wesentliche Herausforderungen dabei ist das Datenmanagement, die Modellerstellung, die Verifikation und die Überwachung der Modelle im Produktiveinsatz [Lwa19]. Es gibt in der Literatur bereits einige Ansätze und Metriken, um die Qualität von Rohdaten zu messen und zu verbessern, [Sch18] und [Bar19]. Es war allerdings noch nicht klar, welche Strategien im Kontext der Erstellung von Materialmodellen hier nötig und sinnvoll sind. Mögliche neuartige Ansätze wurden auf die Erkennung von Ausreißern, den Umgang mit Unsicherheiten und die Abschätzung der nötigen Datenmenge und -auflösung abgezielt. Zur Verwaltung und Versionierung von Trainingsdaten und trainierten Algorithmen gibt es verschiedene quelloffene Softwarepakete (z.B. mlflow, Pachyderm, Polyaxon, KubeFlow), auf denen die Projektpartner aufbauen konnten. Es mussten dabei neue Lösungen gefunden werden, die den Besonderheiten in der Materialmodellierung Rechnung tragen. Dies gilt auch für Verfahren, die eine Anpassung vorgefertigter Modelle durch den Nutzer erleichtern.

5 Zusammenarbeit mit anderen Stellen

Im Rahmen des Forschungsvorhabens wurde die Zusammenarbeit mit den Verbundpartnern in Form regelmäßiger Projektbesprechungen (persönlich oder telefonisch) gestaltet. Weitergehend wird bei Mercedes-Benz AG eine Promotion in Kooperation mit der Fakultät für Informatik der Technischen Universität Dortmund durchgeführt.

II Eingehende Darstellung

1 Verwendung der Zuwendung und erzielte Ergebnisse

1.1 DYNAmore

AP1: Erzeugung klassischer Materialkarten

AP1.2: Klassische Charakterisierung und Modellierung eines Metalls

Als Ausgangspunkt und Referenz wurde der Stahlwerkstoff DP800HD auf konventionelle Weise charakterisiert, entsprechend dem aktuellen Stand der Technik. Hierbei wurden mittels inverser Parameteridentifikation die Parameter und mechanischen Zusammenhänge in einem Materialmodell ermittelt.

Zunächst wurden die hierfür erforderlichen Charakterisierungsversuche durchgeführt, wobei die Proben aus dem Blech mittels Wasserstrahlschneiden entnommen wurden. Die Versuche wurden unter Einsatz von Digital Image Correlation (DIC) durchgeführt, um möglichst umfassende Informationen zum Deformationszustand zu erhalten. Neben klassischen quasi-statischen und dynamischen (siehe EMI) Zugversuchen wurden weitere Versuche zur Charakterisierung des Schädigungs- und Versagensverhaltens durchgeführt.

Als Materialmodell wurde ein isotropes, elastoplastisches von Mises-Modell verwendet, welches in LS-DYNA mit dem Keyword *MAT_PIECEWISE_LINEAR_PLASTICITY oder auch *MAT_024 ausgewählt werden kann. Zur Berücksichtigung des Schädigungs- und Versagensverhaltens kam GISSMO (*MAT_ADD_DAMAGE_GISSMO) zum Einsatz.

AP2: Erzeugung simulativer Trainingsdaten

AP2.1: Schnittstellen

Gemeinsam mit den Projektpartnern wurden die zu verarbeitenden Daten und Prozessschritte analysiert, um die daraus resultierenden Anforderungen an Schnittstellen und Datenformate zu ermitteln. Diese Formate wurden im weiteren Projektverlauf bei der Entwicklung von Tools und Skripten berücksichtigt oder es wurden bestehende Skripte entsprechend angepasst und weiterentwickelt. Dies umfasst unter anderem Skripte zur Erzeugung von Input-Dateien für LS-DYNA sowie zur Extraktion von Simulationsdaten aus den Ergebnisdateien. Des Weiteren wurden die Definitionen bei Skripten zur Erzeugung von Versuchsdaten und zur Analyse der Ergebnisse berücksichtigt.

AP2.2/2.3: Erzeugung simulativer Trainingsdaten für einen Kunststoff / ein Metall

Es wurde ein Skript entwickelt, welches unter Berücksichtigung definierter Kriterien komplexe Dehnpfade erzeugt. Diese Dehnpfade werden anschließend in Randbedingungen für Einzelelementsimulationen übersetzt und daraus entsprechende Input-Dateien für LS-DYNA erstellt.

Das Hauptziel war die Erzeugung von Trainingsdaten mittels FE-Simulationen, wobei ein breites Spektrum an Daten erzeugt werden sollte, ohne unerwünschte Abhängigkeiten einzuführen. In der ersten Version dieses Skripts erfolgte die Generierung der Dehnpfade inkrementell. Hierbei wurde die Dehnung zunächst in volumetrische und deviatorische Anteile unterteilt. Dies ermöglicht eine vergleichsweise einfache Berücksichtigung von Einschränkungen in den volumetrischen Deformationen, was für viele ingenieurtechnisch relevante Werkstoffe physikalisch sinnvoll ist. Besonderes Augenmerk wurde daraufgelegt, dass eine Vielzahl von Parametern bei der Generierung der Dehnpfade variiert werden kann, um unerwünschte Abhängigkeiten oder "blinde Flecken" in den Trainingsdaten zu vermeiden. Zusätzlich wurden zahlreiche Variablen zufällig variiert, um die Varianz weiter zu erhöhen. Alle Dehnpfade beginnen in einem unverformten Zustand und entwickeln sich entsprechend der gewählten Parameter. Abbildung 5 und Abbildung 6 zeigen Beispiele für Dehnpfade im Hauptspannungsraum bei Variation verschiedener Parameter.




Abbildung 5: Variation der maximalen Winkel zwischen verschiedenen Dehnpfadsegmenten




Abbildung 6: Variation des "Rauschens" innerhalb der Segmente des Dehnpfads

Für den ML-Ansatz wurden drei Varianten untersucht: das LASSO-Regressionsmodell, das Feedforward Neural Network (FFNN) und ein spärliches, datengesteuertes Modell. Bei letzterem wurde ein hybrides Von-Mises-Plastizitätsmodell formuliert, in dem der plastische Fluss durch eine neuartige SIPS-Methode (Sparse Identification of Plastic Strain Rate) ersetzt wurde. Zudem wurde eine vergleichende Analyse der Leistung des hybriden Modells durchgeführt. Das SIPS-basierte Hybridmodell reduzierte die Rechenkosten um fast 40% und erreichte eine Genauigkeit von bis zu 95%. In diesem Zusammenhang wurde im Projekt eine Masterarbeit („Investigation and Implementation of Machine-Learning-based Hybrid Material Models“) und ein Konferenzbeitrag („Accelerating elastoplastic material models with sparse nonlinear regression: A hybrid approach“) veröffentlicht (vgl. II-6).

Hybride Modelle können nicht nur durch die Substitution einzelner Bestandteile klassischer Modelle erzeugt werden, sondern es können auch **physikalische Gesetzmäßigkeiten in holistische Modelle** eingebracht werden. So wurden an dieser Stelle Informationen wie die Linearisierung und weitere Aspekte aus der Veröffentlichung von Bonatti & Mohr [Bon22] implementiert. Diese Hybridisierung wurde in einigen Modellen in AP4 entsprechend übernommen.

AP3.2: Weiterentwicklung der ML-Module für Versuchsdaten

Da die lokalen Spannungen im Versuch nicht gemessen werden können, jedoch für das Training entsprechender ML-Modelle unabdingbar sind, müssen entsprechende Methoden entwickelt werden, um eine implizite Berücksichtigung dieser Größe zu gewährleisten. In diesem Zusammenhang wurde ein neuartiges Verfahren entwickelt, welches die Erfüllung mehrerer notwendiger Bedingungen fordert. Die berücksichtigten Bedingungen sind:

- Interne und externe Energie müssen gleich groß sein,
- Die über den Rand integrierten Spannungen müssen den von außen angreifenden Kräften entsprechen,
- Das Spannungsfeld muss quellenfrei sein.

Da dies jeweils nur notwendige, aber keine hinreichenden Bedingungen sind, können diese Bedingungen kaum verwendet werden, um ein Modell von Grund auf zu trainieren. Vielmehr ist es von Vorteil ein vortrainiertes Modell zu haben, welches bereits auf einen ähnlichen Werkstoff trainiert wurde, bzw. auf simulativen Trainingsdaten, die mit Hilfe eines klassischen Materialmodells erstellt wurden. Dieses Vorgehen wurde exemplarisch als Peer-Review Paper im Fachjournal Computer Methods in Applied Mechanics and Engineering veröffentlicht.

AP3.4: Untersuchung möglicher Kombinationen von mehreren ML-Modulen

Der Anteil der Modelle, die ökonomisch und technisch interessant sind (Substitution des Rückprojektionsalgorithmus und Hybridisierung holistischer Ansätze) lassen sich aufgrund der Überlagerung der substituierten Anteile nicht kombinieren.

AP4: Holistische Materialmodelle

AP4.1: Bestimmung der Vollständigkeit der Datenbasis

Im Bereich der Strukturmechanik werden in einem Materialmodell die Zusammenhänge zwischen Dehnungs- und Spannungsgrößen betrachtet. Klassische Modelle können neben Dehnungen oder Dehnungsinkrementen auch eine Vielzahl anderer Größen wie Temperatur, Geschwindigkeiten oder Aushärtegrade berücksichtigen. Im Rahmen dieses Projekts wurden jedoch ausschließlich Dehnungen bzw. Dehnungsinkremente als Eingangsgrößen für das Training der ML-Modelle verwendet. Als Ausgangsgrößen werden in LS-DYNA die Komponenten des Spannungstensors erwartet.

Für das Training auf Versuchsdaten kann auf alle für das Training benötigten Größen direkt zugegriffen werden, da diese bei Simulationen direkt als Output geschrieben werden können. Um Trainingsdaten aus Versuchen zu verwenden ist die Situation deutlich komplexer, da die (wahren) Spannungen (lokal) nicht direkt gemessen werden können. Hierfür wurden an anderer Stelle (AP3.2) des Projekts entsprechende Methoden entwickelt, um ein Training dennoch zu ermöglichen.

AP4.2: Vergleich und Auswertung von State-of-the-Art ML-Algorithmen

Es gibt verschiedene Ansätze, um die Lernrate (Learning rate) bei den Trainings zu wählen. Im Rahmen des Projekts wurde der von Smith vorgestellte Ansatz einer zyklischen Lernrate untersucht. Hierbei wandert die Lernrate linear zwischen einem maximalen und einem minimalen Grenzwert hin und her, vgl. Abbildung 9.




Abbildung 9: Prinzipskizze der zyklischen Learning rate

Wie in Abbildung 10 gezeigt, ist mit diesem Ansatz ein sehr effizientes Lernen möglich. Hierbei wird durch die zeitweise größere Lernrate zwar der Fehler kurzzeitig größer, jedoch kann so evtl. auch ein lokales Minimum wieder verlassen werden. Die mitunter sehr kleinen Zeitschritte erlauben zeitweise eine deutliche Verkleinerung des Fehlers was zu entsprechend genaueren Prognosen im Vergleich mit einer konstanten Lernrate führt.




Abbildung 10: Vergleich zyklischer und konstanter Learning Rate

AP4.3: Entwicklung von ML-Verfahren zur holistischen Materialmodellierung

Je nach Materialmodell und Anwendung können bei der Betrachtung der ML-Modelle unterschiedliche, grundsätzliche Annahmen getroffen werden. Bei Simulationen im Crash-Bereich wird beispielsweise zumeist angenommen, dass die Richtungsabhängigkeit im Material von untergeordneter Relevanz für die Simulationsergebnisse ist und daher in der Regel vernachlässigt werden kann. Dies führt im vorliegenden Fall direkt zu der Frage, ob diese Annahme für

das Training der gewählten Modelle von Vorteil sein kann. Letztendlich entspricht diese Annahme der Aussage, wonach es nicht relevant sei, wie das Bezugssystem ausgerichtet ist und somit die Prognose des Materialverhaltens davon nicht abhängen darf. Dies könnte ausgenutzt werden, indem die Eingangsgrößen (Komponenten des Dehnungs- bzw. des Dehnungssinkrementensors) in die Hauptrichtung transformiert werden. Die entsprechende Rücktransformation muss dann ebenfalls auf die Outputs (Komponenten des Spannungstensors) angewandt werden, um wieder in das Ausgangssystem zu gelangen. Hierdurch reduziert sich die Anzahl sowohl der Inputs als auch der Outputs um jeweils 3. Dies ermöglicht eine Reduktion des benötigten ML-Modells, wodurch es schneller ausgewertet werden kann. Da allerdings zusätzlicher Rechenaufwand durch die Bestimmung der Eigenvektoren und der entsprechenden Transformationen entsteht und darüber hinaus auch die künftige Erweiterbarkeit auf anisotropes Verhalten eingeschränkt wird, wurde dieser Ansatz im Projekt nicht weiterverfolgt. Allerdings wurde die Isotropie des Werkstoffs bei der Generierung der Trainingsdaten ausgenutzt, indem die Daten in unterschiedliche Raumrichtungen transformiert wurden.

AP4.4: Evaluierung der Genauigkeit, Robustheit und Effizienz der Modelle

Zum Abgleich der implementierten und trainierten Modelle wurde im Projekt ein Hut-Profil als kleiner Demonstrator verwendet. Dieser wurde in einem Drei-Punkt-Biegeversuch durch einen Impaktor mit definierter Initialgeschwindigkeit belastet. Hier wurden dann nicht nur die Kraft-Weg-Kurven des Impaktors verglichen, vielmehr konnten das gesamte Verschiebungsfeld sowie die Dehnungs- und Spannungsfelder verglichen werden.


AP4.6: Untersuchung von Transfer-Learning Verfahren zur Beschleunigung des Modellierungsprozesses

Für die Einbindung von trainierten ML-Modellen wurde in AIMM ein Tool verwendet, das unter Federführung von Mercedes-Benz im Vorgängerprojekt AIAx entwickelt wurde. Für die Anforderungen in AIMM wurde das Tool deutlich erweitert und beschleunigt. DYNAmore war hier in erster Linie beratend tätig, um eine möglichst robuste Implementierung zu ermöglichen.

AP5: Neuartige Charakterisierungsversuche für das Training von KI-Modellen

AP5.1/5.2: Neuartige Charakterisierungsversuche

Für das Training der ML-Modelle auf Versuchsdaten müssen diese ein möglichst breites Spektrum an Zuständen abbilden. Um eine optimale Probengeometrie zu identifizieren, wurden verschiedene Geometrien parametrisiert und simulationsgestützt optimiert.



$$-45 \leq x_i \leq 45, \quad i = 1:14$$

$$-30 \leq y_i \leq 30$$

Abbildung 11: Beispielhafte Parametrisierung der Probengeometrie




Abbildung 12: Beispielhafte Erzeugung einer Probengeometrie

Als Optimierungsziel musste zunächst eine Metrik definiert werden, um die Eignung einer Geometrie zu beurteilen. Hierfür wurden für alle Zeitpunkte und für alle Orte der Simulation die plastischen Dehnungen über der Spannungsmehrrachsigkeit in einem Diagramm mit einer definierten Pixelgröße aufgetragen. Anschließend wurde bestimmt, wie groß der bedeckte Flächenanteil des Diagramms war. Dieser Parameter konnte dann bei der Optimierung maximiert werden.




Abbildung 13: Beispielhafte Darstellung aller Punkte (Bild a) und der bedeckten Fläche (Bild b)

Für die Optimierung wurden folgende Schritte durchgeführt:

1. Automatische Erzeugung und Vernetzung der Geometrie
2. Simulation des Versuchs
3. Auswertung der Simulation und Extraktion der Daten (plast. Dehnung vs. Triaxialität)
4. Erzeugung der Diagramme und Bestimmung des Anteils der bedeckten Fläche
5. Optimierung der Parameter für die nächste Iteration

Diese Schritte (1.-5.) wurden wiederholt ausgeführt, bis ein Optimum erreicht wurde.




Abbildung 14: Ergebnis einer Geometrieoptimierung

Wenn Zugproben nicht achsensymmetrisch sind, entstehen an der Einspannung horizontale Kräfte. Diese Kräfte können in den meisten Versuchsanlagen nicht gemessen werden, weshalb im Verlauf des Projektes als zusätzliche Bedingung die Achsensymmetrie eingeführt wurde. Die finale Probengeometrie in deformiertem Zustand ist in Abbildung 15 zu sehen.




Abbildung 15: Finale Probengeometrie mit maximierter Datenstreuung

Während der Zugbereich sehr gut abgedeckt wird, ist es leider nur sehr eingeschränkt möglich Druckspannungen (negative Triaxialität) in einer Zugversuchsprobe auszulösen. Um Detailliertere Messungen über das Materialverhalten unter Druck zu erhalten, müssen daher andere Versuche durchgeführt werden. Hierfür wurden verschiedene weitere Geometrien unter Druck getestet. Der Problematik, dass diese Proben natürlich sehr stark knickgefährdet sind, wurde versucht durch entsprechende Leitbleche zu begegnen. Das vordere Leitblech wurde dabei mit einem Sichtfenster versehen, um die Dehnungen auf der Probenoberfläche im Verlauf des Versuchs messen zu können. Abbildung 16 bis Abbildung 18 zeigen die Simulationsergebnisse und Auswertungen für 3 verschiedene Varianten.




Abbildung 16: Druckversuch ohne Löcher → 26% Bedeckung im Druckbereich




Abbildung 17: Druckversuch mit vertikalen Löchern → 41 % Bedeckung im Druckbereich




Abbildung 18: Druckversuch mit horizontalen Löchern → 63% Bedeckung im Druckbereich

Auch wenn im Realversuch für die Leitbleche höchstfester Stahl verwendet wurde, konnte ein Ausknicken der Probe nicht verhindert werden. Für Druckversuche konnte im Rahmen des Projekts keine optimale neue Probengeometrie gefunden werden.

Da für Stahl meist grundsätzlich angenommen werden kann, dass das Verhalten unter Zug und Druck symmetrisch ist, kann hier auch von der Zug- in die Druckrichtung extrapoliert werden.

AP6: Versuchsautomatisierung

AP6.1: Festlegung der zu automatisierenden Prozessanteile (Hardware)

Der Versuchsprozess umfasst die folgenden Schritte:

1. Probenentnahme
2. Probenpräparation (Muster applizieren für die DIC-Messung)
3. Probenvermessung
4. Probe einbringen in Versuchsanlage
5. Versuchsanlage in Bereitschaft versetzen
6. Versuch und Messung starten

7. Proben nach Versuchsdurchführung aus der Anlage entnehmen und ablegen
8. Versuchsergebnisse abspeichern

Um eine möglichst unterbrechungsfreie Automatisierung zu ermöglichen, müssen so viele zusammenhängende Schritte wie möglich hintereinander ausgeführt werden. Die Probenentnahme lässt sich nur mit sehr hohem Aufwand automatisieren, weshalb dieser Punkt von der Automatisierung ausgeklammert wurde.

Klassischerweise wird das Muster, welches für die Erfassung der Oberfläche mit DIC auf die Probe aufgebracht werden muss, manuell mit Sprühdosen aufgesprüht. Auch dieser Schritt wäre nur sehr aufwändig zu automatisieren, weshalb er auch von der Automatisierung ausgeklammert wurde.

Alle weiteren Schritte wurden als automatisierbar identifiziert. Hierfür wurden mehrere Geräte beschafft, wobei darauf geachtet wurde, dass beide Projektpartner (IFB und DYNAMORE) möglichst gleiche Komponenten verwenden, um in der Umsetzung maximale Synergieeffekte ausnutzen zu können.

AP6.2: Entwicklung von Konzepten zur Automatisierung (Hardware und Software)

Die Abläufe der einzelnen Systeme wurden in Python realisiert. Eine Ausnahme bildet lediglich der Roboter, dessen Steuerung über eine eigene Steuerungssoftware erfolgt. Die Kommunikation der einzelnen Komponenten des Systems läuft über eine Modbus-Schnittstelle. Hierzu werden entsprechende vorher definierte Werte in bestimmte Register geschrieben. Jeder Schritt eines Systems wird durch das Setzen eines Wertes getriggert und muss bei einer erfolgreichen Beendigung des Vorgangs wiederum durch das Setzen eines entsprechenden Werts bestätigt werden. Fehler werden durch Fehlercodes identifiziert. Es muss während des gesamten Prozesses sichergestellt werden, dass sich das Gesamtsystem im Fall eines Fehlers in einer Systemkomponente in einem sicheren Zustand befindet. Darüber hinaus sollte auch versucht werden, bei Anzeichen eines Problems, wie beispielsweise einem Versagen der Messung, den Ablauf vor der Versuchsdurchführung zu stoppen, um die Probe nach Wiederherstellung der vollen Funktionalität noch testen zu können.

AP6.3: Umsetzung der Automatisierungskonzepte (Hardware)

Die Fertigung der Proben wurde vom vollautomatisierten Prozess ausgeklammert. Um dennoch Proben in hoher Stückzahl und Präzision aus Blechen entnehmen zu können wurde eine Wasserstrahlschneidemaschine (iCUT Water Smart 1000 von imes-icore GmbH) beschafft. Auch die ebenfalls als kaum automatisierbar eingestufte Probenpräparation mit dem für die DIC notwendigen Muster konnte durch die Anschaffung eines UV-LED-Druckers (PS4060 von We Print

Solutions) deutlich beschleunigt. Es können nun Proben in großer Zahl und gleichbleibend sehr hoher Musterqualität gleichzeitig bedruckt werden und auch die Wartezeit zwischen Aufbringen der Farbe und Prüfung, die sonst durch das notwendige Antrocknen der Farbe notwendig ist, kann entfallen.

Für die Automatisierung wurden weitere Geräte beschafft und Konstruktionen durchgeführt. Um die Proben für die automatische Prüfung bereitzulegen, so dass sie vom Roboter gegriffen werden können, wurde ein Magazin entworfen, welches von außerhalb der Gefahrenzone befüllt und bei Bedarf auch einfach erweitert werden kann.

Das Herzstück der Automatisierung ist ein UR5e von Universal Robots. Es handelt sich dabei um einen Cobot, der das eigentliche Handling der Proben übernimmt. Die Steuereinheit des Roboters ist außerdem die zentrale Stelle für die Kommunikation der beteiligten Komponenten. Es wurde untersucht, ob ein manueller Greifer oder ein Vakuumgreifer besser geeignet ist. Der Vakuumgreifer hat zwar den Vorteil, dass er Proben einfach von einem Stapel abheben könnte, jedoch kam er letztendlich nicht in Frage, da er einerseits die Probe nicht perfekt ruhig halten kann bei der 3D-Vermessung und die Probe natürlich im Bereich des Greifers keine Löcher haben darf. Den Herausforderungen eines manuellen Greifers wurde bei der Konstruktion des Magazins entsprechend Rechnung getragen, so dass dieser nun ohne Probleme eingesetzt werden kann.

Nach der Aufnahme der Probe aus dem Magazin muss diese zunächst vermessen werden. Dafür wurde ein GOM Atos Core 185 der GOM GmbH beschafft. Der Roboter präsentiert die Probe dem Scanner, welcher ein 3D-Modell der Probe erstellt. Basierend auf diesem Modell werden die benötigten Maße der Probe extrahiert.

Anschließend wird die Probe vom Roboter in die Spannvorrichtung der Versuchsmaschine eingebracht. Um auch diesen Teil automatisieren zu können wurde ein Luft-hydraulisches Spannzeug der Firma Shimadzu beschafft. Eine Erweiterung der Spannzeugsteuerung mit entsprechenden Relais erlaubt eine Steuerung der Spannbacken durch die Robotersteuereinheit.

Da während der Messung so viele Daten wie möglich erfasst werden müssen, wurde für hochauflösende DIC-Messungen ein GOM Aramis 12M Sensor der GOM GmbH beschafft. Dieser erlaubt die Erfassung sämtlicher während des Versuchs anfallender Daten und die anschließende Auswertung bzw. den entsprechenden Export.

Der Roboter muss für den Einsatz direkt an der Versuchsmaschine platziert werden. Außerdem müssen das Probenmagazin und der 3D-Scanner in unmittelbarer Nähe stehen. Um für andere Anwendungen in der Versuchsmaschine genügend Freiräume schaffen zu können wurde eine

Unterkonstruktion entworfen und umgesetzt, die für die Automatisierung fest mit der Versuchsmaschine verbunden ist, aber auch mit überschaubarem Aufwand gelöst und mit Hilfe der angebrachten Rollen entfernt werden kann.

Für die Steuerung der Automatisierung muss zunächst geklärt werden, wie die einzelnen Komponenten automatisiert werden können und dann müssen diese Komponenten miteinander verknüpft werden. Das Probenmagazin wird manuell befüllt, es wurde ein Programm geschrieben, mit welchem die Position der einzelnen Proben in json-Dateien hinterlegt wird. Der Roboter kann auf eine sehr komfortable Weise mit einem Tablet programmiert werden. Hierbei müssen alle Positionen und Bewegungen berücksichtigt werden. Sowohl die Software für das Atos als auch für das Aramis können intern über Python programmiert werden. Die Steuerung der Spannbacken erfolgt mit Hilfe von Relais, die durch Digitale 24V Ausgänge des Roboters ausgelöst werden können. Die Steuersoftware der Universalprüfmaschine erlaubt leider keine direkte Automatisierung und bietet auch keinerlei API zur externen Steuerung. Es wurde hier stattdessen ein Programm geschrieben, das über Mustererkennung an der Bildschirmausgabe des Programms die Steuerung desselben übernimmt, indem Mausbewegung und Tastatureingaben erzeugt werden. Trotz dieser Herausforderung konnte auch dieser Teil des Prozesses robust automatisiert werden.

Die Kommunikation zwischen den einzelnen Bestandteilen der gesamten Automatisierung erfolgt über die Modbus-Schnittstelle. Hier wird ein von der Robotersteuerung zur Verfügung gestelltes Register genutzt, um an unterschiedlichen Stellen Werte zu schreiben und zu lesen die den Zustand aller Prozesspartner eindeutig definieren.

AP6.4: Festlegung der zu automatisierenden Prozessanteile (Software)

Die Versuche können direkt in der Messsoftware ausgewertet und die relevanten Daten extrahiert werden. Es wurden entsprechende Skripte in Python implementiert die eine vollautomatische Auswertung der Versuche und Export der erforderlichen Daten ermöglichen.

AP6.5: Entwicklung eines softwaregestützten Verfahrens zu Training und Validierung von ML-basierten Materialmodellen

Durch die von Mercedes-Benz in AP4.6 entwickelte Schnittstelle zur Einbindung von ML-Modellen in LS-DYNA war es möglich trainierte Modelle direkt in LS-DYNA zu verwenden.

AP6.6: Aufbau und Anwendung von (teil)automatisierten Prozessen

Die in den vorangestellten APs entwickelten Automatisierungskomponenten wurden zusammengeführt, so dass eine durchgehende Automatisierung von der Probe bis zu den extrahierten Daten zur Verfügung steht.

AP6.7: Evaluation

Es hat sich gezeigt, dass die Versuchsdurchführung durch die Automatisierung selbst nicht merklich beschleunigt wird. Da jedoch die Versuche theoretisch rund um die Uhr durchgeführt werden können, erhöht sich der potenzielle Gesamtdurchsatz erheblich. Ein definitiver Vorteil ist die erhöhte Objektivität der Versuchsdurchführung, da der Einfluss der Versuchsoperatoren entfällt. Insgesamt ist von einer verbesserten Reproduzierbarkeit der Versuche auszugehen.

AP7: Demonstrator

AP7.4 – 7.6:

Die Projektpartner wurden bei der Umsetzung der Demonstratorsimulationen unterstützt.

1.2 ElringKlinger

AP1: Erzeugung klassischer Materialkarten

AP1.1. Klassische Charakterisierung und Modellierung Kunststoff

Um sowohl den Stand der Technik abbilden zu können, als auch einen Bewertungsmaßstab für die im späteren Projektverlauf entwickelten KI-Materialmodelle zu schaffen, wurden zunächst Probekörper aus einem kommerziell verfügbaren Kunststoffmaterial hergestellt. Hierzu wurde von der ElringKlinger AG ein Spritzgusswerkzeug entwickelt, konstruiert und hergestellt, mit welchem die benötigten Probekörper aus thermoplastischem Kunststoff produziert werden konnten. Die Probeplatten mit den Abmessung 250 mm x 200 mm wurden deutlich größer dimensioniert als für klassische Prüfkörper erforderlich, da noch Spielraum gelassen wurde für die in der frühen Projektphase noch nicht definierbaren, in AP5 entwickelten neuartigen Probekörpergeometrien. Anschließend wurde eine erste Charge dieser Probeplatten aus dem im Konsortium festgelegten Kunststoff, ein ungefüllter PC+ABS-Blend Bayblend T65 XF von Covestro, hergestellt und an die weiteren an AP1.1 beteiligten Projektpartner geliefert. Aus den Probeplatten wurden Zug-, Druck- und Scherprüfkörper gefertigt. Anhand dieser Probekörper werden die Materialien als Referenz für die Entwicklung der neuartigen Charakterisierungsversuche verwendet. Nach dem Abschluss der Charakterisierungsversuche für das Kunststoff-Material wurden die Materialmodelle klassisch anhand der Versuchsergebnisse parametrisiert um als Referenz für die Entwicklung der KI-basierten Materialmodelle verwendet werden zu können.

AP2: Erzeugung simulativer Trainingsdaten

AP2.2: Erzeugung simulativer Trainingsdaten

Um die KI-Materialmodelle trainieren zu können, ist eine umfangreiche Datenbasis aus konventionell erzeugten Spannungs-Dehnungs-Informationen notwendig. Hierfür wurden die in AP1.1 erzeugten klassischen Materialien verwendet, um randomisierte Dehnpfade zu erzeugen. Zur Generierung dieser Daten wurde auf Basis der Trainingsdaten der Metall-Simulationen ein Software-Tool entwickelt um die notwendigen Daten zu erzeugen. Die Basis dieses Software-Tools wurde auf die Verwendung mit Kunststoff-Materialmodellen erweitert, um damit die notwendigen Trainingsdaten mit dem ausgewählten Kunststoff-Material für die folgenden Arbeitspakete zu erzeugen. Da hierfür eine große Menge an Trainingsdaten über eine große

Bandbreite an verschiedenen Parametern benötigt wird, wurde hierfür ein teilautomatisierter Prozess entwickelt.

AP5: Neuartige Charakterisierungsversuche für das Training von KI-Modellen

AP5.1: Neuartige Versuche für Kunststoffe

Um die KI-Materialmodelle, welche in den vorherigen APs entwickelt, auf synthetischen Versuchsdaten trainiert und teilweise validiert wurden, anhand realer Versuche trainieren zu können, wurden Simulationen mit neuartigen Probekörpergeometrien durchgeführt. Diese Probekörper sollen alle relevanten Dehnpfade, die für das KI-Training benötigt werden, abbilden können. Dazu wurden verschiedene neue Probekörper simulativ auf ihre Eignung zur Generierung von KI-Trainingsdaten untersucht. Die simulative Untersuchung von verschiedenen parametrisierten Probekörpergeometrien kann semi-automatisch und dadurch deutlich zeiteffizienter durchgeführt werden, als die Fertigung und Untersuchung von vielen unterschiedlichen Probekörpern in Realversuchen. Zur experimentellen Validierung der neuartigen Probekörper wurde eine weitere Charge der Probekörperplatten produziert.

Für das Training der KI-Materialmodelle mit realen Versuchsdaten wurde die Probekörpergeometrie für diese Versuche mittels FEM-Simulation mit konventionellen Materialmodellen noch weiter optimiert. Ziel der Optimierung war eine Probekörpergeometrie, welche möglichst alle in realen Bauteilversuchen auftretenden Belastungsarten beinhaltet. Dazu wurde ein Strukturoptimierungssolver konfiguriert und verwendet, welcher die Geometrie des Probekörpers nach Zielvorgabe einer über die Probe homogenen Triaxialitätsverteilung optimiert. Mit dieser Probekörpergeometrie wurden aus einfachen Charakterisierungsversuchen komplexe KI-Materialmodelle trainiert.

AP6: Automatisierung

AP6.6: Aufbau und Anwendung von teilautomatisierten Prozessen

Zur teilautomatisierten Berechnung von Probekörper- und Demonstratorteilen wurden Templates im CAE Pre-Processor aufgebaut, welche einen teilautomatisierten Workflow für die Berechnung mit unterschiedlichen Materialmodellen und Last-Randbedingungen ermöglichen. Die zuvor aufgebauten und getesteten Templates zur teilautomatisierten Berechnung von sowohl Probekörpern als auch Demonstratorbauteilen aus thermoplastischen Kunststoffen wurden erfolgreich auf die zu berechnenden Teile angewandt. Verschiedene Lastfälle mit unterschiedlichen Materialmodellen wurden erfolgreich im Automatisierungsprozess berechnet. Die notwendigen Berechnungen können ohne großen Konfigurationsaufwand unter verschiedenen

Randbedingungen durchgeführt werden. Berechnungsergebnisse werden automatisch in geeigneten Dateiformaten exportiert um in weiteren Schritten mit den real durchgeführten Versuchen verglichen zu werden.




Abbildung 19: Quasi-statische Berechnungsmodelle (Kunststoff-Modelle)

Standardisierte Randbedingungen unabhängig von der Probekörpergeometrie wurden definiert und versuchsweise in ersten Simulationen erfolgreich getestet (s. Abbildung 19). Diese Randbedingungen konnten automatisiert auf beliebige Probekörper-, Demonstrator- und Bauteilgeometrien appliziert werden. Dadurch wurde es möglich, Berechnungen (teil-)automatisiert durchzuführen. Dies war möglich für alle FEM-Berechnungen, welche im Rahmen von AIMM benötigt wurden. Hierdurch wurde einerseits der Anteil and manuellem Modellaufbau erheblich verringert, andererseits wurde durch einen automatisierten Berechnungsablauf das Training und die Validierung von KI-Materialmodellen erst effizient möglich.

AP7: Demonstrator

AP7.2: Komponententests an Kunststoff-Demonstratoren

Für Versuche auf Komponentenebene dieser Bauteile wurde eine variable Prüfvorrichtung konstruiert und gefertigt, um die geplanten Bauteilversuche in verschiedenen Varianten durchführen zu können. Verschiedene Prüfvarianten bzw. Positionierungen des Bauteils in der Vorrichtung waren nötig, um verschiedene Belastungszustände (Zug-, Druck-, Schubbelastungen) abbilden zu können. Diese sind notwendig, um eine ausreichend hohe Varianz der Belastungszustände für den Abgleich mit Simulationen zu erzeugen. Für den Abgleich von Realversuchen am Demonstrator und Berechnungen wurden in Bauteilversuchen die Dehnungen während der Versuche optisch erfasst, um diese dann direkt mit den durchgeführten Berechnungen vergleichen und die KI-basierten Materialmodelle auch anhand dieser Versuche trainieren zu können.

Ein Prinzipaufbau einer der untersuchten Bauteilpositionen der Komponentenversuche ist in Abbildung 20 dargestellt.



Abbildung 20: Prinzipaufbau der durchgeführten Komponentenversuche

AP7.4: Demonstratoren für Crashesimulation - Kunststoff

Die Produktion von Motorträgern als Demonstratoren war auf einer sich in Serienproduktion befindlichen Produktionsanlage vorgesehen. Um eventuelle Engpässe in Materialversorgung und Produktionskapazität zu vermeiden, wurde die vorbereitenden Schritte zur Demonstratorenproduktion im Zeitplan etwas vorgezogen, damit die Demonstratoren rechtzeitig im Projektablauf vorliegen.

Die Produktion von Motorträgern als Demonstratoren zur Validierung der KI-Materialmodelle hat bereits nach den ersten wenigen, aus der Produktionsanlage fallenden Bauteilen gezeigt, dass die Kombination aus Bauteilgeometrie, Fertigungstechnologie und dem für dieses Projekt ausgewählten thermoplastischem Kunststoffmaterial keine zufriedenstellenden Ergebnisse liefert. Das ausgewählte Material, „Bayblend T65 XF“ basiert auf einem Blend aus Polycarbonat und Acrylnitril-Butadien-Styrol (PC-ABS), das zur Verfügung stehende Spritzgusswerkzeug ist jedoch in erster Linie für Werkstoffe auf Polyamid-Basis (PA) ausgelegt. Für die Produktion der Demonstratorbauteile stand zwischenzeitlich nur noch ein sich bereits seit Jahren in der Serienproduktion verwendetes Spritzgusswerkzeug zur Verfügung. Aufgrund mangelnder Erfahrung in der Verarbeitung von PC-ABS bei ElringKlinger wurde erst bei den ersten Spritzversuchen ersichtlich, dass PC-ABS mit diesem Werkzeug nicht zufriedenstellend verarbeitet werden kann. Um funktionsfähige Demonstratorbauteile aus diesem Werkzeug zu erhalten, wäre ein

sehr aufwändiger und kostenintensiver Umbau des Spritzgusswerkzeugs nötig gewesen, welcher mit dem zu erwartenden Nutzen nicht rechtfertigbar gewesen wäre.

Nachdem der Herstellungsprozess mit dem gewählten Material und dem gewählten Bauteil in dieser Kombination nicht durchführbar war, musste nach einer adäquaten Demonstratorgeometrie gesucht werden. Hierbei wurden die ursprünglichen Anforderungen, die hauptsächlich den Spannungszustand betrafen, um die Produzierbarkeit erweitert. Als größtes Problem der ursprünglichen Demonstratorgeometrie wurde die starke Verrippung ausgemacht. Die für die Versteifung des Motorträgers benötigten Rippen verlaufen über die gesamte Bauteilinnenseite. Durch die nicht ausreichende Kühlung des PC-ABS zwischen dem Einspritzprozess und dem Auswerfen des Bauteils, konnten die Rippen nicht entformt werden. Die neu zu wählende Demonstratorgeometrie durfte deshalb zwar weiterhin Rippen aufweisen, diese sollten jedoch in ihrer Größe reduziert sein. Weiterhin sollte das neue Demonstratorbauteil wieder ein Serienbauteil sein. Auf diesem Weg kann sichergestellt werden, dass viele in den frühen Phasen des Produktionsanlaufes auftretende Probleme bereits erkannt und behoben worden sind. Ebenfalls berücksichtigt wurde, dass der Serienwerkstoff dem PC-ABS bestmöglich ähnelt, sodass das Werkzeugkonzept nicht verändert werden muss. Ein allen ursprünglichen und neu definierten Anforderungen entsprechendes Bauteil ist ein Getriebedeckel, der in Abbildung 21 zu sehen ist. Nach umfänglicher Prüfung aller Gegebenheiten wurden erfolgreich 80 Bauteile gefertigt und an die Konsortialpartner übergeben.



Abbildung 21: Neu gewählte Demonstratorgeometrie in Draufsicht (links) und Untersicht (rechts) in Form einer Getriebeabdeckung

1.3 Fraunhofer EMI

AP1: Erzeugung klassischer Materialkarten

AP1.1: Klassische Charakterisierung und Modellierung eines Kunststoffs

An dem Kunststoffmaterial (Bayblend T65 XF) wurden klassische Zugversuche bei crashrelevanten hohen Dehnraten (bis 100 /s) durchgeführt. Abbildung 22 zeigt links den Versuchsaufbau an einer Schnellzerreimaschine und rechts das mittels DIC gemessene Dehnungsfeld auf einer Probe kurz vor dem Versagen. Diese Versuche ergnzen die quasi-statischen Versuche des IFB und dienen der Bestimmung des Materialverhaltens ber einen groen Dehnratenbereich. Zustzlich wurde mittels Scherzugversuchen der Kunststoff bei einer weiteren Belastungsart untersucht.




Abbildung 22: Links: Versuchsaufbau fr Zugversuche an einer Schnellzerreimaschine. Rechts: Dehnungsfeld kurz vor dem Versagen

Mit den am EMI und am IFB durchgefhrten Charakterisierungsversuchen (Zug, Schub, Druck) wurden anschlieend zwei klassische Materialmodelle in LS-DYNA kalibriert: *MAT_SAMP-1 und *MAT_024. Beide Modelle sind in der Lage, die bei Kunststoffen typische starke Dehnratenabhngigkeit des Materialverhaltens abzubilden. Das SAMP-Modell kann zustzlich weitere kunststofftypische Eigenschaften modellieren: Es erlaubt eine Anpassung der Flieflche an die Versuchsdaten unter Zug-, Schub- und Druckbelastung sowie die Bercksichtigung einer Volumennderung bei der plastischen Verformung. In Abbildung 23 ist ein Vergleich der Zugversuche mit den entsprechenden Simulationen unter Verwendung des SAMP-Modells dargestellt.




Abbildung 23: Vergleich von Experiment und Simulation anhand von Zugversuchen bei verschiedenen Dehnraten

Für die Validierung der beiden klassischen Materialkarten wurden Biegeversuche bei unterschiedlichen Geschwindigkeiten durchgeführt. Bei einem Vergleich zwischen den Versuchsergebnissen und den Simulationen konnte für das SAMP-Modell eine gute Übereinstimmung festgestellt werden. Bei Verwendung der *MAT_024-Karte zeigten sich etwas größere Abweichungen, die sich durch die Einschränkungen dieses Materialmodells (fehlende Zug-Druck-Asymmetrie) erklären lassen.

AP1.2: Klassische Charakterisierung und Modellierung eines Metalls

Es wurden an Proben des betrachteten Stahlwerkstoffs klassische dynamische Zugversuche bei mehreren Dehnraten bis zu 100 /s durchgeführt. Diese Versuche sind für die Kalibrierung der Dehnratenabhängigkeit eines klassischen Materialmodells durch DYNAmore erforderlich. Weiterhin wurden für die Validierung des Materialmodells benötigte Biegeversuche bei verschiedenen Geschwindigkeiten und Orientierungen durchgeführt.

AP2: Erzeugung simulativer Trainingsdaten

AP2.1: Schnittstellen

Gemeinsam mit den Projektpartnern erfolgte zunächst die Analyse der zu verarbeitenden Daten sowie der daraus resultierenden Anforderungen an die zu implementierenden Schnittstellen und Datenformate. Im weiteren Verlauf erfolgte die Unterstützung bei der Implementierung der hierzu erforderlichen Python-basierten Skripte. Dies umfasste beispielsweise die Analyse und

Aufbereitung existierender Skripte zur effizienten und automatisierten Ergebnisextraktion aus FE-Simulationsfiles, die zur ersten Analyse der simulationsbasierten Trainingsdaten genutzt wurden. Zur Ermöglichung einer genaueren Analyse simulationsbasierter Trainingsdaten wurden gemeinsam mit den Partnern Tools zur Ermittlung und angepassten Visualisierung weiterführender kinematischer und kinetischer Größen implementiert und integriert.

AP2.2/2.3: Erzeugung simulativer Trainingsdaten für einen Kunststoff / ein Metall

Eine Möglichkeit zur Erzeugung simulativer Trainingsdaten, die in diesem Vorhaben verfolgt wurde, war die Durchführung einer Vielzahl von Ein-Element-Simulationen mit unterschiedlichen Randbedingungen. Das EMI unterstützte hierbei die Projektpartner bei der Methodentwicklung, insbesondere durch Beiträge im Zusammenhang mit geeigneten Koordinatentransformationen. So konnten beispielsweise durch Verwendung von Zylinderkoordinaten im Hauptdehnungsraum (analog zu Haigh-Westergaard-Koordinaten im Spannungsraum) die Form- und Volumenänderung bei der Generierung der Trainingsdaten einfach separiert werden und entsprechende Randbedingungen für die Elemente bestimmt werden.

AP3: Hybride Materialmodelle

AP3.2: Weiterentwicklung der ML-Module für Versuchsdaten

Für das Training der ML-Modelle werden die zu gegebenen Dehnungspfaden zugehörigen Spannungen an einem materiellen Punkt benötigt. Diese Dehnungs-Spannungs-Paare erhält man problemlos aus Simulationsdaten. Beim Training von ML-Modellen mit Versuchsdaten ergibt sich jedoch ein Problem: Während die Verzerrungen mittels DIC an jedem Punkt der Probenoberfläche messbar sind, können aus Versuchen keine Spannungen bestimmt werden. Messbar ist lediglich die an den Einspannungen einer Probe in Zugrichtung auftretende Komponente der Kraft, die sich aus dem Integral der Spannung über die Einspannfläche ergibt. Daher stehen für das Training mit Versuchsdaten deutlich weniger Informationen zur Verfügung. Eine Möglichkeit, dieses Problem zu umgehen, wäre die Kopplung des Trainingsprozesses mit FE-Simulationen, aus denen die fehlenden Spannungen gewonnen werden. Dies würde jedoch zahlreiche zeitaufwändige Simulationen während des Trainings erfordern.

Daher wurden am EMI die theoretischen Grundlagen für eine neuartige Methode entwickelt, die das Training mit Versuchsdaten ohne FE-Kopplung ermöglicht. Dabei wird die Tatsache genutzt, dass zu jedem Zeitpunkt in jedem Punkt einer Probe ein Kraftgleichgewicht vorliegt. Daraus können drei Bedingungen abgeleitet werden:

1. Im Innern der Probe lässt sich dieses Gleichgewicht durch die Divergenzfreiheit des Spannungstensors ausdrücken.

2. Entlang des freien Probenrands muss die Kraft null sein.
3. Entlang des eingespannten Rands der Probe muss die Kraft der im Versuch beobachteten Kraft entsprechen.

Ein trainiertes ML-Modell muss daher zu den im Versuch gemessenen Verzerrungen stets solche Spannungen berechnen, welche die geforderten Gleichgewichtsbedingungen erfüllen. Mit diesem Ansatz wurden Loss-Funktionen konstruiert, mit deren Hilfe sich ein ML-Modell auf Grundlage von Versuchsdaten trainieren lässt. Im Anschluss daran wird zusätzlich die Isotropie des Materials berücksichtigt, indem die gemessenen Verzerrungstensoren und die vom ML-Modell berechneten Spannungstensoren in zufällige Richtungen rotiert werden und die so generierten Daten in einem weiteren Trainingsschritt verwendet werden. Diese neue Methode für das Training von ML-Modellen mit Versuchsdaten wurde am IFB implementiert und gemeinsam mit den anderen Projektpartnern weiterentwickelt und in einem Paper veröffentlicht.

AP5: Neuartige Charakterisierungsversuche für das Training von KI-Modellen

AP5.1: Neuartige Charakterisierungsversuche für Kunststoffe

Für die Kalibrierung klassischer Materialmodelle werden typischerweise gezielt Versuche mit einem definierten, einfachen Belastungszustand durchgeführt (z.B. uniaxialer Zug), um daraus die notwendigen Parameter für das Modell abzuleiten. Für das Training von ML-Modellen muss im Gegensatz dazu ein anderer Ansatz verfolgt werden: Hier sind Versuchstypen erforderlich, bei denen in einem Probekörper eine Vielzahl von komplexen Belastungszuständen vorliegt. Im Idealfall müssen mit den Versuchen Daten für alle relevanten Inputs (=Dehnungspfade) ermittelt werden, um die ML-Modelle damit trainieren zu können.

Es wurde daher eine Methode zur simulationsbasierten Optimierung von Probekörpern entwickelt. Kernstück ist ein Python-Tool, welches die in der Simulation eines Probekörpers auftretenden Dehnungszustände basierend auf einer Kerndichteschätzung ihrer Häufigkeitsverteilung analysiert und verschiedene Kennzahlen zur Bewertung der Abdeckung des relevanten Dehnungsraums durch diesen Probekörper berechnet. Hierbei wird berücksichtigt, dass sich verschiedene Dehnungszustände bei Annahme von isotropem Verhalten durch Rotation ineinander überführen lassen. Weiterhin muss beachtet werden, dass durch die Verwendung von Schalenelementen und der damit verbundenen Einschränkung auf einen ebenen Spannungszustand ein Freiheitsgrad verloren geht. Ziel der Optimierung ist nun eine möglichst große Abdeckung des Dehnungsraums durch die in dem Probekörper vorliegenden Belastungszustände, um möglichst viele Trainingsdaten für das ML-Modell zu liefern. Abbildung 24 zeigt ein

Beispiel einer solchen Analyse: Jeder schwarze Punkt im linken Diagramm stellt den Dehnungszustand eines Schalenelementes der Probe (rechts) zum betrachteten Zeitpunkt dar. Die helle Fläche im Diagramm repräsentiert den abgedeckten Dehnungsraum.




Abbildung 24: Analyse der Dehnungszustände zu einem festen Zeitpunkt (links) in einem simulierten Probekörper (rechts) unter Zugbelastung mit Hilfe des entwickelten Python-Tools

Betrachtet wurden für die Optimierung unter anderem rechteckige, parametrisierte Zugproben mit drei ellipsenförmigen Löchern, deren Mittelpunkte auf einem Kreis angeordnet sind. Folgende Parameter dieses Probentyps wurden in die Optimierung einbezogen:

- Die Orientierung der Ellipsen (d.h. die Richtung ihrer großen Halbachse)
- Die Exzentrizität
- Die Länge der großen Halbachsen

Mittels eines weiteren Python-Skripts und LS-PrePost konnten automatisiert für einen gegebenen Parametersatz die erforderlichen LS-DYNA-Inputfiles zur Simulation dieser Probekörper erzeugt werden. Unter Nutzung von LS-OPT wurden nun diejenigen Werte der Parameter identifiziert, welche die von dem Python-Tool berechneten Kennzahlen zur Abdeckung des Dehnungsraums maximieren. Anschließend wurden aus dem Kunststoffmaterial Proben mit der gefundenen optimierten Geometrie gefertigt und Versuche bei unterschiedlichen Dehnraten bis zu 200 /s durchgeführt.

Trotz der Optimierung der Probekörpergeometrie hat sich im Rahmen der Untersuchungen gezeigt, dass insbesondere bei hohen Dehnungen eine ausreichende Abdeckung im Dehnungsraum mit nur einem Probekörper nicht erzielt werden kann. Während in weiten Teilen der Probe bei geringen Dehnungen noch komplexe Belastungszustände vorliegen, gehen diese bei hohen Dehnungen immer mehr in einen Zustand nahe dem uniaxialen Zug über. Daher sollten für das

Training der ML-Modelle nicht nur die Daten aus dem optimierten Probekörper genutzt werden, sondern ebenfalls die Ergebnisse weiterer Versuchstypen wie Druck und Scherzug Berücksichtigung finden. Durch die Kombination dieser Versuchstypen erhält man eine deutlich bessere Datengrundlage aus den Versuchen für das Training (siehe Abbildung 25).




Abbildung 25: Dehnungszustände (kumuliert über alle Zeitpunkte) für die Kombination aus optimierter Zug-, Scherzug- und Druckprobe

AP6: Versuchsautomatisierung

Im Hinblick auf die Versuchsautomatisierung lag der Fokus am Fraunhofer EMI auf der Entwicklung eines Systems zur Probenvermessung. Dabei kam kein optisches Messsystem wie bei den anderen Partnern zum Einsatz, sondern mechanische Messtaster zur Messung der Probendicke und -breite (Abbildung 26, links). Die zu vermessenden Proben müssen manuell nacheinander in das Gerät eingelegt werden.

Es wurden die benötigten mechanischen und elektronischen Komponenten aufgebaut und eine einfach zu bedienende Benutzerschnittstelle programmiert (Abbildung 26, rechts). Nach Eingabe der Größe des Messbereichs auf der Probe und der Anzahl der gewünschten Messpunkte werden die einzelnen Messpositionen auf der Probe angefahren, und es werden Dicke und Breite gemessen. Die Ausgabe der Messwerte erfolgt über eine USB-Schnittstelle als Textdatei. Eine Weiterverarbeitung mit Hilfe eines Python-Skripts ermöglicht die Berechnung von z.B. Mittelwerten.




Abbildung 26: Mechanisches Probenvermessungssystem. Links: Messtaster mit eingelegter Probe. Rechts: Steuergerät.

AP7: Demonstrator

AP7.2: Komponententests an Kunststoff-Demonstratoren

Für die Validierung der Modelle sind im AP7 Versuche an unterschiedlichen Demonstratoren vorgesehen. Im crashrelevanten Geschwindigkeitsbereich fanden am EMI Versuche an einer von Mercedes-Benz zur Verfügung gestellten Crashbox aus dem im Projekt untersuchten Kunststoff statt. Um das genaue Versuchssetup festzulegen, wurden vorab Simulationen mit unterschiedlichen Impaktorgeometrien durchgeführt und anschließend mit dem im AP5.1 entwickelten Python-Tool analysiert (siehe Abbildung 27). So ist beispielsweise in Abbildung 27 zu erkennen, dass für das Setup 1 die unterschiedlichen Dehnungszustände (dargestellt durch die schwarzen Punkte) wesentlich gleichmäßiger verteilt sind als beim Setup 2 (erkennbar am Verlauf der farbigen Isolinien). Ziel dieser Untersuchung war es, einen Validierungsversuch zu finden, bei dem während der Belastung möglichst viele unterschiedliche und gleichmäßig verteilte Dehnungszustände in der Crashbox auftreten, um die Materialmodelle bei einer Vielzahl von Eingangsdaten (Dehnungszuständen) validieren zu können.




Abbildung 27: Fünf mögliche Versuchssetups, die analysiert wurden. Der Impaktor bewegt sich jeweils von oben nach unten. Die Diagramme zeigen die mit dem Python-Tool ermittelten Dehnungsverteilungen am Ende der Simulation.

Weitere Kriterien, die für die Bewertung der verschiedenen Versuchssetups herangezogen wurden, waren

1. eine hohe Sensitivität der Messwerte bezüglich der Materialparameter (damit Fehler im Materialmodell deutlich sichtbar werden) und
2. eine geringe Sensitivität der Messwerte bezüglich der Versuchsparameter (damit sich geringe Streuungen z.B. bei der Auftreffgeschwindigkeit oder dem Auftreffort des Impaktors nur wenig auf die Messwerte auswirken).

Am Ende dieser Analysen konnte das Setup 1 aus Abbildung 27 als geeignetster Validierungsversuch unter den fünf betrachteten Varianten identifiziert werden.

Dieser Versuch wurde anschließend an der Komponentencrashanlage des EMI durchgeführt. Hierbei wurde die Crashbox mit einem flachen Impaktor (Masse 472 kg) mit ca. 2.7 m/s getroffen. Abbildung 28 zeigt das Demonstratorbauteil vor und nach dem Versuch. Während der Versuche wurden die Verschiebung des Impaktors und die Kraft gemessen. Zusätzlich kamen zwei Hochgeschwindigkeitskameras zum Einsatz, mit denen die Deformation der Crashbox aus verschiedenen Blickwinkeln aufgezeichnet werden konnte. Mittels einer anschließend durchgeführten DIC-Messung wurden die Verschiebungen mehrerer Punkte auf der Crashbox mit hoher zeitlicher Auflösung ermittelt (siehe Abbildung 29), sodass für einen späteren Vergleich zwischen den Versuchen und den Simulationen auch das lokale Deformationsverhalten des Bauteils herangezogen werden kann.



Abbildung 28: Links: Crashbox vor dem Versuch. Rechts: Crashbox nach dem Versuch.




Abbildung 29: Mittels DIC gemessene Verschiebungen der acht farbig markierten Punkte auf der Crashbox. Der Impaktor trifft von rechts nach links auf das Bauteil.

AP7.4: Demonstratoren für Crashsimulation

Für die im AP7.2 experimentell untersuchte Crashbox wurde ein FE-Modell erstellt. Mercedes-Benz stellte hierfür die Geometrie des Demonstrators in Form eines CAD-Modells zur Verfügung, woraus am EMI in mehreren Arbeitsschritten (Geometriebereinigung, Vernetzung, Kontakte usw.) ein LS-DYNA-Modell generiert wurde.

Anschließend wurden Simulationen des Komponententests mit zwei unterschiedlichen klassischen Materialmodellen (*MAT_024 und *MAT_SAMP-1 aus AP1.1) durchgeführt. Es zeigt sich eine gute Übereinstimmung mit den Versuchsdaten bezüglich des Kraftverlaufs (Abbildung 30), auch wenn nicht alle Kraftpeaks/Plateaus exakt von der Simulation getroffen werden. Auch die lokalen Deformationen des Bauteils an den mittels DIC gemessenen Punkten lassen sich gut mit der Simulation abbilden. Im Rahmen dieser Simulationen mit klassischen Materialmodellen konnte auch der Einfluss verschiedener Aspekte der Materialmodellierung (plastische Volumenkonstanz $\leftrightarrow$ Volumendilatation, Dehnratenabhängigkeit $\leftrightarrow$ dehnratenunabhängiges Fließen) auf die Ergebnisse untersucht werden. Es lässt sich festhalten, dass die verschiedenen Modellierungsvarianten nur einen geringen Einfluss auf die Ergebnisse haben.




Abbildung 30: Vergleich zwischen Crashbox-Versuchen (farbige Kurven) und Simulation mit klassischem Materialmodell (schwarze Kurve) anhand von Kraft-Weg-Kurven

Der Projektpartner IFB hat in einem nächsten Schritt das klassische Materialmodell aus AP1.1 durch ein ML-Modell ersetzt und die Simulation der Crashbox-Versuche erneut durchgeführt. Dieses ML-Modell wurde jedoch mit einem modifizierten klassischen Modell mit veränderter Fließkurve trainiert. Weiterhin enthält es kein Versagenskriterium. Demzufolge zeigt sich bei einem Vergleich eine gute Übereinstimmung der Simulationsergebnisse zwischen ML-Modell und zum Training verwendeten (modifizierten) klassischen Modell (Ground Truth). Man erkennt jedoch etwas größere Abweichung zu den Versuchsdaten.




Abbildung 31: Kraft-Weg-Kurven der Crashbox-Versuche (farbige Kurven) und Simulationen mit ML-Modell (schwarze durchgezogene Kurve) und klassischem Modell (Ground Truth, schwarze gestrichelte Kurve)

Diese sind hauptsächlich auf das fehlende Versagen zurückzuführen, was zu einem veränderten Verformungsverhalten des Bauteils führt. Dies ist in Abbildung 32 dargestellt. Es zeigen sich vor allem im späteren Versuchsverlauf (untere Reihe) deutliche Unterschiede zwischen Versuch und ML-Modell-Simulation.




Abbildung 32: Vergleich der Verformung der Crashbox 8 ms (oben) und 20 ms (unten) nach Versuchsbeginn. Von links nach rechts: Versuch → Simulation mit klassischem SAMP-Modell → Simulation mit klassischem Modell (Ground Truth) → Simulation mit ML-Modell

1.4 IFB

Im Rahmen des Projektes hat das Institut für Flugzeugbau explizit an den folgenden Arbeitspaketen gearbeitet:

- AP1.1: Klassische Charakterisierung und Modellierung eines Kunststoffs
- AP2.1: Schnittstellen

- AP2.2: Erzeugung simulativer Trainingsdaten für einen Kunststoff
- AP2.3: Erzeugung simulativer Trainingsdaten für ein Metall
- AP3.1: Entwicklung von ML-Modulen basierend auf Simulationsdaten
- AP3.2: Weiterentwicklung der ML-Module für Versuchsdaten
- AP4.1: Bestimmung der Vollständigkeit der Datenbasis
- AP4.2: Vergleich und Auswertung von State-of-the-Art ML Algorithmen
- AP4.3: Entwicklung von ML-Verfahren zur holistischen Materialmodellierung
- AP4.4: Evaluierung der Genauigkeit, Robustheit und Effizienz der Modelle
- AP4.6: Untersuchung von Transfer-Learning Verfahren zur Beschleunigung des Modellierungsprozesses
- AP5.1: Neuartige Charakterisierungsversuche für Kunststoffe
- AP5.2: Neuartige Charakterisierungsversuche für Metalle
- AP5.3: Untersuchungen zum Transferlernen
- AP6.1: Festlegung der zu automatisierenden Prozessanteile (Hardware)
- AP6.2: Entwicklung von Konzepten zur Automatisierung (Hardware und Software)
- AP6.3: Umsetzung der Automatisierungskonzepte (Hardware)
- AP6.4: Festlegung der zu automatisierenden Prozessanteile (Software)
- AP6.5: Entwicklung eines softwaregestützten Verfahrens zu Training und Validierung von ML-basierten Materialmodellen
- AP6.6: Aufbau und Anwendung von (teil)automatisierten Prozessen
- AP6.7: Evaluation
- AP7.1: Bereitstellung der ML-Materialmodelle und klassischer Materialkarten für Kunststoff und Metall
- AP7.2: Komponententests an Kunststoff-Demonstratoren

Nachfolgend werden die erbrachten Leistungen in den oben genannten Arbeitspaketen beschrieben und die Ergebnisse dargestellt.

AP1: Erzeugung klassischer Materialkarten

AP1.1: Klassische Charakterisierung und Modellierung eines Kunststoffs

Hintergrund der Erzeugung klassischer Materialkarten in AP1 ist es, eine Grundlage für möglichst realitätsnahe Simulationen der Materialeigenschaften der initial verwendeten Werkstoffe zu schaffen. Durch die kalibrierten und validierten klassischen Materialkarten wird für die nachfolgenden Arbeitspakete der experimentelle Aufwand deutlich reduziert, da statt der Durchführung realer Versuche auf simulative Versuchsdurchführungen zurückgegriffen werden kann. Im

Rahmen des AP1.1 wurden am IFB die quasi-statischen Zug- und Druckversuche für den Kunststoff Bayblend T65 XF durchgeführt. Die Zugversuche wurden aufgrund der Dehnratenabhängigkeit bei Dehnraten von 0,01 /s und 0,1 /s ergänzend zu den am EMI verwendeten hohen Dehnraten (1 /s, 10 /s, 100 /s) durchgeführt. Um lokale Dehnungen entlang der Probenoberfläche aus realen Versuchsdaten für die Materialmodellierung mithilfe der klassischen Materialmodelle *MAT_SAMP-1 und *MAT_024 messen zu können, wurden die Zugversuche mit DIC-Vollfeld-Dehnungsmessungen der im Rahmen dieses Projekts beschafften Systeme GOM Aramis 12M und GOM ATOS Core 185 unterstützt. Die verwendeten Komponenten sind in Abbildung 33 dargestellt.




Abbildung 33: Versuchsaufbau der quasi-statischen Zugversuche am IFB in AP1.1

Für die Druckversuche in AP1.1 wurden quaderförmige Probekörper und eine Dehnrate von 0,01 /s verwendet. Die Verschiebung des Druckstempels wurde hierbei mithilfe eines Videoextensometers gemessen, da die Probekörper zu klein für eine aussagekräftige DIC-Messung waren. Die Ergebnisse der Druckversuche, dargestellt in Abbildung 34, waren insbesondere für die Betrachtung der Zug-Druck-Asymmetrie des verwendeten Kunststoffs relevant. Der verwendete Versuchsaufbau ist in Abbildung 35 dargestellt.




Abbildung 34: Kraft-Weg-Diagramm von in AP1.1 durchgeführten Druckversuchen am IFB




Abbildung 35: Versuchsaufbau der quasi-statischen Druckversuche am IFB in AP1.1

Diese Versuche wurden verwendet, um ein klassisches Materialmodell für den Kunststoff anzupassen. Dies erfolgte durch das Fraunhofer EMI. Die Validierung auf Komponentenversuche konnte durch die Demonstratortests aus AP7 erfolgen.

AP2: Erzeugung simulativer Trainingsdaten

AP2.1: Schnittstellen

Für die Schnittstellen und Datenformate wurden seitens des IFB in diesem Arbeitspaket die Definitionen gemeinsam mit EMI, MB, Renumics und IFU erarbeitet. Hierfür wurden in einem GIT-Repository Programmcode gemeinsam geschrieben und als Resultat steht nun ein komplettes Programmpaket zur Verfügung mit dem sich Trainingsdaten aus Simulationen erstellen lassen. Spezifisch seitens des IFB wurde die automatische Extrahierung der Daten aus den Simulationsdaten definiert und umgesetzt, die Data-Augmentation durch Rotation der Spannungs-/Dehnungspfade beschleunigt und das Ablageformat nach einem Benchmark definiert. Werkstoffe können dynamisch gewählt werden und die Pfad-generatoren wurden in einem durchgängigen Prozess eingebunden, der die Trainingsdaten für das ML-Training ablegt. So können nun einmal erzeugte Pfade mehrfach verwendet werden z.B. für Belastungen zu unterschiedlichen Vergleichsdehnungen, indem der Pfad skaliert wird, auch Material-übergreifend. Dies wird die Laufzeit deutlich verringern, und es wird ermöglicht schneller Trainingsdaten zu generieren.

Des Weiteren wurde das in LS-DYNA implementierte MAT_81 (elasto-plastisch mit Schädigung) in Python übersetzt, sodass hiermit nun ohne Durchlaufen von FE-Simulationen oder des IMMD direkt Spannungsantworten des Materialmodells bei vorgegebenen Dehnpfaden erhalten werden können. Dies entkoppelt die Trainingsdatengenerierung weiter von zeitaufwändigen FE-Durchläufen und erlaubt sogar die Generierung von Daten während des Trainings. Daneben

kann dieses klassische MAT_81 verwendet werden, um die LS-DYNA User-Material Schnittstellen zu validieren, z.B. das IFB UMAT, das bereits im BMWK-geförderten Projekt DigiBody entwickelt wurde und in diesem Projekt weiterentwickelt wird.

AP2.2: Erzeugung simulativer Trainingsdaten für einen Kunststoff

Weiterhin wurden vom IFB alternative Methoden zur Erzeugung von sim. Trainingsdaten mit dem Material-Model-Driver (MMD) gezeigt (präsentiert auf LS-Dyna Konferenz 2021). Der in LS-Dyna integrierte Material-Model-Driver kann nun automatisiert angesteuert werden und kann auch generische Dehnpfade und die daraus resultierende Spannungsantwort erzeugen (siehe Abbildung 36). Dieser automatisierte MMD wurde bereits im vorangegangenen Projekt DigiBody genutzt und wurde nun für AIMM erweitert.

Somit stehen aus AP2.1 nun zwei Methoden bereit, um Materialmodelle auf Basis von maschinellem Lernen zu erzeugen (in AP3 und AP4).

Für den Kunststoff wurden die Trainingsdaten auf Basis der in AP1 entwickelten Anpassungen erzeugt und bereitgestellt.




Abbildung 36: Dehnpfade aus dem Material Model Driver

AP2.3: Erzeugung simulativer Trainingsdaten für ein Metall

Für die beiden Metallwerkstoffe (DP800 und DP600) wurden die Trainingsdaten auf Basis der in AP1 entwickelten Anpassungen unter Verwendung der vorher entwickelten Methoden erzeugt und bereitgestellt.

AP3: Hybride Materialmodelle

AP3.1: Entwicklung von ML-Modulen basierend auf Simulationsdaten

Vorrangig zum Ziel der ML-Materialmodellierung geführt hat die Hybridisierung des Modells. Dickenkomponenten der Spannungen werden nun in einem hybriden Ansatz berechnet, ge-

nauso wie die Dickendehnung. Diese werden nicht vom Modell vorhergesagt, da sie aus Experimenten nicht ermittelt werden können und daher nicht Teil des Erfahrungsraumes des ML-Trainings sein können. Stattdessen werden diese nach der Spannungsprognose klassisch hinzugefügt, wie es auch hergebrachte Modelle in LS-Dyna implementieren. Hierfür sind zwei klassische Parameter nötig, die allerdings aus den Werkstoffversuchen direkt erfassbar sind. Dieser Ansatz wurde in die Softwareumgebung des Projektes eingebunden und kann nun zu den Modellen zugeschaltet werden. Darüber hinaus wurden weitere Architekturen in einer Studie, v.a. mit den Partnern Renumics und Mercedes-Benz durchgeführt. Die besten Modelle zeigt Abbildung 1 mit den mittleren Fehlern auf unterschiedlichen Validierungsdaten. Dabei zeigen die Modelle mit hybridem Ansatz die geringsten Fehler. Die Modelle mit LSMCC-Architektur schneiden am Besten ab und wurden deshalb und wegen weiterer Vorteile im Folgenden weiterverwendet.

In Abbildung 37 ist der Demonstrator von ElringKlinger berechnet am IFB mit den beiden besten Modellen aus vorheriger Tabelle im Vergleich zum klassischen Modell (mittig) gezeigt. Die Übereinstimmung im Spannungsfeld und den globalen Größen sind gut. Damit liegt ein lauffähiges, trainiertes Modell für den Metallwerkstoff vor.




Abbildung 37: Wanne DP800: LSTM vs MAT_024 vs LMSCc

Die Demonstratoren Hutprofil, Crashbox und Kreuznapf wurden ebenfalls erfolgreich am IFB mit den ML-Materialmodellen gerechnet und validiert. Das Training erfolgte analog für einen alternativen, etwas schwächeren Werkstoff DP600. Dieser liegt nun ebenfalls als vortrainiertes, validiertes Modell für den Einsatz im Demonstrator vor.

AP3.2: Weiterentwicklung der ML-Module für Versuchsdaten

Um Materialmodelle auf Basis neuronaler Netze auf Versuchsdaten zu trainieren, wobei die klassische Spannungsantwort unbekannt ist, wurde im Projekt mit großer Beteiligung des IFB bereits eine Strategie entwickelt, die auf virtuellen Versuchsdaten großes Potenzial zeigt und

eine technische Neuheit darstellt. Sie wurde zum Ende des Berichtszeitraums als Peer-Review Paper im Fachjournal Computer Methods in Applied Mechanics and Engineering akzeptiert und dokumentiert.

Ein rudimentäres ML-Modell, welches auch nichtlineares Verhalten abbildet, konnte bereits auf ein virtuelles neues Material auf dieser Basis umtrainiert werden und damit die in der Veröffentlichung gezeigte Methodik auch für komplexeres Verhalten als linear-elastisches angewendet werden.

Die Arbeiten am Training auf realen Versuchsdaten wurden am IFB weitergetrieben und die Fehlerfunktionen auf den Messungen mit Digitaler Bildkorrelation formuliert. Hierzu ist noch eine weitere Validierung erforderlich, dass die Fehler tatsächlich beim korrekten Modell am niedrigsten sind, erste Tests zeigen aber gut Ergebnisse. Essentiell hierfür ist, dass ein Basismodell zur Verfügung steht, welches auf simulativen Daten vortrainiert ist. Hierzu laufen die Arbeiten in AP4 weiter, sobald diese abgeschlossen sind, kann das Training auf Versuchsdaten erfolgen. Die Softwarewerkzeuge aus diesem AP sind nun alle bereit für die Verwendung in AP4.6.

AP4: Holistische Materialmodelle

AP4.1: Bestimmung der Vollständigkeit der Datenbasis

An der Universität Stuttgart wurden gemeinsam von IFU und IFB die Definition von zu erwartenden physikalischen Werten in den Daten vorgenommen. (Siehe auch Bericht IFU speziell für die Materialklasse Stahl). Die generell zu erwartenden Daten im Training sind:

- Virtuell:
 - o Dehnungen & Spannungen am Integrationspunkt aus eloutdet
 - o Im MaterialKOS, nötige Keywords/Einstellungen definiert
 - o In Schnittstellen und Datenformate (AP2) eingeflossen
 - o ggfs. für Training ohne FE relevant: auf Knoten extrapolierte Daten
- Versuch (reell und virtuell):
 - o Kraftverlauf
 - o Dehnung: (DIC) Vollfeld (Export zu AIMM-Schnittstelle möglich (AP2))
 - o (ATOS-)Probenvermessung

Diese sind bereits in die Schnittstelle in AP2 eingegangen. Zu betrachten für die weiteren Arbeiten in den APs sind dadurch:

- Was sind ausreichende Trainingsdaten zur Beschreibung der Effekte im Material – mindestens wie im Basismodell: Ziel: Vermeiden von Lücken oder Bias in den Trainingsdaten.

- o Elastisches Verhalten: ausreichende Datenmenge im elastischen Bereich in Form von Be- und Entlastungen bei unterschiedlichen Spannungsverhältnissen
- o Plastisches Verhalten: Erfordert ein ausreichendes Fließen der Materialpunkte unter unterschiedlichen Spannungsverhältnissen
- o Verfestigungsverhalten: Erfordert Änderung des Spannungsverhältnisses beim Fließen (plastische Verformung).
- o Schädigung & Versagen: Die Abhängigkeit der Schädigung und des Versagenspunktes vom Spannungszustand (Triaxialität) soll erfasst werden können
- Übertrag der Erkenntnisse zu AP5 (neue Versuchsgeometrien/Training aus Versuchsdaten), um diese Daten mit den Versuchen abzudecken.

AP4.2: Vergleich und Auswertung von State-of-the-Art ML Algorithmen

Für den Vergleich und Auswertung von State-of-the-Art ML Algorithmen wurde das am IFB entwickelte User-Materialmodell in AIMM vorgestellt und erweitert. Dies und die MMD-Strategie wurde verwendet, um MLMM zu trainieren (u.a. auch auf der LS-Dyna Konferenz gezeigt).

Für den Kunststoffwerkstoff konnte damit ein MLMM basierend auf einem rekurrenten Neuralen Netz mit Gated Recurrent Units gezeigt werden. Abbildung 38 zeigt die Spannungsantwort des originalen, analytischen Materialmodells (MAT_SAMP in LS-Dyna) und die Anpassung des Rekurrenten MLMM.

Für den Kunststoffwerkstoff konnte damit ein MLMM basierend auf einem rekurrenten Neuralen Netz mit Gated Recurrent Units gezeigt werden. Die folgende Abbildung zeigt die Spannungsantwort des originalen, analytischen Materialmodells (MAT_SAMP in LS-Dyna) und die Anpassung des Rekurrenten MLMM.




Abbildung 38: Antwort des original Modelles MAT_SAMP und des MLMM auf RNN-basis auf 1000 Schritten

Die bereits gute Anpassung kann durch weiteres, besseres Einstellen der Hyperparameter des MLMM noch weiter verbessert werden, zeigt aber bereits das Potential und die Lernfähigkeit der rekurrenten Netze eines solch komplexen Materialverhaltens. Das größte Problem stellt aber die Abhängigkeit von Schrittweiten, bzw. Pfadlänge, dar. Für eine deutlich höhere Schrittzahl (200.000 statt 1.000) kann das MLMM keine korrekte Prognose mehr liefern.

Dies konnte durch Extrapolation der zu kleinen Dehnungen und Rücktransformation der Spannungen gelöst werden, sodass es auch auf kleinen Inkrementen zu einer korrekten Prognose kommt, wie in Abbildung 39 zu sehen:




Abbildung 39: Antwort des original Modelles MAT_SAMP und des interpolierten MLMM auf RNN-basis auf 200.000 Schritten

Des Weiteren, neben der Evaluierung von etablierten rekurrenten Netzen, wurde die neuartige Adaption von LSTM, der Minimal State Cell (Bonatti/Mohr 2021) analysiert und evaluiert.

AP4.3: Entwicklung von ML-Verfahren zur holistischen Materialmodellierung

Eine Parameterstudie zur Modellierung des Materialverhaltens inkl. Plastizität und Implementierung in LS-Dyna wurde durchgeführt. Dazu wurde das elasto-plastische Materialmodell mit von-Mises Fließbedingung (MAT_24 in LS-Dyna), kalibriert auf den im Projekt betrachteten Kunststoff Bayblend, genutzt. Rekurrente neuronale Netze (RNN) wurden aufgrund der im Materialmodell vorhandenen Pfadabhängigkeit verwendet, um auch das plastische Verhalten abbilden zu können. Eine Normalisierung der Trainingsdaten wurde durchgeführt. Lediglich Schalenformulierungen mit ebenem Spannungszustand wurden betrachtet und die Dickendehnung nicht berücksichtigt. Die betrachteten Netze sollen den Zusammenhang zwischen Dehnungen und Spannungen erlernen:

Die Trainingsdaten wurden mit dem Material Model Driver in LS-Dyna auf Basis von Random Walking Pfaden generiert. Diese bilden zufällig Dehnpfade ab, die bis zu einer definierbaren Vergleichsdehnung wachsen dürfen und dann umkehren müssen. Hierauf wurde eine Hyperparameterstudie durchgeführt, um die beste Netzarchitektur zu erfassen. Dazu wurden die in Tabelle 1 aufgeführten Parameter variiert und deren Lernergebnis bewertet. Die gewählte Parameterkombination ergab sich dort, wo die Fehlerfunktionen am niedrigsten sind.

Tabelle 1: Varianten und Ergebnis der Hyperparameterstudie

Studie	Untersuchte Varianten	Ergebnis
1. Anzahl Neuronen	20; 200; 400; 800; 1600; 2400	800
2. Anzahl Schichten	2; 4; 6; 8; 10; 12	2
3. Netzarchitektur	[GRU800]; [Dense800]; Alle 2-Schicht-Permutationen mit 400 Neuronen pro Schicht; Alle 3-Schicht-Permutationen mit 267 Neuronen pro Schicht	[GRU800]; [GRU400-GRU400]
4. Neuronenverteilung	[GRU100-GRU700]; [GRU200-GRU500]; ...; [GRU700-GRU100]	Keine relevanten Unterschiede

Die gefundene Modellarchitektur wurde darauffolgend auf die Performanz bei unterschiedlicher Gestaltung der Ein- und Ausgabegrößen validiert:

- $\varepsilon \rightarrow \sigma$
- $\Delta \varepsilon \rightarrow \Delta \sigma$
- $\Delta \varepsilon \rightarrow \Delta \sigma$ (Training Loss auf σ).

Die Validierung der Modelle erfolgt dreistufig:

- auf vorgegebenen Dehnpfaden aus dem Validierungsset
- auf Dehnpfaden extrahiert aus Simulationen
- in der Simulation (mit Hybridisierung)

Diese dreistufige Validierung ist essenziell, da in der ersten Stufe nur geprüft wird, wie gut das Modell bisher ungesehene Trainingsdaten vorhersagen kann. In der zweiten Stufe, dem sog. Simulations-Zoo, werden dann im Vergleich zu den Trainingsdaten verschieden verlaufende Pfade aus Simulationen extrahiert und außerhalb der Simulation in das Modell gegeben. Erst in der dritten Validierungsstufe läuft das ML-Modell direkt in der FE-Simulation, worin zum ersten Mal der Dehnpfad nicht fix vorgegeben ist (sondern nur durch globale Verschiebungen gesteuert wird). Hier kann durch die Fehlerfortpflanzung im Modell ein anderer Dehnpfad herauskommen und das Modell deutlich schlechtere Ergebnisse liefern als in den vorherigen Validierungsstufen.

Diese Validierungsmethodik ist erweiterbar durch die ganze klassische Validierungspyramide von Ein-Element-Simulationen über Prüfkörper bis zu Bauteilen.

Die Ergebnisse der ML-Modelle mit unterschiedlichen Ein- und Ausgaben wurden evaluiert auf den drei Validierungsstufen.

Als Fazit kann gezogen werden:

- Eine gute Spannungsprognose auf vordefinierten Dehnpfaden aus dem Validierungsset dem Trainingsdatenpool kann mit allen Modellen erreicht werden.
- Dort funktioniert die Verwendung von absoluten Größen am besten, bei Verwendung von inkrementellen Größen wurde eine Verbesserung erreicht, wenn die Fehlerfunktion auf absoluten formuliert wurde.
- Die Extrapolation von Random-Walking-Pfaden auf Single-Element-Pfad funktioniert
- Performance auf vordefinierten Pfaden $\neq$ Performance in der FE-Simulation

Gerade der letzte Punkt stellt ein wichtiges Hindernis dar, der zulässige Fehler muss hier weiter quantifiziert werden, damit schon außerhalb der Simulation eine Bewertung des Netzes hinsichtlich seiner Lauffähigkeit in der Simulation möglich ist.

AP4.4: Evaluierung der Genauigkeit, Robustheit und Effizienz der Modelle

Die Generatoren zur Erstellung der Trainingsdaten aus klassischen Materialmodellen wurden am IFB weiterentwickelt. Die bisherigen Methoden wurden verbessert und erweitert. Es ist nun keine Simulation notwendig, um die Spannungsantwort zu erhalten, sondern sie kann direkt aus der Materialroutine entnommen werden. Hierfür muss diese als Code vorliegen, dies bietet aber den Vorteil, dass die Spannungsantwort schnell und direkt aus der Routine kommt. Hier wurden im Laufe des Projektes Überlagerungen aus dem FE-Zyklus festgestellt, die die Spannungsantwort, die direkt aus dem Materialmodell kommt, und erlernt werden soll, verfälschen.

Auch zur Analyse der Trainingsdaten wurden Analysetools entwickelt und bereitgestellt.

Für die Anwendung der ML-Modelle innerhalb von LS-Dyna liegt nun auch Code vor, der dynamisch die trainierten Netze einbindet und über die Kommunikationsschnittstelle die Skalierung, Prognose und Rückgabe übernimmt. Diese steht im gemeinsamen Projekt GIT zur Verfügung.

AP4.6: Untersuchung von Transfer-Learning Verfahren zur Beschleunigung des Modellierungsprozesses

Vorrangig lag hier der Fokus auf Konzepten für FE-freies Verfahren zum Training auf Versuchsdaten, was die größte Hürde zur serienreifen Anwendung, für die in AIMM angestrebte Materialmodellierung auf maschinellem Lernen darstellt. Am IFB wurden (teilweise in sehr enger Zusammenarbeit) vier Konzepte für die Entkopplung der Machine-Learning-Materialmodelle (MLMM) von simulativen, virtuellen Trainingsdaten vorgestellt, wie in Abbildung 40 zu sehen. Diese Konzepte sind nun Basis zur weiteren Arbeit in AIMM und ermöglichen das ausschließliche Nutzen von Trainingsdaten, die auch im physischen Versuch zur Verfügung stehen.




Abbildung 40: Möglichkeiten zur Modellbildung und Training

Versuchsdaten als Input: Das MLMM prognostiziert weiterhin die Spannungen auf Basis der Dehnungen (wie auf virtuellen Versuchsdaten). Nun werden aber zusätzlich die Versuchsdaten als Eingang in das neuronale Netz mitgegeben, womit unterschiedliche Spannungsantworten auf dieselben Dehnungen bei verschiedenen Materialien abgebildet werden können. Wird am IFB weiterverfolgt.

Externe Optimierung: Gemeinsame Arbeit im Konsortium mit EMI, MB, MB (Renumics), DYN, IFU und IFB. Hier werden die Gewichte der MLMM extern optimiert (Arbeit MB) und solange angepasst, bis die Loss-Funktion auf Versuchsdaten erfüllt ist (Arbeit EMI, IFB). Hierfür wurden am IFB Programme entwickelt, die diese Loss-Funktion berechnen (Divergenz Sigma, Kraft), siehe Abbildung 41).




Abbildung 41: Berechnung Divergenz der Spannungen in Python auf Versuchsdaten

Self-Sim DIC: Diese Methode nutzt eine iterative Anpassung des MLMM an Versuchsdaten und kombiniert dehnungs- und kraftgesteuerte Nachsimulation von Versuchen.

Reinforcement Learning: Beim Reinforcement Learning werden die Netze nicht klassisch mit bekannten Ergebnissen trainiert, sondern korrekte Ergebnisse werden durch Adaption von vorgegebenen Parametern mit Belohnung erreicht.

Da im Versuch nur das Dehnungsfeld (durch optische Messung) und die globale Kraft zur Verfügung stehen und explizit keine Spannungen lokal ermittelbar sind, ist klassisches „Supervised Learning“ nicht möglich – sprich das Demonstrieren von korrekten Dehnung-Spannungspaaren im Training kann nicht erfolgen.

In enger Zusammenarbeit mit allen Projektpartnern (außer TU Berlin) ist eine Methode entstanden, die bereits in einem Journal Paper Preprint unter Führung des IFB eingereicht wurde (Veröffentlicht 19.01.2023, Computer Methods in Applied Mechanics and Engineering).

Kern ist eine, von mehreren im Projekt verfolgten Methoden, wahrscheinlich die vielversprechendste Methode, für das Training auf Versuchen. Abbildung 42 zeigt die Methode grob auf. Ein (auf simulative Trainingsdaten, AP2) vortrainiertes MLMM prognostiziert das Spannungsfeld auf Basis des Inputs des (im Versuch gemessenen) Dehnungsfeldes. Hierauf wurden am

IFB – mit starker Unterstützung v.a. des EMI, IFU, Dynamore und Mercedes-Benz – Fehler-Funktionen entwickelt, welche die Spannungsprognose des MLMM hinsichtlich der Erfüllung der mechanischen Gleichgewichtsbedingungen und Kraft-Randbedingungen bewertet. Mittels dieser Bewertung kann dann das vortrainierte MLMM so lange optimiert werden, bis die Loss-Funktion minimiert ist. Diese „externe“ Optimierung aktualisiert die Gewichte des MLMM nicht wie im klassischen „Supervised Learning“, sondern durch eine besondere zweistufige Optimierungsstrategie trainiert, welche vorrangig bei Mercedes-Benz entwickelt wurde.




Abbildung 42: Optimierung des MLMM auf Versuchsdaten

Hierzu wurde eine Code-Basis geschaffen, welche (virtuelle) Versuche ohne FE-Zyklus bewerten kann. Abbildung 43 zeigt diesen Prozess nochmals detaillierter.




Abbildung 43: Prozess zur MLMM-Optimierung auf Versuchsdaten

Für Hooke'sche Materialien konnte hier gezeigt werden, dass eine Optimierung auf Daten, die auch in der Realität im Versuch erfassbar sind, möglich ist. Abbildung 44 zeigt die Optimierung eines Netzes. Links ist die Loss-Funktion über die Optimierungsiterationen aufgetragen. Im rechten Diagramm werden das vortrainierte Modell, welches die zu erwartenden experimentellen Dehnungs-Spannungsverläufe nicht korrekt wiedergibt, und das resultierende Modell nach der Optimierung gezeigt.




Abbildung 44: Optimierung eines MLMM auf Basis Versuchsdaten

Weitere Schritte und technische Details sind in der dazugehörigen Veröffentlichung nachzulesen, welche den Umfang dieses Berichtes überschreiten. Schlussendlich konnte das mit dieser Methodik trainierte Modell auch in der IFB-UMAT innerhalb LS-Dyna laufen und so im finalen Einsatzbereich gegen das klassische Modell bestehen, wie in Abbildung 45 ersichtlich.




Abbildung 45: Simulation Scherzugprobe mit MLMM und klassischem Modell in LS-Dyna

Weitere Methoden wie die Auto-P Methode wurden auch weiterverfolgt. Sie zeigt vielversprechende, auf den Projekttreffen gezeigte Ergebnisse, birgt aber Limitierungen, welche die pseudogradient-ES Methode mit den Loss-Funktionen nicht einschränkt.

AP5: Neuartige Charakterisierungsversuche für das Training von KI-Modellen

AP5.1: Neuartige Charakterisierungsversuche für Kunststoffe

Für das AP5.1 wurde am IFB mehrere Ansätze verfolgt, um eine Probengeometrie für Kunststoff-Charakterisierungsversuche zu finden, die bei uniaxialer Zugbelastung komplexe Deh-

nungszustände erzeugt. Dadurch soll ermöglicht werden, die für eine effiziente Materialmodellierung notwendige Anzahl an Versuchstypen zu reduzieren und damit den Versuchsaufwand erheblich zu reduzieren.

Zur Bewertung der erzeugten Probengeometrien wurden Simulationen basierend auf der Materialkarte aus AP1 durchgeführt und anschließend die effektive plastische Vergleichsdehnung ϵ_{eff} über der Triaxialität η geplottet. Basierend auf den Triaxialitätswerten wird ersichtlich, welchen Spannungszustand die einzelnen Mesh-Elemente im Zugversuch in Abhängigkeit der Dehnung erfahren. Wie in Abbildung 46 dargestellt verläuft die Belastungsrichtung der Mesh-Elemente einer klassischen Zugprobe in dieser Darstellungsmethode bei uniaxialer Zugbelastung mit zunehmender Dehnung und Deformation vom uniaxialen Zugbelastungszustand ($\eta=1/3$) in Richtung der biaxialen Zugbelastung ($\eta=2/3$).




Abbildung 46: Effektive plastische Vergleichsdehnung über der Triaxialität für eine klassische Zugprobe

Für die neuartige Probengeometrie soll hingegen erreicht werden, dass trotz global uniaxialer Zugbelastung lokale Mesh-Elemente auf Druck und Schub belastet werden, bei möglichst hohen plastischen Vergleichsdehnungen. Dies entspricht in der verwendeten Darstellungsmethode im Diagramm, dass möglichst im gesamten Triaxialitätswertebereich Pfade einzelner Elemente auftreten sollen. Zusätzlich sollen die Werte der effektiven plastischen Vergleichsdehnung möglichst hoch werden, damit für die ML-Materialmodellierung eine hohe Anzahl an Trainingsdaten basierend auf Spannungs-Dehnungs-Korrelationen generiert werden. Als „gut“ geeignete Probengeometrien werden in diesem Zusammenhang jene klassifiziert, die die in Abbildung 46 eingezeichneten Bereiche für auftretende Druck- und Schubbereiche abdecken können. Die größten Herausforderungen zur Findung einer geeigneten Probengeometrie bestanden in folgenden drei Fragestellungen:

- Auf welcher Basis optimiert man die Geometrien?

- Wie erzeugt man bei global uniaxialer Zugbelastung lokal auch bei hohen Dehnungen Druckbereiche?
- Welche Geometrien sind für reale Probekörper realisierbar?

In einem ersten Ansatz wurde die parametrisierte Erzeugung von Probengeometrien untersucht, bei der die in AP1 verwendete Kunststoff-Zugprobengeometrie mit unterschiedlichen Taschengeometrien basierend auf verschiedenen geometrischen Basisstrukturen versehen wurde. Hier wurden bei einer Vielzahl von betrachteten Geometrien jedoch keine zufriedenstellenden Ergebnisse erzielt, da die Geometrieerzeugung stärker auf das Ziel der komplexen Dehnungszustände ausgerichtet werden musste. Zudem hatte sich herausgestellt, dass die verwendeten Außenabmessungen der gewählten Probengeometrie zu klein waren, um effiziente Taschengeometrien zu platzieren.

Ein weiterer Ansatz zum Finden einer neuartigen Probengeometrie mit komplexen Dehnungszuständen bestand darin, die Geometrie durch iterativ optimiertes Löschen von Mesh-Elementen zu erzeugen. Hierbei wurden erste Versuche ausgehend von einer manuell erzeugten Basisgeometrie durchgeführt, bei der initial hohe Druckspannungen durch aufgebrachte Lasten in Zugrichtung herrschen sollen. Die verwendete Basisgeometrie ist in Abbildung 47 dargestellt.




Abbildung 47: Manuell erzeugte Basisgeometrie für Optimierung durch Mesh-Elemente Löschung; grau markiert sind die Auswertungsbereiche, an denen die höchsten Druckspannungen zu erwarten sind

Als Werkzeug zur Optimierung wurde die Software LS-TaSC gewählt. Mithilfe dieses nichtlinearen Topologieoptimierers wurde der Ansatz untersucht, neue Probengeometrien durch gezieltes Löschen beziehungsweise der Zuweisung von Pseudosteifigkeiten von Mesh-Elementen zu finden, bei denen unter Zugbelastung zunächst Schubspannungen und schließlich Druckspannungen auftreten. Als Optimierungsziel wurde hierbei eine Probe mit prozentual zur jeweiligen Festigkeit gleichmäßigen Dehnungen in allen Belastungsrichtungen und Arten definiert, die bestenfalls nicht vorzeitig lokal versagt. Die Auswertung wurde an einer Stelle ausgeführt, an der hohe Druckspannungen erwartet wurden (grau markierte Bereiche in Abbildung 47). Beim Aufbringen einer Verschiebung in Zugrichtung wurde als Optimierungszielfunktion die Minimierung der Spannungen bei einer Maximierung der Druckspannung im Auswertebereich definiert. Die mit diesen Vorgaben iterativ erzeugte Probengeometrie ist in Abbildung 48 dargestellt. Auffallend ist bei diesem Ergebnis, dass insbesondere die Maximierung der Druckspannung im

Auswertebereich nach wenigen Iterationen stagniert (siehe Abbildung 48 rechts), während der Optimierungsalgorithmus in den nachfolgenden Iterationen die Minimierung der Masse weiter optimieren kann.




Abbildung 48: Iteratives Löschen von Mesh-Elementen – Ergebnisse Variante 1

Als zweite Variante der Optimierung wurde bei gleichen Randbedingungen wie in der ersten Variante pro Iteration insgesamt 3 Optionen ausgerechnet, und die beste (mit der maximalen Druckspannung) mittels Sensitivitätsanalyse ausgewählt. Die Ergebnisse dieser Optimierung sind in Abbildung 49 dargestellt.




Abbildung 49: Iteratives Löschen von Mesh-Elementen – Ergebnisse Variante 2

Die Auswertung beider Varianten zeigt, dass eine weitreichendere Definition des Optimierungsziels ausgearbeitet werden muss, um den Algorithmus des Topologieoptimierungstools zur Erzeugung einer passenden Probengeometrie sinnvoll nutzen zu können. Eine der größten Herausforderungen besteht unter anderem darin, das Optimierungsziel auf auftretende Spannungen innerhalb des Probekörpers, statt auf Minimierung der Masse zu lenken. Was bei dieser

Methode jedoch vernachlässigt werden musste, ist die Fertigbarkeit der erzeugten Probengeometrien für reale Versuchsdaten.

Für weitere Untersuchungen wurde der Aspekt der Fertigung realer Probekörper stärker betrachtet. Da der in AIMM verwendete Kunststoff Bayblend T65 XF beim Projektpartner Elring-Klinger im Spritzgussverfahren als homogene Platte hergestellt wurde, sind die Probekörper im Fräsverfahren gefertigt worden. Zusätzlich wurden zur schnelleren Durchführbarkeit von realen Versuchen neuer Geometrien Probekörper additiv mittels Stereolithografieverfahren gefertigt, die ebenfalls isotropes Materialverhalten aufweisen. Bei neuen Taschengeometrien wurde deshalb darauf geachtet, dass keine Hinterschnitte oder zu geringe Krümmungsradien für die Aussparungen verwendet wurden. In einem ersten Schritt wurden dazu elliptische Basisgeometrien parametrisiert erzeugt, die in der Ausdehnung, Anzahl und Ausrichtung variiert wurden. Ausgewählte Simulationsergebnisse sind in Abbildung 50 dargestellt.




Abbildung 50: Dehnungs-Triaxialitäts-Diagramme für verschiedene elliptische Taschengeometrien

Die in Abbildung 50 dargestellten Ergebnisse sind charakteristisch für die untersuchten ellipsenbasierten Taschengeometrien und weisen im Vergleich zu einer klassischen Zugprobe (siehe Abbildung 46) hohe Dehnungen im Bereich der Zugbelastung auf, jedoch erhält man keine Elemente, die auf Druck belastet werden. Diese Taschengeometrien sind daher gut geeignet zur Datengenerierung von Zugspannungs-Dehnungs-Korrelationen bei der Kombination mehrerer Versuchstypen (siehe EMI-Ansatz für AP5.1), jedoch nicht für komplexe Dehnungszustände inklusive Druck- und Schubbereichen. Eine Abwandlung der ellipsenbasierten Taschengeometrien hin zu tragflügel-ähnlichen Geometrien (siehe Abbildung 50 unten rechts) führte ebenfalls zu hohen Dehnungen für Zugbelastungen und zusätzlich zu einem gewissen Anteil an Schubbereichen. Jedoch hatte sich auch bei dieser Basisgeometrie keine Variante gefunden, die ebenfalls Druckbereiche ausreichend gut abdeckt.

Erstmals ausgeprägte Druck- und Schubbereiche ließen sich mithilfe von L-förmigen Taschengemetrien erreichen, wie in Abbildung 51 visualisiert ist. Die Dehnungen sind verglichen zu den ellipsenbasierten Geometrien geringer, jedoch lassen sich klar abgestufte Bereiche mit Druck und Schub in den Diagrammen erkennen. Außerdem hatte diese Geometrie das Potential, als realer Probekörper gefräst zu werden. Im realen Versuch trat bei dieser Variante jedoch Torsion in der Probenmitte auf, weshalb diese Geometrie nicht weiterverfolgt werden konnte.




Abbildung 51: Dehnungs-Triaxialitäts-Diagramm sowie EMI-Auswertung für L-förmige Taschengemetrie

Die finale Herangehensweise zur Erzeugung einer Probekörpergeometrie wurde schließlich in der Verwendung von Knickmechanismen gefunden. Ähnlich wie bei nachgiebigen Systemen wird der Probekörper mithilfe von Aussparungen in mehrere Stege unterteilt, die durch den Knickmechanismus neben hohen Zugspannungen ebenfalls die Entstehung von Bereichen mit Druck- und Schubbelastungen begünstigen sollen. Für diese Methode wurden diverse Geometrien erzeugt, die simulativ vielversprechende Ergebnisse aufgewiesen haben mit hohen plastischen Vergleichsdehnungen im Druckbereich, sehr hohen Dehnungen im Zugbereich und akzeptablen Ergebnissen im Schub. Beispielhaft sind die Ergebnisse von zwei Geometrien in Abbildung 52 dargestellt.




Abbildung 52: Dehnungs-Triaxialitäts-Diagramme für zwei Knickmechanismus-Taschengemetrien

In den realen Versuchen hat sich bei diesen Geometrien jedoch gezeigt, dass die Knickmechanismen zwar wie in der Simulation funktionieren, allerdings war die Stegbreite nicht ausreichend für eine zufriedenstellende DIC-Messung. Für die finale Probekörpergeometrie wurde deshalb die Proben- und Stegbreite nochmals erhöht. Die Geometrie ist in Abbildung 53 oben zu sehen.

Durch Zugbelastung werden die inneren Stege nach innen geknickt, was zum Auftreten von Druck auf der nach außen gerichteten Seite der inneren Stege führt (in Abbildung 53 unten als blaue Bereiche zu erkennen). Die äußeren Stege hingegen sorgen für hohe Zugbelastungen. Durch die Anordnung der Aussparungen entstehen zusätzlich Bereiche mit Schubbelastungen.




Abbildung 53: Finale Probekörpergeometrie aus AP5.1 am IFB während des simulativen Zugversuchs

Die Visualisierung der Simulationsergebnisse sowohl nach IFB- als auch EMI-Methode in Abbildung 54 zeigt eine hohe Abdeckung des Spannungs-Dehnungs-Raumes. Dass weiterhin der Druckbereich eine wesentlich geringere Abdeckung erhält liegt an der global anliegenden Zugbelastung.




Abbildung 54: Dehnungs-Triaxialitäts-Diagramm sowie EMI-Auswertung für die finale Probekörpergeometrie aus AP5.1 am IFB

Das Deformationsverhalten der realen Versuche deckt sich mit den Ergebnissen aus der Simulation und wurde mit dem Aramis 12M – System mithilfe von DIC-Vollfeldmessungen tiefergehend analysiert. Wie in Abbildung 55 ersichtlich, ist der verwendete Kunststoff Bayblend T65 XF aufgrund seiner Duktilität hervorragend dazu geeignet, bei Zugbelastung die gewünschten Knickmechanismen auszulösen. Während die inneren Stege nach erfolgreichem Knickmechanismus versagen, halten die äußeren Stege bis zu hohen Zugdehnungen stand, bis sie schließlich ebenfalls versagen (siehe Abbildung 55 unten).




Abbildung 55: Reale DIC-Dehnungsmessung der finalen Probekörpergeometrie aus AP5.1 am IFB

Mit der gefundenen Probekörpergeometrie wurden folgende Eigenschaften erreicht:

- Messung von DIC im gesamten Prüfbereich
- Fertigung der Aussparungen mit Fräswerkzeugen möglich
- Hohe Dehnungen im Zug- und Schubbereich
- DIC-sichtbare Bereiche mit auftretenden Druckbelastungen
- Proben transport durch den Cobot aus AP6 möglich

Der Versuchsaufbau ist in Abbildung 56 dargestellt.




Abbildung 56: Eingespannte finale Probekörpergeometrie aus AP5.1 am IFB

AP5.2: Neuartige Charakterisierungsversuche für Metalle

Basierend auf den Erkenntnissen aus den vorangegangenen Arbeitspaketen hat das IFB unterstützend im AP5.2 mitgewirkt.

AP5.3: Untersuchungen zum Transferlernen

Für die Untersuchungen zum Transferlernen wurden in diesem Unterarbeitspaket virtuelle Trainingsdaten für das Transferlernen generiert. Weitere Inhalte dieses Unterarbeitspakets sind in den Zusammenfassungen von AP4 zu finden.

AP6: Versuchsautomatisierung

AP6.1: Festlegung der zu automatisierenden Prozessanteile (Hardware)

Zur automatisierten Bereitstellung von experimentellen Trainingsdaten wurde gemeinsam mit den AP-Partnern evaluiert, welche Prozesse automatisiert werden müssen und wie dies umgesetzt werden kann. Die am IFB automatisierten Prozesse beinhalten das Probenhandling, die Materialprüfung mit in-situ Vollfeld-Dehnungsmessung mittels DIC sowie die Probenvermessung.

Für das Probenhandling wurde im Rahmen des Projekts ein kollaborierender Roboter (Cobot) UR5e von Universal Robots beschafft, der an einer bereits vorhandenen Universalprüfmaschine am Institut für die Versuchsautomatisierung eingesetzt werden soll. Für die in-situ Vollfeld-Dehnungsmessungen wurde das Aramis 12M – System von GOM beschafft, um mit hochaufgelösten DIC-Messungen das Deformationsverhalten von Probekörpern unter Belastung zu verfolgen und damit unter anderem lokale Dehnungen aus realen Versuchsdaten für die spätere datengetriebene Materialmodellierung erzeugen und analysieren zu können. Zur Durchführung einer automatisierten Probenvermessung wurde zudem das Atos Core 185 – System von GOM im Rahmen des Projekts beschafft, das mithilfe seiner zwei Kameras und der Streifenlichtprojektionsmethode die Möglichkeit bietet, durch die Aufnahme von Probekörpern aus mehreren Perspektiven ein dreidimensionales Abbild zu erzeugen, welches anschließend in der Software vermessen werden kann. Zusätzlich kann das Atos Core ebenfalls als Messsystem zur DIC-Vollfeldmessung genutzt werden, allerdings bei geringeren Bildauflösungen und Messfrequenzen als das Aramis 12M.

AP6.2: Entwicklung von Konzepten zur Automatisierung (Hardware und Software)

In Abstimmung mit den AP-Partnern wurden verschiedene Konzepte entwickelt, die durch möglichst herstellerunabhängige Kommunikationsmöglichkeiten zwischen den Komponenten eine größtmögliche Kompatibilität bieten sollen. Während die DIC-Messsysteme und der Cobot für

den Projektpartner Dynamore und am IFB die gleichen Systeme sind, unterscheiden sich die verwendeten Universalprüfmaschinen in der Bauart und dem Hersteller. Ziel der Automatisierungskonzepte war die Entwicklung einer Server-Client-Kommunikationsstruktur, bei der eine übergeordnete Komponente die Koordination über alle Abläufe der Versuchsautomatisierung übernimmt, während die untergeordneten Instanzen nur über die jeweils für sie relevanten Prozessfortschritte informiert werden. Die übergeordnete Instanz kann beim Auftreten von Unregelmäßigkeiten den Prozess unterbrechen beziehungsweise beenden. Dadurch soll die Menge der ausgetauschten Daten reduziert und gleichzeitig die Stabilität des Gesamtprozesses gewährleistet werden.

Da der verwendete Cobot über verschiedene Kommunikationsschnittstellen verfügt, wurde deren spezifische Eignung zur Versuchsautomatisierung untersucht und sich schließlich auf eine Kommunikation primär basierend auf dem Modbus TCP – Netzwerkprotokoll, nachfolgend abgekürzt Modbus, fokussiert. Hierbei werden die Hard- und Softwarekomponenten über ein lokales, auf Ethernet-Verbindungen basierendes Netzwerk verbunden und können mithilfe der Modbus-Kommunikation bestimmte Zustände oder Werte mithilfe von Modbus-Registern an andere Komponenten im Netzwerk übermitteln. Während der Cobot herstellerseitig bereits Modbus-Registeradressen vorkonfiguriert hatte, mussten diese für die weiteren Komponenten noch erstellt werden. Mithilfe eines vom Projektpartner IFU bereitgestellten Python-Codes und der Python-Bibliothek pyModbus konnte die Modbus-Kommunikation für weitere Komponenten prototypisch in Betrieb genommen werden. Zur Integration der DIC-Systeme in die Automatisierung war ebenfalls die Python-Programmiersprache relevant, um mit der implementierten Programmierschnittstelle innerhalb der GOM-Software durch Skriptbefehle softwareseitige Prozesse wie beispielsweise das Starten von Bildaufnahmen von Aramis und Atos oder das Laden von Projektvorlagen zu automatisieren. Zusätzlich wurden verschiedene Automatisierungskonzepte zur Probenpräparation für die DIC-Messung erarbeitet. Für die DIC-Messsysteme notwendige Probenpräparation Für die automatisierte Probenbereitstellung, Prüfmaschinenbedienung und quasi-statische Versuchsdurchführung wurden ebenfalls verschiedene Konzepte entwickelt, jedoch wurden hier durch die unterschiedlichen Prüfmaschinenarchitekturen gesonderte Rahmenbedingungen bei den einzelnen Projektpartnern nötig.

AP6.3: Umsetzung der Automatisierungskonzepte (Hardware)

Zur Umsetzung der Automatisierungskonzepte wurde der Aufbau von Cobot und DIC-Messsystemen an den vorhandenen Bauraum um den Aufstellort der verwendeten Universalprüfmaschine angepasst. Für eine feste Positionierung des Cobots neben der Prüfmaschine wurde dieser auf ein Unterbaugestell aus Aluminiumprofilen montiert, sodass der Cobot mit seinem

verfügbaren Aktionsradius den Probentransport zwischen Probenmagazin, Probenvermessung und Probeneinspannung in der Prüfmaschine problemlos bewältigen kann, ohne dabei die Arbeitssicherheit zu gefährden. Die beschafften Greifer des Cobots, ein mechanischer Greifer und ein Vakuumgreifer, wurden auf ihre Eignung für die verwendeten Kunststoffproben hin untersucht. In Abstimmung mit den AP-Partnern wurde sich schließlich für die Verwendung des mechanischen Greifers entschieden, weil mit diesen unter anderem die Reproduzierbarkeit der Positionierung des Probekörpers zur Vermessung und der Einspannung in den Spannbacken am besten gewährleistet werden konnten. Der Cobot wurde programmiert für den Probentransport, inklusive dem Einlernen von virtuellen Sicherheitsebenen, um Kollisionen mit Personen oder Objekten bestmöglich zu vermeiden. Die DIC-Messsysteme wurden prototypisch in Betrieb genommen und zunehmend automatisiert. Zur prototypischen Inbetriebnahme der Komponenten und der Gesamtanlagen war die Ausarbeitung der Kommunikationsinfrastruktur von großer Bedeutung. Der Cobot agiert in der Server-Client-Struktur in der übergeordneten Rolle als Server, der mithilfe des MODBUS TCP – Netzwerkprotokolls Statuseinträge der über Ethernet verbundenen Komponenten abfragen und weiterverarbeiten kann sowie Status-Änderungen erteilt. Hierbei hat jede Komponente eigene Statusregisteradressen wie z.B. eine Adresse, die jeweils angibt, ob die Komponente bereit oder beschäftigt ist. Aus Sicht des Cobots ergibt sich hierdurch die in Abbildung 57 visualisierte Struktur mit den beiden Unterprogrammen für die Vermessung sowie des Zugversuchs.




Abbildung 57: Schematischer Ablauf des automatisierten Versuchs aus Sicht des Cobots

Die Probenvermessung mittels Atos Core und Cobot wurde als erster Umsetzungsschritt in die Versuchsautomatisierung eingebunden. Durch die Möglichkeit der Modbus-Kommunikation

zwischen den beiden Komponenten wurden die Bewegungen des Cobots mit den Scanvorgängen des Atos koordiniert. Dadurch entstanden Einzelaufnahmen des Probekörpers aus verschiedenen Perspektiven, indem der Cobot den Probekörper vor dem fest montierten Atos bewegte und damit die für die 3D-Zusammensetzung benötigten Aufnahmen erzeugte, wie in Abbildung 58 dargestellt ist. Die automatisierenden Softwareanteile wurden unter anderem durch ein vom assoziierten Projektpartner GOM entwickeltes Skript unterstützt, welches innerhalb der GOM Software die erforderlichen Softwareschritte zur Vermessung des Probenbreite und -dicke an verschiedenen, vordefinierten Probenquerschnitten ausführt und daraus einen jeweiligen Mittelwert errechnet. Im Anschluss an die Probenvermessung wird durch ein weiteres Skript die automatisierte Abspeicherung der Probenabmessungen durchgeführt, damit diese Daten für die am darauffolgenden (Zug-)Versuch beteiligten Komponenten Prüfmaschine und Aramis über die Netzwerkinfrastruktur übermittelt werden.




Abbildung 58: Ablauf ATOS-Probenvermessung

Für die Probenpräparation zur DIC-Messung wird für die verwendeten Systeme ein schwarz-weißes stochastisches Speckle-Muster benötigt, das für die gesamte Versuchsdauer an der Probenoberfläche haften soll und sich mit der Probe deformiert. Für die Einbindung dieses Prozesses in die Automatisierung wurden unter anderem Wiegestempel und Rollstempel gefertigt, die der Cobot mit seinen Greifern auf einem Stempelkissen und anschließend auf den Probekörpern abrollen kann. Hier hatte sich jedoch gezeigt, dass insbesondere bei dem Stempeln von Kunststoffen mit glatten Oberflächen ein Verschmieren des Musters nicht gänzlich vermieden werden konnte. Aus diesem Grund wurde sich am IFB dazu entschieden, die DIC-Probenpräparation wie in der Vergangenheit mittels Sprühlackdosen vor dem automatisierten Versuch durchzuführen.

Zur Lagerung und automatisierten Bereitstellung von Probekörpern wurde am IFB ein Probenmagazin gebaut, das die Proben auf insgesamt vier schrägen Ebenen in Richtung des Cobot-Greifens transportiert. Hierbei wurden pro Ebene jeweils zwei Entnahmestellen definiert, die im

Cobot-Programm als feste Wegpunkte eingespeichert werden konnten. Mithilfe von verschiebbaren Seitenwänden wurde das Probenmagazin für variable Probenabmessungen ausgelegt, sodass auch von der Norm abweichende Probengeometrien aus AP5 verwendet werden können. Die Größe des Probenmagazins wurde an den vorhandenen Bauraum sowie die Reichweite des Cobots angepasst und hat bei 15 mm Probenbreite eine Kapazität von 320 Zugproben. Der Aufbau des Probenmagazins ist in Abbildung 59 dargestellt.




Abbildung 59: Vorder- und Seitenansicht des Probenmagazins zur automatisierten Materialprüfung am IFB

AP6.4: Festlegung der zu automatisierenden Prozessanteile (Software)

Für die softwareseitige Automatisierung war die Möglichkeit von Datenaustausch zwischen den Softwarepaketen der DIC-Systeme und Prüfmaschine sowie dem Cobot von großer Bedeutung. Für die DIC-Messsysteme waren bereits Automatisierungsmöglichkeiten durch die implementierte Python-Schnittstelle gegeben, sodass durch die Verwendung von Skriptbefehlen verschiedene Prozesse als automatisierbar festgelegt wurden, wie beispielsweise die Interaktion zwischen DIC-System und Cobot sowie dem automatisierten Datentransfer von Versuchsergebnissen. Für die Schnittstellen aus der Bildkorrelationssoftware war Unterstützung durch den assoziierten Projektpartner GOM gegeben. Als ein weiterer zu automatisierender Softwareprozess wurde die Bedienung der Prüfmaschinensoftware festgelegt. Wichtige Schritte waren hierbei der Datenimport der zuvor ermittelten Probenabmessungen durch Einlesen einer csv-Datei, das Verfahren der Prüfmaschinetraverse in die Belade- und Einspannposition sowie das Starten und Beenden eines quasi-statischen Versuchs. Für eine ML-geeignete Datenformatierung wurden verschiedene Datenformate auf ihre Eignung untersucht und sich schließlich für die Abspeicherung im XML-Format entschieden.

AP6.5: Entwicklung eines softwaregestützten Verfahrens zu Training und Validierung von ML-basierten Materialmodellen

Im Zusammenspiel mit den Inhalten aus AP3 und AP4 wurde in diesem Unterarbeitspaket die erzeugten Versuchsdaten in einem XML-Dateiformat aufbereitet. Damit sind die aufbereiteten experimentellen Messungen in die gesamte Prozesskette des Projektes integrierbar. Innerhalb der Prozesskette ist eine Vergrößerung des Datensatzes durch Datenaugmentation möglich.

AP6.6: Aufbau und Anwendung von (teil)automatisierten Prozessen

Um in der Prüfmaschinensoftware Benutzereingaben zu ersetzen, wurde zunächst mithilfe der Python-Bibliothek pyAutoGUI ein Skript erstellt, die das virtuelle Betätigen bestimmter Schaltflächen im Softwarefenster ausführen kann und damit den menschlichen Prüfmaschinenbediener imitiert. Aufgrund der Architektur der Prüfmaschinensoftware konnten verschiedene sicherheitsrelevante Funktionen jedoch nicht durch dieses externe Skript automatisiert werden, beispielsweise, um bei der Probekörpereinspannung einen Krafthaltemodus zu aktivieren. In Abstimmung mit dem Prüfmaschinenhersteller wurde das Kommunikationskonzept dahingehend angepasst, dass mithilfe der pneumatischen Steuerungseinheit und Anpassungen in der Prüfmaschinensoftware die Kommunikation über Digitalsignale zwischen Prüfmaschine und Cobot eingerichtet wird, statt wie zuvor über Modbus-Kommunikation und pyAutoGUI. Die resultierende Kommunikationsstruktur ist in Abbildung 60 dargestellt.




Abbildung 60: Schematischer Überblick zur Kommunikationsstruktur der Versuchsautomatisierung in AP6 am IFB

Mithilfe der Digitalkommunikation zwischen Cobot und Prüfmaschine konnte durch die Anpassung der Cobot-Skripte erreicht werden, dass beispielsweise das Verfahren der Traverse, das Schließen und Öffnen der Spannbacken oder auch der (softwareseitige) Start des Zugversuchs durch den Cobot ausgelöst wird. Dadurch konnte der Probentransport sowohl der ungeprüften,

intakten Probe als auch den Probenresten eines geprüften Exemplars durch die Interaktion zwischen Cobot und der Prüfmaschine sowie den pneumatisch betriebenen Spannbacken durchgeführt werden, wie beispielhaft in Abbildung 61 zu sehen.



Abbildung 61: Cobot bei der Probeneinbringung (links Standardzugprobe, mittig neuartige Zugprobe aus AP5) und Probenentnahme (rechts) an der Prüfmaschine

Die DIC-Systeme (GOM Atos Core und GOM Aramis) kommunizieren mit dem Cobot wie bereits in der Vergangenheit weiterhin über die Modbus-Schnittstelle. Die Positionierung des Atos Core an der Prüfmaschine wurde im Laufe des Projekts dahingehend angepasst, dass beide Funktionalitäten des Atos Core (Probenvermessung mittels Streifenlichtprojektion und DIC-Messung) ohne Umbau durchführbar sind. Für die softwareseitige Automatisierung wurde innerhalb der GOM-Software ein Code geschrieben, um das Atos Core als Zustandsmaschine in Bereitschaft zu versetzen, um je nach Befehl des Cobots entweder die Probenvermessung oder DIC-Messung durchzuführen.




Abbildung 62: Positionierung des Probekörpers zur Vermessung (links) sowie softwareseitige Auswertung der Probenabmessungen (rechts)

AP6.7: Evaluation

Zur Überprüfung der Reproduzierbarkeit sowie der Weiterentwicklung der ATOS-Probenvermessungen mithilfe des vom assoziierten Projektpartners GOM bereitgestellten Skripts wurde

ein automatisierter Prüfplan erstellt und durchgeführt, bei der eine Zugprobe insgesamt 100-fach ohne Unterbrechung vermessen wurde. Mithilfe einer Parameterstudie konnten in mehreren Messreihen diverse Einstellungen innerhalb der GOM Software, beispielsweise die Belichtungszeiten, die Suchzeit des CAD-Fittings oder die benötigte Anzahl an Einzelaufnahmen hinsichtlich ihrer Auswirkungen auf die Qualität und Dauer der Messung untersucht werden. Zusätzlich zu den Einstellungen in der GOM-Software wurde zudem die Positionierung der Probe für die jeweiligen Einzelaufnahmen durch geänderte Wegpunkte des Cobot-Greifers verbessert. Wie in Abbildung 63 dargestellt konnte hierdurch erreicht werden, dass anfängliche Schwankungen der Messergebnisse signifikant verringert werden konnten. Zudem konnte die benötigte Zeit zur Probenvermessung mehr als halbiert werden verglichen zum Anfangszustand. Die Schlüsselfaktoren waren hier ebenfalls die Optimierung der Cobot-Bewegungen zur Probenpositionierung bei gleichzeitiger Reduktion der Einzelmessungen.




Abbildung 63: Messreihen aus der Parameterstudie zur Evaluation der ATOS-Probenvermessung

Die anfänglichen Schwankungen in Breitenrichtung waren unter anderem darauf zurückzuführen, dass das CAD-Fitting teilweise fehlerhaft war und außerhalb des taillierten Bereichs des Probekörpers die Breite ermittelt hat, wie in Abbildung 64 oben dargestellt ist. Nach der Parameteroptimierung war dieses Problem behoben.




Abbildung 64: ATOS-Probenvermessung mit fehlerhaftem CAD-Fitting des Probekörpers (oben) und mit korrektem CAD-Fitting (unten); dies war eine der Ursachen für die anfänglichen Messschwankungen in Breitenrichtung

Durch kontinuierlich optimierte Verfahrenswege und -geschwindigkeiten des Cobots sowie der Probenvermessung mit nur noch einer Belichtungszeit statt ursprünglich drei verwendeten Belichtungszeiten konnte der Gesamtprozess der Versuchsautomatisierung im Laufe der Projektlaufzeit deutlich beschleunigt werden. Durch die hohe Positionierungsgenauigkeit des Cobots und der Anbindung des Cobots und Probenmagazins an den Prüfmaschinentisch konnte eine hohe Reproduzierbarkeit der Probeneinspannung und eine sehr gute Messdatenqualität erreicht werden.

AP7: Demonstrator

AP7.1: Bereitstellung der ML-Materialmodelle und klassischer Materialkarten für Kunststoff und Metall

Die Ergebnisse der vorangegangenen Arbeitspakete wurden dem Projektkonsortium über zwei über die Versionsverwaltungssoftware GitHub nutzbare Anwendungspakete zur Verfügung gestellt. Das Repository "AIMM" enthält den Programmcode zur Erstellung und Validierung der ML-Materialmodelle. Das Repository "interface-dyna" stellt die ML-Modelle samt der Schnittstelle für LS-Dyna bereit. Die Daten und Programme wurden von den Projektpartnern über die Projektlaufzeit dynamisch erweitert.

Die Berechnungen und Auswertung der Demonstratoren mit ML-Modellen erfolgte am IFB und den Partnern bereitgestellt. Der Demonstrator B-Säule wurde durch Mercedes-Benz berechnet.

AP7.2: Komponententests an Kunststoff-Demonstratoren

Für das AP7.2 wurden am IFB die vom Projektpartner ElringKlinger bereitgestellten Kunststoff-Wannen aus dem in AP1 charakterisierten Kunststoff Bayblend T65XF quasi-statisch im Druckversuch getestet. Mithilfe von DIC-Messungen konnten bei dem in Abbildung 65 dargestellten

Versuchsaufbau neben der globalen Kraft und dem Traversenweg auch die Oberflächendefor-
mation unter anderem in Form von Verschiebungen und Dehnungen ermittelt werden (siehe
Abbildung 66).




Abbildung 65: Versuchsaufbau quasi-statische Demonstrator-Druckversuche am IFB in AP7.2




Abbildung 66: DIC-Messung Demonstratorversuch am IFB, hier dargestellt die Verschiebung in Druckrich-
tung

Die Versuche wurden bis zu einer Last von etwa 10 kN durchgeführt, bei der noch kein globales
Versagen der Bauteilstruktur aufgetreten ist. Die plastische Verformung nach dem Versuch ist
in Abbildung 67 zu sehen. Gut erkennbar ist hier auch die Kontaktfläche zwischen Bauteil und
Druckstempel.




Abbildung 67: Geprüfte Kunststoffwanne nach dem Druckversuch zeigt plastische Verformungen durch den Druckstempel

Die Ergebnisse der realen Demonstratorversuche wurden verwendet, um die Simulationsergebnisse zu validieren. Hier hat sich eine große Übereinstimmung zwischen den Simulationen des Versuchs mit MAT_24 und dem ML-Materialmodell gezeigt.




Abbildung 68: Simulativer Abgleich des Druckversuchs mit MAT_24 (links) und dem ML-Modell in AIMM (rechts)

Arbeiten am IFB im Unterauftrag an die Renumics GmbH

Umat24 in Python für Trainingsdatengenerierung (AP2.1):

Die Implementierung von Umat24 in Python hat sich als effizienter Weg zur Generierung von Trainingsdaten erwiesen:

- 1 Verständlichkeit: Der Prozess ist einfacher und transparenter im Vergleich zur Extraktion von Eingaben und Ausgaben des Materialmodells aus der Simulation.
- 2 Performance: Dank der Implementierung in Numba wurde eine massive Beschleunigung erreicht (Speedup von ca. 100 gegenüber der regulären Python-Lösung).

- 3 Optimierung: Mit einem JIT-Compiler, der direkt optimierte Maschinensprache generiert, konnte die Geschwindigkeit noch weiter erhöht werden.

Einfache Installation des AIMM Repositories (AP4):

Die Module des AIMM Repository lassen sich nun unkompliziert mit einer einzigen Zeile mit pip installieren. Es ist lediglich notwendig, die Umgebungsvariablen für LS_DYNA zu setzen, um z.B. Auswertungen starten zu können.

Simulationbasierte Validatoren (AP3+4)

Für fünf simulationsbasierte Validatoren wurde ein gemeinsames Interface entwickelt:

- Aufruf: Die Validatoren können mit einem einfachen Befehl aus der Kommandozeile und in Python aufgerufen werden.
- Auswertung: Standardisierte Analyse mit ca. 50 Visualisierungen und Plots ist verfügbar, alle im HTML-Format.

Erweiterung der Modelle (AP3+4)

Neue Modelle wie LSTM_200 und LSMCc wurden hinzugefügt, sowie die Möglichkeit, ein Modell aus einem beliebigen GIT-Repository hinzuzufügen. Dies erlaubt eine einfache und flexible Integration von Modellen.

Verbesserung der Datageneration API (AP2)

Die Datageneration API wurde optimiert, sodass Trainingsdaten jetzt auch während des Trainingsprozesses erzeugt werden können. Dies steigert die Effizienz und ermöglicht eine flexiblere Handhabung von Trainingsdaten.

Sensitivitätsanalyse

Das vielversprechende Modell im Projekt LMSCc wurde auf seine Sensitivität überprüft. Es wurde Rauschen hauptsächlich in Schubspannungskomponenten festgestellt, die durch eine entsprechende Dämpfung bei der Anwendung des MLMM in der Simulation kompensiert werden muss. Die Stärke der Dämpfung wurde für DP800 aus den Arbeiten zur Minimal State Cell (Bonatti/Mohr 2021) übernommen und für den Kunststoff umgerechnet.

Modellierung eines Kunststoffs

Die für LMSCc basierten Modelle für DP800 wurden für den Kunststoff angepasst und trainiert. Dabei konnten ähnlich gute Ergebnisse wie bei DP800 erreicht werden, was auf eine gute Generalisierbarkeit der Methode hindeutet.

Zusammenfassung der Unterarbeiten

Die vorgenommenen Arbeiten seitens Renumics im Unterauftrag der Universität Stuttgart haben die Leistungsfähigkeit, Flexibilität und Benutzerfreundlichkeit des Systems erheblich gesteigert. Die Implementierung von Umat24 in Python mit Numba hat zu beträchtlichen Geschwindigkeitsgewinnen geführt, während die Vereinfachung der Installation und die Standardisierung der Validatoren die Benutzerfreundlichkeit erhöhen.

1.5 IFU

Im Rahmen des Projektes hat Institut für Umformtechnik explizit an den folgenden Arbeitspaketen gearbeitet:

- AP1.3: Charakterisierung und Modellierung des Umformverhaltens
- AP2.1: Schnittstellen
- AP2.3: Erzeugung simulativer Trainingsdaten – Metall
- AP3.4: Untersuchung möglicher Kombinationen von mehreren ML-Modulen
- AP4.1: Bestimmung der Vollständigkeit der Datenbasis
- AP4.3: Entwicklung von ML-Verfahren zur holistischen Materialmodellierung
- AP4.5: Untersuchungen von Transfer-Learning Verfahren zur Beschleunigung des Modellierungsprozesses
- AP5.2: Neuartige Versuche für Metalle
- AP5.3: Untersuchungen zum Transferlernen
- AP6.1: Festlegung der zu automatisierenden Prozessanteile (Hardware)
- AP6.2: Entwicklung von Konzepten zur Automatisierung (Hardware und Software)
- AP6.4: Festlegung der zu automatisierenden Prozessanteile (Software)
- AP7.3: Hardware- Umformversuche für metallischen Werkstoff
- AP7.6: Simulation – Umformen: Metall mit ML- und klassischen Modellen

Nachfolgend werden die erbrachten Leistungen in den oben genannten Arbeitspaketen beschrieben und die Ergebnisse dargestellt.

AP1: Erzeugung klassischer Materialkarten

AP1.3: Charakterisierung und Modellierung des Umformverhaltens

Im Rahmen von AP1 wurde der metallische Werkstoff DP800 hinsichtlich seines Umformverhaltens nach dem Stand der Technik charakterisiert und die Materialkarten für das Werkstoffmodell YLD2000-2D der Software LsDyna erstellt. Hierbei wurden die anisotropen Fließeigenschaften durch Zug- und biaxiale Versuche, Versuche zum ebenen Dehnungszustand und auch mittels Scherversuche ermittelt. Abschließend erfolgte die Bestimmung der Fließkurve durch inverse Parameterbestimmung.

Das IFU hat für die Transfer-Lernstudien in AP-3, -4 und -5 zudem die klassische Materialkarte für DP600 bereitgestellt. Ein Vergleich der klassischen Materialkarten zeigt erwartungsgemäß, wie in Abbildung 69 dargestellt, dass DP600 eine gänzlich andere Fließkurve und Fließortkurve (Anisotropieparameter) aufweist als das im Projekt verwendete DP800-HD.

DP600 vs. DP800

σ_0		Alpha Parameters									
		a1	a2	a3	a4	a5	a6	a7	a8	e	
DP600	362.28 MPa	0.99278	0.94191	0.93671	0.96395	1.00895	0.97131	0.95630	1.01265	6	
DP800	481.20 MPa	0.90834	1.02202	0.90505	0.97322	1.00190	0.88071	0.98935	1.11292	6	

Stress and R-Values											
	S00	S45	S90	Sbiax	PS1x	PS1y	PS2x	PS2y	S1	S2	R00
DP600	1.0	1.0243	1.0351	1.0238	1.1091	0.6148	0.5905	1.1588	0.5761	0.5761	0.78
DP800	1.0	0.9869	1.01	1.0459	1.1246	0.7303	0.6919	1.1516	0.5755	0.5755	0.733

	R45	R90	Rbiax
DP600	0.825	0.985	0.756
DP800	0.91	0.95	0.86






Abbildung 69: Vergleich der mechanischen Kennwerte von DP800 und DP600

AP2: Erzeugung simulativer Trainingsdaten

AP2.1: Schnittstellen

Für die Verwendung von Trainingsdaten aus Simulationen und Experimenten ist es von großer Bedeutung, kohärente Daten aus verschiedenen Quellen zu erhalten. Um dies zu erreichen, wurden Schnittstellen definiert, die es ermöglichen, die unterschiedlichen Darstellungen von

Daten aus verschiedenen Quellen für den Austausch kohärent zusammenzuführen oder umzuformatieren. Dabei wurde darauf geachtet, nur die benötigten Daten zu bestimmen, da die Datenmenge aus den einzelnen Quellen oft relativ groß war. In den gemeinsamen Team-Sitzungen wurde vereinbart, welche Daten und Datenformate aus welchen Quellen wohin übertragen werden sollten. Das IFU hat anschließend Skripte entwickelt, um die Simulationsergebnisse in ein vergleichbares Format mit den Test-Ergebnissen zu konvertieren. In späteren Phasen des Projekts wurden diese jedoch durch die Skripte der GOM-ARAMIS-Software ersetzt.

AP2.3: Erzeugung simulativer Trainingsdaten – Metall

Im Rahmen des AP2 wurden PYTHON-Skripte entwickelt, um simulative Trainingsdaten für Schalenelemente mit Spline-Randbedingungen zu erzeugen. Die Skripte erzeugen Elemente und Dehnungspfade, um das Verhalten des vorhandenen Materialmodells in Form einer Dehnungs-Spannungs-Historie eines Elementknotens abzubilden. Außerdem wurden virtuelle Tests in der Simulationsumgebung für zuvor vereinbarte Geometrien von Probekörpern aus DP800HD-Material durchgeführt. Das Ziel bildete die experimentelle Weiterentwicklung der Trainings- und Bestimmungsmethodik für Geometriedetails von Probekörpern.

AP3: Hybride Materialmodelle

AP3.4: Untersuchung möglicher Kombinationen von mehreren ML-Modulen

Das IFU hat anschließend einen hybriden Ansatz implementiert, mit dem analytische Modelle zur Berechnung der Dehnratenabhängigkeit mit KI-Materialmodellen gekoppelt werden können. Die Dehnratenabhängigkeit kann durch die Änderung der Fließspannungskomponenten als Funktion der Dehnraten definiert werden. Dieser Zusammenhang wird in der Regel als richtungsunabhängig angesehen. Um die Dehnratenabhängigkeit implementieren zu können, wurde zunächst der Multiplikationsfaktor als Funktion der Dehnraten ausgewertet. Die gefundene mathematische Formel wird genutzt, um den Dehnratenabhängigkeitsfaktor zu berechnen, s. Abbildung 70. Dieser Faktor wird für jedes Zeitinkrement und jeden Integrationspunkt berechnet und dient dazu, die aus den KI-Modellen vorhergesagten quasi-statischen Spannungen zu multiplizieren.




Abbildung 70: Bestimmung des analytischen Faktors für die Dehnratenabhängigkeit als hybride Modellkomponente

AP4: Holistische Materialmodelle

AP4.1: Bestimmung der Vollständigkeit der Datenbasis

In AP4.1 wurden die physikalischen Eigenschaften bestimmt, die in den Trainingsdaten enthalten sein sollten: Diese beinhalten das elastische, das plastische und das Verfestigungsverhalten des Blechwerkstoffes bei ausreichender Verformung und umfassenden Spannungs- und Dehnungsverhältnissen.

AP4.3: Entwicklung von ML-Verfahren zur holistischen Materialmodellierung

Das IFU hat im Rahmen der Entwicklung von ML-Methoden für die holistische Materialmodellierung die Eigenschaften der Materialmodelle identifiziert und formalisiert, die in die ML-Modelle eingebettet werden sollten. Insbesondere bei der Modellierung des Umformverhaltens ist es von Bedeutung, die Anisotropie des Materials zu berücksichtigen. Im Gegensatz zur Modellierung des Crashes ist bei der Blechumformung von Automobilkomponenten die Dehnratenabhängigkeit in der Regel nicht erforderlich.

AP4.5: Untersuchungen von Transfer-Learning Verfahren zur Beschleunigung des Modellierungsprozesses

Für ein erfolgreiches Training des ML-Materialmodels mit experimentellen Messungen ist eine umfangreiche Datenbasis notwendig. Obwohl im Rahmen des Projektes neue Proben Geometrien für umfangreiche Dehnungs- und Spannungsverhältnisse entwickelt wurden, ist die valide numerische Erweiterung der Trainingsdatenbank ebenso wichtig. Gelingt dies, können neue, zuvor unbekannte Dehnungs- und Spannungszustände ermittelt und bewertet werden, die experimentell zu erzeugen nicht möglich ist. Das IFU hat gezeigt, s. Abbildung 71, dass für isotrop

verfestigende anisotrope Werkstoffe die Punktspiegelung gemessener Dehnungen und vorhergesagter Spannungen (nach Konvergenz des KI-Modelltrainings) mathematisch korrekte Werte sind und als Teil der Datenbank verwendet werden können. Die meisten auf dem Markt erhältlichen Materialmodelle zur Beschreibung des elastoplastischen Verhaltens von Metallen sind isotrop verfestigende anisotrope Werkstoffe.




Abbildung 71: Die Gültigkeit der Verwendung negativer Werte für "Gesamtdehnungen und prognostizierte Spannungen"

AP5: Neuartige Charakterisierungsversuche für das Training von KI-Modellen

AP5.2: Neuartige Versuche für Metalle

Im Rahmen von AP5 wurden vom IFU im Rahmen der Projektbearbeitung neue Probengeometrien entwickelt, die speziell für die vorliegenden Anwendungen der Blechumformung geeignet sind. In diesem Zusammenhang erfolgte eine Zusammenarbeit mit DYNAmore, die während der Projektlaufzeit ähnliche Probengeometrien für die Charakterisierung der Blechwerkstoffe unter deutlich höheren Dehnraten (Crashverhalten) erarbeiteten. Das Ziel bestand darin, mit möglichst wenigen Versuchen ein umfassendes Set an dichten Dehnungs- und Spannungsverhältnissen sowie Dehnungspfaden für Trainingszwecke zu generieren. In der ersten Phase von AP5 wurden die Probengeometrien virtuell entwickelt und optimiert. Die Geometrie wurde anhand von Triaxialitätsdiagrammen und FLD-Diagrammen optimiert, s. Abbildung 72.




Abbildung 72: Untersuchte Probengeometrien nur mit kreisförmigen Löchern

Im Rahmen von AP5 hat das IFU einen Ansatz aus der Literatur getestet, um die fehlenden Messbereiche an den Rändern bei den optischen Verformungsmessungen aufzufüllen. Die Kernskripte für diesen Ansatz wurden entwickelt und an virtuellen und realen Experimenten erfolgreich getestet (s. Abbildung 73). Die Methode nutzt die Ansatzfunktionen der Finite-Elemente-Methode, um die Zusammenhänge zwischen den GOM-Messpunkten (die roten Punkte im Bild) und den Knoten eines FE-Netzes (die blauen Elemente im Bild) abzubilden. Das FE-Netz deckt dabei die gesamte Oberfläche der Probe ab. Dieser Zusammenhang wird in der Ausgangsposition vor Beginn der Verformung berechnet und bei jeder Messung eines verformten Zustands zur Berechnung der aktualisierten Knotenkoordinaten verwendet. Mit dieser Methode kann auch das räumliche Messrauschen reduziert werden. Um die fehlenden kantennahe Messbereiche zu ergänzen, ist eine genaue Ausrichtung der GOM-Messungen an dem für die numerischen Berechnungen verwendeten Netz erforderlich. Das IFU hat eine Ausrichtungsmethode entwickelt, die auf den verfügbaren Funktionen der GOM-Software basiert. Eine Anleitung dazu wurde erstellt (s. Abbildung 74).




Abbildung 73: Erfolgreiches Auffüllen der fehlenden Messbereiche an den Rändern




Abbildung 74: Ausrichtung der Facetten der GOM-Messungen an dem für das Training verwendeten Netzknoten

AP5.3: Untersuchungen zum Transferlernen

Im Rahmen von AP5.3 hat das IFU die klassische Werkstoffkarte für DP600 zur Verfügung gestellt, so dass diese als Grundlage für die Transfer-Learning-Untersuchungen genutzt werden kann, siehe Abbildung 69. Darüber hinaus wurden Simulationsmodelle mit Probengeometrien und umfangreiche Berechnungsergebnisse zum Verformungsverhalten bereitgestellt.

AP6: Automatisierung

AP6.1: Festlegung der zu automatisierenden Prozessanteile (Hardware)

in diesem AP konnte das IFU seine Erfahrungen in der Automatisierung des Umformprozesses einbringen, indem es verschiedene Vorrichtungen, Messsysteme und Roboter einsetzte, um die für die Automatisierung der Materialprüfung benötigten Hardware-Komponenten festlegen zu können. Nach gemeinsamer Festlegung, welche Komponenten automatisiert werden können, hat das IFU verschiedene Automatisierungskonzepte (z.B. Sterntopologie oder Bustopologie) aufbereitet und bewertet. In Ergänzung zu diesen Konzepten hat das IFU auch die Umsetzungsmöglichkeiten im industriellen Umfeld untersucht. Zunächst wurde dies als SPS-Code in der Beckhoff-Steuerung implementiert. Später wurde das MODBUS-System als zentrale Steuerung in der Robotersteuerung gewählt. IFU lieferte wiederum die Basisskripte für die Kommunikation der Hardware-Komponenten für diese spezifische PYTHON-basierte Kommunikation.

AP6.2: Entwicklung von Konzepten zur Automatisierung (Hardware und Software)

In AP6 wurden die zu automatisierenden Hardware- und Software-Prozesse bestimmt und die Konzepte für die Automatisierung der Kernkomponenten vollständig entwickelt. Der Workflow der Steuerung wurde zunächst als SPS-Code für die Beckhoff TwinCat-Steuerungsumgebung erstellt. Die Flexibilität der Python-Umgebung wurde dabei als Vorteil angesehen, insbesondere für die Steuerung von Software-Komponenten für optische Messsysteme und die Simulationssoftware. Es wurde untersucht, ob Python auch für die Steuerung von Hardware-Komponenten verwendet werden kann.

Es wurde festgestellt, dass die PyModbus Python-Bibliothek ebenso die Kommunikation mit dem Handlings-Roboter zur Zuführung der Blechproben ermöglicht. Über die digitalen Schnittstellen des Roboters wurde auf die Spannbacken der Zugprüfmaschine zugegriffen. Die Steuerung von Systemen ohne direkte Schnittstelle mit Benutzeroberfläche wird in der aktuellen Version des realisierten Gesamtsystems durch Python-Bibliotheken wie PyAutoGui oder PyWinAuto ermöglicht. Auch die Netzwerkkommunikation wird mit der Python-Bibliothek socket realisiert. Das gesamte Steuerungssystem wurde somit in der Programmierumgebung von Python konzipiert und umgesetzt. Die relevanten Kernkommunikationsprotokolle wurden als Code definiert, für die Systeme der Projektpartner getestet und den Projektpartnern zur weiteren Verwendung zur Verfügung gestellt.

AP6.4: Festlegung der zu automatisierenden Prozessanteile (Software)

Gemeinsam mit anderen Projektpartnern wurden für die AP2.1 und AP6.4 die Anforderungen an die Daten und Austauschformate von Datenquellen wie Simulation, Testmaschine und DIC-

Software definiert. Dazu gehören die Entwicklung von Python-Skripten am IFU für die automatische Testauswertung, die Überprüfung der Datenvollständigkeit der DIC-Messung und die Reduktion der Datenmenge durch Interpolationsverfahren auf neue Netze. Am IFU wurden anschließend die Codes für alle jene Operationen programmiert, welche sich auf Schalenelemente beziehen. Dazu gehören die Generierung zufälliger Lastpfade, der Export von Daten aus LsDyna-Simulationen und deren Aufbereitung für das Training.

AP7: Demonstrator

AP7.3: Hardware- Umformversuche für die untersuchten Blechwerkstoffe

Der Kreuznapfversuch wurde zunächst mit den vorhandenen klassischen Materialkarten simuliert, um die Testparameter wie Zuschnitt und Ziehtiefe zu bestimmen, siehe Tabelle 2. Die festgelegten Zuschnitte (Platinengeometrie) wurden am IFU mit dem ARGUS-Netz bemustert und dem Partner Mercedes-Benz zur Verfügung gestellt, damit die dortigen Versuche durchgeführt werden konnten. Nach den Versuchen wurden alle Kreuznäpfe erneut am IFU vermessen und digitalisiert. Die Ergebnisse sind in Abbildung 75 dargestellt.

Als Konzeptteile wurden Nakajima-Proben verwendet, die die Erfassung der zeitlichen Veränderung des Verzerrungsfeldes auf der Probenoberfläche während des Umform- bzw. Prüfvorganges ermöglichen. Diese Tests werden auch im Rahmen des AP7 am IFU durchgeführt (siehe Abbildung 76).

Im Rahmen des AP7 hat das IFU die Messergebnisse der Umformdemonstratoren ausgewertet und in ein XML-Dateiformat exportiert, welche schließlich als längerfristig gültiges Austauschdateiformat definiert und allen Projektpartnern zur Verfügung gestellt wurde.

Anzahl der Platinen	ARGUS-Raster	Material, Zuschnitt & Ziehparameter
2	innen und außen	Material: DP800HD Dicke: 1,5mm
2	nur innen	Zuschnitt: 320×275 – 45°× 61 mm
2	nur außen	Blechhalterkraft: 800 kN
2	ohne	Ziehtiefe: 40 mm
		Ziehspalt: 3 mm
		Ziehradius: 10 mm

Tabelle 2: Versuchsmatrix - Kreuznäpfe




Abbildung 75: Digitalisierung des Kreuznapfs durch das GOM-ARGUS-Netz nach der Umformung




Abbildung 76: Nakajima-Proben: Die Konzeptbauteile mit optischer Messung während des Umformvorganges

AP7.6: Simulation – Umformen: Umformsimulationen mittels klassischer und ML- Materialmodelle

Im Rahmen von AP7 wurden abschließend Experimente für die Geometrien der Umform-Demonstratoren durchgeführt. Hierbei wurden Versuche mit dem o.g. Kreuznapfziehwerkzeug analog zu den FLC-Proben durchgeführt und mit ARGUS-Gittern sowie auf Basis von ARAMIS-Messungen digitalisiert. Die Umformsimulationen für diese Demonstratoren wurden vorbereitet und einerseits mit klassischen und andererseits mit ML-Materialkarten durchgeführt. Die Ergebnisse wurden verglichen und die exemplarischen Ergebnisse sind in den Abbildung 77 und Abbildung 78 dargestellt. Es zeigt sich eine zufriedenstellende Übereinstimmung.




Abbildung 77: Darstellung der Formänderungsverteilungen für den Kreuznapf auf Basis des klassischen und des ML- Materialmodells im Vergleich zum Versuch




Abbildung 78: Nakajima Probe - Vergleich der Formänderungsverteilungen

1.6 Mercedes-Benz

Im Rahmen des Projektes hat Mercedes-Benz AG neben der Leitung des Projektes (gemäß AP 8) explizit an den folgenden Arbeitspaketen gearbeitet:

- AP3.1: Entwicklung von ML-Modulen basierend auf Simulationsdaten
- AP3.2: Weiterentwicklung der ML-Module für Versuchsdaten
- AP3.3: Entwicklung der Schnittstelle für die Anwendung von hybriden ML-Modellen (MLOps)
- AP3.4: Untersuchung möglicher Kombinationen von mehreren ML-Modulen
- AP4.1: Bestimmung der Vollständigkeit der Datenbasis
- AP4.2: Vergleich und Auswertung von State-of-the-Art ML Algorithmen
- AP4.3: Entwicklung von ML-Verfahren zur holistischen Materialmodellierung
- AP4.4: Evaluierung der Genauigkeit, Robustheit und Effizienz der Modelle
- AP4.6: Untersuchung von Transfer-Learning Verfahren zur Beschleunigung des Modellierungsprozesses
- AP6.4: Festlegung der zu automatisierenden Prozessanteile (Software)
- AP6.5: Entwicklung eines softwaregestützten Verfahrens zu Training und Validierung von ML-basierten Materialmodellen
- AP6.6: Aufbau und Anwendung von (teil)automatisierten Prozessen
- AP6.7: Evaluation
- AP7.2: Komponententests an Kunststoff-Demonstratoren
- AP7.3: Hardware- Umformversuche für metallischen Werkstoff
- AP7.4: Demonstratoren für Crashsimulation
- AP7.6: Simulation – Umformen: Blechwerkstoff mit ML- und klassischen Modellen

Folgend werden die erbrachten Leistungen in den oben genannten Arbeitspaketen beschrieben und die Ergebnisse dargestellt.

AP3: Hybride Materialmodelle

AP3.1: Entwicklung von ML-Modulen basierend auf Simulationsdaten

Für das Training von ML-Materialmodellen wurden grundlegend zwei verschiedene Ansätze im Projekt betrachtet. Es wurden einerseits unterschiedliche ML-Materialmodelle trainiert, welche alle Komponenten des Dehnungstensors als Eingabe bekommen und alle Spannungskomponenten prognostizieren sollen (siehe AP4.2 und AP4.3).

In Hinblick auf das Training mit Versuchsdaten wurden außerdem verschiedene ML-Materialmodelle trainiert welche nur die Dehnungskomponenten ε_{xx} , ε_{yy} , ε_{xy} sowie die drei entsprechenden Spannungskomponenten berücksichtigen und die weiteren Komponenten separat rein elastisch auf Basis der Berechnung des klassischen Materialmodells bestimmen.

Diese hybride Nachberechnung wurde berücksichtigt, um die auf diese Weise trainierte ML-Materialmodelle auf Basis von Versuchsdaten weitertrainieren zu können, da in diesem Fall nur diese drei Dehnungskomponenten direkt abgemessen werden können.

Als weiterer hybrider Modellansatz wurde die Möglichkeit untersucht ein klassisches linear elastisches Materialmodell mit einem ML-Materialmodell, welches Plastizität berücksichtigt zu kombinieren, indem für kleine Dehnungen das linear elastische, klassische Modell eingesetzt wird und bei größeren Werten die Vorhersage des ML-Modells übernommen wird.

Obwohl verschiedene Möglichkeiten die Prognose des Übergangsbereiches zwischen klassischer linear elastischer Berechnung und der Vorhersage des ML-Materialmodells im plastischen Bereich zu bestimmen (beispielsweise durch gewichtete Summen mit variabler Gewichtung) führte dieser Ansatz zu keinen ausreichend guten Modellprognosen.

AP3.2: Weiterentwicklung der ML-Module für Versuchsdaten

Für das Training von ML-Materialmodellen basierend auf Daten aus Versuchen mussten im Projekt alternative Fehlerfunktionen (Loss-Funktionen) entwickelt werden auf Basis derer die trainierbaren Parameter der ML-Materialmodelle angepasst werden, da die korrekte Ausgabe der Modelle (lokalen Spannungen) im Versuch nicht abgemessen werden können.

Im Verbund wurden hierfür verschiedene Loss-Funktionen entwickelt und vom Projektpartner IFB implementiert. Die konventionellen Trainingsalgorithmen für ML-Modelle können hierbei nicht direkt auf diese neu entwickelten, alternativen Fehlerfunktionen angewendet werden.

Seitens Mercedes-Benz wurden deshalb neue Trainingsmethoden entwickelt und implementiert um die ML-Materialmodelle (neuronale Netze) auf Basis der neuartigen Loss-Funktionen anzupassen.

Im Rahmen dessen wurden Evolutionäre Algorithmen genutzt, um das Training der ML-Materialmodelle unabhängig der exakten Formulierung der Loss-Funktionen betrachten zu können (siehe Abbildung 79). Es wurden sowohl verschiedene bestehende Algorithmen (wie beispielsweise Covariance-Matrix-Adaption aus [Han96]) betrachtet und ins Training integriert als auch eigene, neuartige Optimierungsalgorithmen entwickelt, implementiert und angewendet (siehe Veröffentlichung 19.01.2023, Computer Methods in Applied Mechanics and Engineering). Für das Training von neuronalen Netzen wurde außerdem gezeigt, dass der Backpropagation-Algorithmus für das Training von ML-Materialmodellen mit Versuchsdaten angepasst werden kann und ausgearbeitet, wie die Berechnung der Gradienten für die im Projekt entwickelten Fehlerfunktionen aussieht. Dieser Ansatz wurde implementiert und validiert für den Spezialfall eines Feed-Forward neuronalen Netzes ohne zwischenliegende Schichten.

Die Methode für das Training mit Versuchsdaten wurde zunächst für ein linear elastisches ML-Materialmodell validiert, indem ein vortrainiertes Feed-Forward neuronales Netz auf Basis eines simulierten Zugversuchs (bereitgestellt durch den Projektpartner IFB) auf andere Modellparameter (E-Modul und Querkontraktionszahl) weitertrainiert und angepasst wird (siehe Veröffentlichung 19.01.2023, Computer Methods in Applied Mechanics and Engineering).

Die Methode wurde anschließend validiert durch eine Anpassung eines rekurrenten neuronalen Netzes für das elastoplastische Materialmodell *MAT_024 für einen DP600 Stahl auf einen DP800 Stahl (vorgestellt auf der LS-Dyna Konferenz 2023), sowie eine Anpassung eines ML-Materialmodells für ein Aluminium auf den DP800 Stahl jeweils auf Basis verschiedener, simulierter Zugversuche (bereitgestellt durch den Projektpartner IFB).

In der Validierung konnte gezeigt werden, dass das ML-Materialmodell die Spannungen aus dem Versuch, welcher im Training genutzt wird, sehr gut vom angepassten ML-Materialmodell vorhergesagt werden können. Eine gute Verallgemeinerungsfähigkeit der Modelle basierend auf Versuchsdaten zu erreichen hat sich allerdings aufgrund der sehr limitierten Daten (gegeben durch einzelne Versuche) als schwierig erwiesen. Die Vorhersage von zufällig gewählten Dehnungs-Spannungsverläufen, welche nicht im Training genutzt wurden, konnte durch das Training basierend auf einfachen Zugversuchen nicht verbessert werden. Aus diesem Grund wurde das Training basierend auf einer vom Projektpartner IFU entwickelten und bereitgestellten neuartigen simulierten Versuchsprobe getestet und auf diese Weise die Vorhersage des Modells von zufällig gewählten Dehnungs-Spannungsverläufen leicht verbessert werden. Die ML-Materialmodelle, welche auf Basis der simulierten Versuche trainiert wurden, konnten im Rahmen einer Validierung in Zugversuch- und Hutprofil-Simulationen angewendet werden.

Ein weiterer Unterschied beim Training mit Versuchsdaten ist die Berücksichtigung mehrerer unterschiedlicher Loss-Funktionen. Diese können für das Training durch eine gewichtete Summe zusammengefasst und das mehrkriterielle Optimierungsproblem in ein einkriterielles transformiert werden (*weighted sum scalarization*). Ein Nachteil dieser Skalarisierung ist die Notwendigkeit der Festlegung geeigneter Gewichte für die unterschiedlichen Zielfunktionen, da die gefundene Lösung stark von der Wahl dieser Gewichte abhängt. Aus diesem Grund wurde das Training von ML-Materialmodellen zusätzlich als mehrkriterielles Optimierungsproblem mithilfe des Optimierungsalgorithmus *NSGA-III* aus [Deb14] betrachtet (vorgestellt auf der LS-Dyna Konferenz 2023).




Abbildung 79: Externe Optimierung neuronaler Netze beim Training mit Versuchsdaten mit Evolutionären Algorithmen

AP3.3: Entwicklung der Schnittstelle für die Anwendung von hybriden ML-Modellen (MLOps)

Der Übergang von der ML-Modellierung zum Betrieb von ML-Applikationen ist herausfordernd. Der Lebenszyklus von ML-Softwareprodukten unterscheidet sich von klassischer Software. Die wichtigsten Herausforderungen dabei sind Skalierbarkeit, Versionskontrolle, Reproduzierbarkeit und die interdisziplinäre Zusammenarbeit. Methoden aus dem MLOps-Bereich (kurz für Machine Learning Operations) können diese Herausforderungen lösen. Für die Entwicklung einer effizienten Anbindung der ML-Module an Training und Anwendung wurden zunächst in Interviews mit allen Projektpartnern erhoben, welche ML/MLOps Technologien bereits verwendet werden (Algorithmen, Softwarepakete und Validierungsprozesse) und welche die wichtigsten Anforderungen an die gemeinsamen Schnittstellen zu den ML-Modulen aus der jeweiligen Sicht des Projektpartners sind. Dafür wurde ein ausführlicher Fragebogen entwickelt, mit allen Projektpartnern ausgefüllt und zusammengeführt. Widersprüche wurden geklärt und die Ergebnisse präsentiert. Darauf aufbauend wurde ein großer Katalog von Softwarewerkzeugen für MLOps und weitere Tools mit den aktuellen Vorgehensweisen, Anforderungen und Rahmenbedingungen aller Partner abgeglichen und Empfehlungen wurden herausgearbeitet. Neben Anforderungen und den bereits vorhandenen Tools aller Projektpartner wurden dabei eigene Erfahrungen mit MLOps Tools und Analysen, Ratings und Vergleiche anderer Experten verwendet. Der Katalog umfasst folgende Empfehlungen:

- Ein gemeinsames Repository, beispielsweise Gitlab oder privates Github, wird für die Zusammenarbeit auf Codeebene empfohlen, um eine zentrale Plattform für die Codeverwaltung zu gewährleisten.
- Die Verwendung von Git wird empfohlen, wobei GitHub oder Gitlab für die Zusammenarbeit noch besser sind, da sie zusätzliche Funktionen für das Projektmanagement bieten.

- Es wird empfohlen, auf Docker zu verzichten, da dies nicht von allen Partnern unterstützt wird und somit Kompatibilitätsprobleme entstehen könnten.
- Python-Abhängigkeiten sollten in einer "requirements.txt" Datei zur Verfügung gestellt werden, um die Einrichtung und Installation zu erleichtern.
- Für hohe Code-Qualität empfiehlt sich die Verwendung von Tools wie Black für das Formatting und pylint für das Linting, um die Lesbarkeit und Wartbarkeit des Codes zu verbessern.
- Manuelle Datenversionierung oder die Verwendung des Tools "Data Version Control" (DVC) wird für die Versionskontrolle vorgeschlagen, um die Nachverfolgbarkeit und Reproduzierbarkeit der Versuche zu gewährleisten.
- Das Parquet-Format wird als Standardformat für Trainingsdaten empfohlen, während pandas für die Datenanalyse und Vorverarbeitung genutzt werden sollte, da es effizient und gut dokumentiert sind.
- Für Visualisierungen werden matplotlib, seaborn oder plotly empfohlen, da sie gut miteinander kombinierbar sind und eine Vielzahl von Diagrammtypen unterstützen.
- Hyperparameter-Tuning sollte mit einem passenden Tool, wie z. B. Optuna, durchgeführt werden, um optimale Modellparameter zu finden und die Modellleistung zu verbessern.
- Bei Deep Learning Frameworks empfehlen wir Keras (in Tensorflow) oder PyTorch - je nach den eigenen Vorkenntnissen, da sie eine große Community und umfangreiche Dokumentationen haben.
- Für das Tracking von Experimenten wird die Verwendung von MLFlow empfohlen, um einen Überblick über verschiedene Modellversionen und -metriken zu behalten.

Eine Beispielimplementierung zur Demonstration der empfohlenen Tools wurde implementiert und den Projektpartnern zur Verfügung gestellt. Diese demonstriert die Einrichtung der Umgebung. Es wird gezeigt, wie die erforderlichen Bibliotheken wie MLFlow, Optuna und PyTorch installiert und konfiguriert werden. Danach werden Daten im Parquet-Format gelesen und in Trainings-, Validierungs- und Testdaten unterteilt. Es wird ein LSTM (Long Short-Term Memory) Netzwerk mit PyTorch trainiert und dessen Hyperparameter mit Optuna optimiert. Dabei wird der Validierungssplit für die Validierung und der Testsplit für die abschließende Evaluation verwendet. Die Verwaltung von Trainingsdaten und Modellen wird dabei in MLFlow demonstriert.

AP3.4: Untersuchung möglicher Kombinationen von mehreren ML-Modulen

Es wurden unterschiedliche Kombinationen von ML-Modellen und Methoden (Ensemble-Modelle) für die Vorhersage untersucht. Hierfür wurden einerseits unterschiedliche ML-Methode

kombiniert, wie beispielsweise ein separates Spline-Regressionsmodell für die Vorhersage der plastischen Dehnung kombiniert mit einem Feed-Forward neuronalen Netz für die Vorhersage der Spannungen. Die Vorhersage dieser Modelle konnte gegenüber den beiden einzelnen ML-Methoden nicht signifikant verbessert werden.

Weiterhin wurden unterschiedliche Feed-Forward neuronale Netze, die sich in ihrer genauen Netzarchitektur bzw. bezüglich des Trainingsdatensatzes unterscheiden für die Vorhersage kombiniert, wodurch in manchen Fällen die Fehlerfortpflanzung leicht verringert werden konnte.

AP4: Holistische Materialmodelle

AP4.1: Bestimmung der Vollständigkeit der Datenbasis

Ein Datensatz aus einer Hutprofil-Simulation wurde für einen Vergleich zu den in AP2 generierten Trainingsdatensätzen herangezogen. Hierfür wurden verschiedene statistische Auswertungsmethoden wie Mittelwerten, Ko-(varianzen), Häufigkeitsverteilungen sowie mechanischen Größen wie Triaxialität und plastischer Dehnung betrachtet. Außerdem wurde für den Fall des Trainings mit plastischer Dehnung eine zusätzliche Erstellung von Trainingsdaten durch die Generierung von Eingabedaten für die ML-Modelle mittels Wahrscheinlichkeitsverteilungen untersucht. Dafür wurden aus verschiedenen Bauteil-Simulationen (bspw. Hutprofil-Simulation, Zugversuch) die Verteilungen der Eingabeverteilung (ermitteln von Mittelwerten, Ko-(varianzen), passenden Wahrscheinlichkeitsverteilungen, Maximum-Likelihood-Schätzer) geschätzt und basierend auf diesen Wahrscheinlichkeitsverteilungen weitere Trainingsdatensätze generiert (siehe Abbildung 80).




Abbildung 80: Verteilung der Dehnungszinkremente, Spannungen und der plastischen Dehnung für die Hutprofil Simulation

AP4.2: Vergleich und Auswertung von State-of-the-Art ML Algorithmen

Es wurden verschiedene Modellierungsmöglichkeiten des klassischen elastoplastischen Materialmodells für den Stahl DP800 und die Einordnung des Problems im Bereich Machine Learning untersucht. Das klassische Materialmodell kann hierfür als multivariates Zeitreihenproblem ohne Beachtung der im Modell vorgegebenen Geschichtsvariablen (plastische Dehnung sowie die Spannungen des vorherigen Zeitschrittes) betrachtet und mit rekurrenten ML-Modellen wie beispielsweise Long-Short-Term-Memory-Modellen (LSTM) oder Gated-Recurrent-Units (GRU) modelliert werden oder als Regressionsproblem für einen jeweiligen Zeitschritt mit Hinzunahme der internen Geschichtsvariablen.

Für die Betrachtung als Zeitreihe wurden verschiedene rekurrente Neuronale Netze (RNN, LSTM, GRU) trainiert. Ferner wurden Transformer für Zeitreihen betrachtet, aber nicht näher verfolgt, da diese aufgrund der langen vorliegenden Sequenzen in Simulationen nicht praktisch anwendbar sind.

Für den Fall der Betrachtung als Regressionsproblem wurden Entscheidungsbäume (unter Berücksichtigung verschiedener Regularisierungsmethoden, wie beispielsweise eine Beschränkung der Baumtiefe) und Random Forests trainiert. Weiterhin wurden Feed Forward neuronale Netze (FFNN) und Regressionsmodelle mit vorheriger Spline Transformation trainiert. Bei letzteren Modellen wurden unterschiedliche Varianten bezüglich der Grade der Splines und der Knotensetzung betrachtet (Anzahl der Knoten, Art der Knotensetzung).

Die unterschiedlichen, trainierten ML-Materialmodelle wurden vor dem Einsatz in den Validierungssimulationen ausgewertet, anhand unterschiedlicher Testdatensätze (zufällig generierte Daten und Datensätze aus Bauteil-Simulationen).

Hierbei wurden verschiedene Metriken betrachtet (z.B. R^2 -Werte, Worst-Case-Pfade) und für die Feed-Forward-Varianten eine Berücksichtigung der Fortpflanzung des Fehlers in die Auswertung integriert, da eine Ungenauigkeit in der Vorhersage der Modelle durch die Eingabe der Modelle im nächsten Zeitschritt weitergegeben wird und so verstärkt werden kann.

AP4.3: Entwicklung von ML-Verfahren zur holistischen Materialmodellierung

Da viele der ML-Modelle insbesondere bei FFNN zu Beginn einer Simulation den Nullzustand der Spannungen nicht ausreichend gut vorhersagen können und aufgrund dessen der Fehler innerhalb der Simulation schon zu Beginn stark ansteigt, wurde basierend auf der Idee aus [Bon22] ein FFNN konstruiert, implementiert und trainiert, welches sicherstellt, dass bei einer Eingabe eines Dehnungsincrements gleich null der Spannungszustand und die plastische Dehnung (Geschichtsvariable) nicht verändert wird. Zusätzlich wurde bei diesen neuronalen Netzen

durch eine geeignete Wahl von Aktivierungsfunktionen sichergestellt, dass die plastische Dehnung nicht negativ ist, da dies zu Abbrüchen von Simulationen mit den ML-Modellen führen kann. Die Performanz der Feed-Forward neuronalen Netze mit Hinblick auf die Fortpflanzung des Fehlers in Simulationen konnte dadurch deutlich verbessert werden.

Für diese Art der Feed Forward Netze, für konventionelle FFNN, sowie für die rekurrenten neuronalen Netze (GRUs, LSTMs) und die LMSC-Modelle aus [Bon22] wurden ausführliche Hyperparameterstudien durchgeführt und die besten daraus resultierenden Modelle in den Demonstratorsimulationen validiert.

AP4.4: Evaluierung der Genauigkeit, Robustheit und Effizienz der Modelle

Die trainierten Modelle wurden ausgewertet sowohl anhand von Testdaten, welche auf gleiche Weise wie die Trainingsdaten generiert wurden (zufällig generierte Dehnpfade) als auch anhand von Daten aus Dehnpfaden von Validierungssimulationen. Bei Letzterem wurde im Fall von Regressionsmodellen zusätzlich der Fall betrachtet, dass die vom Modell vorhergesagte Ausgabe in einem Zeitschritt für die Eingabe des folgenden Zeitschrittes übernommen wird, sodass die Fortpflanzung des Fehlers des ML-Modells, wie es auch bei der Anwendung des ML-Modells innerhalb einer Simulation der Fall ist, berücksichtigt wird. Die vielversprechendsten Modelle wurden in den unterschiedlichen Validierungssimulationen eingesetzt.

AP4.6: Untersuchung von Transfer-Learning Verfahren zur Beschleunigung des Modellierungsprozesses

Um die im Projekt erzeugten Materialmodelle anhand von Demonstratoren zu validieren, müssen die Modelle in die Simulation mit LS-DYNA eingebunden werden. Der kanonische Weg, Materialmodelle außerhalb des Lieferumfangs bereitzustellen, sind die LS-DYNA User Materials (UMATs). UMATs werden in der Regel in Fortran oder C/C++ erstellt und bedienen eine von LS-DYNA bereitgestellte API. Der kompilierte Code kann dann entweder monolithisch oder modular zu LS-DYNA hinzugelinkt werden. Die Modelle im Projekt wurden allerdings in Python entwickelt, um die etablierten Frameworks zum Maschinellen Lernen, wie z.B. Tensorflow oder PyTorch, nutzen zu können.

Daher wurde im Projekt eine auf Interprocess Communication (IPC) basierende Schnittstelle aus dem BMBF-Projekt AIAx übernommen und erheblich weiterentwickelt. Über ein einheitliches UMAT, dessen einzige Aufgabe das Durchreichen der In- und Outputs per IPC ist, kommuniziert die eigentliche Simulation mit einem separaten Prozess, der in Python geschrieben ist. Dieser Prozess nimmt in einer Endlosschleife die Inputs eines Materialmodells (aktuelle Deh-

nungsinkremente, Geschichtsvariablen und vorangegangene Spannungen) entgegen, ruft damit ein vom Anwender bereitgestelltes Python-Materialmodell auf und gibt dessen Ergebnisse (Spannungen, aktualisierte Geschichtsvariablen) per IPC an LS-DYNA zurück.




Abbildung 81: Schematische Darstellung der Interprozesskommunikation der im Projekt verwendeten LS-DYNA-Python-Schnittstelle

Diese Schnittstelle erlaubt das Einbinden beliebiger in Python geschriebener Materialmodelle, insbesondere auch solcher, die AI-Framework verwenden. Im Hinblick auf die Rechenzeit ist dieser Ansatz nicht ansatzweise performant genug, um große Modelle in akzeptabler Zeit zu rechnen. Dafür ermöglicht die Schnittstelle das schnelle Testen von Modellen ohne die fehlerträchtige und vor sehr zeitaufwendige Nachimplementierung von State-of-the-Art AI-Methoden. Erst wenn schließlich ein Modell eine hinreichende Prognosegüte erreicht hat, muss für den produktiven Einsatz das Modell einmalig nach Fortran übersetzt werden.

AP6: Versuchsautomatisierung

AP6.4: Festlegung der zu automatisierenden Prozessanteile (Software)

Um eine hochgradige Automatisierung der Charakterisierungsversuche zu erreichen und ausreichende Datenmengen für das Training neuer ML-Werkstoffmodelle zu generieren, besteht die Notwendigkeit, einen großen Umfang an Versuchsdaten für das Training vorzubereiten. Hierfür sind geeignete Datenformate erforderlich. In diesem Kontext wurden gemeinsame Treffen und Workshops zum Festlegen der Datenformate für die Trainingsdaten durchgeführt. Darauf aufbauend wurden Konverter für die Überführung der Daten aus Simulationen (LSDYNA) und für Daten aus den Versuchen (GOM) in ein gemeinsames Parquet-Format implementiert und den Partnern zur Verfügung gestellt. Darauf aufbauend wurde eine Beispielimplementierung für ein Training auf Daten in diesem Format implementiert und zur Verfügung gestellt. Ein besonderer Fokus lag dabei auf der erreichbaren Performance mit dem Datenformat sowie der Untersuchung unterschiedlicher Möglichkeiten, die Daten für das Training zu laden, je nachdem, ob sie in den Arbeitsspeicher passen oder nach und nach geladen werden müssen.

Außerdem wurde die Verwendung eines Ähnlichkeitsmaßes für Versuchsdaten vorgeschlagen. Es ermöglicht:

- Einfache übersichtliche Darstellung der Versuche in Ähnlichkeitskarten
- Erkennung von potenziellen Ausreißern
- Unterstützung bei der Exploration der Daten

Dazu werden die Daten aus Versuchen mit einem Autoencoder reduziert. Dieses Vorgehen ermöglicht es, kompakte Repräsentationen der komplexen Daten zu bestimmen, die eine (verlustbehaftete) Rekonstruktion der Eingabedaten aus einem einzigen Vektor ermöglichen. Diese Embeddings können als Merkmalsvektoren für die Ähnlichkeitssuche und Datenexploration verwendet werden. Durch eine weitere Dimensionsreduzierung durch UMAP (Uniform Manifold Approximation and Projection) können die Versuche in einer 2D Ähnlichkeitskarte dargestellt werden s. Abbildung 82. Hier erkennt man eine gute Trennung der Versuche nach Versuchsart und Belastungsgeschwindigkeit schon bei der Verwendung sehr weniger (Daten aus weniger als 50 Versuchen) Trainingsdaten.




Abbildung 82: 2D Ähnlichkeitskarte der Versuche

Für die Validierung der Modelle ist aufgrund der Datenmengen ein strukturiertes Vorgehen notwendig. Dafür wurde eine entsprechende 3-stufige Validierungsvorlage für ML-basierte Materialmodelle entworfen. Die erste Stufe umfasst den lokalen Vergleich der Simulationsergebnisse des ML-Modells mit den Simulationsergebnissen eines klassischen Materialmodells. In der zweiten Stufe werden die Ergebnisse anhand von globalen Metriken verglichen, die aus dem

Anwendungsfall motiviert sind - beispielsweise die maximale Differenz in der von Mises Spannung oder Unterschiede in Auswertungskennzahlen einer Crashsimulation. In der dritten Stufe werden dann die Simulationsergebnisse mit realen Versuchsergebnissen verglichen.

AP6.5: Entwicklung eines softwaregestützten Verfahrens zu Training und Validierung von ML-basierten Materialmodellen

Um die großen Datenmengen, die durch die Automatisierung entstehen, effizient für das Training nutzen zu können, wurde ein webbasiertes System für das Training von ML-Materialmodellen entwickelt.

Dieses System umfasst Funktionen zum Laden und Visualisieren der Trainingsdaten (Test und Simulation). Es ermöglicht die Transformation der geladenen Daten, einschließlich der Erstellung zusätzlicher Merkmale (beispielsweise Spannungsnormen) und Einbettungen für Ähnlichkeitsbetrachtungen. Die Transformationen können gespeichert werden. Zudem wurde eine Python API für den einfachen Zugriff auf Trainingsdaten implementiert.

Das System bietet eine Basis-GUI (basierend auf Plotly-Dash) mit vier Tabs für die einzelnen Modellierungsschritte:

- Simulationsdatenverwaltung,
- Vortraining,
- Experimentverwaltung
- Fine-Tuning.

Es enthält GUI-Komponenten für die Auswahl, Selektion und Darstellung der Trainingsdaten sowie Basis-Visualisierungen. Dazu gehören beispielsweise das Plotten von Dehnungs- und Spannungspfaden und der zugehörigen Verteilungen.

Für die Sicherung der Konsistenz der Trainingsdaten wurden ML-basierte Funktionen zur Erkennung von Ähnlichkeiten und Ausreißern integriert. Ein Autoencoder wurde zur Generierung von Ähnlichkeiten für Dehnungspfade und Kurven für den Spannungs-Dehnungsverlauf sowie Dehnungsrate und Weg-Kraft eingebunden. UMAP und PCA-Verfahren wurden für die 2D-Darstellung der Ähnlichkeiten integriert. In der so generierten Ähnlichkeitskarte können einzelne Punkte ausgewählt und die zugehörigen Dehnungs- und Spannungspfade genauer untersucht werden s. Abbildung 83.




Abbildung 83: Ähnlichkeitskarte mit ausgewählten Dehnungs- und Spannungspfaden

Das System ermöglicht die Auswahl eines ML-Modells für ein Training. Dazu wurden ein Beispielmodell (LSTM), ein Beispieltrainer (pytorch_optimize_mse), Modelle von Projektpartnern sowie Optimierer integriert.

AP6.7: Evaluation

Bei der Evaluation der Rechenzeit zeigte sich, dass ein erheblicher Flaschenhals durch die kleine Batchgröße, der vom neuronalen Netz zu verarbeitende Elemente entstand. Hier konnten nur weniger als 100 Elemente auf einmal verarbeitet werden. Dabei war der Overhead für die Vorbereitung des neuronalen Netzes und der Übergang vom Python in den effizienten Maschinencode sehr hoch. Das im Projekt am meisten verwendete neuronale Netz LMSCc benötigt bei einer Batchgröße von 128 ca. 18x so lange wie eine effiziente Implementierung eines klassischen Modells. Das klassische Modell wurde dabei in Python NUMBA implementiert. Bei einer Batchgröße von 16384 würde das LMSCc nur ca. 1.3x so viel Zeit benötigen.

Umfangreiche Workshops wurden mit den ML-Entwicklern in kleinen Runden durchgeführt, um die Nutzung des Trainingscenters zu schulen, aber auch um Feedback einzuholen und das Trainingscenter im weiteren Verlauf des Projekts zu verbessern. Dabei zeigte sich, dass die Verwendung der Python- und CLI-Schnittstellen gegenüber dem Webinterface stark bevorzugt wurde (s. Tabelle 3). Deshalb wurden diese Schnittstellen während der Restlaufzeit weiter verbessert, während die WebGUI nicht weiterbearbeitet wurde.

Funktionalität		ML-Projekt-partner	Anwender-Pro- jektpartner
Verwendete Schnittstelle	Web GUI	2-2-2	1-1-0
	Python	4-4-2	1-0-0
	CLI	1-0-2	0-0-0
Visualisierungen		3-2-1	1-0-0
Ähnlichkeitsmaße		0-0-1	1-0-0
ML-Modelle laden		4-4-1	2-0-0
ML-Modelle trainieren		4-4-1	1-0-0
Validierung	Insgesamt	4-4-1	1-0-0
	Simulationsbasiert	4-4-3	1-0-0
	Pfadbasiert	1-0-1	1-0-0

0 - Nicht genutzt
 1 - Noch nicht genutzt,
 aber geplant
 2 - Wenig genutzt
 3 - Mittelmäßig genutzt
 4 - Viel genutzt

Tabelle 3: Evaluation des Trainingscenters

AP7: Demonstrator

Im Arbeitspaket 7 ging es darum, die entwickelten Methoden im industriellen Umfeld zu evaluieren. Dazu wurden ML-Materialmodelle und klassische Materialkarten bereitgestellt, um die Demonstratoren simulativ nachzubilden. Anschließend wurden die Ergebnisse evaluiert und diskutiert, um Erkenntnisse zur Anwendbarkeit der im Projekt entwickelten Methoden und Tools zu gewinnen. Ziel war es, Technologieträger zur Integration aller untersuchten Methoden und Erkenntnisse bereitzustellen und die Ergebnisse mit dem realen Versuch zu validieren.

AP7.2: Komponententests an Kunststoff-Demonstratoren

Im Rahmen des Arbeitspakets 7.2 wurde im Projekt ein Demonstrator-Bauteil in Form eines Energieabsorbers aus dem untersuchten Kunststoff PC/ABS T65 von Mercedes-Benz gefertigt. Anschließend wurden dynamische Versuche am Energieabsorber vom EMI durchgeführt. Dabei wurden unterschiedliche Größen wie Kräfte und Verschiebungen direkt auf dem Bauteil mittels DIC gemessen, um die Ergebnisse für die Validierung von Simulationen zu nutzen. Die Messungen wurden vom IFB und EMI durchgeführt.



Abbildung 84: Smart-Crashbox als Kunststoff Demonstrator im AP7.2

AP7.3: Hardware- Umformversuche für metallischen Werkstoff

AP7.6: Simulation – Umformen: Blechwerkstoff mit ML- und klassischen Modellen

In Arbeitspaketen 7.3 und 7.6 übernahm die Mercedes-Benz AG die Verantwortung für mehrere Aufgaben. Dazu gehörte die Bereitstellung des Blechmaterials sowie für die Untersuchung der Eigenschaften des Werkstoffs DP800HD als auch für die Herstellung der Kreuznäpfe, s. Abbildung 85 und Abbildung 86.




Abbildung 85: Platinenabmessung für die Herstellung der Kreuznäpfe



Abbildung 86: Kreuznäpfe für die Validierung von Umformsimulationen

Weiterhin wurden das Versuchsprotokoll zu den Kreuznapfversuchen sowie die Einstellungen der Kreuznapf-Versuche in Abstimmung mit dem IFU ausgearbeitet. Insgesamt wurden 8

Kreuznäpfe mit unterschiedlichen ARGUS-Rastern hergestellt, um das Umformverhalten zu validieren, s. Tabelle 4. Dabei wurde die optische Messung im Detail durchgeführt und gleichzeitig der Einfluss des Rasters auf das Reibverhalten überprüft.

Anzahl der Platinen	ARGUS-Raster	Material, Zuschnitt & Ziehparameter
2	innen und außen	Material: DP800HD Dicke: 1,5mm Zuschnitt: 320×275 – 45°× 61 mm Niederhaltungskraft: 800 kN Ziehtiefe: 40 mm Ziehspalt: 3 mm Ziehradius: 10 mm
2	nur innen	
2	nur außen	
2	ohne	

Tabelle 4: Versuchsmatrix - Kreuznäpfe

Zur Bestimmung der Umformgrenzen und des Versagensverhaltens wurden weiter zwei Versuche durchgeführt. Dabei wurden Bleche mit den Maßen 320 x 275 mm - 45° x 40 mm verwendet. Der erste Versuch hatte eine Ziehtiefe von 40 mm. Im zweiten Versuch wurde die Ziehtiefe je nach Ergebnis des ersten Versuchs angepasst. Wenn der erste Versuch riss oder lokal einschnürte, wurde die Ziehtiefe auf 30 mm reduziert. Wenn der erste Versuch hingegen nicht riss oder nicht lokal einschnürte, wurde die Ziehtiefe auf 55 mm erhöht. Durch diese Versuchsreihe konnten die Umformgrenzen und das Versagensverhalten des Materials bestimmt werden.

Nach der Durchführung von Hardware-Versuchen wurden die Kreuznäpfe, deren zugehörigen FE-Netze im LS-DYNA-Format sowie die Zeit-Kraft-Weg-Kurven aus den Versuchen für die Validierung von FEM-Simulationen dem Partner IFU zur Verfügung gestellt.

AP7.4: Demonstratoren für Crashsimulation

Ein Schwerpunkt im Projekt lag bei der Mercedes-Benz AG auf Materialmodelle für die Simulation von Crash-Lastfällen. Aufgrund des hohen Rechenzeitbedarfs einer Gesamtfahrzeug-Crash-Simulation in der Größenordnung von einem Tag auf einem Hochleistungs-Cluster muss hier ein Kompromiss zwischen Geschwindigkeit, Prognosegüte und numerischer Stabilität gefunden werden. Hieraus ergibt sich für gängige Werkstoffe die Festlegung auf ein Materialmodell, dessen Parametrisierung, die sogenannte Materialkarte, anhand von experimentell zu bestimmenden Materialkennwerten und -kurven für einen konkreten Werkstoff angepasst werden muss. Die Feinauslegung dieser Parameter und Kurven wird mittels Optimierung über eine Va-

Validierungspyramide erreicht: Zunächst wird klassisch in Form von Elementarversuchen eine initiale Materialkarte erstellt. Im nächsten Schritt wird mit der initialen Materialkarte ein Ersatzlastfall für ein einzelnes Bauteil (Prinzipbauteil oder Serienbauteil) simuliert und mit einem gleich aufgebauten Real-Versuch abgeglichen. Die Materialkarte wird so lange nachjustiert, bis eine zufriedenstellende Prognosegüte erreicht wird. Erst dann wird das Vorgehen schrittweise für Zusammenbauten und Teilaufbauten bis schließlich zur Validierung am Gesamtfahrzeugversuch wiederholt.

Für die Validierung der im Projekt entstandenen datengetriebenen Materialmodelle wurde ein Ersatzlastfall für ein Seitenaufprallszenario ausgewählt. Hierzu existierten bei der Mercedes-Benz AG bereits ein Hardware-Versuch eines Teilaufbaus und ein passendes Simulationsmodell.

1.7 Renumics

Über die hier aufgeführten Arbeiten hinaus hat Renumics im Rahmen von Unteraufträgen verschiedene Projektpartner bei ihren Arbeiten unterstützt.

AP6: Versuchsautomatisierung

AP6.6: Aufbau und Anwendung von (teil)automatisierten Prozessen

Das Trainingssystem aus AP6.5 wurde den Projektpartnern im gemeinsamen GIT Repository zur Verfügung gestellt. Es wurde demonstriert, wie man das gesamte Trainingssystem als Anwender oder als ML-Entwickler installieren und verwenden kann. Es fanden Weiterentwicklungen des Systems auf Basis von Feedback der Anwender statt. So wurde beispielsweise die Python Schnittstelle stärker auf die Bedürfnisse der ML-Entwickler zugeschnitten und weitere Formate unterstützt. Außerdem wurde die Visualisierung aus dem webbasierten Trainingssystem extrahiert und über Python zur Verfügung gestellt, um den Trainingsworkflow zu verbessern. Weiterhin wurde Trainingscode, der auf die speziellen Anforderungen der Partner zugeschnitten war, zusammen mit den ML-Projektpartnern entwickelt und betrieben. Für die Anwender, die möglichst einfach die generierten ML-Modelle in Simulationen verwenden wollen, wurde ein leichtgewichtiges Vorgehen implementiert und über GIT zur Verfügung gestellt. Durch eine kurze Schulung wurde erleichtert, dass alle Anwendungs-Projektpartner die Modelle verwenden können.

2 Wichtigste Positionen des zahlenmäßigen Nachweises

2.1 DYNAmore

Bei DYNAmore stellen die Personalkosten den größten Anteil der Gesamtkosten dar. Des Weiteren sind die Kosten für die Beschaffung der benötigten Geräte zur Durchführung der automatisierten Versuche signifikant. Die Ausgaben für Reisen zu den regelmäßigen Projekttreffen sind vergleichsweise gering. Eine detaillierte Aufschlüsselung aller Kostenpositionen ist im Verwendungsnachweis verfügbar.

2.2 ElringKlinger

Die wichtigsten Positionen im zahlenmäßigen Nachweis stellen bei ElringKlinger die Personalkosten. Die Konzeption, Konstruktion und Fertigung des Werkzeugs für das Demonstratorbauteil sowie die Herstellung der Demonstratoren wurde bei ElringKlinger über die „Innerbetrieblichen Leistungen“ erfasst.

2.3 Fraunhofer EMI

Den größten Teil der Projektkosten stellen am EMI die Personalkosten der wissenschaftlichen Mitarbeiter dar. Eine weitere relevante Position im zahlenmäßigen Nachweis sind die Kosten für die im Rahmen des Projekts beschafften Geräte, die für die Durchführung der experimentellen Arbeiten erforderlich waren. Die kleinste Position entfällt auf die Reisekosten für die Teilnahme an den regelmäßigen Projekttreffen. Eine detaillierte Auflistung ist im Verwendungsnachweis zu finden.

2.4 IFB

Beim zahlenmäßigen Nachweis des Instituts für Flugzeugbau sind der größte Posten die wissenschaftlichen und technischen Mitarbeitenden. Zusätzlich wurden studentische Hilfskräfte im Projekt eingesetzt und finanziert. Weitere wichtige Posten stellen Gerätekosten sowie ein vergebener Unterauftrag an die Firma Renumics GmbH, um spezifische Arbeiten für das Gesamtprojekt zu übernehmen. Dienstreisen wurden in geringerem Umfang als ursprünglich geplant wahrgenommen. Detailliert sind alle Positionen im Verwendungsnachweis aufgeführt.

2.5 IFU

Der Großteil der Zahlen des Instituts für Umformtechnik entfällt auf die wissenschaftlichen und technischen Mitarbeiter. Zusätzlich wurden studentische Hilfskräfte im Projekt beschäftigt und finanziert. Weitere wichtige Posten sind der Rechner für die Simulationen zur Entwicklung von

Probengeometrien, die Generierung von Trainingsdaten auf Einzelelementbasis sowie Vergleiche zwischen klassischen und ML-Materialkarten mit Vollkomponentensimulationen. Es wurde auch die angefallenen Kosten zur Herstellung der Werkzeuge und Probenpräparation mit einbezogen. Die Dienstreisen wurden nahezu wie geplant durchgeführt. Der Verwendungsnachweis enthält eine detaillierte Auflistung aller Positionen.

2.6 Mercedes-Benz

Die Projektmittel der Mercedes-Benz AG setzte sich aus Personal- und Materialkosten zusammen. Die Personalkosten waren ein wesentlicher Bestandteil der Arbeitskosten und umfassten die Beschäftigten in Forschung und Entwicklung. Die Materialkosten resultierten aus der Unterbeauftragung der Firma Renumics. Diese Zusammenarbeit war von großer Bedeutung für die Erreichung der Projektziele. Durch die Zusammenarbeit mit Renumics konnten wir unsere Kapazitäten erweitern und das Projekt erfolgreich abschließen. Detaillierte Informationen hierzu sind dem Verwendungsnachweis zu entnehmen.

2.7 Renumics

Die Projektmittel der Renumics GmbH wurde durch Unterbeauftragungen durch Mercedes-Benz und das IFB gestellt. Den wesentlichen Bestandteil der Kosten bilden die Personalkosten.

3 Notwendigkeit und Angemessenheit der geleisteten Arbeit

In dem Kooperationsprojekt wurden Synergieeffekte zwischen der anwendungsorientierten Expertise der Industriepartner und den wissenschaftlich-methodischen Kompetenzen der Forschungsinstitute produktiv genutzt, sodass die geleisteten Aufwände zu guten Ergebnissen geführt haben. Darüber hinaus wurde durch die Einbindung von assoziierten Partnern über den gesamten Verlauf der Forschungs- und Entwicklungsarbeiten die Anwendungsperspektive immer gegenwärtig gehalten, und als letztendliches Erfolgskriterium berücksichtigt. Insgesamt kann angesichts der erzielten Ergebnisse resümiert werden, dass die Arbeiten sinnvoll und notwendig waren für die Eröffnung neuer Wirtschaftspotentiale und zur Stärkung der technologischen Basis des beteiligten Unternehmens im Sinne der Sicherung vorhandener Arbeitsplätze, Schaffung neuer Arbeitsplätze und Stärkung der Konkurrenzfähigkeit gegenüber internationalen Mitbewerbern. Die geleistete Arbeit war zur Vorbereitung und Durchführung der in den einzelnen Arbeitspaketen aufgeführten Untersuchungen erforderlich. Die geleistete Arbeit entspricht in vollem Umfang der Vorhabenbeschreibung und war daher für die Durchführung des Projektes notwendig und angemessen. Insgesamt waren die durchgeführten Arbeiten zur

Erreichung der einzelnen Ziele innerhalb der Arbeitspakete wie auch zur Erreichung der übergeordneten Ziele des Forschungsprojektes erforderlich.

3.1 DYNAmore

Im Rahmen des Projekts wurden bei DYNAmore verschiedene Schwerpunkte verfolgt, darunter die Entwicklung von Machine-Learning-Modellen, die Optimierung von Probengeometrien und die Automatisierung von Versuchen. Expertenteams waren für die Umsetzung dieser Themenbereiche verantwortlich und investierten beträchtliche Arbeitszeit sowie Ressourcen in die Realisierung der Ideen. Insbesondere erforderte die Automatisierung der Versuche erhebliche Investitionen in Hardware. Jeder dieser Schwerpunkte trug maßgeblich zum Gesamterfolg des Projekts und zur Erreichung seiner Ziele bei.

3.2 ElringKlinger

ElringKlinger verfolgte mit der Mitwirkung im Verbundprojekt „AIMM“ das Ziel, die Übertragbarkeit der entwickelten Modellansätze für die Materialmodellierung auf kundenspezifische Problemlösungen zu untersuchen. Die, durch die interdisziplinäre Zusammenarbeit, entwickelten Modellansätze, ermöglichen zukünftig eine Verringerung des Zeitbedarfs für die simulationsgestützte Bauteilauslegung und somit eine signifikante Reduktion von Entwicklungszeiten. Die Erfolgsaussichten des Projektes lagen für ElringKlinger zum einen in der Übertragung der neuartigen Modellansätze in die vorhandene Simulationsumgebung sowie in dem Nachweis der Ergebnisqualität durch den im Rahmen des Projekts durchgeführten Abgleich mit experimentellen Ergebnissen. Aufgrund der wissenschaftlichen und technischen Fragestellungen, Risiken und Herausforderungen, konnte das Projekt nicht aus eigenen Mitteln finanziert werden, ElringKlinger war auf die Förderung angewiesen. Alternative Finanzierungsmöglichkeiten standen bei ElringKlinger nicht zur Verfügung. Die durchgeführten Forschungsarbeiten waren im vorwettbewerblichen Bereich und daher mit hohen technischen und wirtschaftlichen Risiken verbunden. Auch der Zugang zu den, durch das schlagkräftige und interdisziplinär aufgestellte Konsortium zur Verfügung stehenden, Informationen wäre ohne den Verbund in einem Fördervorhaben nicht realisierbar gewesen.

Die durchgeführten Arbeiten banden personelle und technische Ressourcen bei ElringKlinger. Das Verbundvorhaben hat erheblich dazu beigetragen, die Kompetenzen und die Sichtbarkeit von ElringKlinger zu stärken und die Position des Automobilzulieferers in der europäischen Fahrzeugbranche als Ideengeber und Lösungsanbieter auszubauen.

3.3 Fraunhofer EMI

In AIMM wurden nicht nur neuartige Ansätze für ML-Materialmodelle verfolgt, sondern parallel dazu neue Methoden und Vorgehensweisen entwickelt, welche die effiziente Nutzung solcher Modelle überhaupt erst ermöglichen. Hierzu gehören beispielsweise das Training der Modelle ohne FE-Kopplung anhand von Versuchsdaten, neuartige Probekörpergeometrien und die Automatisierung. Die Förderung des Projekts war notwendig, um sich mit diesem breiten Spektrum an Arbeiten in der erforderlichen Tiefe auseinandersetzen und Ergebnisse erzielen zu können.

Neben den theoretischen und numerischen Arbeiten wurde im Projekt ebenfalls eine Vielzahl an Experimenten durchgeführt. Insbesondere für die Messungen bei hohen Dehnraten ist spezialisierte Messtechnik erforderlich, die mit Hilfe der Fördermittel beschafft werden konnte.

Die Mittel, sowohl für Personal als auch für Anlagen, wurden zweckbestimmt und sinnvoll eingesetzt.

3.4 IFB

Die Förderung des **Instituts für Flugzeugbau** (IFB) durch Bundesmittel war aufgrund der spezifischen Anforderungen und Zielen des Projekts gerechtfertigt. Die Arbeiten zielten darauf ab, fortschrittliche Materialmodelle und Automatisierungstechniken zu entwickeln, die für die Verbesserung von Produktionsprozessen und die Stärkung der technologischen Kompetenz wesentlich sind. Die Notwendigkeit der Bundesförderung ergab sich aus dem hohen Innovationsgrad, dem spezialisierten Ressourcenbedarf und der strategischen Bedeutung der Forschung für den wissenschaftlichen Fortschritt und die industrielle Anwendung. Die Förderung von Gegenständen, wie dem kollaborierenden Roboter und den 3D-Messsystemen zur Dehnungs- und Probekörpervermessung wurden in die im Projekt erarbeiteten Methoden sinnvoll eingegliedert und waren notwendig, um die Projektziele zu erreichen. Dieses Engagement unterstützte nicht nur die Erreichung der projektbezogenen Ziele, sondern trug auch zum langfristigen Wissensaufbau und zur technologischen Weiterentwicklung bei.

Diese Vorarbeiten und Aktivitäten im Projekt verdeutlichen die Relevanz und Angemessenheit der Forschungsausrichtung des Instituts im Projekt AIMM, das darauf abzielt, die digitale Werkstoffmodellierung und zugehörige Werkstoffprüfung durch den Einsatz von KI und Roboterautomatisierung weiterzuentwickeln. Die zugewiesenen Mittel wurden zweckbestimmt und sinnvoll eingesetzt. Die Mitarbeiter und Mitarbeiterinnen waren kontinuierlich im Projekt beschäftigt, und die gewonnenen Ergebnisse sind einzigartig und von hohem Neuheitsgrad.

3.5 IFU

Die Bundesförderung des **Instituts für Umformtechnik (IFU)** war durch die spezifischen Projektanforderungen und -ziele berechtigt. Die Arbeiten, die vom IFU übernommen wurden, hatten hauptsächlich zum Ziel, Strategien zur Automatisierung von Prüfungen zu entwickeln, neue Probengeometrien und Prüfverfahren zu finden, die große Datenmengen für das Training von maschinellen Lernmodellen erzeugen können, die Entwicklung von maschinellen Lernmodellen für den Anwendungsfall der Metallumformung zu unterstützen und Demonstrationstests durchzuführen, um die Anwendbarkeit von maschinellen Lernmodellen bei der Simulation von Umformprozessen zu validieren. Die Arbeiten des IFU lieferten die für das Gesamtziel des Projektes erforderlichen Ergebnisse und trugen zur Erreichung des Gesamtziels bei. Die frühzeitige Entwicklung von Konzepten zur Automatisierung bildete die Grundlage für den erfolgreichen Abschluss dieses umfangreichen Arbeitspaketes. Die Optimierung der Probengeometrien und die Erstellung von virtuellen Trainingsdaten wurde durch die hohe Rechenleistung der geförderten Rechner ermöglicht. Die geförderten LsDyna-Lizenzen waren notwendig, um langwierige Rechenaufgaben zu realisieren. Die entwickelten praxisnahen Methoden, wie die Ausrichtung von optischen Messergebnissen und die Abbildung von Messwerten aus der Probe auf das Berechnungsnetz für die gesamte Probe, können als Arbeitshilfe für weitere Forschungs- und Industrieprojekte wiederverwendet werden. Ohne die Demonstratortests für das Umformverhalten wäre es nicht möglich gewesen, die Eignung der ML-Modelle für diese Anwendung zu prüfen. Diese Aktivitäten im Rahmen des Projekts zeigen die Relevanz und Angemessenheit des Forschungsschwerpunkts des Instituts im AIMM-Projekt. Ziel war es, bessere und flexiblere Wege der Materialmodellierung und -prüfung durch verbesserte und moderne Ansätze zu fördern. Die zugewiesenen Mittel wurden zweckgebunden und sinnvoll eingesetzt. Die Forscher waren kontinuierlich an dem Projekt beteiligt und haben einzigartige und höchst innovative Ergebnisse erzielt.

3.6 Mercedes-Benz

Im Rahmen des Projektes waren erhebliche personelle Kapazitäten von Experten auf dem Gebiet der numerischen Methoden notwendig. Die Entwicklung der ML-basierten Materialmodelle erforderte zunächst eine umfangreiche Literaturrecherche und anschließend eine Implementierung vieler verschiedener, teils neuartiger ML-Modellen und Trainingsmethoden, welche alle hinsichtlich ihrer Performanz evaluiert und validiert werden mussten.

3.7 Renumics

Die Kapazitäten für die einfache Zugänglichkeit der ML-Methoden für Anwender und ML-Entwickler zu verwenden, war ein wichtiger Schritt, um die Effizienz und Produktivität im Gesamtprojekt zu steigern. ML-Entwickler sind Experten auf ihrem Gebiet, doch die Zusammenarbeit und Integration ihrer Arbeit in größere Systeme kann eine Herausforderung darstellen. Durch die Mitarbeit am gemeinsamen GIT Repository und einer benutzerfreundlichen Schnittstelle im Trainingscenter wurde nicht nur die Zusammenarbeit zwischen den Entwicklern verbessert, sondern auch die Integration ihrer Arbeit in den allgemeinen Workflow erleichtert. Dies ermöglichte es den ML-Entwicklern, sich auf die Entwicklung und Verbesserung von ML-Methoden zu konzentrieren. Gleichzeitig konnten Anwender von der einfacheren Anwendung der ML-Methoden profitieren.

4 Voraussichtlicher Nutzen und Verwertbarkeit der Ergebnisse im Sinne des fortgeschriebenen Verwertungsplans

4.1 DYNAmore

Durch die Beteiligung am Projekt AIMM ist DYNAmore in einer einzigartigen Position, um direkt von den sich ständig weiterentwickelnden Möglichkeiten zu profitieren, die unseren Kunden zur Verfügung gestellt werden können. Unser Engagement bei der Entwicklung neuer Methoden und Techniken ist daher von entscheidender Bedeutung, um unseren Kunden stets innovative Lösungen bieten zu können. Durch die Integration neuer Funktionalitäten in unsere Software erweitern wir nicht nur deren Leistungsfähigkeit, sondern stärken auch unsere Wettbewerbsposition im Markt. Darüber hinaus ermöglicht uns der Aufbau von Fachwissen in diesem Bereich, die Agilität und Reaktionsfähigkeit unseres Unternehmens zu erhöhen, um schnell auf sich ändernde Kundenanforderungen reagieren zu können. Wir erkennen nicht nur ein enormes Potenzial in dem untersuchten Gebiet, sondern sehen auch die Chance, unsere Innovationskraft zu stärken und neue Geschäftsmöglichkeiten zu erschließen.

DYNAmore wird insbesondere profitieren durch mögliche Erweiterungen von LS-DYNA sowie die neuen Fähigkeiten im automatisierten Testing. Letzteres ist für die Erzeugung von Zuverlässigen Versuchsdaten für die Charakterisierung von Materialien in großer Menge und daher zur Erzeugung von Trainingsdaten für ML-basierte Werkstoffmodelle von großem Vorteil.

Erkenntnisse und Grundlagen, die in diesem Projekt entstanden sind, werden bereits erfolgreich in ein Folgeprojekt (DigiTain) eingebracht.

4.2 ElringKlinger

Für die spätere Serienentwicklung von leichtbaueffizienten Bauteilen aus thermoplastischen (Verbund-) Materialien kann ElringKlinger nach der erfolgreichen Beteiligung am Fördervorhaben AIMM Kompetenzen anbieten, die eine signifikante Reduktion der Entwicklungszeiten von Bauteilen ermöglicht und hiermit dem Ruf nach immer kürzeren Entwicklungszyklen gerecht werden, die vor allem bei neuen OEM für die Entwicklung von Leichtbauteilen für Fahrzeuge mit alternativen Antriebskonzepten gefordert sind. Hierdurch kann ElringKlinger auch zukünftig wettbewerbsfähig bleiben, seine Marktposition halten und weiterhin ausbauen und den Entwicklungsstandort Deutschland stärken. Nach erfolgreichem Projektabschluss ist das übergeordnete Ziel, die entwickelten Technologieansätze in die internen Entwicklungsprozesse zu implementieren und hierdurch die simulative Bauteilauslegung zu beschleunigen und den zeitlichen Bedarf für die Durchführung der bislang sehr zeit- und kostenintensiven experimentellen Bauteilvalidierung zu reduzieren.

ElringKlinger verfolgt hierzu folgende Ansätze:

Kurzfristige Ziele:

- Finale Implementierung der erarbeiteten Modellansätze in bestehende Simulationsumgebung
- Erprobung und Validierung der neuen Berechnungsansätze an aktuellen Kundenprojekten durch Abgleich mit den Standardauslegungsmethoden
- Übertragung der Erkenntnisse auf die experimentelle Bauteilvalidierung und Festlegung der zukünftigen Validierungsstrategie

Mittelfristige Ziele:

- Durchführung neuer Kundenprojekte mit den entwickelten Simulations- und Validierungskonzepten

Langfristige Ziele:

- Eintritt in neue Marktsegmente durch größere Flexibilität und hieraus direkt sich ergebender größeren Kapazität bei der Bauteilauslegung
- Sicherung der Produktionsstandorte in Deutschland aufgrund größerer Produktvielfalt
- Erhalt bestehender Arbeitsplätze und Schaffung neuer Arbeitsplätze am Standort Deutschland

Weitere Punkte zur Ergebnisverwertung sind im Erfolgskontrollbericht von ElringKlinger dargestellt.

4.3 Fraunhofer EMI

Das Fraunhofer EMI profitiert in erster Linie von den Projektergebnissen durch die Etablierung eines neuen Forschungsfeldes. Während in anderen Bereich KI-Methoden bereits seit längerer

Zeit am Institut eingesetzt werden, stellt die Verwendung von ML-Materialmodellen eine Erweiterung der Kompetenzen des EMI dar. Hierfür werden die in AIMM erzielten Ergebnisse aufgearbeitet und somit für das Institut für eine weitere Verwertung nutzbar gemacht.

Weiterhin können die Tools, die im Rahmen von AP5 für die Optimierung der Probekörper entwickelt wurden, ebenfalls in anderen Projekten des EMI eingesetzt werden. Am Crashzentrum können damit beispielsweise zukünftig Versuche optimiert werden, so wie dies bereits im AP7 für den Kunststoff-Demonstrator (Crashbox) umgesetzt wurde. Die kontinuierliche Weiterentwicklung dieser Methoden erfolgte einerseits schon während der AIMM-Projektlaufzeit im Rahmen einer Masterarbeit und findet momentan innerhalb eines Folgeprojektes (DigiTain) statt.

4.4 IFB

Für das IFB erweitern die im Projekt erarbeiteten Methodiken die Kompetenzen des Instituts in Forschung und Lehre. Diese können in Vorlesungen mit Fokus auf Leichtbau sowie Materialprüfung an Studierende vermittelt werden. Für künftige Projekte stellt die Erweiterung dieser Arbeiten eine gute Basis dar. Es konnten bereits die Ergebnisse von Projekt AIMM in Folgeprojekten genutzt werden (z.B. Projekt DigiTain). Über die Projektlaufzeit wurden innerhalb des Projektes Bachelor- und Masterarbeiten sowie studentische Hilfskräfte an die Thematik herangeführt. Durch Veröffentlichungen auf nationalen sowie internationalen Konferenzen sowie mehreren Veröffentlichungen in peer-review Journalen konnten die entwickelten Methodiken einem breiten wissenschaftlichen Publikum zugänglich gemacht werden. Für die Themen, die in AIMM betrachtet wurden, sind zwei Dissertationen in Anfertigung.

4.5 IFU

Die im Rahmen des Projekts entwickelten Methoden erweitern die Kompetenzen des IFU in Forschung und Lehre. Sie werden bereits in Vorlesungen zur Werkstoffcharakterisierung und Umformtechnik integriert. Die Anwendung von KI-Methoden in diesen Bereichen wird thematisch vermittelt. Damit wird die Kompetenz des IFU und die Beteiligung an zukünftigen Projekten gestärkt. Die am IFU im Rahmen des AIMM-Projekts entwickelten Methoden wurden bereits in studentischen Arbeiten zur Materialcharakterisierung und in neuen Projekten wie dem Schwerpunktprogramm "Datengetriebene Prozessmodellierung in der Umformtechnik" (SPP 2422) eingesetzt. Im Rahmen des Projekts wurden Bachelor- und Masterarbeiten sowie studentische Hilfskräfte an das Thema herangeführt. Die entwickelten Methoden wurden durch Veröffentlichungen auf nationalen und internationalen Konferenzen der wissenschaftlichen Gemeinschaft zur Verfügung gestellt. Derzeit wird am IFU eine Industriepromotion in Zusammenarbeit mit der Firma Dynamore durchgeführt.

4.6 Mercedes-Benz

Im Zuge des AIMM-Projekts hat sich der Einsatz von Künstlicher Intelligenz (KI) im Produktentstehungsprozess, insbesondere in der digitalen Absicherungsphase, als wertsteigernd erwiesen. Die Einführung von KI-gestützten Materialmodellen revolutioniert die Materialmodellierung und verspricht erhebliche wirtschaftliche Vorteile für die Zukunft. Die Implementierung dieser KI-Technologien beschleunigt nicht nur die Entwicklung innovativer Werkstoffe durch eine verkürzte Charakterisierungs- und Modellierungsphase, sondern trägt auch zu einer rascheren Markteinführung der Produkte bei. Die Automatisierung dieser Prozesse senkt die Zeitinvestition für Materialcharakterisierung und -modellierung signifikant, was eine direkte Kosteneinsparung zur Folge hat.

Die Anwendung von Machine-Learning-Modellen steigert die Präzision der Materialmodelle, was zu einer höheren Produktqualität führen kann. Diese Modelle haben das Potenzial, herkömmliche Ansätze zu ergänzen oder zu ersetzen und ermöglichen durch ihre Effizienz eine Reduktion des Rechenaufwands. Dies resultiert in kürzeren Simulationszeiten und einer weiteren Kostensenkung. Die fortlaufende Optimierung dieser Methoden und die Integration von Expertenbewertungen gewährleisten die Akzeptanz der KI-gestützten Modelle in der Praxis. Die Forschungsergebnisse anderer Institute und Unternehmen bekräftigen die Relevanz und die wirtschaftlichen Erfolgsaussichten dieser Technologie. KI-gestützte Materialmodelle haben das Potenzial, den Materialentwicklungsprozess signifikant zu verbessern und langfristig zur Kosteneffizienz und Wettbewerbsfähigkeit von Mercedes-Benz beizutragen.

Wissenschaftlich betrachtet, haben die im Rahmen von AIMM erzielten Ergebnisse bereits zu mehreren Publikationen geführt und dienen als solide Grundlage für die fortgesetzte Zusammenarbeit mit der wissenschaftlichen AI-Community. Darüber hinaus wird das Thema in einer anstehenden Dissertation weiter vertieft. Die Übernahme der Projektergebnisse in den Produktentstehungsprozess bei Mercedes-Benz AG innerhalb der nächsten 3 bis 5 Jahre unterstreicht die Tragweite und Anwendbarkeit der Forschung. Die Weiterverwendung der Ergebnisse im BMWK-Projekt DigiTain bekräftigt zusätzlich die wissenschaftliche und wirtschaftliche Anschlussfähigkeit der Entwicklungen, was die strategische Bedeutung der KI-Materialmodelle für die Zukunftsfähigkeit von Mercedes-Benz AG hervorhebt.

4.7 Renumics

Renumics profitiert in vielfacher Hinsicht von den durchgeführten Arbeiten und der effizienteren Zusammenarbeit. Die Erfahrungen, die im Zuge der engen Zusammenarbeit mit ML-Entwicklern gewonnen wurden, können in das Open-Source-Projekt Renumics-Spotlight einfließen. Dies fördert die Nutzung und Weiterentwicklung der interaktiven Datenexploration von multimodalen Daten und verstärkt Renumics' Rolle als wichtiger Akteur in diesem Bereich. Darüber hinaus verbessert die Erfahrung der Integration von ML-Methoden in größere Projekte die Qualität und Effizienz ihrer zukünftigen Ingenieurdienstleistungen, was zu einer erhöhten Kundenzufriedenheit führt. Schließlich haben die Unterbeauftragungen durch Mercedes-Benz und das IFB zu einer Erweiterung des Netzwerks von Renumics geführt. Durch diese Kontakte besteht die Möglichkeit, zukünftige Folgeaufträge zu gewinnen.

5 Während der Durchführung des Vorhabens dem ZE bekannt gewordenen Fortschritte auf dem Gebiet des Vorhabens bei anderen Stellen

Aktuelle Recherchen bei allen Partnern im Konsortium haben keine neuen Veröffentlichungen Dritter gegenüber dem in der Vorhabenbeschreibung dokumentierten Stand der Technik ergeben.

6 Erfolgte und geplante Veröffentlichungen der Ergebnisse

A machine learning material model for structural adhesives in finite element analysis

 D. Sommer, A. Haufe, P. Middendorf

 *International Journal of Adhesion and Adhesives*, 2022.

Artificial neural networks as material models for finite element analysis

 D. Sommer, B. Troff, P. Middendorf

 Current Perspectives and New Directions in Mechanics, Modelling and Design of Structural Systems - 8th International Conference on Structural Engineering, Mechanics and Computation, 2022, Cape Town, South Africa

A strategy to train machine learning material models for finite element simulations on data acquirable from physical experiments

 P. Böhringer, D. Sommer, T. Haase, M. Barteczko, J. Sprave, M. Stoll, C. Karadogan, D. Koch, P. Middendorf, M. Liewald

 *Computer Methods in Applied Mechanics and Engineering*, 2022

Automatisierte Cobot- und DIC-gestützte Vermessung und Prüfung komplexer Prüfkörpergeometrien

 D. Platzer, M. Drašković, P. Middendorf

 28. Stuttgarter Kunststoffkolloquium, 2023, Stuttgart, Germany

An Interprocess Communication based Integration of AI User Materials into LS-DYNA

 J. Sprave, T. Erhart, A. Haufe

 14th European LS-Dyna Conference, 2023, Baden-Baden, Germany

On Accelerating Elastoplastic Material Models with Machine Learning

 G. Bokil, D. Koch, A. Haufe, H. Steeb

 14th European LS-Dyna Conference, 2023, Baden-Baden, Germany

Using Data from Physical Experiments to Train Machine Learning Material Models

 D. Sommer, P. Böhringer, M. Stoll, P. Middendorf

 14th European LS-Dyna Conference, 2023, Baden-Baden, Germany

Creating Machine-Learning-Friendly Training Data from Crash Simulation Data

 S. Zenne, J. Sprave, M. Stoll

 14th European LS-Dyna Conference, 2023, Baden-Baden, Germany

Training Machine Learning Material Models for Finite Element Simulations Based on Data available from Physical Experiments

 P. Böhringer, D. Sommer, M. Stoll, P. Middendorf

 1st Conference on Artificial Intelligence in Materials Science and Engineering, 2023, Saarbrücken, Germany

Data-driven Material Models – Quantification of Strain Information Content in Characterization Tests

 F. M. Guillén

 Master Thesis, Albert-Ludwigs-Universität Freiburg, EMI-Report A 38/23, 2023

AI in sheet metal forming

👤 *Mathias Liewald*

📍 Keynote to Mini-Symposium, IDDRG 2022, 6-10 June 2022, Lorient, France

Perspectives on AI applications in sheet metal forming

👤 *Mathias Liewald*

📍 Plenary Keynote, IDDRG 2023, 19 – 22 June 2023 in Luleå, Sweden

Stress-Free Determination of Yield Locus and Flow Curve Parameters by Partial Full-Field Measurements

👤 *Karadogan, C., Liewald, M.*

📍 14th International Conference on the Technology of Plasticity, 2023, Mandelieu, France

Investigation and Implementation of Machine-Learning-based Hybrid Material Models

👤 *G. Bokil*

📍 *Master Thesis, Institute of Applied Mechanics of the University of Stuttgart, Report Nr.: 22-II-4, 2022.*

Displacement driven simulation and material calibration based on digital image correlation Part I – Theory

👤 *C. Liebold, C. Ilg, A. Haufe, T. Usta, V. Sreenivasa*

📍 *IOP Conf. Ser.: Mater. Sci. and Eng., 2023*

Displacement driven simulation and material calibration based on digital image correlation Part II – Application

👤 *C. Ilg, C. Liebold, A. Haufe, V. Sreenivasa, C. Karadogan, M. Liewald*

📍 *IOP Conf. Ser.: Mater. Sci. and Eng., 2023*

Inverse Parameter Identification of an anisotropic constitutive model by using optically measured displacement field

👤 *M. Shetty*

📍 *Master Thesis, Institute of Applied Mechanics of the University of Stuttgart, Report Nr.: 23-II-3, 2023.*

III **Abbildungsverzeichnis**

Abbildung 1	Strukturbauteile als Metall-Kunststoff-Hybride in der Kombination von Innenhochdruckumformen (IHU) und Spritzgießen (© ElringKlinger)	6
Abbildung 2	Thermoplastische Hybride in der Kombination von thermoplastischen Halbzeugen (Organobleche) mit thermoplastischem Spritzguss (© ElringKlinger)	7
Abbildung 3	Thermoplast-Sandwichstrukturen aus recycelten C-Fasern (© ElringKlinger).....	7
Abbildung 4:	Arbeitsplan des Projekts AIMM	12
Abbildung 5	Variation der maximalen Winkel zwischen verschiedenen Dehnpfadsegmenten	21
Abbildung 6	Variation des "Rauschens" innerhalb der Segmente des Dehnpfads.....	21
Abbildung 7	Beispiel für die Übergabe eines neuronalen Feedforward-Netzes an LS-DYNA.	22
Abbildung 8	Substitution der iterativen Rückprojektion im Plastizitätsalgorithmus.....	22
Abbildung 9	Prinzipskizze der zyklischen Learning rate	25
Abbildung 10	Vergleich zyklischer und konstanter Learning Rate	25
Abbildung 11	Beispielhafte Parametrisierung der Probengeometrie.....	27
Abbildung 12	Beispielhafte Erzeugung einer Probengeometrie.....	27
Abbildung 13	Beispielhafte Darstellung aller Punkte (Bild a) und der bedeckten Fläche (Bild b)	28
Abbildung 14	Ergebnis einer Geometrieoptimierung	28
Abbildung 15	Finale Probengeometrie mit maximierter Datenstreuung.....	29
Abbildung 16	Druckversuch ohne Löcher → 26% Bedeckung im Druckbereich	29
Abbildung 17	Druckversuch mit vertikalen Löchern → 41 % Bedeckung im Druckbereich	30
Abbildung 18	Druckversuch mit horizontalen Löchern → 63% Bedeckung im Druckbereich ..	30
Abbildung 19	– quasi-statische Berechnungsmodelle Kunststoff-Modelle	37
Abbildung 20:	Links: Versuchsaufbau für Zugversuche an einer Schnellzerreißmaschine. Rechts: Dehnungsfeld kurz vor dem Versagen.	40
Abbildung 21:	Vergleich von Experiment und Simulation anhand von Zugversuchen bei verschiedenen Dehnraten.	41
Abbildung 22:	Analyse der Dehnungszustände zu einem festen Zeitpunkt (links) in einem simulierten Probekörper (rechts) unter Zugbelastung mit Hilfe des entwickelten Python-Tools.	44
Abbildung 23:	Dehnungszustände (kumuliert über alle Zeitpunkte) für die Kombination aus optimierter Zugprobe + Scherzugprobe + Druckprobe.	45
Abbildung 24:	Mechanisches Probenvermessungssystem. Links: Messtaster mit eingelegter Probe. Rechts: Steuergerät.	46

Abbildung 25: Fünf mögliche Versuchssetups, die analysiert wurden. Der Impaktor bewegt sich jeweils von oben nach unten. Die Diagramme zeigen die mit dem Python-Tool ermittelten Dehnungsverteilungen am Ende der Simulation.	46
Abbildung 26: Links: Crashbox vor dem Versuch. Rechts: Crashbox nach dem Versuch.	47
Abbildung 27: Mittels DIC gemessene Verschiebungen der acht farbig markierten Punkte auf der Crashbox. Der Impaktor trifft von rechts nach links auf das Bauteil.....	48
Abbildung 28: Vergleich zwischen Crashbox-Versuchen (farbige Kurven) und Simulation mit klassischem Materialmodell (schwarze Kurve) anhand von Kraft-Weg-Kurven.	49
Abbildung 29: Kraft-Weg-Kurven der Crashbox-Versuche (farbige Kurven) und Simulationen mit ML-Modell (schwarze durchgezogene Kurve) und klassischem Modell (Ground Truth, schwarze gestrichelte Kurve).....	49
Abbildung 30: Vergleich der Verformung der Crashbox 8 ms (oben) und 20 ms (unten) nach Versuchsbeginn. Von links nach rechts: Versuch → Simulation mit klassischem SAMP-Modell → Simulation mit klassischem Modell (Ground Truth) → Simulation mit ML-Modell.....	50
Abbildung 31: Versuchsaufbau der quasi-statischen Zugversuche am IFB in AP1.1.....	52
Abbildung 32: Kraft-Weg-Diagramm von in AP1.1 durchgeführten Druckversuchen am IFB..	52
Abbildung 33: Versuchsaufbau der quasi-statischen Druckversuche am IFB in AP1.1	53
Abbildung 34: Dehnpfade aus dem Material Model Driver	54
Abbildung 35: Wanne DP800: LSTM vs MAT_024 vs LMSCc.....	55
Abbildung 36: Antwort des original Modelles MAT_SAMP und des MLMM auf RNN-basis auf 1000 Schritten	57
Abbildung 37: Antwort des original Modelles MAT_SAMP und des interpolierten MLMM auf RNN-basis auf 200.000 Schritten.....	58
Abbildung 38: Möglichkeiten zur Modellbildung und Training	60
Abbildung 39: Berechnung Divergenz der Spannungen in Python auf Versuchsdaten.....	61
Abbildung 40: Optimierung des MLMM auf Versuchsdaten.....	62
Abbildung 41: Prozess zur MLMM-Optimierung auf Versuchsdaten.....	62
Abbildung 42: Optimierung eines MLMM auf Basis Versuchsdaten	63
Abbildung 43: Simulation Scherzugprobe mit MLMM und klassischem Modell in LS-Dyna	63
Abbildung 44: Effektive plastische Vergleichsdehnung über der Triaxialität für eine klassische Zugprobe	64
Abbildung 45: Manuell erzeugte Basisgeometrie für Optimierung durch Mesh-Elemente Löschung; grau markiert sind die Auswertungsbereiche, an denen die höchsten Druckspannungen zu erwarten sind.....	65
Abbildung 46: Iteratives Löschen von Mesh-Elementen – Ergebnisse Variante 1	66

Abbildung 47: Iteratives Löschen von Mesh-Elementen – Ergebnisse Variante 2	66
Abbildung 48: Dehnungs-Triaxialitäts-Diagramme für verschiedene elliptische Taschengeometrien	67
Abbildung 49: Dehnungs-Triaxialitäts-Diagramm sowie EMI-Auswertung für L-förmige Taschengeometrie	68
Abbildung 50: Dehnungs-Triaxialitäts-Diagramme für zwei Knickmechanismus-Taschengeometrien	68
Abbildung 51: Finale Probekörpergeometrie aus AP5.1 am IFB während des simulativen Zugversuchs	69
Abbildung 52: Dehnungs-Triaxialitäts-Diagramm sowie EMI-Auswertung für die finale Probekörpergeometrie aus AP5.1 am IFB	69
Abbildung 53: Reale DIC-Dehnungsmessung der finalen Probekörpergeometrie aus AP5.1 am IFB.....	70
Abbildung 54: Eingespannte finale Probekörpergeometrie aus AP5.1 am IFB	70
Abbildung 55: Schematischer Ablauf des automatisierten Versuchs aus Sicht des Cobots....	73
Abbildung 56: Ablauf ATOS-Probenvermessung	74
Abbildung 57: Vorder- und Seitenansicht des Probenmagazins zur automatisierten Materialprüfung am IFB	75
Abbildung 58: Schematischer Überblick zur Kommunikationsstruktur der Versuchsautomatisierung in AP6 am IFB.....	76
Abbildung 59: Cobot bei der Probeneinbringung (links Standardzugprobe, mittig neuartige Zugprobe aus AP5) und Probenentnahme (rechts) an der Prüfmaschine	77
Abbildung 60: Positionierung des Probekörpers zur Vermessung (links) sowie softwareseitige Auswertung der Probenabmessungen (rechts)	77
Abbildung 61: Messreihen aus der Parameterstudie zur Evaluation der ATOS-Probenvermessung.....	78
Abbildung 62: ATOS-Probenvermessung mit fehlerhaftem CAD-Fitting des Probekörpers (oben) und mit korrektem CAD-Fitting (unten); dies war eine der Ursachen für die anfänglichen Messschwankungen in Breitenrichtung.....	79
Abbildung 63: Versuchsaufbau quasi-statische Demonstrator-Druckversuche am IFB in AP7.2	80
Abbildung 64: DIC-Messung Demonstratorversuch am IFB, hier dargestellt die Verschiebung in Druckrichtung.....	80
Abbildung 65: Geprüfte Kunststoffwanne nach dem Druckversuch zeigt plastische Verformungen durch den Druckstempel.....	81

Abbildung 66: Simulativer Abgleich des Druckversuchs mit MAT_24 (links) und dem ML-Modell in AIMM (rechts)	81
Abbildung 67: Vergleich der mechanischen Kennwerte von DP800 und DP600	85
Abbildung 68: Bestimmung des analytischen Faktors für die Dehnratenabhängigkeit als hybride Modellkomponente	87
Abbildung 69: Die Gültigkeit der Verwendung negativer Werte für "Gesamtdehnungen und prognostizierte Spannungen"	88
Abbildung 70: Untersuchte Probengeometrien nur mit kreisförmigen Löchern	89
Abbildung 71: Erfolgreiches Auffüllen der fehlenden Messbereiche an den Rändern	90
Abbildung 72: Ausrichtung der Facetten der GOM-Messungen an dem für das Training verwendeten Netzknoten	90
Abbildung 73: Digitalisierung des Kreuznapfs durch das GOM-ARGUS-Netz nach der Umformung	93
Abbildung 74: Nakajima-Proben: Die Konzeptbauteile mit optischer Messung während des Umformvorganges	93
Abbildung 75: Darstellung der Formänderungsverteilungen für den Kreuznapf auf Basis des klassischen und des ML- Materialmodells im Vergleich zum Versuch	94
Abbildung 76: Nakajima Probe - Vergleich der Formänderungsverteilungen	94
Abbildung 77: Externe Optimierung neuronaler Netze beim Training mit Versuchsdaten mit Evolutionären Algorithmen	98
Abbildung 78: Verteilung der Dehnungsinkremente, Spannungen und der plastischen Dehnung für die Hutprofil Simulation	100
Abbildung 79 Schematische Darstellung der Interprozesskommunikation der im Projekt verwendeten LS-DYNA-Python-Schnittstelle	103
Abbildung 80 2D Ähnlichkeitskarte der Versuche	104
Abbildung 81 Ähnlichkeitskarte mit ausgewählten Dehnungs- und Spannungspfaden	106
Abbildung 82 Smart-Crashbox als Kunststoff Demonstrator im AP7.2	108
Abbildung 83 Platinenabmessung für die Herstellung der Kreuznäpfe	109
Abbildung 84 Kreuznäpfe für die Validierung von Umformsimulationen	109

IV Literaturverzeichnis

- [Abb13] Abbassi, F., Belhadj, T., Mistou, S., Zghal, A.: Parameter identification of a mechanical ductile damage using Artificial Neural Networks in sheet metal forming. *Materials & Design* (1980-2015) 2013;45:605–15.
- [Ash19] Ashmore, R. Calinescu, R., Paterson C., Assuring the Machine Learning Lifecycle: Desiderata, Methods, and Challenges, *Computing Research Repository (CoRR)*, May 2019
- [Bac15] Bach, S., Binder, A., Montavon, G., Klauschen, F., Müller, K.R. and Samek, W., 2015. On pixel-wise explanations for non-linear classifier decisions by layer-wise relevance propagation. *PloS one*, 10(7), p.e0130140.
- [Bar03] Barlat, F., Brem, J.C., Yoon, J.W., Chung, K., Dick, R.E., Lege, D.J., Pourboghrat, F., Choi, S.H., Chu, E. Plane stress yield function for aluminium alloy sheets—part 1: theory. *International Journal of Plasticity* 19 (2003), Nr. 9, S. 1297-1319
- [Bar14] Barlat, F., Vincze, G., Grácio, J.J., Lee, M.G., Rauch, E.F., Tomé C.N. Enhancements of homogenous anisotropic hardening model and application to mild and dual-phase steels. *International Journal of Plasticity* 58 (2014), S. 201-218
- [Bar19] Barrett, L., Sherman, M. W.. Improving ML Training Data with Gold-Standard QualityMetrics, *KDD '19: 25th ACM SIGKDD Conference on Knowledge Discovery and Data Mining*, 2019
- [Bes17] Bessa, M.A., Bostanabad, R., Liu, Z., Hu, A., Apley, D.W., Brinson, C., Chen, W., Liu, W.K. A frame-work for data-driven analysis of materials under uncertainty: Countering the curse of dimensionality. *Computer Methods in Applied Mechanics and Engineering* 320 (2017), S. 633-667
- [Bon22] Bonatti, C., Mohr, D.: On the importance of self-consistency in recurrent neural network models representing elasto-plastic solids. *Journal of the Mechanics and Physics of Solids* 158 (2022)
- [Cor22a] <https://cordis.europa.eu/project/id/605410>
- [Cor22b] <https://cordis.europa.eu/project/id/690802>
- [Deb14] Deb K. & Jain H. - An Evolutionary Many-Objective Optimization Algorithm Using Reference-Point-Based Nondominated Sorting Approach, Part I: Solving Problems With Box Constraints - *IEEE Transactions on Evolutionary Computation*, vol. 18, no. 4, pp. 577-601, 2014
- [Dit19] Dittmann, J., & Middendorf, P. (2019). *Der digitale Prototyp* (pp. 3-6). Springer Berlin Heidelberg.

- [Ebe21] Eberhard, S., Jamei, S., Sprave, J., Dölle, N., Peters, S., Krahe, C. M., Jacob, A., Stähr, T., Echsler Minguillon, F., Hofmann, C., Overbeck, L. V., Schäfer, L., Kandler, M., Lanza, G., Marinov, M., Oppermann, H., Schönborn, N., Tayyub, J., Frey, V., Koch, D., Haufe, A., Bui, T.B., Winkler, P.-L., Müller, K.-R. (2021). Verbundprojekt AIAX: Machine-learning-driven Engineering - CAx goes AIAX : gemeinsamer Schlussbericht zum Verbundprojekt: Laufzeit vom 01.08.2018 bis 31.07.2021. <https://doi.org/10.2314/KXP:1847158862>
- [EIK06] EL KADI, H. Modeling the mechanical behavior of fiber-reinforced polymeric composite materials using artificial neural networks - A review. *Composite structures* 73 (2006), Nr. 1, S. 1–23
- [FAT21] FAT-Schriftenreihe 353: Charakterisierung und Modellierung des Deformations- und Versagensverhaltens von nicht-faserverstärkten Thermoplasten unter mehrachsiger Crashbelastung, ISSN 2192-7863 (2021)
- [Fra19] https://www.igcv.fraunhofer.de/content/dam/igcv/de/docs/Ausstattung/20190725_flexiSPAN.pdf
- [Fri11] Fritsch, J.: Charakterisierung und Modellierung glasfaserverstärkter Thermoplaste unter dynamischen Lasten, (2011), ISBN 978-3-8396-0333-8
- [Fur98] Furukawa T, Yagawa G.: Implicit constitutive modelling for viscoplasticity using neural networks. *Int. J. Numer. Meth. Engng.* 1998;43(2):195–219.
- [Gaj20] Gajek, S., Schneider, M., Böhlke, T. On the micromechanics of deep material networks. *Journal of the Mechanics and Physics of Solids* 142 (2020)
- [Gor20] Gorji, M.B., Mozaffar, M., Heidenreich, J.N., Cao, J., Mohr, D. On the potential of recurrent neural networks for modeling path dependent plasticity. *Journal of the Mechanics and Physics of Solids* 143 (2020)
- [Gre19] Greve, L., Schneider, B., Eller, T., Andres, M., Martinez, J.D., van de Weg, B. Necking-induced fracture prediction using an artificial neural network trained on virtual test data. *Engineering Fracture Mechanics* 219 (2019), Article 106642
- [Han96] Hansen A., Ostermeier A. Adapting arbitrary normal mutation distributions in evolution strategies: The covariance matrix adaptation. In *Proceedings of the 1996 IEEE Conference on Evolutionary Computation (ICEC '96)*, pages 312–317, 1996.
- [Har19] P. von Hartrott, R. Reichenbach, M. Dlugosch, M. Huschka, C. Schweizer, D. Helm und C. Eberl, "Datenräume für Werkstoff- und Werkstoffprozessdaten unternehmensübergreifend nutzen," *Werkstoffwoche 2019*, Dresden, 18.-20.09.2019.

- [Hau19] Haufe, A.: On Identification of industrial Needs, providing of Solutions and training of Clients in macroscopic Constitutive Modelling in Engineering Applications, EMMC Workshop 2019, Industrial Impact of Materials Modelling, 8-10 July 2019, Turin, Italy.
- [Heb93] Heberling, D., ed., Automation of Mechanical Testing. (West Conshohocken, PA: ASTM International, 1993), <https://doi.org/10.1520/STP1208-EB>
- [Heg01] <https://www.hegewald-peschke.de/produkte/automatisierte-pruefsysteme.html>
- [Hel10] Held, C., Liewald, M., Sindel, M., Extended Material Test for the Characterization of Light Weight Design Materials in View of Their Edge Cracking Sensitivity. Materialpruefung/Materials Testing. (2010), 52. 596-602.
- [Hen17] Henn, P.; Liewald, M. & Sindel, M., 'Investigation on crashworthiness characterisation of 6xxx-series aluminium sheet alloys based on local ductility criteria and edge compression tests', (2018) IOP Conference Series: Materials Science and Engineering 418 (1).
- [Hen18] Henn, P., M. Liewald and M. Sindel., "Characterising ductility of 6xxx-series aluminium sheet alloys at combined loading conditions." AIP Conference Proceedings. (2018)1896. 020008. 10.1063/1.5007965.
- [Hil48] Hill, R: A theory of the yielding and plastic flow of anisotropic metals. Proceedings of the Royal Society London A. Mathematical, Physical and Engineering Sciences 193 (1948), Nr. 1033, S. 281-297
- [Hus19] M. Huschka und M. Dlugosch, "Konzept zur Digitalisierung der Datenverarbeitung aus werkstoffwissenschaftlicher Forschung," in Werkstoffe und Bauteile auf dem Prüfstand: Tagung Werkstoffprüfung 2019, Neu-Ulm, 2019.
- [Jan07] Jansen, J. „Ein Werkstoffmodell für eine Aluminium-Druckgusslegierung unter statischen und dynamischen Beanspruchungen (2007), ISBN 978-3-8167-7382-5
- [Jen16] Jenab, A., Sarraf, I.S., Green, D.E., Rahmaan, T., Worswick M.J. The use of genetic algorithm and neural network to predict rate-dependent tensile flow behaviour of AA5182-O sheets. Materials & Design 94 (2016), S. 262-273
- [Jor19] Jordan, B., Gorji, M.B., Mohr, D. Neural network model describing the temperature- and rate-dependent stress-strain response of polypropylene. International Journal of Plasticity (2019). submitted for publication.

- [Ilg19a] Ilg, Chr. Witowski, K., Koch, D., Roehl-Suanno, P., Haufe, A.: Constitutive model parameter identification via full-field calibration, November 2019, IOP Conference Series Materials Science and Engineering 651:012070, DOI: 10.1088/1757-899X/651/1/012070
- [Ilg19b] Ilg, Chr., Witowski, K., Koch, D. Roehl Suanno, P., Haufe, A.: Parameter Identification using Full-Field Calibration (FFC), 38th International Deep-Drawing Research Group Conference 2019, June 3-7, 2019, Enschede, The Netherlands.
- [Kar17] Karadogan, C., Tamer M.E.: A novel and simple cruciform specimen without slits on legs yet higher plastic strain in gauge, Procedia Eng., 207 ICTP 2017, Sept.17-22 2017, Cambridge UK, pp. 1992-1927
- [Kar20] Karadogan, C., Cyron, P., Liewald, M., 2020, Materialcharakterisierung mittels Künstlicher Intelligenz – Parameter Identifikation für Fließortmodelle für Blechwerkstoffe, WT Werkstattstechnik, BD. 110 (2020) NR. 10
- [Koc19a] Koch, D., Haufe, A.: First Steps towards Machine-Learning supported Material Parameter Identification, 12th European LS-DYNA Conference 2019, Koblenz, Germany.
- [Koc19b] Koch, D., Haufe, A.: An Investigation of Machine Learning Capabilities to Identify Constitutive Parameters in Yield Curves, Forming Technology Forum 2019, September 19–20, 2019, utg, TUM, Germany.
- [Koc19c] Koch, D., Haufe, A.: Machine Learning unterstützte Identifikation von konstitutiven Parametern in der Werkstoffcharakterisierung, VDI Wissensforum Automotive CAE, 19-20. November 2019, Kongresshaus Baden-Baden, Germany.
- [Kri07] Krivachy, R. „Charakterisierung und Modellierung kurzfaserverstärkter thermoplastischer Kunststoffe zur numerischen Simulation von Crashvorgängen“ (2007), ISBN 978-3-8167-7364-1
- [Kup17] Kupfer, R. Multi-Material-Design für die Großserie - Leichtbauer kombinieren Organobleche, Faserverbund-Hohlprofile und Spritzgieß-Knotenstrukturen in einem Prozess. [Online] 2017. [Cited: August 12, 2021.] <https://tu-dresden.de/ing/maschinenwesen/ilk/das-institut/news/multi-material-design-fuer-die-grossserie>
- [Lec12] LeCun, Y.A., Bottou, L., Orr, G.B. and Müller, K.R., 2012. Efficient backprop. In Neural networks: Tricks of the trade (pp. 9-48). Springer, Berlin, Heidelberg.
- [Lef03] Lefik, M., Schrefler, B.A. Artificial neural network as an incremental non-linear constitutive model for a finite element code. Computer Methods in Applied Mechanics and Engineering 192 (2003), Nr. 28-30, S. 3265-3283.

- [Lie15] Liewald, M., Drotleff, K., Novel Punch Design for Nonlinear Strain Path Generation and Evaluation Methods. Key Engineering Materials (2015) 639, 317–324.
- [Lie19_1] Liewald, M., Karadogan, C., Lindemann, B., Jazdi, N., Weyrich, M., “Performance Increase in Forging Through Workpiece Tracking, Adaptive Control and Machine Learning“, New Developments in Forging Technology - 2019, Page 177-196, 14-15 May 2019
- [Lie19_2] Liewald, M., Karadogan, C., Lindemann, B., New Approaches in Adaptive Control and Machine Learning in Forging of Aluminium, 1. Workshop “Alu - Schmieden” Zauchensee, 21-22 March 2019
- [Lie21_1] Liewald, M., Karadogan, C., Lindemann, B., Use of machine learning in adaptive control of hot forging, Forming Technology Forum, June 2021, Twente (invited Keynote)
- [Lie21_2] Liewald, M., Karadogan, C., Lindemann, B., Neural network based model inversion applied in the control of metal forming processes: comparison of two strategies, Forming Technology Forum, June 2021, Twente (accepted for publication)
- [Liu19] Liu, Z., Wu, C.T., Koishi, M. A deep material network for multiscale topology learning and accelerated nonlinear modeling of heterogeneous materials. Computer Methods in Applied Mechanics and Engineering 345 (2019), S. 1138-1168
- [Liu19a] Liu, Z., Wu, C.T. Exploring the 3D architectures of deep material network in data-driven multiscale mechanics. Journal of the Mechanics and Physics of Solids 127 (2019), S. 20-46
- [LiX19] Li, X., Roth, C.C., Mohr, D. Machine-learning based temperature- and rate-dependent plasticity model: application to analysis of fracture experiments on DP steel. International Journal of Plasticity 118 (2019), S. 320-344
- [Los23] Lossau, S., Hoss, B., Fürle, F., Jamei, S., Dölle, N., Liebold, C., Klöppel, T., Usta, T., Haufe, A., Bohne, F., Kose, K., Gleich, H., Beule, F., Al Trjman, M., Aubel, T., Meschut, G., Facciotto, S., Sommer, D., Middendorf, P., ...DuPont Specialty Products. (2023). *DigiBody - Digitale Prozesskette zur Abbildung und Optimierung der Fügetechnik im Rohbau: gemeinsamer Schlussbericht zum Verbundprojekt: Laufzeit vom 01.04.2019 bis 30.09.2022*. Mercedes-Benz AG. <https://doi.org/10.2314/KXP:1880060051>
- [Lwa19] Lwakatare L.E., Raj A., Bosch J., Olsson H.H., Crnkovic I. (2019) A Taxonomy of Software Engineering Challenges for Machine Learning Systems: An Empirical Investigation. In: Kruchten P., Fraser S., Coallier F. (eds) Agile Processes in

- Software Engineering and Extreme Programming. XP 2019. Lecture Notes in Business Information Processing, vol 355.
- [Man11] Man, H., T. Furukawa, T. Neural network constitutive modelling for non-linear characterization of anisotropic materials. International Journal for Numerical Methods in Engineering 85 (2011), Nr. 8, S. 939-957
- [Mic11] Michopoulos, J. G., Hermanson, J. C., Iliopoulos, A., Lambrakos, S. G., and Furukawa, T. (June 22, 2011). "Data-Driven Design Optimization for Composite Material Characterization." ASME. J. Comput. Inf. Sci. Eng. June 2011; 11(2): 021009.
- [Moz19] Mozaffar, M., Bostanabad, R., Chen, W., Ehmann, K., Cao, J., Bessa, M.A. Deep learning to compute path dependent plasticity. Proceedings of the National Academy.
- [Mül01] Müller, K.R., Mika, S., Ratsch, G., Tsuda, K. and Scholkopf, B., 2001. An introduction to kernel-based learning algorithms. IEEE transactions on neural networks, 12(2), pp.181-201.
- [Pan20] Pandya, K.S., Roth, C.C., Mohr, D. Strain rate and temperature dependent fracture of aluminum alloy 7075: Experiments and neural network modeling. International Journal of Plasticity (2020). In Press, Journal Pre-proof
- [PMD] <https://www.materialdigital.de/>
- [Pet04] Peter, J. „Experimentelle und numerische Untersuchung zum Crashverhalten von Strukturbauteilen aus kohlefaserverstärkten Kunststoffen (2004), ISBN 3-8167-6748-6
- [ReLei] Fertigungs- und Recyclingstrategien für die Elektromobilität zur stofflichen Verwertung von Leichtbaustrukturen in Faserkunststoffverbund-Hybridbauweise. Förderkennzeichen 02PJ2800. Schlussbericht erhältlich über TIB Hannover (<https://www.gbv.de/dms/tib-ub-hannover/1032659467.pdf>)
- [Rup12] Rupp, M., Tkatchenko, A., Müller, K.R. and Von Lilienfeld, O.A., 2012. Fast and accurate modeling of molecular atomization energies with machine learning. Physical review letters, 108(5), p.058301.
- [Sch09] Schleich, R., Denninger, R., Held, C., Liewald, M., Beitrag zur verbesserten Charakterisierung der Umformbarkeit von Aluminiumfeinblechwerkstoffen. Materials Testing. (2009) 51. 547-553. 10.3139/120.110068.

- [Sch17] Schütt, K., Kindermans, P.J., Felix, H.E.S., Chmiela, S., Tkatchenko, A. and Müller, K.R., 2017. Schnet: A continuous-filter convolutional neural network for modeling quantum interactions. In *Advances in neural information processing systems* (pp. 991-1001).
- [Sch18] Schelter, S., Lange, D., Schmidt, P., Celikel, M., Biessmann, F., Grafberger, A.: Automating large-scale data quality verification. *Proc. VLDB Endow.* 11, 1781–1794, 2018
- [Shm17] S. Slavetinsky, V. Herzog, A. Meyer, S. Stoll, S. Suwelack, “Deep Learning for CAE Automation”, NAFEMS World Congress, 2017
- [Shs18] S. Suwelack, D. Häntsch, S. Slavetinsky, M. Stoll: Simulation process data management in the age of AI, NAFEMS SPDM Europe, 2018
- [Ssh19] S. Suwelack, S. Slavetinsky, D. Häntsch, M. Stoll: Deep Learning for Geometry Understanding, NAFEMS World Congress, 2019
- [SMS16] S. Suwelack, A. Meyer, S. Slavetinsky, M. Stoll, N. Bursac, A. Albers, R. Dillmann, S. Speidel: Towards Cognitive Computer Aided Engineering, NAFEMS Americas, 2016 (best paper award)
- [Sss17] S. Suwelack, S. Slavetinsky, M. Stoll, “The Computer Aided Engineering Middleware Library – Towards the Legofication of CAE”, NAFEMS World Congress 2017
- [Yos02] Yoshida, F., Uemori, T. A model of large-strain cyclic plasticity describing the Bauschinger effect and work hardening stagnation. *International Journal of Plasticity* 18 (2002), Nr. 5-6, S. 661-686
- [Yun12] Yun GJ, Saleeb A, Shang S, Binienda W, Menzemer C. Improved SelfSim for Inverse Extraction of Nonuniform, Nonlinear, and Inelastic Material Behavior under Cyclic Loadings. *J. Aerosp. Eng.* 2012;25(2):256–72
- [Zgo12] Zgoul MH. Use of artificial neural networks for modelling rate dependent behaviour of adhesive materials. *International Journal of Adhesion and Adhesives* 2012;36:1–7.
- [Zha03] Zhang, Z., Friedrich, K. Artificial neural networks applied to polymer composites: a review. *Composites Science and technology* 63 (2003), Nr. 14, S. 2029–2044
- [Zop217] Zopf, C., Kaliske, M. Numerical characterisation of uncured elastomers by a neural network based approach. *Computers & Structures* 182 (2017), S. 504–525
- [Zwi01] <https://www.zwickroell.com/en/automated-testing-systems>

Berichtsblatt

1. ISBN oder ISSN	2. Berichtsart (Schlussbericht oder Veröffentlichung) Schlussbericht
3. Titel AIMM – Artificial Intelligence for Material Models	
4. Autor(en) [Name(n), Vorname(n)] [Böhringer, Pauline] [Sprave, Joachim] [Jamei, Said] [Dölle, Norbert] [Koch, David] [Ilg, Christian] [Haufe, André] [Haase, Thomas] [Soot, Thomas] [Kleih, Julian] [Gorbach, Gabriele] [Sommer, Daniel] [Platzer, Dominik] [Middendorf, Peter] [Karadogan, Celalettin] [Liewald, Mathias] [Stoll, Markus] [Suwelack, Stefan]	5. Abschlussdatum des Vorhabens 31.12.2023
	6. Veröffentlichungsdatum
	7. Form der Publikation Document Control Sheet
8. Durchführende Institution(en) (Name, Adresse) (Mercedes-Benz AG, Benzstraße, 71059 Sindelfingen) (DYNAmore GmbH, Industriestraße 2, 70565 Stuttgart) (Universität Stuttgart, IFB, Pfaffenwaldring 31, 70569 Stuttgart) (Universität Stuttgart, IFU, Holzgartenstraße 17, 70174 Stuttgart) (Fraunhofer Gesellschaft, EMI, Ernst-Zermelo-Straße 4, 79104 Freiburg) (ElringKlinger AG, Max-Eyth-Straße 2, 72581 Dettingen/Erms) (Renumics GmbH, Haid-und-Neu-Straße 7, 76131 Karlsruhe)	9. Ber.-Nr. Durchführende Institution
	10. Förderkennzeichen 19I20024A
	11. Seitenzahl 134
	13. Literaturangaben 78
12. Fördernde Institution (Name, Adresse) Bundesministerium für Wirtschaft und Klimaschutz der Bundesrepublik Deutschland Postanschrift: Bundesministerium für Wirtschaft und Klimaschutz 11019 Berlin	14. Tabellen 4
	15. Abbildungen 84
16. DOI (Digital Object Identifier)	
17. Vorgelegt bei (Titel, Ort, Datum) Dr. Norbert Dölle, Böblingen, 01.07.2024	
18. Kurzfassung Das Ziel des Vorhabens AIMM ist es, die klassische, oftmals bereichsweise definierte Materialmodellierung durch eine alternative datengetriebene und damit digitale Materialmodellierung zu ergänzen oder zu ersetzen. Durch die Etablierung von ML-Methoden in der simulationsgestützten Fahrzeugentwicklung sollen aufwendige Modellierungsprozesse vereinfacht werden, was zu einer Verkürzung der Entwicklungszeiten führt und die digitale Funktionsabsicherung (durch einen größeren Anwenderkreis) ermöglicht. Auf diese Weise können langfristig Rechenzeiten reduziert werden, da durch den Einsatz von ML-Modellen die iterative Lösung von Materialgleichungen vermieden werden kann. Damit wird es zukünftig möglich werden, alternative Struktur- und Crashkonzepte mit weniger Computerleistung in kürzerer Zeit berechnen und bewerten zu können. Vor dem Hintergrund des Einsatzes neuer und komplexer Werkstoffe sollen die Grenzen der konventionellen Materialmodellierung überwunden werden und es kann eine schnelle Materialbeschreibung für neue Materialien erfolgen.	
19. Schlagwörter Künstliche Intelligenz, Machine Learning, Materialmodellierung, Datengetriebene Entwicklung, Fahrzeugentwicklung, Digitale Funktionsabsicherung, CAE, Werkstofftechnik, Effizienzsteigerung in der Entwicklung	
20. Verlag	21. Preis

Nicht änderbare Endfassung mit der Kennung 2332543-8

Document control sheet

1. ISBN or ISSN	2. type of document (e.g. report, publication) Veröffentlichung (Publikation)	
3. title AIMM – Artificial Intelligence for Material Models		
4. author(s) (family name, first name(s)) [Böhringer, Pauline] [Sprave, Joachim] [Jamei, Said] [Dölle, Norbert] [Koch, David] [Ilg, Christian] [Haufe, André] [Haase, Thomas] [Soot, Thomas] [Kleih, Julian] [Gorbach, Gabriele] [Sommer, Daniel] [Platzer, Dominik] [Middendorf, Peter] [Karadogan, Celalettin] [Liewald, Mathias] [Stoll, Markus] [Suwelack, Stefan]	5. end of project 31.12.2023	6. publication date
	7. form of publication Document Control Sheet	
	9. originators report no.	
8. performing organization(s) name, address (Mercedes-Benz AG, Benzstraße, 71059 Sindelfingen) (DYNAmore GmbH, Industriestraße 2, 70565 Stuttgart) (Universität Stuttgart, IFB, Pfaffenwaldring 31, 70569 Stuttgart) (Universität Stuttgart, IFU, Holzgartenstraße 17, 70174 Stuttgart) (Fraunhofer Gesellschaft, EMI, Ernst-Zermelo-Straße 4, 79104 Freiburg) (ElringKlinger AG, Max-Eyth-Straße 2, 72581 Dettingen/Erms) (Renumics GmbH, Haid-und-Neu-Straße 7 76131 Karlsruhe)	10. reference no. 19I20024A	
	11. no. of pages 134	
	13. no. of references 78	
	14. no. of tables 4	
12. sponsoring agency (name, address) Bundesministerium für Wirtschaft und Klimaschutz der Bundesrepublik Deutschland Postanschrift: Bundesministerium für Wirtschaft und Klimaschutz 11019 Berlin	15. no. of figures 84	
	16. DOI (Digital Object Identifier)	
17. presented at (title, place, date) Dr. Norbert Dölle, Böblingen, tbd		
18. abstract The objective of the project AIMM is to enhance or potentially replace classical material modeling with a data-driven and digital approach. The integration of machine learning (ML) techniques into simulation-based vehicle development is intended to enhance complex modeling processes, thereby shortening development cycles, and facilitating digital functional verification accessible to a broader range of users. This strategy is expected to significantly reduce computational times over the long term, as the deployment of ML models circumvents the need for iterative solutions to material equations. Consequently, it will become feasible to compute and assess alternative structural and crash concepts more efficiently, using less computational power and time. Considering the adoption of new and sophisticated materials, this project aims to transcend the boundaries of conventional material modeling, enabling rapid characterization of novel materials.		
19. keywords Artificial Intelligence, Machine Learning, Material Modeling, Data-Driven Development, Vehicle Development, Digital Functional Verification, CAE, Materials Engineering, Efficiency Improvement in Development.		
20. publisher	21. price	

Nicht änderbare Endfassung mit der Kennung 2332630-8