



Gefördert durch:



aufgrund eines Beschlusses  
des Deutschen Bundestages

## Abschlussbericht

<b>Projektzeitraum</b>	01.09.2021 – 30.11.2024
<b>Name des Zuwendungsempfängers</b>	Universität Tübingen
<b>Förderkennzeichen</b>	19I21036E
<b>Projektname</b>	KI-LaSt – KI basierte Strategie zur optimalen Auslegung von AM-Gitterstrukturen („Lattice Structures“) für Crashwanwendungen
<b>Teilprojekt</b>	Entwicklung eines KI-Systems zur Feinoptimierung vorausgelegter Gitterstruktur

# Inhaltsverzeichnis

1.	Kurze Darstellung .....	1
1.1	Aufgabenstellung .....	1
1.2	Voraussetzungen, unter denen das Vorhaben durchgeführt wurde, .....	2
1.3	Planung und Ablauf des Vorhabens, .....	3
1.4	Wissenschaftlicher und technischer Stand, an den angeknüpft wurde.....	4
1.5	Zusammenarbeit mit anderen Stellen. ....	5
2.	Eingehende Darstellung .....	5
2.1	Positionen des zahlenmäßigen Nachweises .....	16
2.2	Notwendigkeit und Angemessenheit der geleisteten Arbeit.....	16
2.3	Voraussichtlicher Nutzen .....	17
2.4	Fortschritts auf dem Gebiet des Vorhabens bei anderen Stellen .....	17
2.5	Erfolgen oder geplanten Veröffentlichungen des Ergebnisses.....	17

## **1. Kurze Darstellung**

Im Verbundprojekt „KI-LaSt“ („KI-basierte Strategie zur optimalen Auslegung von 3D-gedruckten Gitterstrukturen für Crashanwendungen“) wird eine durchgängige Methodik entwickelt, die Künstliche Intelligenz in den Entwicklungsprozess von additiv gefertigten Crash-Bauteilen integriert. Ziel des Konsortiums aus Industrie- und Forschungspartnern ist es, neue KI-Verfahren in bestehende Simulationsketten einzubetten, um Entwicklungszeiten deutlich zu verkürzen und gleichzeitig das Leichtbaupotenzial zu erhöhen.

Die Methodik wird exemplarisch anhand von Aluminium-Gitterstrukturen demonstriert, die im Pulverbettverfahren hergestellt werden, von einfachen Prüfkörpern bis hin zu kompletten Fahrzeugbauteilen. Virtuelle Entwicklungsansätze spielen hierbei eine Schlüsselrolle, da sie aufwendige physische Prototypen ersetzen, Fehlentwicklungen vermeiden und kostenintensive Korrekturschleifen reduzieren.

Additive Fertigung bietet insbesondere im Automobilbereich die Möglichkeit, hoch effiziente und belastungsoptimierte Strukturen umzusetzen und damit einen Beitrag zur Erreichung von CO<sub>2</sub>-Zielen zu leisten. Besonders interessant sind Gitterstrukturen, die zusätzliche Freiheitsgrade in der Gestaltung eröffnen. Da der Lösungsraum jedoch nahezu unbegrenzt ist, mit Variationen bei Zelltypen, Orientierung, Parametern und Geometrien, ist die Auswahl einer optimalen Struktur ohne KI-Unterstützung für Konstrukteure kaum zu bewältigen. Genau hier setzt das Projekt an.

### **1.1 Aufgabenstellung**

Das Ziel des Vorhabens KI-LaSt ist es, den Auslegungsprozess von additiv gefertigten Gitterstrukturen für crashrelevante Bauteile durch den Einsatz künstlicher Intelligenz entscheidend zu unterstützen. Die zentrale Herausforderung liegt darin, dass eine Vielzahl von Gestaltungsparametern – wie Gittertyp, Orientierung oder Zellgröße – das mechanische Verhalten einer Komponente maßgeblich beeinflussen. Die Auswahl dieser Parameter ist hochkomplex und für Konstrukteure kaum vollständig zu überblicken. Mit Hilfe einer KI-gestützten Methodik soll dieser Prozess künftig automatisiert und beschleunigt werden. Parallel dazu wird eine durchgängige CAE-Prozesskette aufgebaut, die den virtuellen Entwicklungsablauf umfassend abbildet. Auf diese Weise soll die Akzeptanz für den Einsatz additiver Fertigung in der Großserie gesteigert und das Leichtbaupotenzial dieser Technologie besser nutzbar gemacht werden.

Im Teilvorhaben der Universität Tübingen (UT) liegt der Fokus auf der Entwicklung von KI-Methoden zur Feinoptimierung vorausgelegter Gitterstrukturen. Diese stellen die zweite Stufe der KI-basierten Strukturfindung dar und unterscheiden sich klar von der explorativen Suche nach grundsätzlich geeigneten Grundstrukturen. Das System soll lernen, Zusammenhänge zwischen feinen lokalen Änderungen in der Parametrisierung und den resultierenden Bauteileigenschaften zu erkennen. Darauf aufbauend kann es Strukturen gezielt im Detail anpassen und so für definierte Lastfälle optimal auslegen.

## 1.2 Voraussetzungen, unter denen das Vorhaben durchgeführt wurde,

Das Konsortium bestand aus sieben Forschungspartnern: der Ford-Werke GmbH, AM Metals, DYNAmore GmbH, der Eberhard Karls Universität Tübingen (UT) sowie drei Instituten der RWTH Aachen (Institut für Kraftfahrzeuge (ika), Lehrstuhl für Software Engineering (SE) und Institut für Strukturmechanik und Leichtbau (SLA)). Die Partner arbeiteten in wöchentlichen Meetings eng zusammen und stimmten sich zu den Arbeitspaketen ab.

Die Verantwortung für die Arbeitspakete war wie folgt verteilt:

- AP1: ika
- AP2: DYNAmore (Simulation) und AM Metals (Werkstoffentwicklung)
- AP3: SE
- AP4: UT
- AP5: Ford

Zwei assoziierte Partner, BETA CAE Systems International AG und EOS GmbH Electro Optical Systems, begleiteten das Vorhaben beratend.

Während des Projektverlaufs traten mehrere Herausforderungen auf, die zu Änderungen im ursprünglichen Plan führten:

- **Ausstieg von nTopology (2023):** Das Unternehmen verließ das Projekt früher als geplant. Eine neue Prozesskette zur Erstellung von FE-Modellen von Gitterstrukturen musste entwickelt werden, um die Trainingsdaten für die KI in AP3 und AP4 bereitzustellen.
- **Umstrukturierung bei Ford:** Der Stellenabbau in Europa führte dazu, dass die Arbeiten in AP2 bis AP6 nur eingeschränkt durchgeführt werden konnten. Besonders in AP5 wurde der Umfang erheblich reduziert.
- **Herausforderungen im SE-Team:** Wiederholte Personalwechsel verursachten Verzögerungen in AP3. Mit neuem Personal konnte der Rückstand auch im Rahmen der Verlängerung teilweise aufgeholt werden.
- **Ausstieg von AM Metals (Januar 2024):** Aufgrund eines Liquidationsverfahrens musste AMM das Projekt verlassen. Die umfangreichen Arbeiten in AP5 konnten nicht in vollem Umfang fortgeführt werden. Die RWTH übernahm Teile der Aufgaben durch den Lehrstuhl für Digital Additive Production (DAP), der über den gleichen 3D-Drucker (EOS M290) verfügt. Durch eine Verringerung der Anwendungsbeispiele wurde der Arbeitsumfang reduziert. Da das DAP Teil der RWTH ist, konnten vorhandene Mittel genutzt werden. Eine Umverteilung von Projektbudgets war nicht nötig.
- **Projektverlängerung:** Wegen des Ausscheidens von AM Metals und der damit verbundenen Umplanung wurde das Projekt kostenneutral um drei Monate verlängert. Die UT konnte aufgrund der Kurzfristigkeit der Projektverlängerung und der damit einhergehenden Personalverwaltungsprozesse lediglich vom letzten Monat der Verlängerung partizipieren.

### 1.3 Planung und Ablauf des Vorhabens

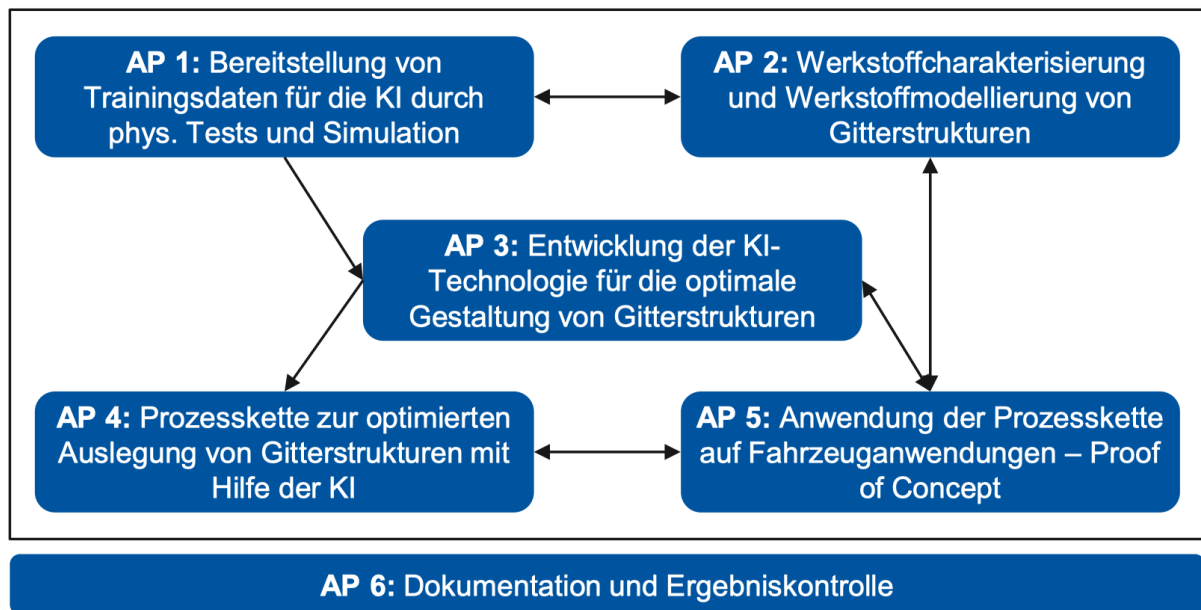


Abbildung 1: Arbeitspaketstruktur des KI-LaSt Projekts

Wie oben beschrieben, ist das Ziel des Projekts KI-LaSt, den Auslegungsprozess von Gitterstrukturen für additiv gefertigte, crashrelevante Bauteile durch den Einsatz künstlicher Intelligenz zu unterstützen. Die Gestaltung solcher Strukturen ist hochkomplex, da zahlreiche Parameter das mechanische Verhalten beeinflussen und von Konstrukteuren nur schwer überschaubar sind. Mithilfe einer KI-Methodik soll künftig eine automatisierte und anforderungsgerechte Parameterauswahl erfolgen, um den Entwicklungsprozess deutlich zu beschleunigen. Ergänzend wird eine CAE-Prozesskette aufgebaut, die den virtuellen Entwicklungsprozess ganzheitlich abbildet und so die Akzeptanz der additiven Fertigung in der Großserie erhöht. Die Arbeitsteilung auf die einzelnen Arbeitspakete sowie deren Abhängigkeiten werden in Abbildung 1 dargestellt.

In **Arbeitspaket 1** (Bereitstellung von Trainingsdaten für die KI durch physikalische Tests und Simulation) werden zunächst numerische Simulationsmodelle für eine ausreichende Zahl an Gitterstrukturen sowie deren mechanische Eigenschaften erstellt. Ergänzend werden diese Simulationen punktweise durch physikalische Tests validiert.

In **Arbeitspaket 2** (Werkstoffcharakterisierung und -modellierung von Gitterstrukturen) liegt der Fokus auf der Entwicklung geeigneter Simulationsmethoden für eine robuste Crashsimulation additiv gefertigter Gitterstrukturen mit LS-DYNA. Dazu gehören die Kalibrierung statischer und dynamischer Werkstoff- und Versagensmodelle, die Materialcharakterisierung sowie die Validierung der entwickelten Modelle.

In **Arbeitspaket 3** (Entwicklung der KI-Technologie zur optimalen Gestaltung von Gitterstrukturen) werden unterschiedliche Machine-Learning-Ansätze untersucht, um eine automatisierte und lastfalloptimierte Generierung von Gitterstrukturen zu ermöglichen. Hierfür wird eine KI-Architektur entwickelt, deren Modelle mit den in AP1 bereitgestellten Daten trainiert werden.

In **Arbeitspaket 4** (Prozesskette zur optimierten Auslegung von Gitterstrukturen mit Hilfe der KI) wird eine Methodik erarbeitet, die eine Anpassung der in AP3 entwickelten Gitterstrukturen an veränderte

Randbedingungen ermöglicht. Ziel ist es, durch lokale Optimierungen die Robustheit sowie die spezifischen Eigenschaften der Strukturen weiter zu verbessern.

In **Arbeitspaket 5** (Anwendung der Prozesskette auf Fahrzeuganwendungen) werden die Simulationsmethoden aus AP2 sowie die KI-Lösungen aus AP3 und AP4 auf reale Fahrzeugstrukturen übertragen. Die Validierung der ganzheitlichen Methodik erfolgt durch dynamische Tests an einem Demonstratorbauteil, deren Ergebnisse mit den Simulationen verglichen werden.

Die UT war im Wesentlichen in AP3 (sekundär) und AP4 (primär) aktiv. Dort lag der Schwerpunkt auf der Erforschung und Entwicklung innovativer KI-Methoden zur automatisierten Generierung von Gitterstrukturen sowie auf der Ausarbeitung einer robusten Prozesskette, die eine praxisnahe und flexible Anwendung dieser Technologien ermöglicht.

#### **1.4 Wissenschaftlicher und technischer Stand, an den angeknüpft wurde**

Die UT übernahm im Projekt insbesondere die Aufgabe der KI-Begleitung. Dies betrifft vor allem AP3 und AP4, in denen die Entwicklung, Evaluierung und Anwendung geeigneter KI-Methoden im Vordergrund stand. Der Stand der Forschung beschränkt sich in diesem Kontext wesentlich auf KI-Methodik und deren Anwendung auf die spezifischen Fragestellungen des Projekts.

Nach aktuellem Kenntnisstand existieren zum Zeitpunkt der Antragstellung keine etablierten Ansätze zur Automatisierung der Parametrisierung und Erzeugung von Gitterstrukturen mittels Machine Learning. In AP3 wird daher ein Surrogate Model entwickelt, das aus den Designvariablen einer Gitterstruktur physikalische Performanzindikatoren vorhersagen kann. Hierfür werden auf Basis von MLP-Netzwerken eigene Architekturen entworfen und evaluiert. Voraussetzung hierfür ist eine gezielte Einschränkung des Lösungsraums.

Das trainierte Simulationsnetzwerk dient anschließend als Grundlage für ein Optimierungsnetzwerk, das für einen vorgegebenen Bauraum und Lastfall die optimale Gitterstruktur ableitet. Um dieses Netzwerk zu trainieren, wird Reinforcement Learning eingesetzt. Dabei wird das Simulationsnetzwerk als Trainingsumgebung genutzt, da physikalische Simulationen selbst zu rechenintensiv für iterative Optimierungsprozesse wären.

Für die in AP4 verfolgte Feinoptimierungsmethodik kommen Machine-Learning-Modelle zum Einsatz, die lokale geometrische Zusammenhänge von Gitterstrukturen auf feingranularer Ebene erfassen können. Ziel ist es, das komplexe, nichtlineare Deformationsverhalten sowie die Energieabsorptionscharakteristik unter spezifischer Lasteinwirkung vorherzusagen. Besonders vielversprechend sind hierfür Ansätze aus dem Bereich des Geometric Deep Learning. Typische Vertreter sind Graph Neural Networks oder Graph Convolutional Networks. Im Unterschied zu klassischen Deep-Learning-Methoden ermöglichen diese Architekturen das Aggregieren von Informationen aus variierenden Graphstrukturen in kompakte Repräsentationen, die eine systematische Weiterverarbeitung erlauben. Ein wesentlicher Vorteil besteht darin, dass sie durch ihre flexiblen Aggregationsmechanismen auch auf bisher unbekannte Strukturen übertragen und in vielen Fällen beliebig skaliert werden können.

## **1.5 Zusammenarbeit mit anderen Stellen.**

Die Arbeiten erfolgten in enger Abstimmung mit den Projektpartnern und den assoziierten Partnern. Die UT war hierbei im Wesentlichen für die Entwicklung und Anwendung der KI-Methodik in AP3 und AP4 verantwortlich und arbeitete dabei besonders mit SE und SLA zusammen.

## **2. Eingehende Darstellung**

### **2.1 Erzielte Ergebnisse**

Die UT leistete im Rahmen der Arbeitspakete AP3 und AP4 einen wesentlichen Beitrag zur Entwicklung und Evaluierung von KI-Methoden für die Auslegung und Optimierung von Gitterstrukturen. Ein zentrales Ergebnis war die enge Abstimmung mit SE zur Definition und Abgrenzung der jeweiligen Ansätze. In der frühen Projektphase konnte so ein gemeinsames Vorwärtsmodell entwickelt werden, das später in beiden Arbeitspaketen weiterverwendet und methodisch angepasst wurde.

Darüber hinaus führte die UT eine umfassende Literaturstudie zu KI-basierten Verfahren in der Strukturauslegung durch. Diese Analyse identifizierte Anwendungsfelder, offene Forschungsfragen sowie bewährte Architekturen, mit besonderem Fokus auf den bislang wenig genutzten Potenzialen von Graph Neural Networks (GNNs). Die Ergebnisse dieser Studie flossen direkt in die Entwicklung und Validierung der Modelle ein und bildeten eine methodische Grundlage für die weitere Arbeit.

Im weiteren Verlauf standen die Umsetzung spezifischer KI-Methoden und die Entwicklung neuer Optimierungsansätze im Vordergrund. In AP3 wurde ein Surrogate Model zur Unterstützung von Reinforcement-Learning-Verfahren aufgebaut, während in AP4 ein flexibles, Gradienten-basiertes Feinoptimierungsframework entwickelt wurde. Dieses konnte auch auf die Vorwärtsmodelle aus AP3 angewendet werden, wodurch Synergien zwischen den Arbeitspaketen genutzt werden konnten. Trotz methodischer Unterschiede in den späteren Entwicklungsphasen führte die enge Zusammenarbeit zu beschleunigten Fortschritten und einer fundierten KI-Methodik, die sowohl theoretisch als auch praktisch im Industriekontext erprobt wurde.

Im Folgenden gehen wir auf zentrale Aspekte der Ergebnisse näher ein.

#### **2.1.1 Ausführliche Literaturstudie im Kontext des Projekts (AP3)**

Ein wesentlicher Beitrag der UT im Projekt war die Durchführung einer umfassenden Literaturstudie. Ziel war es, den Stand der Forschung zu KI-gestützten Methoden für die Modellierung und Optimierung von Gitterstrukturen systematisch zu erfassen und zu bewerten. Die Analyse erfolgte zweigleisig: Zum einen wurden die eingesetzten KI-Techniken klassifiziert, zum anderen die Herkunft der Publikationen nach Fach-Communities untersucht.

Die Auswertung zeigte, dass insbesondere seit 2019 eine deutliche Zunahme der einschlägigen Veröffentlichungen zu verzeichnen ist. Während klassische Methoden des maschinellen Lernens weiterhin Anwendung finden, dominieren seit 2020 insbesondere Artificial Neural Networks (ANNs) und Convolutional Neural Networks (CNNs). Gleichzeitig wird sichtbar, dass modernere Ansätze wie Reinforcement Learning oder generative Verfahren nur punktuell genutzt werden (vgl. Abbildung 2). Ein bislang wenig genutztes, aber vielversprechendes Potenzial bietet der Einsatz von Graph Neural Networks (GNNs), da diese die Modellierung komplexer geometrischer Strukturen und physikalischer Eigenschaften besonders gut unterstützen können.

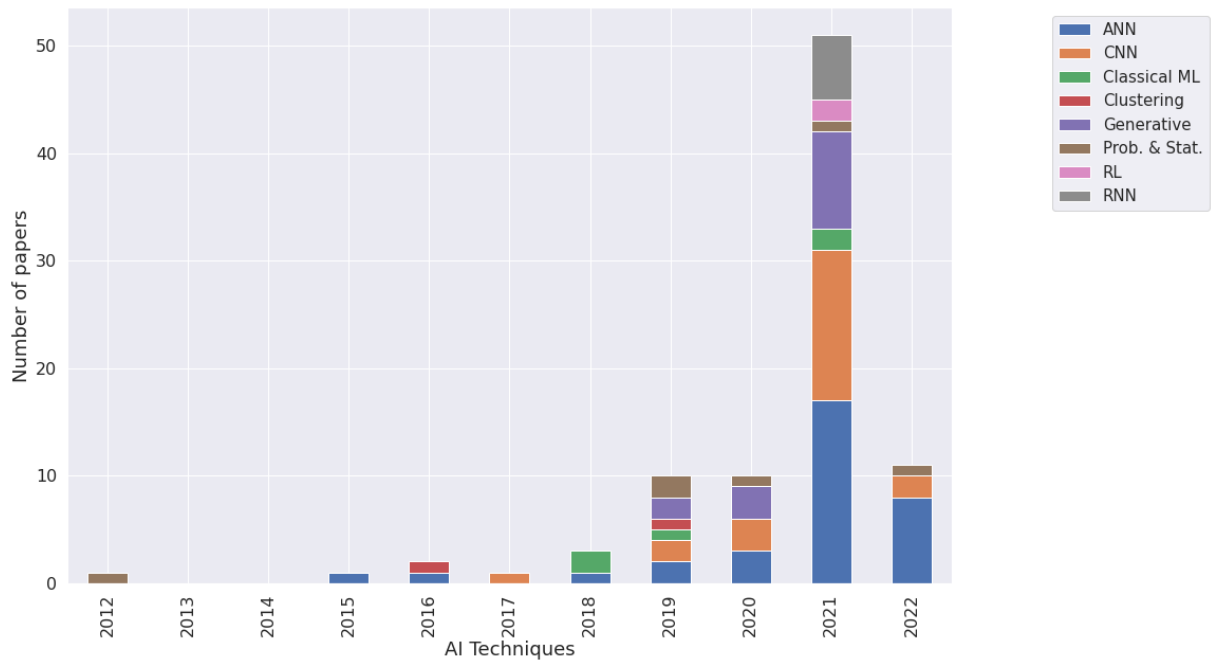


Abbildung 2: Häufigkeit des Auftretens verschiedener KI-Techniken in veröffentlichten Fachartikeln pro Jahr.

Darüber hinaus verdeutlicht die Analyse der Publikationsorte (vgl. Abbildung 3), dass relevante Arbeiten nicht nur in der klassischen Informatik-Community erscheinen, sondern zunehmend auch in ingenieurwissenschaftlichen Feldern wie Maschinenbau, Materialwissenschaften und Strukturmechanik. Dies unterstreicht die wachsende Interdisziplinarität des Themenfeldes. Gleichzeitig zeigt sich, dass additive Fertigung und Strukturoptimierung als eigenständige Communities noch vergleichsweise schwach vertreten sind, was weiteres Forschungspotenzial hervorhebt.

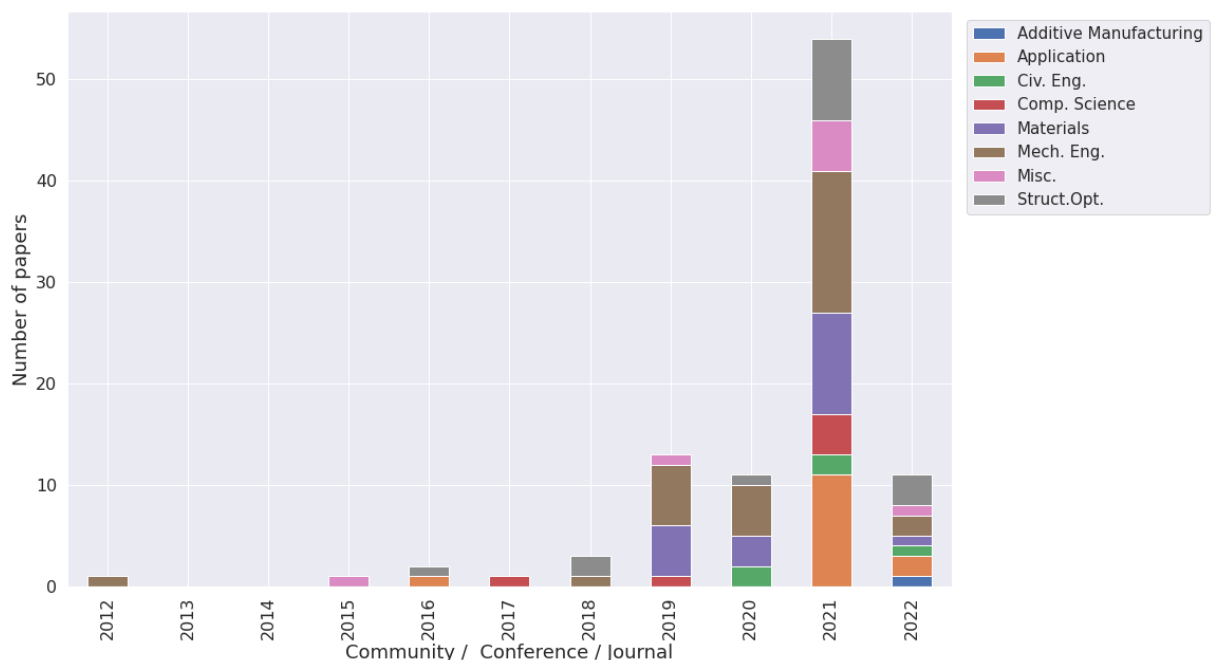


Abbildung 3: Häufigkeit der verschiedenen Communities pro Jahr, in denen relevante Paper veröffentlicht wurden.

Die Ergebnisse der Literaturstudie fließen direkt in die Projektarbeiten ein: Sie dienen als Orientierung für die Auswahl und Anpassung von Architekturen, für die Erweiterung der Datensätze sowie für die Definition geeigneter Validierungsmethoden. Durch eine automatisierte Aktualisierung konnte die

Analyse zudem fortlaufend an den Stand der Forschung angepasst werden, sodass aktuelle Trends zeitnah in AP3 und AP4 einbezogen werden konnten.

### 2.1.2 Deformationsvorhersage mittel Neuronaler Netze (AP3, AP4)

Im Rahmen der Arbeitspakete AP3 und AP4 war die UT maßgeblich an der Entwicklung und Evaluation einer neuartigen KI-Architektur für die Vorhersage von Deformationen in Gitterstrukturen beteiligt. Die Ergebnisse dieser Arbeiten wurden in der Publikation "3D Lattice Deformation Prediction with Hierarchical Graph Attention Networks" auf der International Conference on Artificial Neural Networks (ICANN) 2024 vorgestellt (Ciurletti et al. 2024).

Ziel der Forschung war es, effiziente surrogate Modelle zu entwickeln, die klassische Finite-Elemente-Simulationen (FEM) in der Strukturauslegung ergänzen oder teilweise ersetzen können. Dies ist insbesondere für die schnelle Bewertung von additiv gefertigten Gitterstrukturen von hoher Relevanz, da FEM-Simulationen für diese hochkomplexen Geometrien sehr rechenintensiv sind.

#### Ausgangssproblematik

##### *Komplexität von Gitterstrukturen*

Additive Fertigung (AM) erlaubt die Realisierung hochkomplexer Gitterstrukturen, die sich durch geringes Gewicht und gleichzeitig hohe Energieabsorptionsfähigkeit auszeichnen. Diese Eigenschaften machen sie insbesondere für crashrelevante Anwendungen in der Automobilindustrie hochinteressant. Gleichzeitig führt die Vielfalt möglicher Gittergeometrien zu einem enorm erweiterten Designraum.

Die Bewertung solcher Strukturen erfolgt traditionell über FEM-Simulationen. Diese liefern zwar hochpräzise Ergebnisse, sind aber mit enormem Rechenaufwand verbunden. Schon für einzelne Varianten einer Gitterstruktur müssen umfangreiche Simulationen durchgeführt werden. Für die Optimierung über viele Varianten hinweg ist dieser Ansatz praktisch nicht skalierbar.

##### *Grenzen klassischer Machine-Learning-Ansätze*

Maschinelles Lernen, insbesondere auf Basis von Artificial Neural Networks (ANNs) oder Convolutional Neural Networks (CNNs), hat in den letzten Jahren Einzug in die Strukturoptimierung gehalten. Diese Modelle können aus Daten lernen und Simulationen teilweise ersetzen. Allerdings stoßen sie bei Gitterstrukturen schnell an ihre Grenzen:

- **Topologie-Sensitivität:** Klassische ANN- oder CNN-Modelle sind auf feste Eingabeformate wie Bilder oder reguläre Gitter angewiesen. Gitterstrukturen hingegen sind unregelmäßig und hochdimensional.
- **Lokale vs. globale Effekte:** Mechanische Belastungen in Gitterstrukturen wirken sowohl lokal (z. B. Knicken einzelner Streben) als auch global (Lastweiterleitung durch das gesamte Bauteil). Klassische Modelle erfassen diese Multiskalenabhängigkeiten unzureichend.
- **Skalierbarkeit:** Tiefe neuronale Netze mit sehr vielen Schichten sind theoretisch in der Lage, auch weit entfernte Abhängigkeiten zu modellieren. Praktisch treten jedoch Probleme wie Overfitting, Oversmoothing und eine hohe Rechenlast auf.

## *Bisherige GNN-Ansätze und ihre Limitationen*

Graph Neural Networks sind prinzipiell besser geeignet, da Gitterstrukturen sich direkt als Graphen darstellen lassen (Knoten = Verbindungsstellen, Kanten = Streben). Sie sammeln Informationen von Nachbarknoten und können so strukturelle Abhängigkeiten modellieren. Doch auch klassische GNNs sind mit Problemen behaftet:

- **Informationsflüsse über große Distanzen:** In Gitterstrukturen wirken Kräfte über die gesamte Struktur hinweg. Klassische GNNs müssten sehr viele Schichten verwenden, um entfernte Knoten zu verbinden. Dies führt zu sehr tiefen Netzen, die schwer zu trainieren sind und häufig unter Oversmoothing leiden.
- **Vermischung von Geometrie- und Zustandsinformationen:** Bisherige GNNs codieren sowohl geometrische als auch physikalische Informationen in denselben latenten Vektoren. Dies erschwert es, die komplexen geometrischen Abhängigkeiten präzise abzubilden.
- **Mangelnde physikalische Plausibilität:** Existierende GNN-Simulatoren für Partikeldynamik oder Fluide sind nicht direkt übertragbar, da sie auf dynamische Graphen (z. B. sich bewegende Partikel) ausgelegt sind. Gitterstrukturen hingegen haben eine feste Konnektivität, was spezielle Architekturen erfordert.

## **Der Ansatz der UT – Hierarchical Graph Attention Networks (HIGAT)**

Um diese Herausforderungen zu überwinden, entwickelte die UT eine neue Architektur: das Hierarchical Graph Attention Network (HIGAT). Dieses kombiniert mehrere methodische Innovationen:

1. **Hierarchische Repräsentation:**
  - Durch sukzessives Clustering der Knoten wird eine hierarchische Struktur erzeugt (Multi-Resolution-Graph).
  - Dadurch können auch weit entfernte Knoten in einem einzigen Forward-Pass Informationen austauschen.
  - Dies reduziert die Notwendigkeit sehr tiefer Netze und verhindert Oversmoothing.
2. **Position-Aware Graph Attention Layer:**
  - Eine erweiterte Form der Graph Attention Networks, die explizit die räumliche Position in die Berechnung der Aufmerksamkeitsgewichte integriert.
  - Dies trennt geometrische Informationen von physikalischen Zuständen und ermöglicht eine präzisere Modellierung lokaler Wechselwirkungen.
3. **Encoder-Decoder-Architektur mit Residuals:**
  - Der Abwärts- und Aufwärtsweg durch die Hierarchie wird durch Residualverbindungen gekoppelt.
  - Dies verbessert die Stabilität, verhindert Informationsverluste und erlaubt es, Detailinformationen effizient zurückzuführen.

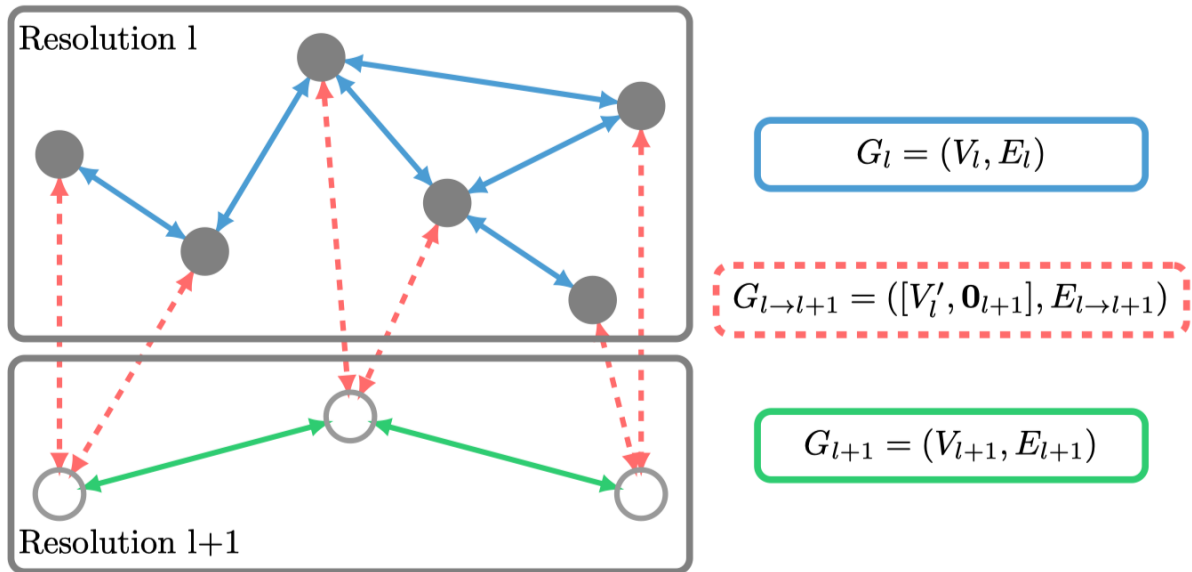


Abbildung 4: Illustration der verschiedenen Sub-Graphen in einem Rechenblock des HIGAT-Modells. Quelle (Ciurletti et al. 2024).

Abbildung 4 zeigt den Aufbau des HIGAT-Modells. Die Farben kennzeichnen die einzelnen Mengen von Kanten, die in jedem Graphen verwendet werden. Blau: Laterale Verbindungen zwischen Gitterknoten (auf der untersten Ebene) bzw. Clusterknoten (auf höheren Ebenen). Rot gestrichelt: Abstrahierte Verbindungen zu Clusterknoten der nächsthöheren Ebene (diese sind abhängig von der Rechenphase gerichtet: von höher zu niedriger Auflösung im Downsampling-Pfad und umgekehrt im Upsampling-Pfad). Grün: Laterale Verbindungen zwischen Clusterknoten der nächsthöheren Ebene.

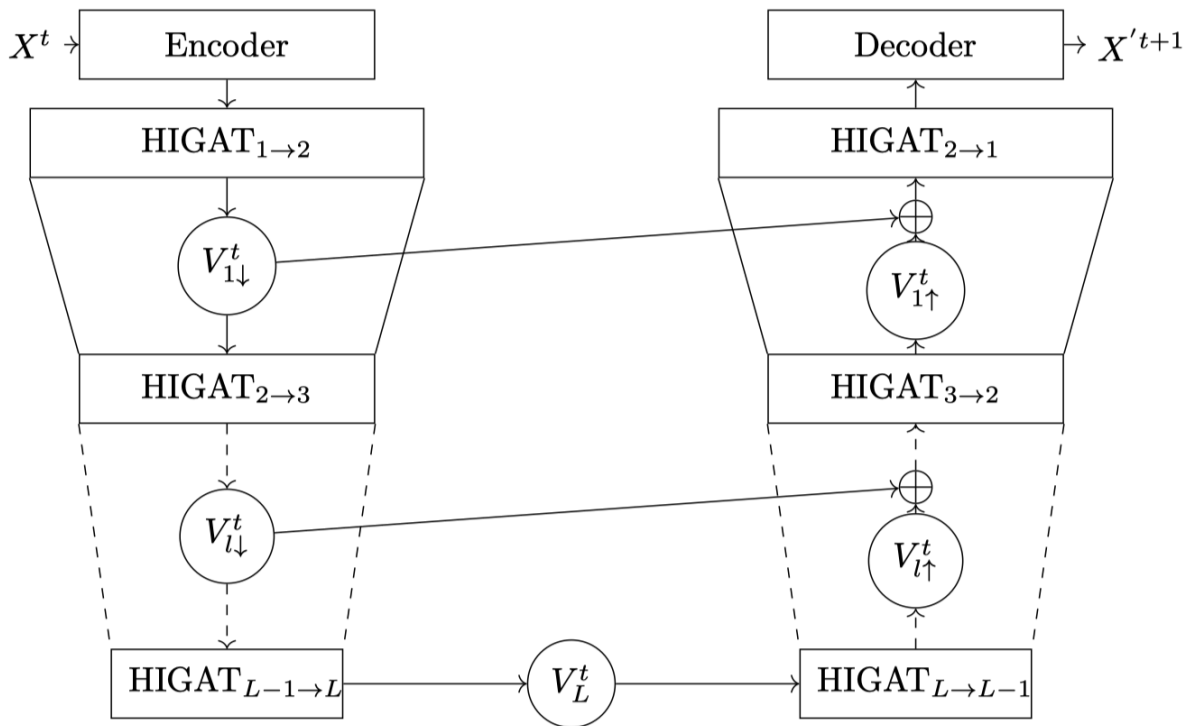


Abbildung 5: Verschiedene Units des HIGAT Modells. Quelle (Ciurletti et al. 2024).

Das HIGAT-Modell (siehe Abbildung 5) besteht aus mehreren Recheneinheiten. Jede Einheit berechnet die latenten Zustände der Knoten auf zunehmend feineren Auflösungsebenen, bis am Ende nur noch ein einzelner Knoten verbleibt. In der anschließenden Upsampling-Phase werden die Ergebnisse aus den entsprechenden Downsampling-Ebenen über Residualverbindungen wieder eingefügt und an die nächsten Einheiten weitergegeben.

### Datengrundlage und Training

Für das Training wurde ein maßgeschneiderter Datensatz erstellt:

- **FEM-Simulationen:** 21.600 FEM-Simulationen mit LS-DYNA, Materialmodell Aluminium AA6014-T4.
- **Variationen:**
  - Unterschiedliche Unit-Cell-Typen (kubisch, fcc, truncated cube).
  - Lokale Variation der Stabdurchmesser.
  - Gezielte Verschiebungen von Knoten.
  - Kombination von Variationen.
- **Outputdaten:** Zeitserien von Knotenverschiebungen, Strut-Kräften und Kraft-Weg-Kurven.
- **Training/Test:** 80 % Training, 20 % unabhängiger Testdatensatz.

Das Modell wurde trainiert, indem es die Geschwindigkeit der Knoten für den nächsten Zeitschritt vorhersagen musste. Mit einem Euler-Integrator wurden daraus Positionen abgeleitet.

### Ergebnisse

#### *Qualitative Ergebnisse*

Ein zentrales Ergebnis bestand darin, dass HIGAT realistische Deformationsverläufe der untersuchten Strukturen wesentlich besser approximieren konnte als der als Benchmark genutzte Graph Network-based Simulator (GNS). Während GNS-Modelle in frühen Zeitschritten noch ähnliche Vorhersagen wie die Simulation lieferten, zeigten sie mit zunehmender Simulationsdauer unphysikalische Abweichungen. Besonders deutlich wurde dies an zwei Phänomenen:

- **Fehlende Falt- und Knickmechanismen bei GNS:** Die GNS-Modelle neigten dazu, alle Knoten nahezu gleichförmig zu verschieben. Komplexe Falt- oder Knickprozesse, wie sie in realen FEM-Simulationen auftreten, wurden nicht korrekt abgebildet.
- **Realistische Bewegungsmuster bei HIGAT:** Im Gegensatz dazu war HIGAT in der Lage, differenzierte Deformationsmuster zu reproduzieren, einschließlich seitlicher Ausweichbewegungen und lokal begrenzter Instabilitäten. Diese qualitative Annäherung an die FEM-Simulationen wurde in den Visualisierungen (vgl. Abbildung 6 und Abbildung 7) eindrucksvoll nachgewiesen.

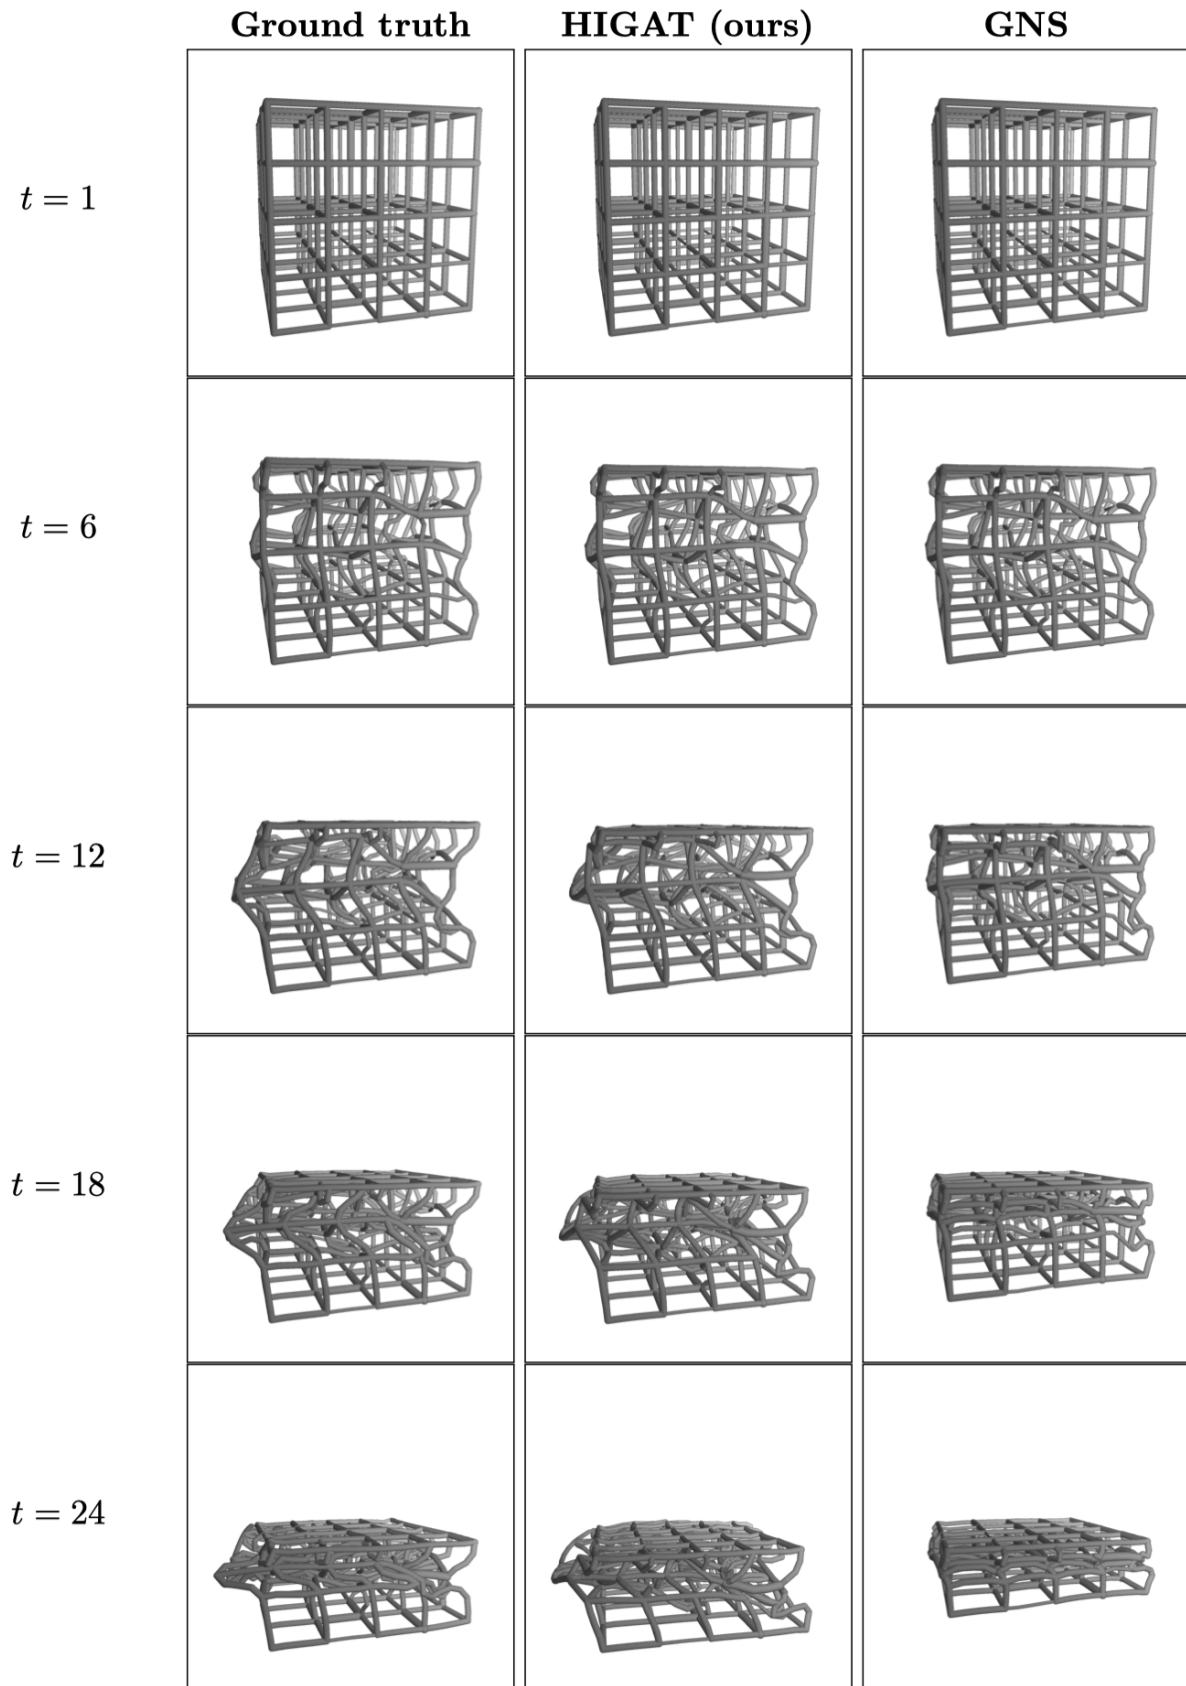


Abbildung 6: Visueller Vergleich des Deformationsprozesses einer kubischen Gitterstruktur mit einfacher kubischer Einheitszelle zwischen dem Simulationsergebnis, unserem HIGAT-Modell und dem GNS-Modell. Quelle (Ciurletti et al. 2024).

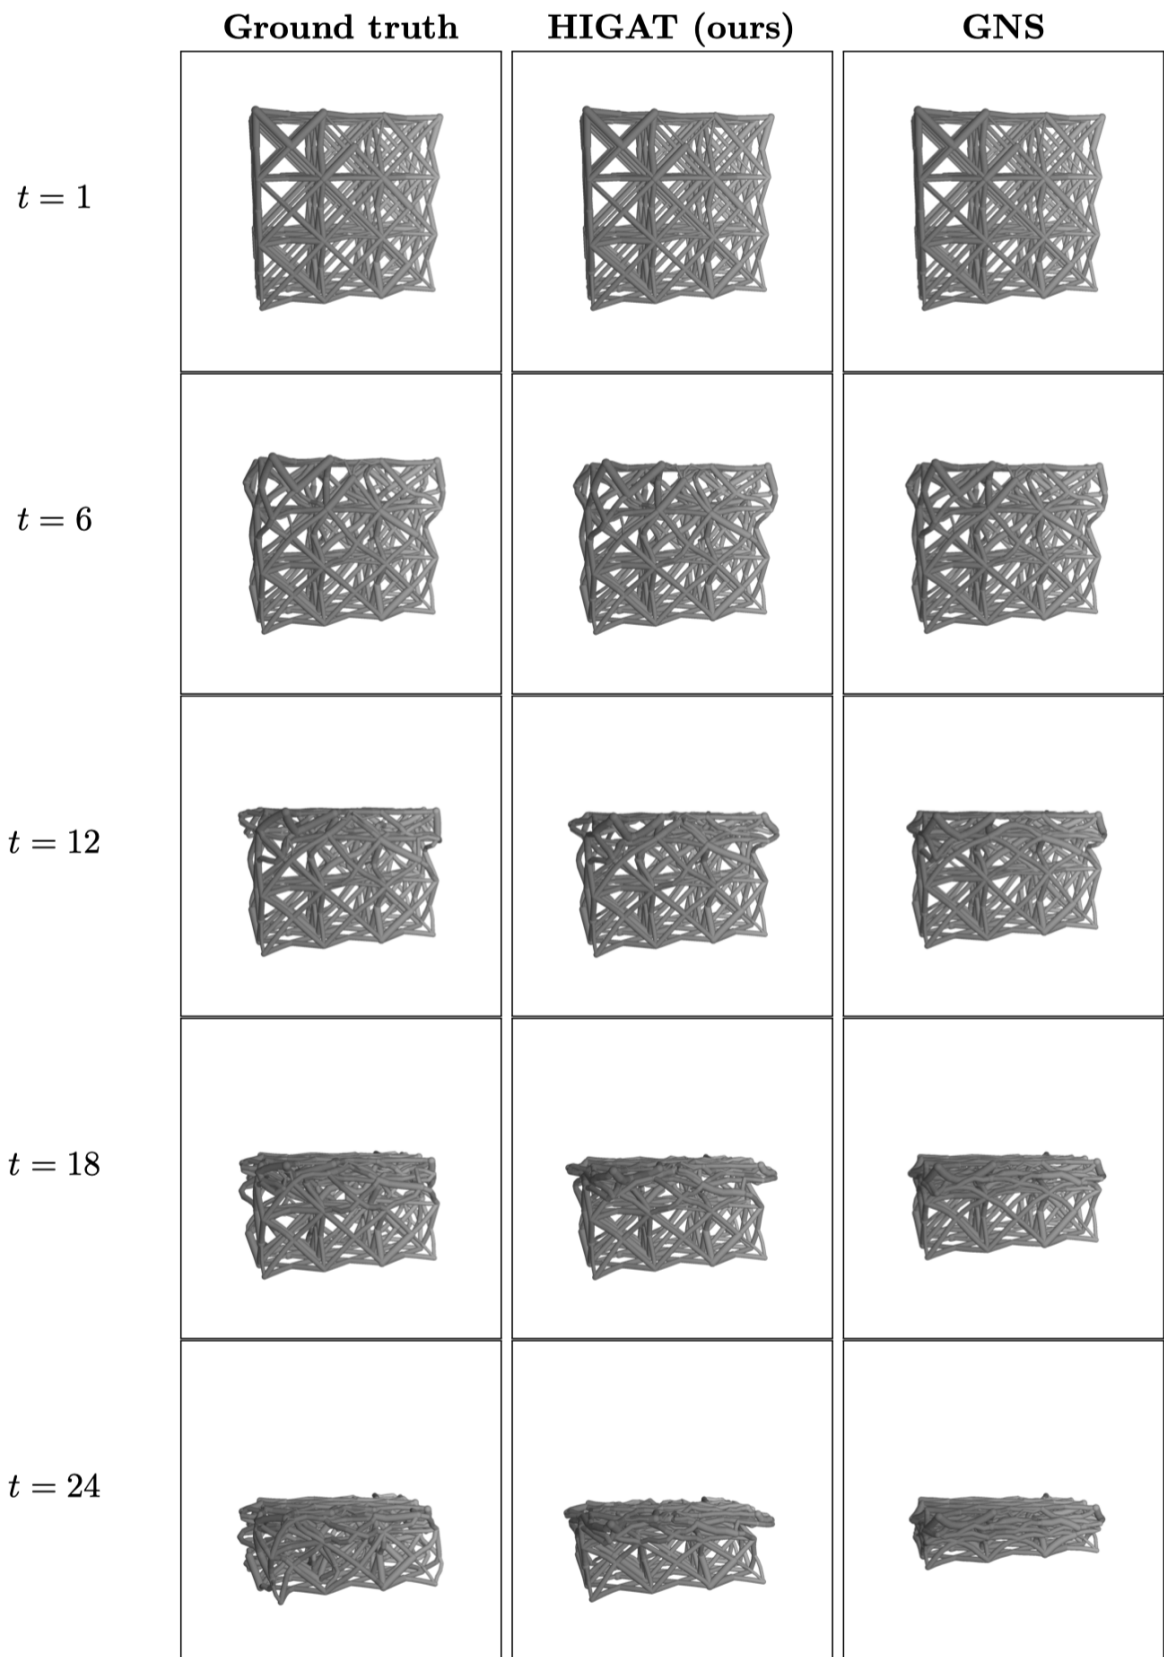


Abbildung 7: Visueller Vergleich des Deformationsprozesses einer quaderförmigen Gitterstruktur mit flächenzentrierter kubischer Einheitszelle zwischen dem Simulationsergebnis, unserem HIGAT-Modell und dem GNS-Modell. Quelle (Ciurletti et al. 2024).

## Quantitative Ergebnisse

Neben der visuellen Beurteilung wurden die Modelle auch anhand quantitativer Metriken verglichen (vgl. Abbildung 8). Hierbei zeigten sich konsistente Vorteile des HIGAT:

- **Positionsfehler der Knoten:** Die mittlere quadratische Abweichung (RMSE) der Knotenpositionen lag bei HIGAT über die gesamte Sequenz hinweg deutlich niedriger als bei den GNS-Varianten. Besonders in den mittleren und späten Zeitschritten zeigte sich eine klare Differenz zugunsten von HIGAT.
- **Erhalt der Strut-Längen:** Da die Balken der Gitterstrukturen unter idealen Bedingungen ihre Länge beibehalten sollten, ist jede künstliche Stauchung oder Dehnung ein Hinweis auf Modellfehler. HIGAT-Modelle konnten diese Längenvariationen im Schnitt auf unter 20 % begrenzen (beste Variante 14 %), während die GNS-Modelle Abweichungen bis zu 30 % zeigten. Damit war HIGAT deutlich näher an der physikalischen Realität.
- **Robustheit:** Durch gezieltes Training mit verrauschten Eingangsdaten zeigte HIGAT eine hohe Stabilität auch in autoregressiven Vorhersagen, d. h. wenn die Modelloutputs als Eingaben für die nächsten Zeitschritte dienten.

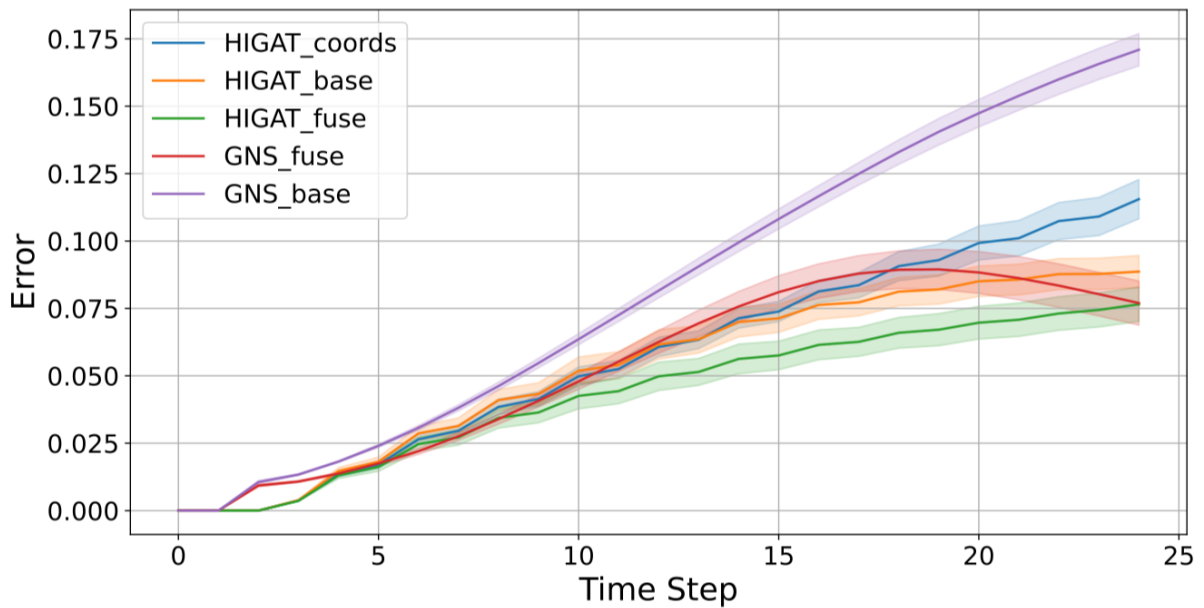
Diese Ergebnisse belegen, dass HIGAT nicht nur numerisch überlegen ist, sondern auch die physikalische Plausibilität der Simulationsergebnisse sicherstellt.

## Schlussfolgerungen

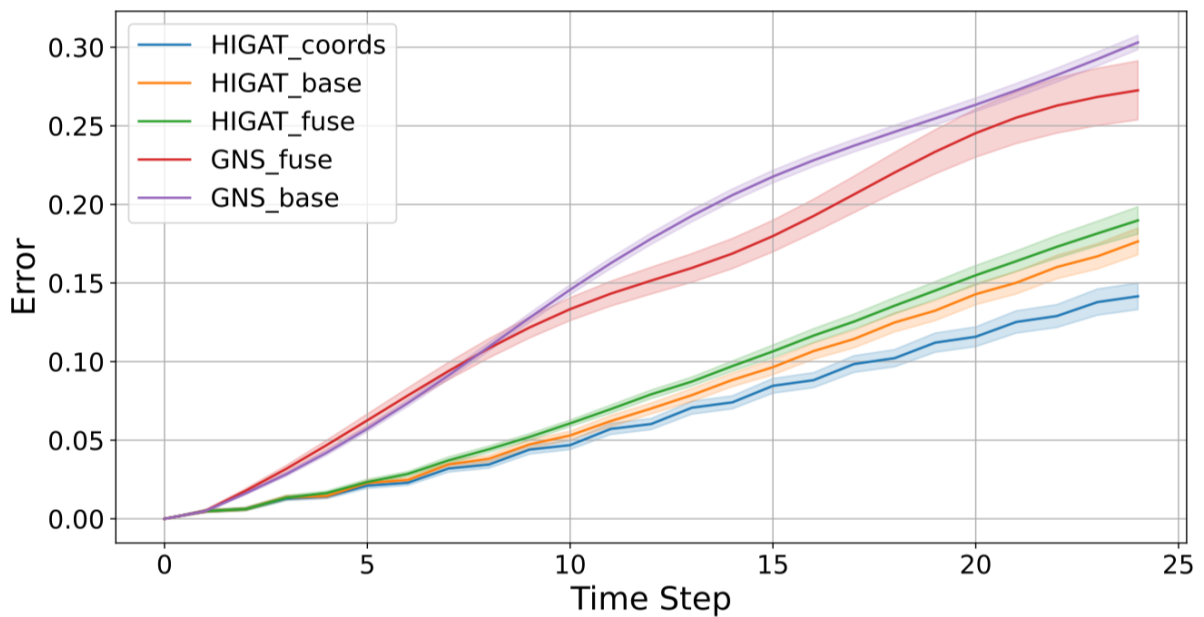
Die Ergebnisse zeigen klar, dass das HIGAT-Modell die bestehenden Limitierungen klassischer GNN-Ansätze erfolgreich überwindet und eine leistungsfähige Alternative zu zeitaufwändigen FEM-Simulationen darstellen kann. Mehrere Schlussfolgerungen lassen sich ziehen:

1. **Hierarchische Architekturen sind entscheidend:** Das Clustering der Knoten und die hierarchische Repräsentation erlauben es, globale Effekte (z. B. Kraftübertragungen über die gesamte Struktur) effizient zu modellieren, ohne extrem tiefe Netzwerke zu benötigen. Dies löst das bisherige Grundproblem klassischer GNNs bei großen Strukturen.
2. **Trennung von Geometrie und Zuständen:** Die explizite Berücksichtigung von Knotenpositionen in der Attention-Berechnung verbessert die Generalisierungsfähigkeit und erlaubt es, auch bislang unbekannte Strukturen zuverlässig zu simulieren.
3. **Physikalische Plausibilität als Qualitätskriterium:** HIGAT konnte nicht nur Fehlerwerte reduzieren, sondern auch qualitative Aspekte wie realistische Faltprozesse abbilden. Damit liefert das Modell Ergebnisse, die für praktische Konstruktions- und Optimierungsaufgaben relevant sind.
4. **Potenzial für inverse Optimierung:** Da HIGAT als vollständig differenzierbares Surrogatmodell für FEM-Simulationen dient, eröffnet es die Möglichkeit, Gradienteninformationen direkt für die Strukturoptimierung zu nutzen. Perspektivisch können damit inverse Designaufgaben adressiert werden, bei denen z. B. ein Zielwert für die Energieabsorption vorgegeben wird und das Modell die passende Gitterstruktur vorschlägt.
5. **Relevanz für die Industrie:** Für crashrelevante Anwendungen in der Automobilindustrie bedeutet dies, dass Entwicklungszyklen erheblich beschleunigt werden könnten. Statt wochenlanger FEM-Rechnungen könnten mit HIGAT schnell große Designräume exploriert werden. Dies stärkt die Wettbewerbsfähigkeit und macht additive Fertigung für Serienanwendungen attraktiver.

6. **Wissenschaftlicher Mehrwert:** Diese Arbeit zeigt, dass GNNs, die bisher in der Strukturoptimierung kaum genutzt wurden, großes Potenzial besitzen. HIGAT stellt hier einen neuartigen Ansatz dar und kann als Grundlage für weitere Anwendungen dienen.



(a) Euclidean Distance Error



(b) Edge Length Error

Abbildung 8: Mittlerer Fehler und Standardabweichung von (a) den euklidischen Abständen der vorhergesagten Knoten zu ihren Referenzpositionen und (b) der relativen Abweichung der Stablängen zwischen Vorhersage und Simulation. Quelle (Ciurletti et al. 2024).

### 2.1.3 Ansatz zur Feinoptimierung von Gitterstrukturen (AP4).

Ein wesentlicher Aspekt der Arbeiten in AP4 bestand in der Entwicklung einer KI-gestützten Prozesskette zur feinoptimierten Auslegung von Gitterstrukturen. Der in Abbildung 10 dargestellte Ansatz verbindet Simulation, maschinelles Lernen und Optimierung in einer geschlossenen Schleife.

Ausgangspunkt ist eine vorausgelegte Struktur, wie sie in AP3 erzeugt wird. Diese Struktur wird zusammen mit den Randbedingungen – insbesondere dem definierten Lastfall und ersten analytisch bzw. numerisch ermittelten Vorabschätzungen – als Eingang in das System eingebracht. Anschließend erfolgt eine Graph-basierte Repräsentation der Struktur, die die wesentlichen topologischen und geometrischen Eigenschaften in einer für KI-Modelle verarbeitbaren Form darstellt.

Im nächsten Schritt kommt ein Graph Convolutional Network (GCN) zum Einsatz, das als Encoder dient und eine latente Repräsentation der Struktur erzeugt. Diese verdichtete Darstellung enthält die für die Vorhersage relevanten Informationen über das mechanische Verhalten der Gitterstruktur. Darauf aufbauend wird ein Prädiktormodell (wahlweise als Feedforward- oder Rekurrentes Netzwerk implementiert) genutzt, um das Energieabsorptionsverhalten  $p(t)$  unter dem vorgegebenen Lastfall vorherzusagen.

Dieses vorhergesagte Verhalten wird anschließend mit einem gewünschten Energieabsorptionsverhalten  $q(t)$  verglichen. Ziel ist es, die Abweichung zwischen den beiden Verläufen zu minimieren. Zu diesem Zweck wurde ein spezielles Optimierungsmodul („Structure Optimization Inference“) entwickelt, das den Fehler über die Zeit integriert und daraus Gradienteninformationen ableitet. Diese Gradienten fließen zurück in die Strukturparameter (z. B. Geometrievariablen einzelner Streben), sodass eine iterative Anpassung und Feinoptimierung der Gitterstruktur möglich wird. Das Ergebnis dieser Schleife ist eine feinoptimierte Struktur, die besser an die gewünschten Anforderungen angepasst ist.

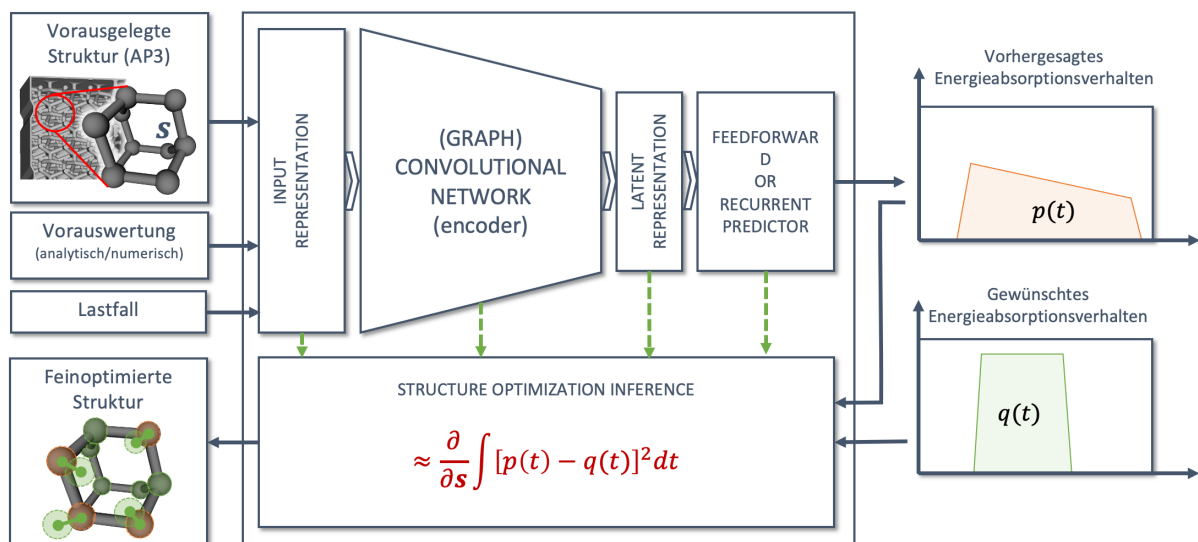


Abbildung 9: Schematische Darstellung der in AP4 entwickelten KI-gestützten Prozesskette zur feinoptimierten Auslegung von Gitterstrukturen. Das System kombiniert Simulation, Graph Convolutional Networks und Optimierungsverfahren, um das vorhergesagte Energieabsorptionsverhalten zu optimieren.

Das entwickelte System stellt einen methodischen Beitrag zur Auslegung von Gitterstrukturen dar. Es ermöglicht, das Optimierungsproblem direkt an einer gewünschten Zielgröße wie beispielsweise dem Energieabsorptionsverhalten auszurichten und Simulation, Bewertung und Anpassung in einem durchgängigen, KI-gestützten Prozess zu integrieren.

Im Rahmen von AP4 konnte durch die UT gezeigt werden, dass dieser Ansatz methodisch tragfähig ist und in einer prototypischen Umgebung implementiert wurde. Aufgrund von Projektverzögerungen, insbesondere durch den Ausstieg von Partnern und die damit verbundenen organisatorischen Einschränkungen, war eine umfassende Evaluation jedoch nicht mehr möglich. Weder eine groß angelegte Testung in Simulationen noch eine Validierung an real gefertigten Bauteilen konnte im Projektzeitraum durchgeführt werden.

Trotz dieser Einschränkungen bildet der Ansatz eine belastbare Grundlage, die in zukünftigen Arbeiten weiterentwickelt und praktisch erprobt werden kann. Während das in AP3/4 entwickelte HIGAT-Modell vollständig evaluiert und publiziert werden konnte, blieb die in AP4 entwickelte Prozesskette zur Feinoptimierung im Projektzeitraum auf die konzeptionelle und prototypische Umsetzung beschränkt. Eine umfassende Testung in Simulationsstudien sowie eine Validierung an real gefertigten Bauteilen war aufgrund der Projektverzögerungen nicht mehr möglich.

## **2.2 Positionen des zahlenmäßigen Nachweises**

Den größten Anteil der Projektkosten machten die Personalkosten für Wissenschaftler und wissenschaftliche Hilfskräfte aus. Im Mittelpunkt standen hierbei die Finanzierung eines Informatikers (M. Sc.) sowie die anteilige Beschäftigung von zwei wissenschaftlichen Hilfskräften, durch die die erforderliche Qualifikation und Unterstützung im Projekt gewährleistet werden konnte.

## **2.3 Notwendigkeit und Angemessenheit der geleisteten Arbeit**

Es kann festgestellt werden, dass die von der UT im Rahmen des Projekts erbrachten Arbeiten sowie die eingesetzten Mittel zielgerichtet und angemessen verwendet wurden. Die Forschung erfolgte dabei in einem klaren Industriekontext und adressierte die effiziente Produktentwicklung unter Einsatz neuer KI-Methoden – ein Feld, in dem deutsche Unternehmen und Forschungsinstitute in einem starken internationalen Wettbewerb stehen. Um den hohen wissenschaftlich-technologischen Status in diesem Bereich zu halten und weiter auszubauen, sind kontinuierliche Forschungs- und Entwicklungsarbeiten unerlässlich.

Gerade die Arbeiten der UT in AP3 und AP4, die auf die Entwicklung innovativer KI-Strategien für die Auslegung komplexer Gitterstrukturen in crashrelevanten Automobilbauteilen abzielten, waren mit einem hohen Entwicklungsrisiko verbunden. Hier wurde Neuland betreten, indem grundlegende Methoden erforscht und in einem industriellen Anwendungskontext erprobt wurden.

Eine Eigenfinanzierung der erforderlichen Untersuchungen wäre für die UT nicht möglich gewesen. Erst durch die vollständige Förderung des Bundesministeriums für Wirtschaft und Energie über den Projektträger TÜV Rheinland konnte diese Forschung im industriellen Umfeld realisiert werden. Für die Bewilligung und die begleitende Betreuung des Projekts möchten wir daher unseren besonderen Dank aussprechen.

## **2.4 Voraussichtlicher Nutzen**

In AP4 lag der Fokus der UT auf der Entwicklung und Evaluation von KI-Ansätzen zur Feinoptimierung von Gitterstrukturen. Ein zentraler Beitrag war die Erforschung von Verfahren des Geometric Deep Learning, die es ermöglichen, komplexe Deformations- und Energieabsorptionsmechanismen auf Basis lokaler geometrischer Zusammenhänge vorherzusagen. Der gemeinsam mit dem SLA entwickelte Ansatz HIGAT zur Vorhersage von Gitterstruktur-Deformationen wurde evaluiert und auf der International Conference on Artificial Neural Networks (ICANN) publiziert und dort der Fachwelt vorgestellt (Ciurletti et al. 2024).

Darüber hinaus wurde im Rahmen von AP4 eine Prozesskette zur KI-gestützten Feinoptimierung von Gitterstrukturen konzipiert und prototypisch implementiert. Aufgrund der Projektverzögerungen konnte diese Prozesskette im Projektzeitraum jedoch nicht mehr in umfangreichen Simulationsstudien oder an real gefertigten Bauteilen erprobt werden. Sie stellt dennoch eine wichtige methodische Grundlage dar, die in nachfolgenden Forschungsarbeiten weitergeführt und praktisch angewendet werden kann.

## **2.5 Fortschritt auf dem Gebiet des Vorhabens bei anderen Stellen**

Im Verlauf der Projektlaufzeit hat sich die UT kontinuierlich über den Stand der Technik sowie über Fortschritte im Bereich KI-gestützter Technologien informiert. Die Ziele des Vorhabens KI-LaSt behalten dadurch ihre volle Aktualität und bleiben unverändert bestehen.

## **2.6 Erfolgten oder geplanten Veröffentlichungen des Ergebnisses**

Ciurletti, M., von Behren, A.L., Bühring, J., Otte, S. (2024). *3D Lattice Deformation Prediction with Hierarchical Graph Attention Networks*. In: International Conference on Artificial Neural Networks (ICANN) 2024. Lecture Notes in Computer Science, vol 15020. Springer, Cham.