



## Teil I: Kurzbericht

# KISync: Künstliche Intelligenz zur prozessübergreifenden Synchronisierung von Entscheidungen in der operativen Supply-Chain-Planung

Förderkennzeichen: 16DKWN092A und 16DKWN092B

## 1 Ursprüngliche Aufgabenstellung und Stand der Forschung

In modernen Produktionsumgebungen stellt die operative Supply-Chain-Planung eine persistente rechnerische Herausforderung dar. Unternehmen, die unter Make-to-Order-Bedingungen fertigen, müssen die Bearbeitung hunderter verschiedener Produktvarianten auf begrenzten Kapazitäten koordinieren, wobei jeder Auftrag eigene Rüstzeiten erfordert. Das resultierende kombinatorische Optimierungsproblem ist NP-schwer. Zudem operieren diese internen Planungsprozesse nicht isoliert, sondern sind in globale Liefernetzwerke eingebettet, die zwar ökonomisch effizient, aber strukturell fragil sind. Störungen wie Maschinenausfälle oder Lieferantenausfälle können vorgefertigte Planungen jederzeit ungültig machen. Bisherige Ansätze der integrierten Planung erzeugen statische Optimierungsergebnisse, die bei Störungen nicht angepasst werden können, während die rechnerische Latenz von Metaheuristiken und gemischt-ganzzahliger linearer Programmierung eine Echtzeitsteuerung ausschließt.

Das Forschungsvorhaben KISync untersuchte, wie Methoden der künstlichen Intelligenz eingesetzt werden können, um die Entscheidungsprobleme verschiedener Prozesse in der operativen Supply-Chain-Planung unter dem Einfluss von Unsicherheiten zu synchronisieren. Im Fokus stand die Entwicklung eines datengetriebenen Entscheidungsunterstützungssystems, das Beschaffungs- und Produktionsentscheidungen integriert optimiert und Echtzeitentscheidungen unter stochastischen Störungen ermöglicht. Das Vorhaben wurde im Rahmen der BMBF-Richtlinie zur Stärkung der Datenkompetenzen des wissenschaftlichen Nachwuchses als Verbundprojekt der Otto-von-Guericke-Universität Magdeburg (Institut für Engineering von Produkten und Systemen) und der Universität Mannheim (Lehrstuhl für Künstliche Intelligenz) durchgeführt.

## 2 Ablauf des Vorhabens

Das Forschungsvorhaben gliederte sich in fünf inhaltliche Arbeitspakete. In der ersten Projektphase (Oktober 2022 bis Dezember 2023) wurden eine systematische Literaturrecherche mit Analyse von 460 Publikationen sowie die System- und Datenanalyse der Supply-Chain-Daten eines mittelständischen EMS-Dienstleisters durchgeführt. Auf dieser Basis wurde ein konzeptionelles Modell entwickelt, das eine generative Hyper-Heuristik auf Basis eines genetischen Algorithmus (GA) als Synchronisierungsmethode vorsieht. Parallel wurde die Implementierung eines LSTM-basierten GA für die integrierte Beschaffungs- und Scheduling-Optimierung begonnen.

In der zweiten Phase (Januar 2024 bis Dezember 2024) wurde die Simulationsumgebung als digitaler Zwilling der Produktionsumgebung um stochastische Maschinenausfälle und kaskadierende Lieferantenausfälle erweitert. Ein Forschungsaufenthalt an der University of Hyogo (Japan) ermöglichte die Entwicklung eines makroskopischen Supply-Chain-Simulationsmodells für realistische Störungsszenarien. In der dritten Phase (Januar bis September 2025) wurde die vollständige Methoden-Pipeline implementiert und evaluiert: Imitation Learning auf GA-Lösungen trainiert Transformer-basierte neuronale Netze, die anschließend durch Reinforcement Learning (Proximal Policy Optimisation) für stochastische Umgebungen feinabgestimmt werden.

### 3 Wesentliche Ergebnisse (und ggf. die Zusammenarbeit mit anderen Forschungseinrichtungen)

Die entwickelten Machine-Learning-Ansätze wurden anhand von 100 realen Scheduling-Instanzen des Industriepartners in 12 verschiedenen Störungsszenarien gegen 14 Baselines evaluiert. Im deterministischen Fall erreichen die gelernten Policies nahezu die Qualität des genetischen Algorithmus bei gleichzeitiger Echtzeitfähigkeit (Entscheidungszeit unter einer Minute gegenüber 25 Minuten). Unter neun Maschinenausfall-Szenarien übertreffen die beiden ML-Ansätze alle Baselines konsistent mit einer durchschnittlichen Verbesserung von 8% gegenüber der besten Heuristik. Unter zwei Lieferantenausfall-Szenarien erzielt der durch Reinforcement Learning (RL) feinabgestimmte Agent die beste Gesamtleistung mit einer Verbesserung von 27%. Die Ergebnisse belegen, dass durch Imitation Learning (IL) vortrainierte und durch RL verfeinerte Transformer-Policies einen praktikablen Weg zu schnellen, qualitativ hochwertigen und resilienten integrierten Scheduling-Entscheidungen unter internen und externen Störungen bieten.

Die Forschungsergebnisse wurden in zwei Artikeln im International Journal of Production Research veröffentlicht (Bubak et al. 2024<sup>1</sup>; Rolf et al. 2024<sup>2</sup>). Ein weiterer Artikel zu den Transformer-basierten IL/RL-Ergebnissen wurde beim European Journal of Operational Research eingereicht. Darüber hinaus wurden die Ergebnisse auf der GOR-Jahrestagung 2023, der Herbsttagung der Wissenschaftlichen Kommission für Produktionswirtschaft 2023, der IFAC INCOM 2024<sup>3</sup> und der Conference on Complex Systems (CCS) 2025 präsentiert.

Die enge Zusammenarbeit der beiden Verbundpartner resultierte in gemeinsamen Publikationen, gegenseitigen Forschungsbesuchen und der Betreuung von über zehn Masterarbeiten mit Bezug zum Forschungsvorhaben. Die Forschungsergebnisse wurden in Lehrveranstaltungen an beiden Universitäten integriert und tragen zum neuen Studiengang AI Engineering an der OVGU bei. Ein BMFTR-Folgeprojekt (MINDNET) wurde gewonnen und ein Anschlussprojekt mit direkter Industriebeteiligung ist in Planung.

---

<sup>1</sup> Bubak, A., Rolf, B., Reggelin, T., Lang, S. und Stuckenschmidt, H. (2024): An LSTM network-based genetic algorithm for integrated procurement and scheduling optimisation. International Journal of Production Research. DOI: 10.1080/00207543.2024.2434948. (<https://www.tandfonline.com/doi/full/10.1080/00207543.2024.2434948>)

<sup>2</sup> Rolf, B., Beier, A., Jackson, I., Müller, M., Reggelin, T., Stuckenschmidt, H. und Lang, S. (2024): A review on unsupervised learning algorithms and applications in supply chain management. International Journal of Production Research. DOI: 10.1080/00207543.2024.2390968. (<https://www.tandfonline.com/doi/full/10.1080/00207543.2024.2390968>)

<sup>3</sup> Katoor Vishnuthilak, K., Rolf, B., Reggelin, T. und Lang, S. (2024): Using sentiment analysis to detect disruptive events in supply chains. IFAC INCOM 2024, Wien. DOI: 10.1016/j.ifacol.2024.09.178 (<https://www.sciencedirect.com/science/article/pii/S2405896324015933>)



## Teil II: Eingehende Darstellung

# KISync: Künstliche Intelligenz zur prozessübergreifenden Synchronisierung von Entscheidungen in der operativen Supply-Chain-Planung

Förderkennzeichen: 16DKWN092A und 16DKWN092B

Laufzeit: 01.10.2022 bis 30.09.2025

Das diesem Bericht zugrundeliegende Vorhaben wurde mit Mitteln des Bundesministeriums für Forschung, Technologie und Raumfahrt unter den Förderkennzeichen 16DKWN092A und 16DKWN092B gefördert. Die Verantwortung für den Inhalt dieser Veröffentlichung liegt bei den Autoren.

Finanziert durch die Europäische Union – NextGenerationEU. Die geäußerten Ansichten und Meinungen sind ausschließlich die des Autors/der Autoren und spiegeln nicht unbedingt die Ansichten der Europäischen Union oder der Europäischen Kommission wider. Weder die Europäische Union noch die Europäische Kommission können für sie verantwortlich gemacht werden.

## Inhaltsverzeichnis

<b>1</b>	<b><i>Aufgabenstellung</i></b> .....	<b>2</b>
1.1	Gesamtziel des Forschungsvorhabens .....	2
1.2	Bezug zu den förderpolitischen Zielen .....	2
1.3	Wissenschaftliche und technische Arbeitsziele .....	3
1.4	Wissenschaftlicher und technischer Ausgangspunkt .....	3
<b>2</b>	<b><i>Wissenschaftlicher und technischer Stand, an den angeknüpft wurde</i></b> .....	<b>4</b>
2.1	Integrierte Beschaffungs- und Produktionsplanung .....	4
2.2	Supply-Chain-Resilienz und Disruptionen .....	4
2.3	Deep Reinforcement Learning im Scheduling.....	4
<b>3</b>	<b><i>Planung und Ablauf des Vorhabens</i></b> .....	<b>4</b>
3.1	Planung des Vorhabens .....	5
3.2	Ablauf des Vorhabens .....	5
3.3	Verbundpartner Universität Mannheim .....	6
3.4	Industriepartner.....	6
3.5	Internationale Kooperation .....	6
3.6	Abgrenzung zu verwandten Vorhaben.....	7
<b>4</b>	<b><i>Inhaltliche Ergebnisse</i></b> .....	<b>7</b>



4.1	Ergebnisse nach Arbeitspaketen.....	7
4.2	Schlüsselerkenntnisse .....	12
5	<i>Wichtigste Positionen des zahlenmäßigen Nachweises.....</i>	<i>13</i>
6	<i>Notwendigkeit und Angemessenheit der geleisteten Projektarbeiten.....</i>	<i>13</i>
7	<i>Voraussichtlicher Nutzen, Verwertbarkeit der Ergebnisse und zukünftige Planungen im Sinne des Verwertungsplans .....</i>	<i>14</i>
7.1	Wissenschaftlicher Nutzen .....	14
7.2	Wirtschaftlicher Nutzen .....	14
7.3	Verwertung in der Lehre.....	14
8	<i>Fortschritt auf dem Gebiet des Vorhabens während der Durchführung des Vorhabens bei anderen Stellen .....</i>	<i>14</i>
9	<i>Erfolgte oder geplante Veröffentlichungen der Projektergebnisse .....</i>	<i>15</i>
10	<i>Literaturverzeichnis.....</i>	<i>15</i>

## 1 Aufgabenstellung

### 1.1 Gesamtziel des Forschungsvorhabens

Im Forschungsvorhaben KISync wurde untersucht, wie Methoden der künstlichen Intelligenz (KI) angewendet werden müssen, um die Entscheidungsprobleme verschiedener Prozesse in der operativen Supply-Chain-Planung unter dem Einfluss von Unsicherheiten zu synchronisieren. Dabei wurde vor allem die unternehmensinterne Planung in kompetitiven Supply Chains mit geringem Informationsaustausch untersucht. Ein weiterer Schwerpunkt war die Frage, wie KI Synergien mit dem Menschen bilden kann, damit Entscheidungen in komplexen Situationen im Supply Chain Management verbessert werden und auch die prozessübergreifende Datenkompetenz des Entscheidungsträgers nachhaltig gesteigert wird.

Das technische Arbeitsziel des Forschungsvorhabens war die Entwicklung eines datenbasierten Entscheidungsunterstützungssystems für die operative Supply-Chain-Planung, das eine prozessübergreifende Sichtweise einnimmt. Das System sollte die Entscheidungsprobleme in der operativen Supply-Chain-Planung optimieren und Handlungen für den Entscheidungsträger vorschlagen. Aufgrund der hohen Komplexität der operativen Supply-Chain-Planung und des kurzen Planungshorizonts sieht das System den Einsatz von KI-Methoden vor, insbesondere maschinelles Lernen und Reinforcement Learning. Dazu sollten die Nachwuchswissenschaftler ein prototypisches System implementieren und anhand realer Industriedaten evaluieren.

### 1.2 Bezug zu den förderpolitischen Zielen

Die Beantragung des Forschungsvorhabens erfolgte im Rahmen der Bekanntmachung der BMBF-Richtlinie zur Förderung von Projekten zur Stärkung der Datenkompetenzen des wissenschaftlichen Nachwuchses. Das Forschungsvorhaben KISync unterstützt primär das dritte Handlungsfeld der Datenstrategie der Bundesregierung: Datenkompetenz erhöhen und Datenkultur etablieren. Bisher gibt es in der Hochschulbildung keine flächendeckenden Angebote von Datenkompetenzkursen. Daher



wurde dieses Forschungsvorhaben als hochschul- und disziplinübergreifendes Projekt konzipiert, um ein Vorreiter für den Aufbau von Datenkompetenz bei Nachwuchswissenschaftlern zu sein. Von dem Vorhaben profitieren sowohl die projektbearbeitenden Doktoranden als auch Studierende der beiden Universitäten in aktuellen Studiengängen und im neu etablierten Studiengang AI Engineering an der OVGU.

Sekundär adressiert das Forschungsvorhaben die KI-Strategie der Bundesregierung, die darauf abzielt, mehr KI-Fachkräfte auszubilden und die Anwendung von KI im Mittelstand zu fördern. Durch die Generierung datenbasierteren Wissens über Zusammenhänge in der operativen Supply-Chain-Planung können Wertschöpfungsketten transparenter und robuster werden.

### 1.3 Wissenschaftliche und technische Arbeitsziele

Das wissenschaftliche Arbeitsziel des Forschungsvorhabens war der Aufbau von neuem Wissen über die Zusammenhänge in der operativen Supply-Chain-Planung. Dafür sollte der Einsatz von KI, insbesondere maschinelles Lernen und Reinforcement Learning, erforscht werden. Vor allem die Betrachtung und Optimierung der Entscheidungsprobleme in einer kompetitiven Supply Chain aus einer prozessübergreifenden Sicht ist in der Wissenschaft kaum verbreitet.

Darüber hinaus sollte das Vorhaben untersuchen, ob eine Synchronisierung der Entscheidungsprobleme die Lösungsgüte und Robustheit verbessert. Dazu wurden verschiedene Experimente mit dem Softwareprototypen durchgeführt, um die synchronisierten Lösungen direkt mit den isolierten Lösungen zu vergleichen. Zusätzlich sollten neue Erkenntnisse über die Zusammenhänge zwischen den Entscheidungsproblemen der operativen Supply-Chain-Planung gewonnen werden, um Entscheidungen besser und robuster zu machen.

Ein zusätzlicher Effekt der wissenschaftlichen und technischen Arbeitsziele war der Aufbau von Datenkompetenz bei den projektbearbeitenden Nachwuchswissenschaftlern. Die Generierung von Wissen über die Zusammenhänge für den Menschen war unabdingbar mit dem Aufbau von prozessübergreifender Datenkompetenz verknüpft, da in der operativen Supply-Chain-Planung verschiedenste Datenquellen und Optimierungsmethoden existieren.

### 1.4 Wissenschaftlicher und technischer Ausgangspunkt

Zu Beginn des Vorhabens befand sich die Forschung an der Schnittstelle dreier Forschungsströme, die jeweils spezifische Limitationen aufwiesen:

Im Bereich der integrierten Beschaffungs- und Produktionsplanung hatten Meta-Analysen gezeigt, dass integrierte Optimierung durchschnittlich 11% Kosteneinsparungen gegenüber sequenzieller Planung erzielt.

Im Bereich der Supply-Chain-Resilienz war bekannt, dass sich Störungen nichtlinear durch strukturelle Interdependenzen in Liefernetzwerken ausbreiten. Empirische Simulationen des Tohoku-Erdbebens von 2011 hatten beispielsweise gezeigt, dass indirekte Produktionsverluste durch Propagation etwa hundertmal größer sein können als direkte Schäden. Diese Dynamik wurde jedoch in Scheduling-Modellen nicht berücksichtigt.

Im Bereich des Deep Reinforcement Learning für Scheduling hatten einzelne Arbeiten gezeigt, dass trainierte Agenten valide Produktionspläne in unter 0,2 Sekunden generieren können. Allerdings beschränkte sich die Literatur auf interne Unsicherheiten wie Maschinenausfälle und ging von unbegrenzter Materialverfügbarkeit aus. Externe Supply-Chain-Risiken waren in der RL-Scheduling-Literatur nicht adressiert.



## 2 Wissenschaftlicher und technischer Stand, an den angeknüpft wurde

Die Herausforderung der echtzeitfähigen integrierten Scheduling-Optimierung unter Supply-Chain-Störungen liegt an der Schnittstelle dreier Forschungsströme: der integrierten Planung, der Supply-Chain-Resilienz und des Deep Reinforcement Learning.

### 2.1 Integrierte Beschaffungs- und Produktionsplanung

Integrierte Planung bezeichnet die simultane Optimierung mehrerer Funktionsbereiche innerhalb einer Supply Chain, die traditionell isoliert betrieben werden. Während sequenzielle Planung einer Wasserfalllogik folgt, bei der die Beschaffung die Rahmenbedingungen für die Produktion setzt, behandelt integrierte Planung diese Funktionen als ein einheitliches Entscheidungsproblem. Eine Meta-Analyse von Hrabec et al. (2022) identifizierte eine durchschnittliche Kosteneinsparung von 11,1% und stellte fest, dass die Vorteile mit der Problemkomplexität korrelieren.

### 2.2 Supply-Chain-Resilienz und Disruptionen

Obwohl Standard-Planungsmodelle die Effizienz optimieren, beruhen sie typischerweise auf vereinfachten Annahmen bezüglich der Materialverfügbarkeit. Diese Modelle behandeln Versorgungsengpässe im Allgemeinen als statische, unabhängige Wahrscheinlichkeiten, ein Ansatz, der den strukturellen Ursprung von Störungen in Liefernetzwerken vernachlässigt, in denen Interdependenzen nichtlineare, kaskadierende Ausfälle erzeugen können.

Das Feld der Supply Network Science untersucht Verwundbarkeiten durch statische Topologieanalyse oder dynamische Simulation. Ivanov (2014) konzeptualisierte die Propagation als Ripple-Effekt, der die kaskadierende Auswirkung struktureller Störungen auf die nachgelagerte Leistung beschreibt. Inoue (2019) zeigte in einer empirischen Simulation des Tohoku-Erdbebens von 2011, dass indirekte Produktionsverluste durch Propagation etwa hundertmal größer waren als direkte Schäden.

### 2.3 Deep Reinforcement Learning im Scheduling

In unsicheren Fertigungsumgebungen hängt die operationelle Stabilität von der Fähigkeit ab, in Echtzeit auf unerwartete Ereignisse zu reagieren. Klassische Lösungsansätze stoßen hier an eine fundamentale Grenze: Rechnerische Methoden wie gemischt-ganzzahlige lineare Programmierung oder Metaheuristiken erfordern erhebliche Optimierungszeit, die eine sofortige Reaktion auf plötzliche Zustandsabweichungen ausschließt.

Deep Reinforcement Learning adressiert dieses Problem, indem es den Rechenaufwand in eine Offline-Trainingsphase verlagert. Dies ermöglicht dem Agenten, eine gelernte Policy in Echtzeit auszuführen. Lang et al. (2020) demonstrierten die Machbarkeit anhand desselben Anwendungsfalls eines EMS-Dienstleisters, der auch in diesem Vorhaben adressiert wird: Trainierte Agenten generierten valide Schedules in unter 0,2 Sekunden.

Trotz dieser Fortschritte bestätigte ein aktueller Literaturüberblick von Ngwu et al. (2025), dass die RL-Literatur im dynamischen Job Shop Scheduling auf interne Unsicherheiten beschränkt ist. Externe Supply-Chain-Risiken fehlen in den identifizierten Kernherausforderungen. Selbst Studien, die explizit Materialengpässe berücksichtigen, modellieren diese typischerweise als einfache binäre Zustände, was die komplexen vorgelagerten Dynamiken und kaskadierenden Ausfallwahrscheinlichkeiten ignoriert.

## 3 Planung und Ablauf des Vorhabens

Die Durchführung des Vorhabens stützte sich auf die Expertise und Infrastruktur der beiden Verbundpartner sowie auf die Verfügbarkeit realer Industriedaten.

Das Institut für Engineering von Produkten und Systemen (IEPS) der Otto-von-Guericke-Universität Magdeburg verfügt über Kernkompetenzen in der Analyse, Planung, Modellierung und Optimierung logistischer Systeme. Besondere Schwerpunkte liegen in der Anwendung von Simulation und KI in produktionslogistischen Systemen.

Der Lehrstuhl für Künstliche Intelligenz (LKI) der Universität Mannheim brachte über 15 Jahre Erfahrung in Grundlagen und Anwendungen von KI-Methoden ein. Der LKI beschäftigt sich methodisch mit der Kombination aktueller Methoden des maschinellen Lernens mit symbolischer Wissensrepräsentation und diskreten Optimierungsproblemen.

Die empirische Grundlage des Vorhabens bildeten reale Supply-Chain-Daten eines mittelständischen EMS-Dienstleisters aus Mitteldeutschland, der auf die Leiterplatten-Bestückung spezialisiert ist. Das Unternehmen stellte 100 reale Scheduling-Instanzen mit jeweils 160 Jobs bereit, einschließlich Bearbeitungszeiten, Fälligkeitsterminen und Produktfamilienzugehörigkeiten für zwei Produktionsstufen (SMT und AOI). Diese Datenbasis ermöglichte die Evaluation unter industrienahen Bedingungen.

### 3.1 Planung des Vorhabens

Das Forschungsvorhaben wurde in fünf inhaltliche Arbeitspakete (AP 1 bis 5) sowie ein übergreifendes Arbeitspaket für Projekt- und Risikomanagement (AP 0) gegliedert. Die geplante Laufzeit betrug 36 Monate (Oktober 2022 bis September 2025).

AP	Bezeichnung	Leitung	Zeitraum
0	Projekt- und Risikomanagement	IEPS	Laufend
1	Analyse	IEPS	Monat 1–6
2	Konzeptionelles Modell	IEPS	Monat 4–12
3	Implementierung Softwareprototyp	IEPS	Monat 10–24
4	Feinabstimmung und Evaluation	IEPS	Monat 22–33
5	Verwertung und Dokumentation	IEPS	Laufend

Dem Ablaufplan lagen fünf Meilensteine zugrunde: (1) System- und Datenskizze nach Abschluss der Analysephase, (2) Konzeptionelles Modell für den Softwareprototyp, (3) Vorläufiger Softwareprototyp nach Abschluss der Implementierung, (4) Vollständiger Softwareprototyp nach Feinabstimmung und Evaluation, sowie (5) Vollständige Leistungsbeschreibung und Projektbericht.

### 3.2 Ablauf des Vorhabens

Der tatsächliche Ablauf des Vorhabens folgte grundsätzlich der geplanten Struktur, wobei eine konzeptionelle Anpassung der Implementierungs- und Evaluierungsstrategie vorgenommen wurde. Statt der ursprünglich geplanten sequenziellen Bearbeitung der Arbeitspakete 3 und 4 wurde ein dreistufiger Komplexitätsansatz gewählt, der eine fokussierte Evaluation und Publikation von Teilergebnissen ermöglichte.

In der ersten Projektphase (Oktober 2022 bis Dezember 2023) wurden die Arbeitspakete 1 und 2 vollständig abgeschlossen. Die systematische Literaturrecherche umfasste die Analyse von 460 potenziell relevanten Publikationen in der Scopus-Datenbank, aus denen 34 Kernpublikationen nach Ähnlichkeit und Impact-Faktor identifiziert wurden. Die Analyse bestätigte die identifizierte Forschungslücke: Keine der existierenden Publikationen vereint alle Anforderungen des Vorhabens. Parallel wurde die System- und Datenanalyse der Industriedaten durchgeführt und das konzeptionelle Modell entwickelt. Die Implementierung eines LSTM-basierten genetischen Algorithmus für die integrierte Beschaffungs- und Scheduling-Optimierung wurde begonnen.



Die zweite Projektphase (Januar 2024 bis Dezember 2024) umfasste die Fertigstellung der ersten Komplexitätsstufe und den Beginn der erweiterten Szenarien. Der LSTM-basierte Genetische Algorithmus wurde erfolgreich implementiert und in einem Artikel im International Journal of Production Research veröffentlicht. Die Simulationsumgebung wurde um stochastische Maschinenausfälle und kaskadierende Lieferantenausfälle erweitert. Ein Forschungsaufenthalt des Projektbearbeiters an der University of Hyogo in Japan (November 2023 bis April 2024) ermöglichte die Entwicklung eines agentenbasierten makroskopischen Supply-Chain-Simulationsmodells, das realistische Lieferantenausfallszenarien auf Basis empirischer Daten des Tohoku-Erdbebens von 2011 generiert.

In der dritten Projektphase (Januar bis September 2025) wurde die vollständige Methoden-Pipeline implementiert und umfassend evaluiert. Die Transformer-basierte Actor-Critic-Architektur wurde entwickelt, durch Imitation Learning auf den GA-Lösungen vortrainiert und mittels Proximal Policy Optimisation für die stochastischen Umgebungen feinabgestimmt. Die Evaluation erfolgte über 100 reale Scheduling-Instanzen in 12 verschiedenen Störungsszenarien gegen 14 Baselines.

### Wesentliche Abweichungen von der ursprünglichen Planung:

- Dreistufiger Komplexitätsansatz: Die Arbeitspakete 3 und 4 wurden nicht streng sequenziell, sondern in drei Komplexitätsstufen bearbeitet (deterministisch, Maschinenausfälle, Lieferantenausfälle). Dies ermöglichte eine fokussierte Evaluation und die Publikation von Zwischenergebnissen.
- Fokus auf Beschaffung und Produktion: Das ursprünglich geplante Vehicle Routing Problem für die Distribution wurde zugunsten einer vertieften Integration von Beschaffung und Produktion zurückgestellt. Diese Entscheidung war durch den deutlich höheren Erkenntnisgewinn bei der Integration dieser beiden Bereiche begründet.
- Methodische Erweiterung: Statt der ursprünglich geplanten reinen RL-Lösung wurde eine dreistufige Methoden-Pipeline (GA, Imitation Learning, Reinforcement Learning) entwickelt, um die Lösungsqualität zu verbessern.

### 3.3 Verbundpartner Universität Mannheim

Der Lehrstuhl für Künstliche Intelligenz (LKI) der Universität Mannheim übernahm die Rolle des datenbezogenen Partners im Verbund und brachte spezifische Expertise in der Anwendung von KI-Methoden auf Supply-Chain-Probleme ein. Die Zusammenarbeit umfasste gemeinsame Publikationen, die gemeinsame Nutzung der Recheninfrastruktur beider Universitäten (CUDA-fähige Hardware) für das Training der neuronalen Netze sowie die Entwicklung des agentenbasierten Supply-Chain-Simulationsmodells. Die Nachwuchswissenschaftler beider Standorte besuchten die jeweils andere Einrichtung für gemeinsame Forschungsarbeiten.

### 3.4 Industriepartner

Ein mittelständischer EMS-Dienstleister aus Mitteldeutschland, spezialisiert auf die Leiterplatten-Bestückung, stellte die empirische Datenbasis bereit. Das Unternehmen operiert unter einer Make-to-Order-Strategie und verarbeitet eine diverse Palette von Produkten mit variablen Losgrößen und unterschiedlichen Rüstanforderungen. Es stellte 100 reale Scheduling-Instanzen mit jeweils 160 Jobs bereit, die Bearbeitungszeiten, Fälligkeitstermine und Produktfamilienzugehörigkeiten für zwei Produktionsstufen (SMT und AOI) umfassen.

### 3.5 Internationale Kooperation

Im Rahmen des Vorhabens wurde eine Forschungsk Kooperation mit der University of Hyogo, Graduate School of Information Science, in Kobe, Japan, etabliert. Der Projektbearbeiter der OVGU absolvierte einen Forschungsaufenthalt von November 2023 bis April 2024 bei Prof. Hiroyasu Inoue. In dieser Kooperation wurde ein makroskopisches Supply-Chain-Simulationsmodell entwickelt, das die



Propagation von Störungen in Liefernetzwerken auf Basis empirischer Daten des Tohoku-Erdbebens von 2011 simuliert. Aus 22.500 Simulationsläufen wurden realistische, zeitabhängige Lieferantenausfallwahrscheinlichkeiten abgeleitet, die direkt in das KISync-Framework integriert wurden.

### 3.6 Abgrenzung zu verwandten Vorhaben

Während der Projektlaufzeit wurde ein thematisch verwandtes Vorhaben an der Martin-Luther-Universität Halle-Wittenberg identifiziert, das sich mit der integrierten Planung logistischer Prozesse in komplexen Produktionsnetzwerken befasst. KISync grenzt sich durch den Fokus auf kompetitive Supply Chains mit geringem Informationsaustausch, die Betrachtung von Stückgut-Produktion und die Integration externer Supply-Chain-Risiken ab.

## 4 Inhaltliche Ergebnisse

Die folgenden Abschnitte stellen die inhaltlichen Ergebnisse anhand der entwickelten Methodik und der durchgeführten Evaluationen dar. Die Darstellung verdeutlicht insbesondere, welche neuen Forschungserkenntnisse und -methoden durch die Zusammenarbeit der fachlichen (Logistik/Produktionsplanung) und datenwissenschaftlichen (KI/Machine Learning) Mitarbeiter gewonnen wurden und wie die Projektergebnisse zur Datenkompetenzsteigerung in der Fachdisziplin Logistik beitragen.

### 4.1 Ergebnisse nach Arbeitspaketen

#### AP 1 – Analyse

Die systematische Literaturrecherche in der Scopus-Datenbank identifizierte 460 potenziell relevante Publikationen. Nach einem mehrstufigen Screening-Prozess wurden 34 Kernpublikationen für die detaillierte Analyse ausgewählt. Die Analyse ergab, dass lediglich 25 Prozent der Arbeiten detaillierte operative Supply-Chain-Planung betrachten, 12 Prozent einen rollierenden Planungshorizont berücksichtigen und nur 10 Prozent Unsicherheiten einbeziehen. Keine der existierenden Publikationen erfüllte alle Anforderungen des KISync-Vorhabens.

Die System- und Datenanalyse der Supply-Chain-Daten des EMS-Dienstleisters ergab eine für maschinelles Lernen gut geeignete, homogene Datenbasis. Die 100 Scheduling-Instanzen weisen ähnliche Verteilungen der Bearbeitungszeiten (Median ca. 200 Minuten), ausreichende Schlupfzeiten und eine starke positive Korrelation der Bearbeitungszeiten zwischen den beiden Produktionsstufen auf.

Im Rahmen der Analysephase wurden zwei zentrale Aufgaben bearbeitet: eine systematische Literaturrecherche zur Identifikation des Forschungsstands und der Forschungslücken sowie eine System- und Datenanalyse der realen Industriedaten.

Die systematische Literaturrecherche in der Scopus-Datenbank identifizierte 460 potenziell relevante Publikationen an der Schnittstelle von integrierter Planung, Supply-Chain-Resilienz und Deep Reinforcement Learning im Scheduling. Nach einem mehrstufigen Screening-Prozess basierend auf Ähnlichkeit und Impact-Faktor wurden 34 Kernpublikationen für die detaillierte Analyse ausgewählt. Die Analyse ergab, dass lediglich 25 Prozent der Arbeiten detaillierte operative Supply-Chain-Planung betrachten, 12 Prozent einen rollierenden Planungshorizont berücksichtigen und nur 10% Unsicherheiten einbeziehen. Keine der existierenden Publikationen vereinte alle Anforderungen des KISync-Vorhabens, insbesondere die Kombination aus echtzeitfähiger integrierter Beschaffungs- und Produktionsplanung unter sowohl internen (Maschinenausfällen) als auch externen (Lieferantenausfällen) Störungen. Im Bereich der integrierten Planung bestätigten Meta-Analysen, dass integrierte Optimierung durchschnittlich 11,1% Kosteneinsparungen gegenüber sequenzieller Planung erzielt, wobei die Vorteile mit der Problemkomplexität korrelieren.

Im Bereich der Supply-Chain-Resilienz wurde nachgewiesen, dass sich Störungen nichtlinear durch strukturelle Interdependenzen in Liefernetzwerken ausbreiten – empirische Simulationen des Tohoku-Erdbebens von 2011 zeigten, dass indirekte Produktionsverluste durch Propagation etwa hundertmal größer sein können als direkte Schäden. Im Bereich des Deep Reinforcement Learning hatten einzelne Arbeiten die Machbarkeit von trainierten Agenten bestätigt, die valide Produktionspläne in unter 0,2 Sekunden generieren können. Allerdings beschränkte sich die gesamte RL-Scheduling-Literatur auf interne Unsicherheiten und ging von unbegrenzter Materialverfügbarkeit aus. Daraus wurden drei konkrete Forschungsbeiträge abgeleitet: die Überwindung der Entscheidungslatenz statischer integrierter Modelle, die Integration externer Lieferantenrisiken in das Scheduling und die Entwicklung einer direkten Policy-Steuerung anstelle indirekter Dispatching-Regel-Selektion.

Die System- und Datenanalyse der Supply-Chain-Daten des EMS-Dienstleisters ergab eine für maschinelles Lernen gut geeignete, homogene Datenbasis. Der Industriepartner, ein mittelständischer deutscher EMS-Dienstleister, stellte 100 reale Scheduling-Instanzen mit jeweils 160 Jobs bereit, einschließlich Bearbeitungszeiten, Fälligkeitsterminen und Produktfamilienzugehörigkeiten für die beiden Produktionsstufen SMT und AOI. Die Analyse zeigte ähnliche Verteilungen der Bearbeitungszeiten über beide Stufen mit einem Median von ca. 200 Minuten und einer leicht rechtsgipfligen Verteilung (siehe Abbildung 1). Die Schlupfzeiten sind durchgehend positiv mit einem Median von ca. 15.000 Minuten, was darauf hindeutet, dass die meisten Jobs termingerecht fertigstellbar sind. Die untere Schranke des Makespan liegt zwischen 13.000 und 17.000 Minuten. Zudem wurde eine starke positive Korrelation der Bearbeitungszeiten zwischen den beiden Stufen festgestellt sowie die Beobachtung, dass jede Instanz dieselben 20 Fälligkeitstermine aufweist – beides Eigenschaften, die von fortgeschrittenen Scheduling-Ansätzen ausgenutzt werden können.

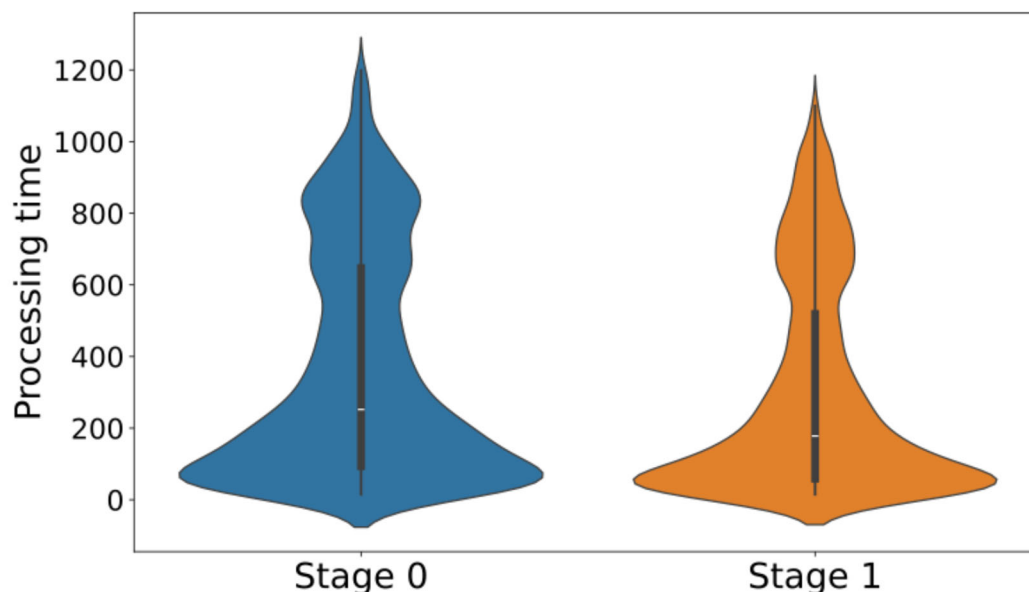


Abbildung 1: Aggregierte deskriptive Analyse der 100 Probleminstanzen. Die Diagramme zeigen ähnliche Bearbeitungszeiten auf den Stufen mit etwas längeren Bearbeitungszeiten auf Stufe 1.

## AP 2 – Konzeptionelles Modell

Das Produktionsproblem wurde als zweistufiges Hybrid Flow Shop mit parallelen Maschinen, sequenzabhängigen Rüstzeiten und Hilfsressourcen-Restriktionen modelliert. Stufe 0 (SMT) umfasst vier parallele Maschinen mit sequenzabhängigen Rüstzeiten (Minor-Setup: 20 Minuten, Major-Setup: 65 Minuten), Stufe 1 (AOI) fünf parallele Maschinen mit festen Rüstzeiten (25 Minuten).



Als Synchronisierungsmethode wurde eine generative Hyper-Heuristik auf Basis eines genetischen Algorithmus mit variabel-langem Chromosom-Encoding konzipiert. Statt feste Jobsequenzen zu optimieren, evolviert der Algorithmus zeitabhängige Sequenzen von Prioritätsregeln. Eine Bibliothek von 14 Dispatching-Regeln in vier Kategorien wurde implementiert: zeitbasierte Regeln (FIFO, LIFO, SPT, EDD), dynamische Slack-basierte Regeln (MST, CR), zusammengesetzte setup-orientierte Regeln (SST-EDD, SST-SPT, SST-MST, SST-CR, EDDxSPT) sowie zwei neu entwickelte risikoaware Regeln (MTSF, MTSF-MST) für Lieferantenausfälle.

Auf Basis der Analyseergebnisse wurde das konzeptionelle Modell des Gesamtsystems entwickelt. Das Produktionsproblem wurde als zweistufiges Hybrid Flow Shop (HFS) mit parallelen Maschinen, sequenzabhängigen Rüstzeiten und Hilfsressourcen-Restriktionen formalisiert. Stufe 0 (SMT) umfasst vier parallele Maschinen mit sequenzabhängigen Rüstzeiten (Minor-Setup: 20 Minuten innerhalb einer Produktfamilie, Major-Setup: 65 Minuten zwischen verschiedenen Familien). Stufe 1 (AOI) umfasst fünf parallele Maschinen mit festen Rüstzeiten von 25 Minuten. Eine zusätzliche globale Hilfsressourcen-Restriktion stellt sicher, dass pro Produktfamilie nur ein Setup-Trolley verfügbar ist, was die gleichzeitige Bearbeitung derselben Familie auf mehreren Maschinen verhindert.

Für die Abbildung stochastischer Störungen wurden zwei Erweiterungen konzipiert. Stochastische Maschinenausfälle werden durch ein probabilistisches Modell mit drei Parametern (Verfügbarkeit A, Mean Time To Repair MTTR und daraus abgeleiteter Mean Time Between Failures MTBF) gesteuert. Die Ausfallzeiten folgen einer Exponentialverteilung, die Reparaturzeiten einer Erlang-Verteilung. Für kaskadierende Lieferantenausfälle wurde ein agentenbasiertes makroskopisches Supply-Chain-Simulationsmodell auf Basis empirischer Daten des Tohoku-Erdbebens von 2011 konzipiert. Dieses Modell simuliert 22.500 Disruptionsszenarien und liefert zeitabhängige, korrelierte Ausfallwahrscheinlichkeiten für 15 Schlüssellieferanten. Damit werden Lieferantenausfälle nicht als unabhängige binäre Zustände behandelt, sondern als kaskadierende Netzwerkstörungen mit realitätsnaher Propagationsdynamik.

Die Zielfunktion minimiert die Summe aus Makespan, Total Tardiness und Total Time Since Failure (TTSF), wobei die letzte Komponente nur im Lieferantenausfall-Szenario aktiviert wird. Als Synchronisierungsmethode wurde eine dreistufige Methoden-Pipeline konzipiert: ein genetischer Algorithmus mit variabel-langem Chromosom-Encoding als generative Hyper-Heuristik, Imitation Learning zur Destillation der GA-Lösungen in neuronale Netzwerke und Reinforcement Learning zur Feinabstimmung. Eine Bibliothek von 14 Prioritätsregeln in vier Kategorien wurde definiert: zeitbasierte Regeln (FIFO, LIFO, SPT, EDD), dynamische Slack-basierte Regeln (MST, CR), zusammengesetzte setup-orientierte Regeln (SST-EDD, SST-SPT, SST-MST, SST-CR, EDDxSPT) sowie zwei neu entwickelte risikobewusste Regeln (MTSF, MTSF-MST) für Lieferantenausfälle.

Die Zielfunktion minimiert die Summe aus Makespan, Total Tardiness und Total Time Since Failure, wobei die letzte Komponente nur im Szenario mit Lieferantenausfällen aktiviert wird.

### AP 3 – Implementierung

Die Implementierung umfasste vier Hauptkomponenten (siehe auch Abbildung 2):

1. **Discrete-Event-Simulation:** Ein digitaler Zwilling der Produktionsumgebung wurde in Python (salabim 25.0.8) implementiert. Die Simulation bildet beide Produktionsstufen mit ihren jeweiligen Maschinen, sequenzabhängigen Rüstzeiten und Hilfsressourcen-Restriktionen vollständig ab. Jede Maschine fungiert als eigenständiger Entscheidungsagent, der bei Freiwerden den Lösungsansatz nach dem nächsten Job befragt. Stochastische Maschinenausfälle und kaskadierende Lieferantenausfälle werden in Echtzeit während des Simulationslaufs generiert.



2. **Genetischer Algorithmus:** Der GA wurde als generative Hyper-Heuristik implementiert. Statt feste Jobsequenzen zu optimieren, evolviert der Algorithmus zeitabhängige Sequenzen von Prioritätsregeln mittels eines variabel-langen Chromosom-Encodings. Die Implementierung umfasst 50 Generationen mit einer Populationsgröße von 80, Elitismus (8 Elite-Individuen), Turnirselektion (Turniergröße 3), zeitliches Crossover sowie spezialisierte Drop- und Add-Mutation zur dynamischen Anpassung der Chromosomkomplexität. Die durchschnittliche Laufzeit beträgt ca. 25 Minuten pro Instanz im deterministischen Fall und steigt auf ca. 7,3 Stunden bei robuster Optimierung unter Lieferantenausfällen (mit 20 stochastischen Evaluationsläufen pro Fitness-Bewertung).
3. **Transformer-basierte Actor-Critic-Architektur:** Eine Custom-Architektur für die direkte Jobauswahl wurde entwickelt. Die Architektur verarbeitet variable Jobmengen durch eine Pipeline aus Feature-Embedding (Shared-MLP), Transformer-Encoder-Blöcken mit Multi-Head Attention zur Erfassung von Inter-Job-Abhängigkeiten und einem Dual-Head-Output. Der Actor-Head erzeugt mittels Action Masking eine Wahrscheinlichkeitsverteilung über verfügbare Jobs, während der Critic-Head durch Mean Pooling einen globalen Zustandswert schätzt. Zwei unabhängige Policies werden trainiert: eine für die SMT-Stufe (mit Features für Bearbeitungszeiten, Schlupfzeiten, Rüstzeiten, Ausfallwahrscheinlichkeiten und Time Since Failure) und eine für die AOI-Stufe (mit reduzierten Features). Die Hyperparameter wurden durch 5-Fold-Kreuzvalidierung auf den 80 Trainingsinstanzen optimiert.
4. **Imitation Learning Pipeline:** Die besten 30 GA-Individuen pro Scheduling-Instanz werden in Zustands-Aktions-Paare umgewandelt und nach Deduplizierung als Klassifikationsdatensätze für das überwachte Training mittels Cross-Entropy-Loss verwendet. Die Netzwerke erreichen eine Top-1-Genauigkeit von 72,5% (Stufe 0) bzw. 96,2% (Stufe 1) und eine Top-5-Genauigkeit von über 99%. Die hohe Top-5-Genauigkeit inspirierte die Entwicklung eines schnellen Online-Explorationsmechanismus auf Basis von Top-k-Sampling: Bei jeder Entscheidung werden 20 parallele Evaluationsläufe durchgeführt (1 greedy, 19 mit Top-5-Sampling), was eine Entscheidungszeit von unter einer Minute bei verbesserter Lösungsqualität gewährleistet. Die vortrainierten Gewichte werden anschließend durch Proximal Policy Optimisation (PPO) in der stochastischen Simulationsumgebung feinabgestimmt, wobei eine Warm-Start-Strategie für den Critic die Konvergenz beschleunigt.

Der gesamte Tech-Stack umfasst Python 3.9.18, PyTorch 2.7.1 und Ray 2.43.0. Die Experimente wurden auf CUDA-fähiger Hardware der Universität Mannheim durchgeführt.

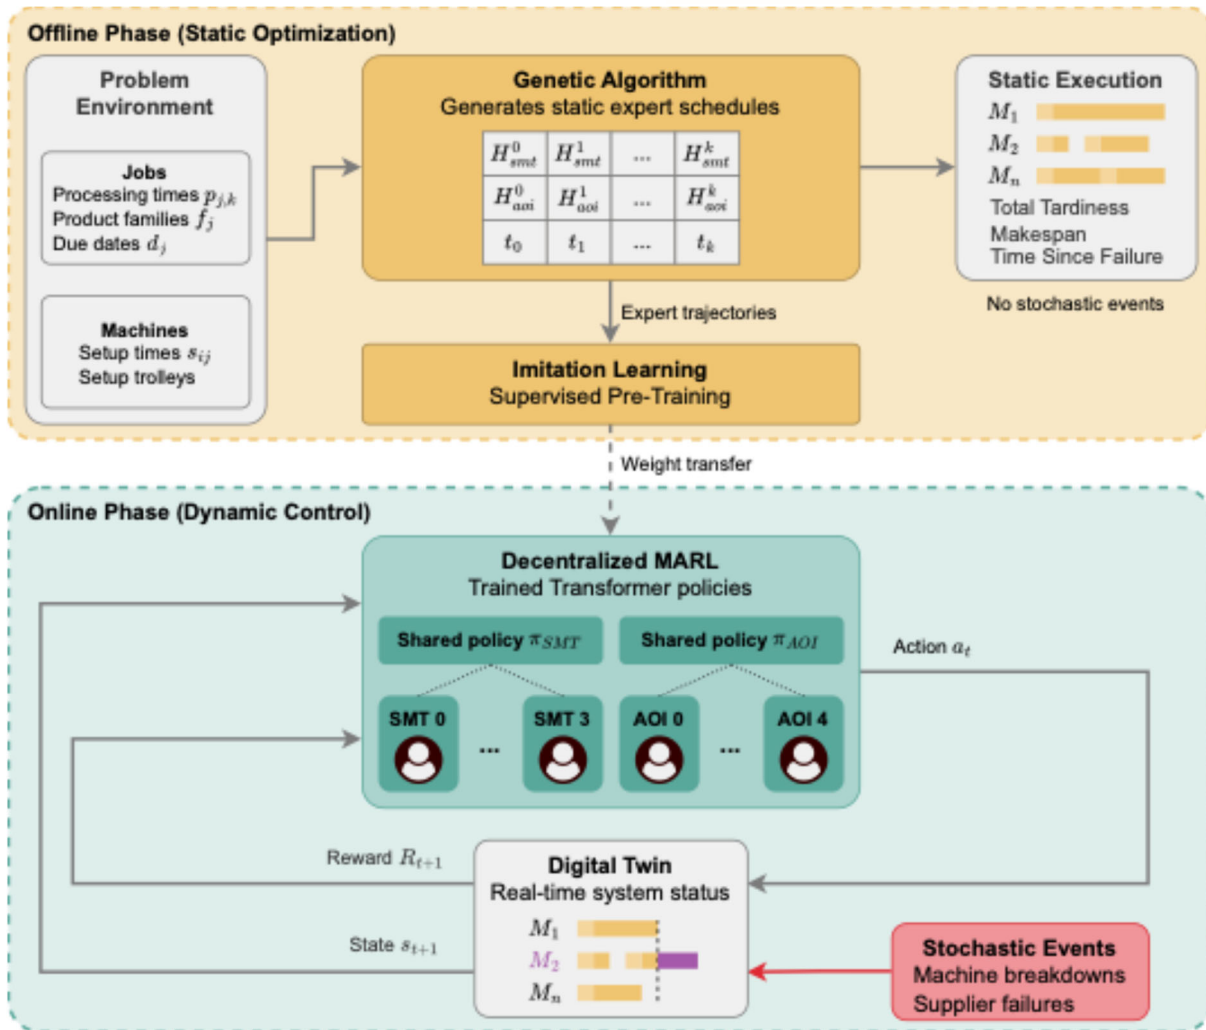


Abbildung 2: Methodisches Framework

#### AP 4 – Feinabstimmung und Evaluation

Die Evaluation erfolgte über 100 reale Scheduling-Instanzen (80 Training, 20 Test) in drei Szenarien mit insgesamt 12 Störungseinstellungen. Als Baselines dienen 13 Dispatching-Regeln und der genetische Algorithmus.

**Deterministisches Umfeld:** Im deterministischen Fall erreichten die gelernten Policies nahezu die Qualität des genetischen Algorithmus: IL erzielte einen durchschnittlichen Gap von 1,2 % und IL+RL von 2,2% auf den Testinstanzen. Die beste Heuristik (Critical Ratio) erreichte einen Gap von 7,6%. Die durchschnittlichen Ränge aller Ansätze auf den 100 Testinstanzen sind in Abbildung 3 gegeben. Der entscheidende Vorteil der ML-Ansätze liegt in der Entscheidungsgeschwindigkeit: Während der GA ca. 25 Minuten pro Instanz benötigt, treffen die ML-Agenten Entscheidungen in unter einer Minute. Ein von Grund auf trainierter RL-Agent erreichte lediglich einen Gap von 113,2%, was die Notwendigkeit des Imitation-Learning-Vortrainings belegt.

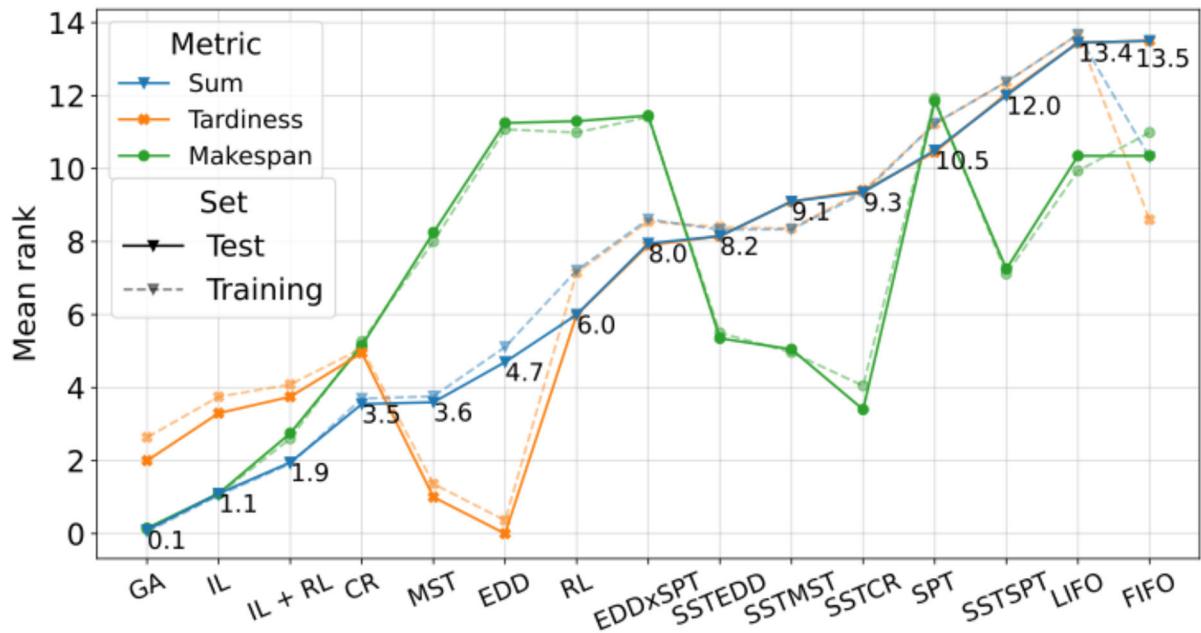


Abbildung 3: Durchschnittlicher Rang aller 15 Ansätze im deterministischen Szenario.

**Maschinenausfälle (9 Settings):** Unter neun Maschinenausfall-Einstellungen übertrafen die beiden ML-Ansätze alle 14 Baselines in allen Settings konsistent. IL+RL zeigte die beste Leistung in den disruptivsten Szenarien (niedrige Verfügbarkeit, hohe Reparaturzeit), während IL in den weniger gestörten Umgebungen dominierte. Die durchschnittliche Verbesserung gegenüber der besten Heuristik (MST) betrug ca. 8%. Der statische GA-Lösungsplan war nun nur noch vergleichbar mit den besten Heuristiken, was die Notwendigkeit ereignisbasierter Neuplanung unterstreicht.

**Lieferantenausfälle (2 Settings):** Unter Lieferantenausfällen erzielte IL+RL die beste Gesamtleistung mit einem Gap von 5,1% im Setting mit hoher Verwundbarkeit und 6,9% im Setting mit niedriger Verwundbarkeit. Die Verbesserung gegenüber der besten nicht-ML-basierten Methode betrug 27%. Die Feature-Importance-Analyse offenbarte eine fundamentale Änderung der Policy durch RL-Fine-Tuning: eine Verschiebung von einer reaktiven Strategie, die auf eingetretene Lieferantenausfälle reagiert, zu einer prädiktiven Strategie, die Jobs mit hoher Ausfallwahrscheinlichkeit bevorzugt früh einplant.

#### AP 5 – Verwertung und Dokumentation

Die Forschungsergebnisse wurden in zwei peer-reviewed Artikeln, u.a. im International Journal of Production Research, veröffentlicht und auf mehreren nationalen und internationalen Konferenzen präsentiert. Die Ergebnisse wurden in Lehrveranstaltungen an beiden Universitäten integriert. An beiden Standorten wurden insgesamt über zehn Masterarbeiten mit Bezug zum Forschungsvorhaben betreut. Details zu Publikationen und Verwertung finden sich in den Abschnitten 9 und 11.

## 4.2 Schlüsselerkenntnisse

Aus den experimentellen Ergebnissen lassen sich vier generalisierende Erkenntnisse ableiten:

- Ereignisbasierte Neuplanung mit gelernten Policies ist statischer Voro Optimierung klar überlegen, selbst wenn die statische Lösung eine relativ adaptive Sequenz von Heuristiken vorschreibt. Dieses Ergebnis ist ein starkes Argument für flexible Neuplanungsmethoden in jeder Umgebung, die stochastischen Störungen ausgesetzt ist.
- Imitation Learning ermöglicht den Transfer der Leistungsfähigkeit rechenintensiver Metaheuristiken in Echtzeit. Dies ist hochrelevant für die Operations-Research-Community, da Metaheuristiken eine



populäre Lösungsmethode für viele Problemklassen sind, aber die Rechenzeit ein limitierender Faktor sein kann.

- RL-Fine-Tuning ist am wertvollsten in den disruptivsten Umgebungen und erzeugt bedeutungsvollere Policies. Die Feature-Importance-Analyse zeigt, dass RL dem Agenten Konzepte lehrt, die in der statischen Offline-Lösung nicht erfasst wurden, insbesondere die Verschiebung von reaktiven zu prädiktiven Strategien.
- In stochastischen Multi-Ziel-Umgebungen sind einzelne Dispatching-Regeln nicht ausreichend für eine gute Gesamtleistung. Gute Lösungen erfordern anspruchsvollere Policies, wie sie nur von Metaheuristiken oder ML-Ansätzen bereitgestellt werden können.

## 5 Wichtigste Positionen des zahlenmäßigen Nachweises

Der Ausgabenplan wurde eingehalten.

## 6 Notwendigkeit und Angemessenheit der geleisteten Projektarbeiten

Die im Rahmen des Vorhabens durchgeführten Arbeiten waren notwendig, um die identifizierte Forschungslücke an der Schnittstelle von integrierter Planung, Supply-Chain-Resilienz und maschinellem Lernen zu adressieren.

Die systematische Literaturrecherche in AP 1 war erforderlich, um den Stand der Forschung zu dokumentieren und die Forschungslücke empirisch zu belegen. Die Analyse von 460 Publikationen bestätigte, dass kein existierender Ansatz alle Anforderungen des Vorhabens erfüllt.

Die Implementierung des genetischen Algorithmus als Synchronisierungsmethode war die notwendige Voraussetzung für den nachfolgenden Imitation-Learning-Ansatz. Die GA-Lösungen dienten als Expertenwissen für das überwachte Vortraining der neuronalen Netze. Ein Training des RL-Agenten von Grund auf erwies sich als nicht erfolgreich (Gap von 113,2%), was die Notwendigkeit des zweistufigen Ansatzes bestätigt.

Die Konzentration auf die Integration von Beschaffung und Produktion statt aller drei Supply-Chain-Prozesse gleichzeitig war angemessen. Der Erkenntnisgewinn in diesem Bereich war am größten, da die Schnittstelle zwischen Beschaffung und Produktion die unmittelbarsten Auswirkungen von Supply-Chain-Störungen aufweist.

Der Forschungsaufenthalt an der University of Hyogo war für die realistische Modellierung von Lieferantenausfällen unerlässlich. Ohne dass dort entwickelte agentenbasierte Simulationsmodell mit 22.500 Disruptionsszenarien wären die Lieferantenausfallwahrscheinlichkeiten rein hypothetisch geblieben.

Die Nutzung von CUDA-fähiger Hardware an der Universität Mannheim war für das Training der Transformer-basierten neuronalen Netze unerlässlich. Die Hyperparameteroptimierung mittels 5-facher Kreuzvalidierung und das RL-Training mit parallelen Umgebungsrunnern erfordern erhebliche Rechenkapazitäten.



## 7 Voraussichtlicher Nutzen, Verwertbarkeit der Ergebnisse und zukünftige Planungen im Sinne des Verwertungsplans

### 7.1 Wissenschaftlicher Nutzen

Das Forschungsvorhaben leistet einen Beitrag zur Grundlagenforschung an der Schnittstelle von maschinellem Lernen und Operations Research. Die entwickelte Methoden-Pipeline (GA als Expertensolver, Imitation Learning für Echtzeitfähigkeit, RL-Fine-Tuning für stochastische Anpassung) ist konzeptionell auf andere kombinatorische Optimierungsprobleme übertragbar. Die Ergebnisse zeigen zwei generalisierbare Erkenntnisse: Erstens, dass Imitation Learning ein wertvoller Ansatz ist, um die Leistung rechenintensiver Suchmethoden in Echtzeit verfügbar zu machen. Zweitens, dass RL am effektivsten als Fine-Tuning-Instrument für vortrainierte Agenten eingesetzt wird.

Darüber hinaus leistet das Vorhaben einen Beitrag zur Supply-Chain-Resilienzforschung durch die erstmalige Integration kaskadierender Lieferantenausfallwahrscheinlichkeiten in den RL-Beobachtungsraum eines Scheduling-Problems. Die Erkenntnis, dass RL-Fine-Tuning eine Verschiebung von reaktiven zu prädiktiven Strategien ermöglicht, ist für die weitere Forschung richtungsweisend.

### 7.2 Wirtschaftlicher Nutzen

Das entwickelte prototypische Entscheidungsunterstützungssystem bietet funktionalen Mehrwert insbesondere für kleine und mittlere Unternehmen im produzierenden Gewerbe, deren Entscheidungen in der Supply-Chain-Planung in der Regel noch basierend auf implizitem Erfahrungswissen getroffen werden. Die quantifizierten Verbesserungspotenziale von 8% bei Maschinenausfällen und 27% bei Lieferantenausfällen belegen den wirtschaftlichen Nutzen datengetriebener Ansätze.

Ein Anschlussprojekt mit einem Industriepartner als direktem Fördermittelempfänger befindet sich in Vorbereitung. Das BMFTR-Folgeprojekt MINDNET baut direkt auf den Erkenntnissen von KISync auf und verwendet Daten wieder.

### 7.3 Verwertung in der Lehre

Die Forschungsergebnisse wurden an beiden Universitäten in die Lehre integriert. An der OVGU flossen die Erkenntnisse in die Lehrveranstaltungen Simulation in Produktion und Logistik sowie Modellierung und Simulation in der Logistikplanung ein. An der Universität Mannheim wurden die Ergebnisse in den Veranstaltungen Industrial Applications of Artificial Intelligence und Künstliche Intelligenz verwendet. An beiden Standorten wurden zusammen über zehn Masterarbeiten mit Bezug zum Forschungsvorhaben betreut.

Das Forschungsvorhaben trägt zum neuen Studiengang AI Engineering an der OVGU bei, der seit dem Wintersemester 2023/2024 angeboten wird. Die Erfahrungen zum Aufbau von Datenkompetenz in Kombination mit KI werden direkt in das Curriculum des neuen Studiengangs integriert.

## 8 Fortschritt auf dem Gebiet des Vorhabens während der Durchführung des Vorhabens bei anderen Stellen

Während der Projektlaufzeit wurden von mehreren Forschungsgruppen RL-basierte Ansätze für dynamisches Scheduling veröffentlicht. Yi et al. (2025) verwendeten ein Double Deep Q-Network mit einem Action Space Pre-Screening Mechanismus für die dynamische Auswahl von Dispatching-Regeln bei Maschinenausfällen. Wu et al. (2025) setzten adaptive Gewichtungsmechanismen für Multi-Ziel-Abwägungen bei Equipmentausfällen ein. Lv et al. (2025) wendeten Multi-Agent Reinforcement Learning mit Graph Neural Networks für dezentralisiertes Re-Routing an.



Allerdings bestätigte ein aktueller Literaturüberblick von Ngwu et al. (2025), dass die gesamte RL-Literatur im dynamischen Job Shop Scheduling auf interne Shop-Floor-Unsicherheiten beschränkt bleibt. Externe Supply-Chain-Risiken und die Integration von Beschaffungsentscheidungen in das Scheduling sind weiterhin nicht adressiert. KISync adressiert diese Lücke als eines der ersten Forschungsvorhaben durch die Integration kaskadierender Lieferantenausfallwahrscheinlichkeiten in den RL-Beobachtungsraum und die integrierte Betrachtung von Beschaffung und Produktion.

## 9 Erfolge oder geplante Veröffentlichungen der Projektergebnisse

### Peer-reviewed Journal-Artikel:

- Bubak, A., Rolf, B., Reggelin, T., Lang, S. und Stuckenschmidt, H. (2024): An LSTM network-based genetic algorithm for integrated procurement and scheduling optimisation. International Journal of Production Research. DOI: 10.1080/00207543.2024.2434948
- Rolf, B., Beier, A., Jackson, I., Müller, M., Reggelin, T., Stuckenschmidt, H. und Lang, S. (2024): A review on unsupervised learning algorithms and applications in supply chain management. International Journal of Production Research. DOI: 10.1080/00207543.2024.2390968
- Rolf, B., Bubak, A., Reggelin, T., Stuckenschmidt, H. und Lang, S. (2026): Production scheduling under disruptions: Imitation learning and reinforcement learning for stochastic hybrid flow shops (am 28.02.2026 eingereicht beim European Journal of Operational Research)

### Konferenzbeiträge:

- Katoor Vishnuthilak, K., Rolf, B., Reggelin, T. und Lang, S. (2024): Using sentiment analysis to detect disruptive events in supply chains. IFAC INCOM 2024, Wien. DOI: 10.1016/j.ifacol.2024.09.178

### Konferenzpräsentationen:

- GOR e.V. Jahrestagung 2023, Hamburg (29. August bis 1. September 2023)
- Wissenschaftliche Kommission für Produktionswirtschaft, Herbsttagung 2023, Technische Universität Berlin (3. bis 4. November 2023)
- Conference on Complex Systems (CCS), Satellitensymposium "Economic and Financial Networks" FinEcoNets, <https://ccs25.cssociety.org/satellites-list/> (3. - 4. September 2025)

### Betreute Masterarbeiten (Auswahl):

- Data-driven production scheduling: A case study on a German logistics company (Universität Mannheim)
- Comparative Analysis of Separated and Integrated Approaches in Data-Driven Supply Chain Optimization (Universität Mannheim)
- Reinforcement Learning for the Vehicle Routing Problem (Universität Mannheim)
- Using sentiment analysis to improve sourcing decisions in supply chain management (OVGU, 2023)
- Entwicklung eines Entscheidungsunterstützungssystems zur qualitätsorientierten Auftragsreihenfolgeplanung (OVGU, 2024)
- Developing a dynamic visualization tool for macroscopic supply chain simulation models (OVGU, 2024)

## 10 Literaturverzeichnis

Bubak, A., Rolf, B., Reggelin, T., Lang, S. und Stuckenschmidt, H. (2024): An LSTM network-based genetic algorithm for integrated procurement and scheduling optimisation. International Journal of Production Research. DOI: 10.1080/00207543.2024.2434948.



- Inoue, H. und Todo, Y. (2019): Firm-level propagation of shocks through supply-chain networks. *Nature Sustainability*, 2(9), S. 841–847. DOI: 10.1038/s41893-019-0351-x.
- Ivanov, D., Sokolov, B. und Dolgui, A. (2014): The Ripple effect in supply chains: trade-off “efficiency-flexibility-resilience” in disruption management. *International Journal of Production Research*, 52(7), S. 2154–2172. DOI: 10.1080/00207543.2013.858836.
- Lang, S., Behrendt, F., Lanzerath, N., Reggelin, T. und Müller, M. (2020): Integration of Deep Reinforcement Learning and Discrete-Event Simulation for Real-Time Scheduling of a Flexible Job Shop Production. *Proceedings of the 2020 Winter Simulation Conference (WSC)*, S. 3057–3068. DOI: 10.1109/WSC48552.2020.9383997.
- Lv, L., Fan, J., Zhang, C. und Shen, W. (2025): A multi-agent reinforcement learning based scheduling strategy for flexible job shops under machine breakdowns. *Robotics and Computer-Integrated Manufacturing*, 93, 102923. DOI: 10.1016/j.rcim.2024.102923.
- Ngwu, C., Liu, Y. und Wu, R. (2025): Reinforcement learning in dynamic job shop scheduling: a comprehensive review of AI-driven approaches in modern manufacturing. *Journal of Intelligent Manufacturing*, S. 1–16. DOI: 10.1007/s10845-025-02585-6.
- Rolf, B., Beier, A., Jackson, I., Müller, M., Reggelin, T., Stuckenschmidt, H. und Lang, S. (2024): A review on unsupervised learning algorithms and applications in supply chain management. *International Journal of Production Research*. DOI: 10.1080/00207543.2024.2390968.
- Wu, R., Zheng, J. und Yin, X. (2025): Dynamic Scheduling for Multi-Objective Flexible Job Shops with Machine Breakdown by Deep Reinforcement Learning. *Processes*, 13(4), 1246. DOI: 10.3390/pr13041246.
- Yi, W., Deng, Q., Wang, B., Chen, Y. und Pei, Z. (2025): Dynamic flexible job shop scheduling problem considering multiple types of dynamic events. *International Journal of Production Research*, 63(24), S. 10291–10308. DOI: 10.1080/00207543.2025.2550454.