



Sachbericht Teil I: Kurzbericht

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

Förderkennzeichen: 16DKWN092B

1 Ursprüngliche Aufgabenstellung und Stand der Forschung

Das Forschungsvorhaben KISync verfolgte das Ziel, die Anwendung von Methoden der Künstlichen Intelligenz auf die prozessübergreifende Synchronisierung von Entscheidungsproblemen in der operativen Supply-Chain-Planung zu untersuchen. Im Mittelpunkt stand dabei die innerbetriebliche Planung in kompetitiven Supply Chains mit begrenztem Informationsaustausch zwischen den beteiligten Akteuren. Neben der Entwicklung neuer methodischer Ansätze sollte geklärt werden, in welcher Weise KI zur Entscheidungsunterstützung in komplexen Planungssituationen beitragen und zugleich die prozessübergreifende Datenkompetenz von Entscheidungsträgern stärken kann. Aus technischer Sicht war hierzu die Entwicklung eines prototypischen Entscheidungsunterstützungssystems vorgesehen.

Ausgangspunkt des Vorhabens war die hohe Komplexität moderner Supply Chains, die von hoher Unsicherheit und einem Bedürfnis nach Resilienz und Agilität geprägt sind. Die zugehörigen Entscheidungsprobleme in Beschaffung, Produktion und Distribution gehören zu den kombinatorisch hoch anspruchsvollen Optimierungsproblemen. In der wissenschaftlichen Literatur und in der betrieblichen Praxis werden diese Probleme aufgrund ihrer Komplexität vielfach getrennt betrachtet, obwohl zwischen ihnen enge wechselseitige Abhängigkeiten bestehen.

Der wissenschaftliche und technische Stand zum Projektbeginn war dadurch geprägt, dass für einzelne Teilprobleme der Supply-Chain-Planung bereits zahlreiche Lösungsansätze aus dem Operations-Research sowie zunehmend aus dem Bereich des maschinellen Lernens vorlagen. Demgegenüber war die integrierte Betrachtung operativer Beschaffungs- und Produktionsentscheidungen deutlich weniger weit entwickelt. Die ausgewertete Literatur verweist darauf, dass integrierte Planungsansätze zwar ein erhebliches Effizienzpotenzial besitzen, belastbare empirische Nachweise hierfür auf operativer Ebene jedoch bislang nur in begrenztem Umfang vorlagen. Insbesondere die Verbindung von Beschaffung und Produktion war in der Forschung unterrepräsentiert; zugleich dominierten vielfach deterministische Modelle, die dynamische Unsicherheiten und Störungen nur eingeschränkt abbilden und zusätzlich oftmals lediglich auf künstlich simulierten statt realen Daten evaluiert wurden.

Vor diesem Hintergrund bestand die ursprüngliche Aufgabenstellung des Projekts darin, prozessübergreifende operative Planungsprobleme in ihrem Zusammenhang zu analysieren, hierfür KI-gestützte Lösungsansätze zu entwickeln und diese auf realen Daten zu testen. Von besonderem Interesse war, ob sich maschinelles Lernen und Reinforcement Learning dazu eignen, komplexe Interdependenzen zwischen Beschaffung und Produktion abzubilden und unter Unsicherheit belastbare Entscheidungsvorschläge zu erzeugen. Das Vorhaben knüpfte damit an einen klar identifizierten Forschungsbedarf an: an der Schnittstelle zwischen integrierter operativer Planung, datengetriebener Entscheidungsunterstützung und resilienter Ausgestaltung von Supply Chains.

2 Ablauf des Vorhabens und wesentliche Ergebnisse

Die Bearbeitung des Forschungsvorhabens kann in drei Projektphasen gegliedert werden, die gemeinsam die fünf Arbeitspakete des Verbundvorhabens abdecken.



In der ersten Projektphase wurde eine systematische Literaturrecherche inkl. der Analyse von 460 Publikationen durchgeführt. Die Recherche hatte zwei Schwerpunkte. Zum einen wurde zur Förderung der KI-Kompetenz der Projektmitarbeiter und zur Vorbereitung der Entwicklung des KI-gestützten Entscheidungsunterstützungssystems der Einsatz von Methoden des Unüberwachten Lernens im Supply Chain Management erforscht. Die Ergebnisse wurden im International Journal of Production Research veröffentlicht (Rolf et al., 2024). Außerdem wurde der aktuelle Stand der Literatur zu integrierten Ansätzen in der operativen Supply Chain-Planung aufgearbeitet. Parallel dazu wurde in dieser Phase die Analyse von Supply-Chain-System und -Daten eines mittelständischen Halbleiterherstellers durchgeführt.

Auf dieser Basis wurde in der zweiten Projektphase ein konzeptionelles Modell entwickelt, das eine generative Hyper-Heuristik auf Basis eines genetischen Algorithmus (GA) als Synchronisierungsmethode vorsieht. Zur konkreten Umsetzung dieses Konzeptes wurde ein LSTM-basierter GA für die integrierte Beschaffungs- und Scheduling-Optimierung implementiert. Der Synchronisierungsagent wurde auf den Scheduling-Daten des Halbleiterherstellers und einer hohen Anzahl verschiedener Kostenszenarien evaluiert und erzielte Kosteneinsparungen gegenüber isolierten Optimierungsansätzen von durchschnittlich 69%. Die Resultate wurden auf der GOR-Jahrestagung 2023, der Herbsttagung der Wissenschaftlichen Kommission für Produktionswirtschaft 2023 und der IFAC INCOM 2024 präsentiert sowie im International Journal of Production Research veröffentlicht (Bubak et al., 2024).

In der dritten Phase 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. Aufbauend auf diesem digitalen Zwilling wurde die vollständige Methoden-Pipeline implementiert und evaluiert. Der finale Ansatz beruht auf der Vorab-Berechnung von GA-Lösungen, mit deren Hilfe ein Transformer-basierter KI-Agent vortrainiert wird. Anschließend wird der Agent mittels Bestärkendem Lernen auf stochastische Disruptionen wie Maschinen- und Lieferantenausfälle feinabgestimmt. Das finale KI-gestützte Entscheidungssystem wurde auf 100 realen Scheduling-Instanzen des Industriepartners in 12 verschiedenen Störungsszenarien gegen 14 Baselines evaluiert. Der Agent erreicht im deterministischen Fall nahezu die Qualität des genetischen Algorithmus bei gleichzeitiger Echtzeitfähigkeit, unter Maschinenausfällen eine durchschnittliche Kostenersparnis von 8% und unter Lieferantenausfällen eine durchschnittliche Verbesserung von 14%. Die Ergebnisse wurden zu einem Forschungsartikel zusammengefasst, der beim European Journal of Operational Research eingereicht wurde und sich dort aktuell im Review-Prozess befindet.

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.

3 Literaturverzeichnis

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.

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.



Sachbericht Teil II: Eingehende Darstellung

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

Förderkennzeichen: 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.

Inhaltsverzeichnis

1	Aufgabenstellung.....	2
1.1	Gesamtziel des Forschungsvorhabens	2
1.2	Bezug zu den förderpolitischen Zielen	2
1.3	Wissenschaftliche und technische Arbeitsziele	3
2	Stand der Forschung.....	3
3	Planung und Ablauf des Vorhabens	5
3.1	Planung des Vorhabens.....	5
3.2	Ablauf des Vorhabens.....	6
3.3	Verbundpartner Universität Mannheim	7
3.4	Industriepartner.....	7
3.5	Internationale Kooperation	7
3.6	Abgrenzung zu verwandten Vorhaben	8
4	Inhaltliche Ergebnisse	8
4.1	Ergebnisse nach Arbeitspaketen.....	8
4.2	Schlüsselerkenntnisse	13
5	Wichtigste Positionen des zahlenmäßigen Nachweises	14
6	Notwendigkeit und Angemessenheit der geleisteten Projektarbeiten.....	14
7	Voraussichtlicher Nutzen, Verwertbarkeit der Ergebnisse und zukünftige Planungen im Sinne des Verwertungsplans.....	15
7.1	Wissenschaftlicher Nutzen.....	15
7.2	Wirtschaftlicher Nutzen	15
7.3	Verwertung in der Lehre.....	15



8	Fortschritt auf dem Gebiet des Vorhabens während der Durchführung des Vorhabens bei anderen Stellen	16
9	Erfolgte oder geplante Veröffentlichungen der Projektergebnisse	16
10	Literaturverzeichnis.....	17

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. Neben der Entwicklung neuer methodischer Ansätze sollte geklärt werden, in welcher Weise KI zur Entscheidungsunterstützung in komplexen Planungssituationen beitragen und zugleich die prozessübergreifende Datenkompetenz von Entscheidungsträgern stärken kann.

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 „Richtlinie zur Förderung von Projekten zur Stärkung der Datenkompetenzen des wissenschaftlichen Nachwuchses“ des BMBF. 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 den Einsatz von Daten eines mittelständischen Unternehmens beschäftigt sich das Projekt mit industrienaher Grundlagenforschung und hilft bei der Beantwortung von Fragestellungen mit hoher Relevanz für die Industrie.



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 war in der Wissenschaft kaum verbreitet. Auch der Einsatz von maschinellem Lernen sowie Reinforcement Learning war in diesem Zusammenhang bisher kaum erforscht. Das technische Arbeitsziel war die Entwicklung eines Entscheidungsunterstützungssystems, das Entscheidungsprobleme in der operativen Supply-Chain-Planung optimiert und Handlungen für den Entscheidungsträger vorschlägt. Dazu sollte durch die Nachwuchswissenschaftler ein prototypisches System implementiert werden.

Ein mit den wissenschaftlichen und technischen Arbeitszielen einhergehender Effekt war der Aufbau von Datenkompetenz bei den projektbearbeitenden Nachwuchswissenschaftlern. Durch die verschiedensten Datenquellen und Optimierungsmethoden, die in der operativen Supply-Chain-Planung eine Rolle spielen, war die Bearbeitung des Projekts und insbesondere die Implementierung des Prototyps unmittelbar mit dem Aufbau von Daten- und KI-Kompetenz verknüpft.

2 Stand der Forschung

Die operative Supply-Chain-Planung ist durch eine Vielzahl komplexer, miteinander verknüpfter Entscheidungsprobleme geprägt. Zu den zentralen Problemklassen zählen die Beschaffung (Order Allocation Problem), die Produktionsplanung (Scheduling Problem) sowie die Distribution (Vehicle Routing Problem). Diese Probleme sind in der Regel NP-schwer und können selbst in isolierter Form nur mit erheblichem Rechenaufwand gelöst werden. Entsprechend dominieren in der Literatur heuristische und metaheuristische Verfahren sowie mathematische Optimierungsmodelle. In den letzten Jahren gewinnen zudem Methoden der Künstlichen Intelligenz zunehmend an Bedeutung, insbesondere zur datengetriebenen Unterstützung von Entscheidungsprozessen.

Ein wesentliches Merkmal des Stands der Forschung ist die überwiegend isolierte Betrachtung einzelner Entscheidungsprobleme. In der wissenschaftlichen Literatur haben sich weitgehend getrennte Forschungsstränge für Beschaffung, Produktion und Distribution entwickelt, die jeweils eigene Methoden und Modelle hervorgebracht haben.

Diese Fragmentierung führt dazu, dass die Interdependenzen zwischen den Prozessen nur unzureichend berücksichtigt werden. In realen Supply Chains wirken sich Entscheidungen in einem Prozess unmittelbar auf nachgelagerte Prozesse aus. Beispielsweise beeinflussen Beschaffungsentscheidungen die Materialverfügbarkeit und damit die Produktionsplanung. Dennoch werden diese Abhängigkeiten in vielen Modellen durch vereinfachende Annahmen, etwa exogene oder deterministische Eingangsgrößen, approximiert.

Ein weiterer zentraler Kritikpunkt betrifft die unzureichende Berücksichtigung von Unsicherheiten. Reale Supply Chains sind durch vielfältige stochastische Einflüsse gekennzeichnet, darunter schwankende Nachfrage, Lieferverzögerungen oder Maschinenausfälle. Diese Unsicherheiten wirken sich nicht nur lokal, sondern entlang der gesamten Wertschöpfungskette aus. In der Literatur dominieren jedoch weiterhin Modelle mit deterministischen Parametern. Auch in integrierten Planungsansätzen werden Unsicherheiten häufig stark vereinfacht oder vollständig ausgeblendet. Dies führt zu einer eingeschränkten Übertragbarkeit der Ergebnisse auf reale Anwendungsszenarien. Die mangelnde Realitätsnähe der wissenschaftlichen Forschung wird von der bevorzugten Verwendung synthetischer statt realer Daten noch verstärkt.



Vor dem Hintergrund der genannten Limitationen hat sich ein wachsendes Forschungsfeld zur integrierten Planung entwickelt. Ziel dieser Ansätze ist es, mehrere Entscheidungsprobleme simultan zu betrachten und dadurch die Effizienz der Gesamtplanung zu verbessern. Studien zeigen, dass integrierte Planung im Vergleich zu sequenziellen Ansätzen potenziell signifikante Kostenvorteile ermöglichen kann. Dennoch weist die bestehende Literatur mehrere strukturelle Einschränkungen auf. Ein Großteil der Arbeiten fokussiert sich auf die Integration von Produktion und Distribution, während andere Kombinationen, insbesondere Beschaffung und Produktion, deutlich seltener untersucht werden. Außerdem sind viele Modelle auf taktische Planungsebenen ausgerichtet, während die operative Planung mit ihren höheren Anforderungen an Rechenzeit und Detailgrad weniger berücksichtigt wird. Die empirische Validierung integrierter Ansätze ist begrenzt; häufig beschränken sich Arbeiten auf konzeptionelle oder modellbasierte Analysen ohne umfassende Vergleichsstudien. Hinzu kommt, dass integrierte Modelle oft weiterhin auf vereinfachte Problemstrukturen zurückgreifen, etwa deterministische Parameter oder reduzierte Systemkomplexität. Insgesamt lässt sich festhalten, dass zwar ein zunehmendes Interesse an integrierten Planungsansätzen besteht, jedoch weiterhin erhebliche Forschungslücken hinsichtlich Realitätsnähe, Komplexität und empirischer Absicherung bestehen.

Neben der Integration mehrerer Entscheidungsprobleme gewinnt auch die Frage nach der Resilienz und Agilität von Supply Chains zunehmend an Bedeutung. Klassische Planungsmodelle sind in der Regel statisch und optimieren für einen festen Planungshorizont. Sie berücksichtigen jedoch nur unzureichend die dynamische Natur realer Systeme, in denen sich Zustände kontinuierlich ändern und Störungen auftreten können. Die Literatur zur Supply-Chain-Resilienz hebt hervor, dass Störungen häufig nicht isoliert auftreten, sondern sich entlang von Netzwerken fortpflanzen können. Diese sogenannten Kaskadeneffekte führen zu komplexen Abhängigkeiten, die in vielen Optimierungsmodellen nicht explizit berücksichtigt werden. Zur Modellierung solcher Dynamiken werden zunehmend simulationsbasierte Ansätze sowie agentenbasierte Modelle eingesetzt. Gleichzeitig zeigt sich, dass klassische Optimierungsverfahren aufgrund ihrer Rechenzeiten nur eingeschränkt für Echtzeitentscheidungen geeignet sind.

Vor diesem Hintergrund wird der Einsatz von Methoden der Künstlichen Intelligenz, insbesondere maschinelles Lernen und Reinforcement Learning, intensiv diskutiert. Diese Methoden ermöglichen es, Entscheidungsstrategien auf Basis von Daten zu erlernen und in dynamischen Umgebungen in Echtzeit anzuwenden. Insbesondere Reinforcement Learning bietet die Möglichkeit, sequenzielle Entscheidungsprobleme unter Unsicherheit zu adressieren, indem Entscheidungen adaptiv an den aktuellen Systemzustand angepasst werden. Dennoch zeigt die bestehende Literatur, dass entsprechende Ansätze bislang überwiegend auf isolierte Problemstellungen, insbesondere innerhalb der Produktion, beschränkt sind. Die Integration externer Einflüsse, wie beispielsweise Beschaffungsrisiken, wird nur selten berücksichtigt.

Zusammenfassend war der Stand der Forschung zu Projektbeginn durch folgende zentrale Charakteristika geprägt:

1. **Dominanz isolierter Optimierungsansätze** für einzelne Entscheidungsprobleme der Supply-Chain-Planung,
2. **begrenzte Integration** dieser Probleme, insbesondere mittels realitätsnaher Modellierung auf der operativen Ebene,
3. **unzureichende Berücksichtigung von Unsicherheiten, Realdaten und Dynamik**,
4. sowie eine noch fragmentierte Nutzung von **KI-Methoden** in integrierten Kontexten.

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 Logistik und Materialflusstechnik (ILM) 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. Das Forschungsvorhaben wurde durch Dr.-Ing. Tobias Reggelin geleitet, der in seiner Dissertation 2011 einen mesoskopischen Simulationsansatz für logistische Flusssysteme entwickelte und über langjährige Erfahrung in der Durchführung von Forschungsprojekten (EU, BMBF, BMWi) verfügt. Seit März 2024 wurde die Arbeitsgruppe durch Jun.-Prof. Dr.-Ing. Sebastian Lang verstärkt, der spezifische Expertise in KI-Methoden für Produktion und Logistik einbrachte. Der Projektbearbeiter Benjamin Rolf war seit Juli 2021 als wissenschaftlicher Mitarbeiter und Doktorand am ILM tätig. Im Rahmen seiner Dissertation, die thematisch eng mit dem Forschungsvorhaben verknüpft ist, hat er umfangreiche Expertise in der Anwendung von Metaheuristiken und KI für das Scheduling Problem aufgebaut.

Der Lehrstuhl für Künstliche Intelligenz (LKI) der Universität Mannheim unter Leitung von Prof. Dr. Heiner Stuckenschmidt brachte über 15 Jahre Erfahrung in Grundlagen und Anwendungen von KI-Methoden in unterschiedlichen Bereichen ein. Prof. Stuckenschmidt ist auf dem Bereich der Künstlichen Intelligenz international anerkannt und Gründungsmitglied der Data and Web Science Research Group der Universität Mannheim. Der Projektbearbeiter Ralph Alexander Beier (seit 2024: Ralph Alexander Bubak) promovierte seit Juli 2021 am LKI. Im Rahmen seiner Dissertation, die thematisch eng mit dem Forschungsvorhaben verknüpft ist, hat er umfangreiche Expertise in der Problemmodellierung sowie der Anwendung von Metaheuristiken und KI in verschiedenen Bereich des Supply Chain Management entwickelt.

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. 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	PM (ILM/LKI)	Plan	Umsetzung
0	Projekt- und Risikomanagement	ILM	1/1	10/22 – 09/25	10/22 – 09/25
1	Analyse	ILM	3/3	10/22 – 12/22	10/22 – 03/23
2	Konzeptionelles Modell	ILM	4/4	01/23 – 04/23	01/23 – 09/23
3	Implementierung Softwareprototyp	LKI	14/14	05/23 – 08/24	05/23 – 03/25
4	Feinabstimmung und Evaluation	LKI	8/8	09/24 – 05/25	09/23 – 07/25
5	Verwertung und Dokumentation	ILM	6/6	10/22 – 09/25	10/22 – 09/25

Die Arbeitspakete 1-5 zielten jeweils auf folgende Meilensteine ab: (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 mehrstufiger Komplexitätsansatz gewählt, der eine schrittweise Erhöhung der Komplexität des betrachteten Problems und des Entscheidungsagenten, eine fokussierte Evaluation und die Publikation von Teilergebnissen ermöglichte.

In der ersten Projektphase (Oktober 2022 bis März 2023) wurde eine systematische Literaturrecherche inkl. der Analyse von 460 Publikationen durchgeführt. Die Recherche hatte zwei Schwerpunkte. Zum einen wurde zur Förderung der KI-Kompetenz der Projektmitarbeiter und zur Vorbereitung der Entwicklung des KI-gestützten Entscheidungsunterstützungssystems der Einsatz von Methoden des Unüberwachten Lernens im Supply Chain Management erforscht. Die Ergebnisse wurden im International Journal of Production Research veröffentlicht (Rolf et al., 2024). Außerdem wurde der aktuelle Stand der Literatur zu integrierten Optimierungsansätzen in der operativen Supply Chain-Planung aufgearbeitet. Die Analyse bestätigte die identifizierte Forschungslücke: Keine der existierenden Publikationen vereinte alle Anforderungen des Vorhabens (s. Kapitel 2). Parallel dazu wurde in dieser Phase die Analyse von Supply-Chain-System und -Daten eines mittelständischen Halbleiterherstellers durchgeführt.

Auf dieser Basis wurde in der zweiten Projektphase (April 2024 – Mai 2024) ein konzeptionelles Modell entwickelt, das eine generative Hyper-Heuristik auf Basis eines genetischen Algorithmus (GA) als Synchronisierungsmethode vorsieht. Hier wurde außerdem die Entscheidung getroffen, die ursprüngliche Planung des Vorhabens wie erwähnt dahingehend abzuändern, dass das Vorhaben in zwei Komplexitätsstufen bearbeitet werden sollte. In der aktuellen Projektphase stand eine deterministische Evaluationsumgebung im Fokus, stochastische Einflussgrößen wurden bis zur dritten Projektphase aufgeschoben. Zur konkreten Umsetzung des aktuellen Konzeptes wurde ein LSTM-basierter GA für die integrierte Beschaffungs- und Scheduling-Optimierung implementiert. Der Synchronisierungsagent wurde auf den Scheduling-Daten des Halbleiterherstellers und einer hohen Anzahl verschiedener Kostenszenarien evaluiert und erzielte Kosteneinsparungen gegenüber isolierten Optimierungsansätzen von durchschnittlich 69%. Die Resultate wurden auf der GOR-Jahrestagung 2023, der Herbsttagung der Wissenschaftlichen Kommission für Produktionswirtschaft 2023 und der IFAC INCOM 2024 präsentiert sowie im International Journal of Production Research veröffentlicht (Bubak et al., 2024).

In der dritten Phase (November 2023 bis September 2025) wurde die Simulationsumgebung als digitaler Zwilling der Produktionsumgebung um stochastische Maschinenausfälle und kaskadierende Lieferantenausfälle erweitert. Der Forschungsaufenthalt des Projektbearbeiters Benjamin Rolf an der University of Hyogo (Japan) ermöglichte die Entwicklung eines makroskopischen Supply-Chain-Simulationsmodells für realistische Störungsszenarien. Aufbauend auf diesem digitalen Zwilling wurde die vollständige Methoden-Pipeline implementiert und evaluiert. Der finale Ansatz beruht auf der Vorab-Berechnung von GA-Lösungen, mit deren Hilfe ein Transformer-basierter KI-Agent vortrainiert wird. Anschließend wird der Agent mittels Bestärkendem Lernen auf stochastische Disruptionen wie Maschinen- und Lieferantenausfälle feinabgestimmt. Das finale KI-gestützte Entscheidungssystem wurde auf 100 realen Scheduling-Instanzen des Industriepartners in 12 verschiedenen Störungsszenarien gegen 14 Baselines evaluiert. Der Agent erreicht im deterministischen Fall nahezu die Qualität des genetischen Algorithmus bei gleichzeitiger Echtzeitfähigkeit, unter Maschinenausfällen eine durchschnittliche Kostenersparnis von 8% und unter Lieferantenausfällen eine durchschnittliche Verbesserung von 14%. Die Ergebnisse wurden zu einem Forschungsartikel zusammengefasst, der



beim European Journal of Operational Research eingereicht wurde und sich dort aktuell im Review-Prozess befindet.

Wesentliche Abweichungen von der ursprünglichen Planung:

- **Mehrstufiger Komplexitätsansatz:** Die Arbeitspakete 3 und 4 wurden nicht streng sequenziell, sondern in drei Komplexitätsstufen bearbeitet (deterministisch, Maschinenausfälle, Lieferantenausfälle). Dies ermöglichte die Entwicklung und Publikation von Zwischenergebnissen und eine adaptive Umsetzung des Vorhabens.
- **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. Der Unternehmensbereich der Distribution wird in der Realität oft externen Dienstleistern überlassen, in anderen Zeitintervallen geplant oder ist anderweitig von den anderen beiden Bereichen entkoppelt.
- **Methodische Erweiterung:** Statt der ursprünglich geplanten reinen RL-Lösung wurde eine dreistufige Methoden-Pipeline (GA, Imitation Learning, Reinforcement Learning) entwickelt, um der Komplexität des Problems Rechnung zu tragen und die Lösungsqualität zu verbessern.

3.3 Verbundpartner Universität Mannheim

Der Lehrstuhl für Künstliche Intelligenz (LKI) der Universität Mannheim unter Leitung von Prof. Dr. Heiner Stuckenschmidt übernahm die Rolle des datenbezogenen Partners im Verbund. Der Projektbearbeiter Ralph Alexander Bubak 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 Benjamin Rolf 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

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

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 Prozent 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 die Produktionsplanung 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. 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.

Der Industriepartner, ein mittelständischer deutscher Halbleiterhersteller, stellte 100 reale Scheduling-Instanzen mit jeweils 160 Jobs bereit, einschließlich Bearbeitungszeiten, Fälligkeitsterminen und Produktfamilienzugehörigkeiten für die beiden Produktionsstufen SMT und AOI. Die Analyse der Supply-Chain-Daten des EMS-Dienstleisters ergab eine für maschinelles Lernen gut geeignete, homogene Datenbasis. Die Analyse zeigte ähnliche Verteilungen der Bearbeitungszeiten über beide Stufen mit einem Median von ca. 200 Minuten. 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 der Gesamtbearbeitungszeit 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.

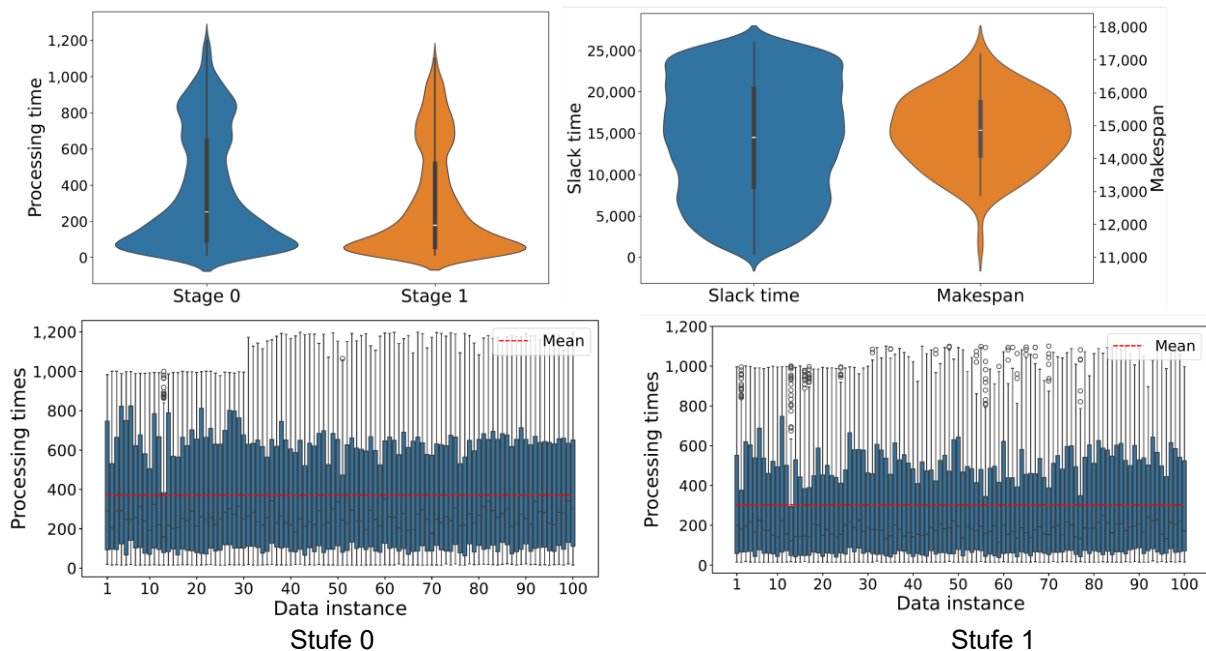


Abbildung 1: Aggregierte deskriptive Analyse der 100 Probleminstanzen. Die Diagramme zeigen ähnliche Bearbeitungszeiten auf den beiden Stufen, ausreichende Schlupfzeiten für eine rechtzeitige Bearbeitung, eine durchschnittliche Gesamtbearbeitungszeit von ca. 15.000 Minuten und Homogenität über die 100 Datensätze.

AP 2 – Konzeptionelles Modell

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 Restriktion stellt sicher, dass auf Stufe 0 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. Die Größe misst die vergangene Zeit zwischen Bearbeitungsbeginn eines Auftrags und dem Ausfall des zugeordneten Lieferanten, und dient so als Metrik für die Reaktivität des Entscheidungssystems auf unvorhergesehene Lieferantenstörungen.

Als Synchronisierungsmethode wurde eine dreistufige Methoden-Pipeline konzipiert. Der erste Schritt besteht in einer generativen Hyper-Heuristik auf Basis eines genetischen Algorithmus mit variablem Chromosom-Encoding. Statt feste Jobsequenzen zu optimieren, evolviert der Algorithmus zeitabhängige Sequenzen von Prioritätsregeln. Eine Bibliothek von 13 Dispatching-Regeln in vier Kategorien wurde implementiert: zeitbasierte Regeln (FIFO, LIFO, SPT, EDD), dynamische Schlupfzeitenbasierte Regeln (MST, CR), zusammengesetzte setup-orientierte Regeln (SST-EDD, SST-SPT, SST-MST, SST-CR, EDDxSPT) sowie zwei neu entwickelte, die Unsicherheit der Lieferanten berücksichtigende Regeln (MTSF, MTSF-MST). Der zweite Schritt nutzt Imitation Learning zur Destillation der GA-Lösungen in neuronale Netzwerke. Abschließend wird der so vortrainierte Entscheidungsagent im dritten Schritt mit Hilfe von Reinforcement Learning verbessert und auf umgebungsspezifische Unsicherheiten feinabgestimmt.

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 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 mit 8 Individuen, Turnierselektion mit 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. In stochastischen Umgebungen, in denen kurzfristig auf unvorhergesehene Störungen reagiert werden muss, ist der GA demnach als eigenständiger Lösungsansatz nicht geeignet.
3. **Transformer-basierte Actor-Critic-Architektur:** Für den Entscheidungsagenten wurde eine spezielle Netzwerkarchitektur konzipiert. Die Architektur verarbeitet variable Jobmengen durch eine Pipeline aus Feature Embedding, Transformer-Encoder-Blöcken mit Multi-Head Attention zur Erfassung von Job-Abhängigkeiten und einem zweiköpfigen Output. Der Actor-Kopf erzeugt mittels Action Masking eine Wahrscheinlichkeitsverteilung über verfügbare Jobs. Zwei



voneinander unabhängige Entscheidungsstrategien werden trainiert: eine für die SMT-Stufe und eine für die AOI-Stufe (mit reduzierten Features aufgrund der auf Stufe 1 reduzierten Problemkomplexität). Die Hyperparameter der Architektur wie Anzahl der Embedding-Schichten, Anzahl der Transformer-Blöcke etc. wurden durch 5-fache Kreuzvalidierung auf den 80 Trainingsinstanzen optimiert.

4. **Imitation Learning Pipeline:** Die besten GA-Individuen pro Scheduling-Instanz werden in Zustands-Aktions-Paare umgewandelt und nach Deduplizierung als Klassifikationsdatensätze für Vortraining verwendet. Die mittels Supervised Learning vortrainierten Netzwerke erreichen eine Top-1-Genauigkeit von 72,5% (Stufe 0) bzw. 96,2% (Stufe 1) und eine Top-5-Genauigkeit von über 99% im deterministischen Fall. Unter Lieferantenausfällen werden Top-1-Genauigkeiten von 50% bzw. 98% und Top-5-Genauigkeiten von 80% bzw. 99% erreicht. 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 Reinforcement Learning in der stochastischen Simulationsumgebung feinabgestimmt, wobei eine Warm-Start-Strategie für den Critic die Konvergenz beschleunigt.

Die für die Implementierung wichtigsten Sprachen, Pakete und Versionen sind Python 3.9.18, PyTorch 2.7.1 und Ray 2.43.0. Die Experimente wurden auf CUDA-fähiger Hardware der Universität Mannheim durchgeführt.

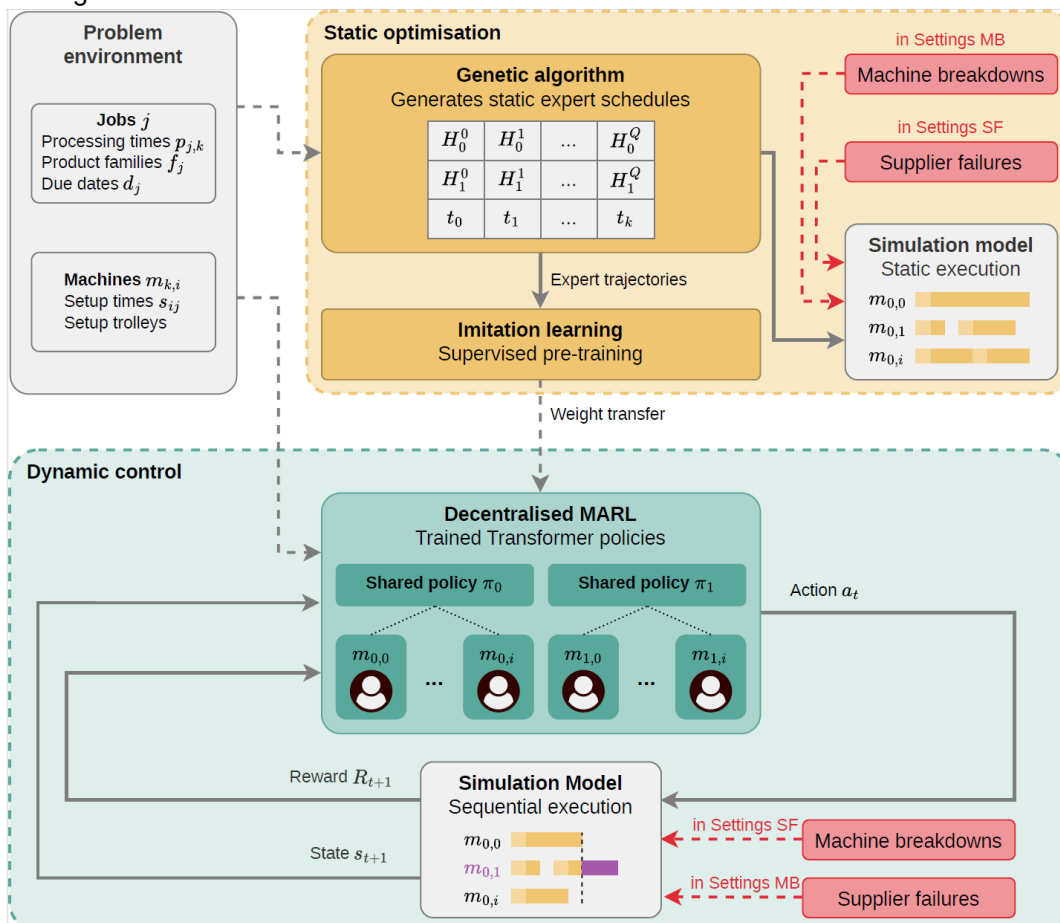


Abbildung 2: Methodisches Framework

AP 4 – Feinabstimmung und Evaluation



Die Evaluation erfolgte über 100 reale Scheduling-Instanzen (80 Training, 20 Test) in drei Szenarien (deterministisch, Maschinenausfälle, Lieferantenausfälle) mit insgesamt 12 Störungseinstellungen. Als Baselines dienten 13 Dispatching-Regeln und der genetische Algorithmus. Zur Evaluation unseres eigenen Entscheidungssystems betrachten wir die Performance von purem Imitation Learning (IL) sowie dem mittels Reinforcement Learning feinabgestimmten Systems (IL + RL).

Deterministisches Umfeld: Im deterministischen Fall erreicht der Entscheidungsagent 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%. 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.

	GA	IL	IL+RL	CR	MST	RL	SST-MST	FIFO
Gap (%)	0.1	1.2	2.2	7.6	8.1	113.2	354.0	1,393.1
95% CI	(0.0, 0.8)	(0.0, 2.3)	(1.3, 3.6)	(5.0, 10.8)	(6.0, 10.4)	(87, 143)	(175, 587)	(997, 1,847)
Obj. Z	17,015	17,203	17,384	18,292	18,368	36,238	77,731	254,558
Tardiness	0	107	1	508	0	17,417	59,968	235,897
Makespan	17,015	17,096	17,383	17,783	18,368	18,822	17,763	18,661

Tabelle 1: Resultate in der deterministischen Umgebung

Maschinenausfälle (9 Settings): Unter neun Maschinenausfall-Einstellungen (MB0-MB8) übertrafen die beiden ML-Ansätze alle 14 Baselines in allen Settings konsistent. IL+RL zeigte die beste Leistung in den disruptivsten Szenarien (MB1 & MB2: niedrige Verfügbarkeit, hohe Reparaturzeit), während IL in den weniger gestörten Umgebungen dominierte. Die durchschnittliche Verbesserung gegenüber der besten Heuristik (MST) betrug ca. 7%. Der statische GA-Lösungsplan war nun nur noch vergleichbar mit den besten Heuristiken, was die Notwendigkeit ereignisbasierter Neuplanung unterstreicht.

Setting	IL	IL+RL	MST	GA	EDD×SPT	IL Greedy	IL+RL Greedy	RL
MB0	0.0	1.4	6.4	15.9	249.8	–	–	–
MB1	0.4	0.0	7.0	16.9	246.3	–	–	–
MB2	1.0	0.0	7.3	18.9	245.8	11.9	3.7	158.9
MB3	0.0	0.6	7.3	6.0	238.5	–	–	–
MB4	0.0	1.3	7.1	5.7	236.6	–	–	–
MB5	0.0	0.7	7.1	6.6	233.1	–	–	–
MB6	0.0	1.0	8.1	2.5	220.4	–	–	–
MB7	0.0	1.5	8.0	2.3	219.2	–	–	–
MB8	0.0	0.9	7.9	1.9	216.9	–	–	–
Mean	0.16	0.82	7.36	8.51	234.06	11.86	3.72	158.88

Tabelle 2: Resultate unter Maschinenausfällen

Lieferantenausfälle (2 Settings): Unter Lieferantenausfällen erzielte IL+RL die beste Gesamtleistung mit einem Gap von 5,1% im Setting mit hoher Verwundbarkeit (SF0) und 6,9% im Setting mit niedriger Verwundbarkeit (SF1). Die Verbesserung gegenüber der besten nicht-ML-basierten Methode (GA) betrug jeweils ca. 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.



Setting	Metric	IL+RL	IL	GA	MTSF-MST	MST	MTSF	RL
SF0	Gap (%)	5.1	14.6	32.3	57.7	221.6	396.7	513.3
	Obj. Z	95,771	105,749	121,476	134,884	258,460	312,293	356,786
	Tardiness	12,316	17,516	16,537	53,020	0	231,404	181,335
	Makespan	18,522	18,501	18,641	18,601	18,368	18,677	18,696
	TTSF	64,932	69,732	86,297	63,262	240,092	62,212	156,755
SF1	Gap (%)	6.9	12.4	34.0	52.8	248.6	775.4	586.2
	Obj. Z	40,939	43,298	53,217	56,694	129,684	267,612	226,432
	Tardiness	2,577	3,678	3,313	21,890	0	233,385	124,915
	Makespan	18,391	18,302	18,542	18,517	18,368	18,612	18,822
	TTSF	19,971	21,318	31,363	16,287	111,316	15,615	82,695

Tabelle 3: Resultate unter Lieferantenausfällen

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 adaptive Sequenz von Heuristiken (statt einer expliziten Auftragsreihenfolge) vorschreibt. Dieses Ergebnis ist ein starkes Argument für flexible Neuplanungsmethoden in jeder Umgebung, die stochastischen Störungen ausgesetzt ist.
- Imitation Learning ermöglicht die Übertragung der Leistungsfähigkeit rechenintensiver Lösungsalgorithmen wie z.B. Metaheuristiken auf Methoden, die in Echtzeit entscheiden können. Dies ist hochrelevant für die Operations-Research-Community, da Metaheuristiken eine populäre Lösungsmethode für viele Problemklassen sind, die Rechenzeit in der Praxis aber 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 Umgebungen mit mehreren, konkurrierenden Zielmetriken sind eindimensionale Heuristiken 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

Position	Geplant (EUR)	Ist (EUR)
Personalausgaben (Beschäftigte E12-E15)	218.898,00 €	
Dienstreisen	17.100,00 €	
Sonstige Ausgaben	0,00 €	
Zwischensumme	235.998,00 €	
Projektpauschale (20%)	47.199,60 €	
Gesamt	283.197,60 €	

Für die Ist-Werte fehlen auch nach wiederholter Nachfrage leider die genauen Daten der Abteilung für die Verwaltung von Drittmitteln der Universität Mannheim. Dem Projektbearbeiter sind jedoch außer geringerer Kosten beim Posten „Dienstreisen“ keine Abweichungen bekannt. Genaue Zahlen können dem zahlenmäßigen Nachweis entnommen werden.

6 Notwendigkeit und Angemessenheit der geleisteten Projektarbeiten

Die im Rahmen des Vorhabens durchgeführten Arbeiten waren notwendig, um die in Kapitel 2 dargestellte 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 Analyse von Unüberwachtem Lernen im Supply-Chain-Management diente dem im Vorhaben explizit als Ziel ausgewiesenen Aufbau von KI-Expertise bei den Projektarbeitern.

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% bis über 500%), 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. Außerdem ermöglichte die Konzentration auf Beschaffung und Produktion eine realitätsnähere Problemmodellierung und damit einen erhöhten Mehrwert für die Industrie. Die nachgeschaltete Distribution wird in der Praxis oft ausgelagert oder anderweitig von den vorgeschalteten Problemen entkoppelt.

Der Forschungsaufenthalt an der University of Hyogo war für die realistische Modellierung von Lieferantenausfällen unerlässlich. Ohne das 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 aufwändige Generation der GA-Lösungen, die Hyperparameteroptimierung mittels 5-facher Kreuzvalidierung und das RL-Training erfordern erhebliche Rechenkapazitäten. Außerdem erlaubten die Rechenserver die Betrachtung einer hohen Anzahl verschiedener Kosten- und Unsicherheitsszenarien, was die Generalisierbarkeit der Ergebnisse sicherstellt und den Wert des Vorhabens deutlich erhöht.

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 über das konkret betrachtete Problem hinaus. Die entwickelte Methoden-Pipeline (GA als Experte, Imitation Learning für Echtzeitfähigkeit, RL-Feinabstimmung) 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 statt dem Training von Grund auf 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 „Foundations of AI: Search & Problem Solving“ und „Industrial Applications of Artificial Intelligence“ 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 Erfolgte 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

Geplante Journal-Artikel:

- Rolf, B., Bubak, A., Reggelin, T., Lang, S. und Stuckenschmidt, H.: Production scheduling under disruptions: Imitation learning and reinforcement learning for stochastic hybrid flow shops [Eingereicht und im Review-Prozess bei: 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)

**Betreute Masterarbeiten (Auswahl):**

- Data-driven production scheduling: A case study on a German logistics company (Universität Mannheim, 2022)
- Comparative Analysis of Separated and Integrated Approaches in Data-Driven Supply Chain Optimization (Universität Mannheim, 2024)
- Reinforcement Learning for the Vehicle Routing Problem (Universität Mannheim, 2024)
- Finetuning Inventory Management to Predict Optimal Safety Stock (Universität Mannheim, 2025)
- Optimizing (r, Q) Inventory Policies under Unknown, Non-Stationary Demand using Machine Learning (Universität Mannheim, 2025)
- 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: 10.1080/00207543.202