



ANWENDUNG VON DEEP REINFORCEMENT LEARNING UND GENETISCHER ALGORITHMEN ZUM LÖSEN DES FLEXIBLE JOB SHOP PROBLEMS

CLEMENS STOLLREITER (MASTERSTUDIUM INFORMATIK)

Betreuer: Prof. Dr. Kai Höfig, Prof. Dr. Markus Breunig

2019 repräsentierte die Fertigungsindustrie 16% des weltweiten und 18% des deutschen Bruttoinlandsprodukts [Wor]. Die Unternehmen arbeiten dabei in einem Umfeld, das von einem sich verschärfenden internationalen Wettbewerb gekennzeichnet ist. Um ihre Marktanteile und Gewinne langfristig halten oder sogar ausbauen zu können, werden Verbesserungen in der Effizienz daher immer wichtiger [And00] [KPM20]. Eine Möglichkeit besteht in der Optimierung von Arbeitsabläufen durch eine gezielte Produktionszeitplanung. Dies führt zu kürzeren Produktionszeiten sowie zu einer höheren Maschinenauslastung. Letztendlich verbessert sich damit nicht nur die Wirtschaftlichkeit des Unternehmens, sondern auch die Zufriedenheit der Kunden [Li16].

Die Wissenschaft beschäftigt sich im Rahmen des Flexible-Job-Shop-Problems mit der industriellen Produktionszeitplanung. Dabei wird eine endliche Menge an n Aufträgen (englisch Jobs) $J = \{J_1, J_2, \dots, J_n\}$ einer endlichen Menge an m Maschinen $M = \{M_1, M_2, \dots, M_m\}$ zur Verarbeitung zugeordnet [Gey04]. In diesem Zusammenhang ist der Arbeitsschritt (Operation) O_{ij} der j -te auszuführende Teil von Auftrag J_i . Die Arbeitsschritte eines Auftrags müssen üblicherweise in einer vordefinierten Reihenfolge durchgeführt werden [Bot17].

Zur Lösung des Flexible-Job-Shop-Problems müssen zwei Teilaspekte berücksichtigt werden:

- **Maschinenauswahl:** Auf welcher Anlage wird der Arbeitsschritt erledigt? Dabei sind Unterschiede hinsichtlich der Bearbeitungszeiten möglich.

- **Ablaufplanung:** In welcher Reihenfolge werden die Arbeitsschritte unterschiedlicher Aufträge an den Maschinen durchgeführt?

Die sich damit ergebenden Produktionszeitpläne werden normalerweise in Form von Gantt-Charts visualisiert. Abbildung 1 zeigt ein Beispiel mit sechs verschiedenen Maschinen. Die zehn unterschiedlich kolorierten Aufträge bestehen aus jeweils sechs Arbeitsschritten. Bei der gezeigten Lösung ergibt sich eine gesamte Produktionsdauer von 43 Zeiteinheiten.

Die hier vorgestellte Masterarbeit beschäftigt sich mit der Frage, wie sinnvoll Deep Reinforcement Learning in der Produktionszeitplanung eingesetzt werden kann. Ziel ist ein Deep-Reinforcement-Learning-Agent, der in den Trainingsdaten Zusammenhänge erkennt und diese danach zur Planung nutzt. Zum Vergleich der Ergebnisse dient als Standardansatz ein genetischer Algorithmus. Dabei werden zunächst möglichst unterschiedliche Zeitpläne erstellt, um sie danach durch Kombination und Modifikation zu optimieren. Darüber hinaus wird ein sehr einfacher Ansatz berücksichtigt: In jedem Planungsschritt entscheiden zwei zufällig ausgewählte Prioritätsregeln über die Maschinenzuordnung und die Arbeitsschrittsequenz.

Zur Bewertung der drei Ansätze wurden 61 Testdatensätze verwendet, die in der Forschung zum Flexible-Job-Shop-Problem weit verbreitet sind. Für jeden dieser Datensätze ist das Minimum an nötiger Produktionszeit bekannt, das bisher

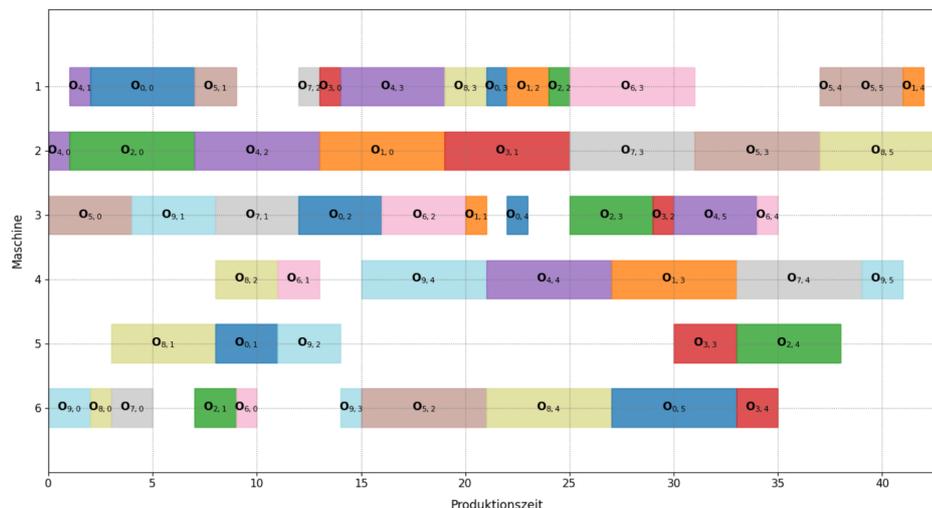


Abbildung 1 – Beispiel eines Produktionszeitplans

ROSENHEIMER INFORMATIKPREIS INF-MASTER

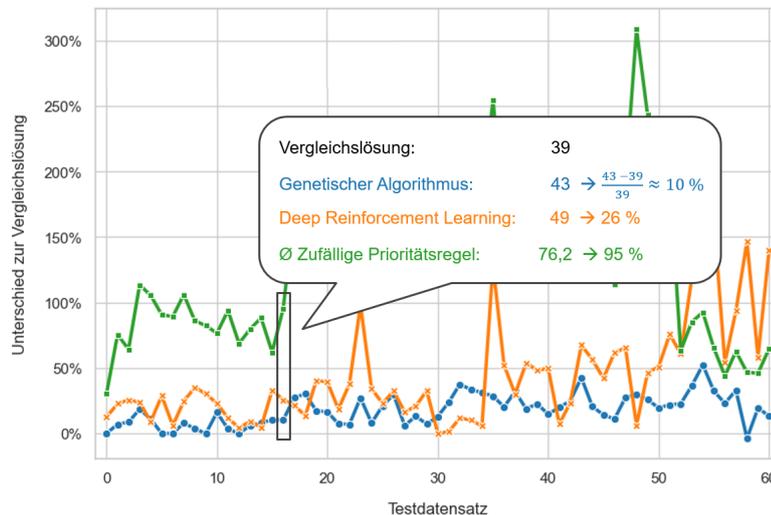


Abbildung 2 – Unterschiede der erzielten Produktionszeiten in Relation zum bisher bekannten Minimum

in der Wissenschaft erreicht werden konnte. Abbildung 2 zeigt die Resultate für alle Testdatensätze und erläutert das Ergebnis für einen bestimmten Datensatz. Dieser bildet die Grundlage für den Produktionszeitplan in Abbildung 1, welcher mit Hilfe des genetischen Algorithmus erstellt wurde. Die Güte von 10 % ist die relative Differenz zwischen dem bisher in der Wissenschaft festgestellten Minimum und der von der Methode erzielten Produktionsdauer.

Der Deep-Reinforcement-Learning-Agent erlernt tatsächlich gültige Zusammenhänge und ist für den Großteil der Datensätze in der Lage sinnvolle Entscheidungen zu treffen. Außerdem zeichnet sich der Ansatz durch sehr kurze Laufzeiten aus. Jedoch bestehen Zweifel hinsichtlich seiner Stabilität und seiner Praxistauglichkeit. So kann bereits die Grundkonfiguration zu nicht vorhersehbaren Schwankungen in der Modellqualität führen. Außerdem hat der Ansatz Probleme in Situationen mit relativ vielen verfügbaren Maschinen. Darüber hinaus handelt es sich um einen Black-Box-Ansatz. Es ist also nicht bekannt, warum der Agent jeweils zu der Entscheidung kommt und wie er auf ihm unbekannt Situationen reagiert. Im Vergleich arbeitet der genetische Algorithmus stabiler. Auch liefert er die insgesamt besseren Ergebnisse. Bei den Laufzeiten zeigt sich jedoch der Nachteil dieser Methode. Der genetische Algorithmus braucht in komplexen Fällen relativ lange, um die Produktionszeitpläne zu erstellen.

Weitere Forschung sollte sich verstärkt mit dem Praxiseinsatz beschäftigen. So ist es in der Industrie zum Beispiel üblich, dass Aufträge erst an unterschiedlichen Freigabezeitpunkten

beginnen können. Solche Informationen fehlen jedoch in den wissenschaftlichen Datensätzen. Diese sind allgemein durch eine starke Vereinfachung gekennzeichnet. Sie müssten dementsprechend angepasst werden. Des Weiteren sollten andere Zielgrößen, wie zum Beispiel das Einhalten bestimmter Lieferfristen, bei der Lösungsfindung Beachtung finden.

Quellen:

- [And00] M. M. Andreasen und L. Hein. Integrated product development. IPU, 2000
- [Bot17] G. P. Bottlik. An Introduction to the Mathematics of Planning and Scheduling. Routledge, New York, 1. Aufl., 2017.
- [Gey04] F. Geyik und I. H. Cedimoglu. The strategies and parameters of tabu search for job-shop scheduling. Journal of Intelligent Manufacturing, 15:439–448, 2004.
- [KPM20] KPMG. Fertigungsindustrie - Branchenreport aus dem Future Readiness Index 2020, 2020. Zugriff am 12.01.2022 über <https://hub.kpmg.de/future-readiness-index/fertigungsindustrie>.
- [Li16] X. Li und L. Gao. An effective hybrid genetic algorithm and tabu search for flexible job shop scheduling problem. International Journal of Production Economics, 174:93–110, 2016.
- [Wor] World Bank. Manufacturing, value added (% of GDP). Zugriff am 15.12.2021 über <https://data.worldbank.org/indicator/NV.IND.MANF.ZS>.