

Selbstoptimiertes Auftragsmanagement für autonome Transportfahrzeuge

Jie Zhang^{1*}, Xiaobo Liu-Henke¹, Thomas Vietor²

¹Institut für Mechatronik Ostfalia Hochschule für angewandte Wissenschaften, Salzdahlumer Str. 46/48, 38302 Wolfenbüttel, Deutschland; *jie.zhang@ostfalia.de

²Institut für Konstruktionstechnik, Technische Universität Braunschweig, Hermann-Blenk- Str. 42, 38108 Braunschweig, Deutschland

Abstract. Der folgende Beitrag beschreibt eine Assistenzfunktion zur Unterstützung des Auftragsmanagementsystems bei der Verwaltung der Transportaufträge (TA) auf Basis von genetischem Algorithmus (GA), so dass die TA unter Berücksichtigung von deren Priorität und vordefinierten Deadline klassifiziert und in einer bestimmten Reihenfolge zu einem neuen Auftrag Transportfahrzeug (FTF) umgruppiert werden. Das Ziel ist, die Intralogistik in der Situation von mangelnder Transportleistung mittels FTF im Vorfeld vor der Ausführung des TA zu optimieren, insbesondere die Transportverzögerung zu minimieren und damit die Pünktlichkeitsrate des Gütertransportes zu erhöhen.

Einleitung

Aufgrund des Entwicklungstrends der zukünftigen Produktion nach kundenspezifischen Anforderungen und dem Einsatz von I4.0-Lösungen zur Optimierung der Prozesse eines Produktionsunternehmens, ist die weitere Erhöhung des Automatisierungsgrades der Produktionsakteure, insbesondere Produktionsmaschine zur Produktfertigung und FTF in der Intralogistik, erforderlich, um die Flexibilität des gesamten Produktionssystems zu

gewährleisten [1, 2, 3]. Um die Ziele zu erreichen und damit die Anforderungen an die zukünftige kundenindividuelle Produktion zu erfüllen, wird an der Ostfalia ein autonomes FTF mit Mecanumrädern entwickelt, welche gegenüber des konventionellen FTF über IoT-basierte Kommunikationstechnologie mit anderen Produktionsakteuren vernetzen und anhand der ausgetauschten Informationen selbst Entscheidungen treffen ohne Eingriff von Bedienern [4].

Im vorliegenden Beitrag wird eine Assistenzfunktion auf Basis von GA zur Klassifizierung und Umgruppierung der TA konzipiert und entwickelt, welche beim autonomen Gütertransport mittels des dezentralen Auftragsmanagementsystems von FTF unterstützt. Dadurch lassen sich mehrere Ziele der Intralogistik gleichzeitig in der Situation von mangelnden Transportleistung mittels FTF optimieren.

1 Stand des Wissens

1.1 Dezentrales Auftragsmanagementsystem von autonomen FTF

Wie bereits erwähnt, um die Flexibilität und den Auto-

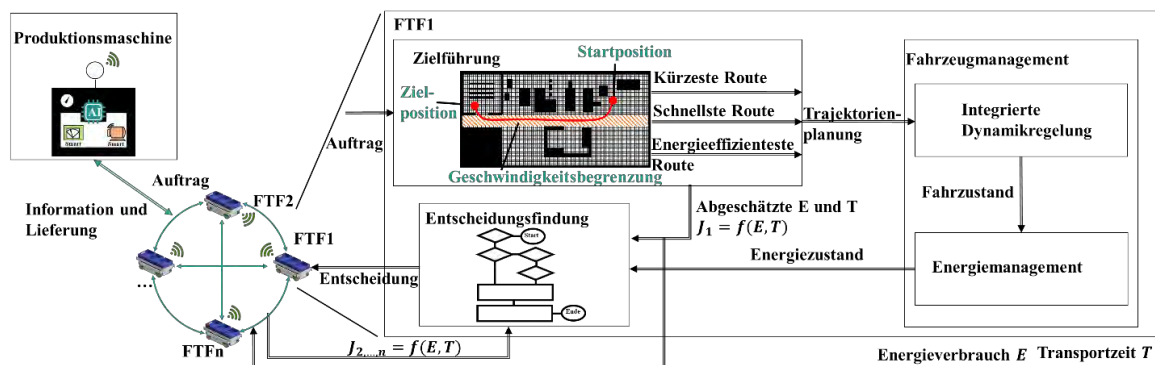


Abbildung 1: Konzept des dezentralen Auftragsmanagementsystems für autonome FTF

matisierungsgrad des FTF zu erhöhen sowie damit den autonomen Gütertransport zu realisieren, werden die Leitsteuerung der konventionellen FTF dezentralisiert [5] und die FTF mit IoT-basierter Kommunikationstechnologie, intelligenter Hard- und Software ausgebaut. An der Ostfalia werden autonome FTF entworfen und das dezentrale Auftragsmanagementsystem zur Vernetzung der FTF mit der Produktionslinie entwickelt.

Abbildung 1 stellt das Konzept des dezentralen Auftragsmanagementsystems und auch die Funktionsstruktur der autonomen FTF vor [6]. Alle Produktionsakteure, z.B. Produktionsmaschinen FTF, in einer Produktionsanlage vernetzen sich direkt miteinander mittels IoT-basierter Kommunikationstechnologie und mithilfe der eigenen Intelligenz treffen selbständig Entscheidungen zur Durchführung der Produktion und Transportabwicklung. Anhand der TA, die von den Produktionsmaschinen erstellt und anschließend über Kommunikationsmodule die FTF mitgeteilt werden, können die FTF eigenständig eine kürzeste Route zwischen der aktuellen Position und Zielposition ohne Konflikt mit den stationären Hindernissen ermittelt und dann eine Trajektorie unter Berücksichtigung des dynamischen und kinematischen Verhaltens des FTF berechnet. Mit der abgeschätzten Transportzeit und Energiekosten der TA wird die Fahrkosten J mithilfe der künstlichen Intelligenz bestimmt und die FTF konkurrieren sich miteinander, um TA zu gewinnen. Das heißt, die FTF vergleichen die Fahrkosten durch das Kommunikationsmodul miteinander zu einer gemeinsamen Entscheidungsfindung, welches FTF diesen TA übernehmen und durchführen soll. Das dezentrale Auftragsmanagement und die jeweiligen Fahrfunktionen des FTF werden modellbasiert entwickelt und deren Funktionalität in einer realitätsnahen Simulationsplattform abgesichert [7].

1.2 Genetischer Algorithmus

Genetischer Algorithmus (GA) ist in den letzten Jahrzehnten weit verbreitet zur Lösung der Optimierungsprobleme, welcher nicht-deterministische stochastische Suchmethode ist und nach der Evolutionsprinzip „Survival of the fittest“ von Charles Darwin entwickelt wird. GA generiert Populationen der Individuen und damit die gute Genfragmente mittels genetischen Evolutionsprozesses bzw. Selektion, Kreuzung und Mutation beibehalten, sodass die Lösungsqualität fortlaufend verbessert wird und es zu einer optimalen Lösung schnell konvergiert, ohne jede mögliche Lösung zu untersuchen.

Das grundlegende Konzept von GA ist, dass die Stärkeren dazu neigen, sich anzupassen und zu überleben, während die Schwächere zum Aussterben neigen. Das heißt, die Optimierung basiert auf der Evolution und dem Konzept des Überlebens der Stärkeren im iterativen Evolutionsprozess. GA hat die Fähigkeit, eine anfängliche Population realisierbarer Lösungen zu erstellen und diese dann so zu rekombinieren, dass ihre Suche nur auf die vielversprechendsten Bereiche des Lösungsraums gelenkt wird.

Abbildung 2 verdeutlicht den grundlegenden Ablauf des GA. Nachdem das zu optimierende Problem unter Berücksichtigung des Anwendungsfalls individuell kodiert wird, wird eine Population von Individuen bzw. den möglichen Lösungskandidaten des Optimierungsproblems zufällig erzeugt und initialisiert, die von der Generation 0 genannt wird. Um besser angepasste Individuen in einer neuen Generation zu erstellen, wird die Güte jedes Individuums mithilfe einer speziell für die Aufgabenstellung entworfenen Fitnessfunktion in der Anwendung bestimmt. Die Fitness eines Individuums wird als ein Maß der Fähigkeit zum Überleben und zur Produktion der Nachkommen bezeichnet. Durch die genetische Manipulation nach probabilistischen Regeln, bzw. Selektion, Kreuzung und Mutation evolviert sich die Individuen, gemessen an der Fitnessfunktion, in die nächste Generation. Der genetische Prozess wiederholt sich, bis sich ein Individuum mit den gewünschten Eigenschaften entwickelt hat oder die vordefinierte Abbruchbedingung erfüllt ist. Das Konzept und der Entwicklungsprozess der Assistenzfunktion auf Basis von GA wird in Abschnitt 3 und 4 detailliert dargestellt.

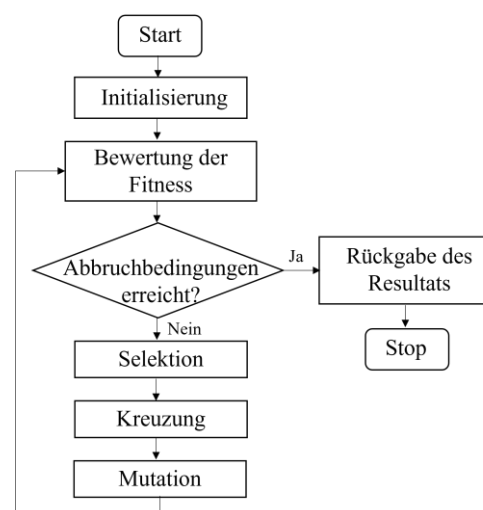


Abbildung 2: Entwicklungsablauf von GA [8]

2 Methodik

Die durchgängig modellbasierte und verifikationsorientierte Funktionsauslegung und -absicherung vernetzter mechatronischer Systeme nach [9] hat sich in zahlreichen Anwendungen in Forschung und Industrie als zeit- und kosteneffizient erwiesen.

Abbildung 3 illustriert den modellbasierten mechatronischen Entwicklungskreislauf, welcher zur Absicherung Model-in-the-Loop- (MiL-), Software-in-the-Loop- (SiL-) und Hardware-in-the-Loop- (HiL-) Simulationen sowie die Echtzeiteralisierung durch Prototypen beinhaltet. Basierend auf den Anforderungen, welche durch die systematische Betrachtung des Zusammenspiels dessen Komponenten aus verschiedenen Domänen abgeleitet und konkretisiert werden [10, 11], erfolgen bereits in frühen Entwicklungsphasen Optimierungen, Tests und Verifikationen. In MiL-Simulationen werden dabei Funktionsmodelle gegen komplexe Modelle der Umgebung, in einer realitätsnahen Simulationsumgebung getestet. Ist ein hinreichender Funktionsstand erreicht, erfolgt die automatische Generierung von C-Code, welcher in SiL-Simulationen mit Hilfe des Streckenmodells verifiziert wird. Unter Echtzeitbedingungen erfolgen schließlich weitere Optimierungen und Verifikationen mittels HiL-Simulationen unter Verwendung echtzeitfähiger Streckenmodelle, welche durch reale Komponenten ergänzt werden. Letztendlich erfolgen Feldtests unter echtzeitigen Bedingungen durch den Einsatz von Prototypen.

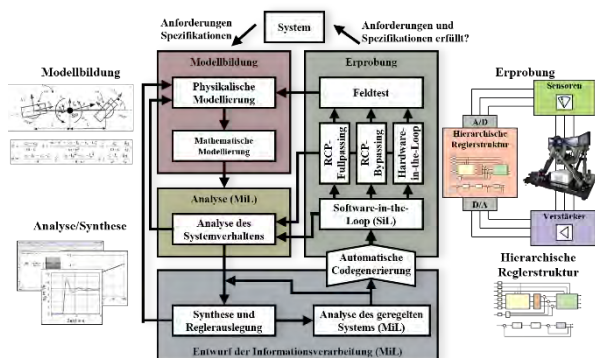


Abbildung 3: Mechatronischer Entwicklungskreislauf

Mithilfe des mechatronischen Entwicklungskreislaufes wird eine durchgängige Funktionsentwicklung und deren Integration bis zum Gesamtsystem sichergestellt. Dieser Beitrag stellt aus der Methodik schwerpunktmäßig die Entwicklung und Verifikation der Assistenzfunktion MiL-Simulation dar.

3 Konzeption der Assistenzfunktion zur Unterstützung des dezentralen Auftragsmanagementsystems

Dieser Abschnitt stellt die Anforderungen an die Assistenzfunktion zur Unterstützung des dezentralen Auftragsmanagementsystems bei der Klassifikation und Umgruppierung der TA in einer Situation von mangelnder Transportleistung vor und beschreibt das Konzept der Assistenzfunktion.

3.1 Problemstellung und Anforderungen

Die Funktionsweise des dezentralen Auftragsmanagementsystems in einer Situation von genügender Transportleistung mittels autonomen FTF, wobei FTF die TA einer Produktionsanlage termingerecht ausführen können, wird erfolgreich getestet und in [6] aufgezeigt. Aber die weiter erhöhte Nachfrage an die Transportleistung mit einer bestimmten Anzahl von FTF führt zur Verzögerung der Ausführung der TA und sogar zum Stillstand der Produktion infolge der mangelnden Materialien am Eingang der Produktionsmaschinen. Während das Problem in Mangel an Transportleistung sich durch Einsatz neuen FTF leicht überwinden lassen kann, erhöht dies jedoch die Ausrüstungsinvestitionen. Es wäre besser, dass die TA, dessen Datenstruktur wie in der Abbildung 4 dargestellt wird, vor Ausführung durch FTF unter Berücksichtigung von der Priorität und vordefinierten Deadline klassifiziert und umgruppiert werden. Damit wird die Priorität der TA nach der entsprechenden Deadline dynamisch angepasst und die Reihenfolge zur Bearbeitung der TA im Voraus optimiert. Außerdem liegen die weiteren Vorteile insbesondere darin, dass die Verzögerung des Gütertransportes reduziert und sogar vermieden ohne Einsatz von neuen FTF werden kann.

Anhand der definierten Ziele werden die folgenden wesentlichen Anforderungen mittels des modellbasierten Anforderungsmanagements anhand [11] an die Assistenzfunktion abgeleitet und definiert:

- [R1] Dynamische Anpassung der Priorität der zu bearbeitenden TA in der Wartelist.
- [R2] Festlegung einer optimalen Reihenfolge der abzuwickelnden TA
- [R3] Integration ins dezentrale Auftragsmanagementsystem.



Abbildung 4: Datenstruktur eines TA

3.2 Entwurf der Assistenzfunktion

Nach dem Informationsfluss des dezentralen Auftragsmanagementsystems und der definierten Anforderungen werden für die Assistenzfunktion die folgenden Funktionsmodule konzipiert, deren Entwicklungsprozess im Abschnitt 4 detailliert wird:

- [F1] Dynamische Anpassung der Priorität von TA: da in der Situation mit mangelnder Transportleistung die TA nicht zeitnahe bearbeitet werden kann und damit es zu einer großen Ansammlung von TA infolge Blockaden führt, soll die Priorität der TA dynamisch über die Zeit angepasst und dann die TA mit gleicher Priorität in einer Gruppe zusammengesammelt werden. Hierdurch werden die TA mit hoher Priorität vorrangig ausgeführt und somit lässt sich die Verzögerung des Gütertransportes minimieren. Die neu priorisierten TA werden in einer Wartelist gesammelt und stellen als Eingangsdaten für Klassifizierung und Umgruppierung zur Verfügung.
- [F2] Klassifikation und Umgruppierung der TA: die TA in einer Gruppe sollen anhand der Auftragsinformationen z.B. die Abhol- und Abgabestation klassifiziert und sich miteinander in einer bestimmten Reihenfolge als einen neuen TA für FTF verknüpfen, sodass die Umwege des FTF aufgrund der unterschiedlichen Abhol- und Abgabestationen von TA minimiert und die Intransitzeit sowie der Produktionsprozess beschleunigt werden kann.

4 Entwicklung der Assistenzfunktion mittels GA

Die im Abschnitt 3 konzipierte Assistenzfunktion soll modellbasiert entwickelt werden, deren Entwicklungsprozess wie im Folgenden detailliert beschrieben wird.

4.1 Initialisierung und Kodierung

Um das Optimierungsproblem mittels GA zu lösen bzw. die optimale Klassifizierung und Umgruppierung der TA zu ermöglichen, wird das Optimierungsproblem zuerst kodiert. Entlehnt von der Genetik wird folgendes

Vokabular spezielle für dies Optimierungsproblem definiert und initialisiert:

- Individuum S : Jedes Individuum wird als eine mögliche Lösung des Optimierungsproblems bzw. eine optimale Umgruppierung der TA für FTF in einer bestimmten Reihenfolge bezeichnet.
- Länge eines Individuums n : Hierbei bezieht sich die Länge n auf die Anzahl der zu bearbeitenden TA.
- Gen: Eine bestimmte Stelle bzw. Sequenz eines Chromosoms wird als Gen bezeichnet. Unter Berücksichtigung der Datenstruktur eines TA wird in diesem Beitrag das TA-ID als Gen verwendet.
- Population i und Generation t : Eine Menge von Individuen, die in einem bestimmten Evolutionsprozess entstehen, wird als eine Population und die Population als Generation bezeichnet.

Durch Zuweisung der entsprechenden Werten zu Genen eines Individuums wird das Optimierungsproblem kodiert. Die Abbildung 5 stellt ein kodiertes Individuum S_i^t in einer Generation t vor, welches als eine Reihe des ID von n TA in bestimmter Reihenfolge dargestellt wird.



Abbildung 5: Kodierung des Optimierungsproblems

4.2 Fitnessfunktion und Abbruchbedingung

Durch die Fitnessfunktion wird die Güte eines Individuums bezüglich der zu optimierenden Aufgabe bewertet und quantifiziert. Zur Festlegung der optimalen Reihenfolge von TA werden die folgenden Zielkriterien mit entsprechenden Kennwerten definiert, durch welche die möglichen Lösungen bzw. die Individuen S_i^t einer Generation quantitativ bewertet:

- Transportzeit $t(S_i^t)$ von FTF zur Ausführung S_i^t
- gesamte Länge der Fahrwege $l(S_i^t)$ von FTF zur Ausführung S_i^t
- Pünktlichkeitsrate des Gütertransportes $u(S_i^t)$

$$u(S_i^t) = \frac{n_p(S_i^t)}{n_{all}(S_i^t)} \quad (1)$$

n_p : Anzahl der pünktlich ausgeführten TA

n_{all} : Anzahl der gesamten originalen TA

- gesamte Verzögerungszeit des Gütertransportes t_{gvz} :

$$t_{gvz}(S_i^t) = \sum_{j=1}^{n_{all}-n_p} t_{vz}(S_i^t) \quad (2)$$

Weil die Zielkriterien unterschiedlich skaliert werden, sollen die Kennwerte der entsprechenden Zielkriterien mit einer geeigneten Skalierung normiert werden und somit die können miteinander verglichen werden. Deren Normierung wird, beispielsweise für den Kennwert Transportzeit $t(S_i^t)$, wie folgend aufgezeigt:

$$t_\alpha = \frac{t_{max} - t(S_i^t)}{t_{max} - t_{min}} \quad (3)$$

$$t_{max} = \max(t(S_1^t), t(S_2^t), \dots, t(S_n^t))$$

$$t_{min} = \min(t(S_1^t), t(S_2^t), \dots, t(S_n^t))$$

Um die erwähnten Zielkriterien gleichzeitig zu optimieren, wird die folgende Fitnessfunktion $F(S_i^t)$ für jeweiliges Individuum S_i^t formuliert, bei der die Gewichtungsfaktoren bzw. a, b, c und d für unterschiedene Zielkriterien unter Berücksichtigung von dem Anwendungsfall individuell ermittelt wird:

$$F(S_i^t) = a \cdot t_\alpha + b \cdot l_\alpha + c \cdot u_\alpha + d \cdot t_{gvz_\alpha} \quad (4)$$

Wie bereits erwähnt, wiederholt sich der iterative Verlauf des GA, bis sich ein Individuum mit den gewünschten Eigenschaften entwickelt hat oder die vordefinierte Abbruchbedingung erfüllt ist. Zur Begrenzung der Rechenkosten wird hierbei die Abbruchbedingung verwendet. D.h., die Iterationsschleife bricht ab, wenn sie eine vorgegebene Anzahl der Generation erreicht.

4.3 Selektion, Kreuzung und Mutation

Nach dem GA entwickeln sich die neuen Individuen (Kinder) in der Generation $t + 1$ von den Individuen (Eltern) in der vorherigen Generation t . Um die Gesamtfitness der Population ständig zu verbessern, werden anhand genetischer Manipulation nach probabilistischen Regeln die besten Individuen in der Population mithilfe der Selektion während des iterativen Verlaufs behalten und die schwachen Individuen mit niedriger Fitness verworfen. D.h., die Individuen mit größerer Fitness haben höhere Wahrscheinlichkeit zur Rekombination der neuen Individuen. In diesem Beitrag wird die fitnessproportionale Selektionsmethode durch Wettkampfselektion durchgeführt, um die Vielfalt der Individuen einer Generation zu gewährleisten und die vorzeitige Konvergenz in der frühen Phase des GA zu vermeiden. Nach der Wettkampfselektion werden n Individuen zufällig aus der Generation als eine kleine Gruppe ausgewählt und jedes Individuum hat die gleiche Wahrscheinlichkeit zur Rekombination. Anschließend wird das Individuum mit der höchsten Fitness von der Gruppe zu Rekombination als Eltern-Individuum bestimmt.

Dieser Vorgang wird fortgesetzt, bis die erforderliche Anzahl der Individuen als Eltern erreichen.

Durch Kreuzung (Abbildung 6) werden zwei neue Individuen S_i^{t+1} und S_j^{t+1} in Generation $t + 1$ aus zwei ausgewählten Individuen S_i^t und S_j^t der Generation t durch Austausch der Gene erzeugt. Die Eltern-Individuen werden zufällig ausgewählt, was durch die Kreuzungsrate P_c repräsentiert. In dieser Arbeit wird die sogenannte Zwei-Punkt-Kreuzung-Methode verwendet. Hierbei werden die beiden Positionen für Kreuzung zufällig ermittelt und dann die ausgewählte Genfragmente der Eltern-Individuen miteinander ausgetauscht, sodass die beiden Kinder-Individuen sich generieren.




Abbildung 6: Zwei-Punkt-Kreuzung

Durch Mutation wird die zusätzliche Variabilität von Individuen in einer Generation initiiert, was durch die passende Einstellung der Mutationsrate P_m erfolgt. In Analogie zu der Genetik, da die Mutation in der Natur sehr selten passiert, soll die Mutationsrate gegenüber der Kreuzungsrate einen kleineren Wert genommen werden. Abbildung 7. stellt die in diesem Beitrag genutzte Mutationsoperation dar, wobei ein neues Individuum $S_{i_new}^{t+1}$ durch Umkehrung der Gene eines zufällig ausgewählten Mutationsbereiches auf Individuum S_i^{t+1} erstellt wird.




Abbildung 7: Mutationsoperation

4.4 Elitismus Strategie

Im GA ersetzen die Nachkommen der neuen Generation $t + 1$ nach dem genetischen Evolutionsprozess die gesamte Population der vorherigen Generation t . Aber es ergibt sich jedoch die Gefahr, dass die besten Individuen durch zufällige Kreuzung und Mutation sich ver-

lieren, was zur Verschlechterung der Individuenqualität und Verlangsamung der Konvergenz des Optimierungsproblems führt. Um das erwähnte Risiko zu vermeiden, wird die sogenannte Elitismus-Strategie in den genetischen Entwicklungsprozess eingesetzt, wobei die schlechtesten Nachkommen mit kleinster Fitness der aktuellen Generation durch die besten Individuen mit größter Fitness der vorherigen Generation ersetzt werden sollen, wie in der Abbildung 8 veranschaulicht [12].

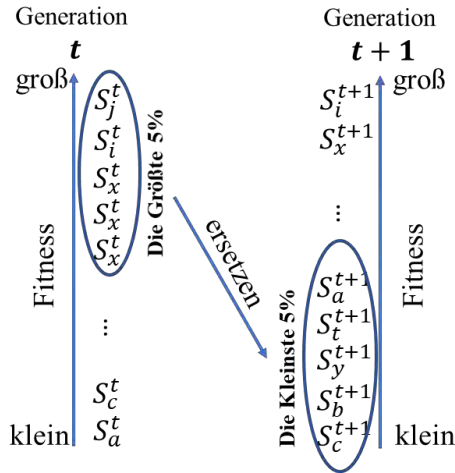


Abbildung 8: Elitismus Strategie

4.5 Dynamische Kreuzung- und Mutationsrate

Aufgrund der Konvergenz von GA und der eingesetzten Elitismus-Strategie verliert sich die Population die Diversität der Individuen während des iterativen Evolutionsprozesses insbesondere in dessen späten Phase [13]. Um die Diversität der Individuen in der späten Phase des Evolutionsprozesses zu behalten und die Gefahr der Konvergenz zu einem lokalen Optimum, sollen die Kreuzung- und Mutationsrate bzw. P_c und P_m sich im Zug des Evolutionsprozesses dynamisch anpassen [14]. Falls der prozentuale Anteil der Individuen mit höherer Fitness bzw. f_{cur} den vordefinierten Schwellenwert f_w überschreitet, vergrößern sich die Kreuzung- und Mutationsrate, um die Diversität der Individuen zu erhöhen:

$$P_c = \begin{cases} P_c^1, & f_{cur} < f_w, P_c^1 < P_c^2 \\ P_c^2, & f_{cur} \geq f_w \end{cases} \quad (5)$$

$$P_m = \begin{cases} P_m^1, & f_{cur} < f_w, P_m^1 < P_m^2 \\ P_m^2, & f_{cur} \geq f_w \end{cases} \quad (6)$$

5 Funktionsabsicherung mittels MiL-Simulation

Anhand des mechatronischen Entwicklungsprozesses wird die entwickelte Assistenzfunktion mit einem Test-szenario mittels MiL-Simulation abgesichert und demonstriert.

5.1 Szenariobeschreibung

Zur realitätsnahen Entwicklung und vor allem Erprobung der beschriebenen Funktionalitäten eines einzelnen FTF, der IoT-basierten Kommunikation in Produktionsanlage sowie der selbstoptimierten Intralogistik und Produktionsplanung wird ein cyber-physisches Industrie-4.0-Labortestfeld an der Ostfalia konzipiert und entwickelt, welche Untersuchungen in einer realen Umgebung unter Echtzeitbedingungen ermöglicht. Abbildung 9 stellt die Konfiguration des Testfeldes dar, wobei eine Produktionsanlage mit drei Produktionsmaschinen, einem Lager, einem Warenausgang und vier autonomen FTF simuliert wird.

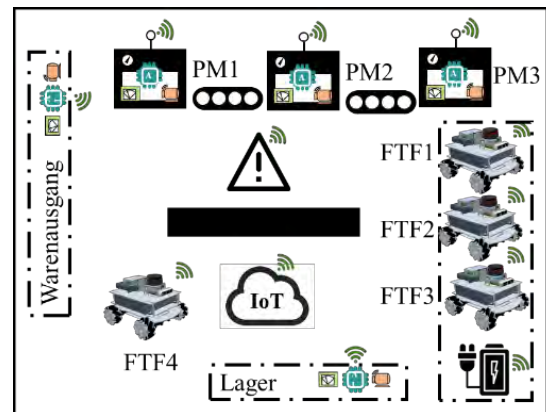


Abbildung 9: Cyber-physisches Industrie-4.0-Labortestfeld

Zur experimentellen Überprüfung der Funktionalität der entwickelten Assistenzfunktion werden 40 TA anhand der Konfiguration des Labortestfeldes zufällig generiert. Ausgehend von den TA werden die Transportzeit und die Länge des Fahrweges von jeweiligem TA mittels der entwickelten intelligenten Fahrfunktionen bzw. Zielführung und konfliktfreien Trajektorienplanung berechnet [6]. Aufbauend auf die Transportzeit und vordefinierte Deadline des TA können die Pünktlichkeit des Gütertransportes überprüft und die verzögerte Transportzeit bestimmt werden.

5.2 Simulationsergebnisse

Die Assistenzfunktion wird nach der Szenariobeschreibung mittels CAE-Werkzeug Matlab/Simulink durchgeführt. Die Simulationsergebnisse werden durch die folgenden Abbildungen veranschaulicht.

Abbildung 10 zeigt die Umgruppierung der TA als die endgültige Lösung des Optimierungsproblems für vier FTF auf, die durch das Gantt-Diagramm visualisiert wird. Bei entsprechender Gruppe verbinden sich die originalen TA miteinander in einer bestimmten Reihenfolge. Die Ziffer auf jeweiligem Balken bezieht sich auf den ID des originalen TA und die Länge des Balkens repräsentiert die Größe der Transportzeit.




Abbildung 10: Gantt-Diagramm der neu umgruppierten TA

Die folgenden vier Abbildungen stellen die Konvergenzdiagramme der entsprechenden Zielkriterien bzw. Länge der Fahrwege l , Transportzeit t , Pünktlichkeitsrate u und Verzögerungszeit des Gütertransportes t_{gvz} bis zu 200 Generationen dar, wobei die Konvergenztendenz im Zug des Evolutionsprozesses von GA verdeutlicht. Die Schwankungen, die in den Abbildungen darunter erscheinen, sind auf die Tatsache zurückzuführen, dass das GA mehrere Ziele gleichzeitig optimiert. Aber solche Ziele können in Konflikte zueinander stehen und ein Kompromiss untereinander muss getroffen werden, sodass die Schwankungen unvermeidlich sind.




Abbildung 11: Konvergenzdiagramm für das Ziel zur Optimierung des Fahrweges

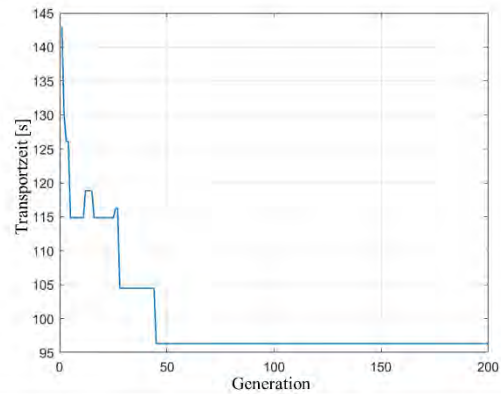


Abbildung 12: Konvergenzdiagramm für das Ziel zur Optimierung der Transportzeit




Abbildung 13: Konvergenzdiagramm für das Ziel zur Optimierung der Pünktlichkeitsrate

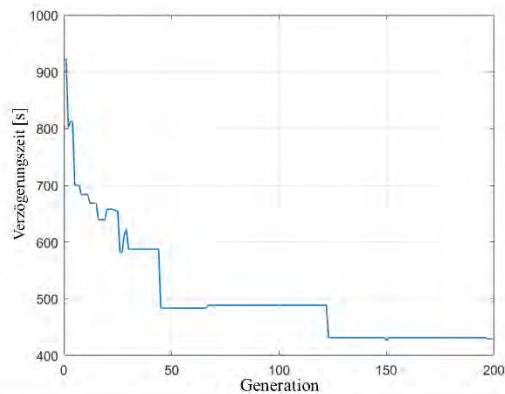


Abbildung 14: Konvergenzdiagramm für das Ziel zur Optimierung der Verzögerungszeit

6 Zusammenfassung und Ausblick

Im vorliegenden Beitrag wird die Assistenzfunktion mittels GA zur Klassifikation und Umgruppierung der

TA konzipiert und entwickelt, sodass die Multi-Ziele insbesondere Erhöhung der Pünktlichkeit und Minimierung der Verzögerung des Gütertransportes in einer Situation von mangelnder Transportleistung gleichzeitig optimiert werden können. Gegenüber des konventionellen GA, um die Konvergenz zu der globaloptimalen Lösung zu beschleunigen und die vorzeitige Konvergenz zu einer lokaloptimalen Lösung zu vermeiden, werden die Optimierungsansätze bzw. Elitismus-Strategie und adaptiv anpassende Kreuzung- und Mutationsrate eingesetzt. Mithilfe des Test szenarios wird die Funktionalität der Assistenzfunktion in der Simulationsumgebung validiert und demonstriert.

In den nächsten Schritten soll die Assistenzfunktion weiter optimiert und entwickelt werden. Obwohl die möglichen Konflikte zwischen FTF während des Gütertransportes mithilfe der Fahrfunktion Trajektorienplanung gelöst werden, sind die Rechenkosten von FTF ziemlich hoch [7]. Es wäre besser, solche möglichen Konflikte könnten auch in der Umgruppierung der TA im Vorfeld identifiziert und ggf. gelöst werden. Außerdem soll die unter Echtzeitbedingungen mittels HiL-Simulation erprobt und optimiert.

Danksagung

Dieser Beitrag wurde im Rahmen des Forschungsprojektes SMILE (*Simulationsbasierte Methodik zur Integration verteilter IoT-basierter, smarterer Systeme mit dezentraler Intelligenz im lokalen Energienetz*) durch den Europäischen Fonds für regionale Entwicklung (EFRE) unter dem Förderkennzeichen ZW 6-85037374 gefördert. Die Verantwortung für den Inhalt liegt bei den Autoren.



Literatur

- [1] Matt DT, Modrák V, Zsifkovits H. *Industry 4.0 for SMEs: Challenges, Opportunities and Requirements*. Palgrave Macmillan, 2020, ISBN 978-3-030-25424-7.
- [2] VDI-Handbuch Technische Logistik, Band 2. *Automated Guided Vehicle Systems (AGVS)*. VDI 2510, Beuth Verlag, Düsseldorf, 2005.
- [3] Sundermeier J, Gehlhoff F, Fay A. *Development of a Simulation Model to Analyze the Performance of Decentral Rescheduling Algorithms in Production Systems*. SNE Simulation Notes Europe 30(1), Mar. 2020, pp. 15-22, doi: 10.11128/sne.30.tn.10504.
- [4] Liu-Henke X, Yarom OA, Göllner M. *Concept for the simulation-based description of intelligent mechatronic components and their networking in an Industry 4.0 (I4.0) production line*. The International Congress and Exhibition on Industrial and Manufacturing Engineering (ICEIME), Prague, Czech Republic, Aug. 2019.
- [5] Munkelt T, Krockert M. *An Approach to a Self-organizing Production in Comparison to a Centrally Planned Production*. SNE Simulation Notes Europe 30(1), Mar. 2020, pp. 23-30, doi: 10.11128/sne.30.tn.10504.
- [6] Zhang J, Yarom OA, Liu-Henke X. *Decentralized, Self-optimized Order-acceptance Decision of Autonomous Guided Vehicles in an IoT-based Production Facility*. International Journal of Mechanical Engineering and Robotics Research, vol. 10, no.1, pp. 1-6, 2021.
- [7] Liu-Henke X et al. *Cyber-physical Industry 4.0 laboratory test field to simulate self-optimizing intralogistics*. The 19th International Conference on Mechatronics – Mechatronika (ME), pp.1-6, Dec. 2020.
- [8] Mousavi M, Yap HJ, Musa SN, Tahriri F, Dawal SZMd. *Multi-objective AGV scheduling in an FMS using a hybrid of genetic algorithm and particle swarm optimization*. PLoS ONE 12(3): e0169817. <https://doi.org/10.1371/journal.pone.0169817>.
- [9] Liu-Henke X, Jacobitz S, Scherler S, Göllner M, Yarom OA, Zhang J. *A Holistic Methodology for Model-Based Design of Mechatronic Systems in Digitized and Connected System Environments*. The 16th International Conference on Software Technologies (ICSOFT), Online, July 6-8, 2021.
- [10] Inkermann D, Huth T, Vietor T, Grewe A, Knieke C, Rausch A. *Model-Based Requirement Engineering to Support Development of Complex Systems*. Procedia CIRP, 84, pp 239-244, 2019 doi: 10.1016/j.procir.2019.04.345
- [11] Yarom OA, Zhang J, Raulf C, Liu-Henke X, Vietor T. *Anforderungsmanagement für die modellbasierte Entwicklung mechatronischer Systeme im digitalisierten und vernetzten Umfeld*. 25. Symposium Simulationstechnik ASIM 2020, virtuelle Tagung, October 14 – 15 2020, pp 213-220, doi:10.11128/arep.59.a59029
- [12] Sun MH, Cui HT, Wen WD. *Topology optimization of continuum structure under multiple constraints using genetic algorithm with elitist strategy*. Journal of Aerospace Power, 2016, vol. 21 No. 4, pp. 732-737.
- [13] Chen P. *An improved genetic algorithm for solving the Traveling Salesman Problem*. 2013 Ninth International Conference on Natural Computation (ICNC), 2013, pp. 397-401, doi: 10.1109/ICNC.2013.6818008.
- [14] Cao K, Chen G, Jiang H, Ma H. *Guided self-adaptive evolutionary genetic algorithm*. Journal of Electronics & Information Technology, 2014, vol. 36(8), pp. 1884–1890, doi: 10.3724/SP.J.1146.2013.01446.