

**Simulationsbasierte Generierung von  
Situation/Maßnahmen Zuordnungen unter  
subjektiver Berücksichtigung möglicher Zukünfte  
und aktuellem Systemzustand im Kontext einer  
situationsbasierten Steuerung von logistischen  
Systemen**

Dissertation  
zur Erlangung der Würde eines  
Doktors der Wirtschaftswissenschaften  
(Dr. rer. pol.)  
der Universität Paderborn

vorgelegt von  
M.Sc. Alexander Klaas  
geboren am 15.04.1984 in Vechta

Paderborn, Juni 2014

Dekan: Prof. Dr. Martin Schneider  
Referent: Prof. Dr.-Ing. habil. Wilhelm Dangelmaier  
Korreferent: Prof. Dr. Leena Suhl



# Inhaltsverzeichnis

<b>Abbildungsverzeichnis</b>	<b>v</b>
<b>Tabellenverzeichnis</b>	<b>vii</b>
<b>1. Einleitung</b>	<b>1</b>
<b>2. Problemstellung</b>	<b>5</b>
2.1. Betrachtungsgegenstand . . . . .	5
2.2. Fortlaufende Evaluierung der Relevanz der erzeugten Situationen . . . . .	9
2.3. Simulationsmodellbasierte Generierung von Situationen . . . . .	11
2.3.1. Definition von Systemparametern als Input . . . . .	12
2.3.2. Definition von Situationen als Output . . . . .	12
2.4. Evaluierung von alternativen Maßnahmen in einer Situation . . . . .	13
2.4.1. Zukunftsgenerierung aufgrund von alternativen Maßnahmen und Unsicherheiten . . . . .	14
2.4.2. Bewertung der alternativen Maßnahmen . . . . .	15
2.5. Anpassung der Zuordnungen bei festgestellter oder antizipierter Irrelevanz	16
2.5.1. Prognose der Systemparameter auf Basis des bisherigen Verlaufes .	18
2.5.2. Vorausschauende Gegenmaßnahmen nach Registrierung von Ereignissen im System . . . . .	19
2.5.3. Automatisiertes Neugenerieren und Löschen von Zuordnungen . . . .	19
2.6. Effizienzsteigerung der erzeugten Situation/Maßnahme Zuordnungen . . . .	21
2.6.1. Minimierung der Anzahl der Zuordnungen bei gleichbleibender Er- gebnisqualität . . . . .	21
2.6.2. Darstellung der Zuordnungen als Hypothese überwachter Lernverfahren	21
<b>3. Stand der Technik</b>	<b>23</b>
3.1. Fortlaufende Evaluierung der Relevanz der erzeugten Situationen . . . . .	23
3.2. Simulationsmodellbasierte Generierung von Situationen . . . . .	27
3.3. Simulative Vorausschau zur Evaluierung von Alternativen . . . . .	34
3.4. Anpassung der Zuordnungen . . . . .	37
3.5. Effizienzsteigerung einer Menge von Situation/Maßnahme Zuordnungen . .	41
<b>4. Zu leistende Arbeit</b>	<b>43</b>
<b>5. Konzeption</b>	<b>45</b>
5.1. Fortlaufende Evaluierung der Relevanz von Situationen . . . . .	46

5.2.	Simulation zur Generierung der Situationen . . . . .	51
5.2.1.	Definition von Systemparametern als Input . . . . .	51
5.2.2.	Definition von Situationen als Output . . . . .	52
5.2.3.	Simulationsaufbau . . . . .	55
5.3.	Simulative Vorausschau zur Evaluierung von Alternativen . . . . .	56
5.3.1.	Zukunftsgenerierung aufgrund von alternativen Maßnahmen und Unsicherheiten . . . . .	56
5.3.2.	Bewertung der alternativen Maßnahmen . . . . .	60
5.4.	Anpassung der erzeugten Zuordnungen bei festgestellter Irrelevanz . . . . .	70
5.4.1.	Prognose für die Systemparameter auf Basis des bisherigen Verlaufs	70
5.4.2.	Prognose aufgrund von registrierten Ereignissen . . . . .	72
5.4.3.	Neugenerieren von Zuordnungen . . . . .	73
5.5.	Effizienzsteigerung einer Menge von Situation/Maßnahme Zuordnungen . .	77
5.5.1.	Minimierung der Anzahl der Zuordnungen bei gleichbleibender Er- gebnisqualität . . . . .	77
5.5.2.	Darstellung der Zuordnungen als Hypothese überwachter Lernverfahren	78
5.6.	Notwendige Schritte zur Adaption des Verfahrens für ein konkretes System	79
<b>6.</b>	<b>Validierung</b>	<b>81</b>
6.1.	Konkreter Anwendungsfall: Automatisches Material Handling System . . .	81
6.2.	Umsetzung des Verfahrens . . . . .	83
6.2.1.	Maßnahmen . . . . .	83
6.2.2.	Situationsdefinition . . . . .	86
6.2.3.	Systemparameter . . . . .	87
6.2.4.	Bewertung der Maßnahmen . . . . .	88
6.2.5.	Simulationsmodell . . . . .	95
6.3.	Evaluierung . . . . .	98
6.3.1.	Evaluierung des angewendeten Konzeptes unter konstanten System- parametern . . . . .	99
6.3.1.1.	Leistungskennzahlen bei Anwendung des Konzeptes . . . . .	101
6.3.1.2.	Untersuchung des Betriebsablaufes bei Anwendung des Konzeptes . . . . .	102
6.3.1.3.	Detaillierte Evaluierung . . . . .	115
6.3.2.	Evaluierung einzelner Komponenten . . . . .	121
6.3.2.1.	Evaluierung der Bewertung der Maßnahmen . . . . .	121
6.3.2.2.	Evaluierung der Situationsdefinition . . . . .	123
6.3.2.3.	Evaluierung der Effizienzsteigerung . . . . .	128
6.3.3.	Evaluierung des angewendeten Konzeptes unter veränderlichen Sy- stemparametern . . . . .	129
6.3.4.	Abschließende Überlegungen . . . . .	132
<b>7.</b>	<b>Zusammenfassung und Ausblick</b>	<b>135</b>
	<b>Literaturverzeichnis</b>	<b>137</b>

**A. Definitionen**

**143**



# Abbildungsverzeichnis

2.1.	Schematische Darstellung eines Einlagervorganges des MHS . . . . .	6
2.2.	Partitionierung des Verfahrens in Teilkomponenten, die in den angegebenen Kapiteln definiert werden. . . . .	8
2.3.	Die Evaluierung der Relevanz der erzeugten Zuordnungen in der Übersicht	9
2.4.	Die simulationsmodellbasierte Generierung von Situationen in der Übersicht	11
2.5.	Die Zukunftsgenerierung und Bewertung alternativer Maßnahmen in der Simulation in der Übersicht . . . . .	13
2.6.	Die Prognose und Anpassung der Zuordnungen in der Übersicht . . . . .	17
3.1.	Darstellung des allgemeinen Organic Computing Frameworks . . . . .	28
3.2.	Darstellung des Operator-Controller-Moduls . . . . .	29
3.3.	Darstellung des Jägerszenarios zur Validierung des anytime learning . . . .	32
3.4.	Eine Anweisung, um zu einer Anwendung die Klasse von Prognoseverfahren zu identifizieren . . . . .	39
3.5.	Befragung von Prognostikern zum verwendeten Verfahren . . . . .	40
5.1.	Übersicht der einzelnen Komponenten des Verfahrens . . . . .	46
5.2.	Skizze des Zustandsraumgraphen . . . . .	57
5.3.	Skizze des Zustandsraumgraphen bei Anwendung der Maßnahme $m_1$ mit Berücksichtigung von Unsicherheiten . . . . .	59
5.4.	Statischer Zeithorizont . . . . .	61
5.5.	Situationsabhängiger Zeithorizont . . . . .	61
5.6.	Dynamischer Zeithorizont . . . . .	61
5.7.	Skizze der Maßnahmenteilbäume bei rekursiver Anwendung des Verfahrens mit resultierenden Zielknoten mit positiven Eintrittswahrscheinlichkeiten .	65
5.8.	Drei Fälle für einen Systemparameterverlauf kurz nach Eintritt eines Ereignisses $e$ . . . . .	73
5.9.	Eine Kollision . . . . .	75
5.10.	Streuung der zur Neugenerierung verwendeten Systemparameterausprägung anhand der Prognosewerte (linearer Verlauf) . . . . .	77
5.11.	Skizze der Überdeckung der Kugeln um Situationen . . . . .	78
6.1.	Status der Übergabekabinen bei Einlagervorgängen . . . . .	83
6.2.	Im Statusdiagramm von Aufzügen beobachtetes Optimierungspotenzial durch Prefetching . . . . .	84
6.3.	Die verschiedenen Stellplatzbereiche . . . . .	85
6.4.	Ausschnitt des Zustandsraumgraphen . . . . .	90

---

6.5. Rekursive Bewertung der Maßnahmen unter Berücksichtigung des Ereignisses um 14:00 und den Pruning Methoden . . . . .	94
6.6. Visualisierung des MHS mit Diagrammen . . . . .	97
6.7. 3D Modell des MHS in der Simulationssoftware d <sup>3</sup> fact in Kombination mit der Visualisierungssoftware PadRend . . . . .	98
6.8. Tageskurve des eingehenden und ausgehenden Materials . . . . .	100
6.9. Bestbewertete Abfolge von Maßnahmen . . . . .	100
6.10. Durchschnittliche Wartezeiten für ein- und ausgehendes Material . . . . .	101
6.11. Darstellung des MHS nach jeder Stunde . . . . .	114
6.12. Kumulierte Wartezeiten ein- und ausgehender Aufträge summiert pro Stunde im Tagesverlauf . . . . .	116
6.13. Status der Übergabekabinen bei Anwendung des Maßnahmenpfades . . . . .	120
6.14. Status der Übergabekabinen in Zeiten hoher Last . . . . .	120
6.15. Betrachtete Knoten bei Berücksichtigung des Ereignisses und Bewertung mittels Aggregation . . . . .	123
6.16. Ausschnitt der resultierenden Trainingsbeispielen im ARFF Dateiformat . . . . .	124
6.17. Screenshot des Tools zum Test der Situationsdefinition . . . . .	126
6.18. Oberfläche der Random Forest Komponente . . . . .	126
6.19. Screenshot der Visualisierung der Trainingsdatenmenge in Weka . . . . .	129
6.20. Durchschnittliche Wartezeiten zu verschiedenen Tageskurven . . . . .	132
6.21. Prognoseergebnis der Exponentiellen Glättung 1. und 2. Ordnung . . . . .	133
6.22. Kumulierte Wartezeiten ein- und ausgehender Aufträge summiert pro Stunde im Tagesverlauf bei Betrieb im Energiesparmodus . . . . .	134



# Tabellenverzeichnis

3.1. Beispiel der Bewertung von Maßnahmen nach dem $\mu - \rho$ -Prinzip . . . . .	37
6.1. Definition des Maßnahmenkatalogs durch Kombination von alternativen Strategien . . . . .	86
6.2. Beispiel einer Situation . . . . .	87
6.3. Erwartete Anzahl an eingehendem und ausgehendem Material pro Stunde .	99
6.4. Gemessene Anzahl an Shuffle- und Umlagervorgängen pro Stunde . . . . .	117
6.5. Wartezeiten pro Stunde, nach Ein- und Auslagerungen aufgeschlüsselt . . .	118
6.6. Berechnung der Aggregation mittels des Kriteriums von Hodges-Lehmann	122
6.7. Gemessener Raw Score des Random Forest Verfahrens . . . . .	127



# 1. Einleitung

Ein automatisches Lager (Oberbegriff Material Handling System - MHS) ist ein System mit fördertechnischen Einrichtungen, die Material aufnehmen und automatisch zu einem Lagerfach (Stellplatz) transportieren, um es dort einzulagern und es bei Bedarf wieder auszulagern. Die Steuerung eines MHS hat die Aufgabe, anstehende Ein- und Auslagerungsaufträge möglichst schnell zu erfüllen und koordiniert dazu die Fördereinheiten. Es sollen online, d. h. ohne vorherige Kenntnis der Aufträge, Entscheidungen wie etwa die Auswahl des Stellplatzes bei Einlagerungen getroffen werden. Diese Entscheidungen hängen teilweise voneinander ab (z. B. ist ein ausgewählter Stellplatz für zukünftige Einlagerungen belegt) und es existieren zahlreiche Handlungsalternativen. Zusätzlich erschwerend sind die Notwendigkeit, das System in Echtzeit zu steuern sowie die Tatsache, dass externe Einflüsse, in diesem Fall die Aufträge, Eingabegrößen darstellen.

Ein MHS stellt ein Beispiel eines logistischen Systems dar. Dabei lässt sich nach exakten und heuristischen Steuerungsverfahren unterscheiden. Exakte Verfahren basieren auf mathematischen Modellen des Problems und können für diese optimale Lösungen berechnen [Zim05]. Allerdings sind die Probleme typischerweise  $\mathcal{NP}$ -schwer, sodass die Rechenzeit für Anwendungen wie das MHS zu hoch für einen praktischen Einsatz ist. Im Gegensatz zu exakten Verfahren verwenden heuristische Verfahren kein mathematisches Modell und basieren auf Schätzungen. Wegen ihrer geringen Rechenzeit finden heuristische Verfahren zur Steuerung von logistischen Systemen eine hohe Verbreitung [Hac89].

Wissensbasierte Systeme stellen eine spezielle Klasse von heuristischen Verfahren dar. Dabei basiert die Berechnung der Heuristik auf gesammeltem Wissen, das getrennt von der Programmablaufstruktur dargestellt wird [Kur92]. Einer der Vorteile dieses Ansatzes liegt in der Fähigkeit, das Wissen zu reorganisieren. Dies ist besonders bei Problemstellungen, die von veränderlichen Umgebungen abhängen, relevant.

Erste Ansätze im Bereich der wissensbasierten Steuerung von logistischen Systemen wurden zu Beginn der neunziger Jahre gemacht. Unter anderem stellen Piramunthu

et. al. [PRSP93] heraus, dass die Effektivität von Prioritätsregeln des Scheduling vom aktuellen Systemstatus abhängt und sich daraus das Problem ergibt, einem Systemstatus eine Prioritätsregel zuzuordnen. Dies wurde durch ein wissensbasiertes Verfahren gelöst. Weiterentwicklungen solcher situationsabhängigen Steuerungen für verschiedene logistische Systeme sind etwa [ADLR08], [BS11], [JKK11], [MC05], [Vit97].

Die Zuordnung der Steuerungssituation zu einer auszuführenden Maßnahme benötigt mittels wissensbasierter Verfahren sehr wenig Rechenzeit und kann daher auch in echtzeitnahen Anwendungen wie der Steuerung von logistischen Systemen stattfinden. Zum Aufbau der Wissensbasis ist es eine mögliche Herangehensweise, einer Software aus Erfahrungen mittels überwachtem maschinellen Lernen Wissen sammeln zu lassen. Die Qualität der Steuerung hängt dann maßgeblich von den Trainingsbeispielen, mit denen trainiert wurde ab. Unter Annahme der Gültigkeit des Analogieschlusses<sup>1</sup> soll zur aktuellen Steuerungssituation eine möglichst ähnliche schon erlernt sein. Daraus ergibt sich das Ziel, dass die Situationen in der Trainingsmenge möglichst ähnlich zu zukünftig auftretenden sind, speziell auch bei Änderungen im System oder Eintritt von unvorhergesehenen Ereignissen, die andere Situationen bedingen.

Gegenstand dieser Arbeit ist die Ausarbeitung eines Verfahrens zur Generierung von Zuordnungen, das möglichst oft zu auftretenden Situationen bereits passende Zuordnungen bereit hält. Es soll auf einem sich fortlaufend anpassenden simulationsbasierten Ansatz basieren. In einer Simulation des zu steuernden Systems werden dabei Situation/Maßnahme Zuordnungen generiert, die in einer Datenbank abgespeichert und zur Wissensbasis verarbeitet werden. Eine Evaluierungs- und Anpassungskomponente steuert über Systemparameter die Simulation, abhängig von registrierten Ereignissen, Situationen und Systemparametern des zu steuernden Systems. Das Wissen soll damit den aktuellen Gegebenheiten entsprechen. Resultat der Arbeit soll ein Verfahren sein, das robust gegenüber Änderungen im System ist und autonom und vorausschauend diese in die interne Wissenserfassung übernimmt. Zudem soll die Leistung einer Maßnahme auch unter verschiedenen Szenarien berücksichtigt werden. Somit soll in jeder Situation eine Maßnahme von hoher Lösungsqualität echtzeitnah bestimmt werden können.

Aufgrund des breiten Anwendungsgebietes des Steuerungsverfahrens soll dieses zudem in abstrakter, möglichst allgemeingültiger Weise beschrieben werden. Die anwendungsspezifi-

---

<sup>1</sup> Der Analogieschluss ist die Schlussfolgerung nach dem Muster:  $A$  ist ähnlich zu  $B$ ,  $A$  hat Eigenschaft  $x$ , dann hat  $B$  auch die Eigenschaft  $x$ .

schen Aspekte werden dann einzeln bei der Anpassung des Konzeptes auf konkrete Systeme definiert. Dadurch soll bei Entwicklung der Steuerung einzelner Systeme ein Großteil der konzeptionellen Arbeit entfallen.



## 2. Problemstellung

Im Folgenden werden die Problemstellung und die Anforderungen an die Problemlösung definiert. Dazu wird in Abschnitt 2, nach einer grundlegenden Beschreibung des Betrachtungsgegenstandes, die Problemstellung in einzelne Teilprobleme partitioniert und detailliert beschrieben mitsamt ihren Zielen und Anforderungen.

### 2.1. Betrachtungsgegenstand

Es wird ein reales, aber aus Vertraulichkeitsgründen abstrahiert dargestelltes automatisches Material Handling System betrachtet, welches zum Zeitpunkt der Erstellung dieser Arbeit in Entwicklung ist. Zur Identifizierung der Problemstellung eines Steuerungsverfahrens wird im Folgenden der Materialfluss des Systems, also die Ein- und Auslagerung von Material, beschrieben. Das System besteht aus mehreren Ebenen. Es existieren als zu steuernde Fördereinheiten Übergabekabinen, die gleichzeitig Aufzüge (auch Hoists genannt) sind und die Verbindung zur Umgebung darstellen. Die Übergabekabinen sind dazu konzipiert, Material aufzunehmen bzw. abzugeben und das Material zwischen den einzelnen Ebenen zu befördern. Weiterhin sind auf jeder Ebene Transfer Vehicle (TV), die entlang einer Gasse die Stellplätze anfahren und das Material somit zwischen Aufzug und Stellplatz befördern. Über sogenannte Manipulatoren an einem TV wird das Material zwischen Aufzug und TV bzw. TV und Stellplatz bewegt.

Der Ablauf einer Einlagerung am System ist schematisch in Abbildung 2.1 illustriert. Das Material wird in eine Übergabekabine eingefahren. Während dieses Vorgangs ist sie daher für andere Operationen gesperrt. Anschließend fährt die Übergabekabine die entsprechende Ebene an (1), wo ein Manipulator das Material auf ein Shuttle umlädt (2). Das Shuttle bewegt sich zum zuvor festgelegten Stellplatz (3). Dort angekommen, wird das Material wiederum mittels Manipulatoren auf einen Stellplatz transportiert (4).




Abbildung 2.1.: Schematische Darstellung eines Einlagervorganges des MHS

Ein Auslagerungsvorgang wird auf Anfrage gestartet, bei dem die erläuterten Schritte in umgekehrter Reihenfolge ausgeführt werden.

Die Problemstellung der Steuerung lautet, die Fördereinheiten in einer Weise einzusetzen, die die Wartezeiten der Benutzer minimiert. Es können dazu der Zeitpunkt der Beauftragung und das Ziel der Fördereinheiten manipuliert werden. Bei dem MHS haben Voruntersuchungen gezeigt, dass im Wesentlichen die zeitliche Koordinierung zwischen TVs und Aufzügen sowie die Auswahl des konkreten Stellplatzes bei einer Einlagerung Einfluss auf die Wartezeiten haben. Je nach aktueller sowie vergangener Auftragslast sind verschiedene Entscheidungsalternativen optimal. Zur Anwendung des Prinzips der situationsbasierten Steuerung wurden entsprechende Maßnahmen und Situationen definiert. Es ergibt sich das Problem, in einer Situation die Maßnahme zu wählen, die die zukünftigen Wartezeiten minimiert.

Aufgrund der zahlreichen Abhängigkeiten zwischen diesen Entscheidungen kann die Auswirkung einer Maßnahmenauswahl nicht in Echtzeit betrachtet werden. Es sollen daher offline Situation/Maßnahme Zuordnungen im Sinne eines induktiven Lernens vorgegeben werden. Diese können in einer Simulation des logistischen Systems generiert werden. Folgende Probleme ergeben sich bei der Fragestellung, wie die Zuordnungen generiert werden sollen.



Aufgrund der hohen Anzahl an möglichen Situationen in logistischen Systemen<sup>1</sup> können nicht alle a priori einer Maßnahme zugeordnet werden. Es ist eine Auswahl derer nötig, die möglichst ähnlich zu den zukünftig auftretenden sind. Dabei muss die Auswahl aufgrund von erwarteten Änderungen im System dynamisch, das heißt abhängig von den Systemparametern<sup>2</sup>, erfolgen. Zunächst ist daher eine Definition von Ähnlichkeit notwendig, die eine Berechnung anhand zwei Situationen ermöglicht. Weiterhin sind Kriterien zu definieren, die die systemabhängige Definition von Situationen und Systemparametern eines Systems anleiten. Zur Berücksichtigung der Dynamik im System muss zusätzlich ein Verfahren vorhanden sein, das auf diese Dynamik reagiert, sodass die Ähnlichkeit der zugeordneten Situationen zu den auftretenden konstant hoch bleibt. Bei dem MHS beispielsweise kann ein verändertes Nutzerverhalten bedingen, dass andere Systemlasten und damit Situationen auftreten und verschiedene Maßnahmen optimal werden.

Die Zuordnung zu einer Maßnahme zur Leistungsmaximierung soll langfristige Effekte und stochastischen Entwicklungen berücksichtigen. Dies verlangt eine Bewertung jeder möglichen Maßnahme unter verschiedenen Szenarien bei offenem zeitlichen Horizont. So stellt beim MHS das Eintreten eines Ereignisses, das plötzlich eintretende Lastspitzen verursacht, eine nicht vorhersagbare Entwicklung dar. Weiterhin bedingt die frühzeitige Entscheidung, Material auf einem bestimmten Stellplatz einzulagern, dass dieser für zukünftige Einlagerungen belegt ist. Es ist eine geeignete Methodik zu entwickeln, die es ermöglicht, langfristige Auswirkungen in angemessener Rechenzeit zu berücksichtigen. So sollen die Leistungen unter verschiedenen stochastischen Entwicklungen zu einer Gesamtbewertung zusammen gefasst werden können.

Zu einer Situation muss im Betrieb schnell (in Echtzeit) eine Maßnahme ausgewählt werden können. Dies bedingt ein Verfahren, um einerseits die Anzahl an Zuordnungen zu begrenzen, möglichst ohne dass die Leistung der Steuerung sinkt. Andererseits sollten die enthaltenen Informationen geeignet aufbereitet werden.

Gegenstand dieser Arbeit ist die Ausarbeitung eines Verfahrens zur Generierung von Zuordnungen, das die genannten Probleme mittels eines sich fortlaufend anpassenden simulationsbasierten Ansatzes lösen soll. Die Struktur des Verfahrens ist in Abbildung 2.2 dargestellt. In einer Simulation des zu steuernden Systems werden unter Berücksichtigung von stochastischen Einflüssen Situation/Maßnahme Zuordnungen generiert. Ausgehend von

---

<sup>1</sup> Bei dem MHS etwa existiert für jede Kombination von aktuellen und vergangenen Systemlasten eine Situation.

<sup>2</sup> siehe Definition A.13

einer Situation werden verschiedene Szenarien betrachtet und die Maßnahmen bewertet, um die jeweils optimale zu bestimmen. Die Zuordnungen werden in einer Datenbank abgespeichert und zur Wissensbasis verarbeitet, anhand derer in Echtzeit gesteuert werden kann. Eine Evaluierungs- und Anpassungskomponente steuert über Systemparameter die Simulation, abhängig von registrierten Ereignissen, Situationen und Systemparametern des zu steuernden Systems. Dadurch wird die treffende Auswahl der Situationen gewährleistet. Der zukünftige Systemparameterverlauf wird zusätzlich prognostiziert, um auf kommende Änderungen frühzeitig zu reagieren.

Die dargestellten Teilkomponenten stellen im Zusammenhang das Verfahren dar, das die dargelegten Probleme lösen soll. Dabei ist die Ausarbeitung der einzelnen Teilkomponenten Problemstellung dieser Dissertation. Diese sollen möglichst unabhängig vom zu steuernden System erarbeitet werden. Die einzelnen Teilkomponenten sind in den folgenden Abschnitten 2.2 bis 2.6 detailliert definiert.

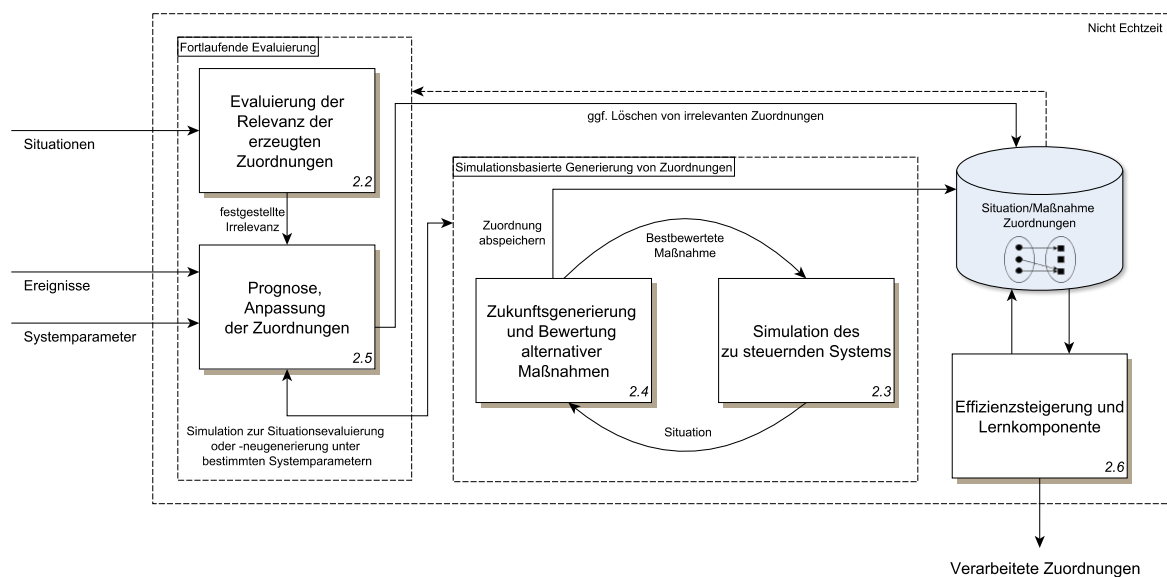


Abbildung 2.2.: Partitionierung des Verfahrens in Teilkomponenten, die in den angegebenen Kapiteln definiert werden.

## 2.2. Fortlaufende Evaluierung der Relevanz der erzeugten Situationen

Um die Relevanz der Zuordnungen auch bei Änderungen im zu steuernden System sicherzustellen, sollen die tatsächlich auftretenden Situationen registriert und anhand dessen die erzeugten Zuordnungen fortlaufend evaluiert werden. Ziel ist es, eine zu geringe Ähnlichkeit zu einer registrierten Situation (eine Irrelevanz) feststellen und daraufhin entsprechend reagieren zu können. Da von der Gültigkeit des Analogieschlusses ausgegangen wird, erwirkt nämlich eine Irrelevanz der erzeugten Zuordnungen einen Leistungsverlust im System. Dem Klassifizierer steht in diesem Fall kein Wissen zur Verfügung, um eine Maßnahme mit hoher Leistung auszuwählen.

Zur Feststellung der Irrelevanz ist, wie in Abbildung 2.3 dargestellt, eine Vergleichsmöglichkeit von Situationen zur Menge der bereits erzeugten notwendig, insbesondere eine Definition von Ähnlichkeit.




Abbildung 2.3.: Die Evaluierung der Relevanz der erzeugten Zuordnungen in der Übersicht

Ziel ist es, ein berechenbares binäres Kriterium der Irrelevanz

$$R(S_{erz}, s) \in \{relevant, irrelevant\}$$

bezüglich der Menge der erzeugten Situationen  $S_{erz} \subseteq S$  relativ zu einer Referenzsituation  $s$  zu bestimmen:

$$R : \mathcal{P}(S) \times S \rightarrow \{relevant, irrelevant\}$$

Zur Berechnung von  $R(S_{erz}, s)$  erscheint es sinnvoll, eine zugrunde liegende Metrik in  $S$  zu entwickeln, die einen Abstand, also sinngemäß eine Ähnlichkeit, zwischen zwei Situationen  $s_1, s_2 \in S$  bestimmt:

$$d_S : S \times S \rightarrow \mathbb{R}$$

Die Funktion muss die drei Bedingungen einer Metrik (Definitheit, Symmetrie, Dreiecksungleichung) erfüllen. Weiterhin soll aufgrund der unterschiedlichen Bedeutung der in den Situationen enthaltenen Komponenten auf die Maßnahmenzuordnung die Möglichkeit gegeben sein, einzelne Komponenten unterschiedlich zu gewichten. Die Metrik soll aufgrund der vorgesehenen Verwendung, besonders in Bereichen des Situationsraumes mit wenigen generierten Zuordnungen eine Irrelevanz anzuzeigen, nicht ausschließlich auf den bisher generierten Zuordnungen basieren. Vielmehr soll die Möglichkeit gegeben sein, systemspezifische Umstände zu berücksichtigen, die als zu entwickelnde Parameter in die Metrik einfließen. Die Metrik kann also als Funktion

$$d_S : S \times S \times U \rightarrow \mathbb{R}$$

aufgefasst werden, wobei  $U$  die Menge der möglichen Parameter für einen Situationsraum darstellt, die für ein System konstant sind. Neben der mathematischen Definition von  $U$  steht die Entwicklung von Kriterien im Vordergrund, anhand derer Parameterwerte gewählt werden können.

Mithilfe der zu entwickelnden Formel für  $R$  und  $d_S$  soll dann jede auftretende Situation  $s$  und die aktuelle Menge  $S_{erz}$  ausgewertet werden. Bei  $R(S_{erz}, s) = \textit{irrelevant}$  wird die Anpassung der Zuordnungen angestoßen. Dabei muss sichergestellt werden, dass die Leistung des Systems unter Zuordnungen, die als relevant hinsichtlich der aktuellen Situation betrachtet werden, höher ist als bei irrelevant betrachteten. Ansonsten würde die Selbstanpassung eine Verschlechterung der Leistung bewirken.

## 2.3. Simulationsmodellbasierte Generierung von Situationen

Mittels eines ausführbaren Simulationsmodells des zu steuernden Systems sollen gerade die Situationen ermittelt werden, die im realen Betrieb auftreten werden<sup>3</sup>. Dazu werden, wie in Abbildung 2.4 illustriert, dem Simulationsmodell Systemparameter als Eingabe zugeführt und das Modell durch einen Simulationskern<sup>4</sup> ausgeführt. Dabei wird der Ablauf des Systems nachgebildet und es treten in der Simulation Situationen auf, die als Ausgangspunkt für die Maßnahmenbewertung verwendet werden und an dieser Stelle die Ausgabe der Teilkomponente darstellen. Es wird eine entsprechende Validierung<sup>5</sup> des Simulationsmodells in dieser Arbeit vorausgesetzt. Die Systemparameter können zur Realisierung der Anpassungsmöglichkeit an Änderungen im System verstellt werden.

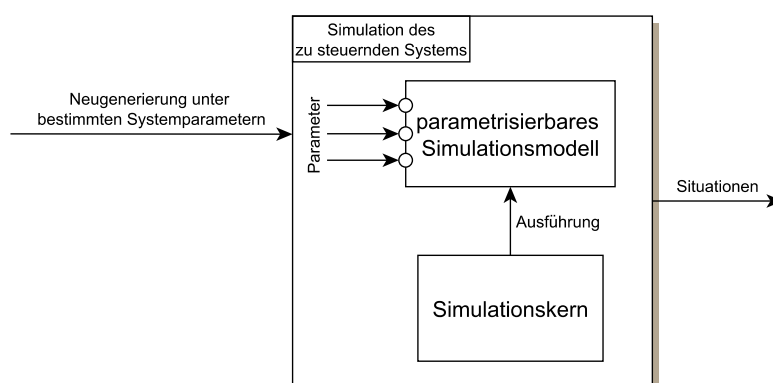


Abbildung 2.4.: Die simulationsmodellbasierte Generierung von Situationen in der Übersicht

Zur Realisierung der Teilkomponente sind die in den folgenden Abschnitten definierten Probleme zu lösen.

<sup>3</sup> Es soll also eine hohe Relevanz der Situationen nach der erfolgten Definition in Abschnitt 2.2 erzielt werden.

<sup>4</sup> vgl. [VDI96]

<sup>5</sup> Validierung ist die „Überprüfung der hinreichenden Übereinstimmung von Modell und System“. [VDI96] Es existieren zahlreiche Methoden zur Validierung. [RSW08]

### 2.3.1. Definition von Systemparametern als Input

Die konkrete Definition der Systemparameter  $P$  hängt von dem zu steuernden System ab. Ziel dieses Teilproblems soll es vielmehr sein, Kriterien auszuarbeiten, die bei der Definition gelten, um den gewünschten Effekt der Anpassungsfähigkeit der Generierung zu gewährleisten. Diese Kriterien sollen in Form einer praktisch umsetzbaren Anweisung ausgearbeitet werden, anhand derer zur Steuerung eines logistischen Systems leicht die Systemparameter definiert werden können. Zudem ist auszuarbeiten, welche Formen der mathematischen Modellierung (auch von stochastischen Systemparametern) zur praktischen Anwendung im Gesamtkontext, insbesondere der simulationsbasierten Vorausschau, geeignet sind.

### 2.3.2. Definition von Situationen als Output

Ähnlich wie bei den Systemparametern ist auszuarbeiten, welche Kriterien bei der Definition von Situationen  $S$  in einer konkreten Anwendung gelten, um eine Maßnahme von hoher Lösungsqualität passend auswählen zu können. Es soll zudem ein Verfahren entwickelt werden, um anhand der erzeugten Zuordnungen die Definition von Situationen bewerten zu können. Dieses Bewertungsverfahren soll so gestaltet sein, dass ein automatisierter Durchlauf möglich ist. Dem Anwender soll zu einer Trainingsdatenmenge direkt ein Kriterium angezeigt werden, ob die Situationsdefinition eine Ober- (es sind unnötige Attribute vorhanden) oder eine Untermenge (es fehlen relevante Attribute) der optimalen Definition darstellt. Ebenfalls stellt sich die Frage, in welcher Form die Situationen mathematisch zu modellieren sind, um sie softwaretechnisch verwenden zu können.

## 2.4. Evaluierung von alternativen Maßnahmen in einer Situation




Abbildung 2.5.: Die Zukunftsgenerierung und Bewertung alternativer Maßnahmen in der Simulation in der Übersicht

Ziel der Komponente ist es, zu einer in der Simulation (siehe Abschnitt 2.3) des zu steuernden Systems aufgetretenen Situation (Input) eine in dieser Situation als optimal angesehene Maßnahme zu bestimmen (Output). Diese Maßnahme, die aus einer a priori definierten Menge an Maßnahmen für das betrachtete zu steuernde System ausgewählt wird, wird einerseits in den weiteren Simulationsverlauf übernommen, andererseits zusammen mit der Situation als Zuordnung abgespeichert.

Wie in Abbildung 2.5 dargestellt, besteht die Bestimmung der optimalen Maßnahme aus zwei Schritten: Unter Anwendung jeder Maßnahme sowie unter Berücksichtigung von stochastischen Einflüssen wird mittels der Simulation projiziert, wie sich das System in diesen Zukünften entwickeln würde (siehe Abschnitt 2.4.1). Es ergibt sich ein Baum von Zukünften, der im zweiten Schritt analysiert wird und mittels dessen jede Maßnahme bewertet wird (siehe Abschnitt 2.4.2). Die Maßnahme mit der besten Bewertung wird schließlich ausgegeben.

### 2.4.1. Zukunftsgenerierung aufgrund von alternativen Maßnahmen und Unsicherheiten

Von einer Situation als Input ausgehend, soll mittels Simulation ermittelt werden, wie sich das System unter Anwendung der möglichen Maßnahmen entwickeln würde. Dazu soll eine Beschreibung in Form eines Graphen (speziell eines Baumes) erarbeitet werden, die den Verlauf repräsentiert und mittels der die in Abschnitt 2.4.2 beschriebenen Methoden arbeiten können.

Zudem sollen die Auswirkungen einer Maßnahme nicht nur unter einer angenommen zukünftigen Entwicklung des Systems, sondern auch unter verschiedenen Szenarien, darunter etwa das Eintreten nicht antizipierbarer Ereignisse wie Störfälle, untersucht werden können. Dies soll es wiederum bei einer konkreten Anwendung ermöglichen, Entwicklungen zu berücksichtigen und leicht in die Zukunftsgenerierung zu integrieren.

Konkret sollen folgende Arten von Unsicherheiten berücksichtigt werden:

**Definition 2.1** (Ereignis). *Eine plötzliche, unerwartete Änderung im System, die zu einer Änderung der folgenden Steuerungssituationen und optional auch dauerhaft eines oder mehrerer Systemparameter führt. Für eine Anwendung wird dazu eine Menge  $E$  an Ereignissen definiert, die berücksichtigt werden sollen. Im Simulationsmodell ist die Auswirkung des Ereignisses hinterlegt. Innerhalb der Zukunftsgenerierung ist es möglich, zu beliebigen Zeitpunkten den Eintritt des Ereignisses zu triggern.*

*Die dauerhafte Änderung der Systemparameter bei Eintritt eines Ereignisses  $e \in E$  wird mittels einer Funktion  $f_e : P \rightarrow P$  definiert.*

*Beispiele für Ereignisse sind etwa ein Ausfall von technischen Einheiten oder ein sprunghafter Anstieg an Systemlast.*

**Definition 2.2** (Ausprägungen stochastischer Systemparameter). *Wie in Abschnitt 2.3.1 beschrieben, können Systemparameter stochastische Größen darstellen, die bei jedem Ablauf eine Ausprägung annehmen. Die Auswirkung verschiedener Ausprägungen dieser Systemparameter soll berücksichtigt werden.*

*An das Simulationsmodell kann innerhalb der Zukunftsgenerierung die konkrete Ausprägung übergeben werden.*



Ein Beispiel sind mögliche Parameterwerte von Verteilungsfunktionen für zukünftige Systemlasten. Die Ausprägung eines stochastischen Systemparameters kann also ihrerseits wieder einen stochastischen Prozess beschreiben.

**Definition 2.3** (Ausprägungen allgemeiner stochastischer Prozesse). *Weitere stochastische Einflüsse innerhalb des Simulationsmodelles können explizit berücksichtigt und deren Ausprägungen kontrolliert ausgeführt werden, um ihren Einfluss auf die Maßnahmenauswahl zu bestimmen.*

Ein Beispiel hierfür sind Verspätungen von Transportfahrzeugen.

Der Baum von Zukünften als Output der Komponente hat aufgrund der immer weiteren Verzweigung der Zukünfte eine hohe Größe<sup>6</sup> und zudem ist die Bestimmung eines Knotens aufgrund der benötigten Simulation rechenaufwendig. Daher ist eine implizite Darstellung auszuarbeiten, die der folgenden Komponente als Input dient, ohne dass alle Knoten explizit bestimmt wurden.

### 2.4.2. Bewertung der alternativen Maßnahmen

Anhand des Baums von Zukünften, also der Entwicklung des Systems unter jeder möglichen Maßnahme und verschiedenen Szenarien, soll nun jede Maßnahme bewertet und schließlich die als optimal angesehene bestimmt werden.

Grundsätzlich besteht das Problem, dass eine Maßnahme zu kurzfristig bewertet wird und nur lokaler Gewinn berücksichtigt wird, ohne dass der langfristige Nutzen einer Maßnahme genügend Gewichtung findet<sup>7</sup>. Andererseits ist anzunehmen, dass die Auswirkung einer Maßnahme im Laufe der Zeit abnimmt, d. h. dass bei einem zu langen zeitlichen Horizont der kausale Zusammenhang zur Maßnahmenauswahl nicht mehr gegeben ist. Es ist also der richtige Zeitraum zu wählen, um die Konsequenzen einer Maßnahme einzuschätzen. Dieser kann etwa statisch (die Simulation läuft eine konstante Simulationszeit  $t$ ) oder dynamisch definiert werden, indem nach bestimmten Gegebenheiten in der Simulation entschieden wird, die Vorausschau zu beenden. Diese Gegebenheiten hängen wiederum vom konkreten zu steuernden System ab. In diesem Teilproblem sollen also Kriterien entwickelt werden,

<sup>6</sup> Mit jeder weiteren zukünftigen Situation ergibt sich ein exponentielles Wachstum des Baumes.

<sup>7</sup> Es muss ein lokales Optimum vermieden werden.

mittels derer je nach Anwendung entschieden werden kann, welche Zeiträume verwendet werden.

Eine weitere Herausforderung liegt darin, die Konsequenzen einer Maßnahme unter den verschiedenen Szenarien im Baum der Zukünfte zu einer einzelnen Bewertung zusammenzufassen. Es sollen alternative Rechenvorschriften zur Bewertung herausgearbeitet werden, die eine einstellbare Risikoaversität bzw. -affinität erlauben. Andererseits sollen sie einen Faktor beinhalten, nachdem der Anwender sein Vertrauen in die Wahrscheinlichkeitswerte der Szenarien definieren kann. Weiterhin sind definierte Eintrittswahrscheinlichkeiten subjektiv gewählt und sollten nicht als gesicherte Informationen in die Berechnung einfließen.

Es ist abzusehen, dass zur hinreichend schnellen Berechnung von Zuordnungen aufgrund der hohen Anzahl nicht alle Knoten im Baum der Zukünfte explizit bestimmt – also durch die Simulation erfasst – werden können. Deshalb soll das Bewertungsverfahren so gestaltet werden, dass nur eine möglichst kleine Teilmenge der Knoten bestimmt wird. Dazu muss ein Kriterium entwickelt werden, das den erwarteten Informationsgewinn eines Knotens angibt. Beispielsweise bieten Knoten in der Zukunft einer Maßnahme, die aufgrund bisheriger Berechnungen schon sicher als nicht optimal bewertet werden, keinen Informationsgewinn und sollten nicht berechnet werden. Weiterhin soll das Verfahren auch unter Verlust von Informationen in der Lage sein, Knoten zu verwerfen, falls ansonsten in einer gegebenen Rechenzeit die Berechnung nicht abgeschlossen werden könnte.

Output der Komponente ist schließlich die als optimal bestimmte Maßnahme, die in den Simulationsverlauf übernommen wird und zusätzlich zusammen mit der Ausgangssituation in der Datenbank der Zuordnungen abgespeichert wird.

## **2.5. Anpassung der Zuordnungen bei festgestellter oder antizipierter Irrelevanz**

Eine wesentliche Eigenschaft des in dieser Arbeit zu entwickelnden Verfahrens ist die automatisierte Anpassung der Zuordnungen, um auf Änderungen im zu steuernden System zu reagieren. Diese können eine geringe Relevanz der Zuordnungen bewirken und letztlich zu einer Leistungsreduzierung des Systems führen. Da nicht alle Entwicklungen des Systems und von exogenen Faktoren – wie etwa Systemlast – zum Zeitpunkt der Inbetriebnahme vorhergesehen werden können, ist die Anpassung notwendig.

Die in Abbildung 2.6 dargestellte Komponente soll die Anpassung umsetzen. Ihr Output sind die Systemparameter, unter denen die simulationsmodellbasierte Generierung (siehe Abschnitt 2.3) neue Zuordnungen erstellen soll. Es soll im Sinne eines proaktiven Handelns nicht nur auf aktuelle Gegebenheiten im System a posteriori reagiert werden, sondern möglichst auch die zukünftigen Systemparameter abgeschätzt werden können. Eine korrekte Abschätzung ermöglicht eine frühzeitige Neugenerierung von Zuordnungen, bevor die Gegebenheiten eintreten, sodass dem Klassifizierer immer relevante Zuordnungen zur Verfügung stehen.

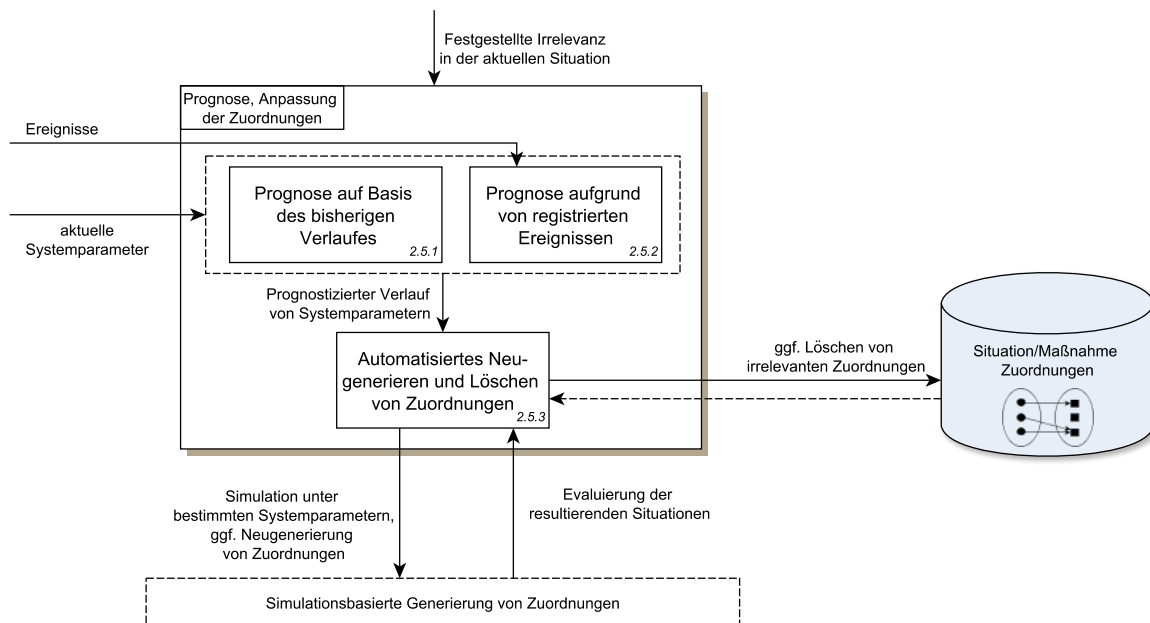


Abbildung 2.6.: Die Prognose und Anpassung der Zuordnungen in der Übersicht

Zur Prognose des zukünftigen Verlaufes der Systemparameter ( $p_t$ ) existieren zwei Teilkomponenten. Einerseits soll eine langfristige Prognose, basierend auf dem bisherigen Verlauf der Systemparameter (Abschnitt 2.5.1), es ermöglichen, Veränderungen im System zu antizipieren. Andererseits können plötzliche Ereignisse im System kurzfristige Änderungen auslösen, die ggf. nicht durch entsprechende Zuordnungen abgedeckt sind und deshalb mit einer in Abschnitt 2.5.2 beschriebenen Teilkomponente prognostiziert werden sollen.

Auf Basis der entweder kurz- oder langfristigen Prognose soll dann die in Abschnitt 2.5.3 beschriebene Teilkomponente bestimmen, ob und mit welchen Systemparametern eine Neugenerierung in der Simulation geschieht und ob vorhandene Zuordnungen gelöscht werden sollen. Dazu interagiert sie auch direkt mit der Simulation, um zunächst die

resultierenden Situationen zu bestimmten Systemparametern zu erhalten.

Die Komponente hat als Input eine bereits festgestellte Irrelevanz in der aktuellen Situation (siehe Abschnitt 2.2), die aktuellen Systemparameter oder ein registriertes Ereignis im System.

### 2.5.1. Prognose der Systemparameter auf Basis des bisherigen Verlaufes

Ziel ist es, zum Zeitpunkt  $t_0$  anhand des bisherigen Verlaufes der Systemparameter (siehe Abschnitt 2.3.1)  $(p_t), t \leq t_0$  eine Prognose  $(p_t), t > t_0$  für die Zukunft zu erstellen. Es wird angenommen, dass der Systemparameterverlauf langfristige Veränderungen im System widerspiegelt, die hauptsächlich durch exogene Einflüsse wie andere Systemlasten entstehen. So können durch eine möglichst präzise Prognose im Voraus neue Zuordnungen generiert und gegebenenfalls nicht mehr benötigte Zuordnungen gelöscht werden.

Der Verlauf eines einzelnen Systemparameters stellt eine Zeitreihe dar, die klassischerweise in der Ökonomie in folgende Komponenten unterteilt wird [Lew74]:

- Trendkomponente
- Konjunkturkomponente
- Saisonkomponente
- Irreguläre Komponente

Die Problemstellung liegt also einerseits in der Identifizierung und Adaption eines universell (unabhängig vom konkreten System und ohne Anpassungsbedarf) geeigneten Verfahrens zur Zeitreihenanalyse und Prognose, andererseits in der Bestimmung der zu verwendenden Anzahl an Prognosewerten. Letztere soll berücksichtigen, wie viel Zeit zur Generierung der Zuordnungen zur Verfügung steht.

Das Verfahren soll die folgenden Annahmen in den Systemparametern berücksichtigen können, die als typisch für die Domäne der logistischen Systeme angesehen werden:

- Konstanter Verlauf
- Linearer Verlauf: Ein linearer Trend (Wachstum/Schrumpfung) soll erkannt und fortgeführt werden können.

### **2.5.2. Vorausschauende Gegenmaßnahmen nach Registrierung von Ereignissen im System**

Nicht antizipierbare Ereignisse, deren Auswirkungen zwar bekannt wird, aber deren Eintreten zeitlich nicht vorhergesehen werden können, mindern die Leistung des Systems gegebenenfalls. Kurzfristig werden die erzeugten Zuordnungen bei Eintritt irrelevant und aufgrund der benötigten Rechenzeit können nicht schnell genug neue generiert werden. Beispielsweise bringen Ausfälle von einzelnen Einheiten im System dieses potentiell in Situationen, für die keine Zuordnungen gelernt wurden, da aus Komplexitätsgründen nicht jede Kombination aus Ausgangszustand und möglichem Ereignis a priori trainiert werden kann. Aus diesem Grund soll bei Registrierung eines Ereignisses eine kurzfristige Prognose der Systemparameter erstellt werden, um gegebenenfalls so früh wie möglich relevante Zuordnungen zu generieren. So kann einerseits die Zeit zwischen Auftreten eines Ereignisses und einer unbekanntem Situation ausgenutzt werden, andererseits anhand der speziellen kurzfristigen Prognose für die nahe Zukunft eine Relevanz erreicht werden.

Ziel der Teilkomponente ist es folglich, Methoden zu entwickeln, mit denen die Auswirkungen eines Ereignisses auf die Systemparameter in berechenbarer Weise beschreibbar sind, und diese exemplarisch für zu erwartende Ereignistypen auszumodellieren. Der Zusammenhang zu den in Abschnitt 2.4.1 beschriebenen Ereignissen, die direkt in der Simulation umgesetzt werden, ist auszuarbeiten. Mithilfe der hier entwickelten Methoden kann dann anhand des bisherigen Systemparameterverlaufes eine kurzfristige Prognose erstellt werden, die als Eingabe für die folgende Teilkomponente dient.

### **2.5.3. Automatisiertes Neugenerieren und Löschen von Zuordnungen**

Auf Basis der prognostizierten Systemparameter soll in dieser Teilkomponente bestimmt werden, ob und gegebenenfalls welche Zuordnungen gelöscht werden und unter welchen Systemparametern die simulationsbasierte Neugenerierung angestoßen wird.

Zunächst soll mittels der in Abschnitt 2.3 beschriebenen Simulation bestimmt werden, welche Situationen sich aus dem prognostizierten Verlauf der Systemparameter ergeben. Die Simulation soll also in der Lage sein, schnell und ohne die rechenaufwendige Evaluierung von alternativen Maßnahmen (siehe 2.4) abzulaufen.

Es soll mittels einer hier zu entwickelnden Abwandlung der Relevanzfunktion  $R$  dann ein Vergleich von prognostizierten zu erzeugten Situationen ermittelt werden, um zu bestimmen, ob eine Neugenerierung von Zuordnungen notwendig ist. Die Relevanzfunktion stützt sich dabei auf die in Abschnitt 2.2 definierte Ähnlichkeitsmetrik  $d_S$ .

Zur Neugenerierung im Falle einer bestimmten Notwendigkeit müssen die Ausprägungen der Systemparameter bestimmt werden. Dabei soll zur Kompensation von Prognosefehlern eine Streuung um den prognostizierten Verlauf zur Neugenerierung definiert werden, anstatt ausschließlich die berechneten Prognosewerte zu übernehmen.

Weiterhin muss die Anzahl an verwendeten Prognosewerten zur Neugenerierung bestimmt werden. Die Rechenvorschrift hierzu soll die zur Verfügung stehende Zeit zur Generierung von Zuordnungen skalierbar ausnutzen. Dies führt zu einer erhöhten Anzahl an generierten Zuordnungen.

Es soll zudem bestimmt werden, welche Zuordnungen gelöscht werden sollten. Dies sollte mittels den anhand der Prognose und in der Simulation bestimmten erwarteten Situationen und unter Verwendung der Ähnlichkeitsmetrik  $d_S$  geschehen. Wiederum ist zu berücksichtigen, als wie sicher die Prognose anzusehen ist und ob eine dauerhafte Abkehr von bisherigen Gegebenheiten im System, etwa durch eine trendmäßige Erhöhung der Systemlast, zu erwarten ist.

Zudem soll der Zeitpunkt der Generierung einer Zuordnung betrachtet werden und das Konzept des Alterns von Wissen übertragen werden. Dies eignet sich hier speziell dazu, um eine nicht hinreichend umfassende Situationsdefinition zu kompensieren. Es ist nämlich denkbar, dass in zwei gleichen Situationen weitere nicht erfasste Gegebenheiten im System Einfluss auf die Bewertung der Maßnahmen haben. In dem Fall wäre es sinnvoll, die ältere Zuordnung zu löschen, auch wenn sie anhand der Relevanzfunktion  $R$  als relevant betrachtet wird, und zur Situation eine neue Zuordnung zu erstellen. Voraussetzung ist allerdings, dass die nicht erfassten Gegebenheiten durch Systemparameter abgedeckt sind, um sie überhaupt der Simulation zuführen zu können. Es bleiben dem Verfahren alle Informationen verdeckt, die nicht über Systemparameter abgebildet werden können.

## **2.6. Effizienzsteigerung der erzeugten Situation/Maßnahme Zuordnungen**

Die Klassifizierung von Situationen zu einer Maßnahme muss bei der Steuerung des realen Systems in Echtzeit geschehen. Es sollen daher Verfahren erarbeitet werden, die eine hohe Geschwindigkeit der Klassifizierung anhand der generierten Situation/Maßnahme Zuordnungen sicherstellen. Dies soll auf zwei verschiedene Arten geschehen, die in den folgenden Abschnitten beschrieben werden. Einerseits soll die Anzahl an Zuordnungen minimiert werden, andererseits sollen die Zuordnungen anhand von maschinellen Lernverfahren zu Datenstrukturen verarbeitet werden, die eine sehr schnelle Klassifizierung erlauben.

### **2.6.1. Minimierung der Anzahl der Zuordnungen bei gleichbleibender Ergebnisqualität**

Die Anzahl  $|Z_{erz}|$  an Zuordnungen hat Einfluss auf die Rechenzeit verschiedener Komponenten des Gesamtsystems, etwa die Auswertung des Relevanzkriteriums (siehe Abschnitt 2.2). Deshalb soll eine Methode entwickelt werden, die die Anzahl an Zuordnungen minimiert. Dabei soll sich die Ergebnisqualität nicht verringern.

### **2.6.2. Darstellung der Zuordnungen als Hypothese überwachter Lernverfahren**

Die Zuordnungen werden im letzten Schritt der Gesamtverfahrens an den Klassifizierer übergeben, der sie zu einem Wissensmodell mittels Methoden des maschinellen Lernens verarbeitet. Es soll identifiziert werden, in welchem Zusammenhang die Zuordnungen zu überwachten Lernverfahren stehen, um daraus Voraussetzungen für die Auswahl eines solchen Verfahrens abzuleiten.





## 3. Stand der Technik

Nachdem im vorangegangenen Kapitel die Problemstellung dargelegt wurde, soll der Untersuchungskontext in diesem Abschnitt betrachtet werden, um gegebenenfalls vorhandene Methoden zur Problemlösung zu identifizieren. Hinsichtlich der Anforderungen wird eine Bewertung der existierenden Verfahren und Konzepte aus den jeweiligen Fachgebieten vorgenommen.

Analog zur Partitionierung in Teilprobleme in Kapitel 2 wird der Stand der Technik hinsichtlich der einzelnen Fragestellungen in Teilkapitel betrachtet. Zunächst wird in Abschnitt 3.1 beleuchtet, welche Methoden zur Bestimmung einer Relevanz existieren. In Abschnitt 3.2 wird der Stand der Technik im Bereich der (parametrisierten) simulationsbasierten Generierung von Situationen betrachtet. Abschnitt 3.3 stellt relevante Lösungen aus dem Bereich der simulativen Vorausschau sowie aus der Entscheidungstheorie dar, die das Problem der Bewertung von Maßnahmen berühren. Weiterhin werden in den Abschnitten 3.4 und 3.5 weitere Konzepte zur Anpassung der Zuordnungen sowie letztlich Effizienzsteigerung dargelegt.

### 3.1. Fortlaufende Evaluierung der Relevanz der erzeugten Situationen

Das in Abschnitt 2.2 definierte Problem, eine Vergleichsmöglichkeit von Situationen zur Menge der bereits erzeugten zu entwickeln, wurde in verschiedenen Bereichen der künstlichen Intelligenz betrachtet. Ausgehend von der Gültigkeit des Analogieschlusses nimmt die Definition einer Ähnlichkeit eine entscheidende Rolle in dem Aufbau zahlreicher Verfahren ein, da die dadurch ermöglichten Schlüsse essentiell sind.

Im Case Based Reasoning (CBR) etwa, das aus vier Phasen besteht, werden beim *Retrieve* und *Reuse* bei Auftreten einer neuen Klassifizierungsaufgabe möglichst ähnliche bekannte

Beispiele bestimmt [AP94]. Hierbei wurden zahlreiche unterschiedliche Ähnlichkeitsmetriken untersucht [Cun09].

Es existieren Verfahren, die Strukturen innerhalb der bekannten Beispiele betrachten. Dabei müssen die Beispiele nicht nur als Vektor  $\in \mathbb{R}^n$  vorliegen, sondern etwa in eine definierte Hierarchie eingeordnet sein. Beispielen innerhalb einer Hierarchiestufe würden dann eine höhere Ähnlichkeit zugeordnet werden. Da solche Strukturdefinitionen allerdings nicht systemunabhängig definiert werden können, werden nachfolgend ausschließlich direkte Verfahren beleuchtet. Diese betrachten zwei Vektoren  $s_1, s_2 \in S$ . Zu den direkten Verfahren wird resümiert:

„They have the advantage of being computationally efficient and are effective in most situations.“ [Cun09]

In der Anwendungsdomäne der Clusteringverfahren beispielsweise wird versucht, mehreren ähnlichen Objekten dieselbe Eigenschaft zuzuordnen, um etwa diese Menge von Objekten zusammenfassen zu können<sup>1</sup>. Das am häufigsten verwendete Verfahren lautet *k-means-Clustering* [RN09]. Während das Verfahren prinzipiell mit beliebigen Metriken funktioniert, ist die meist verwendete Ähnlichkeitsmetrik die euklidische Distanz ( $S \subseteq \mathbb{R}^n$  vorausgesetzt):

$$d_S(s_1, s_2) = \|s_1 - s_2\|_2 = \sqrt{\sum_{i=1}^n (s_{1_i} - s_{2_i})^2}$$

Die euklidische Distanz findet ebenfalls Anwendung im *anytime learning* [RG94]. Ähnlich wie in dieser Arbeit werden online Zuordnungen vorgehalten, die bei einer festgestellten Änderung von Systemparametern verworfen und offline neu generiert werden. Bei der Neugenerierung werden die Zuordnungen zu den fünf „nächsten“ Situationen zur aktuellen als Basislösung mit verwendet. Die Bestimmung dieser fünf Situationen geschieht mittels der euklidischen Distanz. Das eigentliche Kriterium, nachdem eine Neugenerierung angestoßen wird, liegt in einem statistischen Test. Die Systemparameter sind statistische Verteilungen.

Eine weitere Anwendung der euklidischen Distanz findet sich in [KK12] auf normalisierten Ereignishäufigkeiten in *many core Systemen*<sup>2</sup>. Dabei sind die Werte also ebenfalls homogen.

<sup>1</sup> Eine Anwendung findet sich in [Dör09].

<sup>2</sup> *many core Systeme* sind Computersysteme, die aus mehreren Prozessoren bestehen.

Die euklidische Distanz setzt allerdings eine Gleichgewichtung aller  $n$  Komponenten voraus. Da der kausale Zusammenhang zwischen einzelnen Komponenten einer Situationsdefinition eines konkreten Systems zur Maßnahmenwahl unterschiedlich sein kann, war eine in Kapitel 2.2 definierte Anforderung, dass eine Gewichtung möglich ist.

Die Mahalabonis Distanz stellt die Verallgemeinerung der euklidischen Distanz dar, bei der diese Gewichtung möglich ist:

$$d_S(s_1, s_2) = \sqrt{(s_1 - s_2)^T C^{-1} (s_1 - s_2)}$$

Die Gewichtung erfolgt anhand der Matrix  $C \in \mathbb{R}^{n \times n}$ . Falls  $C$  die Identitätsmatrix ist, entspricht die Mahalabonis Distanz gerade der euklidischen Distanz.

Die Mahalabonis Distanz wird im Clustering klassischerweise dazu verwendet, eine lineare Korrelation zwischen den Komponenten der Situationen herauszurechnen, indem  $C$  gleich der Kovarianzmatrix der Differenz der beiden Argumente der Metrik gesetzt wird [YL10]. Bildlich gesprochen entspricht dies der Umrechnung von ellipsenförmigen Clustern in 2D in kreisförmige.

Es existieren zahlreiche Weiterentwicklungen, um die Mahalabonis Distanz im maschinellen Lernen anzuwenden. Dabei wird die Anpassung der Distanz auf spezielle Anwendungen – wie etwa der Handschriftenerkennung [KSO<sup>+</sup>99] oder dem kontinuierlichen Navigieren eines Roboters [RS97]<sup>3</sup> – untersucht. Das Lernen der optimalen Matrix  $C$  anhand einer bekannten Datenmenge stellt einen weiteren Forschungsbereich dar [XNZ08] [KJD91]. Dabei wird etwa mit genetischen Algorithmen eine Kombination von Gewichten gesucht und schließlich bestimmt, mittels welcher sich eine bestimmte Datenmenge (Trainingsbeispiele mit bekannten Klassen) am präzisesten klassifizieren lässt.

Im Gegensatz dazu besteht in dieser Arbeit allerdings der Forschungsgegenstand darin, eine für die Domäne der Logistiksysteme allgemeingültige Metrik zu definieren, die nicht ausschließlich auf den zur Verfügung stehenden Daten basiert (siehe Abschnitt 2.2). Daher bleibt die Frage offen, wie  $C$  zu definieren ist.

Für den Bereich des CBR wird in zahlreichen Arbeiten eine Abwandlung der Hamming Distanz verwendet, die sich in einer verallgemeinerten Form wie folgt darstellt [BKI08]:

---

<sup>3</sup> In [RS97] wird die quadratische Mahalabonis Distanz verwendet.

$$d_S(s_1, s_2) = \frac{\sum_{i=1}^n w_i \cdot \text{sim}_i(s_{1_i}, s_{2_i})}{\sum_{i=1}^n w_i}$$

Dabei stellen  $w_i$  Gewichte der einzelnen Komponenten der Situationsdefinition dar,  $\text{sim}_i$  wiederum sind Distanzmaße auf den einzelnen Mengen  $S_i$  für jede Komponente. Es ist allerdings weiterhin unklar, wie die Gewichte und einzelnen Distanzmaße zu definieren sind.

Es wird das Beispiel einer Anwendung betrachtet, bei der anhand der aktuellen Situation im zu steuernden System gegebenenfalls neue Zuordnungen offline generiert werden. Es handelt sich um die Steuerung von Verkehrsampeln an Kreuzungen [PRT<sup>+</sup>08], bei denen die Situation aus dem Verkehrsstrom in Form einer reellen Zahl (Anzahl Fahrzeuge pro Stunde) pro Verkehrsrichtung besteht. Es wird für das System eine Spanne von 120 pro Dimension vorgegeben, innerhalb derer eine Zuordnung verwendet werden soll. Tritt nun eine Situation auf, für die keine passende Zuordnung vorliegt, wird diese offline mittels der Simulation generiert. Online wird die Manhattan Distanz verwendet, um die nächstliegende Zuordnung zu bestimmen:

$$d_S(s_1, s_2) = \sum_{i=1}^n |s_{1_i} - s_{2_i}|$$

Die Autoren nutzen dabei den Umstand aus, dass die Situation aus homogenen Komponenten (den Verkehrsflüssen) besteht. Eine Gewichtung oder Skalierung einzelner Komponenten entfällt daher.

Die Hamming Distanz erfüllt in den Grundzügen die Anforderungen an die Metrik, wie sie in Abschnitt 2.2 aufgelistet sind. Es lassen sich die einzelnen Komponenten gewichten. Allerdings ist unklar, wie die Gewichte zu wählen sind, ohne ausschließlich die bereits generierten Zuordnungen zu betrachten. Weiterhin ist offen, wie die einzelnen Funktionen der Komponenten  $\text{sim}_i$  auszugestalten sind, sodass eine breite Verwendung für die Domäne der Logistiksysteme gewährleistet ist bzw. eine leichte Anpassung durch den Anwender ermöglicht wird.

Unter denjenigen Verfahren, die eine Ähnlichkeitsmetrik zur Bestimmung der Notwendigkeit einer Neugenerierung verwenden, wird meist vom Anwender ein Schwellenwert vorgegeben. Ein Übertreten des Abstandes von aktueller Situation zur nächsten zeigt dann

die Notwendigkeit an. Ein automatisiertes Verfahren zur Bestimmung eines Schwellenwertes existiert nicht. Dabei ist anzumerken, dass in vielen der betrachteten Anwendungen eine Ähnlichkeitsmetrik zur Zuordnung einer Situation zu einer endlichen Menge an möglichen abstrakteren Zuständen verwendet wird, also kein Schwellenwert notwendig ist.

## 3.2. Simulationsmodellbasierte Generierung von Situationen

Das Prinzip, bei einer Steuerung komplexe Berechnungen in eine offline Phase auszulagern und deren Ergebnisse online zu verwenden, findet in zahlreichen Arbeiten Anwendung [SFN08] [KY04] [Auf11]. Speziell der Einsatz von parametrisierten Simulationsmodellen zur Evaluierung von möglichen Handlungsalternativen unter Berücksichtigung des aktuellen Systemzustandes ist dabei seit einigen Jahren Forschungsgegenstand [PRT<sup>+</sup>08] [RG94].

Der Einsatz einer parametrisierten Simulation zur fortlaufenden Lösungsgenerierung und Anpassung wird in [BMMS<sup>+</sup>06] in Form eines allgemeinen Frameworks beschrieben (Abbildung 3.1). Dabei dient der sogenannte Observer zur Aufbereitung und Vorhersage von wahrgenommenen Sensordaten aus dem System. Die Daten werden in Form einer Situation von einem zweistufigen Controller verarbeitet, indem auf der ersten Stufe online eine Maßnahme (hier “action” genannt) anhand der Wissensbasis (hier “rule base”) ausgewählt wird. Auf der zweiten Stufe wird offline die Situation in das Simulationsmodell überführt und gegebenenfalls die Wissensbasis angepasst<sup>4</sup>.

Eine ähnliche mehrstufige Architektur ist in [FGK<sup>+</sup>04] unter dem Namen Operator-Controller-Modul (OCM) beschrieben (Abbildung 3.2). Hier arbeitet der sogenannte Kognitive Operator anhand von Simulation oder auch anderen Optimierungsmethoden offline, während der darunterliegende Reflektorische Operator online funktionieren muss.

In [SMSÇ<sup>+</sup>10] wird eine Theorie der Selbstanpassung beschrieben. Situationen kommen darin als Attribute eines Systemzustands  $\vec{z}(t)$  in einem Situationsraum  $Z$  vor. Es werden Ereignisse der Umwelt beschrieben, die das System in einen Folgezustand  $\Delta\vec{z}(t)$  bringen. Es wird eine Menge von Zielzuständen beschrieben. Eine Steuerung ist dann adaptiv, wenn es möglich ist, nach einem Ereignis wieder in einen Zielzustand zu kommen.

---

<sup>4</sup> Es wird in diesem Kontext der Begriff des „Organic Computing“ genannt, da durch die Architektur Eigenschaften wie Selbstanpassung aus der Natur übernommen werden.

In [LGM<sup>+</sup>13] werden im Rahmen eines Frameworks Komponenten für selbstanpassende Steuerungen beschrieben, die für die Umsetzung für ein konkretes System entwickelt werden müssen. Für die Implementierung des hier sogenannten observation cluster muss danach definiert werden, welche Informationen gemessen werden sollen:

„What information about the external environment and about the system itself will need to be measured or estimated?“




Abbildung 3.1.: Darstellung des allgemeinen Organic Computing Frameworks [MSSU11]

In der Literatur existieren allerdings keine hinreichenden Kriterien oder Definitionen, die die Parameter und Situationen in einer Art beschreiben, um einem Anwender bei der Auswahl bezüglich eines konkreten Systems zu unterstützen.

Für die jeweiligen Systeme, die gesteuert werden, wurden allerdings in zahlreichen Arbeiten Systemparameter ausgearbeitet. Einige sollen daher nachfolgend reflektiert werden, um Gemeinsamkeiten hinsichtlich einer zu erarbeitenden allgemeingültigen Definition darzule-

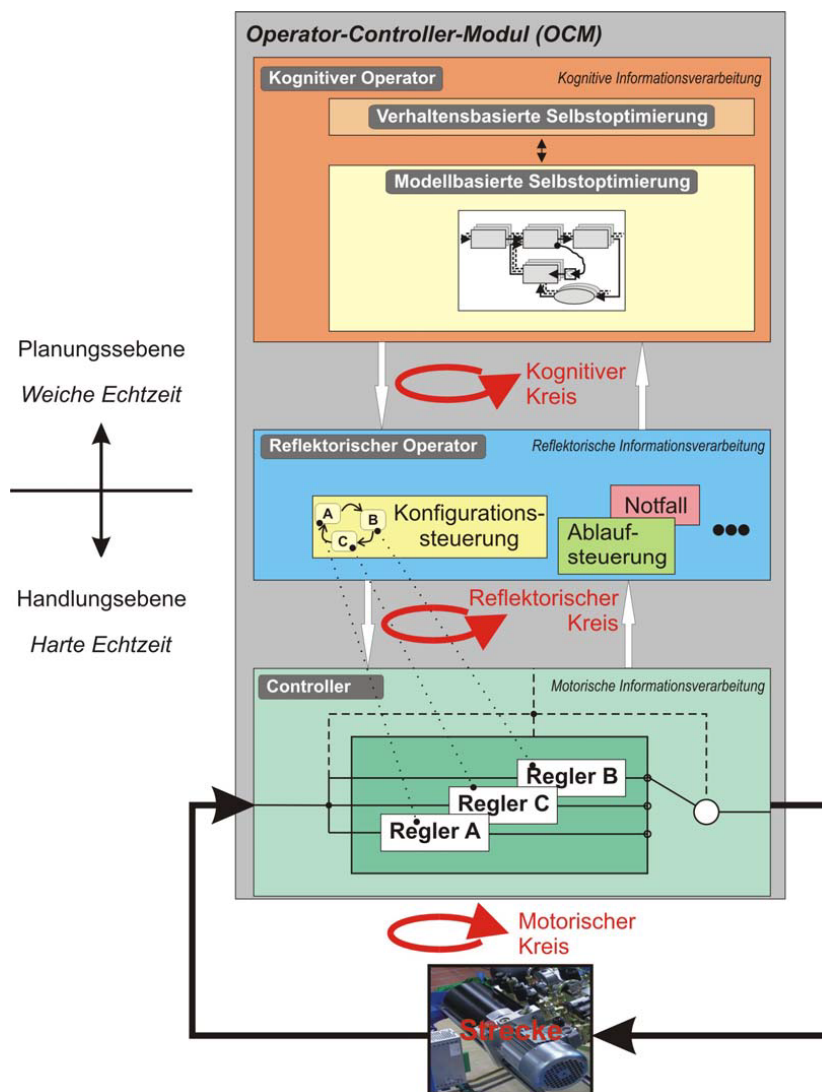


Abbildung 3.2.: Darstellung des Operator-Controller-Moduls [OHG04]

gen. Dabei wird speziell aufgezeigt, ob in bisherigen Arbeiten zwischen Systemparametern für die Modellkalibrierung und Situationen für die online Steuerung unterschieden wird.

Für die Antriebssteuerung von mobilen Arbeitsmaschinen am Beispiel eines Traktors wurde ein situationsbasiertes und simulationsgestütztes Verfahren entwickelt [KWM<sup>+</sup>10]. Es werden Maßnahmen mit dem Ziel des effizienten Betriebes und der damit einhergehenden Spritersparnis anhand der aktuellen Nutzung ausgewählt. Die Nutzungsmodi sind bei mobilen Arbeitsmaschinen sehr vielfältig, die dynamische Auswahl von Maßnahmen bei Bedingungen wie etwa Transport oder Pflügen verspricht daher hohe Ersparnisse. Die Situationsdefinition enthält die aktuelle Geschwindigkeit, das Drehmoment des Nebenab-

triebs<sup>5</sup> sowie weitere ähnliche Komponenten. Die Maßnahmen bestehen aus dem Setzen von Soll-Kurbelwellendrehzahl oder der Differenzialsperre. Falls eine Situation auftritt, zu der keine Zuordnung existiert, wird diese in ein Simulationsmodell in der Software AMESim überführt [KGW13] und eine Maßnahme zugeordnet<sup>6</sup>. Es werden dabei nicht direkt die Situationen zugewiesen, sondern diese mittels einer statistischen Analyse mit Zuständen wie Transport verknüpft. Falls sich eine Situation nicht zu einem der (in der Anzahl recht geringen) bekannten Zuständen zuordnen lässt, wird ebenfalls die Simulation aufgerufen. Die Systemparameter entsprechen also einem Zustand, der repräsentativ für eine Menge von Situationen ist.

Für die Steuerung von „many-core“ Computern<sup>7</sup> wurde das Konzept ebenfalls angewendet [KK12]. Anstelle einer Simulation bewertet die Steuerung die Maßnahmen allerdings in einer Lernphase anhand des tatsächlichen Systems. Es wird also davon ausgegangen, dass innerhalb der Lernphase ausreichend viele Situationen erlernt werden können, sodass im Betrieb zu jeder Situation eine hinreichend ähnliche bekannt ist. Die Situationen bestehen aus Kennzahlen wie „Cache-Misses“<sup>8</sup>. Als Maßnahmen kann die Prozessorfrequenz verändert werden oder auch die Auftragsreihenfolge geändert werden. Wie bei dem Verfahren im vorherigen Beispiel werden nicht alle Situationen direkt zugeordnet, sondern mittels Clustering erkannten repräsentativen Situationen, den Clustermittelpunkten. Es wird nicht zwischen Systemparametern und Situationen unterschieden.

Zur Steuerung von Druckluftstationen wurde ebenfalls ein situationsabhängiges simulationsbasiertes Verfahren entwickelt [WF11]. Die Maßnahmen bestehen aus dem Festlegen von Ober- und Untergrenzen von Drücken, ab bzw. bis zu denen Kompressoren eingeschaltet werden. In einer Spanne von einem Bar werden in Abständen von 50 mbar Grenzen definiert, sodass sich ca. 20 Maßnahmen ergeben. Die Situation besteht aus dem Zustand einzelner Kompressoren, die zu einer Druckluftstation zusammengeschaltet sind, dem aktuellen Druck in einem Zwischenspeicher sowie dem Druckluftverbrauch. Es wird für jede Situation und für jede Maßnahme ein Simulationslauf online durchgeführt und die beste Maßnahme ausgeführt. Dabei wird von einer sehr hohen Geschwindigkeit der Simulation

---

<sup>5</sup> Ein Nebenantrieb wird auch PTO (power take-off) oder Zapfwelle genannt. Er ermöglicht die Übertragung von mechanischer Antriebsenergie auf angeschlossene Geräte wie etwa Mähbalken [Eic99].

<sup>6</sup> Die Zuordnung geschieht hier mittels eines genetischen Algorithmus.

<sup>7</sup> Ein „many-core“ Computer ist ein Verbund von vielen einzelnen Prozessoren.

<sup>8</sup> Rechnerarchitekturen verwenden zur Beschleunigung schnelle Zwischenspeicher von Daten, auch Caches genannt. Bei einem Cache-Miss liegt ein für die aktuelle Berechnung benötigter Wert nicht im Cache und muss zeitaufwendig aus dem Hauptspeicher geladen werden.



(Faktor 10000 zur Echtzeit) ausgegangen. Weitere Parameter fließen nicht in die Simulation ein – es wird nicht zwischen Systemparametern und Situationen unterschieden.

Eine weitere Anwendung findet sich in der Steuerung von Robotern, die sich mittels vier Beinen bewegen können [BZL06]. Es wird speziell die Fähigkeit umgesetzt, sich bei Änderungen am Roboter, wie der Verlust eines Beines, an diese anzupassen und damit kontinuierlich eine hohe Leistung zu erzielen. Mittels eines parametrisierbaren Simulationsmodells des Roboters kann die Steuerung nämlich Maßnahmen unter den neuen Umständen bewerten und folglich die beste ausführen. Eine Situation besteht dabei aus sämtlichen Inputdaten wie Kamerabildern oder Zielkoordinaten, während die Maßnahmen aus dem Einstellen der Winkel der einzelnen Gelenke bestehen. Die Systemparameter, die auch in das Simulationsmodell überführt werden, sind die Verteilung der insgesamt acht Glieder auf die vier Beine<sup>9</sup>. Die Systemparameter sind hier also unabhängig von den Situationen.

Zur Validierung des Konzeptes des anytime learning wurde es in folgendem abstraktem Szenario angewendet (Abbildung 3.3): Ein beweglicher „Jäger“ (mit C dargestellt) mit Position und Rotation verfolgt ein Ziel (mit M dargestellt). Das Ziel bewegt sich dabei im Normalzustand zufällig, weicht aber dem Jäger aus, sobald sich dieser nähert. Die Steuerungssituation des Jägers besteht aus der eigenen Rotation, der Geschwindigkeit und der Rotation des Ziels sowie des Abstandes zum Ziel. Die Maßnahme liegt in der Manipulation der eigenen Geschwindigkeit sowie Rotation, um das Ziel zu „fangen“. Die Maßnahmen werden offline in einer Simulation bewertet. Die Systemparameter sind hier Durchschnitt und Varianz der Geschwindigkeit des Ziels. Hier gibt es also den Zusammenhang zwischen Systemparameter und Situation, dass der Wert des Systemparameters beeinflusst, welche Situationen auftreten werden. In der Situation ist die fluktuierende, aktuelle Geschwindigkeit enthalten, während im Systemparameter stabilere, sich langsam ändernde Durchschnittswerte enthalten sind.

Für die Steuerung von Verkehrsampeln ist das Konzept aufgrund des ständig fluktuierenden Verkehrsaufkommens gut geeignet und wurde in [PRT<sup>+</sup>08] angewendet. Eine Situation besteht hier aus je einer Kennzahl pro Verkehrsrichtung an der zu steuernden Kreuzung, die die Anzahl an Fahrzeugen pro Stunde angibt. Die Maßnahmen sind verschiedene Strategien zur Beschaltung der Verkehrsampel, etwa ein Phasenwechsel nach festen Zeiten. Auch

---

<sup>9</sup> Im Normalzustand besteht jedes der vier Beine aus je zwei Gliedern, es können aber auch Beine aus keinem bis hin zu acht Gliedern existieren.




Abbildung 3.3.: Darstellung des Jägerszenarios zur Validierung des anytime learning [GRR92]

möglich ist ein Phasenwechsel nach dynamischen Gegebenheiten wie erkannten wartenden Verkehrsteilnehmern, wobei beispielsweise eine minimale und eine maximale Zeit für eine Grünphase angegeben werden können. Bei Auftreten einer unbekannt Situation wird offline in einer Simulation diese nachgestellt und eine Maßnahme zugeordnet. Die Situation entspricht also dem Systemparameter.

In [KLFD11] wird eine Steuerung für das Routing von fahrerlosen Transportfahrzeugen in einem Distributionslager beschrieben. Eine Situation besteht hier aus den Positionen von zwei Fahrzeugen, deren Wege sich kreuzen und daher in Konflikt miteinander stehen, sowie deren Zielpositionen, den Positionen aller anderen Fahrzeuge im Lager und den Deadlines, also wie viel Zeit die zwei Fahrzeuge zur Verfügung haben, um ihr Ziel zu erreichen. Die Maßnahmen sind hier Prioritätsregeln, nach denen die Fahrzeuge ihre Wege umplanen. Die Maßnahmen werden in einer Simulation bewertet, die als Parameter eine Lastverteilung sowie die Anzahl an verfügbaren Fahrzeugen erhält. Ähnlich wie beim Jägerszenario des anytime learning beeinflussen die Systemparameter hier die Situationen, da etwa bei zahlreichen Einlagerungen innerhalb eines kurzen Zeitraumes viele Konflikte an den Laderampen vorkommen. Weiterhin beeinflussen sie aber auch die Zuordnung, da etwa bei einer hohen Anzahl an verfügbaren Fahrzeugen eine andere Entscheidung zur Auflösung eines Konfliktes getroffen werden sollte.

Die technische Umsetzung der Parametrisierung oder auch Modellkalibrierung [Ric09], also das Überführen von Parametern in ein Simulationsmodell, ist durch eine Vielzahl an softwaretechnischen Möglichkeiten wie Kommandozeilenparameter oder Methodenparameter

gelöst.

Bei der Betrachtung der jeweils verwendeten Situationsdefinition in den vielfältigen Anwendungen lässt sich resümieren, dass sie Umstände abbilden, die sich innerhalb höchstens wenigen Sekunden ändern. Die einzige Ausnahme unter den dargestellten Beispielen liegt in der Verkehrssituation der Ampelsteuerung, die sich jede Stunde neu definiert, wobei auch kürzere Zeitfenster wie 15 Minuten Intervalle denkbar sind.

In drei der sechs betrachteten Anwendungen verwendet die Simulation in der offline Phase direkt die Situationen als Parameter, denen teilweise repräsentative Cluster zugeordnet werden. Dabei stellt sich ein rein reaktives Verhalten ein. Zu einer neu auftretenden Situation existiert zunächst keine Zuordnung, diese steht erst beim nächsten Auftreten zur Verfügung. Es existieren dabei verschiedene Anforderungen an die Steuerung. So existieren bei der Traktorsteuerung etwa nur begrenzt viele Zustände, die immer wieder eingenommen werden. Das Auftreten einer neuen Situation wird als relativ selten angenommen.

In zwei Anwendungen, dem Jägerszenario des anytime learning sowie dem Routing Verfahren, werden nicht direkt die Situationen in die Simulation überführt. Stattdessen werden Durchschnittswerte, die beeinflussen, welche Situationen auftreten werden sowie wie diese zugeordnet werden, verwendet. Dadurch lässt sich mittels Überführen einer Parameterausprägung eine Menge von Situationen zuordnen. Die verwendeten Parameter ändern sich langsamer als die Situationen.

Bei der Steuerung von Robotern bestehen die Parameter ebenfalls aus langfristig sich verändernden Werten, nämlich der Konfiguration der Beine. Diese beeinflussen die Zuordnung von Situationen zu Maßnahmen, in diesem Fall allerdings nicht, welche Situationen auftreten werden. Die Änderung im Systemparameter, ein physischer Schaden am Roboter, wird hier als unvorhersagbar und plötzlich angenommen.

Die entwickelten Frameworks für situationsbasierte simulationsgestützte Steuerungen bilden den verwendeten Rahmen des Verfahrens in dieser Arbeit ab. Es wird ebenfalls in [SMSC<sup>+</sup>10] ein Situationsraum ähnlich wie in dieser Arbeit definiert. Allerdings fehlt eine hinreichend genaue Definition, wie Situationen oder Parameter für die Simulation zu wählen sind.

Der Umgang mit redundanten Attributen in der Situationsdefinition wird in [GRR92] beschrieben. Es wird dabei die Maßnahmenzuordnung so gestaltet, dass ähnliche Zuordnungen als Ausgangspunkt dienen, sodass die Änderung von redundanten Attributen

keine neue Zuordnung bewirkt. Zudem werden gewichtete Metriken diskutiert, die für redundante Attribute ein geringes Gewicht bestimmen (siehe Abschnitt 3.1). Die Verfahren werden explizit so gestaltet, dass redundante Attribute möglichst geringe Auswirkungen haben. Diese Maßnahmen sind aber für den Anwender nicht transparent, er würde also nicht erkennen, dass ein redundantes Attribut verwendet wird, um es zu entfernen.

### **3.3. Simulative Vorausschau zur Evaluierung von Alternativen**

Bei Betrachtung der in den vorherigen Abschnitten vorgestellten Steuerungsverfahren kann resümiert werden, dass keines eine simulative Vorausschau im Sinne der Problemstellung umsetzt. Dies liegt daran, dass bei sämtlichen Systemen keine längerfristigen Effekte zu der Maßnahmenwahl existieren. Bei logistischen Systemen hingegen, beispielsweise bei der Lagerplatzwahl während einer Einlagerung, sind diese vorhanden. Aus diesem Grund verwenden die simulationsbasierten Steuerungen nur kurze Zeithorizonte. Der Einfluss von Unsicherheiten ist dann ebenfalls geringer und wird daher nicht berücksichtigt.

Eine weitergehende simulative Vorausschau lässt sich allerdings als eine spezielle Art der Szenariokonstruktion betrachten, die in der stochastischen Programmierung, einem Teilbereich des Operations Research [KW94], der Spieltheorie [Pap85] sowie der Entscheidungstheorie [Sch01] Anwendung findet. Im Allgemeinen werden zukünftige Entwicklungen als Graphen dargestellt, bei denen die Knoten Zuständen entsprechen und Kanten die Ausführung von Maßnahmen oder das Eintreten von Unsicherheiten. Von einem Zustand können dabei mehrere Kanten ausgehen, die die entsprechenden nichtdeterministischen möglichen Folgezustände angeben. Den Kanten kann dabei in Form von Gewichten eine Wahrscheinlichkeit zugewiesen werden.

Diese Modellierungsform scheint für eine situationsbasierte Steuerung gut geeignet zu sein, da das Eintreten einer Situation leicht mit dem Begriff eines Zustandes in Einklang zu bringen ist. In der Simulation könnte jede Kante, die den Betriebsablauf dann zwischen zwei Situationen darstellt, gezielt ausgeführt werden.

Um die Anzahl an zu betrachtenden Knoten zu reduzieren, wurde im Teilbereich der stochastischen Programmierung die Methode des Sample Average Approximation (SAA) entwickelt [KSM02]. Dabei werden entsprechend der Wahrscheinlichkeiten entlang der

Kanten zufällige Entwicklungen als Probe entnommen und betrachtet. SAA entspricht also dem Ansatz einer Monte Carlo Simulation. Für SAA konnte gezeigt werden, dass sich mit steigender Probengröße eine Konvergenz zum Ergebnis bei Betrachtung aller Szenarien ergibt [KSM02].

Zur Reduzierung von zu betrachtenden Knoten wurde in der Spieltheorie das sogenannte „Alpha-Beta Pruning“ entwickelt [RN09]. Es handelt sich um ein Verfahren aus der Klasse der Branch and Bound Algorithmen [LD60]. Grundsätzlich wird bei einem Knoten der maximale Nutzen aller Folgeknoten im Teilbaum abgeschätzt und damit eine obere Schranke definiert. Es kann dann unter Umständen festgestellt werden, dass die Betrachtung eines Teilbaumes das Endergebnis nicht mehr beeinflussen kann und somit reduziert sich die effektive Anzahl der Knoten. Das Verfahren hängt dabei stark von der verwendeten Heuristik ab, die die Schranke zu einem Teilbaum berechnet.

Die Ausführung einer Maßnahme führt zu mehreren Szenarien mit jeweiligen Nutzenwerten. Es stellt sich dann die Frage, wie diese Werte zu einem einzelnen Wert aggregiert werden sollten. Dies ist eine fundamentale Frage in der Entscheidungstheorie [Lau05] [Sch01], es handelt sich speziell um das Problem der Entscheidung unter Unsicherheit bzw Risiko<sup>10</sup>.

Eine naive Bewertungsfunktion ist der Erwartungswert  $\mu$  einer Maßnahme  $m_j$

$$B(m_j) = \mu_j = \sum_{i=1}^n p(v_{j_i}) \cdot N(v_{j_i})$$

mit den resultierenden Folgezuständen  $v_{j_i}$ , den zugeordneten Wahrscheinlichkeiten  $p(v)$  und Nutzen  $N(v)$ . Der Erwartungswert erfüllt allerdings nicht die in der Problemstellung gestellten Anforderungen, da es etwa nicht möglich ist, eine Risikoaversität anzunehmen.

Das Kriterium von Hodges-Lehmann wurde zu diesem Zweck entwickelt [Lau05]: Zur Bewertung einer Maßnahme  $m_j$  wird zunächst der Erwartungswert des Nutzens der resultierenden  $n$  Zielknoten berechnet:

$$\mu_j = \sum_{i=1}^n p(v_{j_i}) \cdot N(v_{j_i})$$

<sup>10</sup> Eine Entscheidung unter Risiko liegt vor, wenn dem Entscheidungsträger die Eintrittswahrscheinlichkeiten der verschiedenen möglichen Ergebnisse bekannt sind. Bei einer Entscheidung unter Unsicherheit sind diese nicht bekannt. Allerdings ist es in der Realität nicht immer möglich, objektive Wahrscheinlichkeiten anzugeben. Dafür können aber meistens subjektive Wahrscheinlichkeiten bestimmt werden, die tendenziell ausdrücken, bei welchen Ereignissen von einer größeren Eintrittswahrscheinlichkeit ausgegangen wird als bei anderen [Endr07-79].

Dazu wird das ungünstigste Ergebnis  $v_{j_k}$  bestimmt, sodass gilt:

$$N(v_{j_k}) = \min_i N(v_{j_i})$$

Die Werte werden mit einem Vertrauensparameter  $q$  mit  $0 \leq q \leq 1$  gewichtet und es ergibt sich als Bewertungsfunktion die gewichtete Summe

$$B(m_j) = q \cdot \mu_j + (1 - q) \cdot N(v_{j_k})$$

Je größer  $q$  ist, desto mehr Einfluss hat der Erwartungswert und je kleiner  $q$  ist, desto mehr hat das ungünstigste Ergebnis Einfluss auf die Entscheidungsfindung. Je risikofreudiger der Entscheidungsträger ist, desto größer wird er  $q$  wählen und entsprechend kleiner, je risikoaverser er ist. Als Vorteil dieses Kriteriums kann angesehen werden, dass durch die Wahl eines kleineren Wertes für den Vertrauensparameter  $q$  der Einfluss der gegebenenfalls abweichend geschätzten Eintrittswahrscheinlichkeiten verringert wird. Es wird sowohl versucht, einen gewissen Mindesterfolg abzusichern, indem das schlechteste Ergebnis negativ in die Bewertung einfließt, als auch den größtmöglichen Erwartungswert anzustreben.

Beim  $\mu - \rho$ -Prinzip [Lau05] wird nicht nur der Erwartungswert  $\mu_j$  betrachtet, sondern auch die Streuung der verschiedenen Handlungsergebnisse um diesen Wert herum. Allerdings fließen lediglich die unerwünschten negativen Abweichungen nach unten in die Betrachtung ein, die positiven Abweichungen nach oben hingegen nicht:

$$\rho_j = \sum_{i=1}^n p(v_{j_i}) \cdot (\max(0, \mu_j - N(v_{j_i})))^2$$

Die Bewertungsfunktion ist dann:

$$B(m_j) = \mu_j + q \cdot \rho_j^2$$

Dabei bewirkt der Faktor  $q < 0$  ein einstellbar risikoscheues Entscheiden, da so neben dem Erwartungswert ein mögliches negatives Abweichen in die Gewichtung einfließt. Für den Parameter  $q = -0,75$  ergeben sich daraus beispielsweise die in Tabelle 3.1 aufgeführten Nutzen. Der risikoscheue Entscheider, der möglichst wenig Abweichung vom zu erwartenden Ergebnis möchte, würde also nach dem  $\mu - \rho$ -Prinzip  $m_1$  wählen [Sch01].

Da nur die Abweichung vom Erwartungswert in eine Richtung in die Berechnung eingeht, wird ausschließlich das Risiko einer Verschlechterung minimiert und nicht das Risiko einer allgemeinen (eventuell auch positiven) Änderung. Resultierend werden die Maßnahmen positiv bewertet, deren Ergebnisse wenig Abweichungen ins Negative beinhalten und somit eine gewisse Sicherheit liefern.

Beide Entscheidungsregeln erfüllen die gestellten Anforderungen.

Gewichtete Ergebnisse		Ausprägungen der Unsicherheiten			Erwartungswert	Semivarianz	Bewertung
		$v_{j_1}$	$v_{j_2}$	$v_{j_3}$			
$p(v_{j_i})$		0,5	0,3	0,2	$\mu_j$	$\rho_j^2$	$B(m_j)$
Maßnahmen	$m_1$	10	3	5	6,9	5,29	<b>2,93</b>
	$m_2$	7	2	8	5,7	4,11	2,62

Tabelle 3.1.: Beispiel der Bewertung von Maßnahmen nach dem  $\mu - \rho$ -Prinzip

### 3.4. Anpassung der Zuordnungen

Zur frühzeitigen Antizipation von Irrelevanz, die in dieser Arbeit entwickelt werden soll, ist die Identifikation geeigneter Prognosetechniken notwendig.

Die Prognose findet sich in unzähligen Wissenschaften und Bereichen wieder. Es gehört zum Selbstverständnis der Forschung, aus vergangenen Daten und Informationen zukünftige Ereignisse vorhersagen zu wollen. Aus diesem Grund existiert auch eine große Menge von Verfahren, die von allgemeinen Analysen bis hin zu sehr spezifischen Problemen diverse Vorhersagen ermöglichen. Die Frage der Qualität, d. h. ob eine bestimmte prognostizierte Erwartung wirklich eintritt, ist dabei sehr schwankend und hängt sowohl von den Eingabedaten als auch von der verwendeten Prognosetechnik ab [Lew74].

Es soll in diesem Abschnitt eine geeignete Methode identifiziert werden, die automatisiert anhand des bisherigen Systemparameterverlaufes  $(p_t), t \leq t_0$  eine Prognose  $(p_t), t > t_0$  für die Zukunft erstellt.

Eine Betrachtung der in den vorherigen Abschnitten vorgestellten Steuerungsverfahren ergibt, dass eine langfristige Prognose von Systemparametern nicht umgesetzt wurde. Dies liegt einerseits an einer fehlenden Notwendigkeit, da oft nur ein sehr begrenzter

Systemparameterraum angenommen wird, sodass ein häufiges Auftreten neuer Parameterwerte nicht möglich ist. Weiterhin ist die Generierung von neuen Zuordnungen in den Arbeiten schneller möglich, als es in dieser Arbeit aufgrund der simulativen Vorschau angenommen wird. Ein Leistungsverlust aufgrund von Änderungen wäre daher bei einer reaktiven Steuerung nur von kurzer Dauer.

Die betrachteten Steuerungsverfahren erstellen dennoch kurzfristige Prognosen, die allerdings direkt in der Klassifizierung der Situationen verwendet werden: Bei der Steuerung für „many-core“ Computer [KK12] wird der wahrscheinlichste Folgezustand anhand eines Markov-Modells antizipiert. Das für mobile Arbeitsmaschinen entwickelte Verfahren [WMS<sup>+</sup>10] verwendet ein künstliches neuronales Netz, um auf ähnliche Weise den nächsten Zustand zu prognostizieren. Diese Ansätze sind allerdings nicht in der Lage, längerfristige Trends zu erkennen. Für das Beispiel im Kontext von Ampelsteuerungen [STH13] versuchen die Autoren, die kommende Verkehrssituation ebenfalls mit einem künstlichen neuronalen Netz vorherzusagen. Die Entwicklung einer langfristigen Prognose wird von den Autoren in einem Ausblick angekündigt.

Es existieren zur Anwendung in vielen verschiedenen Wissenschaften zahlreiche Verfahren zur Lösung des Prognoseproblems, die in eine Taxonomie geordnet wurden [Arm01]. Eine Anweisung, zu einer Anwendung die am besten geeignete Klasse von Verfahren zu identifizieren, liefert Abbildung 3.4. Für die Prognose des zukünftigen Verlaufes der Systemparameter ergibt sich aus dem Schaubild folgende Klasse von Verfahren: Es liegen objektive quantitative Daten vor, ohne Wissen über den Zusammenhang der Daten untereinander. Diese Daten sind Zeitreihen, und bei einer allgemeingültigen Definition liegt kein Wissen über die Anwendungsdomäne vor. Es werden daher extrapolierende Verfahren empfohlen.

Zur Identifikation eines geeigneten Extrapolationsverfahrens<sup>11</sup> lässt sich die Beobachtung heranziehen, dass komplexe Verfahren in empirischen Tests allgemein keine signifikanten Vorteile gegenüber einfacheren Verfahren ergeben [Arm84]. Die exponentielle Glättung 2. Ordnung ist ein einfaches Explorationsverfahren, das die in Abschnitt 2.5.1 dargelegten Anforderungen, insbesondere das Erkennen eines linearen Trends, erfüllt. Das Verfahren wird in der Logistik bereits oft verwendet, speziell für Nachfrageprognosen [Tem06]. Bei einer industrieübergreifenden Befragung von Prognostikern wurde bestimmt, dass die

---

<sup>11</sup> Es existieren in der Zeitreihenanalyse zahlreiche Verfahren, die teilweise an ein jeweiliges Anwendungsgebiet angepasst sind [Arm84].






Abbildung 3.4.: Eine Anweisung, um zu einer Anwendung die Klasse von Prognoseverfahren zu identifizieren [Arm01]

exponentielle Glättung in der Praxis weit verbreitet ist (Abbildung 3.5).

Es existieren verschiedene Varianten der exponentiellen Glättung 2. Ordnung. Das Verfahren von Holt verwendet zwei verschiedene Parameter, um getrennt die Glättung des Trends einstellen zu können. Im Gegensatz dazu verwendet die normale exponentielle Glättung 2. Ordnung nur einen Parameter, mit dem gleichermaßen Trend und Niveau behandelt werden [Tem06]. Zur Identifikation des geeigneten Modells wird die Beobachtung herangezogen, dass bei ausschließlichem Vorliegen eines linearen Trends die normale Glättung in empirischen Tests besser abschneidet [GD80]. Zudem vereinfacht die Definition nur eines Parameters ihre Anwendung. Für die allgemeingültige Verwendung in logistischen Systemen ist die Verwendung der exponentiellen Glättung 2. Ordnung daher gut geeignet.

Die hier vorgestellte Gleichung ist die Entwicklung von Brown [Mer12]:




Abbildung 3.5.: Befragung von Prognostikern zum verwendeten Verfahren [Cro10]

$$a_t^* = x_t^* + (1 - B^2)(x_t - x_t^*)$$

$$b_t^* = b_{t-1}^* + ((1 - B)^2)(x_t - x_t^*)$$

$$p_{t+1} = b_t^* \cdot i + a_t^*$$

Die Modell-Koeffizienten werden hierbei direkt fortgeschrieben. Dies geschieht, indem der Trendwert und der Grundwert zerlegt werden.  $a_t^*$  und  $b_t^*$  werden hierzu berechnet und in die dritte Formel, die den letztendlichen Prognosewert  $p_{t+1}$  beschreibt, eingesetzt. Bei dem ersten Schätzwert  $a_t^*$  handelt es sich um den Glättungswert erster Ordnung.  $b_t^*$  wird analog dazu berechnet. Das direkte Fortschreiben des Koeffizienten erspart den Rechenaufwand, diesen immer neu festzulegen und korrigiert so Trendabweichungen.

Es gilt  $B = 1 - \alpha$  [Mer12].  $\alpha$  wird als Gegenwartsfaktor bezeichnet und legt mit einem Wert zwischen 0 und 1 die Stärke der Glättung fest, also wie stark aktuelle Werte gegenüber vergangenen Werten gewichtet werden sollten. Ein Wert nahe 1 gewichtet dabei aktuelle Werte stärker, die Glättung nimmt ab. Die Bestimmung eines allgemeingültigen Wertes von  $\alpha$  ist eine notwendige Adaption des Verfahrens für die Zwecke in dieser Arbeit.

Für den in Abschnitt 2.5.2 dargelegten Fall, dass sich Systemparameter plötzlich ändern, existiert bei verwandten Steuerungsverfahren keine Prognosemöglichkeit. Bei der Steuerung eines Roboters [BZL06] wird die Annahme getroffen, dass die Änderung dauerhaft ist. Für den Bereich der logistischen Systeme ist diese Annahme unzutreffend.

Weiterhin setzen die existierenden Steuerungsverfahren kein Löschen von irrelevanten Zuordnungen um. Die Notwendigkeit ist nicht gegeben, da der Systemparameterraum hinreichend klein ist, was bei logistischen Systemen ebenfalls nicht gegeben ist.

### 3.5. Effizienzsteigerung einer Menge von Situation/Maßnahme Zuordnungen

Es existieren zahlreichen Verfahren, um die Anzahl an Trainingsbeispielen bei Verfahren des maschinellen Lernens zu reduzieren [AR11]. Die Forschungsfrage wurde intensiv im Kontext der „k-Nearest-Neighbor“ (KNN) Klassifikation untersucht, da hier die Laufzeit von der Anzahl an Trainingsbeispielen abhängt<sup>12</sup>.

Mittels der „Fast Condensed Nearest Neighbor Rule“ (FCNN) lässt sich eine Menge an Trainingsbeispielen auf folgende Weise reduzieren [Ang05]: Es werden Teilbereiche des Situationsraums bestimmt, die anhand der vorliegenden Zuordnungen als komplett zu einer Klasse zugehörig definiert werden können. Im Falle der FCNN sind diese Bereiche vom durch die Trainingsmenge induzierten Voronoi Diagramm vorgegeben. Die Zentren der Teilbereiche können dann als Repräsentanten für alle weiteren Trainingsbeispiele in diesem Bereich gewählt werden und sämtliche weitere werden gelöscht. Dabei ändert sich nicht die Klassifikation einer neuen Instanz.

Für die Anwendung in dieser Arbeit ist FCNN allerdings nicht direkt geeignet. Ähnlich wie bei der Betrachtung von Distanzfunktionen in Abschnitt 3.1 sollte das Verfahren zur Effizienzsteigerung nicht ausschließlich auf der verfügbaren Datenmenge basieren. Im Gegensatz zu klassischen Problemen des maschinellen Lernens existiert hier die Möglichkeit, Trainingsbeispiele zu generieren. Daher kann es im Verlauf des Betriebs vorkommen, dass innerhalb eines Teilbereiches eine neue Zuordnung generiert wird, die eine abweichende Maßnahme besitzt. In diesem Fall müsste das FCNN Verfahren die Teilbereiche neu definieren. Bereits gelöschte Zuordnungen würden in diesem Fall einen Verlust von Informationen bedeuten, die nur durch einen hohen Einsatz an Rechenzeit wiederhergestellt werden könnten. Es sollten daher beim Löschen von Zuordnungen weitere Kriterien, die zugrunde

---

<sup>12</sup> Bei der KNN Klassifikation werden neue Instanzen anhand der  $k$  nächsten Nachbarn klassifiziert. Daher hängt die Laufzeit der Klassifizierung von der Bestimmung der Nachbarn ab – der naive Algorithmus durchläuft alle Trainingsbeispiele und benötigt  $\mathcal{O}(N \cdot d)$ . Dabei ist  $N$  die Anzahl an Beispielen und  $d$  deren Dimension.

liegende Informationen über das zu steuernde logistische System beinhalten, definiert werden.

Die generierten Zuordnungen sollen für die online Klassifizierung durch Verfahren des überwachten Lernens verarbeitet werden, um eine hohe Klassifikationsgeschwindigkeit zu gewährleisten. Gleichzeitig ermöglichen es die Lernverfahren, neue Situationen optimal zu klassifizieren, indem Strukturen in den Zuordnungen aufgedeckt werden. Die folgende Betrachtung der Verfahren im Stand der Technik soll es erlauben, Voraussetzungen für die Verwendung der Zuordnungen als Trainingsbeispiele zu identifizieren.

Überwachtes Lernen arbeitet auf Trainingsdaten  $(x_i, y_i)$ , wobei  $y_i$  die Werte  $y_i = f(x_i)$  einer unbekanntes Funktion  $f$  sind [RN09]. Ziel ist es, eine Funktion  $h$  zu bestimmen, die  $f$  approximiert. Man nennt  $h$  auch Hypothese. Wird eine gute Hypothese gefunden, lassen sich anhand dieser die Werte von neuen Eingaben  $x_j$  bestimmen, ohne  $f$  zu kennen. Ergebnisse der Computer-Lerntheorie haben gezeigt, dass die Güte der Hypothese  $h$  mit steigender Anzahl an Trainingsbeispielen wächst: Sei  $\epsilon \in \mathbb{R}$  eine kleine Konstante. Dann ist  $h$  eine annähernd korrekte Hypothese, wenn  $P(h(x) \neq f(x)) \leq \epsilon$  für ein zufälliges  $x \in S$ . Dann ist die Wahrscheinlichkeit, dass eine falsche Hypothese mit  $N$  Beispielen konsistent ist:

$$\leq (1 - \epsilon)^N \xrightarrow{N \rightarrow \infty} 0.$$

Eine Hypothese, die mit vielen Trainingsbeispielen trainiert wurde, ist somit also unwahrscheinlich falsch.

Die a priori Auswahl eines Lernverfahrens aufgrund von Annahmen über das zu steuernde System ist wenig erfolgversprechend [AS06]. Vielmehr ist es notwendig, empirische Tests anhand der vorliegenden Trainingsbeispiele vorzunehmen. Ein solches Testverfahren zur Evaluierung von Lernverfahren ist die  $k$ -fache Kreuzvalidierung [RN09]. Dabei wird die Trainingsmenge in  $k$  Teilmengen zerlegt. Das Lernverfahren wird dabei anhand der  $k - 1$  Teilmengen trainiert und mit der restlichen Teilmenge getestet. Der Test wird mit jeder der  $k$  Teilmengen wiederholt und die Leistung des Lernverfahrens ergibt sich aus dem Durchschnitt aller korrekt klassifizierten Testbeispiele pro Teilmenge.

## 4. Zu leistende Arbeit

Im Folgenden wird anhand des dargelegten Standes der Technik und der Problemstellung resümiert, welche Arbeiten zu leisten sind.

Es existieren zwar in einzelnen Teilbereichen Lösungsverfahren, allerdings fehlt ein integriertes allgemeingültiges Gesamtkonzept. Bisherige Arbeiten auf dem Gebiet der simulationsbasierten Generierung von Zuordnungen sind allzu oft anwendungsspezifisch oder nehmen keine hinreichende Trennung zwischen allgemeingültigen Lösungen und spezifischen Anpassungen vor. Teilbereiche wie Prognosetechniken und Entscheidung unter Unsicherheit sind meist in diesem Kontext nicht bearbeitet worden. Dafür sind zahlreiche Lösungen für andere Bereiche der Informatik oder Wirtschaft entwickelt worden.

Die zu leistende Arbeit liegt also in der Beschreibung einer integrierten Methode zur anpassungsfähigen, simulationsbasierten Generierung von Zuordnungen. Wenn möglich, sollen allgemeingültige Verfahren entwickelt werden, um den Aufwand einer Umsetzung der Methode für eine konkrete Anwendung zu minimieren. Falls anwendungsspezifisches Wissen erforderlich ist, sollen genaue Kriterien und Voraussetzungen identifiziert werden. In einigen Teilbereichen sind geeignete Verfahren neu zu entwickeln oder aus anderen Anwendungsgebieten zu identifizieren und zu adaptieren. Konkret sind folgende Arbeiten umzusetzen.

Es sollen Berechnungsfunktionen entwickelt werden, die den Zeitpunkt der Neugenerierung von Zuordnungen bestimmen. Dabei soll eine Metrik im Situationsraum  $S$  auf Basis der in Abschnitt 3.1 dargelegten Hamming Distanz entwickelt werden, um eine Ähnlichkeit von Situationen zu quantifizieren. Konkret müssen Verfahren zur Bestimmung der Gewichtung einzelner Komponenten einer Situation sowie eines Schwellenwertes, dessen Überschreiten eine Neugenerierung anstößt, entwickelt werden.

Basierend auf den in Abschnitt 3.2 geschilderten Beobachtungen von Situationsdefinitionen in existierenden simulationsbasierten Steuerungen sollen abstrakte Definitionen von

Systemparametern und Situationen entwickelt werden. Darüber hinaus sollen Kriterien, nach denen sie in konkreten Anwendungen auszuwählen sind, dargelegt werden. Zudem soll ein Bewertungsverfahren für eine konkrete Situationsdefinition entwickelt werden, um den Benutzer bei der Adaption des Konzeptes für ein zu steuerndes System zu unterstützen.

Eine vorhandene Materialflusssimulationssoftware soll erweitert werden, um die Zuordnungen zu generieren. Dazu sind speziell die Parametrisierung eines Simulationsmodells und die Integration der Bewertungsmethode mittels simulativer Vorausschau softwaretechnisch zu entwickeln.

Aufbauend auf den in Abschnitt 3.3 dargelegten Techniken der Szenariokonstruktion in der stochastischen Programmierung, Spiel- und Entscheidungstheorie soll eine Methode entwickelt werden, um den Verlauf des zu steuernden Systems in der Simulation auch unter stochastischen Einflüssen zu modellieren. Darüber hinaus sollen Kriterien dargelegt werden, nach denen der Wirkhorizont einer konkreten Maßnahme definiert werden kann. Die in der Entscheidungstheorie entwickelten Aggregationsfunktionen mehrerer Szenarien sollen übernommen und darüber hinaus Kriterien entwickelt werden, um die Auswahl einer Aggregationsfunktion bei Anwendung des Verfahrens zu unterstützen. Ein Verfahren zur Reduzierung der Anzahl der zur Berechnung benötigten Knoten im Szenariobaum innerhalb der Simulation soll weiterhin entwickelt werden.

Die in Abschnitt 3.4 dargelegte exponentielle Glättung 2. Ordnung wurde als geeignet identifiziert. Zur Verwendung in dieser Arbeit muss ein Wert für den Glättungsfaktor  $\alpha$  bestimmt werden. Weiterhin sollen Methoden entwickelt werden, die nach Eintritt eines Ereignisses eine kurzfristige Prognose berechnen. Zudem soll ein Kriterium entwickelt werden, anhand dessen aufgrund von Veränderungen im System nicht mehr benötigte Zuordnungen gelöscht werden.

Ein Verfahren zur Minimierung der Anzahl von Zuordnungen ohne Leistungsverlust des resultierenden trainierten Klassifizierers soll entwickelt werden. Dies soll auf Basis der in Abschnitt 3.5 dargelegten Verfahren zur Auswahl von Repräsentanten eines Teilbereichs im Situationenraum geschehen.

Eine Übersicht der notwendigen Adaptionsschritte des Konzeptes zur Steuerung einer konkreten Anwendung soll erstellt werden. Durch die genaue Trennung zwischen allgemeingültigen Verfahren und anwendungsspezifischen Aspekten soll das abstrahierte Verfahren möglichst leicht für verschiedene Systeme anwendbar sein.

## 5. Konzeption

In Abbildung 5.1 sind die zu entwickelnden Komponenten abgebildet. In der Abbildung sind sie in einen Gesamtzusammenhang gesetzt. Die jeweiligen Kapitel, in denen die Komponenten dargelegt werden, sind vermerkt. Abschnitt 5.1 beschreibt die fortlaufende Evaluierung der Relevanz der erzeugten Zuordnungen anhand der auftretenden Situationen im System. Anschließend wird in Abschnitt 5.2 auf die Parametrisierung der Simulation des zu steuernden Systems eingegangen. Die innerhalb der Simulation vorgenommene Bewertung der alternativen Maßnahmen wird in Abschnitt 5.3 dargelegt. In Abschnitt 5.4 werden die Anpassung der Zuordnungen und die Prognose der Systemparameter gelöst. Schließlich wird in Abschnitt 5.5 darauf eingegangen, wie die erzeugten Zuordnungen effizient zum Zweck der späteren online Steuerung verarbeitet werden können. In Abschnitt 5.6 werden die einzelnen Schritte benannt, die zur Anwendung des dargelegten allgemeinen Konzeptes zur Steuerung eines konkreten Systems erforderlich sind.




Abbildung 5.1.: Übersicht der einzelnen Komponenten des Verfahrens

## 5.1. Fortlaufende Evaluierung der Relevanz von Situationen

Bezüglich einer im System aufgetretenen Situation  $s_a \in S = \mathbb{R}^n$  soll nun anhand der in diesem Abschnitt dargelegten Methode evaluiert werden, inwieweit die erzeugten Situationen  $S_{erz}$  relevant sind.

Es soll dazu zunächst eine Ähnlichkeitsmetrik  $d_S : S \times S \rightarrow [0,1]$  auf Basis der in Abschnitt 3.1 untersuchten Hamming Distanz entwickelt werden. Wie in Kapitel 4 erläutert, ist eine Funktion für die Ähnlichkeit einzelner Komponenten sowie deren Gewichtung erforderlich.



Innerhalb einer Komponente wird für allgemeine logistische Systeme ein linearer Zusammenhang zwischen einzelnen Werten angenommen, also dass ein Abstand zwischen zwei Werten eine proportional große Auswirkung hat. Diese Annahme stützt sich auf Beobachtungen wie beispielsweise den linearen Zusammenhang zwischen Anzahl an Maschinen und Größe der Menge an produzierten Gütern in der Produktion.

Es wird dem Anwender allerdings die Möglichkeit gegeben, für jede Komponente eine Ober- und Untergrenze vorzugeben. Differenzen zwischen den Werten werden nur innerhalb dieses Bereiches übernommen. Liegt ein Wert ober- oder unterhalb der Grenzen, wird stattdessen mit der jeweiligen Grenze gerechnet. Die Differenz wird auf den Bereich normiert. Hintergrund ist die Annahme, dass es für die Steuerung von logistischen Systemen nur einen bestimmten Bereich gibt, innerhalb dessen das System auf Änderungen sensibel reagiert. Werte über- und unterhalb des Bereiches können dagegen zusammengefasst als ein Zustand aufgefasst werden, bei dem das System über- bzw. unterfordert ist. Beispielsweise sei eine Komponente einer Situation die Anzahl an aktiven fahrerlosen Transportfahrzeugen. Für den Anwender könnte erkennbar sein, dass der Einsatz von 0-3 Fahrzeugen als ein Zustand aufzufassen, der mit „Leerlauf“ gleichbedeutend ist, während im Bereich von 3-7 Fahrzeugen eine differenzierte Steuerung erforderlich ist. Der Einsatz von mehr als 7 Fahrzeugen hingegen führt in einen Zustand jenseits der Auslegung des Systems. Der Anwender könnte nun eine Untergrenze von 3 sowie eine Obergrenze von 7 definieren. Ohne diese Grenzen wäre für die Steuerung der Unterschied zwischen 0 und 3 Fahrzeugen derselbe wie zwischen 4 und 7 Fahrzeugen (es wäre lediglich eine Differenz von 3 Einheiten erkennbar). Während im letzten Fall hinsichtlich der Steuerung ein gewichtiger Unterschied vorliegt, erfordert der erste Fall keine Reaktion. Im Sinne der Parametrisierung der Metrik, wie in Abschnitt 2.2 dargestellt, gilt also  $U = \mathbb{R}^2$ . Es ergibt sich folgende Funktion für die Ähnlichkeitsmetrik:

$$d_S(s_1, s_2) = \frac{\sum_{i=1}^n w_i \cdot \frac{|\min(i_o, \max(i_u, s_{1_i})) - \min(i_o, \max(i_u, s_{2_i}))|}{i_o - i_u}}{\sum_{i=1}^n w_i}$$

Dabei sind  $i_u$  und  $i_o$  die für die konkrete Situationsdefinition in einer Anwendung angenommenen Unter- und Obergrenzen der Komponente  $i$ . Die Differenz zwischen zwei Werten einer Komponente wird auf die Breite des Bereiches zwischen den Grenzen normiert. Ein Wert von 1 bedeutet dann minimale, ein Wert von 0 maximale Ähnlichkeit.  $w_i$  stellen die Gewichte einer Komponente dar, die zu bestimmen sind.

Mit wie viel Gewicht eine einzelne Komponente in die Entscheidung der Steuerung einfließt, ist a priori für den Anwender schwer abzuschätzen. Aus diesem Grund wird folgend eine Berechnung eingeführt, die auf den bereits erstellten Zuordnungen, ohne Einfluss des Anwenders, basiert.

Es wird aus der Informationstheorie der Begriff der Entropie verwendet. Der Begriff findet bei dem Aufbau von Entscheidungsbäumen Anwendung, um die Reihenfolge der Komponenten im Baum zu bestimmen [RN09]. Entropie beschreibt in diesem Zusammenhang die Höhe an Informationen, die eine Menge von Zuordnungen enthält. So haben Zuordnungen, die alle auf dieselbe Maßnahme abbilden, eine geringe Entropie. Man kann aus dieser Menge schließlich nur folgern, dass alle möglichen Situationen in derselben Maßnahme resultieren. Im Gegensatz dazu lassen Zuordnungen mit vielen unterschiedlichen Maßnahmen mehr Rückschlüsse zu.

Der Informationsgehalt einer Komponente lässt sich dann definieren, indem die Entropie der Teilmengen der Zuordnungen, die durch Auswahl aller möglichen Komponentenwerte innerhalb des jeweiligen Definitionsbereiches entstehen, berechnet wird. Reduziert sich die Entropie stark, „sortiert“ die Komponente die Zuordnungen gut und es hat scheinbar eine große Bedeutung bei der Zuordnung von Situation zu Maßnahme.

Sei  $Z_{erz}$  die Menge der Zuordnungen,  $i$  der Index der zu prüfenden Komponente,  $S_i$  die Menge der möglichen Komponentenwerte und  $Z_w$  die Teilmenge von  $Z_{erz}$ , für die das Attribut mit dem Index  $i$  den Wert  $w \in S_i$  annimmt.

$$\text{Informationsgehalt}(i) = \text{Entropie}(Z_{erz}) - \sum_{w \in S_i} \frac{|Z_w|}{|Z_{erz}|} \cdot \text{Entropie}(Z_w)$$

mit

$$\text{Entropie}(Z) = - \sum_{m \in M} p_Z(m) \cdot \log p_Z(m)$$

$$p_Z(m) = \frac{|\{(s,n) \in Z | n=m\}|}{|Z|}$$

für jede Teilmenge  $Z \subseteq S \times M$  mit entsprechenden Anteilen jeder Maßnahme  $p_Z(m)$  relativ zur Gesamtanzahl der Zuordnungen. Der Wertebereich eines jeden Attributes muss dazu noch entsprechend diskretisiert werden.

Es gilt dann:

$$w_i = \text{Informationsgehalt}(i)$$

Es ist zu zeigen, dass  $d_S$  auf  $S$  eine Metrik darstellt, indem Definitheit, Symmetrie und die Dreiecksungleichung nachgewiesen werden (Annahme o. B. d. A.:  $s_{1_i}$  und  $s_{2_i}$  liegen innerhalb von  $i_u$  und  $i_o$ ):

1. Definitheit:  $d_S(s_1, s_2) = 0 \Leftrightarrow s_1 = s_2$ . Annahme: Definitheit gilt nicht.  $s_1 = s_2 \Rightarrow \exists i : s_{1_i} \neq s_{2_i} \Rightarrow |s_{1_i} - s_{2_i}| > 0 \Rightarrow d_S(s_1, s_2) > 0 \not\checkmark$ . Analog für die Rückrichtung. Aus diesem Widerspruch folgt die Definitheit.
2. Symmetrie:  $d_S(s_1, s_2) = d_S(s_2, s_1)$ . Folgt aus  $|s_1 - s_2| = |-(s_2 - s_1)| = |s_2 - s_1|$
3. Dreiecksungleichung:  $d_S(s_1, s_2) \leq d_S(s_1, s_3) + d_S(s_3, s_2)$ .

$$\begin{aligned} d_S(s_1, s_2) &= \frac{\sum_{i=1}^n w_i \cdot \frac{|s_{1_i} - s_{2_i}|}{i_o - i_u}}{\sum_{i=1}^n w_i} \\ &\leq \frac{\sum_{i=1}^n w_i \cdot \frac{|s_{1_i} - s_{3_i} + s_{3_i} - s_{2_i}|}{i_o - i_u}}{\sum_{i=1}^n w_i} \\ &\quad \text{(Dreiecksungleichung in } \mathbb{R} \text{)} \\ &\leq \frac{\sum_{i=1}^n w_i \cdot \frac{|s_{1_i} - s_{3_i}| + |s_{3_i} - s_{2_i}|}{i_o - i_u}}{\sum_{i=1}^n w_i} \\ &\leq \frac{\sum_{i=1}^n w_i \cdot \frac{|s_{1_i} - s_{3_i}|}{i_o - i_u}}{\sum_{i=1}^n w_i} + \frac{\sum_{i=1}^n w_i \cdot \frac{|s_{3_i} - s_{2_i}|}{i_o - i_u}}{\sum_{i=1}^n w_i} \\ &= d_S(s_1, s_3) + d_S(s_3, s_2) \square. \end{aligned}$$

Anhand der definierten Ähnlichkeitsmetrik soll nun das binäre Entscheidungskriterium zum Anstoßen einer Neugenerierung konstruiert werden. Es ist an dieser Stelle offen, wie der anhand der Zuordnungen trainierte Klassifizierer bei Auftreten einer neuer Situation

das Klassifikationsergebnis bestimmt (siehe Abschnitt 2.6). Der Rechenweg bei den typischerweise eingesetzten subsymbolischen Verfahren ist auch nicht nachzuvollziehen. Aus diesen Gründen soll an dieser Stelle nur die Distanz zur nächsten bekannten Zuordnung betrachtet werden, da nicht klar ist, inwieweit und ob überhaupt weitere Nachbarn bei der tatsächlichen Klassifizierung berücksichtigt werden.

Es wird also auf Überschreiten eines Schwellenwertes getestet:

$$R(S_{erz}, s_a) = \min_{s_e \in S_{erz}} d_S(s_e, s_a) < d$$

Um den Schwellenwert  $d$  zu definieren, dessen Überschreiten eine Irrelevanz anzeigt, wird die minimale Distanz zwischen zwei Situationen, deren Maßnahmen sich unterscheiden, betrachtet. Es gilt:

$$S_{\text{diff}} = \{(s_1, s_2) \in S_{erz} \times S_{erz} \mid Z_{erz}(s_1) \neq Z_{erz}(s_2)\}$$

$$d = \min_{(s_1, s_2) \in S_{\text{diff}}} d_S(s_1, s_2)$$

Es wird also eine Irrelevanz angezeigt, sobald zur nächstliegenden Zuordnung eine größere Distanz vorhanden ist, als minimal zwischen zwei Situationen mit verschiedenen zugeordneten Maßnahmen liegt. In dem Fall ist nämlich anzunehmen, dass möglicherweise in der aufgetretenen Situation eine unbekannte Maßnahme optimal ist, die verschieden von der in der nächsten Situation ist. Der Klassifizierer kann in diesem Fall nicht die optimale Maßnahme kennen und die Anpassung sollte daher angestoßen werden. Aufgrund der erforderlichen Vergleiche zwischen zwei Situationen bzw. Zuordnungen ergibt sich eine Rechenzeit von  $\mathcal{O}(|S_{erz}|^2)$ .

Das Verfahren geht davon aus, dass bereits eine gewisse Anzahl an Zuordnungen existiert, anhand derer ein sinnvoller Schwellenwert berechnet werden kann. Diese Anzahl müsste so hoch sein, dass die minimale Schrittweite zwischen zwei Maßnahmenwechseln annähernd abgebildet ist. Für den praktischen Einsatz ist also eine Initialisierungsphase zu empfehlen, bei der zu jeder aufgetretenen Situation eine Zuordnung generiert wird. Diese Phase sollte dann mindestens so lange andauern, bis das System den im Normalbetrieb zu erwarteten Situationenbereich ausgefüllt hat, also in jedem Teilbereich Situationen aufgetreten sind.

## 5.2. Simulation zur Generierung der Situationen

Der Einsatz von speziell parametrisierter Simulation zum Erzeugen der Situationen wurde bereits häufig angewendet und in Ansätzen auch in abstrakten Frameworks beschrieben<sup>1</sup>. Im Folgenden soll zunächst eine sowohl praktische als auch abstrakte Definition der Parameter der Simulation dargelegt werden. In Abschnitt 5.2.2 werden für die situationsabhängige Steuerung von logistischen Systemen Kriterien und Testverfahren für die Situationsdefinition erarbeitet. Abschließend wird in Abschnitt 5.2.3 die konkrete Funktionsweise der in dieser Arbeit verwendeten simulationsmodellbasierten Generierung beschrieben.

### 5.2.1. Definition von Systemparametern als Input

Nach Definition A.13<sup>2</sup> werden die Systemparameter aus dem zu steuernden System ausgelesen, um Änderungen in der Generierung mittels Übermittlung an das parametrisierte Simulationsmodell zu berücksichtigen. Es sollen hier Kriterien ausgearbeitet werden, nach denen je nach Anwendung Systemparameter definiert werden können.

Motivation für die Berücksichtigung von Systemparametern ist die Beobachtung, dass in logistischen Systemen die Auswahl der Steuerungsmaßnahme von sich verändernden exogenen Einflüssen abhängt. Ein Beispiel ist die spezifische Systemlast wie etwa Nachfrageverhalten. Systemparameter sollen also sich langfristig verändernde Einflüsse darstellen, von denen die Zuordnung von Maßnahme zu Situation abhängt. Zudem beeinflussen Systemparameter, welche Situationen im System auftreten werden. Weiterhin sollen Systemparameter Umstände abbilden, die durch plötzlich eintretende, unvorhergesehene Ereignisse im System verändert werden können. Als Beispiel sei der Ausfall von technischen Einheiten genannt, wodurch plötzlich weniger Kapazität vorhanden ist.

Die mathematische Modellierung von Systemparametern bzw. deren Wertebereiche  $P_i$  unterliegt zunächst keinen grundsätzlichen Einschränkungen, da die Auswirkung der Systemparameter im Simulationsmodell selbst hinterlegt sein muss. Eine Transformation auf  $\mathbb{R}^n$  ist aber praktisch immer möglich und erforderlich, um Werte informationstechnisch verarbeiten zu können.

---

<sup>1</sup> siehe Abschnitt 3.2

<sup>2</sup> Seite 144

Als ein Spezialfall von Systemparametern sollen stochastische Systemparameter (siehe Definition A.14) berücksichtigt werden. Wenn ein Systemparameter Werte aus der Menge  $\Omega$  annehmen kann, ist ein stochastischer Systemparameter  $p_i : \Omega \rightarrow [0,1] \in P_i \subset F(\Omega, [0,1])$  ein Element des Funktionsraumes, der jedem Wert aus  $\Omega$  eine Wahrscheinlichkeit zuweist, mit der Bedingung:  $\sum_{\omega \in \Omega} p_i(\omega) = 1$ .

Als Beispiel sei eine Systemlast über die nächsten fünf Zeiteinheiten genannt:  $\Omega = \mathbb{R}^5$ ,  $p_i = ((2,4,4,3,2), 50\%), ((2,3,5,6,7), 50\%)$ . Es gibt hier zwei Möglichkeiten, die zu je 50% angenommen werden. Die simulationsmodellbasierte Generierung sollte dabei die entstehenden Situationen unter beiden Möglichkeiten ausgeben, da nur kurzfristig eine der beiden tatsächlich eintritt.

### 5.2.2. Definition von Situationen als Output

Situationen stellen nach Definition A.4<sup>3</sup> eine Steuerungsnotwendigkeit dar. Eine Situationsdefinition besteht aus Merkmalen, die einen für die Maßnahmenauswahl relevante Ausschnitt  $s$  des Systemzustandes  $z$  darstellen. Es kann daher jedem Zustand  $z$  eine Situation  $s$  zugewiesen werden. Dem Klassifizierer stehen ausschließlich die in den Merkmalen enthaltenen Informationen für die Maßnahmenauswahl zur Verfügung.

In Abgrenzung zu Systemparametern beschreibt eine Situation sich kurzfristig verändernde Umstände im System. Dazu gehören auch Umstände, die sich durch Ereignisse ändern können.

Da Systemparameter und Situationen Einfluss auf die Maßnahmenauswahl haben, ergibt sich die Anforderung, dass  $P \times S \rightarrow M$  funktional ist, d. h. dass unter bestimmten Systemparametern eine Situation eindeutig bestimmt, welche Maßnahme zu wählen ist. Da an den Klassifizierer allerdings nur die Situationen, nicht aber Parameter übergeben werden, ergibt sich auch, dass  $Z_{erz} : S_{erz} \rightarrow M$  funktional sein muss. Daraus folgt die Notwendigkeit, beim Generieren der Zuordnungen zu berücksichtigen, unter welchen Systemparametern diese erfolgten und auf weitere Gültigkeit zu prüfen.

Durch die Trennung von Systemparametern und Situationen ergibt sich ein wesentlich kleinerer Situationsraum  $S$ , was beim Lernen und Klassifizieren die Rechenzeit verkürzt. Zudem lassen sich die Systemparameter getrennt leichter prognostizieren, da sie geringere

---

<sup>3</sup> siehe Seite 143

zufällige Fluktuationen enthalten als die Situationen. Bei der Situationsdefinition einer konkreten Anwendung ist es also für den Modellierer wichtig, zu erkennen, wovon die Maßnahmenauswahl abhängt. Dabei ist anzumerken, dass im Zweifel mehr Merkmale als notwendig in die Definition einfließen sollten, da irrelevante Merkmale durch die Lernverfahren erkannt werden können und bei der Klassifikation dann weniger Einfluss auf die Entscheidung haben werden.

Eine Situation muss als Element des  $\mathbb{R}^n$  darstellbar sein, um sie maschinell verarbeiten zu können. Für die Ähnlichkeitsmetrik (siehe Abschnitt 5.1) ist es notwendig, pro Komponente eine vermutete Ober- und Untergrenze, innerhalb deren sich die Werte voraussichtlich bewegen werden, anzugeben.

### Bewertungsverfahren für die Situationsdefinition

Um a posteriori nach Generieren der Zuordnungen eine Situationsdefinition bewerten zu können, wird folgendes Verfahren definiert:

1. Test auf fehlende Merkmale anhand Duplikatsuche:

$Z_{erz}$  wird auf Duplikate bezüglich eines Schwellenwertes  $\epsilon \in \mathbb{R}^+$  getestet:

$$\exists s_1 \in S_{erz}, s_2 \in S_{erz} : d_S(s_1, s_2) < \epsilon \wedge Z_{erz}(s_1) \neq Z_{erz}(s_2)$$

Existieren zwei Situationen, die laut der in Abschnitt 5.1 definierten Metrik eine hohe Ähnlichkeit besitzen (dementsprechend einen Funktionswert der Metrik unterhalb des definierten Schwellenwertes), sollte diesen gemäß den Grundannahmen des Verfahren die gleiche Zuordnung zugewiesen werden. Falls Duplikate vorhanden sind, bedeutet dies, dass außerhalb der Situationsdefinition relevante Merkmale existieren. Es sind Umstände in der Simulation abgebildet, die Einfluss auf die Maßnahmenbewertung und -auswahl haben, aber nicht in der Situationsdefinition abgebildet sind. Die Situationsdefinition ist damit nicht hinreichend. Weitere Merkmale müssen identifiziert und hinzugefügt werden.

2. Test auf redundante Merkmale:

Es werden drei alternative statistische Verfahren definiert, anhand derer der Anwender Hinweise auf redundante Merkmale in der Situationsdefinition erhalten kann.

- a) Bewertung der einzelnen Merkmale nach Einfluss auf die Maßnahmenauswahl mittels des in Abschnitt 5.1 eingeführten Begriffes des Informationsgehalts:

Attribute mit geringem Informationsgehalt haben demnach für sich allein genommen eine geringe kausale Wirkung auf die Maßnahmenwahl und können eventuell entfernt werden. Dabei muss beachtet werden, dass ein Attribut auch nur in Kombination mit anderen Attributen einen Informationsgehalt besitzen kann.

- b) Bewertung der einzelnen Merkmale mittels des Permutationsverfahren anhand eines Random Forest:

Das Random Forest Verfahren beschreibt die Klassifizierung anhand mehrerer Entscheidungsbäume (dem Random Forest), die anhand einer zufällig ausgewählten Teilmenge der Merkmale der Trainingsbeispiele erstellt werden [Bre01]. Bei der Klassifizierung werden die Ergebnisse mehrerer Bäume anstatt eines einzelnen betrachtet. Es lässt sich nun eine Bewertung eines Merkmals vornehmen, indem die Werte des Attributes in den Trainingsbeispielen durch zufällige Werte ersetzt werden und diese Trainingsbeispiele mittels des Random Forests klassifiziert werden. Bei einem Attribut mit einem hohen Einfluss auf die Klassifikationsgüte sollte sich diese bei dieser Permutation verringern. Aufgrund der Einschränkung auf eine zufällige Teilmenge der Attribute bei jedem Baum ist auch sichergestellt, dass jedes Attribut in dem Random Forest für eine gewisse Anzahl an Entscheidungen herangezogen wird. Die Differenzen aus den Klassifikationsgütern bilden die Bewertung, den sogenannten „Raw Score“. Durch die praxisnahe Berechnung wird auch berücksichtigt, ob ein Merkmal nur in Kombination mit anderen innerhalb eines Baumes wirkt.

- c) Faktoranalyse:

Die explorative Faktoranalyse ist ein Verfahren der multivariaten Statistik und dient der Entdeckung zugrundeliegender sogenannter latenter Variablen – den Faktoren – hinter empirischen Beobachtungen [NW06]. Es wird nach einer Menge von Faktoren gesucht, deren Anzahl geringer ist als die der Variablen, aber dennoch die Variablen als Linearkombination der Faktoren darstellbar sind. Übertragen auf die Situationsdefinition bedeutet dies, dass die Menge an



Merkmale durch eine kleinere Menge ohne bzw. mit geringem Informationsverlust ersetzt werden könnte. Um eine Situationsdefinition zu testen, würde die Zuordnungsmenge einer Faktoranalyse unterzogen werden. Die Analyse verläuft in mehreren Schritten, bei dem hier besonders der Schritt der sogenannten Faktorextraktion relevant ist. Dabei wird geschätzt, wie viele Faktoren ausreichen, um die Variablen darzustellen. Für Details wird auf [NW06] verwiesen. Ergibt die Schätzung einen weit geringeren Wert als die Anzahl der Merkmale, ist dies ein Hinweis auf redundante bzw. korrelierte und damit abhängige Merkmale. Eine Voraussetzung für die Anwendung der Faktoranalyse sind intervallskalierte Merkmale [Sti99].

### 5.2.3. Simulationsaufbau

Das parametrisierte Simulationsmodell wird unter den gegebenen Parametern durch den Simulationskern  $d^3fact$  [DL07] geladen und zum Generieren der Zuordnungen wird der Ablauf des zu steuernden Systems simuliert.  $d^3fact$  ist ein diskreter Ereignissimulator, sodass zum Simulieren Ereignisse auf einer Zeitschiene in Form einer PriorityQueue abgelegt werden und in zeitlicher Reihenfolge abgearbeitet werden. Innerhalb eines solchen Ereignisses kann es dann zu einer Situation  $s$  kommen. In dem Moment wird die in Abschnitt 5.3 entwickelte Bewertungsmethode aufgerufen, eine Maßnahme  $m$  ausgewählt und auch ausgeführt. Die Zuordnung  $(s, m)$  wird dann in der Menge der erzeugten Zuordnungen  $Z_{erz}$  abgelegt. Die Simulation beendet sich, wenn eine vordefinierte Simulationszeit erreicht ist.

Die Simulation ermöglicht es, eine konkrete Ausprägung der betrachteten Unsicherheiten<sup>4</sup> auszuführen. Wenn weitere nichtdeterministische Vorgänge im Simulationsmodell hinterlegt sind<sup>5</sup>, wird die Simulation bis zum Erreichen einer gegebenen maximalen Rechenzeit in einer Endlosschleife neu gestartet, da bei jedem Durchlauf leicht andere Situationen auftreten.

Es wird bei jeder Situation ein Vergleich zu den bisher zugeordneten Situationen  $S_{erz}$  vorgenommen, um nicht unnötigerweise ein zweites Mal eine Maßnahme zuzuordnen.

---

<sup>4</sup> Siehe Abschnitt 2.4.1

<sup>5</sup> Da in logistischen Systemen meist ein gewisser Nichtdeterminismus vorhanden ist, ist dies der typische Fall.

## 5.3. Simulative Vorausschau zur Evaluierung von Alternativen

In der Generierung von Zuordnungen soll nun zu einer Steuerungssituation  $s$  die Maßnahme bestimmt werden, die unter den möglichen mit dem höchsten Nutzen behaftet ist. Dabei sollen, wie in Abschnitt 2.4 beschrieben, die Maßnahmen hinsichtlich ihrer Auswirkung auf das zu steuernde System in der Simulation bewertet werden. Zudem soll ihre Leistung unter möglichen zukünftigen Verläufen berücksichtigt werden, die zum Entscheidungszeitpunkt nicht deterministisch vorhersagbar sind.

In Abschnitt 5.3.1 wird eine Struktur zur Darstellung der zukünftigen Entwicklungen aufgezeigt. In Abschnitt 5.3.2 wird die Bewertung einer Maßnahme anhand dieser Struktur entwickelt.

### 5.3.1. Zukunftsgenerierung aufgrund von alternativen Maßnahmen und Unsicherheiten

Basierend auf den in Abschnitt 3.3 erläuterten Darstellungsformen von Szenarien wird folgend eine Modellierung für die situationsabhängige Steuerung unter verschiedenen Entwicklungen dargelegt.

Die Zukünfte lassen sich als Zustandsraumgraphen  $G = (V, A)$ <sup>6</sup>, speziell als Baum<sup>7</sup>, darstellen. Ein Knoten  $v \in V$  ist dabei definiert als  $v := (z, s, t) \in (Z, S, \mathbb{R}_{\geq 0})$ , also als der Zustand des Systems (auch allgemeine Situation), der zugehörigen Steuerungssituation (siehe Abschnitt 5.2.1) und einer Simulationszeit  $t \in \mathbb{R}_{\geq 0}$ , die relativ zur Ausgangssituation definiert wird. Diese stellt als  $v_0 = (z_0, s_0, 0)$  die Wurzel des Graphen dar. Abbildung 5.2 illustriert den Zustandsraumgraphen.

Für jede in  $s$  ausführbare Maßnahme  $m \in M$  entsteht nun ein Kindknoten, der durch eine gerichtete Kante  $a \in A$  mit dem Elternknoten verbunden wird. Das System wird nach Anwendung der Maßnahme zu einem Zeitpunkt  $t_1$  in die nächste Steuerungssituation  $s_1$  kommen. Der Kindknoten kann somit durch Simulation bestimmt werden, indem der aktuelle Simulationszustand kopiert wird und die Simulation gesteuert unter verschiedener

<sup>6</sup> Mit Knotenmenge  $V$  und Kantenmenge  $A$

<sup>7</sup> Der Graph kann keinen Zyklus enthalten, da zeitliche und kausale Zusammenhänge repräsentiert werden.




Abbildung 5.2.: Skizze des Zustandsraumgraphen

Maßnahmenanwendung fortgeführt wird. Die Zeitpunkte der Kindknoten können, je nach Definition einer Steuerungssituation, verschieden sein, d. h. je nach Maßnahme wird das System zu verschiedenen Zeitpunkten in die nächste Steuerungssituation geraten.

Beim iterativen Aufbau des Baums wird innerhalb der Simulation entschieden, ob in der gegebenen Steuerungssituation ein zu definierender Zielzustand erreicht wurde. Die Definition eines Zielzustandes hängt mit der Bewertung der Maßnahmen zusammen und wird in Abschnitt 5.3.2 erläutert. Ein Knoten, der einem Zielzustand entspricht, ist im Zustandsraumgraphen dann ein Blatt und besitzt keine Kinder.

Im Folgenden soll die Beschreibung um die Berücksichtigung der in Abschnitt 2.4.1 dargelegten Formen von Unsicherheit erweitert werden und stellt die Grundlage für die in Abschnitt 5.3.2 beschriebenen Bewertungsmethoden dar.

### Zukunftsgenerierung unter Unsicherheit

Der Zustandsraumgraph wurde bisher unter der Annahme entwickelt, dass alle Maßnahmen wie geplant umgesetzt werden können und keine nichtdeterministischen Einflüsse im

System existieren. Aufgrund der Tatsache, dass die Maßnahmen je nach Ausprägung dieser nichtdeterministischen Einflüsse eine unterschiedliche Güte besitzen können, sind sie bei der Bewertung zu berücksichtigen und sollen deshalb in dem Baum der Zukünfte enthalten sein.

Bisher wurde davon ausgegangen, dass zu einer Situation  $s_0$  zum Zeitpunkt  $t_0$  bei Anwendung einer Maßnahme deterministisch die Folgesituation  $s_1$  zum Zeitpunkt  $t_1$  resultiert. Bei Berücksichtigung der Unsicherheiten lässt sich die Bestimmung der Folgeknoten wie folgt beschreiben.

Zu einer Anwendung wird eine Relation  $W$  bestimmt, die zu einer Situation, einer Maßnahme, stochastischer Systemparameter, einem Ereignis bzw. dessen Nichteintritt sowie der vergangenen Zeit Wahrscheinlichkeiten für Folgeknoten angibt:

$$W \subseteq (V \times M \times RP \times (E \cup \bar{E}) \times \mathbb{R}_{>0}) \times (V \times [0,1])$$

Dabei *kann* der Wert für  $W$  in die Bewertung der Maßnahmen einfließen. Da der Wert keine perfekte Information sein kann, ist es der Bewertungsfunktion überlassen, inwiefern er berücksichtigt werden soll.

Abbildung 5.3 illustriert den resultierenden Baum. In dem Beispiel sind für eine Maßnahme  $m_1$  die aus den Unsicherheiten resultierenden Kanten und Nachfolgesituationen abgebildet. Ausgehend von der Wurzel, kann das Ereignis  $e_1$  eintreten. Zudem kann ein stochastischer Systemparameter mit dem Wertebereich  $P_i$  die Ausprägung  $p_{i_1}$  oder  $p_{i_2}$  annehmen. Daraus resultieren bei Anwendung der Maßnahme  $m_1$  vier mögliche Nachfolgezustände, deren Eintrittswahrscheinlichkeiten durch die  $W$  Relation angegeben werden. Es gilt in dem Beispiel etwa  $(v_0, m_1, p_{i_2}, e_1, t_1), (v_1, 85\%) \in W$ . Die einzelnen Typen von Unsicherheit hängen von verschiedenen Komponenten der linken Seiten der  $W$  Relation ab, können also hinsichtlich einzelner Komponenten konstant sein. So kann etwa die Eintrittswahrscheinlichkeit eines Ereignisses von der Maßnahme abhängen, muss es aber nicht.

Einen Spezialfall stellen dabei kontinuierliche Wahrscheinlichkeitsverteilungen von Ereignissen bezüglich der vergangenen Zeit dar. Diese werden hier hinsichtlich der vergangenen Zeit bis zur nächsten Steuerungssituation bei Nichteintritt des Ereignisses diskretisiert. In dem Beispiel aus Abbildung 5.3 etwa fließt die Eintrittswahrscheinlichkeit bei Eintreten von  $p_{i_1}$  nach  $t_1$  Zeiteinheiten in  $W$  ein.




Abbildung 5.3.: Skizze des Zustandsraumgraphen bei Anwendung der Maßnahme  $m_1$  mit Berücksichtigung von Unsicherheiten

Es lässt sich folgende Notation für die Eintrittswahrscheinlichkeit aus der  $W$  Relation zwischen zwei Knoten definieren:

$$p(v_i, v_j) := \{r | \exists m, p_{i_j}, t, e : ((v_i, m, p_{i_j}, e, t), (v_j, r)) \in W\}$$

Ausgehend von einem Knoten  $v_i$  gilt für jede Maßnahme  $m_j$  mit je  $n$  Folgeknoten  $v_{j_1}, \dots, v_{j_n}$ , dass die Summe der Wahrscheinlichkeiten der Folgeknoten 1 ergibt:

$$\sum_{k=1}^n p(v_i, v_{j_k}) = 1$$

Die hier dargestellte Baumstruktur erlaubt es, die Auswirkungen einzelner Szenarien kontrolliert zu untersuchen und etwa den worst case bei Anwendung jeder Maßnahme zu betrachten. Weitere stochastische Prozesse innerhalb der Simulation, deren einzelne Ausprägungen nicht kontrolliert untersucht werden müssen, aber die dennoch einen nicht zu vernachlässigbaren Einfluss auf das Ergebnis haben, lassen sich mittels des in Abschnitt 3.3 erläuterten Sample Average Approximation (SAA) berücksichtigen. Dabei wird jeder Pfad innerhalb des Baumes mehrfach simuliert und der Nutzen eines Zielknotens ergibt sich aus dem Mittelwert der einzelnen Durchläufe.

SAA könnte anstatt der expliziten Modellierung von Ausprägungen von Unsicherheiten im Baum verwendet werden, indem von der Wurzel aus die Simulation bis zu einem Zielknoten mehrmals durchgeführt wird. Der Vorteil der expliziten Modellierung liegt

allerdings darin, dass die Auswirkung einer Maßnahme unter bestimmten Szenarien kontrolliert durchgeführt werden kann. Dies führt letztlich zu einer reduzierten Rechenzeit, da Zwischenergebnisse genutzt werden können. Zudem kann die Maßnahme unter einem angenommenen worst case sicher bewertet werden, während bei einem SAA Einsatz dieser nur mit einer bestimmten Wahrscheinlichkeit, abhängig von der Anzahl an Durchläufen und definierten Eintrittswahrscheinlichkeiten, eintreten wird.

An jedem Knoten ist es möglich, einzelne Nachfolgeknoten in der Simulation zu generieren, sodass auch nicht alle Knoten an die folgende Bewertungsmethode explizit übergeben werden müssen. Laut Problemstellung in Abschnitt 2.3 ist dies aufgrund einer zu hohen Anzahl an Knoten nicht möglich. Die folgende Betrachtung unterstreicht dies:

Sei  $n_e$  die Anzahl der möglichen Ereignisse,  $n_r$  die Anzahl der Ausprägungen stochastischer Systemparameter,  $n_M$  die Anzahl möglicher Maßnahmen,  $n_s$  die durchschnittliche Anzahl sonstiger stochastischer Ausprägungen pro Kante,  $t_s$  die durchschnittliche Dauer zwischen zwei Steuerungssituationen und  $t_g$  der durchschnittliche Betrachtungszeitraum einer Maßnahme. Dann ist die Anzahl der Knoten<sup>8</sup> im Baum  $(n_M \cdot n_e \cdot n_r \cdot n_s)^{t_s/t_g+1} - 1$ .

### 5.3.2. Bewertung der alternativen Maßnahmen

Die mittels des Baums der Zukünfte dargestellten Szenarien bei Anwendung einer Maßnahme sollen nun zur Auswahl der in der Ausgangssituation als optimal angesehenen Maßnahme führen. In diesem Abschnitt werden die einzelnen notwendigen Schritte zur Bewertung beschrieben.

Dazu ist zunächst zu definieren, wann ein Knoten als Zielknoten und damit als Blatt gilt. Diese Bestimmung hängt mit dem angenommenen Wirkzeitraum einer Maßnahme im System zusammen und ist wiederum bei jeder Anwendung und jeder Maßnahme verschieden. Die folgende Auflistung stellt Kriterien auf, nach denen die Definition eines Zielknotens vorgenommen werden kann.

- Bewertung der Situation nach einer festen Zeit  $t_f$  (Abbildung 5.4):

Diese Definition ist sinnvoll, wenn kausale Zusammenhänge im System zur Auswahl einer Aktion klar begrenzt sind und sich über immer gleiche Zeiträume erstrecken. Ein

<sup>8</sup> Dabei wird davon ausgegangen, dass höchstens ein Ereignis zwischen zwei Steuerungssituationen eintritt und der gleichzeitige Eintritt von mehreren extrem unwahrscheinlich und somit vernachlässigbar ist.




Abbildung 5.4.: Statischer Zeithorizont. Ausgehend von jeder Ursprungssituation, wird immer  $t_f$  betrachtet.




Abbildung 5.5.: Situationsabhängiger Zeithorizont. Ausgehend von einer Ursprungssituation  $s$ , wird  $T(s)$  betrachtet.




Abbildung 5.6.: Dynamischer Zeithorizont. Unabhängig vom Zeitpunkt der Ursprungssituation, wird der Zeitraum bis zum Eintreten bestimmter Umstände betrachtet.

Beispiel ist die Auswahl einer Maßnahme für eine Periode, ohne dass die Leistung des Systems von der bisherigen Leistung abhängt<sup>9</sup>. Ein Knoten ist dann ein Zielknoten, wenn seine Zeit  $t \geq t_f$  ist.

- Bewertung der Situation nach einer in Abhängigkeit von der Ausgangssituation bestimmten Zeit (Abbildung 5.5):

Ähnlich zur Bewertung nach einer festen Zeit kann die zeitliche Dauer kausaler Zusammenhänge zur Maßnahmenauswahl begrenzt werden, ist hier aber nicht immer gleich. Es wird mittels einer Funktion  $T : S \rightarrow \mathbb{R}$  bestimmt, wie groß die Dauer ist und ein Knoten ist dann ein Zielknoten, wenn seine Zeit  $t \geq T(s)$  bei einer Ausgangssituation  $s$  ist.

- Dynamische Definition, unabhängig von der vergangenen Zeit seit der Ausgangssituation (Abbildung 5.6):

Falls der Wirkzeitraum einer Maßnahme bis zum Eintreten bestimmter Umstände in dem System besteht, sollte ein Knoten auf diese Umstände geprüft werden und anhand dessen als Zielknoten deklariert werden können<sup>10</sup>. Ein Beispiel hierfür ist die Auswahl einer Heuristik zum Routen von Fahrzeugen zu einer Position  $x$ . Die Auswahl der Heuristik hat nach Erreichen aller Fahrzeuge der Position  $x$  keine Auswirkung mehr, weshalb bei Erreichen des Umstandes „Alle Fahrzeuge an der Position  $x$ “ ein Knoten als Zielknoten deklariert wird.

Den mittels einer der drei Definitionstypen deklarierten Zielknoten (und allen anderen Knoten) werden nach Optimierungsziel der Maßnahmen Nutzen  $N : V \rightarrow \mathbb{R}$  zugeordnet. Die Nutzenfunktion ist wiederum anwendungsspezifisch. Es können bei Mehrzieloptimierung auch gewichtete Einzelziele in die Funktion einfließen.

### Zugeordnete Eintrittswahrscheinlichkeiten von Zielknoten

Es soll nun anhand der bereits definierten Wahrscheinlichkeiten von Folgeknoten pro Maßnahme auf jeder Ebene eine Eintrittswahrscheinlichkeit pro Zielknoten zugeordnet werden. Diese leitet sich aus der bereits erfolgten Definition der Wahrscheinlichkeit von Übergängen

<sup>9</sup> Vernachlässigbar kleine Abhängigkeiten können existieren.

<sup>10</sup> Es müsste garantiert werden, dass die Umstände in endlicher Zeit erreicht werden oder dass die Bewertungsmethode nach endlicher Zeit einen Knoten auch ohne Erreichen der Umstände als Zielknoten deklariert, um nicht in eine Endlosschleife zu geraten.



zwischen zwei Knoten  $p(v_i, v_j)$  ab. Auf dem Pfad von Wurzel zu einem Zielknoten muss allerdings noch beachtet werden, dass an jeder unter der Wurzel liegenden Ebene, also in einer in der Zukunft liegenden Steuerungssituation, die folgende Maßnahmenauswahl zu bestimmen ist. Hierbei ist zu entscheiden, ob die Maßnahmenwahl ausschließlich von den im Baum zur Verfügung stehenden Informationen abhängt oder Knoten außerhalb, also noch weiter in der Zukunft, für die Entscheidung notwendig sind. Die Maßnahmenwahl kann dann entweder als deterministisch oder stochastisch angesehen werden.

Im ersten Fall kann innerhalb der laufenden Bewertung die Maßnahme zur zukünftigen Situation bestimmt werden. Damit im Baum alle benötigten Informationen enthalten sind, muss der Wirkzeitraum der Maßnahmenauswahl von der Wurzel aus zu einem früheren oder gleichen Zeitpunkt enden, wie von allen anderen Knoten im Baum. Dies ist einerseits der Fall, wenn ein dynamischer Wirkzeitraum (siehe Seite 60) verwendet wird. Dann endet der Wirkzeitraum bei Eintreten des definierten Kriteriums in der Simulation, unabhängig vom ursprünglichen Knoten und damit für die Wurzel und alle anderen Knoten gleichermaßen. Bei einem vom Ausgangsknoten abhängigen Wirkzeitraum muss folgende Bedingung erfüllt sein, um die Maßnahmenauswahl ebenfalls deterministisch bestimmen zu können:

$$\begin{aligned} &\text{Für Knoten } v_1 = (z_1, s_1, t_1) \text{ und } v_2 = (z_2, s_2, t_2), \text{ o.B.d.A.} \\ &t_1 \leq t_2 : t_2 - t_1 + T(s_2) \leq t_1 + T(s_1). \end{aligned}$$

Die Bedingung besagt, dass der Wirkzeitraum der Maßnahme, die in der späteren Situation  $s_2$  angewendet wird, zum gleichen oder einem früheren Zeitpunkt als der Wirkzeitraum zur Situation  $s_1$  endet. Dann liegen die Wirkzeiträume aller Maßnahmen innerhalb des Wirkzeitraums der Wurzel, und die Bewertung der Maßnahmen lässt sich rekursiv für Knoten in unteren Ebenen durchführen.

Falls allerdings die Maßnahmenbewertung von Informationen jenseits des von der Wurzel aus betrachteten Wirkzeitraums abhängt, muss an jedem Knoten die Maßnahmenauswahl als nichtdeterministisch angenommen werden. Zusätzlich zu den bisher definierten Unsicherheit bezeichnet dann  $p_{m_j}(v_i)$  die Wahrscheinlichkeit, dass einem Knoten  $v_i$  ausgehend die Maßnahme  $m_j$  ausgewählt wird. Es wird gefordert, dass  $\sum_j p_{m_j}(v_i) = 1$  ergibt. Bei rekursiver Auswahl der Bewertung und Bestimmung der Auswahl auf unteren Ebenen ergibt sich dann für die ausgewählte Maßnahme  $m_w$   $p_{m_w}(v_i) = 1$ , für alle  $j \neq k$   $p_{m_j}(v_i) = 0$ .

Die zugeordnete Eintrittswahrscheinlichkeit  $p$  eines Zielknotens  $v_{z_i}$  kann dann anhand der Wahrscheinlichkeiten der Kanten auf dem jeweiligen Pfad  $(v_0, v_1, \dots, v_n, v_{z_i})$  von der

Wurzel zum Zielknoten, sowie der Wahrscheinlichkeiten der Maßnahmenauswahl  $p_{m_j}(v)$  mit  $m_j$  als Maßnahme die im Pfad von Knoten  $v_j$  zu  $v_{j+1}$  führte, bestimmt werden:

$$p(v_{z_i}) = p(v_n, v_{z_i}) \cdot \prod_{k=0}^{n-1} p_{m_k}(v_k) \cdot p(v_k, v_k + 1)$$

Pro Maßnahme erhält man schließlich einen Teilbaum mit einer Menge von Zielknoten  $v_{z_i}$ , die bei Anwendung der Maßnahme eintreten. Anhand dieser Menge an Zielknoten und deren zugeordneten Nutzen und Eintrittswahrscheinlichkeiten wird die Maßnahme bewertet.

Im Falle der rekursiven Anwendung und damit bestimmter Maßnahmenauswahl auf unteren Ebenen ergeben sich zahlreiche Zielknoten mit Eintrittswahrscheinlichkeit  $p(v_{z_i}) = 0$ , die damit nicht betrachtet werden müssen. Abbildung 5.7 illustriert die Auswahl bestimmter Zielknoten innerhalb eines Baumes. Die orange markierten Pfade stellen die deterministische Maßnahmenauswahl auf jeder Ebene aufgrund rekursiver Anwendung des Verfahrens dar, sodass nur die markierten Zielknoten mit den angegebenen Wahrscheinlichkeiten  $p > 0$  in die Bewertungsfunktion einfließen. Es kann auf jeder Ebene diejenige Maßnahme bestimmt werden, die der Situation zugeordnet wird und daher mit Sicherheit, d. h. deterministisch, ausgewählt werden würde.

Die Anzahl an Zielknoten, die in die Bewertung einfließen, lässt sich wie folgt berechnen: Ohne Einschränkungen, also bei nichtdeterministischer Maßnahmenauswahl auf unteren Ebenen, sind es  $(n_M \cdot n_e \cdot n_r \cdot n_s)^{t_s/t_g}$ . Die rekursive Anwendung der Bewertung führt zu einer Reduzierung auf  $(n_e \cdot n_r \cdot n_s)^{t_s/t_g}$ . Ohne Betrachtung von Unsicherheiten führt die rekursive Anwendung auf  $(1)^{t_s/t_g} = 1$ . Die rekursive Anwendung des Verfahrens erlaubt auch direkt die Zuordnung aller Situationen auf dem Pfad zur Maßnahme, sodass gleichzeitig  $n$  Zuordnungen erstellt werden und nicht nur die zur Wurzel gehörige.

### **Bewertungsfunktion einer Maßnahme**

Anhand der pro Maßnahme  $m_j$  im jeweiligen Teilbaum  $n$  resultierenden Zielknoten  $v_{j_i}$  mit zugeordneten Nutzen  $N(v_j)$  und Eintrittswahrscheinlichkeiten  $p(v_j)$  soll nun mittels einer zu definierenden Bewertungsfunktion  $B : M \rightarrow \mathbb{R}$  die Maßnahme bewertet werden.




Abbildung 5.7.: Skizze der Maßnahmenteilbäume bei rekursiver Anwendung des Verfahrens mit resultierenden Zielknoten mit positiven Eintrittswahrscheinlichkeiten

Die Bewertungsfunktion soll berücksichtigen, dass die Anwendung einer Maßnahme je nach Eintritt der stochastischen Einflüsse Ereignisse, Ausprägungen stochastischer Systemparameter und allgemeiner stochastischer Prozesse zu verschiedenen Nutzen führt. Mittels Gewichtung der einzelnen Nutzen der Zielknoten soll eine Gesamtbetrachtung erfolgen.

Es werden im Folgenden zwei Bewertungsfunktionen definiert, die je nach Anwendung nach bestimmten dargelegten Kriterien verwendet werden sollten.

### Anwendung des Kriteriums von Hodges und Lehmann

Das in Abschnitt 3.3 identifizierte Kriterium von Hodges und Lehmann soll zur Maßnahmenbewertung adaptiert und zudem Kriterien für die Anwendung gegeben werden.

In der Anwendung des Kriteriums ist es sinnvoll, Zielknoten mit einer sehr geringen zugeordneten Eintrittswahrscheinlichkeit (unter 0,1%) auszuspüren, damit unrealistische und sehr negative Szenarien das Ergebnis nicht zu stark beeinflussen. Schließlich existieren neben den betrachteten Unsicherheiten noch andere „Katastrophenfälle“ (Stromausfall z. B.), die ebenfalls nicht betrachtet werden.

Das Kriterium ist für Anwendungen heranzuziehen, bei denen die Werte der Eintrittswahrscheinlichkeiten als unsicher angesehen werden und damit nur gering gewichtet in die Bewertung einfließen sollen (durch Wahl eines geringen  $q$ ), oder wenn der Fokus auf dem sicheren Vermeiden eines einzelnen sehr schlechten Falles liegen soll.

Die Bewertungsfunktion kann direkt übernommen werden und es ergibt sich für eine Maßnahme  $m_j$  bei dem schlechtesten resultierenden Knoten  $v_{j_k}$ :

$$B(m_j) = q \cdot \mu_j + (1 - q) \cdot N(v_{j_k})$$

### Anwendung des $\mu - \rho$ -Prinzips

Als alternative Bewertungsfunktion für bestimmte Arten von Systemen wird das  $\mu - \rho$ -Prinzip (siehe Abschnitt 3.3) adaptiert.

Das  $\mu - \rho$ -Prinzip eignet sich für zu steuernde Systeme mit relativ viel Unsicherheit und damit pro Maßnahme einer hohen Anzahl an Zielknoten. Im Gegensatz zum Kriterium von Hodges und Lehmann werden nämlich nicht nur einzelne, sondern sämtliche Ergebnisse mit negativen Abweichungen berücksichtigt. Ein weiteres Argument für die Anwendung des  $\mu - \rho$ -Prinzips liegt vor, wenn die Eintrittswahrscheinlichkeiten als relativ sicher angesehen werden können, da sie etwa aus Herstellerangaben stammen oder mit viel Erfahrungswerten begründet sind. Schließlich fließen sie hier ohne einstellbares Vertrauen in die Berechnung ein.

Die resultierende Bewertungsfunktion ist

$$B(m_j) = \mu_j + q \cdot \rho_j^2$$

mit

$$\rho_j = \sum_{i=1}^n p(v_{j_i}) \cdot (\max(0, \mu_j - N(v_{j_i})))^2$$

Aufgrund der Werte der jeweiligen Bewertungsfunktion wird nun eine Maßnahme  $m_j$  mit Index  $j$  ausgewählt und ausgegeben:

$$\arg \max_j B(m_j)$$

Es sei an dieser Stelle angemerkt, dass ein wesentlicher Vorteil der Bewertungsmethode darin liegt, dass sie unabhängig vom konkreten Problem mittels der simulativen Vorausschau funktioniert. Es muss also kein spezieller Lösungsalgorithmus vorhanden oder implementiert sein.

### Rechenzeit der Bewertung

Zur Berechnung der Bewertungsfunktion müssen zunächst alle  $(n_M \cdot n_e \cdot n_r \cdot n_s)^{t_s/t_g}$  Knoten des Baumes in der Simulation ermittelt werden, sodass insbesondere bei hohen Zeithorizonten oder bei viel Unsicherheit eine unpraktikable Rechenzeit selbst für die offline Phase entsteht.

Im Folgenden werden drei Methoden dargelegt, die die Rechenzeit des Verfahrens verbessern: das Durchsuchen des Baumes mittels gesteuerter Suche (ohne Verlust an Ergebnisqualität), Pruning (ggf. mit Verlust an Ergebnisqualität) sowie Parallelisierung (ohne Verlust an Ergebnisqualität).

Bei der gesteuerten oder informierten Suche werden die Knoten des Baums in einer bestimmten Reihenfolge durchsucht, um die Maßnahmenbewertung bereits vornehmen zu können, bevor alle Knoten berechnet wurden.

Ohne Berücksichtigung von Unsicherheit kann hier direkt eine modifizierte Breitensuche angewendet werden. Dabei werden die bekannten Kindknoten der aktuellen Ebene nicht wie bei einer Breitensuche in einer FIFO Queue sortiert, sondern in einer PriorityQueue, die nach Kosten sortiert wird. Auf diese Weise wird der frühestmögliche Zielknoten gefunden und alle zeitlich nachfolgenden Zielknoten werden nicht bearbeitet. Das Verfahren ist auch als Uniform-Cost Search bekannt und in Algorithmus 1 dargestellt. *frontier* bezeichnet dabei die PriorityQueue. In Zeile 5 wird dabei anhand der dargestellten Definitionstypen für Zielknoten abgefragt, ob der aktuelle Knoten ein Zielknoten ist.

---

#### Algorithmus 1 : Suche nach dem Zielknoten mit höchstem Nutzen

---

OptimalNodeSearch(SimZustand wurzel):

```

1  frontier.add(wurzel)
2  while TRUE
3      if frontier.isEmpty() then return NULL
4      node = frontier.pop()
5      if node.isGoal() then return node
6      if ¬prune(node)
7          frontier.add(node.createChildren())

```

Die Voraussetzung für die Anwendung ist hier, dass ohne Unsicherheit der einzelne Zielknoten mit dem höchsten Nutzen ausreicht, um die Maßnahme, in deren Teilbaum der Zielknoten liegt, auszuwählen. Dies ist der Fall, wenn der Nutzen eines Knotens mit jeder Kante abnimmt, was etwa in vielen Anwendungen mit dynamischem Zeithorizont denkbar ist, beispielsweise wenn ein Auftrag möglichst schnell fertig gestellt werden soll. Die Optimalität des Verfahrens ist garantiert, d. h. dass die Ergebnisqualität sich nicht verändert. Ohne die Voraussetzung kann ansonsten nicht garantiert werden, dass ein anderer Knoten im Baum noch höheren Nutzen hat, ohne dass alle berechnet werden.

Sei  $N$  der Nutzen des besten Zielknotens und  $n$  der durchschnittliche Zugewinn an Nutzen pro Kante. Es ergibt sich dann eine Laufzeit von  $\mathcal{O}(n_M^{N/n})$ , da bis zum Erreichen des ersten Endzustandes mit Nutzen  $N$ , bei durchschnittlicher Schrittweite  $n$ , exponentiell viele Knoten erzeugt werden und von jedem Knoten aus für jede Maßnahme jeweils ein Kindknoten erzeugt wird. Selbst mit Uniform-Cost Search hat die Suche exponentielle Laufzeit, sodass eine Kombination mit Pruning meist sinnvoll ist. Pruning kann auch in Anwendungen, in denen Uniform-Cost Search nicht angewendet werden kann, benutzt werden.

Beim Pruning werden mittels einer anwendungsspezifischen Heuristik bestimmte Pfade des Baumes, die entweder mit Sicherheit oder vermutlich zu keinem besseren Endknoten führen werden, nicht weitergeführt. In Algorithmus 1 ist in Zeile 6 der Aufruf der Heuristik als boolean Methode *prune* dargestellt. Die Prune Methode bewertet anhand des aktuellen Knotens und des bisher bekannten besten Knotens, ob ein Zielknoten mit höherem Nutzen im folgenden Teilbaum des aktuellen Knotens erreicht werden kann und gibt „wahr“ oder „falsch“ zurück.

Dabei wird unterschieden, ob mit Sicherheit festgestellt werden kann, dass kein besserer Zielknoten mehr gefunden werden kann oder ob dies nur geschätzt wird. Bei einer zeitabhängigen Nutzenfunktion ist ersteres der Fall. Anhand der Zeit des aktuellen Knotens und des besten Zielknotens kann mit Sicherheit bestimmt werden, ob genügend Zeit vorhanden ist, um auf dem aktuellen Pfad einen besseren Zielknoten zu erreichen. Eine Schätzung wird vorgenommen, um weiter die Anzahl an zu berechnenden Knoten zu verringern. Wenn es als unwahrscheinlich angesehen wird, dass vom aktuellen Knoten aus eine Verbesserung erzielt wird, obwohl es noch möglich sein sollte, soll die Methode dennoch „falsch“ zurück geben.

Bei Berücksichtigung von Unsicherheit können zudem die Nutzenwerte der bereits bekann-

ten Zielknoten verwendet werden, um die Maßnahmenbewertung (in die ja alle Zielknoten einfließen) abzuschätzen. Insbesondere Zielknoten, die mit hoher Gewichtung in die Bewertung einfließen, können dann schon als Approximation der endgültigen Bewertung dienen und sollten als erstes berechnet werden. Dabei sollten bei Anwendung des Kriteriums von Hodges und Lehmann zunächst Knoten mit voraussichtlich niedrigem Nutzen durchsucht werden, da das negativste Ergebnis ja besonders stark in die Bewertung einfließt. Bei Anwendung des  $\mu - \rho$ -Prinzips sollten Knoten in absteigender zugeordneter Eintrittswahrscheinlichkeit berechnet werden. Bei rekursiver Anwendung der Bewertung kann diese Methode an jeder Ebene angewendet werden, um von den Kindknoten eines Knotens möglichst wenige berechnen zu müssen.

Da das gesamte Bewertungsverfahren allerdings unter anderem zum Ziel hat, lokale Minima zu umgehen, sollte die Schätzung vorsichtig gewählt werden. Ansonsten könnten Knoten auf Pfaden zu globalen Optima verworfen werden, wenn ein lokales Minimum dabei durchlaufen wird. Die Ergebnisqualität verringert sich also zwangsläufig. Um einen guten Kompromiss zwischen Rechenzeit und Ergebnisqualität zu erreichen, sollte bei der Schätzung ein Schwellenwert als einstellbarer Parameter definiert sein. Je nach Anwendung, verwendeter Hardware und verfügbarer Rechenzeit kann so möglichst selten anhand der Schätzung „falsch“ zurück gegeben werden, was das Risiko einer Fehlschätzung und Verlust an Ergebnisqualität reduziert. Dennoch kann das Bewertungsverfahren in akzeptabler Rechenzeit abgeschlossen werden.

Eine weitere Möglichkeit, die Laufzeit zu erhöhen, liegt in der parallelisierten Ausführung des Verfahrens auf  $n$  CPUs. Es ergibt sich ein vorteilhafter linearer Speedup von  $S_n = n$ , da einzelne Teilbäume oder auch einzelne Kindknoten unabhängig voneinander berechnet werden können.

## 5.4. Anpassung der erzeugten Zuordnungen bei festgestellter Irrelevanz

### 5.4.1. Prognose für die Systemparameter auf Basis des bisherigen Verlaufs

Bei der Betrachtung der existierenden Prognoseverfahren wurde die exponentielle Glättung 2. Ordnung als gut geeignet identifiziert (siehe Abschnitt 3.4). In diesem Abschnitt werden die notwendigen Anpassungen für den Einsatz dargelegt.

Zunächst muss der Glättungsparameter  $\alpha$  bestimmt werden. Für den Zweck in dieser Arbeit ist eine Übergewichtung von aktuellen Werten (und damit ggf. Ausreißern) weniger problematisch als eine zu späte Reaktion auf Veränderungen: Bei einer Übergewichtung werden ggf. Zuordnungen generiert, die nie benötigt werden. Bei zu später Reaktion auf Trends allerdings könnte das System in Situationen ohne passende Zuordnung geraten. Aus diesem Grund wird  $\alpha = 0,4$  gewählt, was eine relativ hohe Gewichtung von aktuellen Werten bedeutet.

Um die exponentielle Glättung 2. Ordnung anwenden zu können, muss für einen Systemparameter eine Periode  $\Delta t$  definiert werden, in der ein  $p_i$  ausgelesen wird und die Prognose angestoßen wird. Die Periode hängt einerseits von der erwarteten Änderungsrate eines Parameters ab und sollte nicht zu groß gewählt werden, um Änderungen früh genug zu registrieren. Ein zu kleines  $\Delta t$  wiederum erhöht andererseits die Anzahl der benötigten  $n$  Werte, die in die Prognose einfließen, um auch längerfristige Trends zu erkennen.

Die einzelnen Systemparameter  $p_i$ , die – wie in Abschnitt 5.2 erläutert – Elemente des  $\mathbb{R}^n$  sind, werden in ihren einzelnen Komponenten (also Elemente aus  $\mathbb{R}$ ) prognostiziert. Bei stochastischen Systemparametern (Elemente aus  $F(\Omega, [0,1])$ ) werden die Wahrscheinlichkeitswerte, also die Werte  $p_i(\omega) \in [0,1]$ , einzeln prognostiziert.

Es wurde bisher von unabhängigen Systemparametern und auch von der Unabhängigkeit innerhalb der Komponenten von vektorialen Systemparametern ausgegangen. Etwaige Abhängigkeiten können dabei mittels einer Regressionsanalyse<sup>11</sup> entdeckt werden, um dann die Prognose nur von unabhängigen Komponenten zu betreiben – die zukünftigen

---

<sup>11</sup> Die Methode der kleinsten Quadrate ist hierfür ein geeignetes Verfahren.



Schätzwerte für die übrigen Komponenten können mittels der entdeckten Abhängigkeiten berechnet werden.

Sind bessere Ergebnisse zur weiteren Leistungssteigerung der Relevanz der Zuordnungen erforderlich, kann die exponentielle Glättung durch ein anderes, anwendungsspezifisches Prognoseverfahren ausgetauscht werden.

Es ist Teil der Fragestellung, wie viele Prognosewerte berechnet werden sollen. Für die Steuerung ist es zunächst nicht erforderlich, Prognosewerte über die nächste Periode hinaus zu generieren, da diese im Rahmen der dynamischen Planung nicht einbezogen werden – die Maßnahmenauswahl hängt stets nur von den aktuellen Systemparametern bzw. der aktuellen Situation ab. Um eine Fehlprognose zu kompensieren, wird bei der Neugenerierung allerdings auch der Wert der übernächsten Periode betrachtet. Zudem kann die Generierung mehr Rechenzeit als die Dauer einer Periode  $\Delta t$  benötigen. Daher soll mehr als ein Wert berechnet werden, um sicherzustellen, dass die Zeit bis zum Eintreten der Änderung ausreicht, um die Generierung abzuschließen. Die Anzahl an zu generierenden Prognosewerten  $m + 1$ , unter denen mittels der in Abschnitt 5.4.3 beschriebenen Methode neue Zuordnungen generiert werden sollen, hängt wie folgt von  $\Delta t$ , der benötigten Rechenzeit  $r$  für die Generierung einer Zuordnung ab, sowie von der gewünschten Mindestanzahl an Zuordnungen  $x$  pro Prognosewert:

$$m = \left\lceil \frac{r \cdot x}{\Delta t} \right\rceil$$

Mit dieser Berechnung ist für eine erforderliche Neugenerierung in Periode  $m$  genügend Zeit vorhanden, proaktiv relevante Zuordnungen zu generieren – unter der Annahme, dass für die prognostizierten Perioden  $< m$  bereits  $x$  Zuordnungen existieren. Dies ist der Fall, wenn Änderungen durchschnittlich höchstens alle  $m$  Perioden auftreten. Es wird also so weit in die Zukunft prognostiziert, dass frühzeitig eine Änderung antizipiert werden kann und dies nicht zu kurzfristig passiert. Bei häufigeren Änderungen und  $m > 1$  ist die Rechenzeit für Zuordnungen schlicht zu hoch, um proaktiv die Prognosewerte zu verwenden, die Generierung hinkt dann hinterher.

### 5.4.2. Prognose aufgrund von registrierten Ereignissen

Die Auswirkung eines Ereignisses  $e \in E$  auf die Systemparameter wird mittels einer Funktion  $f_e : P \rightarrow P$  beschrieben. Beispielsweise würde die Auswirkung eines Ausfalls einer Produktionseinheit, deren Anzahl in einem Systemparameter abgebildet ist, durch die Funktion  $f_e : x \mapsto x - 1$  beschrieben werden.

Bei Registrierung eines Ereignisses wird mittels der veränderten, aktuellen Systemparameter zunächst die Neugenerierung gestartet und dann im Anschluss die Prognose neu gestartet.

Bei der weiteren Prognose muss berücksichtigt werden, dass eine plötzliche Veränderung aufgrund des Ereignisses stattgefunden hat. Dazu werden pro Eintreten neben des tatsächlichen Verlaufes für eine bestimmte Zeit  $t_e$  zwei weitere Systemparameterverläufe vorgehalten. Es werden drei verschiedene mögliche Fälle unterschieden, die in Abbildung 5.8 skizziert sind:

1. Das System erholt sich sehr schnell (innerhalb von  $t_e$ ) von den Auswirkungen des Ereignisses (blaue Kurve) und die Systemparameter nehmen die Werte an, die sie ohne Eintritt erreicht hätten. In diesem Fall würde eine Prognose unter Berücksichtigung der Werte kurz nach Eintritt des Ereignisses keine guten Ergebnisse erzielen – eine Prognose auf Basis der Werte bis Eintritt allerdings schon. Es wird also nur der *Verlauf bis zum Eintritt* verwendet.
2. Das System verhält sich nach Eintritt des Ereignisses verschieden; das Ereignis hat eine große dauerhafte Auswirkung auf das gesamte System (rote Kurve). In diesem Fall ist die Prognose aufgrund des *Verlaufes ab Eintritt* sinnvoll.
3. Das Ereignis hat eine dauerhafte Auswirkung auf das System, aber ein bisheriger Trend findet sich weiter in den Daten (orange Kurve). Der *gesamte Verlauf* ist auch kurz nach Eintritt sinnvoll als Basis für eine Prognose zu betrachten, da der Trend in den Daten erkannt werden kann, aber dennoch die kurzfristige Änderung durch das Ereignis berücksichtigt werden sollte.

$t_e$  wird pro Ereignis festgelegt und soll als Abschätzung dienen, wie lange die Auswirkung im System (bei angenommener Erholung) sichtbar ist. Bei Ausfall einer Einheit etwa würde  $t_e$  die maximale Reparaturzeit darstellen. Bei Ereignissen mit dauerhaften Änderungen kann nach  $t_e$  Zeiteinheiten wieder mit dem gesamten Verlauf gerechnet werden – das




Abbildung 5.8.: Drei Fälle für einen Systemparameterverlauf kurz nach Eintritt eines Ereignisses  $e$

Prognoseverfahren ist in der Lage, solche Ausreißer zu erkennen bzw. kann sich auf die Veränderungen, die dann schon  $t_e$  Zeiteinheiten vorhanden sind, einstellen.

Für  $t_e$  Zeiteinheiten wird die Prognose dann unter allen drei Verläufen berechnet, da nicht eindeutig entschieden werden kann, welche der drei Verläufe in den besten Ergebnissen resultiert. Für alle drei Verläufe werden nach der im vorherigen Abschnitt bestimmten Anzahl  $m + 1$  Werte berechnet und die Neugenerierung gestartet. Dies geschieht unter der Beobachtung, dass eventuell unnötig generierte Zuordnungen die Leistung des Systems nicht negativ beeinträchtigen.

### 5.4.3. Neugenerieren von Zuordnungen

Unter den nun prognostizierten  $m + 1$  Werten  $p_1, \dots, p_{m+1}$  soll nun untersucht werden, ob eine Irrelevanz der Zuordnungen antizipiert wird und gegebenenfalls eine Neugenerierung ebendieser angestoßen wird. Laut der in Abschnitt 5.2.1 erarbeiteten Definition der Systemparameter beeinflussen diese, welche Situationen auftreten werden sowie die Zuordnung zu Maßnahmen. Es ist daher zu überprüfen, ob eine prognostizierte Änderung

der Systemparameter das Auftreten verschiedener Situationen oder eine verschiedene Zuordnung bewirkt.

Zunächst soll mittels der Simulation ermittelt werden, welche Situationen unter den prognostizierten Systemparametern in der Periode  $m$  auftreten werden. Die Simulation kann also als eine Funktion  $P \rightarrow \mathcal{P}(S)$  aufgefasst werden. Die ermittelten Situationen  $S_m$  werden dann mit der aktuellen Menge an erzeugten Situationen  $S_{erz}$  verglichen. Dies geschieht mittels der folgenden Funktion, die analog zu den Funktionen aus Abschnitt 5.1 aufgebaut sind:

$$R(S_{erz}, S_m) = \max_{s_m \in S_m} ( \min_{s_e \in S_{erz}} d_S(s_e, s_m) ) < d$$

Hierbei ist  $d_S$  die Ähnlichkeitsmetrik und  $d$  der Schwellwert aus Abschnitt 5.1.

Falls eine zu große Diskrepanz festgestellt wird, ist eine Irrelevanz antizipiert. In dem Fall erfolgt die Neugenerierung und Übernahme von Zuordnungen unter den Systemparametern zur Periode  $m$ . Die neu generierten Zuordnungen  $Z_m$  werden zu  $Z_{erz}$  hinzugefügt, falls keine Kollision auftritt. Eine Kollision sei wie folgt definiert: Zu einer bestehenden Situation  $s_1 \in S_{erz}$  tritt eine hinreichend ähnliche Situation  $s_2 \in S_m$  in der Simulation auf, es wird aber aufgrund der Systemparameter eine andere Maßnahme zugeordnet:

$$\exists s_1 \in S_{erz}, s_2 \in S_m : d_S(s_1, s_2) < \epsilon \wedge Z_m(s_1) \neq Z_{erz}(s_2)$$

Dabei existiert ein Schwellenwert  $\epsilon > 0$ . Eine Kollision ist in Abbildung 5.9 skizziert. Zur Bestimmung, ob eine Kollision vorliegt, sind also die Zuordnungen notwendig. Falls keine Irrelevanz aufgrund der erwarteten Situationen festgestellt wurde, wird die Neugenerierung zum Erkennen von Kollisionen angestoßen, falls auch genügend Zeit bis zur nächsten Periode vorhanden ist. Eine festgestellte Kollision bedingt dann ebenfalls eine Übernahme der neuen Zuordnungen. In dem Fall wird  $Z_m$  nicht direkt zu  $Z_{erz}$  hinzugefügt, sondern separat abgespeichert und erst bei Eintreten der Systemparameter  $p_m$  verwendet. Es werden dann die bisherigen Zuordnungen gelöscht, da sie aufgrund der dann nicht mehr aktuellen Systemparameter veraltet sind. Wie in Abschnitt 2.5.3 erläutert, kann dies auch bei gleichbleibenden Situationen geschehen. Das Auftreten einer Kollision ist also das gesuchte Kriterium, um ein Löschen von veralteten Zuordnungen mit gleichzeitigem Neugenerieren anzustoßen.




Abbildung 5.9.: Eine Kollision, bei der zwei hinreichend ähnlichen Situationen zwei verschiedene Maßnahmen zugeordnet werden. Die Situationen sind unter zwei verschiedenen Systemparametern  $p_1$  und  $p_2$  generiert worden, die die Lage und zugeordnete Maßnahmen der Situationen beeinflussen.

Weiterhin werden zur Reduzierung der Anzahl von Zuordnungen solche gelöscht, welche unter Systemparametern generiert wurden, die in einem zu großen Abstand zu den aktuellen Systemparametern stehen. In dem Fall wird davon ausgegangen, dass diese Zuordnungen nie mehr oder erst in so großer zeitlicher Entfernung relevant werden (aufgrund der angenommenen Änderungsrate der Systemparameter, die antiproportional zu  $\Delta t$  ist), dass noch genügend Zeit für eine Neugenerierung vorhanden wäre. Konkret werden diejenigen Zuordnungen gelöscht, die unter Systemparametern  $p_{gen}$  generiert wurden, wenn für die aktuellen Systemparameter  $p_{cur}$  gilt:

$$|p_{cur} - p_{gen}| > \frac{c \cdot a}{\Delta t}$$

Dabei ist  $\|$  die euklidische Distanz.  $c \in \mathbb{R}$  ist eine Konstante, die die Änderungsrate der Situationen relativ zu den Systemparametern angibt. Falls eine Änderung der Systemparameter um eine Einheit eine hohe Veränderung in den Situationen bewirkt, sollte  $c$  groß gewählt werden. In diesem Fall kann es nämlich schneller passieren, dass die generierten Zuordnungen wieder relevant werden, sodass diese erst bei einer größeren Entfernung gelöscht werden sollten. Es müssen ebenfalls die Abstände innerhalb von  $S$  berücksichtigt werden, ab denen sicher von Irrelevanz ausgegangen wird. Dazu wird ein Abstand  $a \in \mathbb{R}$

definiert. Eine Multiplikation mit  $\frac{1}{\Delta t}$  wiederum bewirkt eine Skalierung um die Änderungsrate der Systemparameter. Je größer die Änderungsrate ist, desto größer ist der benötigte Abstand, um „sicher“ löschen zu können. Die Reduzierung der Anzahl der Zuordnungen sorgt für schnellere Berechnungen an verschiedenen Stellen des Verfahrens.

Falls  $m = 1$  gilt und somit bis zur nächsten Periode noch Zeit vorhanden ist, soll die Neugenerierung wiederholt werden, um etwaige Fehler in den Prognosewerten zu kompensieren. Es wird die Generierung mit Systemparametern, die um die Prognosewerte „gestreut“ werden, wiederholt. Die Annahme hier ist, dass die Wahrscheinlichkeit, unter den tatsächlichen zukünftigen Systemparametern Zuordnungen zu generieren, dadurch steigt. In die Streuung fließen die aktuellen tatsächlichen Systemparameter (Periode  $m - 1$ ) sowie der Prognosewert für  $m + 1$  ein. Damit soll kompensiert werden, dass die Prognose Entwicklungen zu schnell oder zu langsam einschätzen könnte. Konkret gilt für jede Komponente  $p_{i_j}$  der Systemparameter, dass je zwei Streuwerte  $p_{i_j}^o$  und  $p_{i_j}^u$  berechnet werden. Sie sollen eine mögliche Abweichung nach „oben“ (Entwicklung zu langsam eingeschätzt) oder nach „unten“ (Entwicklung zu schnell eingeschätzt) darstellen. Sei  $p_{i_j}^m$  der Wert der Komponente im Prognosewert der Periode  $m$ :

$$\begin{aligned} p_{i_j}^o &= p_{i_j}^m + 0,25 \cdot (p_{i_j}^{m+1} - p_{i_j}^m) \\ p_{i_j}^u &= p_{i_j}^m + 0,25 \cdot (p_{i_j}^{m-1} - p_{i_j}^m) \end{aligned}$$

In Abbildung 5.10 ist die Streuung skizziert. In dem Beispiel sind die Systemparameter zweidimensional und es existiert ein linearer Zusammenhang zwischen den drei Prognosewerten. Die vier grünen Punkte symbolisieren die Streuwerte. Die Systemparameter zur Neugenerierung ergeben sich also aus der Kombination der einzelnen Streuwerte. Im skizzierten Beispiel wären dies etwa  $p_{i_2}^o, p_{i_1}^u$  sowie die weiteren drei möglichen Kombinationen. Sei  $n = |P|$  die Anzahl an Systemparametern und  $|p_i|$  die Anzahl an Komponenten eines Systemparameters, dann ist die Anzahl an Streuwerten

$$\sum_{i=1}^n |p_i|^2$$




Abbildung 5.10.: Streuung der zur Neugenerierung verwendeten Systemparameterausprägung anhand der Prognosewerte (linearer Verlauf)

## 5.5. Effizienzsteigerung einer Menge von Situation/Maßnahme Zuordnungen

Aufgrund der identifizierten Laufzeit des Messens der Relevanz und des Neugenerierens von Zuordnungen soll zunächst in Abschnitt 5.5.1 untersucht werden, inwieweit die Anzahl der Zuordnungen minimiert werden kann. In Abschnitt 5.5.2 wird dargestellt, wie sich die Zuordnungen als Trainingsbeispiele von induktiven Lernverfahren darstellen lassen und welche Konsequenzen für die wissensbasierte Steuerung sich daraus ergeben.

### 5.5.1. Minimierung der Anzahl der Zuordnungen bei gleichbleibender Ergebnisqualität

In Abschnitt 5.1 wird ein Abstand  $d$  definiert, anhand dessen eine Irrelevanz einer neuen Situation definiert wird. In  $S$  kann dann zu jeder Situation eine  $|S|$  dimensionale Kugel  $K$  mit Radius  $d$  definiert werden. Eine Überdeckung einer Kugel von anderen Kugeln ist gegeben, wenn jeder Punkt im Volumen der Kugel bereits in einer anderen enthalten ist

und die zugeordneten Maßnahmen aller betroffenen Situationen gleich sind. Falls nun für eine Situation  $s$  die zugeordnete Kugel  $K_s$  überdeckt ist (siehe Abbildung 5.11), d. h.

$$\exists (K_{s_c} \subset S)_{s_c \in S_c \subseteq S_{erz}} : K_s \subseteq \bigcup_{s \in S_c} K_{s_c} \wedge \forall s_c \in S_c : Z_{erz}(s_c) = Z_{erz}(s)$$

kann die überdeckte Situation  $s$  gelöscht werden, ohne dass sich die spätere Klassifikationsgüte oder Werte der in Abschnitt 5.1 dargelegten Relevanzfunktionen ändern. Für jeden Punkt innerhalb von  $K_s$  existiert schließlich per Definition eine weitere Situation  $s_c$  innerhalb eines Abstandes  $d$ , der dieselbe Maßnahme zugeordnet ist. Ein Entfernen von  $s$  würde also bei einem späteren Auftreten einer Situation innerhalb von  $K_s$  keine Auswirkung haben. Zudem ist es aufgrund der Definition von  $d$  unwahrscheinlich, dass innerhalb von  $K_s$  zukünftig eine Zuordnung generiert wird, die eine verschiedene Maßnahme hat.

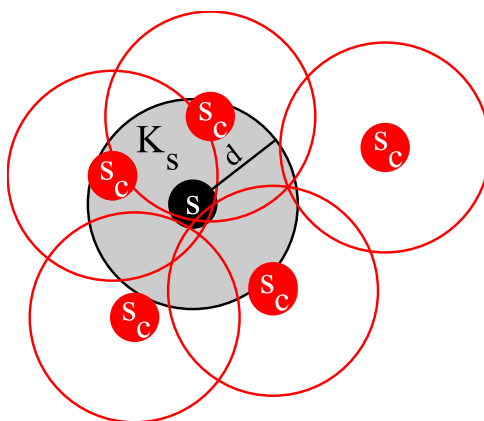


Abbildung 5.11.: Skizze der Überdeckung der Kugeln um Situationen

Die Rechenzeit für Lernverfahren, die als Eingabe die Zuordnungen erhalten, hängt ebenfalls von deren Anzahl ab und reduziert sich durch diese Maßnahme. Die genaue Abhängigkeit ist für jedes Lernverfahren verschieden.

### 5.5.2. Darstellung der Zuordnungen als Hypothese überwachter Lernverfahren

Bezüglich der in Abschnitt 3.5 dargelegten Ergebnisse aus der Computer-Lerntheorie kann die folgende Identifizierung vorgenommen werden.



Die Zuordnungen  $Z_{erz} \subset S \times M$  lassen sich als Trainingsbeispiele darstellen.  $f : S \rightarrow M$  ist die gewünschte Funktion, die jeder Situation die Maßnahme, die die Leistung des Systems optimiert, zuordnet.  $f$  ist anhand der Vielzahl der möglichen Situationen allerdings praktisch nicht vollständig aufzählbar. Anhand der simulativen Vorschau wurde dies für einige Werte, eben den Situationen aus  $S_{erz}$ , getan. Anhand von induktiven, überwachten Lernverfahren wird ein trainierter Klassifizierer aufgebaut, der die Hypothese  $h$  darstellt.

Die Lernverfahren müssen sogenannte faktorielle Attribute unterstützen, da die Situationen Vektoren aus  $\mathbb{R}^n$  darstellen. Zur Bewertung der Lernverfahren, die diese Voraussetzung erfüllen, wird die Kreuzvalidierung verwendet. Für die im Rahmen der Entwicklung dieser Arbeit untersuchten logistischen Systeme erzielten künstliche neuronale Netze, Entscheidungsbäume und Support Vector Machines eine vergleichbar gute Leistung. Es existieren auch Metaverfahren, die verschiedene Methoden wie die drei genannten parallel auswerten und daraus eine Entscheidung ableiten [Die00]. Sie sind daher für die Anwendung in dieser Arbeit gut geeignet.

## 5.6. Notwendige Schritte zur Adaption des Verfahrens für ein konkretes System

Das dargelegte Konzept ist soweit verallgemeinert, dass es für eine nicht genauer definierte Vielzahl von Steuerungsproblemen in logistischen Systemen anwendbar ist. Für eine konkrete Anwendung müssen folgende problemspezifische Anpassungen vorgenommen werden, für die Kriterien innerhalb der Arbeit aufgestellt wurden, um die Anpassung zu erleichtern.

- Ein Maßnahmenkatalog muss definiert werden. Die Auswirkung einer Maßnahme wird dabei innerhalb des zu entwickelnden Simulationsmodells des zu steuernden Systems definiert. Für die Bewertung der Maßnahmen muss der Wirkzeitraums anhand der in Abschnitt 5.3.2 entwickelten Kriterien definiert werden.
- Eine Situationsdefinition anhand der in Abschnitt 5.2.2 dargelegten Kriterien muss erfolgen. Dies wird durch Definition der einzelnen Attribute mit den Grenzen  $i_u$  und  $i_o$  erreicht. Die Attribute müssen aus dem Simulationsmodell zu jedem Zeitpunkt berechenbar sein. Zudem muss im Simulationsmodell ein Trigger hinterlegt sein, der bei Auftreten einer Situation ausgelöst wird.

- Systemparameter müssen nach den in Abschnitt 5.2.1 dargelegten Kriterien definiert werden. Zusätzlich muss für die Prognosefähigkeit eine Periodendauer  $\Delta t$  sowie die erwünschte minimale Anzahl an Zuordnungen  $x$  pro Periode definiert werden. Ein Wert für die Änderungsrate  $c$ , die eine Änderung der Parameter auf die Situationen beschreibt, sowie ein Abstand  $a$  in  $S$  muss für das Löschkriterium (siehe Abschnitt 5.4.3) definiert werden.
- Die Aggregationsfunktion (Hodges-Lehmann oder  $\mu - \rho$ ) muss ausgewählt werden samt des Risikoaversitätsfaktors  $q$  nach den in Abschnitt 5.3.2 dargelegten Kriterien.
- Eine Nutzenfunktion  $N : V \rightarrow \mathbb{R}$  für Knoten innerhalb der Bewertung muss spezifiziert werden. Zusätzlich müssen Prunekriterien entwickelt werden, die anhand der bisher vorliegenden Informationen und eines Knoten definieren, ob die Bewertung an der Stelle weiter verzweigt.
- Ein Zielknoten nach einer der in Abschnitt 5.3.2 definierten Wirkzeitraumtypen der Maßnahmen muss definiert werden.
- Die zu betrachteten Ereignisse müssen spezifiziert werden, indem die Auswirkungen im Simulationsmodell ausgearbeitet werden. Die Auswirkung auf die Systemparameter muss zudem mittels der Funktion  $f_e : P \rightarrow P$  und des Zeitraumes  $t_e$  dargelegt werden. Der Typ der Auswirkung (siehe Abschnitt 5.4.2) und die angenommenen Eintrittswahrscheinlichkeiten komplettieren die Definition.

Im folgenden Kapitel 6 werden die genannten Schritte für ein logistisches System umgesetzt. Im Teilkapitel 6.2 werden die einzelnen Adaptionen detailliert dargestellt.

## 6. Validierung

In diesem Kapitel soll das Konzept zur Steuerung des in Kapitel 2 eingeführten Material Handling System angewendet und experimentell evaluiert werden. Diese Validierung soll einerseits die praxisnahe Verwendungsmöglichkeit aufzeigen, andererseits die Leistungsfähigkeit gegenüber den herkömmlichen Steuerungsmöglichkeiten messen.

Zunächst erfolgt eine ausführliche Beschreibung des zu steuernden Systems in Abschnitt 6.1. Die Adaption des Konzeptes, also die Definition der anwendungsspezifischen Aspekte, ist in Abschnitt 6.2 dargelegt. Die Evaluierungsergebnisse werden schließlich in Abschnitt 6.3 aufgezeigt und diskutiert.

### 6.1. Konkreter Anwendungsfall: Automatisches Material Handling System

Dieser Abschnitt legt in Ergänzung zu der in Abschnitt 2 gegebenen Kurzbeschreibung des MHS die allgemeinen Hintergründe der Anlage dar.

Es existieren pro Gasse zwei TVs, die jeweils die Hälfte der entsprechend angeschlossenen Übergabekabinen und Stellplätze bedient. Diese ergeben sich aus den Zuordnungen von Shuttles zu Aufzügen einerseits und einer möglichst gleichen Anzahl an zugeordneten Stellplätzen zu Shuttles andererseits, um die Last auf alle Shuttles gleichmäßig zu verteilen. Es ergeben sich überlappende Fahrbereiche. Innerhalb dieser Überlappungszonen müssen die Shuttles koordiniert werden – dies wird über eine Semaphore realisiert. Sobald ein Shuttle in den Überlappungsbereich fährt, blockiert dieses den Bereich, sodass er für das andere Shuttle in der Gasse gesperrt ist. Erst wenn das Shuttle den Bereich wieder verlässt, kann das andere diesen befahren. Wird ein dreidimensionales, kartesisches Koordinatensystem zugrunde gelegt, entsprechen die Fördereinheiten jeweils einer Dimension. Die Shuttles

bewegen das Material dabei auf der X-, die Manipulatoren auf der Y- und die Aufzüge auf der Z-Achse.

Bei Auslagerungsvorgängen ist zu beachten, dass eventuell sogenannte „Shufflevorgänge“ nötig sind, um Material auf einem Stellplatz zu erreichen. Diese sind zusätzliche Umlagerungsvorgänge, die benötigt werden, wenn ein Stellplatz nicht direkt zugreifbar ist. Ein vorderer Stellplatz ist belegt und verhindert dadurch den Zugriff auf ein hinteres. Es muss also das Material auf dem vorderen Stellplatz zunächst auf ein Shuttle geladen werden, um es auf einen anderen Stellplatz zu stellen – erst dann kann das hintere Material erreicht werden. Zur Vermeidung von Shufflevorgängen werden verschiedene Strategien angewendet, die im Laufe des Kapitels behandelt werden.

Die beweglichen Fördereinheiten (Shuttles und Übergabekabinen) befinden sich während der gesamten Simulation in einem von fünf Status:

- *Idle*: Eine Einheit hat keine Anweisung für eine Bewegung erhalten. Es wartet auch nicht auf eine andere Einheit.
- *Moving empty*: Eine Einheit bewegt sich ohne Beladung.
- *Moving full*: Eine Einheit bewegt sich, während es Material geladen hat.
- *Loading*: Eine Einheit übergibt Material, also nimmt es auf oder gibt es ab.
- *Waiting*: Eine Einheit wartet auf eine andere, z. B. wartet ein Shuttle auf die Ankunft einer Übergabekabine, in die es Material umladen soll.

Eine Abfolge von Status der Übergabekabinen wird in Abbildung 6.1 gezeigt. Die Kabinen befinden sich zunächst im Zustand *idle* (grün). Anschließend wird ein Einlagerungsvorgang gestartet. Dabei befindet sich die entsprechende Übergabekabine nacheinander in den Zuständen *moving empty* (orange), während die Kabine zunächst leer auf die Übergabeebene fährt, *loading* (blau), in dem das Material in die Kabine gefahren wird, *moving full* (gelb), während sie auf die Ebene fährt, auf der das Material eingelagert werden soll und schließlich *loading* beim Ausladen des Materials auf ein Shuttle.

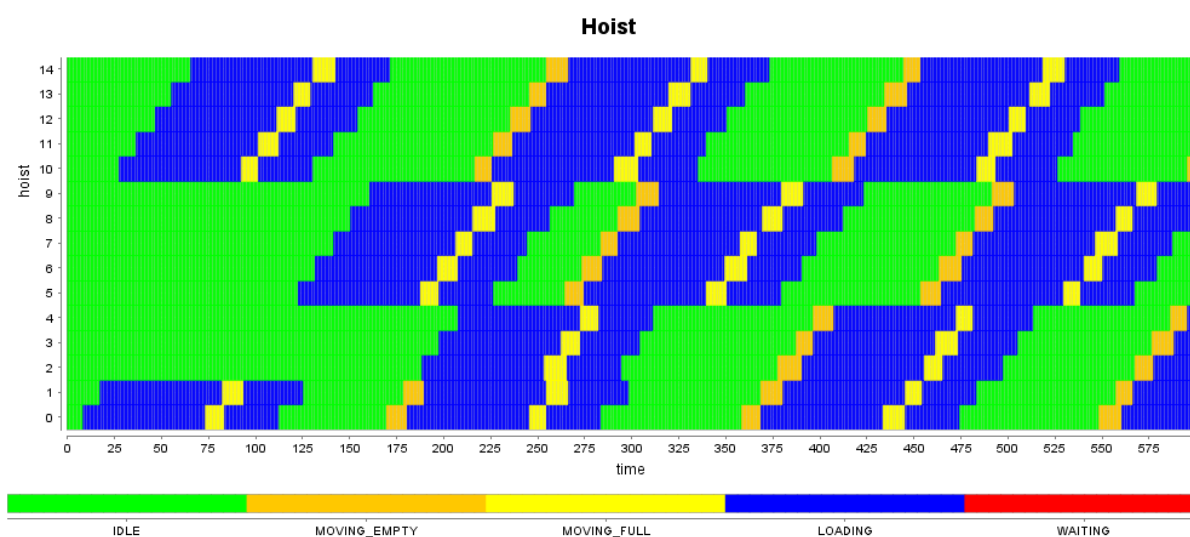


Abbildung 6.1.: Status der Übergabekabinen bei Einlagervorgängen

## 6.2. Umsetzung des Verfahrens

Um das Verfahren umzusetzen, werden die anwendungsspezifischen Teile der Methodik wie in Abschnitt 5.6 definiert ausgefüllt. In den folgenden Abschnitten werden daher der Maßnahmenkatalog, die Situations- und Systemparameterdefinitionen sowie die zur Bewertung von Maßnahmen notwendigen Aspekte (Aggregations-, Nutzenfunktion sowie Ereignisdefinitionen) erläutert. Abschließend wird das entwickelte Simulationsmodell zur Generierung der Zuordnungen sowie zur Evaluation des Verfahrens in Abschnitt 6.2.5 beschrieben.

### 6.2.1. Maßnahmen

Zur Entwicklung der Maßnahmen ist zunächst festzustellen, was die Einflussfaktoren im System auf die Leistung sind, die durch die Steuerung verändert werden können. Weiterhin sieht das Konzept vor, diese Einflussfaktoren je nach Situation im System zu steuern. Dadurch fallen Optimierungen im Betriebsablauf, die zu jeder Zeit positiv sind, nicht in den Definitionsbereich des Maßnahmenkatalogs<sup>1</sup>. Es sind diejenigen Änderungen

<sup>1</sup> Ein Beispiel dafür sind sogenannte „Doppelspiele“: Wenn beim Einlagern ein Shuttle Material in einer unteren Ebene aus einem Aufzug genommen hat, ist es sinnvoll, dass ein Shuttle einer gegenüber liegenden Gasse so früh wie möglich Material an diesen Aufzug übergibt. Dann muss der Aufzug nicht erst seine Ebene verändern.

an Einflussfaktoren zu identifizieren, die jeweils nur unter bestimmten Umständen eine Leistungsverbesserung versprechen. Unter der optimalen Zuordnung von Situationen zu Maßnahmen soll sich dann insgesamt eine Leistungsverbesserung ergeben.

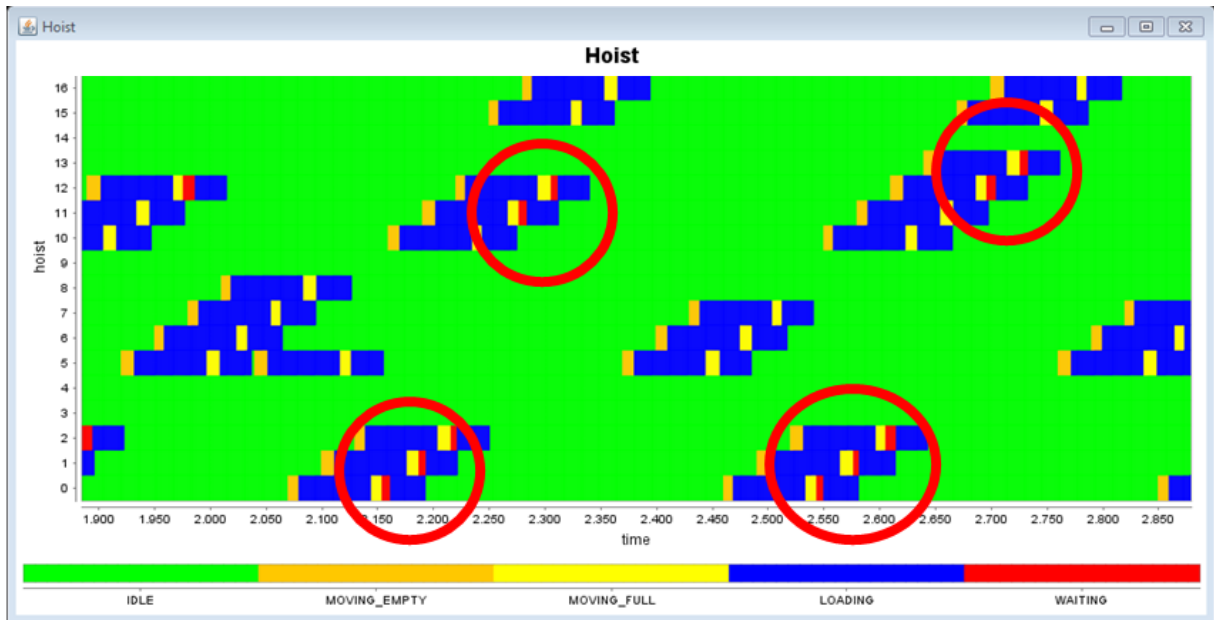


Abbildung 6.2.: Im Statusdiagramm von Aufzügen beobachtetes Optimierungspotenzial durch Prefetching ist zu erkennen. Die roten Bereiche stellen die Zeit dar, in der Aufzüge beim Einlagern auf Shuttles warten.

Nach Beobachtungen des Betriebsablaufes wurden Optimierungspotentiale in drei Bereichen hervorgehoben. In den drei Bereichen wurden alternative Strategien (Werte der Einflussfaktoren) definiert, die in Kombination die Maßnahmen ergeben, die voraussichtlich in verschiedenen Situationen jeweils Leistungssteigerungen erwirken.

Zunächst ist beim Einlagern ein Stellplatz auszuwählen, in den das Material eingelagert werden soll – dabei können die Stellplätze in verschiedene Bereiche eingeteilt werden (siehe Abbildung 6.3). Es werden Bereiche nahe den Aufzügen definiert („innen“) sowie in der größten Entfernung („außen“), sodass ein Shuttle für den Zugriff außen einen weiten Weg zwischen Aufzug und Stellplatz zurücklegen muss. Es wird eine Reihenfolge definiert, wie bei Einlagerung ein Stellplatz ausgewählt wird: „Von innen nach außen“ spezifiziert die Auswahl des ersten freien Stellplatzes in der Sortierung nach Entfernung zum Aufzug. In umgekehrter Reihenfolge geschieht dies nach der Reihenfolge „von außen nach innen“. Weiterhin werden bei letzterer Strategie die Stellplätze zeilenweise sortiert – zunächst alle




Abbildung 6.3.: Die verschiedenen Stellplatzbereiche nah an den Aufzügen (rechts) sind markiert, die durch „innen nach außen“ zuerst ausgewählt werden. Links sind diejenigen zu sehen, die durch „außen nach innen“ zunächst ausgewählt werden. Analog sind die Bereiche für andere Aufzuggruppen im MHS definiert.

hinteren, dann die vorderen. Dadurch sollen zukünftige Shufflevorgänge vermieden werden, da das Material nicht hintereinander gestellt wird, bis es nicht mehr zu vermeiden ist. Zudem bleiben die vorderen Stellplätze, auf die schneller zugegriffen werden kann, für Zeiten hoher Einlagerlast frei. Bei Sortierung von innen nach außen werden die Stellplätze spaltenweise ausgewählt – zunächst an einer x-Position der hintere, dann der vordere. Hier liegt der Fokus auf einen möglichst kurzen Fahrweg eines Shuttles. Je nach Systemlast erscheint es hypothetisch sinnvoll, „gute“ Stellplätze innen freizuhalten, um diese bei einer hohen zukünftigen Einlagerlast verwenden zu können.

In Phasen geringer Last ist ggf. ein Umlagern von Material sinnvoll, um wieder „gute“ Stellplätze verfügbar zu machen und auch künftige Shufflevorgänge zu vermeiden. Dazu wird Material von inneren Stellplätzen auf äußere umgelagert. Weiterhin werden Lücken geschlossen. Diese sind freie hintere Stellplätze, die durch einen belegten vorderen Stellplatz blockiert sind. Die Konstellation wird durch Umlagerung des Materials vom vorderen auf den hinteren Stellplatz aufgelöst. Konkret wird unter folgenden Umständen ein Umlagervorgang angestoßen:

1. Ein Shuttle ist verfügbar (keine Aufträge für die Gasse liegen vor) und
2. es befindet sich Material auf einem der vorderen 30% der Stellplätze, die ohne

Shufflevorgang erreichbar sind und

3. es befindet sich ein freier Stellplatz in den hinteren 30% der Stellplätze, die ohne Shufflevorgang erreichbar sind.

In Abbildung 6.2 ist zu erkennen, dass Aufzüge beim Einlagern, nach Anfahrt der entsprechenden Ebene, auf ein Shuttle warten müssen. Dies liegt daran, dass Shuttles erst in dem Moment beauftragt werden, in dem der Aufzug sich in die Ebene bewegt – je nach Position der Shuttles ist der Aufzug aber schneller als ein TV angelangt. Aufgrund der allgemeinen Beobachtung, dass Aufzüge, und nicht Shuttles, den Flaschenhals in dem MHS darstellen, erscheint es also sinnvoll, zumindest bei einer hohen Einlagerlast die Shuttles früher zu beauftragen, sodass diese auf die Übergabekabinen warten und nicht umgekehrt. Sie werden hier 10 Sekunden vorher beauftragt, wenn das sogenannte *Prefetching* aktiviert ist.

In Tabelle 6.1 sind die definierten Maßnahmen in Hinsicht auf die zuvor genannten Strategien dargestellt. Aufgrund der geschilderten Beobachtungen wird davon ausgegangen, dass eine Auswahl je nach Last (Anzahl Aus- und Einlagerungen) in der dargestellten Kombination die Leistung des Systems steigert. Dabei ist die Last eine nicht beeinflussbare externe Größe und gleichzeitig die einzig für die Steuerung relevante, da alle anderen Einflussfaktoren kontrollierbar sind. Somit wurden die Maßnahmen für drei verschiedene (nicht quantifizierbare) Lastszenarien ausgelegt. Die Zuordnung zu Lasten mit quantifizierten Grenzen soll später durch die Maßnahmenbewertung in Abschnitt 6.2.4 erfolgen.

Maßnahme	Prefetching	Umlagern	Stellplatzauswahl
geringe Last	nein	ja	außen nach innen
hohe Last Einlagerung	ja	nein	innen nach außen
hohe Last Auslagerung oder gemischt	nein	nein	innen nach außen

Tabelle 6.1.: Definition des Maßnahmenkatalogs durch Kombination von alternativen Strategien

### 6.2.2. Situationsdefinition

Bei der Maßnahmendefinition wurde beobachtet, dass die Auswahl der Maßnahme vermutlich von der aktuellen sowie der zukünftigen und vergangenen Systemlast abhängt. Schließlich wird beispielsweise beim Umlagern davon ausgegangen, dass später noch Einlagerungen vorgenommen werden. Zudem erscheint es nicht sinnvoll, kurzfristig eine der



Maßnahmen auszuwählen. Daher wird einmal pro Stunde eine Maßnahmenauswahl getroffen. Diese fixe Auswahl erlaubt ebenfalls bei der Bewertung erhebliche Vereinfachungen.

Die Situation besteht aufgrund dieser Überlegung aus den bisherigen und aktuellen Ein- und Auslageranfragen über den Tag gesehen. Aus diesem Verlauf kann der Klassifizierer bedingt auch auf die möglichen zukünftigen Lasten schließen. Einerseits kann in dem Szenario angenommen werden, dass sämtliches Material bis zum Ende des Tages wieder ausgelagert werden. Zudem entspricht es den Erwartungen des Anwendungsszenarios, dass verschiedene typische Tagesverläufe existieren, wie etwa „Wochentag“ die einen immer ähnlichen Verlauf aufzeigen. Bei der Umsetzung der Bewertung von Maßnahmen soll aber berücksichtigt werden, dass dieser Schluss nicht mit vollständiger Sicherheit gemacht werden kann.

Konkret ist eine Situation ein Vektor aus  $\mathbb{N}^{26}$ , da hier angenommen wird, dass das MHS von 07:00 bis 20:00 verwendet wird, also 13 Stunden lang, und pro Stunde je ein Wert für Ein- und für Auslagerungen definiert wird. Für Stunden, für die noch kein Wert vorhanden ist, wird als Schlüsselwert  $2^{31}$  verwendet<sup>2</sup>. Es gilt für alle Komponenten  $i_u = 0$  und  $i_o = 2000$  entsprechend des angenommenen Wertebereiches. Ein Beispiel einer Situation ist in Tabelle 6.2 dargestellt. Die Situation tritt nach 7 Stunden, also um 14:00, auf.

Einlagerungen	250	500	250	50	0	0	0	$2^{31}$	$2^{31}$	$2^{31}$	$2^{31}$	$2^{31}$	$2^{31}$
Auslagerungen	0	0	0	0	0	250	500	$2^{31}$	$2^{31}$	$2^{31}$	$2^{31}$	$2^{31}$	$2^{31}$

Tabelle 6.2.: Ein Beispiel einer Situation ist dargestellt. Es sind die Werte für Ein- und Auslagerungen dargestellt.

### 6.2.3. Systemparameter

Es wird erwartet, dass die Systemlast über einen Tag gesehen im Laufe der Zeit variiert. Dieser exogene Faktor soll daher in Form von möglichen Tageskurven als stochastischer Parameter definiert werden. Es gilt also mit der in Abschnitt 5.2.1 eingeführten Notation  $\Omega = \mathbb{N}^{26}$ . Für jede mögliche Tageskurve wird eine Wahrscheinlichkeit angegeben. Diese Wahrscheinlichkeit könnte in der Anwendung aus historischen Daten entwickelt werden, wodurch sie eine relativ hohe Sicherheit bekommt. Aufgrund dieser Wahrscheinlichkeiten

<sup>2</sup> Der Maximalwert eines Ganzzahlenwertes mit Vorzeichen in 32-Bit Computerprogrammen ist  $2^{31}$ .

kann, wie im folgenden Abschnitt erläutert, die Bewertungsmethode die Maßnahmen entsprechend ihrer Leistung in mehreren Szenarien bewerten.

Für die Systemparameter benötigen wir entsprechend den in Abschnitt 5.4 dargelegten Überlegungen zur Verwendung in der Adaptionskomponente folgende Werte: Für  $\Delta t$  wird 7 angenommen, dies bedeutet, dass alle 7 Tage die Wahrscheinlichkeiten der Tageskurven aktualisiert werden und die Prognose neu gestartet wird. Für  $x$  kann  $12 \cdot \text{Anzahl betrachteter Tageskurven}$  angenommen werden, da pro Tageskurve lediglich 12 Zuordnungen (eine für jede Stunde) generiert werden müssen. Für  $c$  ist 1 ein sinnvoller Wert, da die Änderungen in den Systemparametern direkt zu Änderungen in den Situationen führen. Es wird  $a = 2000$  angenommen, da eine Verschiebung von 2000 Aufträgen innerhalb eines Tages nach Beobachtungen sicher zu Veränderungen in der Maßnahmenauswahl führen.

#### 6.2.4. Bewertung der Maßnahmen

Anhand des in Abschnitt 5.3.1 eingeführten Graphenmodells lässt sich der Zustand des MHS zu einer vollen Stunde als Knoten definieren. In Analogie zur in Abbildung 5.3 dargestellten abstrakten Struktur existiert für jede der drei Maßnahmen von einem Knoten eine Kante zu den jeweiligen Kindknoten, entsprechend des möglichen Zustands nach einer weiteren Stunde (siehe Abbildung 6.4). Dabei existieren hier nur zwei mögliche Situationen  $s_1$  und  $s_2$  zu den Folgezuständen  $z_1$  bis  $z_6$ . Die Situationsdefinition enthält schließlich keine Komponenten, die abhängig von der Auswahl der Maßnahme sind. Lediglich der Eintritt des Ereignisses führt zu einer anderen Situation, da sich dadurch die Anzahl der Ein- und Auslageraufträge verändert, wie im Folgenden erläutert wird.

Die Bewertung erfolgt unter Berücksichtigung eines unsicheren Ereignisses, wie ebenfalls in Abbildung 6.4 zu erkennen ist. Der Ereignisfall liegt in einem plötzlichen Anstieg an Auslagerungen in der Stunde von 14:00-15:00. Zur Vereinfachung wurde eine bestimmte Stunde gewählt. Das Ereignis wird konkret so definiert, dass sämtliches im MHS vorhandene Material in der Stunde, in dem das Ereignis passiert, als Auslageraufträge angefragt werden. Alle weiteren Einlagervorgänge entfallen. Das Ereignis bewirkt keine Änderung des Systemparameters, also der stochastischen Tageskurve, da der Anstieg unabhängig vom angenommenen Normalverlauf separat betrachtet wird. Somit gilt  $t_e = 0$

und  $f_e(p) = p$  nach den Definitionen aus Abschnitt 5.6. Es wird für die Nichteintritts- bzw. Eintrittswahrscheinlichkeiten von  $p_e = 0,95$  und  $p_{\bar{e}} = 0,05$  ausgegangen.

Der Wirkungszeitraum einer Maßnahme ist in dieser Anwendung bis zum Ende des Tages, es handelt sich also um einen situationsabhängigen Zeithorizont. Für eine Situation  $s_i$  zur Stunde  $t_i$  gilt  $T(s_i) = 13 - t_i$ <sup>3</sup>. Im MHS kann schließlich eine angewandte Maßnahme, bei der beispielsweise Material anders eingelagert werden, Auswirkungen auf Auslagervorgänge am Ende des Tages haben. Die in Abschnitt 5.3 definierte Bedingung für die rekursive Anwendung der Bewertung

$$\begin{aligned} &\text{Für Knoten } v_1 = (z_1, s_1, t_1) \text{ und } v_2 = (z_2, s_2, t_2), \text{ o.B.d.A.} \\ &t_1 \leq t_2 : t_2 - t_1 + T(s_2) \leq t_1 + T(s_1). \end{aligned}$$

ist hier erfüllt. Es gilt schließlich

$$\begin{aligned} &t_2 - t_1 + (13 - t_2) \leq t_1 + (13 - t_1) \\ \Leftrightarrow &13 - t_1 \leq 13 \\ \Leftrightarrow &-t_1 \leq 0 \quad \square \end{aligned}$$

Es ergibt sich daher durch rekursive Anwendung bei dem in Abbildung 6.4 dargestellten Beispiel für die Kanten der Maßnahmen „hohe Last Auslagerung oder gemischt“ und „geringe Last“ eine zugeordnete Wahrscheinlichkeit von 0, da die Bewertung die Auswahl der Maßnahme „hohe Last Einlagerung“ vorgibt. In Kombination mit dem langen Wirkungszeitraum ergibt sich der Umstand, dass die Bewertungsmethode praktisch nur ein Mal auf die Situation am Anfang des Tages angewendet werden muss und dabei gleich für den gesamten Tag allen Situationen innerhalb des Teilbaumes entlang der optimalen Maßnahmen eine Maßnahme zugeordnet werden kann.

Entsprechend des Ziels der Steuerung lautet die zu maximierende Nutzenfunktion  $N$  die negative durchschnittliche Wartezeit eines Auftrages. Für eingehendes Material wird die Zeit dabei vom Einreihen in eine Warteschlange vor dem MHS bis zum Starten des Einlagerns in die Übergabekabine gemessen. Bei ausgehendem Material von der Bestellung bis zur Bereitstellung in der Übergabekabine. Es wären auch andere Ziele denkbar, wie

<sup>3</sup> Dabei entspricht 07:00 Uhr  $t_i = 0$ , 08:00 Uhr  $t_i = 1$  usw.




Abbildung 6.4.: Ausschnitt des Zustandsraumgraphen

etwa die Minimierung der Anzahl an Aufträgen, deren Wartezeit eine bestimmte Zeit übersteigt.

Die unterschiedlichen Zielknoten anhand des plötzlichen Anstieges werden mittels des entwickelten Kriteriums von Hodges-Lehmann mit  $q = 0,25$  aggregiert, da nur zwei Umweltzustände existieren und es wichtiger ist, eine sehr lange Wartezeit bei Auslagern im Ereignisfall zu vermeiden. Dagegen kann eine längere Wartezeit unter moderater Last eher akzeptiert werden. Daher ist das Verfahren nach den Kriterien aus Abschnitt 5.3.2 besser geeignet als das  $\mu - \rho$ -Prinzip.

### Rechenzeit der Bewertung

Es ergibt sich für einen betrachteten Zeitraum von 07:00-20:00 nach der in Abschnitt 5.3.1 entwickelten Abschätzung  $(3 \cdot 1,5)^{13} \approx 310000000$  für die Anzahl an Knoten. Für ein Blatt (Simulation von 13 Stunden) wurde mittels des im folgenden Abschnitt erläuterten Simulationsmodells in d<sup>3</sup>fact eine Rechenzeit von ca. 60 Sekunden gemessen<sup>4</sup>. Dadurch ergibt sich zunächst eine Rechenzeit der Bewertung von  $\sim 585$  Jahren, da weit mehr Blätter als Knoten in den höheren Bereichen des Baumes existieren. Die in Abschnitt 5.3.2 eingeführten Methoden zur Reduzierung der Rechenzeit sind hier also notwendig.

<sup>4</sup> Die Simulation lief auf zum Zeitpunkt der Erstellung dieser Arbeit üblicher PC Hardware: Intel Core i5 Dual Core 2,66Ghz, 8GB RAM

Aufgrund der Betrachtung eines Tages als Periode wird in Hinblick auf Neugenerierung von Zuordnungen eine Rechenzeit von unter 24 Stunden angestrebt.

Die Voraussetzung für Uniform-Cost Search (Nutzen eines Knotens nimmt mit jeder Kante ab) liegt hier nicht vor. Es können allerdings Pruning und Parallelisierung angewendet werden.

Nach folgenden Kriterien werden Zweige im Baum „abgeschnitten“:

1. Die beiden Maßnahmen „hohe Last Einlagerung“ und „hohe Last Auslagerung oder gemischt“ unterscheiden sich lediglich im Prefetching. Bei diesen Maßnahmen wird das Material also an dieselben Positionen gestellt, sodass keine Auswirkungen auf spätere Stunden möglich sind. Nach Ausführung der Maßnahmen kann also sofort der Knoten, der in der letzten Stunde eine höhere Wartezeit hat, sicher abgeschnitten werden. Da dann anstatt drei nur noch zwei Maßnahmen weiterverfolgt werden, verringert sich die Anzahl der Knoten um den Faktor  $\frac{3^{13}}{2} \approx 195$ .
2. In Stunden mit  $>1000$  Auslagerungen und  $<250$  Einlagerungen ist die Maßnahme „geringe Last“ fast identisch mit den anderen beiden. Aufgrund der wenigen Einlagerungen hat die verschiedene Stellplatzauswahl einen geringen Effekt und wegen vieler Auslagerungen sind wenige TVs für Umlagervorgänge verfügbar. Es kann also mit hoher Wahrscheinlichkeit der Zweig abgeschnitten werden, wodurch sich die Rechenzeit um den Faktor  $4,5^n$  verringert, wobei  $n$  die Anzahl der betreffenden Stunden ist.
3. In Stunden mit  $>1000$  Auslagerungen und  $<250$  Einlagerungen ist die Maßnahme „geringe Last“ fast identisch mit den anderen beiden. Aufgrund der wenigen Einlagerungen hat die verschiedene Stellplatzauswahl einen geringen Effekt und wegen vieler Auslagerungen sind wenige TVs für Umlagervorgänge verfügbar. Es kann also mit hoher Wahrscheinlichkeit der Zweig abgeschnitten werden, wodurch sich die Rechenzeit um den Faktor  $4,5^n$  verringert, wobei  $n$  die Anzahl der betreffenden Stunden ist.
4. Es werden zunächst die Zweige ohne Eintreten des Ereignisses verfolgt. Falls die resultierende Bewertung der drei Maßnahmen unter Nichteintritt einen signifikanten Unterschied der bestbewerteten Maßnahme  $m_1$  zur am zweitbesten bewerteten Maßnahmen  $m_2$  ergibt, kann abgeschätzt werden, dass die Betrachtung unter Eintritt die Reihenfolge nicht verändern wird. Es wurde experimentell ermittelt, dass eine

Abweichung von 15% zwischen den beiden Fällen bereits einen negativen Extremfall darstellt. Ein Leistungsverlust ist zwar möglich, kann aber als unwahrscheinlich betrachtet werden. Das konkrete Kriterium lässt sich mithilfe der in Abschnitt 5.3.2 eingeführten Bezeichnungen definieren. Die Bewertung  $B(m_j)$  einer Maßnahme hängt von der Bewertung der resultierenden Kindknoten  $v_{j_e}$  und  $v_{j_{\bar{e}}}$  (jeweils unter Eintritt und Nichteintritt von  $e$ ) ab. Es lässt sich also  $B(m_j) = B(B(v_{j_e}), B(v_{j_{\bar{e}}}))$  schreiben. Im beschriebenen Szenario sind  $B(v_{1_{\bar{e}}})$  und  $B(v_{2_{\bar{e}}})$  bekannt,  $B(v_{1_e})$  und  $B(v_{2_e})$  allerdings unbekannt, wobei auf deren Berechnung möglichst verzichtet werden soll. Der Zweig kann mit einer hohen Wahrscheinlichkeit abgeschnitten werden, wenn  $B(B(v_{1_{\bar{e}}}), 1,15 \cdot B(v_{1_{\bar{e}}})) \geq B(B(v_{2_{\bar{e}}}), B(v_{2_{\bar{e}}}))$ . Dies bedeutet, dass selbst bei einer ungünstigen Verschlechterung der Leistung von  $m_1$  bei Eintritt von  $e$  und gleichzeitig keinem Verlust der Leistung von  $m_2$  im Ergebnis  $m_1$  die höhere Gesamtbewertung hätte. In dem Fall braucht das Ereignis nicht mehr betrachtet werden, was eine Verbesserung um  $1,5^{13} \approx 195$  ergibt, falls dies in jeder Stunde geschieht.

5. Der Wirkzeitraum einer Maßnahme ist weiterhin begrenzt, falls das MHS im Laufe des Tages entweder fast leer oder fast voll ist. Bei einem fast leeren MHS existiert kaum Material, das je nach Maßnahme an anderen Stellplätzen steht und das folglich wenig Einfluss auf die weitere Leistung hat. Bei einem fast vollen MHS existieren nur wenige leere Stellplätze, sodass bei gleich welcher Maßnahme die Stellplatzbelegung ähnlich ausfällt. Als Schwellwert wird hier aus experimentellen Beobachtungen folgend 5% und 75%<sup>5</sup> festgelegt.

Tritt einer der beiden Fälle ein, werden alle Zweige ab diesem Zeitpunkt abgeschnitten und das Verfahren von den bis dahin besten Maßnahmenkombinationen aus neu gestartet. Die Kombinationen sind jeweils in den jeweiligen Ausprägungen der Unsicherheiten bis zu diesem Zeitpunkt optimal. Hier existiert eine optimale Maßnahmenkombination unter normalem Verlauf der Tageskurve, eine unter Eintritt des Anstiegs nach 13:00 Uhr oder nach 14:00 Uhr usw. Es ergibt sich bei  $n$ -maligem Eintritt des Falles nach  $s_1, s_2, \dots, s_n$  Stunden mit jeweils  $u_1, u_2, \dots, u_n$  Ausprägungen eine Reduzierung von  $4,5^{13}$  auf

$$u_1 \cdot 4,5^{s_1} + 4,5^{13-s_n} + \sum_{i=2}^n u_i \cdot 4,5^{s_i-s_{i-1}}.$$

<sup>5</sup> Der höhere Schwellwert ist relativ niedrig, da Stellplätze auf Wartungspositionen bei allen Maßnahmen zunächst freigehalten werden.

Für  $n = 1, s_1 = 4, u_1 = 1$  etwa ergibt dies den Faktor  $\sim 400$ , für  $n = 2, s_1 = 4, u_1 = 1, s_2 = 8, u_2 = 1$  den Faktor  $\sim 13600$ .

6. Schließlich kann der Wirkzeitraum einer Maßnahme auf  $n$  Stunden begrenzt werden und das Verfahren nach jeder Stunde neu gestartet werden. Dadurch gehen mögliche Auswirkungen auf spätere Stunden nicht in die Bewertung ein, allerdings ergibt sich eine Verbesserung der Rechenzeit auf  $13 \cdot 4,5^n$ . Für  $n = 6$  etwa ergibt sich eine Verbesserung um dem Faktor  $\frac{1}{13} \cdot 4,5^6 \approx 640$ .

Die Implementierung der Maßnahme in d<sup>3</sup>fact wurde so gestaltet, dass je nach Anzahl logischer Prozessoren<sup>6</sup> automatisch entsprechend viele Threads erstellt werden, in denen die Simulation eines Knotens erfolgt. Dadurch werden parallel mehrere Knoten ausgewertet, was wiederum einer Reduzierung der Rechenzeit um die Anzahl logischer Prozessoren ergibt. Diese parallele Berechnung auf einem Mehrkernprozessor lässt sich leicht umsetzen und erfordert keine aufwändige (balancierte) Verteilung der Aufträge auf verschiedene in einem Netzwerk verbundene PCs. Die Verteilung geschieht in diesem Fall automatisch durch das Betriebssystem, ebenso werden die Ergebnisse transparent und ohne Netzwerkübertragung dem Programm mitgeteilt.

Insgesamt kann durch Pruning und Parallelisierung das Ziel der Rechenzeit unter 24 Stunden erreicht werden. Beispielsweise ergibt sich bei 4 logischen Prozessoren, dem sicheren Pruning Kriterium 1. und einem vollen MHS nach 6 Stunden  $\frac{3^6+3^6}{4} = 365$  Knoten  $\hat{=} \sim 6$  Stunden Rechenzeit.

In Abbildung 6.5 ist die rekursive Bewertung unter Berücksichtigung des Ereignisses und des Prunings dargestellt. Ausgangspunkt ist die Bewertung von den Maßnahmen „hohe Last Einlagerung“, „hohe Last Auslagerung oder gemischt“ und „geringe Last“, die zur kompakteren Darstellung mit den Berechnungen  $m_1$  bis  $m_3$  abgekürzt werden, zu Beginn des Tages um 07:00. Ein Knoten ist zur Übersicht nur mit der Zeit beschriftet. Anhand des rekursiven Aufbaus werden dann die Maßnahmen – ausgehend von den drei Kindknoten, die die jeweilige Situation um 08:00 darstellen – bewertet. Dabei kann aufgrund der Pruning Methode 1. eines der drei Kindknoten verworfen werden. In der Abbildung ist dies um 08:00 etwa der Knoten nach Ausführung von „hohe Last Auslagerung oder gemischt“. Die Bewertung verzweigt sich immer weiter, bis  $2^7 = 128$  Knoten auf der Ebene entsprechend 14:00 erzeugt wurden. Von diesen Knoten aus werden nun 6 Kindknoten erzeugt, da jede

<sup>6</sup> Moderne Prozessoren bestehen aus mehreren physischen Kernen, in denen wiederum bestimmte Hardwareeinheiten mehrfach ausgelegt sind, was eine Gesamtanzahl an logischen Prozessoren ergibt.




Abbildung 6.5.: Rekursive Bewertung der Maßnahmen unter Berücksichtigung des Ereignisses um 14:00 und den Pruning Methoden

Maßnahme auch unter Eintreten des Ereignisses evaluiert wird. Es werden also weitere  $6 \cdot 2^7 = 768$  Knoten evaluiert. Normalerweise würde für jeden Knoten hier die Bewertung weiter verzweigen, allerdings endet die Bewertung aus zwei verschiedenen Gründen. Zum einen ist im Ereignisfall der Tagesablauf per Definition beendet. Zum anderen greift ohne Ereignis die Pruning Methode 4., da dann so viel Material eingelagert wird, dass das MHS fast vollständig befüllt ist. Aus den aggregierten Werten kann dann die beste Maßnahme eines Knotens zum Zeitpunkt 14:00 bestimmt werden, sodass nur noch 2 der 6 Kindknoten betrachtet werden müssen. Auf jeder darüber liegenden Ebene führt jede alternative Maßnahme somit zu zwei möglichen Zielknoten. Auf jeder Ebene kann die Aggregation durchgeführt werden und somit führt die Bewertung rekursiv zu einer Lösung



für den Ausgangsknoten und allen Knoten auf dem Pfad bis 15:00. Tatsächlich kann hier einfach die Aggregation für alle Knoten um 14:00 durchgeführt werden und der Pfad zum bestbewerteten verwendet werden, da keine Verzweigungen oberhalb existieren. Dabei kann durch die Berücksichtigung des Ereignisses ein gänzlich verschiedener Pfad resultieren, wie das Beispiel in Abbildung 6.5 zeigt. Der Pfad zu dem Knoten mit der optimalen Maßnahmenkombination ohne Eintreten des Ereignisses ist rot dargestellt. Der markierte Knoten um 15:00 entspricht also dem bestmöglichen Resultat der Maßnahmenauswahl in darüber liegenden Ebenen. Der Pfad zum in Aggregation optimalen Knoten ist hingegen in gelb dargestellt. Wie zu erkennen ist, divergiert bei Berücksichtigung des Ereignisses die optimale Maßnahmenwahl vom Ausgangsknoten aus. Dies ist dem Umstand zu schulden, dass Entscheidungen am Anfang die Leistung des Systems im Ereignisfall später negativ beeinflussen können und wird durch die Bewertung aufgedeckt. Die Bewertung kann nach Beendigung ab 15:00 neu gestartet werden gemäß der Pruning Methode 4.

### 6.2.5. Simulationsmodell

Die Entwicklung des Simulationsmodells basiert auf zur Verfügung gestellten Daten des Lagersystems. Diese umfassen die Spezifikationen der Abläufe, Kennzahlen der Steuerkomponenten (Beschleunigungs- und Geschwindigkeitswerte von Aufzügen, Transfer Vehicles etc.) und das Layout des Systems.

Zentraler Bestandteil des Simulationsmodells ist der *Operator*, welcher die Steuerung der einzelnen Transportfahrzeuge koordiniert. Gemäß einer vorgegebenen Anzahl an Ein- und Auslagerungen je Stunde werden gleichverteilt Ein- und Auslagerungsanfragen erstellt. Eine Auslagerungsanfrage bezieht sich immer auf ein zufällig gewähltes Material. Das heißt im Speziellen, dass Material unabhängig von der bisherigen Lagerzeit ausgewählt wird. Diese Anfragen werden in je einer Warteschlange für Ein- und Auslagerungen eingetragen. Der Operator reagiert auf Änderungen in diesen Warteschlangen und Zustandsänderungen der Fördereinheiten. Über eine definierte Strategie entscheidet der Operator, in welcher Reihenfolge die Anfragen bearbeitet werden. Auch beauftragt er die verschiedenen Fördereinheiten.

Während der Simulation ist der Wechsel zwischen verschiedenen Maßnahmen über eine grafische Benutzerschnittstelle möglich. In dieser sind die Effekte der verschiedenen Maßnahmen sichtbar.

Die Simulation wurde mit der Simulationsplattform d<sup>3</sup>fact durchgeführt, welche einige Funktionalität zur Auswertung der einzelnen Simulationsdurchläufe anbietet. So können während der Simulation Kennzahlen visualisiert und exportiert werden. Beispielsweise sind verschiedene Diagrammtypen wie Linien-, Kuchen- oder Zeitliniendiagramme (Abbildung 6.1) anzeigbar. Diese dienen zur Beobachtung von Warteschlangenlängen, Status der beteiligten Fördereinheiten und Wartezeiten der Ein- bzw. Auslagerungen. Die Diagramme sind beliebig vergrößer- bzw. verkleinerbar, sodass eine genauere Untersuchung der interessanten Bereiche möglich ist. Beispiele sind in Abbildung 6.6 dargestellt. Dabei ist die Draufsicht auf das 3D Modell des MHS aus Vertraulichkeitsgründen abstrahiert dargestellt.

Zusätzlich wurde ein 3D Modell (Abbildung 6.7) des Lagersystems umgesetzt, welches die Abläufe und den Zustand zur Laufzeit der Simulation wiedergibt. Es ist eine freie Navigation möglich. So sind die Abläufe der Simulation und die Längen der Warteschlangen direkt sicht- und validierbar.

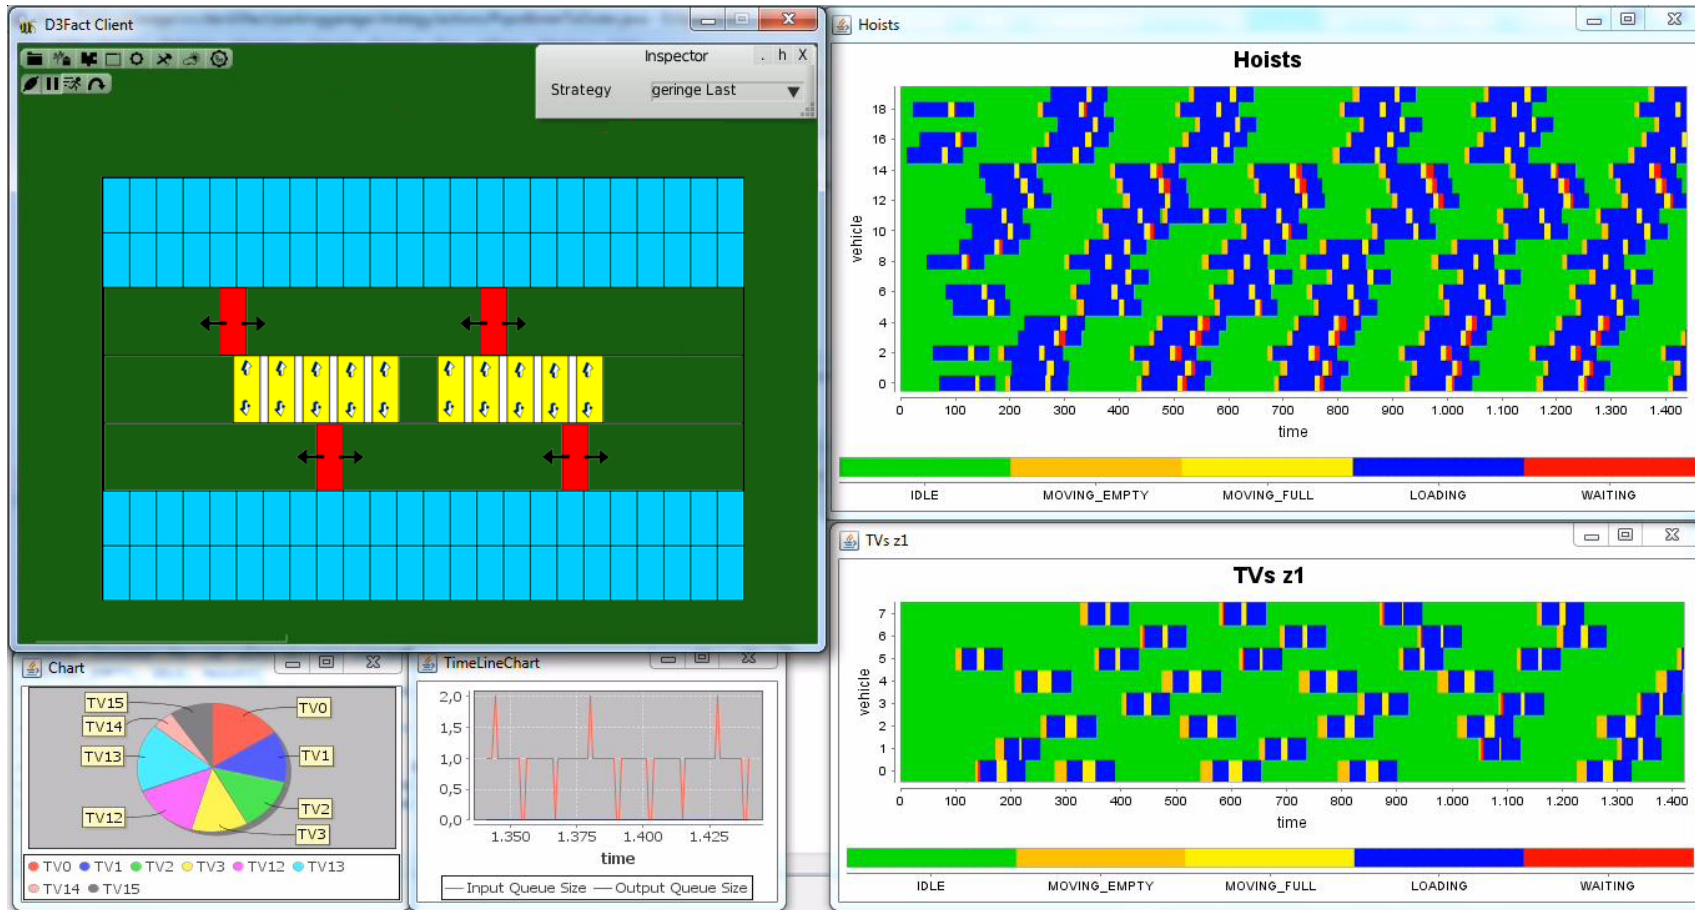


Abbildung 6.6.: Visualisierung des MHS mit Diagrammen




Abbildung 6.7.: 3D Modell des MHS in der Simulationssoftware d<sup>3</sup>fact in Kombination mit der Visualisierungssoftware PadRend

### 6.3. Evaluierung

Es wird zunächst von nicht veränderlichen Systemparametern ausgegangen, um die Funktionalität und Leistung des angewendeten Konzeptes im Vergleich zu Heuristiken darzulegen. In Abschnitt 6.3.1 wird daher ohne Anpassung an Veränderungen eine umfassende experimentelle Evaluierung dargelegt. Es wird speziell die Auswirkung der dynamischen Umschaltung zwischen den einzelnen Maßnahmen untersucht. In Abschnitt 6.3.2 werden weitere einzelne Komponenten des Konzeptes bzw. der gewählten anwendungsspezifischen Umsetzung isoliert betrachtet. Es folgt in Abschnitt 6.3.3 eine Untersuchung der Selbstanpassung des Konzeptes bei variablen Systemparametern. Die einzelnen Mechanismen

der Anpassungskomponenten sowie die resultierende Leistung nach Anpassung werden dargelegt. Das Kapitel endet mit einer abschließenden Bewertung in Abschnitt 6.3.4.

### 6.3.1. Evaluierung des angewendeten Konzeptes unter konstanten Systemparametern

Der einzige Systemparameter im betrachteten Anwendungsfall ist die stochastische Tageskurve der ein- und ausgehenden Materials (siehe Abschnitt 6.2.3). Es wird hier die folgende Tageskurve als konstant betrachtet. Sie ergab sich aus Anforderungsdefinitionen bei Konzeption des MHS und besteht aus den in Tabelle 6.3 dargestellten Werten. Diese Ausprägung wird weiterhin als die einzig mögliche betrachtet, daher ist die Wahrscheinlichkeit 1 zugeordnet. Aufgrund des betrachteten Ereignisses (siehe Abschnitt 6.2.4) ist nämlich bereits ein stochastischer Faktor exemplarisch in der Validierung behandelt.

Uhrzeit	Anzahl eingehend	Anzahl ausgehend
07:00	612	0
08:00	1012	0
09:00	0	0
10:00	617	592
11:00	0	0
12:00	330	750
13:00	0	0
14:00	875	300
15:00	0	0
16:00	0	1000
17:00	0	0
18:00	0	805
19:00	0	0

Tabelle 6.3.: Erwartete Anzahl an eingehendem und ausgehendem Material pro Stunde

In Abbildung 6.8 ist die Tageskurve in Form eines Balkendiagramms dargestellt.

Interessant sind dabei vor allem die Stunden mit einer hohen Anzahl an Ein- bzw. Auslagevorgängen, in denen das System an die Kapazitätsgrenze gehen muss und nicht mehr alle Aufträge schnell genug abarbeiten kann – ein Rückstau bildet sich. Dies führte in der Anwendung des Konzeptes aufgrund der Situationsdefinition zu jeder festen Stunde zu dem Problem, dass der Rückstau in der folgenden Stunde unter einer anderen Maßnahme abgearbeitet wurde. Aus diesem Grund werden die Aufträge in den ersten 45 Minuten




Abbildung 6.8.: Tageskurve des eingehenden und ausgehenden Materials

einer Stunde erzeugt und können somit innerhalb dieser abgearbeitet werden. Bei einer dynamischen Situationsdefinition, auf die hier aufgrund von Komplexitätsgründen verzichtet wurde, existiert dieses Problem allerdings nicht.

Unter der Tageskurve wurde die Trainingsdatengenerierung gestartet und es ergab sich zu den zwölf resultierenden Situationen (nach jeder Stunde jeweils) eine optimale Maßnahme, nämlich die jeweils folgende in der dargestellten Abfolge von Maßnahmen (Abbildung 6.9). Diese Abfolge wird im Folgenden als „Maßnahmenpfad“ bezeichnet. Aufgrund der diskutierten rekursiven Anwendung des Bewertungsverfahrens resultiert die Abfolge aus der Bewertung der Maßnahmen zur ersten Stunde.




Abbildung 6.9.: Bestbewertete Abfolge von Maßnahmen

Es handelt sich in den ersten sechs Stunden um einen Wechsel zwischen den Maßnahmen „geringe Last“ und „hohe Last Einlagerung“ – parallel zu der wechselnden Lastsituation. In den Mittagsstunden schaltet die Steuerung auch in den Ruhephasen in „hohe Last Einlagerung“. Die Gründe hierfür liegen in der Berücksichtigung der Möglichkeit des Ereigniseintritts und werden in Abschnitt 6.3.2.1 zusammen mit weiteren Ergebnissen und Einblicken in die Bewertungsmethode detailliert dargelegt. In den späteren Stunden, in denen viele Auslagerungen passieren, wird zunächst „hohe Last Auslagerung oder gemischt“ angewendet, vor der letzten Stunde mit hoher Last allerdings die Maßnahme „geringe Last“. Dieses Verhalten wird in Abschnitt 6.3.1.3 bei einem Blick auf weitere Kennzahlen verständlich.

### 6.3.1.1. Leistungskennzahlen bei Anwendung des Konzeptes

Unter der dargelegten Umsetzung des Konzeptes soll nun ein Vergleich zur statischen Anwendung jeder der drei Maßnahmen dargelegt werden. Eine Übersicht über die durchschnittlichen Wartezeiten für ein- und ausgehendes Material ist in Abbildung 6.10 gegeben.

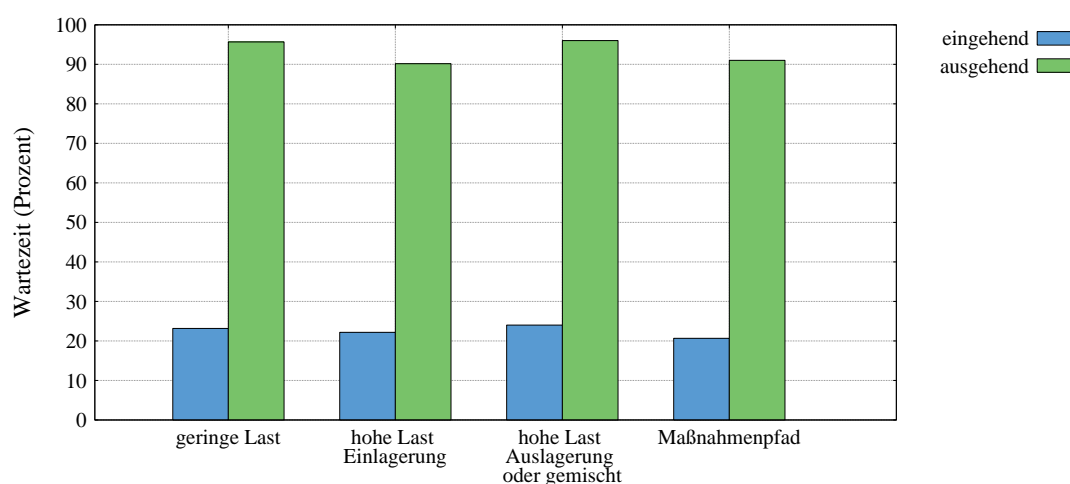


Abbildung 6.10.: Durchschnittliche Wartezeiten für ein- und ausgehendes Material

„hohe Last Einlagerung“ ist von den drei betrachteten Maßnahmen die leistungsfähigste. Die dynamische Umschaltung anhand des Maßnahmenpfades resultiert im Vergleich zur konstanten Anwendung der besten Maßnahme „hohe Last Einlagerung“ in einer Verkürzung

der Wartezeiten um 3,5%. Die Wartezeit bei einer Einlagerung verkürzt sich um durchschnittlich 7,0%, bei einer Auslagerung ist sie gleichbleibend. Allerdings lässt sich durch das Konzept nur ein geringer Anteil des Betriebsablaufes beschleunigen, da Prozesse wie Laden/Umladen eines Materials konstant lange sind. Wesentliches Optimierungspotential lag im Verkürzen der Zeit, in der Aufzüge in Phasen hoher Last auf TVs warten müssen, da festgestellt werden konnte, dass die Aufzüge einen Flaschenhals im System darstellen. Bei Anwendung von „hohe Last Einlagerung“ lag der Anteil dieser Blockierzeit bei lediglich 31% der gesamten Zeit, in der ein Aufzug aktiv ist. Sie konnte um 25% verringert werden und dessen Anteil beträgt bei Anwendung des Maßnahmenpfades nur noch 23%.

Um die gemessenen Werte nachvollziehen und diskutieren zu können, soll zunächst im folgenden Abschnitt eine visuelle Untersuchung des Betriebsablaufes anhand der entwickelten 3D Visualisierung dargelegt werden. Im Anschluss geben weitere detaillierte Kennzahlen Aufschluss über die Wirkungsweise des Konzeptes.

#### **6.3.1.2. Untersuchung des Betriebsablaufes bei Anwendung des Konzeptes**

Im Folgenden werden die Vorgänge im automatischen Lagersystem anhand von Abbildungen des Zustands nach jeder Stunde dargestellt. Diese wurden anhand von Bildschirmfotos einer Draufsicht auf das System in der Simulationsvisualisierung zur Anonymisierung abstrakt nachgezeichnet. Ziel ist es, die Auswirkungen einer Maßnahme nachvollziehbar zu machen und dadurch die gemessenen Kennzahlen in einen verständlichen Kontext zu setzen. Es erfolgt dabei ein visueller Vergleich des Betriebsablaufes unter Verwendung der zuvor durch die Bewertung der Maßnahmen bestimmten optimalen Abfolge von Maßnahmen (siehe Abbildung 6.9), im Vergleich zur ausschließlichen Verwendung der Maßnahme „hohe Last Einlagerung“. Es ergibt sich eine genauere Analyse der Wirksamkeit der dynamischen Maßnahmenauswahl und eine Darstellung der durchgeführten konkreten Vorgänge wie Umlagern. In den Abbildungen 6.11(a) bis 6.11(v) ist der Zustand des MHS jeweils nach einer vollen Stunde angegeben. Es sind die Unterschiede in der Stellplatzauswahl und der Umlagervorgänge zu erkennen und diese sind teilweise in den Abbildungen markiert. Zudem ist die Ausgangssituation der kommenden Stunde dadurch nachvollziehbar.


Nach der ersten Stunde, um 08:00 Uhr (Abbildungen 6.11(a) und 6.11(b)), ist etwa zu erkennen, wie sich die unterschiedliche Stellplatzauswahl auswirkt. Bei Anwendung des Maßnahmenpfades, der in dieser Stunde die Maßnahme „geringe Last“ auswählt, wird das Material von außen nach innen eingelagert. In dieser Stunde ist die Last nämlich



so gering, dass die weiteren Wege der TVs aufgrund genügend hoher Kapazität keinen gewichtigen Leistungsabfall bewirken. Dadurch stehen um 08:00 Uhr, vor einer Stunde mit vielen Einlagerungen, mehr freie Stellplätze nahe der Aufzüge zur Verfügung im Vergleich zur konstanten Auswahl der Maßnahme „hohe Last Einlagerung“, bei der Material immer von innen nach außen eingelagert werden. Im dargestellten Verlauf, unter den gegebenen Parametern Tageskurve und Maßnahmenpfad, passieren relativ wenige Umlagerungen. Im Zeitraum zwischen 11:00 und 12:00 beispielsweise, in dem keine weiteren Vorgänge vorgesehen sind, werden bei Anwendung des Maßnahmenpfades einige Umlagerungen durchgeführt. Ein Ausschnitt ist in Abbildung 6.11(i) dargestellt. Dadurch werden, wie der Vergleich zu Abbildung 6.11(j) zeigt, Lücken innerhalb des Materials geschlossen. Dadurch sollten sich bei Einlagerungen die Anzahl an Shufflevorgängen reduzieren – eine Vermutung, die im folgenden Abschnitt weiter untersucht wird.


Zeitpunkt 08:00: 612 Einlagerungen, 0 Auslagerungen in der vergangenen Stunde

Maßnahmenpfad: „geringe Last“



(a) Material wird zeilenweise von außen nach innen eingelagert. Die Pfeile geben die Richtung der Stellplatzauswahl an.


Konstant „hohe Last Einlagerung“



(b) Material wird spaltenweise von innen nach außen eingelagert. Die Pfeile geben die Reihenfolge der Stellplatzauswahl an.


Zeitpunkt 09:00: 1012 Einlagerungen, 0 Auslagerungen in der vergangenen Stunde

Maßnahmenpfad: „hohe Last Einlagerung“



(c) Material wird spaltenweise von innen nach außen eingelagert. Die Pfeile geben die Richtung der Stellplatzauswahl an.


Konstant „hohe Last Einlagerung“



(d) Weitere Einlagerungen

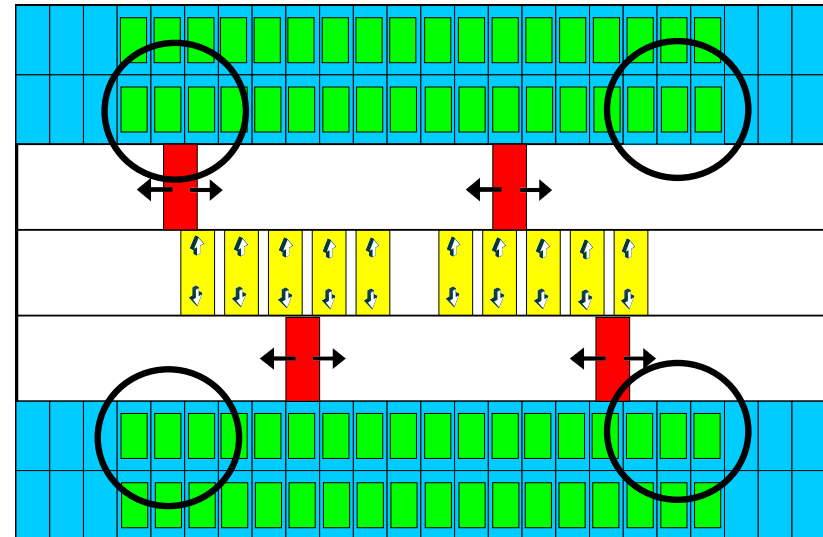
Zeitpunkt 10:00: 0 Einlagerungen, 0 Auslagerungen in der vergangenen Stunde

Maßnahmenpfad: „geringe Last“



(e) Da keine freie Stellplätze in den hinteren Reihen existieren, werden keine Umlagerungen durchgeführt. Aufgrund der Einlagerung von außen nach innen in der ersten Stunde bleiben einige wenige Stellplätze hoher Güte frei (markiert).


Konstant „hohe Last Einlagerung“



(f) Keine Vorgänge


Zeitpunkt 11:00: 617 Einlagerungen, 592 Auslagerungen in der vergangenen Stunde

Maßnahmenpfad: „hohe Last Einlagerung“



(g) Aufgrund der zufälligen Ein- und Auslagerungen ergeben sich Lücken in den hinteren Reihen, die durch das Umlagern geschlossen werden. Eine Umlagerung ist markiert.


Konstant „hohe Last Einlagerung“



(h) Die Lücken sind hier ebenfalls entstanden.


Zeitpunkt 12:00: 0 Einlagerungen, 0 Auslagerungen in der vergangenen Stunde

Maßnahmenpfad: „geringe Last“



(i) Die markierte Umlagerung ist durchgeführt, alle Lücken sind geschlossen.


Konstant „hohe Last Einlagerung“



(j) Keine Vorgänge sind passiert. Die Lücken sind noch offen.


Zeitpunkt 13:00: 330 Einlagerungen, 750 Auslagerungen in der vergangenen Stunde

Maßnahmenpfad: „hohe Last Einlagerung“



(k) Viele Aus- und einige Einlagerungen sind passiert. Aufgrund der Maßnahme bleiben die Lücken vorhanden.


Konstant „hohe Last Einlagerung“



(l) Viele Aus- und einige Einlagerungen


Zeitpunkt 14:00: 0 Einlagerungen, 0 Auslagerungen in der vergangenen Stunde

Maßnahmenpfad: „hohe Last Einlagerung“



(m) Keine Vorgänge

Konstant „hohe Last Einlagerung“




(n) Keine Vorgänge




Zeitpunkt 15:00: 875 Einlagerungen, 300 Auslagerungen in der vergangenen Stunde

Maßnahmenpfad: „hohe Last Einlagerung“



(o) Viele Ein- und einige Auslagerungen


Konstant „hohe Last Einlagerung“



(p) Viele Ein- und einige Auslagerungen


Zeitpunkt 16:00: 0 Einlagerungen, 0 Auslagerungen in der vergangenen Stunde

Maßnahmenpfad: „hohe Last Auslagerung oder gemischt“



(q) Keine Vorgänge

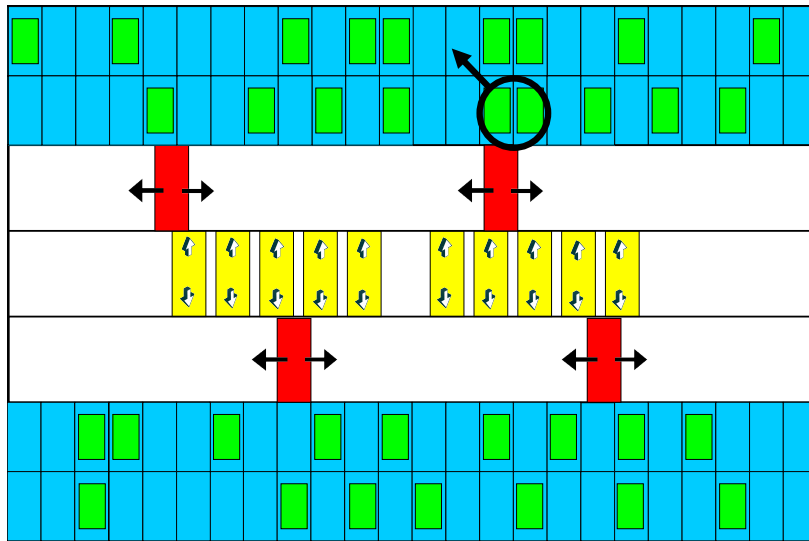
Konstant „hohe Last Einlagerung“



(r) Keine Vorgänge

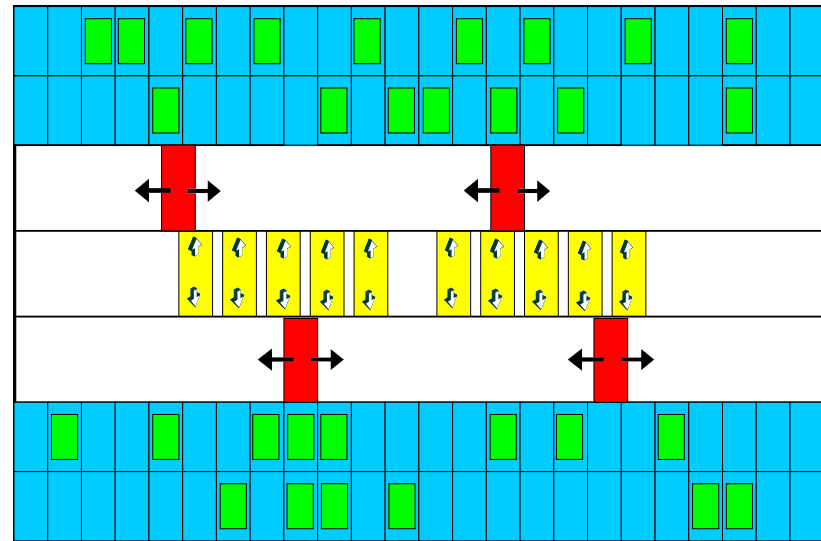
Zeitpunkt 17:00: 0 Einlagerungen, 1000 Auslagerungen in der vergangenen Stunde

Maßnahmenpfad: „hohe Last Auslagerung oder gemischt“



(s) Viele Auslagerungen sind passiert. Eine Umlagemöglichkeit ist markiert.

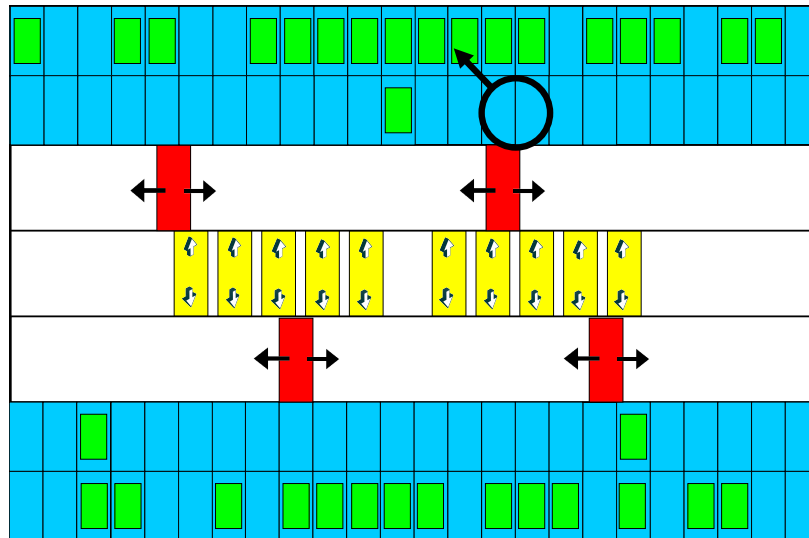
Konstant „hohe Last Einlagerung“



(t) Viele Auslagerungen


Zeitpunkt 18:00: 0 Einlagerungen, 805 Auslagerungen in der vergangenen Stunde

Maßnahmenpfad: „geringe Last“



(u) Weitere Umlagervorgänge sind passiert. Es wurden Situationen mit zwei Einheiten Material hintereinander aufgelöst (beispielhaft markiert). Das dargestellte Material wird in der letzten Stunde ausgelagert.

Konstant „hohe Last Einlagerung“



(v) Keine Vorgänge sind passiert. Das dargestellte Material werden in der letzten Stunde ausgelagert.

Abbildung 6.11.: Darstellung des MHS nach jeder Stunde

### 6.3.1.3. Detaillierte Evaluierung

Anhand weiterer Kennzahlen und der im vorigen Abschnitt dargestellten visuellen Untersuchung soll im Folgenden detailliert dargelegt werden, an welchen Stellen die Anwendung des Konzepts Leistungsvorteile erwirkt. Dabei ist bei der Begründung zu berücksichtigen, dass aufgrund der Tatsache, dass die Maßnahmen auf dem Pfad von der Bewertungsmethode ausgewählt wurden, sichergestellt ist, dass diese Vorteile gegenüber den Alternativen erwirken.

In Ergänzung zu den durchschnittlichen Wartezeiten über den gesamten Tag (in Abbildung 6.10 dargestellt) soll zunächst aufgeschlüsselt werden, in welchen Stunden die Wartezeiten entstehen, die zudem nach Ein- und Auslageraufträgen getrennt gestaffelt sind. Die Werte sind in Tabelle 6.5 dargestellt und in Abbildung 6.12 grafisch illustriert. Zusätzlich ist die Anzahl an Shuffle- und Umlagervorgängen in Tabelle 6.4 dargestellt.

In den ersten beiden Stunden sind keine Unterschiede festzustellen, da das MHS unterhalb der Leistungsgrenzen arbeitet. Im Zeitraum von 10:00-12:00 bewirkt die Anwendung des Konzeptes einen großen Leistungsvorteil von 14%. Die Ursache liegt alleinig im Ausgangszustand des Lagers um 10:00. Wie Abbildung 6.11(e) zeigt, bewirken die geschaffenen freien Stellplätze in der Nähe der Aufzüge, dass genügend eingehendes Material schnell eingelagert werden können. Es entfallen zahlreiche Shufflevorgänge, da die freien Stellplätze erreichbar sind, wie aus Tabelle 6.4 ersichtlich wird. Dadurch werden TV-Kapazitäten für die zeitgleich erfolgenden Auslagerungen frei. Das aktivierte Prefetching, also die Priorisierung von TVs für Einlagerungen, wirkt sich bei konstanter Anwendung der Maßnahme „hohe Last Einlagerung“ in diesem Zeitraum (ausgehend von der Situation in Abbildung 6.11(f)) negativ aus, da TV Kapazitäten dann knapp sind. Bei der Ausgangssituation beim Maßnahmenpfad hingegen ist Prefetching von Vorteil, da aufgrund der genannten Entlastungen genügend TV-Kapazitäten vorhanden sind.

In den weiteren Stunden bis 16:00 hingegen ergeben sich nur geringe Unterschiede in der Leistung. Es werden allerdings aufgrund der Berücksichtigung des Ereignisses in beiden Fällen „hohe Last Einlagerung“ ausgeführt, sodass dieser Umstand zu erwarten war. Die durchgeführten Umlagerungen von 11:00-12:00 wirken sich kaum positiv aus, da von 12:00-13:00 fast keine Einlagerungen geschehen. Um 16:00 Uhr ergibt sich eine fast identische Ausgangssituation – es wurde kein weiteres Umlagern durchgeführt. Durch das Schließen der Lücken ergibt sich bei Auslagerung eines Materials schließlich eine höhere Zugriffszeit.




Abbildung 6.12.: Kumulierte Wartezeiten ein- und ausgehender Aufträge summiert pro Stunde im Tagesverlauf

Die Leistung von 16:00-17:00 ist daher fast identisch. Umlagern ist allerdings vor der letzten Stunde von Vorteil. Aus Abbildung 6.11(u) lässt sich vermuten, dass aufgrund der folgenden zeilenweisen Anordnung des Materials weniger Shufflevorgänge erforderlich sind, da kaum Material hintereinander steht. Die Daten in Tabelle 6.4 bestätigen dies. Allerdings ist vermutlich aufgrund der ausreichend verfügbaren TV-Kapazität dennoch kein bedeutender Leistungsunterschied ersichtlich.

Uhrzeit	Ein	Aus	Shufflevorgänge Maßnahmenpfad (%)	Shufflevorgänge konstant „hohe Last Einlage- rung“ (%)	Umlagervorgänge Maßnahmenpfad (%)
07:00	612	0	0	0	7
08:00	1012	0	0	0	0
09:00	0	0	0	0	3
10:00	617	592	82	100	0
11:00	0	0	0	0	46
12:00	330	750	100	90	0
13:00	0	0	0	0	0
14:00	875	300	46	58	0
15:00	0	0	0	0	0
16:00	0	1000	93	80	0
17:00	0	0	0	0	100
18:00	0	805	5	20	5

Tabelle 6.4.: Gemessene Anzahl an Shuffle- und Umlagervorgängen pro Stunde

Uhrzeit	Ein	Aus	Anzahl Maßnah- menpfad ein	Wartezeit Maßnah- menpfad ein (%)	Anzahl „hohe Last Einla- gerung“ ein	Wartezeit „hohe Last Einla- gerung“ ein (%)	Anzahl Maßnah- menpfad aus	Wartezeit Maßnah- menpfad aus (%)	Anzahl „hohe Last Einla- gerung“ aus	Wartezeit „hohe Last Einla- gerung“ aus (%)
07:00	612	0	612	30	612	30	0	0	0	0
08:00	1012	0	1012	30	1012	30	0	0	0	0
09:00	0	0	0	0	0	0	0	0	0	0
10:00	617	592	617	71	617	100	584	256	567	263
11:00	0	0	0	0	0	0	8	498	25	1719
12:00	330	750	330	26	330	26	720	226	745	227
13:00	0	0	0	0	0	0	30	531	5	394
14:00	875	300	875	78	875	72	300	219	300	226
15:00	0	0	0	0	0	0	0	0	0	0
16:00	0	1000	0	0	0	0	960	224	975	219
17:00	0	0	0	0	0	0	40	689	25	664
18:00	0	805	0	0	0	0	805	129	805	124

Tabelle 6.5.: Wartezeiten pro Stunde, nach Ein- und Auslagerungen aufgeschlüsselt



Zusammenfassend lässt sich beobachten, dass die entwickelten Maßnahmen in der Tat die Leistung des Systems steigern und eine alternierende Umschaltung zwischen ihnen, wie angedacht, von der Bewertung als optimal befunden wurde. In der verwendeten Tageskurve ergibt sich dadurch allerdings nur in einer Stunde eine deutliche Leistungssteigerung von 14%. Die Berücksichtigung eines größeren zeitlichen Horizontes wirkt sich hier positiv aus, da der Grund für die Leistungssteigerung in einer geänderten Einlagerstrategie drei Stunden zuvor liegt. Es ist aus der visuellen Analyse zu beobachten, dass bereits wenige zusätzliche freie Stellplätze einen großen Unterschied in der Leistung bewirken können. In der betrachteten Tageskurve wurden keine weiteren Leistungssteigerungen beobachtet. Dies ist insbesondere mit der Berücksichtigung des Ereignisses zu erklären. Über mehrere Stunden wird kein Umlagern vorgenommen, da im Ereignisfall ein Umlagern negative Auswirkungen hat. Es wurde gemessen, dass Umlagern ohne Eintreten des Ereignisses in der Stunde von 14:00 bis 15:00 eine Verkürzung der Wartezeiten um 10,3% bewirken würde. Weitere Umlagerungen im Tagesverlauf bewirken keine weiteren Steigerungen, da diese hinsichtlich zukünftiger Einlagerungen optimieren, die allerdings nur in den zwei genannten Stunden auftreten. Weiterhin ist zu beobachten, dass die Gesamtwegstrecke, die die TVs in einer Stunde exklusive Shufflevorgänge bewältigen, kaum Einfluss auf die Leistung hat. Die Anzahl an Shufflevorgängen ist hingegen eine einflussreichere Kennzahl.

Abbildung 6.13 illustriert den Status der Aufzüge über die Tageskurve dar. In Zeiten ohne Aus- und Einlagerungen sind die Hoists idle. In den Zeiten hoher Auslastung sind kurze Wartezeiten (rot), aber auch Idlezeiten (grün) zu sehen, obwohl sich bereits eine Warteschlange aufgebaut hat. Dies liegt daran, dass aufgrund fehlender freier TVs der Auftrag nicht an die Aufzüge weitergegeben werden kann. Somit ist also eine Reduzierung von Warte- und Idlezeiten innerhalb einer Phase hoher Last anzustreben. Die prozentualen Verteilungen dieser im Vergleich zwischen Maßnahmenpfad und Anwendung von „hohe Last Einlagerung“ sind in der Abbildung 6.14 angegeben. Es ist zu erkennen, dass die Anwendung des Maßnahmenpfades den Anteil an idle deutlich reduziert und die Aufzüge mehr laden, also besser ausgelastet werden. Diese Beobachtung liefert einen weiteren Grund für die höhere Leistung des Konzepts.

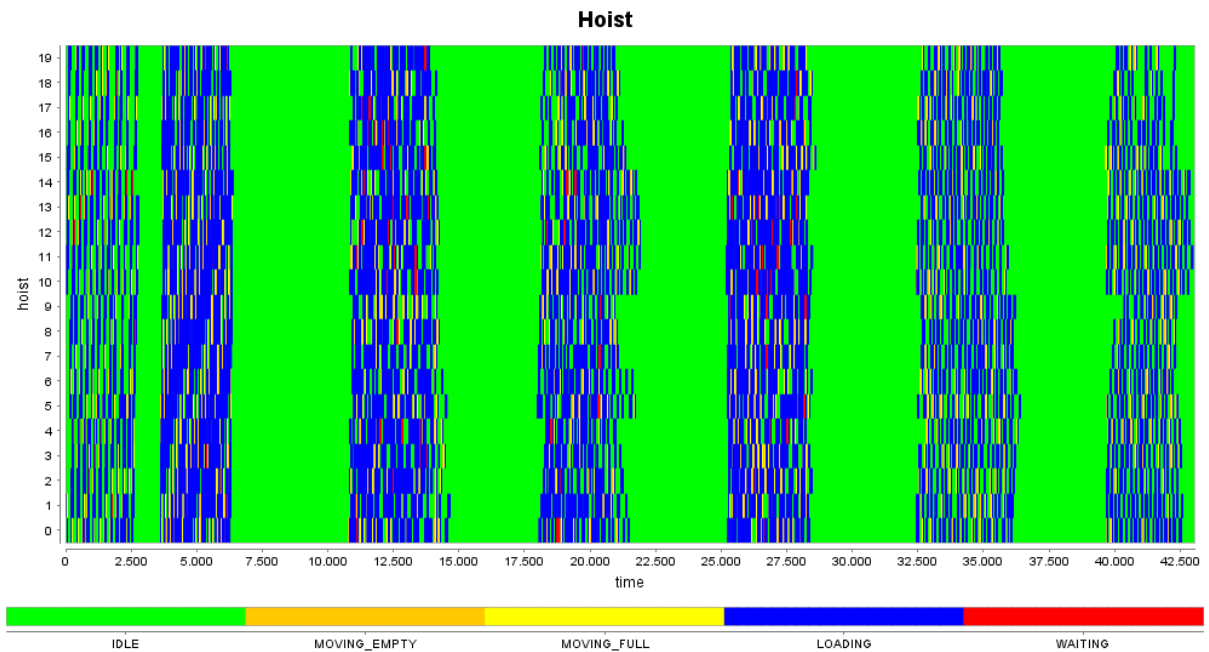


Abbildung 6.13.: Status der Übergabekabinen bei Anwendung des Maßnahmenpfades




Abbildung 6.14.: Status der Übergabekabinen in Zeiten hoher Last

### 6.3.2. Evaluierung einzelner Komponenten

Zunächst sollen diejenigen entwickelten Komponenten einzeln evaluiert werden, die unter jeweils einer Systemparameterausprägung als Eingabe funktionieren. Es wird daher der bisher verwendete Systemparameter weiter konstant gehalten.

#### 6.3.2.1. Evaluierung der Bewertung der Maßnahmen

Zunächst konnte validiert werden, dass anhand der in Abschnitt 5.3 dargelegten Grundlagen und Kriterien zur Bestimmung anwendungsspezifischer Teile, etwa des Zeithorizonts der Maßnahmen, im Falle des MHS eine Bewertung der Maßnahmen in akzeptabler Rechenzeit durchgeführt werden konnte. Speziell die Umsetzung des Prunings und der Bewertung unter Unsicherheit, also dem Eintritt eines Ereignisses, soll in diesem Abschnitt genauer betrachtet werden.

Die Bewertung wurde in zwei Phasen durchgeführt. Wie in Abschnitt 6.2.4 erläutert, konnte nach 15:00 das Verfahren von dem Knoten ausgehend neu gestartet werden, der nach Anwendung des bis dahin besten Maßnahmenpfades entsteht. In der ersten Phase wurden 1161 Knoten ausgewertet. Dieser Wert liegt im erwarteten Bereich. In der zweiten Phase mussten nur noch 93 weitere Knoten betrachtet werden, in Summe 1254. Ohne Pruning wären dies allerdings  $3^7 \cdot 3 + 3^{12} = 538002$  gewesen, da alle Maßnahmenkombinationen bis 19:00 und zusätzlich die Knoten um 15:00, die unter Eintreten des Ereignisses entstehen, hätten ausgewertet werden müssen. Pruning reduzierte die Anzahl hier also um einen Faktor von ca. 430. Auf einer CPU mit 8 logischen Kernen ergab sich schließlich eine Rechenzeit von  $3898 + 953 = 4851$  Sekunden, also ca. 80 Minuten.

Der Eintritt des Ereignisses bewirkte eine Änderung in der Tageskurve. Anstelle von 875 Ein- und 300 Auslagerungen wurden 0 Ein- und 1230 Auslagerungen in der Stunde von 14:00-15:00 generiert. Wie sich herausstellt, bewirken Maßnahmen bis 13:00 keine bedeutsame Änderung in der Leistung des Systems bei Eintritt des Ereignisses, sodass mit und ohne Berücksichtigung der Maßnahmenpfad bis 13:00 identisch ist. Es ergeben sich ab 13:00 die in Abbildung 6.15 dargestellte Verhältnisse. Die Maßnahmen „geringe Last“ und „hohe Last Einlagerung“ werden miteinander verglichen, während „hohe Last Auslagerung oder gemischt“ aus Gründen der Übersichtlichkeit nicht dargestellt ist. Die Maßnahmen, gefolgt von den beiden resultierenden Knoten, wurden bereits bewertet und in beiden Fällen wurde „hohe Last Einlagerung“ ausgewählt. So führt um 13:00 die

Anwendung beider Maßnahmen zu jeweils zwei möglichen Zielknoten. Aus den Nutzen der insgesamt vier möglichen Zielknoten ergibt sich die in Tabelle 6.6 dargestellte Berechnung des aggregierten Nutzens einer Maßnahme. Es zeigt sich, dass die Anwendung von „geringe Last“ im Nichteintrittsfall eine höhere Leistung ergibt. In der Stunde von 14:00-15:00 ergibt sich eine Wartezeit für Einlagerungen, die bei Anwendung von „hohe Last Einlagerung“ um 11% höher ist. Dies ergibt dementsprechend eine geringere durchschnittliche Wartezeit über den gesamten Tag gesehen und normalerweise würde „geringe Last“ ausgewählt werden.

Allerdings ergibt sich im Eintrittsfall des plötzlichen Anstiegs in der betreffenden Stunde ein umgekehrtes Bild. Bei Anwendung von „geringe Last“, bei dem Material in hintere und äußere Stellplätze umgelagert wird, ergibt sich bei vielen plötzlich angefragten Auslagerungen eine Wartezeit, die bei Anwendung von „hohe Last Einlagerung“ um 2,7% geringer ist. Aufgrund der geringen Eintrittswahrscheinlichkeit des Ereignisses ist „geringe Last“ im Erwartungswert dennoch die bessere Maßnahme. Da bei der Berechnung des Kriteriums von Hodges-Lehmann das schlechteste Ergebnis allerdings besonders gewichtet wird, wird letztlich „hohe Last Einlagerung“ höher bewertet und ausgewählt (fett hervorgehoben). In diesem Fall konnte also mit einer einstellbaren Risikoaversität das Ereignis berücksichtigt werden. In diesem Sinne wurde eine Maßnahme ausgewählt, die zwar den Nutzen nach Berechnung des Erwartungswertes verringert, dafür aber im schlechtesten Fall – in der Stunde mit vielen plötzlichen Auslagerungen – eine um 5% höhere Leistung ergibt.

Gewichtete Ergebnisse		Ausprägungen der Unsicherheiten		Erwartungswert $\mu_j$	Schlechtestes Ergebnis $N(v_{jk})$	Bewertung $B(m_j)$
		Kein Anstieg	Anstieg			
$p$		0,95	0,05			
Maßnahmen	„geringe Last“	-278	-356	-282	-356	-337
	„hohe Last Einlagerung“	-281	-352	-285	-352	<b>-335</b>

Tabelle 6.6.: Berechnung der Aggregation mittels des Kriteriums von Hodges-Lehmann

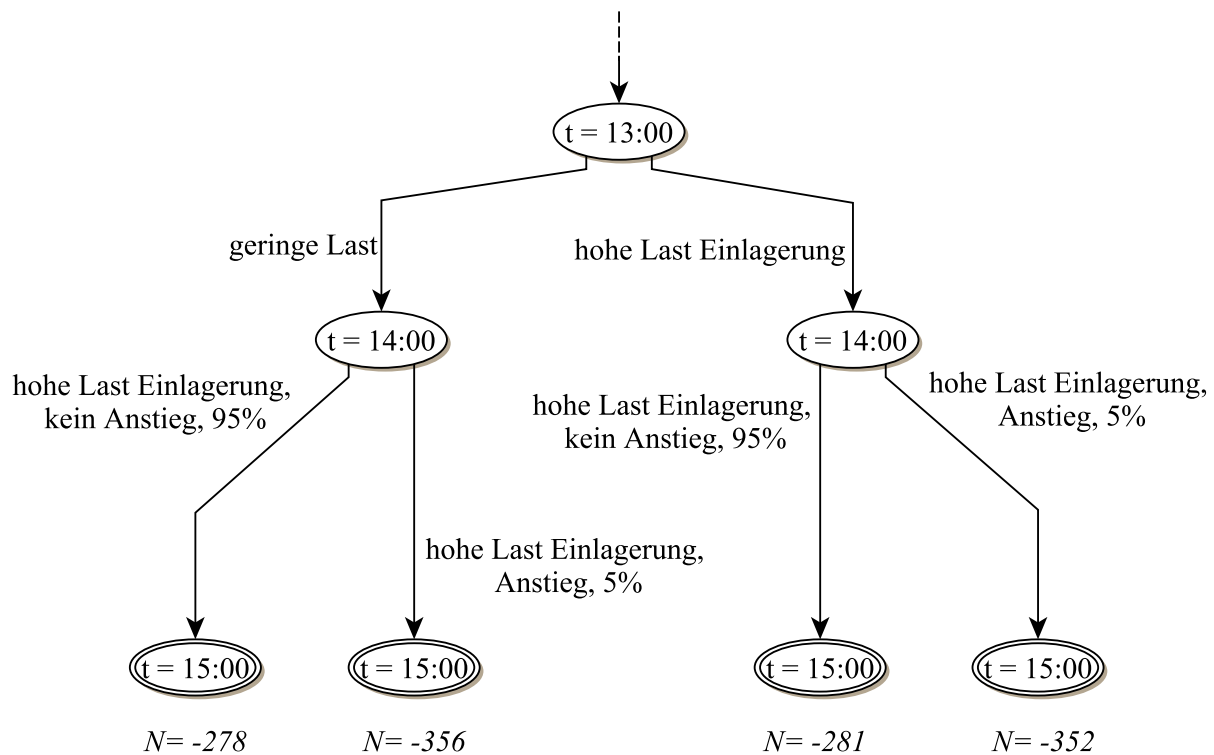


Abbildung 6.15.: Betrachtete Knoten bei Berücksichtigung des Ereignisses und Bewertung mittels Aggregation

### 6.3.2.2. Evaluierung der Situationsdefinition

Die in Abschnitt 5.2.2 definierten Kriterien und das Evaluierungsverfahren für Situationsdefinitionen soll in diesem Abschnitt hinsichtlich der in Abschnitt 2.3.2 genannten Anforderungen evaluiert werden. Dies soll exemplarisch anhand der in Abschnitt 6.2.2 definierten Situationsdefinition geschehen. Die resultierenden Trainingsbeispiele im ARFF Dateiformat sind ausschnittsweise in Abbildung 6.16 dargestellt. Es werden zunächst die 26 Attribute der Last der jeweiligen Stunde als numerisch definiert (lexikografisch sortiert), gefolgt von der ordinalen Definition der Maßnahme. Es sind drei Trainingsbeispiele aufgelistet, die die Situation in der Tageskurve nach drei, acht und zwei Stunden repräsentieren.

Bei dem MHS wurde erkannt, dass die Maßnahmenauswahl nicht nur von der aktuell anliegenden Systemlast abhängt, sondern auch von der im Tagesverlauf bisherigen und angenommenen zukünftigen. Deswegen wurde die Definition auf alle bisherigen Stunden

```

@attribute incoming0 numeric
@attribute incoming1 numeric
@attribute incoming10 numeric
@attribute incoming11 numeric
@attribute incoming12 numeric
@attribute incoming2 numeric
@attribute incoming3 numeric
@attribute incoming4 numeric
@attribute incoming5 numeric
@attribute incoming6 numeric
@attribute incoming7 numeric
@attribute incoming8 numeric
@attribute incoming9 numeric
@attribute outgoing0 numeric
@attribute outgoing1 numeric
@attribute outgoing10 numeric
@attribute outgoing11 numeric
@attribute outgoing12 numeric
@attribute outgoing2 numeric
@attribute outgoing3 numeric
@attribute outgoing4 numeric
@attribute outgoing5 numeric
@attribute outgoing6 numeric
@attribute outgoing7 numeric
@attribute outgoing8 numeric
@attribute outgoing9 numeric
@attribute rule {'geringeLast', 'hoheLastEinlagerung', 'hoheLastAuslagerungodergemischt'}

612, 1012, 2147483647, 2147483647, 2147483647, 0, 2147483647, 2147483647, 2147483647, ↘
  2147483647, 2147483647, 2147483647, 2147483647, 0, 0, 2147483647, 2147483647, ↘
  2147483647, 0, 2147483647, 2147483647, 2147483647, 2147483647, 2147483647, ↘
  2147483647, 2147483647, 'hoheLastEinlagerung'
612, 1012, 2147483647, 2147483647, 2147483647, 0, 617, 0, 330, 0, 875, 2147483647, ↘
  2147483647, 0, 0, 2147483647, 2147483647, 2147483647, 0, 592, 0, 300, 0, 300, ↘
  2147483647, 2147483647, 'hoheLastAuslagerungodergemischt'
612, 1012, 2147483647, 2147483647, 2147483647, 2147483647, 2147483647, 2147483647, ↘
  2147483647, 2147483647, 2147483647, 2147483647, 2147483647, 0, 0, 2147483647, ↘
  2147483647, 2147483647, 2147483647, 2147483647, 2147483647, 2147483647, ↘
  2147483647, 2147483647, 2147483647, 2147483647, 'geringeLast'

```

Abbildung 6.16.: Ausschnitt der resultierenden Trainingsbeispielen im ARFF Dateiformat

erweitert, um auch auf zukünftige schließen zu können. Im resultierenden Maßnahmenpfad kann erkannt werden, dass eine Klassifikation nach der aktuellen Systemlast nicht ausreichen würde. In den Stunden ohne Ein- und Auslagerungen sind Umlagerungen nur bedingt sinnvoll. Eine Situationsdefinition, die nur die aktuelle Last enthält, würde diese Differenzierung nicht erlauben.

Das Evaluierungsverfahren der Situationsdefinition sollte automatisierbar gestaltet werden. Zur Demonstration dieser Eigenschaft wurde das Verfahren in Form eines separaten Analyseprogrammes umgesetzt. Das Programm verfügt über eine grafische Oberfläche, die in Abbildung 6.17 dargestellt ist. Es lässt sich der Speicherort der ARFF Datei und einer Ausgabedatei definieren. Die vier definierten Verfahren lassen sich aus der Oberfläche starten. Dabei sind die Duplikatsuche (die eine Eingabe für  $\epsilon$  erlaubt), die Ermittlung des Informationsgehaltes und die Random Forest Methode vom Hauptbildschirm aus durch Setzen der entsprechenden Haken und Klicken von „anwenden“ zu starten. Teilweise sind die Verfahren Bestandteil des Programms und werden direkt gestartet. Teilweise wird auf das Softwareprogramm Weka [WF05] in Form einer Java Programmbibliothek zurückgegriffen und diese wird ohne Zutun des Benutzers verwendet. In zwei Fällen (Random Forest, Faktoranalyse) werden automatisch externe Implementierungen mit den richtigen Parametern und Daten gestartet. Dies erlaubt eine komfortable Handhabung. Die Ergebnisse werden in dem abgebildeten Ausgabefenster dargestellt. Für die verwendete Trainingsdatendatei ist deren Aussagekraft in diesem Anwendungsfall aufgrund der geringen Anzahl an Trainingsbeispielen begrenzt. Sie werden im Folgenden diskutiert.

Die Duplikatsuche mit  $\epsilon = 0,05$  findet hier erwartungsgemäß keine Duplikate.

Die Bewertung nach Informationsgehalt führt zu dem Ergebnis, dass die Unterschiede zwischen den Attributen relativ gering sind. Eine Ausnahme bilden die Attribute „incoming12“ und „outgoing12“ mit einem InformationGain von 0, da für diese Attribute kein Wert außer  $2^{31}$  angenommen wird. Die Generierung brach die Bewertung vorher ab, da sämtliches Material bereits ausgelagert war. In diesem Fall könnten die Attribute also entfernt werden. Die Attribute entsprechend den Lasten in der Mittagszeit der Tageskurve wurden am höchsten bewertet. Dies liegt an der Struktur des Maßnahmenpfades – vor 15:00 Uhr wird aufgrund vieler Einlagerungen oft „hohe Last Einlagerung“ ausgeführt, danach allerdings nicht mehr, dafür aber „hohe Last Auslagerung oder gemischt“. Das einzelne Attribut „incoming7“ zu dieser Uhrzeit nimmt die möglichen Werte  $2^{31}$  oder 875 an. Aus dieser Unterscheidung lässt sich für den Klassifizierer nur ableiten, ob die aktuelle

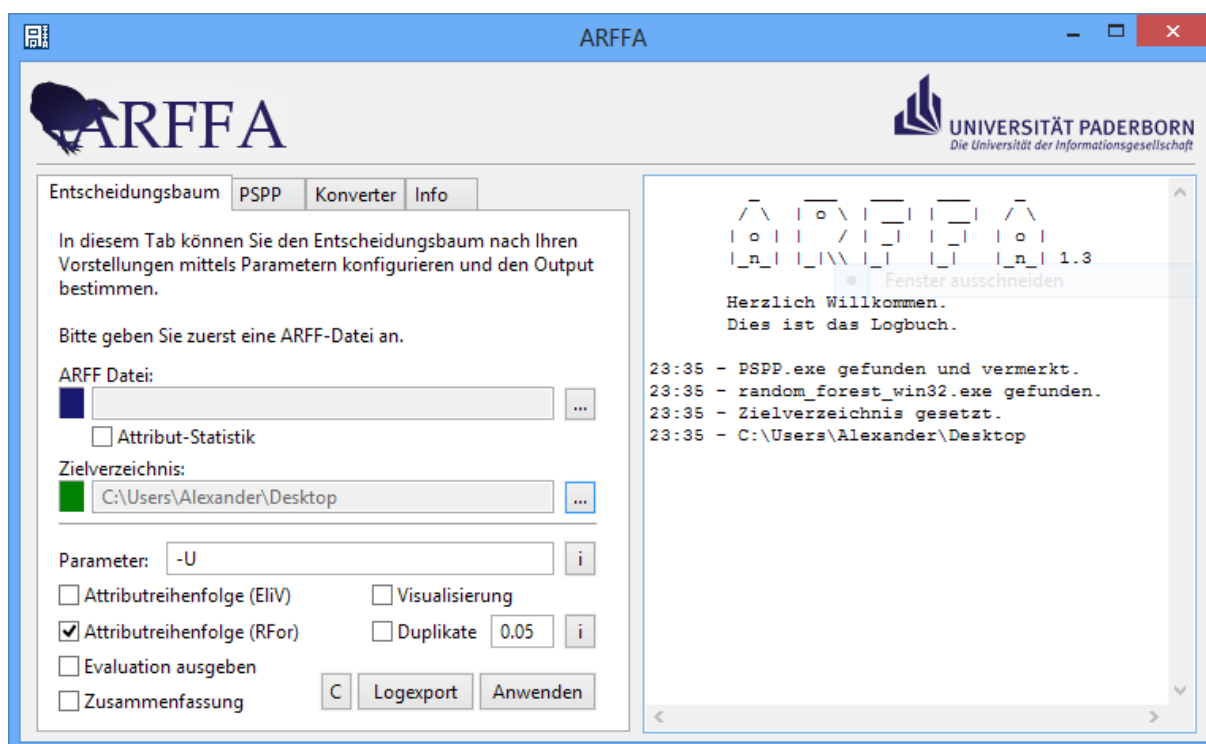


Abbildung 6.17.: Screenshot des Tools zum Test der Situationsdefinition

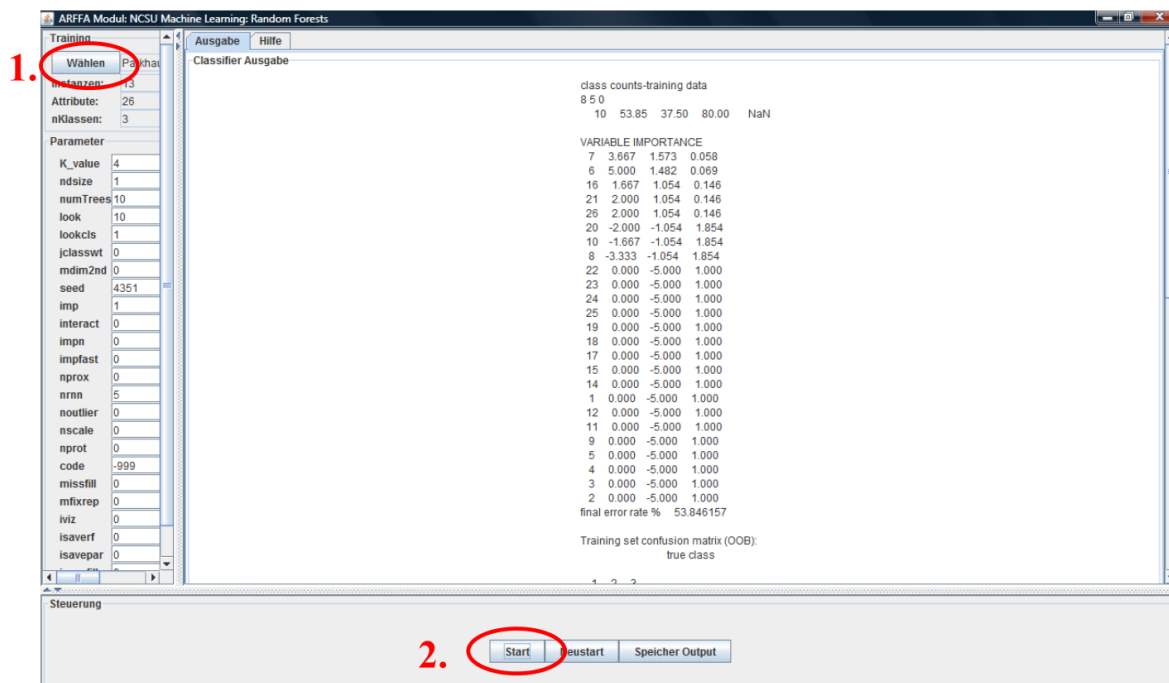


Abbildung 6.18.: Oberfläche der Random Forest Komponente



Uhrzeit vor oder nach 15:00 liegt. Daher sortiert dieses Attribut die Trainingsbeispiele gewissermaßen nach den beiden Maßnahmen. Hier ist die Schwäche der Bewertung deutlich, da ein einzelnes Attribut in dieser Situationsdefinition eine relativ geringe Aussagekraft besitzt und alle Attribute zusammen notwendig sind, um die genaue Uhrzeit und den bisherigen Verlauf zu bestimmen.

Attribute	Raw Score
incoming0	-0,015
incoming1	-0,04
incoming10	-0,065
incoming11	-0,005
incoming12	0,0
incoming2	-0,145
incoming3	-0,02
incoming4	-0,02
incoming5	-0,06
incoming6	-0,03
incoming7	0,315
incoming8	-0,045
incoming9	0,105
outgoing0	-0,01
outgoing1	-0,035
outgoing10	-0,01
outgoing11	-0,015
outgoing12	0,0
outgoing2	-0,025
outgoing3	-0,045
outgoing4	-0,015
outgoing5	-0,005
outgoing6	-0,01
outgoing7	0,155
outgoing8	0,005
outgoing9	0,04

Tabelle 6.7.: Gemessener Raw Score des Random Forest Verfahrens

Bei Durchführen des Random Forest Verfahrens startet das Analyseprogramm die Oberfläche einer externen Implementierung [Liv05]. Dabei sind die Parameter korrekt vorgegeben, es muss lediglich erneut die ARFF Datei spezifiziert werden (Schritt 1) und das Verfahren gestartet werden (Schritt 2). Die Ergebnisse der Berechnung des Raw Scores ist in Tabelle 6.7 dargestellt, unter Verwendung von 1000 Entscheidungsbäumen. Da das Verfahren stets zufällige Teilmengen der Trainingsbeispiele testet und darauf ausgelegt ist, mit einer hohen

Anzahl zu rechnen, sind die absoluten Werte wenig aussagekräftig. Es fällt allerdings auf, dass die Attribute „incoming12“ und „outgoing12“ wieder einen Wert von 0 erhalten. Dagegen sind „incoming7“ und „outgoing7“ am höchsten bewertet – diese Attribute stehen in den meisten Bäumen aufgrund des höchsten InformationGain Wertes weit oben.

Die Faktoranalyse wird in dem Analyseprogramm aus dem Menüpunkt „PSPP“ heraus gestartet und die Implementierung beinhaltet eine Datenkonvertierung für das Statistikprogramm „PSPP“. Da die Situationsdefinition aufgrund des Schlüsselwertes 2<sup>31</sup> allerdings nicht intervallskaliert ist, kann sie hier nicht durchgeführt werden.

Weka erlaubt ebenfalls eine visuelle Analyse der Trainingsdaten. Diese ist in Abbildung 6.19 dargestellt. Dabei ist speziell die abgebildete Darstellung von hochdimensionalen Daten von Interesse. Diese kann wie die Duplikatsuche Hinweise darauf geben, ob die Situationsdefinition ausreichend ist. Jedes Trainingsbeispiel ist entsprechend der zugeordneten Maßnahme als Quadrat, Kreis oder Dreieck dargestellt. Es lassen sich für sämtliche (im Beispiel 13) Achsen Gewichte eingeben, anhand derer die Projektion vom Hochdimensionalen ins Zweidimensionale geschieht. Die Gewichte geben an, wie viel eine Dimension die resultierende X- und Y-Position beeinflusst. Die 13 Achsen sind ebenfalls dargestellt. In der Visualisierung lassen sich nun alle Beispiele einer Maßnahme markieren und durch Verschieben dieser auf der Projektion wird versucht, Gewichte der Achsen zu finden, um die Beispiele von den anderen zu separieren. Dies ist mit den vorliegenden Daten offensichtlich möglich. Dies bedeutet, dass es dem Klassifizierer anhand der gegebenen Merkmale möglich ist, den hochdimensionalen Situationsraum in Teilbereiche zu unterteilen, in denen genau eine Maßnahme zugeordnet wird. Die erfolgreiche Separierung der Daten zeigt an, dass theoretisch eine hohe Klassifikationsgüte anhand der verwendeten Situationsdefinition erzielt werden kann. Bei einer neuen Situation ist eindeutig, welche Maßnahme zugeordnet werden sollte.

### 6.3.2.3. Evaluierung der Effizienzsteigerung

Aufgrund der geringen Anzahl an möglichen Situationen, die sich durch die Tageskurve ergeben und im Situationsraum einen hohen Abstand zueinander besitzen, werden nur wenige Trainingsbeispiele benötigt. Daher ergibt die Berechnung der Überdeckung nach Abschnitt 5.5.1 keine Möglichkeiten zur Effizienzsteigerung.




Abbildung 6.19.: Screenshot der Visualisierung der Trainingsdatenmenge in Weka

Aufgrund der großen Abstände ist ebenfalls das Lernverfahren in diesem Fall trivial - ein einfaches Case Based Reasoning Verfahren wie Nearest Neighbor kann zu 100% korrekt klassifizieren. Die in Abschnitt 5.5.2 dargelegten Testverfahren wie Kreuzvalidierung eignen sich hier nicht zur Anwendung. Die generierten Trainingsbeispiele sind zu wenige, um von etwa 90% auf die fehlenden 10% der Situationen schließen zu können, wie es in der Kreuzvalidierung verlangt ist. Dies ist nur bei einer ausreichenden Abdeckung des Situationenraumes möglich.

Die Testverfahren und auch die weiteren Klassifikationsverfahren wurden in der Software Weka identifiziert und können leicht austauschbar in das in d<sup>3</sup>fact entwickelte Simulationsmodell integriert werden. Die softwaretechnische Eignung der Verfahren konnte somit demonstriert werden.

### 6.3.3. Evaluierung des angewendeten Konzeptes unter veränderlichen Systemparametern

Die selbstadaptierenden Eigenschaften des Konzeptes auf veränderliche Systemparameter sollen anhand des Anwendungsszenarios validiert und evaluiert werden. Es wird dazu die Annahme gemacht, dass sich die Systemparameter, also die erwarteten Ein- und

Auslagerungen in einer Stunde, aufgrund von verändertem Nutzerverhalten wandeln. Exemplarisch verschieben sich die Anzahl der Einlagerungen der ersten beiden Stunden: Die Benutzer fahren vermehrt in der ersten anstatt in der zweiten Stunde in das MHS ein. Der entsprechende Systemparameter der zweiten Stunde verringert sich um  $x$ , der der ersten erhöht sich um  $x$ . In einem ersten Schritt wird eine Verschiebung von  $x = 40$ , in einem zweiten um  $x = 80$  angenommen.

In diesem Abschnitt soll untersucht werden, wie die Anpassungskomponenten des Konzeptes auf diese Änderungen reagieren und wie viel Leistung aufgrund einer eventuell erfolgten Selbstanpassung gewonnen wird. Anhand der in Abschnitt 5.3 definierten Metrik und des Relevanzkriteriums soll zunächst die Situation nach einer Stunde unter der ersten Verschiebung von  $x = 40$  evaluiert werden. Die Gewichte  $w_i$  der einzelnen Attribute konnten hier aufgrund der geringen Anzahl an erzeugten Beispielen nicht anhand des Informationsgewinns ermittelt werden. Auf Basis der in Abschnitt 6.3.2.2 dargelegten Überlegungen kann aber eine gleichmäßige Gewichtung angenommen werden, also  $w_i = 1$ , mit Ausnahme der beiden Attribute zur letzten Stunde.

Es ergibt sich also die Situation  $s_a = 652, 2^{31}, 2^{31}, \dots$ . Das nächstliegende Trainingsbeispiel aus der in 6.16 dargestellten Menge ist offensichtlich das einzige andere nach der ersten Stunde vorliegende  $s_1 = 612, 2^{31}, 2^{31}, \dots$ . Die Metrik ergibt nämlich für zwei Situationen zu unterschiedlichen Stunden gewollt einen sehr hohen Wert, da die Differenz zwischen  $2^{31}$  und einem Wert zwischen 0 und 2000 einfließt. Es ergibt sich  $R(S_{erz}, s_a) = d_S(s_a, s_1) = \frac{40}{24} \approx 0,00083$ . Aufgrund der Tatsache, dass in der bisherigen Menge keine zwei Trainingsbeispiele zu einer Stunde enthalten sind, würde die Schwellwertberechnung einen zu hohen Wert ergeben.<sup>7</sup> Im Vorgriff auf spätere Ergebnisse wird  $d = \frac{45}{24} \approx 0,00094$  angenommen. Somit ist die Trainingsdatenmenge hinsichtlich  $s_a$  als relevant einzuschätzen und in der Situation würde „geringe Last“ klassifiziert und ausgeführt werden.

Bei Auftreten von  $692, 2^{31}, 2^{31}, \dots$  allerdings ergibt sich  $d_S = \frac{80}{24} \approx 0,00167$  und damit eine Überschreitung des Schwellenwertes. Die Neugenerierung unter der neuen Tageskurve mit je 812 Einlagerungen in den ersten beiden Stunden wird angestoßen. Die resultierenden Trainingsbeispiele ergeben hier einen geänderten optimalen Pfad – in der ersten Stunde ist nun „hohe Last Einlagerung“ anstatt „geringe Last“ optimal. Alle anderen Maßnahmen

<sup>7</sup> Aus der Menge lässt sich lediglich schließen, dass zwischen zwei Stunden ein Maßnahmenwechsel möglich ist. Ein Wechsel zur gleichen Stunde aufgrund verschiedener Lasten ist dagegen nicht zu erkennen.

bleiben gleich. Es ist nun in Hinblick auf die folgenden Stunden anscheinend nicht mehr optimal, in der ersten Stunde mehr Material auf weit entfernte Plätze zu stellen. Speziell die Auslagerungen zwischen 10:00 und 11:00 sowie 12:00 und 13:00 dauern bei Anwendung des bisherigen Maßnahmenpfades wesentlich länger, da nun zu viele Material weit entfernt steht.

Um zu ermitteln, wie die Leistung durch die Anpassung auf den adaptierten Pfad gesteigert werden konnte, sind die Ergebnisse bei Anwendung beider Pfade in Abbildung 6.20 gegenübergestellt. Im ursprünglichen Szenario mit 612 und 1012 Einlagerungen in den ersten beiden Stunden ist definitionsgemäß der ursprüngliche Maßnahmenpfad optimal. Bei 652 und 972 Einlagerungen ist der Abstand nur noch sehr gering. Aus dieser Beobachtung ergab sich der Schwellenwert von  $\frac{45}{24} \approx 0,00094$ . Dieser gibt schätzungsweise den Abstand bis zu der Situation an, ab der die Maßnahme „hohe Last Einlagerung“ optimal ist. Bei 692 und 932 Einlagerungen bietet der adaptierte Pfad bereits eine wesentlich höhere Leistung als der bisherige. Die durchschnittliche Wartezeit ist um 2,7% geringer. Dieser Leistungsvorteil ist angesichts des Abstands zwischen Anwendung des Pfades gegenüber der besten konstanten Maßnahmenwahl von 3,5% (siehe Abschnitt 6.3.1) als sehr hoch einzustufen. Die Adaptierung ist also in diesem Szenario essentiell hinsichtlich der Leistung des Systems. Bereits bei einer Verschiebung von 80 Einlagerungen würde schließlich ohne Selbstadaptierung nahezu der gesamte Leistungsgewinn des Verfahrens verloren gehen.

In diesem Szenario sollte zudem untersucht werden, inwieweit das entwickelte Prognoseverfahren die Veränderungen korrekt vorhersagen kann, um frühzeitig neue Trainingsbeispiele zu generieren. Das Ergebnis ist in Abbildung 6.21 dargestellt. Es sind entsprechend den Annahmen des Szenarios für die ersten beiden Stunden jeweils sieben Werte für die Anzahl an Einlagerungen dargestellt, die den zeitlichen Verlauf dieser angeben. Schrittweise, aber mit leichten Schwankungen, verschieben sich Einlagerungen von der zweiten in die erste Stunde. Die Werte stellen die Eingangsdaten der Prognoseverfahren dar. Es werden die Exponentielle Glättung der 1. und 2. Ordnung verglichen. Es wird deutlich, dass die Eigenschaft der Trenderkennung der Glättung 2. Ordnung hier notwendig ist. Die Vorhersage trifft zu, der Wert der zehnten Periode wird fast exakt vorhergesagt. Die Vorhersage der Glättung 1. Ordnung weicht dagegen deutlich ab. Der Wert liegt entgegen dem Trend ober- bzw. unterhalb des letzten Eingabewertes, da dieser als potentieller Ausreißer behandelt wird und die Gewichtung der vorherigen Werte dem Trend entgegenwirken. Es wird zudem deutlich, dass die Glättung 1. Ordnung nur einen Prognosewert liefern kann, der sich für darauffolgende Perioden wiederholt. Die Identifizierung des Prognoseverfahrens konnte




Abbildung 6.20.: Durchschnittliche Wartezeiten zu verschiedenen Tageskurven

also in diesem Anwendungsszenario validiert werden.

### 6.3.4. Abschließende Überlegungen

Unter dem erwarteten Verlauf der Tageskurve zeigt sich bei Anwendung des Konzeptes nur ein geringer Leistungsgewinn, wie in den Abbildungen 6.10 und 6.12 illustriert ist. Generell wurden die Maßnahmen zur Optimierung späterer Einlagervorgänge gestaltet, weshalb in Stunden mit vielen Auslagerungen keine Reduzierung der Wartezeiten erzielt werden konnte. Zudem bilden zahlreiche durch die Steuerung nicht beschleunigbare Prozesse einen Großteil der Wartezeiten. Die Berücksichtigung eines plötzlichen Anstieges an Auslagerungen bewirkt zusätzliche Leistungsverluste für den Normalfall, da die verglichene Maßnahme „hohe Last Einlagerung“ ohne Ausführung von Umlagerungen bereits das Optimum der drei zur Verfügung stehenden Maßnahmen darstellt.

Allgemein konnte erfolgreich die Sinnhaftigkeit der Anwendung des Konzeptes demonstriert werden. Die dynamische Auswahl von Maßnahmen je nach Systemlast resultierte in signifikanten Leistungsvorteile. Weiterhin konnte gezeigt werden, wie das Konzept automatisch mögliche Ereignisse berücksichtigt sowie sich an Änderungen anpasst. Diese beiden Eigenschaften zur Umsetzung der Selbstadaptierung bewirken belegbar signifikante Leistungsvorteile. Die Definition einer weiteren Maßnahme, die zur Optimierung zukünftiger Auslagervorgänge in umgekehrter Reihenfolge wie bisher Umlagerungen durchführt, verspricht bei Betrachtung von Abbildung 6.12 eine weitere Erhöhung des Leistungsvorteils ohne Änderungen im Konzept.

Das dargestellte MHS kompensiert die Nachteile der festen Maßnahmenauswahl durch eine überschüssige Shuttlekapazität. So bewirken eine verringerte Anzahl an Shufflevorgängen




Abbildung 6.21.: Prognoseergebnis der Exponentiellen Glättung 1. und 2. Ordnung. Die Anzahl an eingehenden Einheiten Material für die erste (untere Kurve) und zweite Stunde (obere Kurve) werden jeweils prognostiziert. Der korrekte Wert der 10. Periode für beide Werte (jeweils 812) ist mit einem X gekennzeichnet.

sowie kürzere Fahrwege für Shuttles nicht unbedingt kürzere Wartezeiten, da die Aufzüge den Flaschenhals darstellen und auch bei fester Maßnahmenauswahl ausgelastet werden können. Diese Hypothese wurde durch Versetzen der Shuttles in einen Energiesparmodus untersucht. Die Maximalgeschwindigkeit und Beschleunigung der Shuttles wird auf 50% gesetzt. Dadurch ergibt sich in der Praxis ein geringerer Energieverbrauch sowie ein verringerter Verschleiß. Die Leistungswerte sind in Abbildung 6.22 dargestellt<sup>8</sup>. Zu erkennen ist, dass die Unterschiede zwischen fester und dynamischer Maßnahmenauswahl hier größer ausfallen – in der Stunde 10:00-11:00 liegt der Unterschied bei 24%, während ohne Energiesparmodus 9% gemessen wurde. In späteren Stunden steigt demgegenüber der Nachteil der fehlenden Auslageroptimierung, da die Shuttles durch die Position des Materials in größerer Entfernung zu den Aufzügen längere Fahrzeiten haben. Durch die Anwendung des Konzeptes können die längeren Fahrzeiten der Shuttles durch den Energiesparmodus besser kompensiert werden. Der Leistungsverlust durch die Verlangsamung der Shuttles beträgt lediglich 17% in der Stunde von 10:00-11:00, bei fester Anwendung von „hohe Last Einlagerung“ allerdings 26%, von einem bereits höheren Niveau an Wartezeit ausgehend.

<sup>8</sup> Die Tageskurve wurde hier neu kalibriert, um die Aufträge innerhalb der festen Frist zur Maßnahmenwahl zur vollen Stunde abarbeiten zu können, sodass die absoluten Werte der Abbildungen 6.12 und 6.22 abweichen. Aufgrund der gleichbleibenden vollen Auslastung in den Lastspitzen ist der relative Vergleich allerdings zulässig.

Es zeigt sich neben der moderaten Leistungssteigerung unter Normalbedingungen bei Anwendung des Konzeptes damit ein gewichtigerer Vorteil unter einem anderen Blickwinkel. Anstelle einer Reduzierung der Wartezeit erlaubt das Konzept demnach alternativ hohe Energieeinsparungen<sup>9</sup> bei nur geringen Leistungseinbußen selbst in der Lastspitze.




Abbildung 6.22.: Kumulierte Wartezeiten ein- und ausgehender Aufträge summiert pro Stunde im Tagesverlauf bei Betrieb im Energiesparmodus (Analog zu Abbildung 6.12)

<sup>9</sup> Eine Verringerung der Höchstgeschwindigkeit von Shuttles um 50% entspricht einer Reduzierung der kinetischen Energie, die üblicherweise bei Abbremsung der Shuttles verloren geht, um 75%.



## 7. Zusammenfassung und Ausblick

Gegenstand dieser Arbeit ist die Generierung von Zuordnungen zur situationsabhängigen und wissensbasierten Steuerung von logistischen Systemen. Während bisherige Ergebnisse in dem Gebiet systemspezifische Lösungen sind, wird hier ein abstrahiertes Verfahren präsentiert, das mittels Definition von anwendungsspezifischen Aspekten an verschiedene zu steuernde Systeme angepasst werden kann. Das Verfahren basiert auf der simulationsbasierten Generierung von Situation/Maßnahme Zuordnungen, die in Form von Trainingsbeispielen einem induktiven Lernverfahren zur Verfügung gestellt werden. Anhand eines Simulationsmodells des zu steuernden Systems wird die künftige Leistung unter Anwendung jeder alternativen Maßnahme ermittelt, um zu einer Steuerungssituation die jeweils optimale zu bestimmen. Dabei werden ebenfalls stochastische Entwicklungen berücksichtigt. Die simulationsbasierte Generierung der Zuordnungen wurde zudem um eine Anpassungskomponente ergänzt. Diese ermöglicht es, Änderungen in exogenen Einflussfaktoren automatisiert zu berücksichtigen, um eine konstant hohe Leistung zu erzielen. Dabei werden mittels Prognosetechniken die Änderungen antizipiert, um bereits vor Eintreten die relevanten Zuordnungen generieren zu können.

Das Verfahren wurde zur Steuerung eines realen industriellen automatischem Material Handling Systems mittels Definition der anwendungsspezifischen Aspekte adaptiert. Dabei konnte die Fähigkeit, das abstrakte Konzept auf ein konkretes System anzupassen, validiert werden. Die Funktionsweisen der einzelnen Komponenten wurden anhand der adaptierten Steuerung demonstriert. Signifikante Leistungsvorteile gegenüber einer herkömmlichen Materialflusssteuerung konnten empirisch nachgewiesen werden. Speziell die dynamische Auswahl einer Maßnahme bewirkte, dass das System Leistungspotentiale für Zeiten hoher Last frei schafft. Die Notwendigkeit einer Anpassung an veränderte Gegebenheiten konnte in einem Testfall demonstriert werden, in dem eine ausbleibende Anpassung einen hohen Leistungsverlust bedeuten würde.

Es wurden auch Grenzen des Verfahrens und Anknüpfungspunkte für zukünftige Forschungsvorhaben identifiziert. So zeigte sich in der Evaluierung, dass die Maßnahmendefinition, die derzeit manuell vorgenommen wird, einen großen Einfluss auf die Leistung hat. Ein Verfahren zur Unterstützung bei der Maßnahmendefinition wäre hier wünschenswert. So könnte der Entwickler mehrere einzelne Wertebereiche für Einflussfaktoren vorgeben, die von dem Verfahren automatisiert zu Maßnahmen kombiniert werden. Im Rahmen der simulationsbasierten Bewertung von Maßnahmen ist eine parallele Optimierung der Definition denkbar.

Weiterhin basieren die Bewertungen der Maßnahmen in dem Verfahren ausschließlich auf den Auswirkungen innerhalb des Simulationsmodells des Systems, ausgehend von der Annahme, dass dieses valide ist. Da immer eine gewisse Abweichung zwischen Modell und realem System vorhanden ist, wäre ein Einfluss der Auswirkungen von Maßnahmen im realen System denkbar. Diese liegen schließlich für die tatsächlich ausgeführten Maßnahmen vor und könnten bei der Bewertung die Simulationsergebnisse ergänzen bzw. im Laufe der Zeit ersetzen. Dieser Ansatz wird bei den in Kapitel 3 vorgestellten Verfahren im Bereich des Organic Computing bereits teilweise verfolgt [PRT<sup>+</sup>08].

Bei dem Einsatz der Prognosetechniken wird von der Annahme ausgegangen, dass einzelne Systemparameter stochastisch unabhängig sind. Die Prognosegenauigkeit könnte durch Exploration der Zusammenhänge verbessert werden.

## Literaturverzeichnis

- [ADLR08] AUFENANGER, M. ; DANGELMAIER, W. ; LAROQUE, C. ; RÜNGENER, N.: Knowledge-based event control for flow-shops using simulation and rules. In: MASON, S. J. (Hrsg.) ; HILL, R. R. (Hrsg.) ; MÖNCH, L. (Hrsg.) ; ROSE, O. (Hrsg.) ; JEFFERSON, T. (Hrsg.) ; FOWLER, J. W. (Hrsg.): *Proceedings of the 2008 Winter Simulation Conference*. Piscataway, New Jersey : Institute of Electrical and Electronics Engineers, Inc., 2008, 1952-1958
- [Ang05] ANGIULLI, F.: Fast condensed nearest neighbor rule. In: *Proceedings of the 22nd international conference on Machine learning ACM*, 2005, S. 25–32
- [AP94] AAMODT, A. ; PLAZA, E.: Case-based reasoning: Foundational issues, methodological variations, and system approaches. In: *AI communications 7* (1994), Nr. 1, S. 39–59
- [AR11] AMAL, M.-A. ; RIADH, B.-A. A.: Survey of nearest neighbor condensing techniques. In: *(IJACSA) International Journal of Advanced Computer Science and Applications 2* (2011), Nr. 11
- [Arm84] ARMSTRONG, J. S.: Forecasting by extrapolation: Conclusions from 25 years of research. In: *Interfaces 14* (1984), Nr. 6, S. 52–66
- [Arm01] ARMSTRONG, J.: *Principles of Forecasting: A Handbook for Researchers and Practitioners*. Springer, 2001
- [AS06] ALI, S. ; SMITH, K. A.: On learning algorithm selection for classification. In: *Applied Soft Computing 6* (2006), Nr. 2, S. 119–138
- [Auf11] AUFENANGER, M.: *HNI-Verlagsschriftenreihe, Paderborn. Bd. 269: Situativ trainierte Regeln zur Ablaufsteuerung in Fertigungssystemen und ihre Integration in Simulationssysteme*. Heinz Nixdorf Institut, 2011
- [BKI08] BEIERLE, C. ; KERN-ISBERNER, G.: *Methoden wissensbasierter Systeme: Grundlagen, Algorithmen, Anwendungen*. Wiesbaden : Vieweg+Teubner / GWV Fachverlage GmbH, Wiesbaden, 2008
- [BMMS<sup>+</sup>06] BRANKE, J. ; MNIF, M. ; MÜLLER-SCHLOER, C. ; PROTHMANN, H. ; RICHTER, U. ; ROCHNER, F. ; SCHMECK, H.: Organic Computing - Addressing Complexity by Controlled Self-Organization. In: *Proceedings of the Second International Symposium on Leveraging Applications of Formal Methods, Verification and Validation*. Washington, DC, USA : IEEE Computer Society, 2006 (ISOLA '06), S. 185–191

- [Bre01] BREIMAN, L.: Random Forests. In: *Machine Learning* 45 (2001), Nr. 1, S. 5–32
- [BS11] BERGMANN, S. ; STELZER, S.: Approximation of Dispatching Rules in Manufacturing Control Using Artificial Neural Networks. In: *Principles of Advanced and Distributed Simulation (PADS), 2011 IEEE Workshop on*, 2011, S. 1–8
- [BZL06] BONGARD, J. ; ZYKOV, V. ; LIPSON, H.: Resilient machines through continuous self-modeling. In: *Science* 314 (2006), Nr. 5802, S. 1118–1121
- [Cro10] CRONE, S.: *Neuronale Netze Zur Prognose und Disposition Im Handel*. Westdeutscher Verlag GmbH, 2010 (Gabler research: Betriebliche Forschung zur Unternehmensführung)
- [Cun09] CUNNINGHAM, P.: A Taxonomy of Similarity Mechanisms for Case-Based Reasoning. In: *Knowledge and Data Engineering, IEEE Transactions on* 21 (2009), Nr. 11, S. 1532–1543
- [Die00] DIETTERICH, T. G.: Ensemble methods in machine learning. In: *Multiple classifier systems*. Springer, 2000, S. 1–15
- [DL07] DANGELMAIER, W. ; LAROQUE, C.: d3FACT insight - Immersive Ablaufsimulation von richtungsoffenen und wahlweise zeitorientierten Materialflussmodellen. In: *Industrie Management* 2 (2007), Januar, S. 73–76
- [Dör09] DÖRING, A.: *Effektivität und Effizienz durch problemspezifische Abstraktion : ein Beitrag zum maschinellen Lernen von Regeln zur Steuerung von Produktionsnetzwerken der Serienfertigung*, Diss., 2009
- [Eic99] EICHHORN, H.: *Landwirtschaftliches Lehrbuch, Landtechnik*. 7. Auflage. Ulmer (Eugen), 1999
- [FGK<sup>+</sup>04] FRANK, U. ; GIESE, H. ; KLEIN, F. ; OBERSCHELP, O. ; SCHMIDT, A. ; SCHULZ, B. ; VOECKING, H. ; WITTING, K.: *HNI-Verlagsschriftenreihe, Paderborn*. Bd. 155: *Selbstoptimierende Systeme des Maschinenbaus - Definitionen und Konzepte*. Paderborn : Heinz Nixdorf Institut, Universität Paderborn, 2004
- [GD80] GARDNER, E. S. ; DANNENBRING, D. G.: Forecasting with exponential smoothing: Some guidelines for model selection. In: *Decision Sciences* 11 (1980), Nr. 2, S. 370–383
- [GRR92] GREFENSTETTE ; RAMSEY ; RAMSEY, C. L.: An Approach to Anytime Learning. In: *Proceedings of the Ninth International Conference on Machine Learning*, Morgan Kaufmann, 1992, S. 189–195
- [Hac89] HACKSTEIN, R.: *Produktionsplanung und -steuerung (PPS). Ein Handbuch für die Betriebspraxis*. 2. VDI-Verlag, 1989

- [JKK11] JEON, S. ; KIM, K. ; KOPFER, H.: Routing automated guided vehicles in container terminals through the Q-learning technique. In: *Logistics Research* 3 (2011), S. 19–27
- [KGW13] KAUTZMANN, D.-I. T. ; GEIMER, I. M. ; WÜNSCHE, D.-I. M.: Ganzheitliche Steuerungen Für Mobile Arbeitsmaschinen. In: *ATZoffhighway* 6 (2013), Nr. 1, S. 86–94
- [KJD91] KELLY JR, J. D. ; DAVIS, L.: A Hybrid Genetic Algorithm for Classification. In: *IJCAI* Bd. 91, 1991, S. 645–650
- [KK12] KRAMER, D. ; KARL, W.: Realizing a Proactive, Self-Optimizing System Behavior within Adaptive, Heterogeneous Many-Core Architectures. In: *SASO*, IEEE Computer Society, 2012, 39–48
- [KLFD11] KLAAS, A. ; LAROQUE, C. ; FISCHER, M. ; DANGELMAIER, W.: Simulation Aided, Knowledge Based Routing for AGVs in a Distribution Warehouse. In: JAIN, S. (Hrsg.) ; CREASEY, R. R. (Hrsg.) ; HIMMELSPACH, J. (Hrsg.) ; WHITE, K. P. (Hrsg.) ; FU, M. (Hrsg.): *Proceedings of the 2011 Winter Simulation Conference*. Piscataway, New Jersey : Institute of Electrical and Electronics Engineers, Inc., 2011, S. 1673–1684
- [KSM02] KLEYWEGT, A. ; SHAPIRO, A. ; MELLO, T. Homem-de: The Sample Average Approximation Method for Stochastic Discrete Optimization. In: *SIAM Journal on Optimization* 12 (2002), Nr. 2, S. 479–502
- [KSO<sup>+</sup>99] KATO, N. ; SUZUKI, M. ; OMACHI, S. ; ASO, H. ; NEMOTO, Y.: A handwritten character recognition system using directional element feature and asymmetric Mahalanobis distance. In: *Pattern Analysis and Machine Intelligence, IEEE Transactions on* 21 (1999), Nr. 3, S. 258–262
- [Kur92] KURBEL, K.: *Entwicklung und Einsatz von Expertensystemen: Eine anwendungsorientierte Einführung in wissensbasierte Systeme*. 2., verb. Aufl. Berlin [u.a.] : Springer, 1992
- [KW94] KALL, P. ; WALLACE, S.: *Stochastic programming*. Wiley, 1994 (Wiley-Interscience series in systems and optimization)
- [KWM<sup>+</sup>10] KAUTZMANN, T. ; WÜNSCHE, M. ; MOSTAGHIM, S. ; GEIMER, M. ; SCHMECK, H.: Self-optimizing Machine Management. In: *Proceedings of the 2nd International Conference on Machine Control & Guidance*. Bonn : VDI, März 2010, S. 107 – 115
- [KY04] KWAK, C. ; YIH, Y.: Data-mining approach to production control in the computer-integrated testing cell. In: *Robotics and Automation, IEEE Transactions on* 20 (2004), Nr. 1, S. 107–116
- [Lau05] LAUX, H.: *Entscheidungstheorie*. Springer, 2005

- [LD60] LAND, A. H. ; DOIG, A. G.: An Automatic Method of Solving Discrete Programming Problems. In: *Econometrica* 28 (1960), Nr. 3, S. pp. 497–520. – ISSN 00129682
- [Lew74] LEWANDOWSKI, R.: *Prognose- und Informationssysteme und ihre Anwendungen*. Berlin [u.a.] : de Gruyter, 1974
- [LGM<sup>+</sup>13] LEMOS, R. ; GIESE, H. ; MÜLLER, H. A. ; SHAW, M. ; ANDERSSON, J. ; LITOIU, M. ; SCHMERL, B. ; TAMURA, G. ; VILLEGAS, N. ; VOGEL, T. ; WEYNS, D. ; BARESI, L. ; BECKER, B. ; BENCOMO, N. ; BRUN, Y. ; CUKIC, B. ; DESMARAIS, R. ; DUSTDAR, S. ; ENGELS, G. ; GEIHS, K. ; GÖSCHKA, K. ; GORLA, A. ; GRASSI, V. ; INVERARDI, P. ; KARSAI, G. ; KRAMER, J. ; LOPES, A. ; MAGEE, J. ; MALEK, S. ; MANKOVSKII, S. ; MIRANDOLA, R. ; MYLOPOULOS, J. ; NIERSTRASZ, O. ; PEZZÈ, M. ; PREHOFER, C. ; SCHÄFER, W. ; SCHLICHTING, R. ; SMITH, D. ; SOUSA, J. ; TAHVILDARI, L. ; WONG, K. ; WUTTKE, J.: Software Engineering for Self-Adaptive Systems: A Second Research Roadmap. In: LEMOS, R. (Hrsg.) ; GIESE, H. (Hrsg.) ; MÜLLER, H. (Hrsg.) ; SHAW, M. (Hrsg.): *Software Engineering for Self-Adaptive Systems II* Bd. 7475. Springer Berlin Heidelberg, 2013, S. 1–32
- [Liv05] LIVINGSTON, F.: Implementation of Breiman’s random forest machine learning algorithm. In: *ECE591Q Machine Learning Journal* (2005)
- [MC05] MAZA, S. ; CASTAGNA, P.: A performance-based structural policy for conflict-free routing of bi-directional automated guided vehicles. In: *Comput. Ind.* 56 (2005), Nr. 7, S. 719–733
- [Mer12] MERTENS, P.: *Prognoserechnung*. Physica-Verlag, 2012
- [Mit97] MITCHELL, T.: *Machine Learning*. 1st. McGraw-Hill Education (ISE Editions), 1997
- [MSSU11] MÜLLER-SCHLOER, C. ; SCHMECK, H. ; UNGERER, T.: *Organic Computing - A Paradigm Shift for Complex Systems*. Basel : Springer Basel AG, 2011
- [NW06] NACHTIGALL, C. ; WIRTZ, M.: *Deskriptive Statistik*. Juventa Verlag GmbH, 2006
- [OHG04] OBERSCHELP, O. ; HESTERMAYER, T. ; GIESE, H.: Strukturierte Informationsverarbeitung für selbstoptimierende mechatronische Systeme. In: *Proceedings of the Second Paderborner Workshop Intelligente Mechatronische Systeme* Bd. 145, 2004 (HNI-Verlagsschriftenreihe), S. 43–56
- [Pap85] PAPADIMITRIOU, C. H.: Games against nature. In: *Journal of Computer and System Sciences* 31 (1985), Nr. 2, S. 288–301
- [PRSP93] PIRAMUTHU, S. ; RAMAN, N. ; SHAW, M. J. ; PARK, S. C.: Integration of simulation modeling and inductive learning in an adaptive decision support system. In: *Decision Support Systems* 9 (1993), Januar, Nr. 1, S. 127–142

- [PRT<sup>+</sup>08] PROTHMANN, H. ; ROCHNER, F. ; TOMFORDE, S. ; BRANKE, J. ; MÜLLER-SCHLOER, C. ; SCHMECK, H.: Organic Control of Traffic Lights. In: *Proceedings of the 5th international conference on Autonomic and Trusted Computing*. Berlin, Heidelberg : Springer-Verlag, 2008 (ATC '08), S. 219–233
- [RG94] RAMSEY, C. L. ; GREFENSTETTE, J. J.: Case-based anytime learning. In: *Case Based Reasoning: Papers from the 1994 Workshop* Technical Report WS-94-07, AAAI Press,(Menlo Park, CA), 1994, S. 91–95
- [Ric09] RICHTER, U.: *Controlled Self-organisation Using Learning Classifier Systems*. KIT Scientific Publishing, 2009
- [RN09] RUSSELL, S. ; NORVIG, P.: *Artificial Intelligence: A Modern Approach*. Upper Saddle River, NJ, USA : Prentice Hall Press, 2009
- [Rop99] ROPOHL, G.: *Allgemeine Technologie: eine Systemtheorie der Technik*. München [u.a.] : Hanser, 1999
- [RS97] RAM, A. ; SANTAMARÍA, J.: Continuous case-based reasoning. In: *Artificial Intelligence 90* (1997), Nr. 1–2, S. 25–77
- [RSW08] RABE, M. ; SPIEKERMANN, S. ; WENZEL, S.: *Verifikation und Validierung für die Simulation in Produktion und Logistik: Vorgehensmodelle und Techniken*. Berlin, Heidelberg : Springer-Verlag, 2008. ISSN 978–3–540–35282–2
- [Sch01] SCHOLL, A.: *Robuste Planung und Optimierung: Grundlagen – Konzepte und Methoden – Experimentelle Untersuchungen*. Physica-Verlag, 2001
- [SFN08] SAKAKIBARA, K. ; FUKUI, Y. ; NISHIKAWA, I.: Genetics-Based Machine Learning Approach for Rule Acquisition in an AGV Transportation System. In: *Intelligent Systems Design and Applications, International Conference on 3* (2008), S. 115–120
- [SMSC<sup>+</sup>10] SCHMECK, H. ; MÜLLER-SCHLOER, C. ; ÇAKAR, E. ; MNIF, M. ; RICHTER, U.: Adaptivity and self-organization in organic computing systems. In: *ACM Transactions on Autonomous and Adaptive Systems (TAAS)* 5 (2010), Nr. 3, S. 10
- [STH13] SOMMER, M. ; TOMFORDE, S. ; HÄHNER, J.: Using a Neural Network for Forecasting in an Organic Traffic Control Management System. In: *2013 Workshop on Embedded Self-Organizing Systems*. Berkeley, CA : USENIX, 2013
- [Sti99] STIER, W.: *Empirische Forschungsmethoden: mit 53 Tabellen*. 2., verb. Aufl. Berlin [u.a.], 1999
- [Tem06] TEMPELMEIER, H.: *Material-Logistik : Modelle und Algorithmen für die Produktionsplanung und -steuerung in Advanced-Planning-Systemen*. 6., neubearb. Aufl. Berlin [u.a.] : Springer, 2006

- [VDI96] VDI Richtlinie 3633 - Simulation von Logistik-, Materialfluss- und Produktionssystemen. Begriffsdefinitionen. 1996
- [Vit97] VITIELLO, M.: *Fallbasierte Materialflußsteuerung*. Düsseldorf : VDI-Verlag, 1997
- [WF05] WITTEN, I. H. ; FRANK, E.: *Data Mining: Practical Machine Learning Tools and Techniques*. 2nd. Morgan Kaufmann, 2005 (Morgan Kaufmann series in data management systems)
- [WF11] WAGNER, F. ; FREY, G.: Simulationsbasierte Steuerung von Druckluftstationen. In: *VDI Berichte 2143, Mess- und Automatisierungstechnik; Automation 2011*, 2011
- [WMS<sup>+</sup>10] WUENSCH, M. ; MOSTAGHIM, S. ; SCHMECK, H. ; KAUTZMANN, T. ; GEIMER, M.: Organic Computing in Off-highway Machines. In: *Proceedings of the Second International Workshop on Self-organizing Architectures*. New York, NY, USA : ACM, 2010 (SOAR '10), 51–58
- [XNZ08] XIANG, S. ; NIE, F. ; ZHANG, C.: Learning a Mahalanobis distance metric for data clustering and classification. In: *Pattern Recognition* 41 (2008), Nr. 12, S. 3600–3612
- [YL10] YIH, J.-M. ; LIN, Y.-H.: Clustering Algorithms Based on Mahalanobis Distances. In: *Electronic Commerce and Security (ISECS), 2010 Third International Symposium on*, 2010, S. 228–231
- [Zim05] ZIMMERMANN, H.: *Operations Research*. Vieweg, 2005



## A. Definitionen

**Definition A.1** (Technisches Sachsystem). *Systeme, „die konkrete künstliche Gegenstände repräsentieren und greifbare Wirklichkeit in Zeit und Raum sind“ [Rop99]. Sie sind in eine natürliche, technische und gesellschaftliche Umgebung eingebettet. Es wird nach Energie, Masse und Information bei In- und Output unterschieden.*

**Definition A.2** (Logistisches System). *Eine Klasse von technischen Sachsystemen, bei der Zeit- und Ortskoordinaten (Transport) oder nur Zeitkoordinaten (Lagerung) von Masse verändert werden [Rop99].*

**Definition A.3** (Materialflusssteuerung). *Zusätzlich zum physischen In- und Output von Masse nach [Rop99] bezeichnet die Materialflusssteuerung die Veränderung eines logischen Inputs, basierend auf einem logischen Output des Systems [Vit97]. Dies erlaubt es, das Erreichen bestimmter Ziele des Systems (z. B. hoher Durchsatz) zu beeinflussen.*

**Definition A.4** (Situation). *In Abgrenzung zu einer allgemeinen Situation – dem Zustand des Systems  $z \in Z$  zu einem Zeitpunkt – bezeichnen Situationen hier spezielle Steuerungssituationen, in denen der Fortlauf des Systems vom logischen Input abhängt [Vit97], also eine Steuerungsnotwendigkeit auftritt. Eine Situation ist eine Teilmenge einer allgemeinen Situation. Die Situation stellt zu dem Zeitpunkt den logischen Output des Transport- und Lagersystems dar. Die Menge aller möglichen Situationen wird als  $S \subseteq Z$  bezeichnet. Diese bildet zusammen mit einer in Abschnitt 2.2 zu definierenden Metrik einen metrischen Raum.*

**Definition A.5** (Maßnahme). *Logischer Input des Systems. Maßnahmen bestehen aus einer Folge von Anweisungen, die den weiteren Verlauf von einer Situation aus bestimmen. Die Menge aller möglichen Maßnahmen wird als  $M$  bezeichnet.*

**Definition A.6** (Situationsabhängige Materialflusssteuerung). *Eine Materialflusssteuerung, dessen Steuerungsfunktion<sup>1</sup> nicht konstant ist. Dies bedeutet, dass die aktuelle Situation einen Einfluss auf die Steuerung hat. Dies steht im Gegensatz zu Steuerungsverfahren, bei denen feste Maßnahmen oder Pläne definiert sind, die mit Fortlauf des Systems nicht verändert werden können.*

**Definition A.7** (Klassifikation). *„Die Zuordnung eines Objektes zu einer Kategorie.“ [RN09] Die situationsabhängige Materialflusssteuerung lässt sich so als eine Klassifizierung von Situationen zu Maßnahmen darstellen.*

<sup>1</sup> Die Steuerungsfunktion ist die Bestimmung des logischen Inputs des Systems, basierend auf dem logischen Output.

**Definition A.8** (Situation/Maßnahme Zuordnung). *Ein Element aus der Relation  $Z \subseteq S \times M$ .*

**Definition A.9** (Überwachtes Lernen). *„Das Lernen einer Funktion aus Beispielen ihrer Ein- und Ausgaben“ [RN09]. Eine Form von induktivem Lernen<sup>2</sup>. Ein Lernverfahren zu bestimmen ist Problem der in Abschnitt 2.6 definierten Komponente. Die Beispiele sind dann Situation/Maßnahme Zuordnungen.*

**Definition A.10** (Subsymbolische Wissensrepräsentation). *Eine subsymbolische Repräsentation wird durch Elementareinheiten erreicht, die nicht durch Bezeichner charakterisiert sind, z. B. Zahlen bzw. Zahlenfolgen. Im Gegensatz zu symbolischer Repräsentation ist dann keine unmittelbare Interpretierbarkeit gegeben, allerdings ist der Lernprozess einfacher zu gestalten.*

**Definition A.11** (Wissensbasis). *Im Gegensatz zur üblichen Definition, die von einer symbolischen Wissensrepräsentation ausgeht [RN09], ist hier das Ergebnis der in Abschnitt 2.6 definierten Verarbeitung der erzeugten Zuordnungen gemeint. Es stellt subsymbolisches Wissen in jeweiliger Form des verwendeten überwachten Lernverfahrens dar, beispielsweise Gewichte in einem künstlichen neuronalen Netz [Mit97].*

**Definition A.12** (Parameter). *Ein weiterer und der letzte Teil (neben dem physischen und logischen) des Inputs des Systems, der Einfluss auf dessen Output hat. Hier sind damit alle restlichen Einflussfaktoren aufgeführt, unter anderem jene, die aus der Umwelt stammen (exogene Einflüsse), wie etwa die Systemlast oder Verfügbarkeit einzelner Komponenten aufgrund von Störfällen.*

**Definition A.13** (Systemparameter). *Systemparameter sind hier eine Teilmenge der Parameter des Systems, die explizit ausgelesen werden und dessen Veränderungen bei der Generierung von Zuordnungen berücksichtigt werden sollen. Aus den  $n$  Systemparameter mit jeweiligen Wertebereichen  $P_i$  ergibt sich die Menge aller möglichen Systemparameterausprägungen  $P = \prod_{i=1}^n P_i$ . Eine Ausprägung von Systemparametern ist dann ein Tupel  $p = (p_1, p_2, \dots, p_n) \in P$ .*

**Definition A.14** (Stochastische Systemparameter). *Stochastische Systemparameter beschreiben nichtdeterministische Umstände innerhalb des Systems, die kurzfristig eine Ausprägung annehmen und mittels Wahrscheinlichkeitsverteilungen beschrieben werden können. Sie stehen im Gegensatz zu Systemparametern, die immer einen konkreten Wert annehmen und sich nur langfristig verändern.*

**Definition A.15** (Modell). *„Ein Modell ist eine vereinfachte Nachbildung eines existierenden oder gedachten Systems mit seinen Prozessen in einem anderen begrifflichen oder gegenständlichen System. Es unterscheidet sich hinsichtlich der untersuchungsrelevanten Eigenschaften nur innerhalb eines vom Untersuchungsziel abhängigen Toleranzrahmens vom Vorbild. Es wird genutzt, um eine bestimmte Aufgabe zu lösen, deren Durchführung mittels direkter Operationen am Original nicht möglich oder zu aufwendig wäre“ [VDI96].*

<sup>2</sup> Induktives Lernen verallgemeinert aus dem Speziellen.

**Definition A.16** (Simulation). *„Simulation ist ein Verfahren zur Nachbildung eines Systems mit seinen dynamischen Prozessen in einem experimentierbaren Modell, um zu Erkenntnissen zu gelangen, die auf die Wirklichkeit übertragbar sind. Im weiteren Sinne wird unter Simulation das Vorbereiten, Durchführen und Auswerten gezielter Experimente mit einem Simulationsmodell verstanden.“ [VDI96]*

**Definition A.17** (Prognose). *Die Prognose liefert Angaben über eine voraussichtliche Wirkung und Entwicklung. Sie beruht auf der Annahme eines bestimmten Aktivitäten-Niveaus. Auch keine Veränderung ist dabei eine Aktivität [Han79] [Mer05].*