

# **Schlussbericht**

## zum Forschungsvorhaben

### Online-Materialflussdiagnose (oMFD)

Das IGF-Vorhaben 17343BR der Forschungsvereinigung Bundesvereinigung Logistik (BVL) e.V. wurde über die AiF im Rahmen des Programms zur Förderung der Industriellen Gemeinschaftsforschung (IGF) vom Bundesministerium für Wirtschaft und Technologie aufgrund eines Beschlusses des Deutschen Bundestages im Zeitraum 01.12.2011 – 31.10.2013 gefördert.

#### **Herausgeber**

Prof. Dr.-Ing. habil. Thorsten Schmidt

Technische Universität Dresden  
Professur für Technische Logistik

Telefon: +49 (0) 351 463-34861

<http://www.logistik.mw.tu-dresden.de/>

Prof. Dr.-Ing. habil. Klaus Kabitzsch

Technische Universität Dresden  
Professur für Technische Informationstechnik

Telefon: +49 (0) 351 463-38289

Dieses Werk ist urheberrechtlich geschützt. Die dadurch begründeten Rechte, insbesondere die der Übersetzung, des Nachdrucks, der Entnahme von Abbildungen, der Wiedergabe auf photomechanischem oder ähnlichem Wege und der Speicherung in Datenverarbeitungsanlagen bleiben – auch nur auszugsweise – vorbehalten.

Copyright © 2014 Technische Universität Dresden, Professur für Technische Logistik, Professur für Technische Informationssysteme

# Inhalt

<b>1</b>	<b>Zusammenfassung</b>	<b>3</b>
<b>2</b>	<b>Ausgangssituation</b>	<b>4</b>
2.1	Stand der Technik	5
2.2	Problemstellung und Anforderungen	8
<b>3</b>	<b> Projektdurchführung</b>	<b>10</b>
3.1	Arbeitspakete	10
3.2	Projektbearbeitung	11
<b>4</b>	<b> Darstellung der Forschungsergebnisse</b>	<b>12</b>
4.1	Echtzeitdatenströme, Kenngrößen und Regeln	12
4.1.1	Use Cases	12
4.1.2	Erweiterte und Differenzierte Kenngrößen	15
4.1.3	Erweiterung der Analyse- und Diagnosemethoden	15
4.2	Datenmanagement für Echtzeit-Datenströme	30
4.2.1	Explizite und iterative Berechnung	30
4.2.2	Complex Event Processing	31
4.2.3	Indizierung aufgezeichneter Daten mit Präfixbäumen	33
4.3	Algorithmen zur Online-Diagnose	35
4.4	Konzeption einer Wissensbasis zur Online-Materialflussdiagnose	39
4.5	Visualisierung und Protokollierung	42
4.5.1	Visualisierung	42
4.5.2	Leitfaden für Protokollierung	43
<b>5</b>	<b> Bewertung der Forschungsergebnisse</b>	<b>47</b>
5.1	Zusammenfassung und Ausblick	47
5.2	Nutzen und wirtschaftliche Bedeutung für kmU	47
5.3	Transfer der Forschungsergebnisse	49
5.4	Gewerbliche Schutzrechte	51
<b>6</b>	<b> Beteiligte Forschungsstellen</b>	<b>52</b>
<b>7</b>	<b> Literatur</b>	<b>53</b>
<b>8</b>	<b> Glossar</b>	<b>58</b>
<b>9</b>	<b> Symbole, Objekte und Kenngrößen</b>	<b>59</b>

# 1 Zusammenfassung

Gegenstand des Forschungsprojektes Online-Materialfluss-Diagnose war es, Verfahren für die Analyse des Verhaltens von Materialflusssystemen (MFS), zu entwickeln und zu erweitern mit besonderem Augenmerk auf der Fähigkeit, diese Systeme anhand von Echtzeitdatenströmen, sogenannter Ereignis- oder Trace-Daten, semiautomatisch zu analysieren und zu bewerten.

Im Kern wurden Methoden erforscht, welche es ermöglichen, bereits zeitnah während des Betriebes, Schwachstellen zu identifizieren, zu bewerten und im Diagnose-Schritt mögliche Primär-Ursachen für abweichendes oder unerwünschtes Systemverhalten zu ermitteln. Dafür wurden generische Ansätze zur Verwaltung von Wissen über logistische Systeme, typische Fehler und deren Ursachen ermittelt. Darüber hinaus wurden Möglichkeiten zur Trendanalyse zukünftigen Verhaltens untersucht, womit eine Fehlerfortpflanzung ggf. operativ unterbunden werden kann.

Über den eigentlichen Forschungsgegenstand hinaus wurden die entstandenen Verfahren und Methoden auch exemplarisch für Produktionssysteme eingesetzt und können nahezu an beliebige ereignis-gesteuerte/ -überwachte Systeme angepasst werden. Sämtliche Methoden wurden in Form von Software-Demonstratoren umgesetzt und getestet.

***Das Ziel des Forschungsvorhabens wurde damit erreicht.***

Die Erreichung der Forschungsziele wurde durch eine enge Zusammenarbeit der Forschungsstellen und den damit verbundenen Wissensaustausch zwischen der Professur für Technische Logistik und der Professur für Technische Informationssysteme ermöglicht. Es ist geplant, die Kooperation der Forschungsstellen fortzuführen. Die gewonnenen Erkenntnisse stießen auf positive Resonanz sowohl bei den Mitgliedern des projektbegleitenden Ausschusses als auch bei weiteren im Projektverlauf angesprochenen Industrievertretern.

## 2 Ausgangssituation

Die Aufgabe der Logistik im Allgemeinen besteht in der Bereitstellung der richtigen Güter in der richtigen Menge, am richtigen Ort, zum richtigen Zeitpunkt, in der richtigen Qualität und zu den richtigen Kosten. Diesen Anforderungen obliegen auch Materialflusssysteme als „Träger“ der innerbetrieblichen Logistik (Intralogistik). Darüber hinaus müssen Materialflusssysteme in Zeiten kürzer werdender Produktlebenszyklen flexibel und wandlungsfähig sein. Diesen technischen Anforderungen stehen jedoch immer komplexer werdende Systeme gegenüber. Die Differenzierung der Anbieter, welche derartige Systeme planen (Layout, Steuerung,...), herstellen, warten, betreiben und/oder optimieren, erfolgt zunehmend über die Servicequalität, der Zuverlässigkeit des Systems und vor allem dem Leistungsvermögen verglichen mit den jeweils entstehenden Kosten. Wiederholte Leistungsmängel eines Systems – z. B. lange Durchlaufzeiten oder Warteschlangen – können für den Hersteller, Betreiber oder Dienstleister schnell zur Beeinträchtigung oder sogar zum Verlust des Vertragsverhältnisses führen. Daher ist es ein grundlegendes wirtschaftliches Interesse die Anlagen zum einen anforderungsgerecht zu gestalten und zu betreiben bzw. zu optimieren sowie zum anderen in der Planungsphase nicht überdimensionieren. Vor allem im laufenden Betrieb ist die maximale Leistungsfähigkeit gezielt auszunutzen. Die Identifizierung von (lokalen) Leistungsreserven kann zum Beispiel die Flexibilität der Anlage erhöhen, ohne dass zusätzliche Fördertechnik erforderlich ist. Die genaue Kenntnis systeminterner Abläufe und Verhaltenszustände ist dabei eine wesentliche Voraussetzung.

Das häufig benutzte Standardwerkzeug der Materialflusssimulation (AutoMod, Plant Simulation, u. a.) beantwortet zwar die Frage, ob ein Systementwurf in Layout und Steuerung den globalen Anforderungen (Gesamtdurchsatz, Durchlaufzeit,...) genügt, nicht aber warum und wie gut bzw. schlecht er das tut. Letzteres wird derzeit nur intuitiv vom Entwickler, d. h. ohne Tool-Unterstützung, analysiert. Die systeminterne Analyse und das Auffinden von kritischen Einflüssen hängen somit stark von der Erfahrung des Experten sowie vom Zufall ab (DANGELMAIER et al. 2003). Hinzu kommt der enorme manuelle Aufwand aufgrund riesiger Datenmengen, da moderne Materialflusssysteme in kurzer Zeit sehr viele Ereignisse erzeugen.

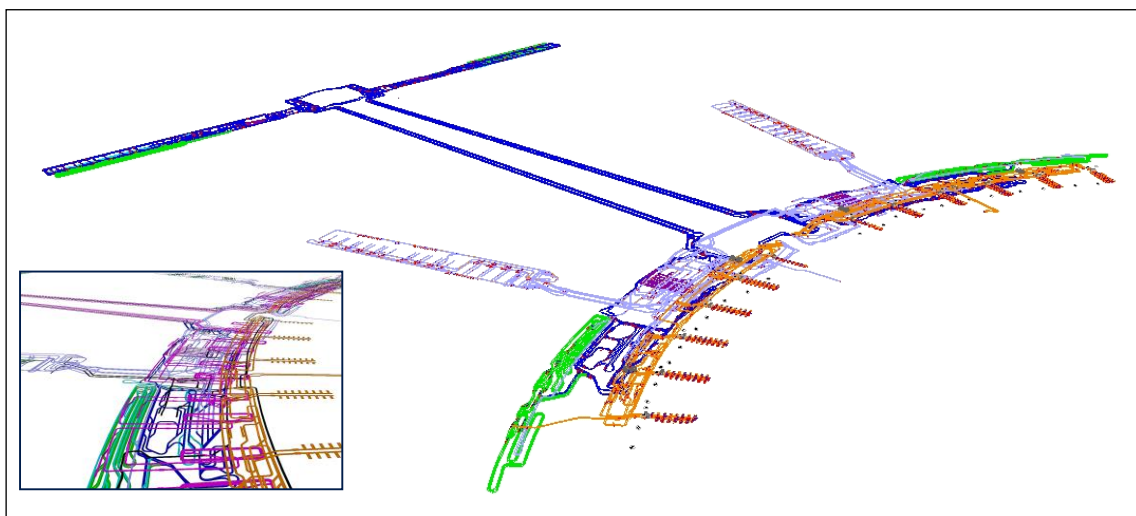


Abbildung 1: Beispiel eines komplexen Materialflusssystems– Gepäckförderanlage des Flughafens Incheon (Korea)

Im Rahmen des Vorgängerprojektes der Materialflussdiagnose (15770) wurden Verfahren erforscht, um die methodische Lücke in der Auswertung intralogistischer Ereignisdaten zu schließen. Für das Diagnosepersonal sollten basierend auf statistischen Verfahren entsprechend relevante suboptimale Verhaltenszustände und -muster innerhalb des Systems rechnergestützt identifiziert werden. Die Ergebnisse zeigten deutlich die Potenziale einer solchen rechnergestützten Diagnose von Materialflusssystemen anhand von Ereignisdaten (Trace-, Log-, Protokolldaten). Mithilfe einer implementierten Test- und Entwicklungsumgebung wurde im Rahmen des Vorgängerprojektes gezeigt, dass aus z. B. 2 Mio. Ereignissen (ca. 1,8 GB Daten im txt-Format) systeminterne Schwachstellen (z. B. Unter-/ Überlast, Warteschlangen,...) in Ort und Zeit identifiziert und dadurch lokale Ursachen für suboptimales Verhalten dem Diagnosepersonal aufgezeigt werden. Allerdings unterlagen die entwickelten Methoden und Algorithmen einigen Restriktionen, die wohl wichtigste war die Beschränkung auf eine ausschließlich „offline“ erfolgende Analyse und Diagnose. Der hier vorliegende Bericht fasst die Erkenntnisse des Forschungsvorhabens zur Online-Materialflussdiagnose zusammen und soll somit in erster Linie den „Sprung“ von der Offline-Diagnose zur Online-Diagnose für Materialflusssysteme im laufenden Betrieb ermöglichen. Die nachfolgende Abbildung 2 fasst die Ausgangssituation und die Grundmotivation für dieses Forschungsvorhaben zusammen.

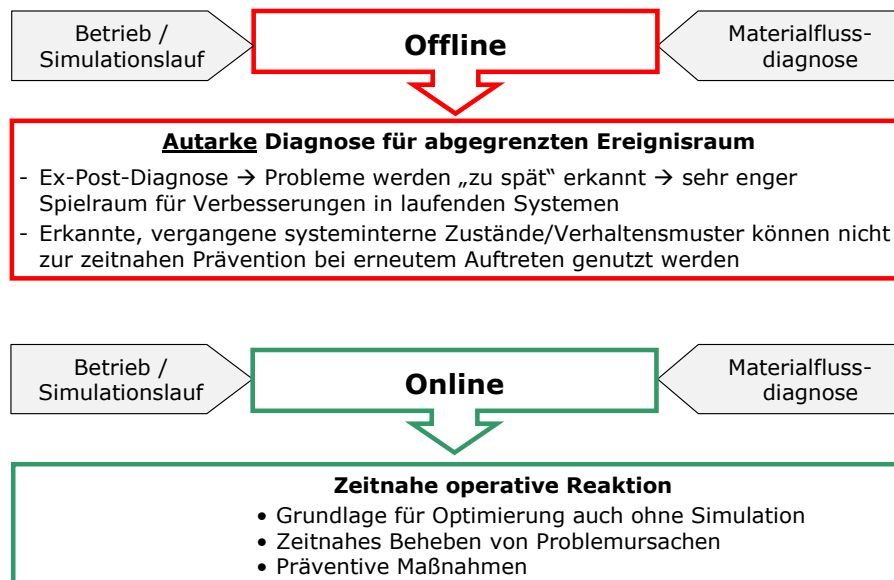


Abbildung 2: Ausgangssituation/ Motivation O-MFD – Offline vs. Online

## 2.1 Stand der Technik

In NAKAYAMA (2006) findet sich eine zusammenfassende Darstellung der verbreiteten Sichtweise auf das Thema „Output analysis for simulations“. So werden häufig statistische Methoden zur Bestimmung von nur globalen Leistungskenngrößen diskutiert (vgl. LAW/ KELTON 2000; FISHMAN 2001). BRATLEY et al. (1987) erläutern zum Beispiel, wie möglichst signifikante Schätzer zur Leistungsbewertung des Gesamtsystems bestimmt werden können. Die Schätzer beschreiben, in welchem Maße spezifische globale Kenngrößen von bestimmten Parametern abhängen. NAKAYAMA (2006) nennt hierbei die „perturbation analysis“ (vgl. BONNANS/ SHAPIRO 2000) und „likelihood-ratio method“ (vgl. RUBINSTEIN 1989) als Verfahren, diese Schätzer für den Grad der Abhängigkeit zu bestimmen. Aufgrund des hohen Zeit- und Rechenaufwandes stellen diese jedoch keine geeignete Möglichkeit dar, um in der für komplexe Systeme charakteristischen

Vielzahl von Abhängigkeiten diejenigen gezielt zu identifizieren, die besonders stark ausgeprägt sind und tatsächliche Analyserelevanz besitzen. Ein weiteres Konzept zur Parametrierung von Simulationsmodellen und zum spurbasierten Debuggen auf Basis von Trace-Daten wird in GORDON/ KEMPER (2007) vorgestellt. Entgegen der Online-Diagnose sind die Zielsetzungen jedoch gänzlich andere. Durch Clusterbildung von einem Set mehrerer Traces soll der Simulationsexperte bei der Organisation der Daten unterstützt und somit die Identifikation von entscheidenden Parametern oder relevanten Simulationsläufen erleichtert werden.

Die Idee, vorhandene Daten für eine Analyse zu nutzen, ist nicht neu. KEMPER/TEPPER (2005) stellen einen Ansatz vor, welcher die ausgeprägte menschliche Fähigkeit zur visuellen Wahrnehmung und Bewertung von Zusammenhängen nutzt. Die Aufbereitung der Daten mittels „Message Sequence Charts (MSC)“ schafft eine Möglichkeit zur Identifikation von zeitweisen Blockierungen sowie Staus, Warteschlangen und Engpässen. Dieser Ansatz wurde jedoch nur für relativ kleine Systeme und somit nur für kleinere Datenmengen betrachtet und ist besonders vor dem Hintergrund der im Online-Betrieb stetig wachsenden Datenmenge nicht geeignet. Die Autoren selbst weisen diesbezüglich darauf hin, dass zur Aggregation größerer Datenmengen die Entwicklung von „reduction techniques“ eine zukünftige Zielsetzung sein sollte.

In KEMPER/TEPPER (2009) beschreiben die Autoren später eine entwickelte „reduction technique“. Diese, den Autoren nach, neue Methode soll dem Modellierer einen Einblick in das komplexe stochastische Verhalten eines ereignisdiskreten Simulationsmodells, basierend auf einer Trace-Analyse<sup>1</sup> durch Reduzierung des Datenumfangs ermöglichen. Es wird ein Algorithmus vorgeschlagen um fortschreitendes von wiederholendem Verhalten abzugrenzen. Informationen zur Reduzierungsoperation sowie das verkleinerte Trace-File selbst unterstützen den Modellierer beim Aufspüren von diversen Modellfehlern. Ein wesentliches Ziel dieses Forschungsvorhabens Materialflusssysteme im laufenden Betrieb zu bewerten und zeitnah Ergebnisse zu visualisieren, wodurch im Gegensatz zu KEMPER und TEPPER keine geschlossene Datenbasis vorliegt. Zwar stellen die Verfahren zur Zyklus- bzw. Mustererkennung interessante Ansätze zur Reduzierung des Datenumfangs für Ereignisdaten aus der Simulation dar, jedoch sind diese für hier angestrebten Ergebnisse nicht geeignet. KEMPER/TEPPER (2009) diskutieren ausschließlich, inwieweit Wiederholungen innerhalb einer Trace-Datei automatisiert identifiziert und entfernt werden können, um das File zu verkleinern, um den Suchraum nach Fehlern für den Modellierer einzugrenzen.

Ein theoretischer Ansatz, ebenfalls zur Nutzung der visuellen Fähigkeiten des Menschen für die Analyse großer Datenmengen mittels selbstorganisierender Merkmalskarten wird in WÖLKER (2000) beschrieben. Die Verwendung von neuronalen Netzen zur Datenaggregation, welche vom Autor selbst als schwierig bezeichnet wird<sup>2</sup>, liefert durch farbige Kennzeichnung auf Komponentenkarten schnell ein Bild vom System. Die direkte Umsetzung der Methode ist im praktischen Umfeld schwierig, da die entstandenen Karten selbst einer abschließenden Interpretation bedürfen. Darüber hinaus ist eine automatisierte Online-Erkennung von Schwachstellen und Diagnose von Primärursachen durch dieses Verfahren nicht möglich.

Dem Ansatz einer automatisierte Materialflussdiagnose kommen BETTER et al. (2007) methodisch am nächsten. Sie entwickeln eine Kombination von Dynamic-Data-Mining- und Optimierungs-Techniken, um die relevanten Variablen, Attribute und Regeln zu identifizieren, welche das Simulationsmodell maßgeblich bestimmen. Die Autoren verfolgen hierbei jedoch das Ziel, die für die Optimierung einer Kenngröße

---

<sup>1</sup> Trace-Analyse: zu deutsch auch Spuranalyse, d.h. Identifikation von Ereignisketten (Ereignisspuren)

<sup>2</sup> WÖLKER (2000) S. 105

erforderliche Zahl von Simulationsläufen zu reduzieren. Auch in KEMPER/TEPPER (2007) wird zwar ein Verfahren vorgestellt, welches die Identifizierung von Fehlern aus Simulations-Traces ermöglicht, jedoch liegt der Fokus nur auf „echten“ Fehlern. Es handelt sich somit um eine Identifikation von Fehlern, welche sich selbst als irregulär definieren, also irreversible Veränderungen im Zustand eines diskreten Simulationsmodells (Modellfehler). Die Zielsetzung liegt hier demnach in der Fehlerbehebung bei der Modellerstellung und nicht in der Fehleridentifizierung und Diagnose bezüglich des Systemverhaltens. Der Ansatz in STRUSS/ERTL (2009) zur Diagnose von Flaschenabfüllanlagen stellt eine modellbasierte Diagnose anhand des Anlagenlayouts vor. Dieser nicht online einsetzbare Ansatz beschränkt sich jedoch nur auf bestimmte Fehlertypen. Nicht das Gesamtsystem wird analysiert, sondern nur ausgewählte Fördererlemente, wodurch dieser Ansatz für eine umfassende Systemanalyse nicht geeignet ist. Es können zum Beispiel keine Engpässe oder Reserven sowie Abhängigkeiten zwischen den Elementen erkannt werden.

In existierenden Materialflussanlagen wird der Fehler häufig erst dann erkannt, wenn globale Leistungswerte aufgrund immanenter Irregularitäten im System nicht erfüllt werden, oder im Extremfall ein Systemausfall vorliegt. Die manuelle Suche nach den Ursachen für systeminternes Fehlverhalten scheitert aufgrund der meist hohen Komplexität automatischer Materialflusssysteme bei der Identifizierung der suboptimalen Zustände im relevanten Betrachtungszeitraum. Darüber hinaus unterliegen laufende Systeme, wie bereits beschrieben, häufigen Anpassungen. Welchen Einfluss diese Änderungen im Einzelfall haben, bleibt meist verborgen und es ist äußerst schwierig die systeminterne Leistungsgüte adäquat bewerten zu können. Demgegenüber steht das riesige, in den Protokoll- oder Logdateien vorhandene, Informationspotenzial. Diese speichern in der Regel jede Zustandsänderung (Ereignisse) im System und enthalten neben Standardinformationen (Zeitstempel, Ereignisort, ID) anwendungsspezifische Zusatzinformationen (vgl. WUSTMANN et al. 2009). Jedoch werden diese Datenmengen nur selten für eine laufende Prozessanalyse genutzt, um systeminterne Schwachstellen oder Leistungsreserven zu identifizieren. Vielmehr entsteht nach TOLUJEW et al. (2007) eine unbefriedigende Situation für alle betroffenen Seiten. Den Logistikern stellt sich die Frage „Was bringen uns, [...], diese Daten?“ wohingegen die Informatiker nicht wissen „wohin mit den Daten“

In Anlehnung an die Definitionen zur Online-Optimierung von KLÖPFER (2009) und TINKL (2008), werden im Rahmen dieses Forschungsvorhabens die Begriffe Online-Analyse und -Diagnose ebenfalls im Kontext unvollständiger Eingabedaten verstanden. Die Ereignisdaten sind zu Beginn der Online-Materialflussdiagnose „unvollständig“, nehmen mit fortschreitender Zeit an Menge stetig zu und sind erst für einen Betrachtungszeitraum gegen unendlich als vollständig anzusehen.

Nachdem der Begriff der Online-Diagnose vordergründig für stetig wachsende Datenmengen steht, wird der Terminus „Echtzeit“ eher hinsichtlich des Antwortzeitverhaltens eines Systems verstanden. Ein System ist echtzeitfähig, wenn es synchron zum Zeitverbrauch der Abläufe in der „realen Welt“ Entscheidungen treffen kann (vgl. JEDERMANN et al. 2006). Mit Echtzeit wird demnach eine Betriebsart beschrieben, welche eine direkte Interaktion mit Daten (hier speziell: Ereignisdaten) im Augenblick der Erzeugung ermöglicht (vgl. KOPETZ 1998). Darüber hinaus steht der Begriff aber auch für eine schritthaltende Verarbeitung von Prozessdaten, d. h. auf extern entstandene Eingangssignale wird innerhalb einer spezifizierten (systemabhängigen) Zeitdauer reagiert. So ist nach BURNS/WELLINGS 2001 und PFÜLLER 2008:

- die Richtigkeit eines Echtzeit-Systems von den logischen Ergebnissen der Berechnung abhängig, sowie auch von dem Zeitpunkt, an dem die Ergebnisse produziert/ausgegeben wurden,
- eine zu späte Antwort genau so schlecht wie eine falsche Antwort und im Extremfall ein richtiges Ergebnis zur falschen Zeit ein Fehler.

Bereits SCHENK et al. (2007) stellen fest, dass experimentelle Untersuchungen sowie ein präzises theoretisches Konzept von großer Bedeutung für die Umsetzung von Echtzeitsystemen sind. Hierzu ist nach TOLUJEW et al. (2007) die Unterscheidung verschiedener Klassen logistischer Echtzeitsysteme sinnvoll. Demnach bilden das Monitoring als Bestandteil des *Logistikcontrollings* (WIENDAHL 2004), das *Event Management* zur automatischen Erkennung vordefinierter Situationen (STEVEN/KRÜGER 2003) sowie *Frühwarnsysteme*, welche durch eine betriebsbegleitende Simulation die Prozesse für einen kurzen Vorhersagezeitraum reproduzieren (HANISCH et al. 2005), die wesentlichen funktionellen Klassen für Echtzeitsysteme in der Logistik.

Einen möglichen Ansatzpunkt für die Online-Bewertung systeminterner Zustände könnte das Feld der statistischen Prozesskontrolle (SPC für statistical process control) liefern. Die ursprünglich aus dem Bereich des Qualitätsmanagements stammende Idee verfolgt den Ansatz, ob sich charakteristische Kennzahlen eines Fertigungsprozesses in einem angestrebten Normalbereich befinden oder der Prozess *außer Kontrolle* gerät (FAES 2009, S. 27). Anwendung findet dies beispielsweise in der Automobilindustrie (vgl. CHRYSLER CORPORATION et al. (1992)). Die SPC unterscheidet grundsätzlich zwei verschiedene Arten von Abweichungen vom Normalzustand um bspw. Maschinenparameter im laufenden Betrieb zu überwachen: Zum einen diejenigen, die als unvermeidbar und ohne besondere Ursache gelten. Dies sind Schwankungen um den Normalwert als konstantes Mittel, welche aufgrund ihrer Geringfügigkeit als gewöhnlich anzusehen sind. Zum anderen existieren außergewöhnliche Abweichungen, welche ein anormales Prozessverhalten anzeigen und einer bestimmten Ursache zuordenbar sind (ROBINSON 2002,2007, S. 2). Die SPC findet darüber hinaus auch Anwendung in der Ermittlung der Einschwingphase von Simulationsmodellen. Dieses Gebiet beschäftigt sich damit, den Übergangspunkt zwischen Einschwingphase und stationärer Phase zu erkennen, die Phasen zu trennen und die Daten der Einschwingphase zu verwerfen. Schwerpunkte liegen demnach in der sinnvollen Untergliederung von Datenmengen und dem Verwerfen einzelner Datenabschnitte. Daraus lassen sich ggf. Analogien zur Einteilung von Ereignisdatenströmen in relevante Zeitbereiche nutzen.

Zusammenfassend lässt sich feststellen, dass derzeit in laufenden Systemen aggregierte Daten (Mittelwerte) aus den Ereignisinformationen gewonnen werden, um globale Leistungsparameter zu bestimmen und diese offline auszuwerten. Die aggregierten Daten erlauben jedoch keinen Zugang zu Einzelereignissen und somit keine gezielte Suche nach systeminternen Schwachstellen (Leistungsreserven oder Überlast) zur Laufzeit.

## 2.2 Problemstellung und Anforderungen

Ausgehend von den Definitionen zum Online- sowie Echtzeitbegriff in 2.1 ergaben sich folgende wesentliche Fragestellungen hinsichtlich der Online-Problematik:

- Allgemeine Kernfrage:  
„Wie ist mit der sich ständig ändernden Informationsbasis umzugehen?“
- Wie sind die bereits entwickelten Methoden und Verfahren (Vorgängerprojekt) im Hinblick auf die Online-Diagnose von Echtzeit-Datenströmen im intralogistischen Umfeld weiterzuentwickeln?
- Wie stellt sich eine intelligente Verwaltung der Online-Datenpuffer dar? Wie ist die Ergebnisverwaltung und -Speicherung im Online-Betrieb zu realisieren (Wissensmanagement)?
- Wie ist mit Inkonsistenzen/Redundanzen in den Daten (Datenmüll) umzugehen, ohne das Antwortzeitverhalten bzw. die Richtigkeit der Diagnose zu beeinträchtigen?



- Inwieweit können, basierend auf den Diagnoseergebnissen der Vergangenheit sowie auf den für den Anwendungsfall spezifischen Erfahrungen, Verhaltenstrends erkannt werden?
- Wie „groß“ müssen die Zeitfenster zu einer automatisierten Variation der Zeitbereiche sein? Das heißt, mit welchen Verfahren kann die Größe der Zeitfenster der Informationsmenge der jeweiligen Datenbasen automatisiert angepasst werden?

Ebenso wie in zahlreichen anderen Forschungsvorhaben besteht auch hier das Problem der Übertragung von empirischen Erfahrungen der Experten in die Diagnosemethoden bzw. in eine maschinenlesbare Form. Die Notwendigkeit eines Eingabemodells zur effizienten Katalogisierung und Verwaltung von Wissen liegt auf der Hand. Bereits NEUMANN/TOMÉ (2007) stellten die Potenziale des Wissensmanagements für den Bereich der Logistik im Allgemeinen heraus. Gleichzeitig bemerken die Autoren das Defizit in der praktischen Umsetzung an.<sup>3</sup> Dieses Forschungsvorhaben erhebt zwar keinen Anspruch auf die Beseitigung dieses Defizits, jedoch ist die Thematik einer effizienten Wissensverwaltung auch für die Online-Diagnose automatischer Materialflusssysteme ein wichtiger Punkt. Es stellen sich zum Beispiel die Fragen: „Welche Meta-Informationen<sup>4</sup> sind neben den Ereignisdaten sinnvoll und durch die potenziellen Anwender mit relativ geringem Aufwand anzugeben?“ und „Wie kann mit der Vielzahl an Kombinationen aus Kenngrößen, Regeln, Ereignisinformationen und Zielstellungen effizient umgegangen werden?“ Die Konzipierung einer wissensbasierten Diagnose stellt demnach, neben der Entwicklung von Laufzeitkenngrößen und Analyseregeln sowie Methoden zur automatisierten Zeitbereichsbildung, einen Forschungsschwerpunkt des vorliegenden Antrags dar.

Ein wissensbasiertes System ist nach CROFT (1987, S. 249) ein System mit einer Wissensbasis und der Möglichkeit, Schlussfolgerungen zu bilden, welche dazu benutzt werden können, Verbindungen zwischen einer Anfrage und einer Menge von Informationen herzustellen. Demnach muss, damit kein Informations- oder Wissensverlust erfolgt, eine sinnvolle Möglichkeit der Wissensstrukturierung gefunden werden. Mit anderen Worten: Wie können Informationen von Quelle A mit denen von Quelle B zu einer erweiterten Wissensstruktur C verbunden bzw. ineinander überführt werden? Anhand der Abbildung 3 wird die Problematik grafisch verdeutlicht.

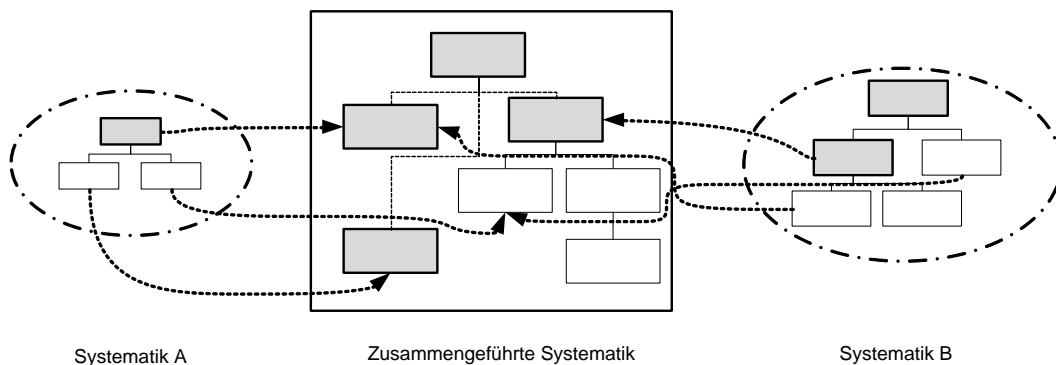


Abbildung 3: Problematik der Vereinigung verschiedener Systematiken – Klassifizierungsproblem

<sup>3</sup> vgl. auch NEUMANN/DÜRING (2008)

<sup>4</sup> z.B. Topologieinformationen (Quellen, Senken...), Sollzeiten für einzelne Prozessschritte,...

## 3 Projektdurchführung

Die Finanzierung des Forschungsvorhabens wurde für den Zeitraum 01.11.2011 – 31.05.2013 bewilligt. Die für die Projektbearbeitung geplanten wissenschaftlichen Mitarbeiter beider Forschungsstellen konnten jedoch, aufgrund Elternzeiten nicht kontinuierlich bereitgestellt werden (siehe Zwischenbericht 2012). Daher mussten einige abschließende Arbeiten zu den APs 3, 4 und 5 in das Haushaltsjahr 2013 verschoben werden. Dementsprechend wurde eine kostenneutrale Verlängerung bis zum 31.10.2013 bewilligt.

Der folgende Abschnitt stellt die geplanten Arbeitspakete inhaltlich kurz vor. Anschließend zeigt Abschnitt 0 den realisierten zeitlichen Ablauf auf. Die Dokumentation der Forschungsergebnisse findet sich in Kapitel 4.

### 3.1 Arbeitspakete

#### **AP 1: Analyse repräsentativer Echtzeitdatenströme, Kenngrößen und Regeln erweitern**

In diesem ersten Arbeitspaket wurden Datenströme anhand von Spezifikationen der Mitglieder des projektbegleitenden Ausschusses insbesondere mit Augenmerk auf enthaltene Merkmale, Ereignishäufigkeiten und Datenqualität untersucht. Weiterhin wurden dieselben Themen mit Vertretern der Halbleiterindustrie diskutiert und entsprechende Daten bereitgestellt. Anschließend wurden relevante Anwendungsszenarien definiert.

#### **AP 2: Analyse- und Diagnosemethoden für zusätzliche Informationen anpassen/ entwickeln**

Das bereits im Rahmen des Vorgängerprojektes entwickelte Softwarewerkzeug zur Analyse wurde so erweitert, dass zusätzliche Ereignisattribute bei Bedarf verarbeitet werden können. Weiterhin wurde eine Methode aus der Qualitätssicherung (SQC) adaptiert und angepasst um Normalverhalten von Kenngrößen oder Kenngrößenkombinationen zu identifizieren und mittels systemspezifischer Regeln sog. Außerkontrollsituationen zu identifizieren (SPC).

#### **AP 3: Algorithmen zur Online-Diagnose, Datenmanagement Echtzeitdatenströme**

In diesem Arbeitspaket wurden zunächst verschiedene Methoden und Strategien zur Verarbeitung von Ereignisströmen recherchiert und ihre Eignung überprüft.

Anschließend wurden Verfahren zur Online-Diagnose recherchiert und mehrere Verfahren umgesetzt beziehungsweise entwickelt. Dabei hat sich gezeigt, dass weniger die Verwaltung der Algorithmen und Kenngrößen als vielmehr die Aufbereitung der Eingangsdaten und Diagnoseergebnisse von praktischem Nutzen ist und durch eine Wissensbasis unterstützt werden muss.

#### **AP 4: Methoden und Verfahren zur Trendanalyse**

Dieses Arbeitspaket nahm insgesamt einen leicht höheren Stellenwert ein als ursprünglich geplant, da hier große Potentiale liegen und die kooperierenden Firmen besonderes Interesse daran zeigten. Es wurden zunächst Trendanalyseverfahren recherchiert und das in Kapitel 4.1.3.3 beschriebene Verfahren ausgewählt. Anschließend wurde das Verfahren in den bereits im Vorgängerprojekt begonnenen Demonstrator integriert und getestet.

#### **AP 5: Konzeption einer Wissensbasis zu Online-Materialflussdiagnose**

Für dieses Arbeitspaket wurden zunächst Recherchen zur Klassifikation und Beschreibung logistischer Systeme sowie allgemeiner relevanter Konzepte durchgeführt. Anschließend wurden mehrere Ontologien

unterschiedlicher Abstraktionsebenen modelliert. Weiterhin wurden Verfahren zur Integration des Wissens in Softwarewerkzeuge recherchiert und getestet.

### **AP 6: Visualisierung und Tests**

Es wurden Visualisierungsframeworks und –techniken ermittelt und getestet, welche sich für die Darstellung großer Systeme eignen. Das Framework Prefuse<sup>5</sup> wurde aufgrund der hervorragenden Darstellungs- und Interaktionsgeschwindigkeit für die Graphdarstellung ausgewählt, angepasst ebenso wie weitere Darstellungsformen und in den Demonstrator integriert.

Die Aussagekraft der Kenngrößen und der Ergebnisse der Diagnosefunktionen wurde in Zusammenarbeit mit Industriepartnern validiert.

### **AP 7: Dokumentation und Veröffentlichung der Forschungsergebnisse**

Es wurden Verfahren zur Visualisierung der Diagnoseinformationen und –ergebnisse gesucht. Mithilfe von geeigneten Methoden soll damit die praktische Anwendbarkeit und Nutzerakzeptanz der Diagnosealgorithmen gewährleistet werden. Weiterhin war die Dokumentation der Forschungsergebnisse in Veröffentlichungen sowie in den zu erstellenden Forschungsberichten Bestandteil dieses Arbeitspaketes. Neben den bereits erfolgten Veröffentlichungen in einschlägigen Fachzeitschriften und Tagungsbeiträgen verschiedener Veranstaltungen, sind noch weitere in Arbeit bzw. bereits zur Veröffentlichung angenommen (vgl. Kapitel 6.2, S.80). Die Suche nach Visualisierungsmöglichkeiten erfolgte bereits in einer sehr frühen Projektphase und beanspruchte mehr Zeit als ursprünglich geplant. Dadurch wurde jedoch die Validierung der entwickelten Methoden erleichtert und bereits in einem frühen Projektstadium die fundamentale Notwendigkeit einer objektbasierten Betrachtung erkannt. Das System als Knoten-Kanten- bzw. Zustands-Übergangsmodell zu behandeln, erwies sich nicht nur im Hinblick auf die Visualisierung als nützlich sondern auch besonders auf die Kenngrößen und Methodenentwicklung.

## **3.2 Projektbearbeitung**

Für die Projektbearbeitung wurde bei TL ein wissenschaftlicher Mitarbeiter für 18 Monate in Vollzeit beschäftigt. Da die durchgeführten Arbeiten unterschiedliche Expertise erforderten, wurden bei TIS 4 wissenschaftliche Mitarbeiter mit insgesamt 19 Mannmonaten beschäftigt. Die wissenschaftlichen Mitarbeiter führten das Projekt über die gesamte Laufzeit selbstständig, mit fachlicher Begleitung durch die Professoren, eigenverantwortlich durch. Des Weiteren wurden an der Forschungsstelle 1 studentische Hilfskräfte (SHK) für insgesamt 1115h und an der Forschungsstelle 2 studentische Hilfskräfte für insgesamt 548h beschäftigt. Der Aufgabenbereich der SHK`s lag vor allem im Testen der entwickelten Diagnosekomponenten sowie in der Systematisierung bzw. Aufbereitung der Forschungsergebnisse. Die insgesamt geleisteten Arbeiten waren für die Durchführung des Vorhabens notwendig sowie angemessen und entsprechen in ihrer Gesamtheit dem geplanten und bewilligten Umfang.

---

<sup>5</sup> <http://prefuse.org/>

## 4 Darstellung der Forschungsergebnisse

### 4.1 Echtzeitdatenströme, Kenngrößen und Regeln

Moderne vollautomatisierte innerbetriebliche Transportsysteme bieten die Möglichkeit, sehr große Mengen an Ereignisdaten aufzuzeichnen. Im Allgemeinen, geben diese Ereignisdaten Auskunft darüber, welches Transportgut zu welcher Zeit sich in welchem Transportabschnitt befunden hat. Mit Hilfe dieser Ereignisdaten lässt sich daher der Weg eines Fördergutes von der Quelle über Transportbänder zu Maschinen bis zur Senke nachvollziehen. Von besonderem Interesse sind Ereignisdaten die, beispielsweise mit Lichtschranken und Barcode-Lesern, an Wegentscheidungspunkten erhoben werden, weil damit Wegspezifische Auswertungen gemacht werden können, um beispielsweise Schwachstellen aufzuspüren.

Falls solche Ereignisdaten aufgezeichnet und genutzt werden, lassen sich verschiedene Leistungskenngrößen bezüglich benutzter Transportwege (Pfade), Transportobjekte (Fördergüter) oder einzelner Transportelemente (Stationen, Kanten) berechnen. Als stellvertretende Beispiele sind die *Nutzungs-Dauer*  $ND(fg, px)$  eines Fördergutes  $fg$  für einen Pfad  $px$ , die *Zwischenankunftszeit*  $ZAZ(fg, i)$  eines Fördergutes  $fg$  an einer Kante  $i$  oder der *Fördergutähler*  $fgZI(i)$  an einer Kante  $i$  zu nennen<sup>6</sup>. Basierend auf der Analyse des zeitlichen Verlaufes solcher Kenngrößen können Rückschlüsse auf die Leistungsfähigkeit des Transportsystems insgesamt sowie auf einzelne Schwachstellen oder Stauschwerpunkte gezogen werden.

Im Rahmen dieses Forschungsprojekt liegt der Fokus auf komplexe Materialflusssysteme wie beispielsweise Sorter, Bagage Handling Systems (BGH) oder automatische Belieferung von Kommissionierstationen aus bspw. einem Hochregallager. Für diese logistischen Systeme ist die Transportzeit stets ein wesentlicher Bewertungsfaktor. Da diese keine Wertschöpfung erzeugt, sind die Betreiber in der Regel bestrebt, sie zu minimieren. Ausgenommen hiervon sind Fertigungsprozesse, bei denen Ziele wie die möglichst hohe Materialverfügbarkeit an belieferten Maschinen mit hohen Investitionskosten eine höhere Priorität einnehmen. Allen Use Cases ist gemeinsam, dass Ereignisdaten bereitstehen, mit Informationen darüber welches Fördergut zu welcher Zeit an welchem Transportabschnitt beobachtet wurde. Diese Beobachtungen können in Logdateien oder als Echtzeit-Datenströme vorliegen. Für die in diesem Projekt angestellten Untersuchungen wurden teilweise die in Logdateien vorliegenden historischen Ereignisdaten als Echtzeitereignisströme interpretiert. Für jeden Use Case werden Besonderheiten der Anlage im Folgenden kurz erläutert.

#### 4.1.1 Use Cases

Für die beschriebenen Use-Cases erfolgte die Simulation der Modelle jeweils in Realzeit damit eine dem Real-Fall analoge Datenrate für den Online-Fall getestet werden konnte. Die analytische Unterteilung von Datenströmen anhand allgemeiner Regeln ist möglich (vgl. Kapitel 4.1.3.1). Mittels zusätzlichen Metainformationen zu relevanten Bereichen lässt sich jedoch bei der Interpretation ggf. die Ergebnissicherheit erhöhen. Beispielsweise können Informationen über Schichtsysteme, Flugpläne oder Anlieferzeiten usw. und damit verbundene Lastwechsel genutzt werden um Datenströme gezielt zu strukturieren und damit die Berechnungen vor allem von statistischen Größen zu steuern.

---

<sup>6</sup> vgl. Forschungsbericht WUSTMANN et al. (2010)

### Use Case I – Beispiel- und Testmodell

Für die ersten Untersuchungen wurde ein Beispielmodell mit folgenden Merkmalen generiert:

- Es ist ein Transportsystem für Stückgut auf Bandförderern mit mehreren Bearbeitungsstationen.
- Die Ereignisse liegen bei Eintritt in Bearbeitungsstation und Austritt aus Bearbeitungsstation, sowie an dem Übergang zu neuen Förderelementen vor.
- Im Knoten-Kanten-Modell der Ereignisspuren sind demnach 145 Knoten, 149 Kanten enthalten.
- Im Schnitt entstehen 2 Ereignisse pro Sekunde (abhängig von den aktuellen Lastsituationen im System).
- Es wurden 3 Szenarien anhand dieses Use-Cases generiert:
  - Szenario 1: mit sehr geringer Last
  - Szenario 2: mit ausgeglichenen Lastverhältnissen
  - Szenario 3: mit starker Überlast.

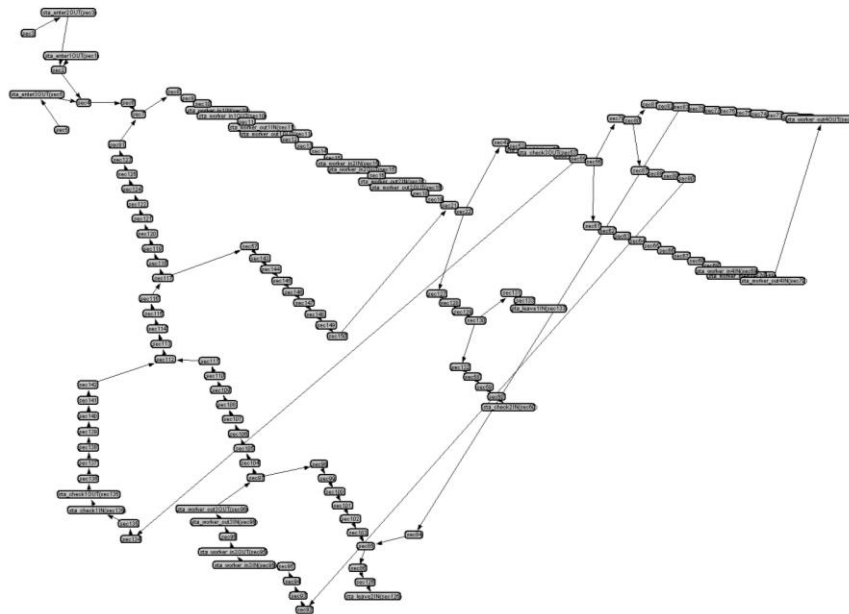


Abbildung 4: KNM des Beispielsystems – Anordnungsalgorithmus Ballon Tree (MELANÇON & HERMAN 1998)

### Use Case II – Flughafen Wien

Die weiterführenden Untersuchungen wurden anhand von Daten aus dem Simulationsmodell des Flughafen Wiens durchgeführt. Dieses Modell wurde zum einen mit dem Flugplan belastet für welchen die Anlage ausgelegt worden war (sog. Originaler-Datensatz) und zum anderen mit einem zufällig manipulierten Flugplan (sog. Test-Datensatz). Folgende weitere Merkmale beschreiben diesen Versuchsaufbau:

- Abstrakt betrachtet ist die Anlage ein riesiger Sorter welcher die Check-In's und Gates sowie Frühgepäckspeicher und Röntgenstationen mit einander verbindet.
- Ereignisse liegen an Entscheidungspunkten sowie an Prüfstationen auf dem Weg vor.
- Das Knoten-Kanten-Modell der Ereignisspuren enthält 769 Knoten und 843 Kanten.
- Im Schnitt entstehen 181 Ereignisse pro Sekunde (für eine analoge Datenrate wurde die Simulationsgeschwindigkeit = Realzeit gesetzt).




Abbildung 5: KNM zum "Flughafen Wien" – Anordnungsalgorithmus Ballon Tree, vgl. MELANÇON & HERMAN 1998)

### Use Case III – Diagnose transportbedingter Verschmutzungen in der Halbleiterfertigung

Halbleiterfabriken beinhalten hochgradig komplexe automatisierte Transportsysteme. Über diese werden die Wafer in offenen oder geschlossenen Behältern von einer Maschine zur nächsten bewegt. Dabei können auch transportbedingte Schäden auftreten, wie die Verunreinigung der Wafer mit Partikeln eines lokal entweichenden Gases. Diese Schäden können nicht immer zeitnah, sondern erst nach vielen Transportvorgängen, erkannt werden so dass als Ursache viele Segmente des Transportsystems in Frage kommen. Da die Halbleiterfertigung ein sehr teurer Prozess ist, muss die Ursache der Verschmutzung möglichst schnell anhand weniger Proben erkannt werden. In dem bearbeiteten Szenario wurden von einem Industriepartner binäre Qualitätsdaten (Wafer ist verschmutzt oder nicht) in Form von Excel-Tabellen sowie zugehörige Transportdaten aus der aktuellen Produktion geliefert welche die befahrenen Segmente pro Wafer auflisten.

Das Modell der Anlage wurde nach Angaben des Industriepartners in *WorkCenter* (entspricht einer logischen Zusammenfassung von Maschinen, Materialversorgung und dem dazugehörigen Transportsystemabschnitt) und entsprechende Unterabschnitte wie *WetChemistryCenter* und *WaferInspectionCenter* erweitert.

### 4.1.2 Erweiterte und Differenzierte Kenngrößen

Im Gegensatz zu der bisherigen Annahme wurde im Laufe der Projektbearbeitung festgestellt, dass die Kantenbelastung  $avg(ND(i))$  nicht unabhängig vom Folgeknoten erfolgen kann, sondern dass der Folgeknoten einen Einfluss auf das Berechnungsergebnis hat. Das vom Projektteam zu Demonstrationszwecken entwickelte Analyse-Werkzeug aus dem Vorgängerprojekt Materialflussdiagnose (MFD) wurde entsprechend erweitert.

Der Grund ist in der Abbildung des im Demonstrator-Werkzeug zu Grunde gelegten State-Transition-Modells auf das in der Logistik übliche Netzwerk- bzw. Knoten-Kantenmodell zu finden. Während Knoten im Netzwerkmodell der Logistik Wegpunkte darstellen, an denen die Fördergüter alternative Kanten beschreiten können, stellen States im Software-Werkzeug die Förderbandabschnitte auf denen Fördergüter sind in Bewegung befinden dar. D.h. logistischen im Netzwerk-Modell vergeht keine Zeit wenn Fördergüter die Knoten (Knoten des Graphen) passieren sondern die Zeit vergeht auf den Kanten (Kanten des Graphen). Im State-Transition-Modell hingegen vergeht die Zeit in den States (Knoten des Graphen) bis ein Fördergut irgendeines mehrerer alternativer Folgeförderbänder erreicht und die Transitionen (Kanten des Graphen) sind zeitlos.

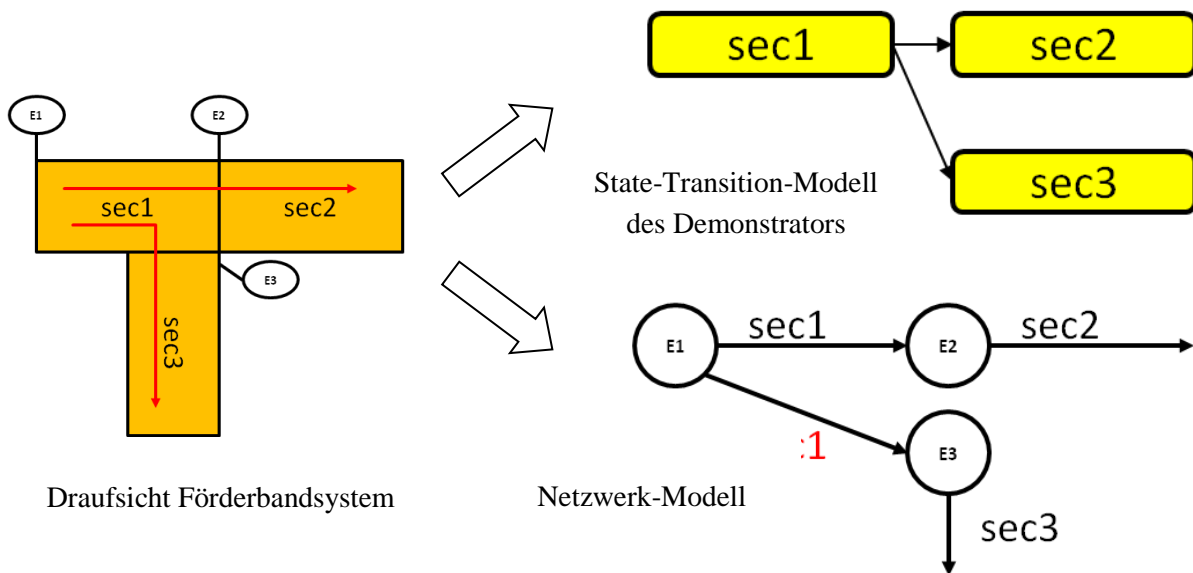


Abbildung 6: Unterschied zwischen State-Transition-Modell und Netzwerkmodell

Die Konsequenz ist, dass im Demonstrator beispielsweise die Durchschnittsberechnung aller Haltezeiten eines States nicht mehr für alle passierten Fördergüter erfolgt, sondern, dass solche Aggregate nun spezifisch für jeden alternativ folgenden State berechnet werden kann. Ein solches spezifisches Aggregat eines State entspricht nun genau dem Aggregat der Daten einer Kante im Netzwerkmodell. Auftretende Fehlinterpretationen der State-Aggregate werden damit erfolgreich vermieden.

### 4.1.3 Erweiterung der Analyse- und Diagnosemethoden

Bei der Analyse von Anomalien wird häufig zwischen Fehlererkennung und Ursachendiagnose unterschieden. Im Rahmen dieses Forschungsprojektes wurden zwei Verfahren entwickelt, welche beide Aufgaben verknüpfen sowie Methoden untersucht, welche auf eine bekannte Fehlerwirkung aufsetzen und diesen Ursachen zuordnen (siehe 4.3).

Auf Basis des in ein Knoten-Kanten-Modell überführtes state-transition-model wurden im Wesentlichen die folgenden weiterführenden Online-(Analyse-)Methoden entwickelt. Diese Methoden dienen gemäß dem Projektziel der Identifizierung relevanter Störungen oder Leistungspotentiale auf Teilstrecken innerhalb des Materialflusssysteme. Globale Anforderungen an das System sind demnach erfüllt, es soll jedoch die Frage beantwortet werden „Wie gut bzw. wie schlecht funktioniert das System und welche Teilstrecken können ggf. noch durch die Beseitigung lokaler Schwachstellen oder die gezielte Nutzung lokaler Leistungsreserven optimiert werden?“.

#### **4.1.3.1 SPC-Methode für Data-Clustering und Anomalie-Identifizierung**

Eine wesentliche Herausforderung des Projektes bestand in der Entwicklung einer Methode zum Clustern des Datenstromes im Online-Fall. Insbesondere für statistische Berechnungen sind unter bestimmten Voraussetzungen vergangene Ereignisse zu verwerfen, da diese keinen realen Einfluss auf das tatsächliche systeminterne Verhalten der Anlage zum Betrachtungszeitpunkt mehr besitzen. Wichtige Voraussetzung für die Online-Anwendung der Kenngrößen und Algorithmen ist demnach das Data-Clustering. Die dynamische Definition relevanter Zeitbereiche anhand von signifikanten Systemzuständen ist dabei ein wesentlicher Bestandteil. Zusätzlich gehört der, ebenso im Offline-Fall zu berücksichtigende statistische Einfluss (vgl. HERZ et al. 1992).

Die Methode zur Bildung von Zeitbereichen soll einerseits eine valide prozessbegleitende Analyse gewährleisten sowie andererseits eine Aussage über die Dauer der Relevanz der dabei entstehenden Kenngrößen liefern. Der Optimalfall ist ein Lösungsweg, der beide Zielstellungen vereint. Online-Analyse bedeutet die Betrachtung einer stetig wachsenden Menge von Ereignisdaten. Ein Antwortzeitverhalten in Echtzeit setzt voraus, dass zu jedem Zeitpunkt Aussagen über den aktuellen Systemzustand getroffen werden können. Dieser Systemzustand kann sich mit fortschreitender Zeit durch äußere Umstände grundlegend ändern.

Zunächst wurden daher mögliche Systemzustände und deren Auswirkungen auf prozessbeschreibende Kenngrößen untersucht. Relevante Zustandsänderungen, welche gegebenenfalls Einfluss auf die prozessbeschreibenden Primärkenngrößen (bspw. Nutzungsdauer von Kanten im KKM) und somit auf die Bildung von Zeitbereichen haben, lassen sich aus den Grundvoraussetzungen an Materialflusssysteme von GÜNTNER/ HEINECKER/ WILKE (2002) ableiten. Diese Anforderungen decken sich mit den Erläuterungen von WILKE (2008, S. 1), wonach folgende Kriterien sich definieren lassen anhand derer unterschiedliche wesentliche Systemänderungen abgeleitet werden könnten:

- Produktart
- Durchsatz
- Fördergeschwindigkeit

Es wurden weiterhin mögliche Systemzustände und deren Auswirkungen auf prozessbeschreibende Kenngrößen untersucht. Jede signifikante Änderung im Systemzustand führt zu einer Änderung mindestens einer prozessbeschreibenden Primärkenngröße (Ausnahme: statistischer Einfluss). Im Umkehrschluss spiegeln daher die Prozesskenngrößen, speziell deren Verlauf, Zustandsänderungen wider. Für das Data-Clustering sind Zustandsänderungen, welche keiner internen Ursache unterliegen, ein geeigneter Anhaltspunkt. Tabelle 1 zeigt mögliche Zustände sowie deren Einfluss auf Kenngrößenverläufe. Je nach Art der Zustandsänderung wirkt sich diese auf die Prozesskenngrößen aus.



Tabelle 1: Einfluss signifikanter Systemzustände auf Kenngrößenverläufe<sup>7</sup>

Systemzustände	ND	ZiS	ZAZ	KL
Leerlauf (Fördergutstrom reißt ab)	→	→	↑	↓
Stillstand (keine neuen Ereignisse)	↑	↑	↑	→
Lastwechsel	→	→	↑↓	↑↓
Fördergutwechsel	→	→	↑↓	↑↓
Geschwindigkeitswechsel	↑↓	↑↓	→ / ↑↓	→

Mit wechselnden Lastphasen (zyklische Änderung des Transportaufkommens) ändern sich bspw. die Kenngrößen bzw. deren statistische Werte zur Zwischenankunftszeit (ZAZ) sowie zur Kantenlast (KL). Der Fördergutwechsel ist an dieser Stelle als Spezialfall des Lastwechsels zu betrachten. Ändert sich die Ausdehnung der Fördergüter in Förderrichtung signifikant, sind die Auswirkungen auf die Kenngrößen analog dem Lastwechsel. Der Wechsel zwischen Systemzuständen verläuft stets kontinuierlich, wodurch jedem neuen Zustand eine Übergangsphase vorangeht.

Die Identifizierung der Zeitbereiche auf Basis des Leerlaufes und Stillstandes ist durch einfache Regeln möglich (Bsp. Leerlauf:  $KL \rightarrow 0$  für  $t \rightarrow n$  mit  $n > \max(ND)$ ). Für das Data-Clustering anhand des Last- bzw. Geschwindigkeitswechsels gilt dies jedoch nicht. Zusätzlich ist sicherzustellen, dass tatsächlich eine Verhaltensänderung und keine temporäre Prozessabweichung, bspw. in Form eines Staus, vorliegt.

Die Abbildung 7 zeigt detailliert den gesamten Methodenbaustein zum Data-Clustering bzw. der Zeitbereichsbildung. Treten keine Zustandsänderungen auf, kann ein Zeitbereich enormer Größe entstehen. Prozessabweichungen sind dann durch prozessbegleitende statistische Kenngrößen schlecht oder nicht zu identifizieren. Daher wird mittels des Prinzips des statischen Einfluss (vgl. HERZ et al. 1993) nach einer spezifischen Anzahl von Ereignissen ein neuer Zeitbereich gebildet.

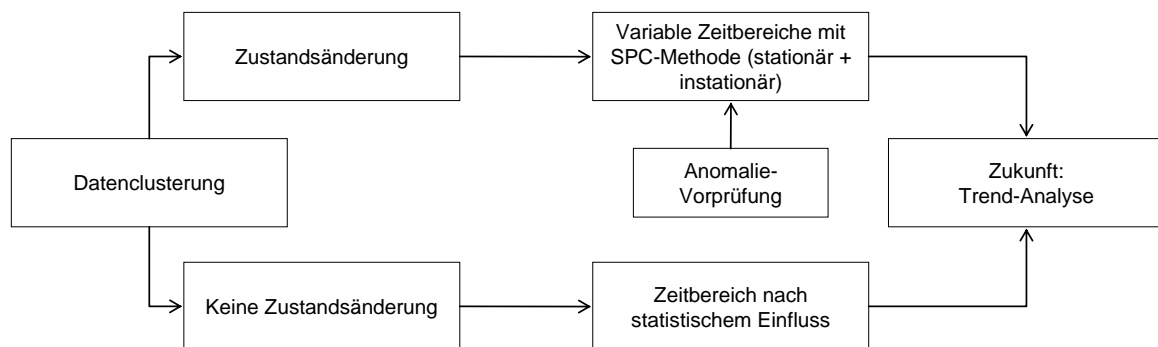


Abbildung 7: Übersicht Zeitbereichsbildung

Da allgemein für die Echtzeitanalyse von Ereignisdaten keine Ansätze bekannt sind, werden die Betrachtungen auf einen verwandten Sachverhalt in der Simulation gerichtet. Üblicherweise ist in einer Simulationsstudie die Zustandsverteilung während der stationären Phase von Interesse. „Ein stochastischer Prozess  $X_t$  wird als stationär bezeichnet, wenn die Wahrscheinlichkeit von  $X_t$  nicht von  $t$  abhängig ist.“ (PAGE/ LIEBERT 1991) Befindet sich das System in einem instationären Zustand (Bsp. Anlaufphase),

<sup>7</sup> Kenngrößen siehe Übersicht unter 9. Symbole, Objekte und Kenngrößen

tritt ein systematischer Initialisierungsfehler auf. Erst die Eliminierung dieses Fehlers aus den Berechnungen garantiert korrekte Schätzer für das Modellverhalten.

Ähnlich verhält es sich bei der Übergangsphase in Folge von Zustandsänderungen. Statistische Prozesskenngrößen sollten lediglich für den Zustand repräsentative Einzelwerte enthalten. Daher wurden Ansätze aus der Simulationstheorie zur Bestimmung des Endpunktes der Warmlaufphase untersucht. Die Tabelle 2 fasst die wesentlichen Untersuchungsergebnisse je Bewertungskategorie für 7 mögliche Methoden und ihren Erfüllungsgrad zusammen.

Tabelle 2: Auswertung von möglichen Verfahren zur Zeitbereichsdefinition:

Verfahren	Genauigkeit	Automatisierungspotential	Allgemeingültigkeit	Grundannahmen
Welch (MAHAJAN/INGALLS 2004)				
Crossing-of-the-Mean (MAHAJAN/INGALLS 2004)				
Conway (MAHAJAN/INGALLS 2004)				
SPC (Robinson 2002 & 2007)				
Yücesan (MAHAJAN/INGALLS 2004)				
Schruben (Schruben 1982; Schruben et al. 1983)				
MSER-5 (MAHAJAN/INGALLS 2004)				

Die SPC-Methode (Statistical Process Control) erwies sich hierbei als besonders geeignet, um sowohl Übergangsphasen in Folge von Zustandsänderungen als auch die Zustandsänderung selbst anhand von Ereignisdaten zu identifizieren. Die ursprünglich aus der Qualitätssicherung stammende Statistische Prozesskontrolle zeigt, ob ein Prozess *unter Kontrolle* verläuft oder eine *Außerkontrollsituation* vorliegt. Die Gleichstellung von Außerkontrollsituationen mit Zustands- bzw. Verhaltensänderungen ermöglicht eine adäquate Verwendung der SPC-Methode. Wie bereits an dieser Stelle die Begriffe andeuten, kann diese Analogie nicht nur für die Ermittlung relevanter Zeitbereiche zum Data-Clustering Verwendung finden, sondern mit einigen Modifikationen der Sigma-Grenzen-Interpretation<sup>8</sup> ebenfalls auch zur Anomalie-Identifikation genutzt werden. Die *Außerkontrollsituationen* können bei der Übertragung auf Materialflusssysteme suboptimales Systemverhalten im zugehörigen Abschnitt aufzeigen. Entsprechend kann die SPC zum Identifizieren von Anomalien auf Teilstrecken genutzt werden.

Die Anwendung der SPC-Methode auf das Teilproblem des Data-Clustering, erfolgt in 2 Schritten: Die Ermittlung der Zustandsänderung selbst (Beginn der instationären Phase) sowie das Bestimmen der Länge der Übergangsphase (Ende der instationären Phase). Die SPC-Methode wird stets anhand der in Tabelle 1 aufgeführten Prozesskenngröße durchgeführt. Sollten Ereignisattribute über die in diesem Forschungsprojekt

<sup>8</sup> Die Interpretation der Lage einzelner Datenpunkte zu den sog. Sigma-Grenzen ist der letzte Schritt der SPC-Methode und folgt gestaltbaren Regeln, dies wird im weiteren Verlauf des Kapitels noch näher erörtert.

betrachteten Standard-Attribute hinaus weitere Prozesskenngößen liefern ist zu prüfen ob diese voneinander unabhängig sind. So ist bspw. die Reduzierung der Kenngrößen aus den Standard-Attributen auf die Nutzungsdauer (*ND*), Kantenlast (*KL*) und Zwischenankunftszeit (*ZAZ*) in der Regel ausreichend, da die ZeitemSystem (*ZiS*) mit *ND* sowie der Fördergutzähler (*FgZ*) mit *ZAZ* korrelieren.

Die grundlegende Vorgehensweise gestaltet sich für die Ermittlung der stationären und instationären Phase beim Data-Clustering sowie für die Anomalie-Identifikation nahezu identisch. Daher soll an dieser Stelle die grundlegende Beschreibung der adaptierten SPC-Methode für dieses Forschungsvorhaben erfolgen. Auf explizite Unterschiede wird dabei an entsprechender Stelle hingewiesen.

Zunächst sind die einzelnen Ereignisdaten  $Y_i$  in einem Vektor  $Y$  zusammenzufassen, welcher eine Zeitreihe mit  $m$  Beobachtungen und  $Y_i$  als  $i$ -te Beobachtung beschreibt.

$$Y = (Y_1; Y_2; \dots; Y_m) \quad \text{mit } i = 1, \dots, m$$

Zur Anwendung der SPC müssen die zugrunde liegenden Daten die Eigenschaft der Unabhängigkeit und der Normalverteilung aufweisen. Da die Ereignisdaten eines Materialflusssystem typischerweise korreliert sind, ist eine Transformation in quasi-unkorrelierte Daten nötig. Hierfür wird die Methode der Batchmittelwerte genutzt (BANKS et al. 2009, S. 450).

Dazu wird die Datenreihe zuerst in Abschnitte einer definierten Länge, den Batches  $h \in H$  zerlegt. Ziel ist es eine Zeitreihe von Batchmittelwerten  $\mu_h$  zu erzeugen, welche den obigen Anforderungen entspricht. Mit steigender Abschnittslänge, beschrieben durch die Batchgröße  $k$ , nimmt für den stationären Teil sowohl die Korrelation, aber auch die Informationsgenauigkeit ab (KLEIJNEN 1974, S. 459). Der Startwert der Batchgröße ist  $k = 1$ , wobei mindestens 20 Batches existieren sollen  $|H| \geq 20$ . Die resultierende Zeitreihe von Batchmittelwerten  $\mu_h$  der Anzahl  $b = |H|$  aus den vorhandenen Batches  $h$  der Größe  $k$  wird damit aus dem Vektor der Ereignisdaten mit  $m$  Einzelereignissen  $Y_i$  erzeugt.

$$Y = (Y_1; Y_2; \dots; Y_m) \rightarrow \bar{Y}_h = \frac{\sum_{i=(h-1)k+1}^{hk} Y_i}{k} \rightarrow \bar{Y} = (\bar{Y}_1; \bar{Y}_2; \dots; \bar{Y}_b)$$

$$\text{mit } h = 1; 2; \dots; \left\lceil \frac{m}{k} \right\rceil$$

Die Schwierigkeit dieses Ansatzes stellt die Wahl der richtigen Batchgröße  $k$  dar, damit die Zeitreihe der Batchmittelwerte den Anforderungen (unkorreliert und normalverteilt) entspricht. An dieser Stelle ist auf den wesentlichen Unterschied bei der Anwendung der SPC-Methode auf die Einsatzfälle des Data-Clustering und der Anomalie-Identifikation hinzuweisen. Für das Data-Clustering und dabei im Besonderen für die Ermittlung des *Endes* der instationären Phase auf Basis von wesentlichen Systemzustandsänderungen wird nur die 2. Hälfte der Reihe von  $\mu_h$  auf Korrelation und Normalverteilung geprüft, da diese repräsentativere Schätzer für die stationäre Phase liefert. Für die Ermittlung des *Beginns* der instationären Phase<sup>9</sup> sowie der Anomalie-Identifikation innerhalb eines gebildeten Daten-Clusters wird die gesamte Reihe der  $\mu_h$  auf die beiden genannten Anforderungen geprüft, da innerhalb dieses Clusters von einem stationären Prozess ausgegangen werden kann.

---

<sup>9</sup> ... also des Endes der stationären Phase durch eine wesentliche Zustandsänderung aufgrund äußerer Systemeinflüsse.

Eine Methode zur Untersuchung der Korrelation der Batchmittelwerte  $\mu_h$  ist der *von Neumann Test*. Alternativ hierzu kann die Lag-1 Autokorrelation  $r_1$  bestimmt werden (ROBINSON 2002, S. 441). Dabei wird zunächst die Zeitreihe gegenüber sich selbst um eine Beobachtung verschoben.

$$\bar{Y}^* = (\bar{Y}_2; \bar{Y}_3; \dots; \bar{Y}_b)$$

Anschließend wird der Schätzer des empirischen Autokorrelationskoeffizienten ( $\hat{r}_{Lag-1}$ ) der beiden Datenreihen bestimmt.

$$\hat{r}_{Lag-1} = \frac{Cov(\bar{Y}, \bar{Y}^*)}{\sqrt{Var(\bar{Y})} \sqrt{Var(\bar{Y}^*)}}$$

Unter der Annahme eines stationären Prozesses, bei welchem die Beobachtungen zum Zeitpunkt  $t$  auch in  $t + 1$  hätten beobachtet werden können und einer hinreichend großen Beobachtungsanzahl ist eine Vereinfachung der Berechnung mit folgender Vorschrift möglich:

$$\frac{1}{b} \sum_{h=1}^b \bar{Y}_h = \frac{1}{b-1} \sum_{h=2}^b \bar{Y}_h^* = \hat{\mu}$$

$$Var(\bar{Y}) = Var(\bar{Y}^*) = \frac{1}{b} \sum_{h=1}^b (\bar{Y}_h - \hat{\mu})^2$$

$$Cov(\bar{Y}, \bar{Y}^*) = \frac{1}{b} \sum_{h=1}^{b-1} (\bar{Y}_h - \hat{\mu}) (\bar{Y}_{h+1} - \hat{\mu})$$

Damit kann der Wert der Lag-1 Autokorrelation bestimmt werden.

$$\hat{r}_{Lag-1} = \frac{\sum_{h=1}^{b-1} \left( \bar{Y}_h - \frac{1}{b} \sum_{h=1}^b \bar{Y}_h \right) \left( \bar{Y}_{h+1} - \frac{1}{b} \sum_{h=1}^b \bar{Y}_h \right)}{\sum_{h=1}^b \left( \bar{Y}_h - \frac{1}{b} \sum_{h=1}^b \bar{Y}_h \right)^2}$$

Dabei ist es als Näherung hinreichend genau, wenn der Wert der Lag-1 Autokorrelation ( $|\hat{r}_{Lag-1}| > 0,1$ ) ist, um die Anforderung nach einer unkorrelierten Beobachtungsreihe zu erfüllen (ROBINSON 2002, S. 441).

Die Batchgröße  $k$  wird so lange erhöht, bis dies erreicht ist. Aus statistischer Sicht ist das Erfüllen der Lag-1 Autokorrelation nicht ausreichend, um eine Unabhängigkeit der Daten vollkommen auszuschließen, da auch Korrelationen höheren Grades existieren können. Zur Anwendung der SPC-Methode genügt jedoch diese Annahme.

Zusätzlich muss die Batchgröße  $k$  so gewählt sein, dass die Verteilung der Batchmittelwerte  $\mu_h$  einer Normalverteilung ( $F_0 \sim N$ ) entspricht. Testmethoden dafür sind beispielsweise der *Kolmogorov-Smirnov Test* (JAMES et al. 2006, S. 269-271) oder der *Anderson-Darling Test* (ANDERSON/ DARLING 1954, S. 765ff).

Eine weitere Methode ist der hier genutzte *Chiquadrat-Anpassungstest*. Dabei werden die Batchmittelwerte  $\mu_h$  als Erstes in Klassen ( $A_1; \dots; A_j$ ) eingeteilt. Zur Ermittlung der Klassenanzahl  $J$  existieren in Abhängigkeit der Anzahl von Batchmittelwerten  $b$  verschiedene Empfehlungen (u.a. FAES 2009; BAMBERG et al. 2008).

$$J = \sqrt{b}; \quad J = 5 * \lg(b); \quad J = 1 + 3,32 * \lg(b)$$

Durch die differierende Klassenanzahl ergeben sich je nach Umsetzung rechentechnische Unterschiede im Umfang nötiger Rechenoperationen und damit verschiedene Laufzeiten. Auswirkungen auf die Testergebnisse konnte jedoch bei den Use-Case' nicht festgestellt werden.

Zusätzlich zur Klassenanzahl sind die absoluten Häufigkeiten der Beobachtungen,

$$N_j = \text{Anzahl der } \mu_h \in A_j \text{ mit } \sum_{j=1}^J N_j = b$$

sowie die theoretischen Wahrscheinlichkeiten dafür, dass eine Beobachtung bei Vorliegen einer Normalverteilung Element der jeweiligen Klasse ist,

$$\pi_j = P(\mu_h \in A_j \parallel F_0)$$

zu berechnen. Anschließend wird geprüft, ob die beobachteten Häufigkeiten den theoretisch zu erwartenden Häufigkeiten entsprechen. Die Prüfgröße hierzu ist  $T$ .

$$T = \sum_{j=1}^J \frac{(N_j - b\pi_j)^2}{n\pi_j}$$

Der für einen Hypothesentest nötige kritische Bereich ist  $K$ .

$$K = ] \chi^2_{J-1, 1-\alpha}, \infty [$$

Dabei wird das Signifikanzniveau  $\alpha$  gewöhnlich mit 5 % angenommen (MOSLER/ SCHMID 2008). Analog zu dem Test auf Korrelation ist auch hier bei Ablehnen der Hypothese die Batchgröße  $k$  so lange zu erhöhen, bis die Hypothese angenommen werden kann.

Nachdem die Batchgröße  $k$  so gewählt ist, dass die Ereignisse der Beobachtungsreihe  $\bar{Y}$  bzw. beim Data-Clustering die 2. Hälfte der Beobachtungsreihe  $\bar{Y}$  unkorreliert und normalverteilt sind, können die drei Paare von Kontrollgrenzen  $\sigma_z$  als unteres bzw. oberes Limit berechnet werden. Hierzu werden der Mittelwert  $\hat{\mu}$  und die Standardabweichung  $\hat{\rho}$  aller Batchmittelwerte  $\mu_h$  als Schätzer für die Sigma-Kontrollgrenzen  $\sigma_z$  herangezogen.

$$\sigma_z = \hat{\mu} \pm \frac{z\hat{\rho}}{\sqrt{\frac{b}{2}}} \text{ mit } z = 1; 2; 3$$

Der zweite Formelterm stellt eine Funktion von  $z$  dar, welche  $z$ -sigmaUP bzw.  $z$ -sigmaLOW, für die obere bzw. untere Sigma-Kontrollgrenze berechnet. Auf Basis definierter Vorgaben über das Verhalten relativ zu den Kontrollgrenzen können Außerkontrollsituationen gefunden werden. Diese Grundlage der Vorgaben lieferten die Regeln welche ursprünglich für den Bereich des Qualitätsmanagements entwickelt wurden (WESTERN ELECTRIC COMPANY 1956 gefunden in MONTGOMERY 2005).

Bei der Analyse Teiltransportprozessen eines Materialflusssystem, also zur Identifikation systeminterner Abweichungen vom statistischen Normalfall der Transportzeiten zwischen zwei Ereignisorten oder beliebig festgelegten Streckenabschnitten, können die Kontrollgrenzen zur Bewertung von Abweichungen vom berechneten Normalverhalten genutzt werden. Entscheidend dabei sind die Regeln zum Erkennen der außer

Kontroll-Situationen innerhalb eines Daten-Clusters, um Anomalie-Ereignisse zu identifizieren. Analog dazu sind Regeln zum Data-Clustering entworfen worden, um somit eine Online-Analyse zu ermöglichen. Regeln für die Anomalie-Identifikation können wie folgt definiert werden und haben sich in den Use-Case bewährt:

1. Weiterführende Betrachtungen mit Netzwerkbewertung (vgl. Wustmann et al. 2010) aller Abweichungen außerhalb der 3-Sigma Kontrollgrenzen ( $\sigma_3$ ).
2. Analyse der Abweichungen zwischen den 2- und 3-Sigma Kontrollgrenzen wenn 2 von 3 aufeinanderfolgende Batchmittelwerte  $\mu_h$  in diesem Bereich liegen.
3. 4 von 6 aufeinanderfolgenden Punkten liegen außerhalb einer 1sigma-Kontrollgrenze
4. 8 oder mehr aufeinanderfolgende Batchmittelwerte  $\mu_h$  liegen auf einer Seite des Normalwertes ( $\hat{\mu}$ ).

Sollten mehrere Regeln zutreffen empfiehlt sich die primäre Betrachtung der größten Abweichungen (in Abbildung 8 mit Pfeilen markiert) auf für das Netzwerk besonders relevanten Kanten. Die Netzwerkbewertung aus dem Vorgängerprojekt wird an dieser Stelle angewendet (WUSTMANN et al. 2010). Hierbei werden Kenngrößen aus der Theorie komplexer Netzwerke wie bspw. Kantenzentralität<sup>10</sup>  $K_{zent}(i)$  und Knotengrade<sup>11</sup>  $G(i)$  sowie die neue Kenngröße des Hansenindex<sup>12</sup>  $Ai(i)$  verwendet. Für das Beispiel der Anomalie-Identifikation im Use-Cae II zeigt die Abbildung 8 einen Auszug der visualisierten Lage der Batchmittelwerte  $\mu_h$  zu den Sigma-Grenzen  $\sigma_z$ . Zuvor wurde für alle Teilstrecken im Netzwerk die Relevanz (bezogen auf die Netzwerkstruktur und Quelle-Senke-Relationen) anhand der beschriebenen Kennwerte ermittelt und anschließend die SPC für die Transportzeit ( $ND(k)$ ) auf die wichtigsten Kanten  $k$  (es waren mehrere nahezu gleicher Relevanz) angewandt.




Abbildung 8: Auszug einer Ergebnisgrafik der SPC-Anomalie-Identifikation für Use-Case II

<sup>10</sup> Die Kantenzentralität beschreibt wie oft eine Kante Bestandteil kürzester Wege zwischen Quellen und Senken ist. Diese Kenngröße wurde abgeleitet aus der Belastungszentralität nach BRANDES & ERLEBACH 2005.

<sup>11</sup> Einfaches Maß für die Anzahl von Kanten an einem Knoten (Ein- und Ausgänge).

<sup>12</sup> Der Hansenindex beschreibt die Erreichbarkeit jedes Knotens von einem anderen aus über die Attraktivität sowie die reziproke Entfernung (TAYLOR & GLEN 2007, S. 9-30; LASCH & SCHULTE 2009).

Je nach Anwendungsfall variieren diese Regeln. Für das Data-Clustering sind die Regeln toleranter gegenüber Abweichungen zu formulieren, da es Ziel ist eine Verhaltensänderung durch äußere Einflüsse im Gesamtsystem zu erkennen. Für das Data-Clustering, also die Einteilung des Datenstromes und damit der Zeitreihe einer Kenngröße in Zeitbereiche haben sich folgende Regeln als sinnvoll für die betrachteten Beispiele herausgestellt. Alle Regeln sind nach dem Handbuch der WESTERN ELECTRIC COMPANY (1956) entwickelt worden.

1. 2 von 3 aufeinanderfolgenden Punkten liegen außerhalb einer 3sigma-Kontrollgrenze ( $\sigma_3$ ).
2. 4 von 6 aufeinanderfolgenden Punkten liegen außerhalb einer 2sigma-Kontrollgrenze ( $\sigma_2$ ).
3. 6 von 8 aufeinanderfolgenden Punkten liegen außerhalb einer 1sigma-Kontrollgrenze ( $\sigma_1$ ).
4. 10 aufeinanderfolgende Punkte liegen auf einer Seite von  $\hat{\mu}$ .

Am Beispiel des Data-Clustering ist in Abbildung 9 der Ablauf der adaptierten SPC-Methode für die Ermittlung des Endes der instationären Phase schematisch dargestellt. Für die Bestimmung des Beginns der Übergangsphase sowie für die Anomalie-Identifikation innerhalb der definierten Zeitbereiche unterscheidet sich dieses Vorgehen in den Regeln zur Lagebewertung der Batchmittelwerte  $\mu_h$  gegenüber dem statischen Normalverhalten  $\hat{\mu}$  sowie in der zugrunde gelegten Reihe der Batchmittelwerte  $\mu_h$  für die Prüfung auf Autokorrelation, den Chiquadrat-Anpassungstest sowie der Berechnung des statistischen Normalfalls  $\hat{\mu}$ .

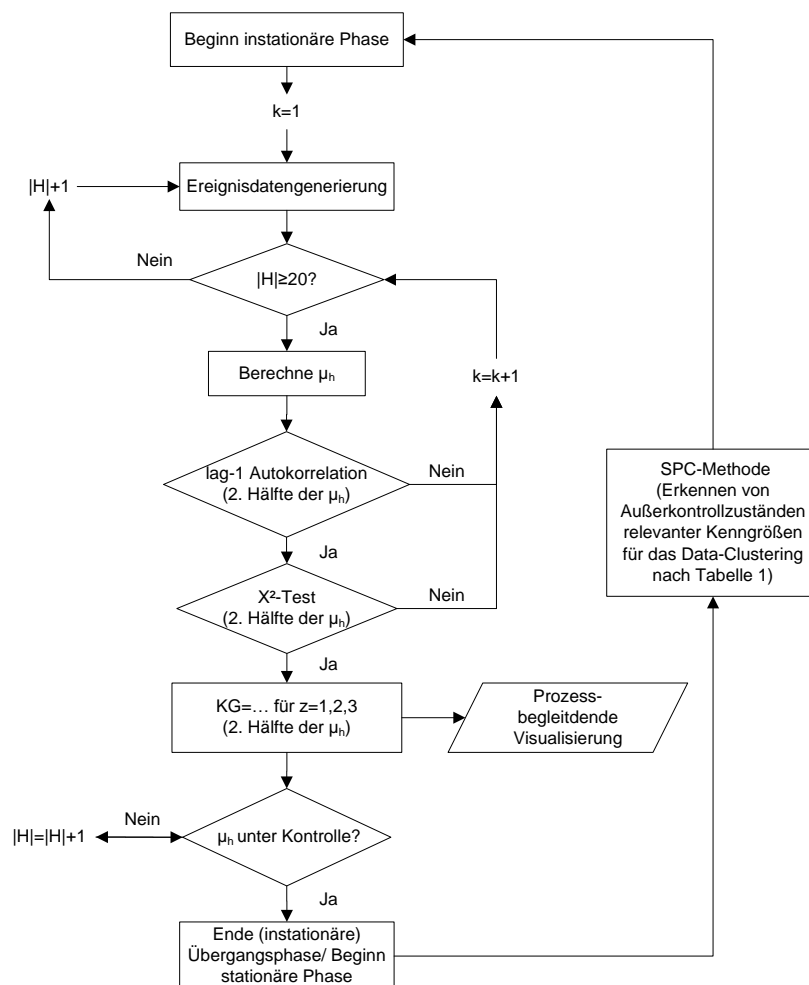


Abbildung 9: SPC-Ablaufdiagramm für die Ermittlung des instationären Datenbereichs

Für den Einsatz der adaptierten SPC-Methode zum Data-Clustering gilt es darüber hinaus den statistischen Einflusses zu beachten. Greift keine der obigen Regeln für das Einteilen eines neuen Zeitbereiches, scheint der Prozess ohne größere Änderungen zu verlaufen. In diesem Fall kann sich ein einzelner Zeitbereich über einen sehr großen Zeitraum ausdehnen. Kleinere Abweichungen<sup>13</sup> gehen dabei in der Masse unter und können durch prozessbegleitende statistische Kenngrößen schlecht oder gar nicht mehr erkannt werden, wodurch die Identifikation suboptimalen Verhaltens erschwert wird. Um dies zu verhindern wird ein Teilschritt der Methode eingeführt, welche einen gleichen<sup>14</sup> Zeitbereich in einzelne Betrachtungszeiträume einteilt. Nach einer bestimmten Anzahl von Ereignissen werden Daten abgeschnitten und ein neuer Zeitbereich gebildet, um die laufenden Berechnungen von statistischen Kenngrößen aussagekräftiger zu gestalten.

Der Zeitbereich des statistischen Einflusses dient nicht in erster Linie einer validen Berechnung und dem Erkennen von Änderungen von Normal- oder Optima, sondern stellt vielmehr eine geeignete Möglichkeit dar, den stetig wachsenden Datenfluss in sinnvolle Untergruppen einzuteilen. Rechengrundlage bildet ein Verfahren aus der Straßenverkehrstechnik und Verkehrsplanung (vgl. Herz et al. 1992, S. 120-121).

Ein neues Cluster wird dann gebildet, wenn der Mittelwert der Grundgesamtheit  $\mu$ , unter Gewährung eines vorher angegebenen relativen Fehlers  $d_r$  mit vorgegebener statistischer Sicherheit  $S$ , mit dem Mittelwert der Stichprobe  $\bar{x}$  übereinstimmt. Der tolerierte relative Fehler ergibt sich wie folgt:

$$d_r = \frac{d}{\mu} \text{ mit } d = \pm(\mu - \bar{x})$$

Mit einer bekannten Grundgesamtheit  $N$  (bekannte Gesamtstückzahl der zu befördernden Fördergüter) errechnet sich der erforderliche Stichprobenumfang  $n$  nach folgender Gleichung:

$$n = \frac{k^2 * V^2 * N}{k^2 * V^2 + (N - 1) * d_r^2}$$

Dabei steht  $k$  für den Genauigkeitsfaktor und  $V$  für den Variationskoeffizienten der Stichprobe. Ist mit einer sehr großen, aber nicht genau bekannten Grundgesamtheit ( $N \rightarrow \infty$ ) wie im Online-Falle zu rechnen, vereinfacht sich obige Gleichung zu folgender Formel:

$$n = \frac{k^2 * V^2}{d_r^2}$$

Der Genauigkeitsfaktor  $k$  kann für verschiedene Ausgangsverteilungen und statistische Sicherheiten  $S$  aus Tabelle abgelesen werden.

*Tabelle 3: Genauigkeitsfaktor bei Normal- und unbekannter Verteilung*

Statistische Sicherheit $S$ in [%]	Genauigkeitsfaktor $k$ bei	
	Normalverteilung	Unbekannter Verteilung
90	1,65	3,16

<sup>13</sup> Unter kleineren Abweichungen sind solche zu verstehen, die nicht ausreichen um mit dem Verfahren aus der statistischen Prozesskontrolle einen neuen Zeitbereich auszulösen.

<sup>14</sup> Systemverhalten ohne größere Änderungen durch äußere Einflüsse



95	1,96	4,47
99	2,58	10,00
99,9	3,29	31,62

Die bestimmten Werte für  $n$  bilden das Ende des Zeitbereichs für den statistischen Einfluss. Nach  $n$  Werten ist der Normalwert demnach hinreichend genau und es müssen keine weiteren Ereignisse zu der Berechnung hinzugezogen werden. Stattdessen beginnt ein neuer Zeitbereich, in dem die Einzelwerte wieder einen größeren Einfluss auf die Berechnung des Normalwertes besitzen. Der Wert  $n$  für das Ende des Zeitbereichs unterscheidet sich zwischen den Kenngrößen in Abhängigkeit ihres Variationskoeffizienten. Ein größerer Variationskoeffizient ergibt einen größeren Wert für  $n$ . Ob nun die Kenngröße mit der größten oder der geringsten Schwankung verwendet wird, ist fallspezifisch zu entscheiden.

#### **4.1.3.2 Ereignisbasierte Erkennung und Diagnose von transienten Staus**

Ein weiterer Schwerpunkt lag auf der Entwicklung eines Verfahrens zur Erkennung, Rückverfolgung und Bewertung von Stauerscheinungen in Materialflusssystemen. Basierend auf dem Zustandsmodell der Anlage und der Kapazität der Komponenten werden zunächst ungewöhnlich lange Haltezeiten von Loads identifiziert, diese anhand der Transitionen der betreffenden States zurückverfolgt und abschließend werden alle erkannten Stauerscheinungen bewertet. Details zu diesem Verfahren können SCHWENKE et al. 2012 entnommen werden.

#### **4.1.3.3 Methode zur Trendanalyse**

Für die Online—Materialflussdiagnose liegt neben der Analyse des jeweiligen Verhaltens und dem Aufspüren von suboptimalen Abweichungen in Prozessparametern auch in der Trenderkennung großes Potential für die betriebsbegleitende Optimierung von bestehenden Anlagen. Nachdem zuvor die Erläuterung der Methoden zur Anomalie-Identifikation, dem Data-Clustering sowie die Diagnose transientser Staus erfolgte, soll nun eine mögliche Methode zur statistischen Trendanalyse in Ereignisdatenströmen vorgestellt werden.

Hierzu wird die Entwicklung von aus den Ereignisdaten berechneten Kenngrößen über die Zeit betrachtet. Im Online-Fall würden durch das beschriebene Data-Clustering für einen einzelnen Zeitbereich keine Abweichungen aufeinanderfolgender Daten vorliegen, die größer sind als durch das Verfahren der statistischen Prozesskontrolle toleriert werden. Es ist jedoch nicht auszuschließen, dass durch kleinere sich fortsetzende Abweichungen ein gewisser Trendverlauf innerhalb der Zeitbereiche existiert. Um die Entwicklung der Kenngrößen von Beginn bis Ende des Zeitbereiches beurteilen zu können, wird daher eine lineare Regression 1. Grades durchgeführt. Nachdem über den Zeitbereich eine Trendgerade gelegt wurde, wird anschließend mit Hilfe der Methode der Trend-Umkehr-Potentiale (TUP) der Datensatz auf die größten Abweichungen innerhalb des Zeitbereiches untersucht. Dies ist einerseits eine Möglichkeit um den Verlauf der Trendgeraden besser interpretieren zu können und um andererseits gegebenenfalls auftretende temporäre negative Entwicklungen innerhalb des Zeitbereiches zu erkennen<sup>15</sup>.

---

<sup>15</sup> Grundsätzlich kann die TUP-Trendanalyse auch für den gesamten Betrachtungszeitraum angewendet werden. Zu beachten ist jedoch für den Online-Fall die quasi unendliche Datenmenge, daher sollten ältere Ergebnisse nach definierten Zeitabschnitten gelöscht werden. Diese Zeitabschnitte sind u.U. sehr fallspezifisch festzulegen, daher wurden im Rahmen des Projektes die ermittelten Zeitbereiche auf Basis des Data-Clustering genutzt.

Erster Schritt der Trend-Analyse ist die stetige Berechnung eines linearen Trends über den gesamten aktuellen Zeitbereich. Dies geschieht mit Hilfe der einfachen linearen Regression. Auf eine ausführliche Erläuterung des Verfahrens wird aufgrund der allgemeinen Bekanntheit an dieser Stelle verzichtet (vgl. FAHRMEIR et al. 2007). Stattdessen wird im Folgenden die Basis der Trend-Analyse, die Methode der Trend-Umkehr-Potentiale, näher erläutert.

WEGSCHEIDER (1993) schlägt ein Verfahren vor, welches der Beschreibung der mit lokalen Trends zusammenhängenden charakteristischen Eigenschaften von Zeitreihen dient. Der Vorteil dieses Verfahren in Bezug auf die im vorliegenden Betrachtungsgegenstand behandelten Ereignisdaten, ist die Möglichkeit der Anwendung auf nicht-äquidistante Daten. Bei diesem Ansatz wird jedem Zeitpunkt  $t$  einer Zeitreihe ein Trend-Umkehr-Potential (TUP)  $p(t)$  zugeordnet. Dabei entsprechen große Absolutwerte gleichzeitig großen Trends. Diese Trendumkehrpunkte stehen an der Stelle in einer Zeitreihe, die das Ende einer Trendrichtung und gleichzeitig den Beginn der entgegengesetzten Trendrichtung beschreibt. Dieses Verfahren ist ein idealer Ansatz, um möglichst schnell grundlegende Trends innerhalb eines Data-Clusters zu erkennen. Das Ergebnis ist ein spezifisches Trendmuster, welches sich für den Vergleich mit der Trendsituation im aktuellen Cluster der Online-Analyse eignet. Mit Hilfe eines geeigneten Toleranzrahmens können somit gegebenenfalls wiederkehrende Verläufe aus gespeicherten Zeitbereichen erkannt und daraus auf zukünftige Entwicklungen der Online-Daten geschlossen werden.

Die Berechnung der TUPs erfolgt iterativ. Punkte der Zeitreihe, die im Hinblick auf eine Trendbeschreibung wenig aussagekräftig sind werden als Erstes gelöscht. Dazu gehören aufeinanderfolgende identische Werte und solche, deren Realisation zwischen ihrem Vorgänger und Nachfolger stehen. Gilt beispielsweise  $x_1 < x_2 < x_3$ , so wird  $x_2$  aus den Betrachtungen gestrichen. Das TUP ist schließlich der vertikale Abstand zwischen den übriggebliebenen Nachbarn. Die Notation zur Bestimmung der TUP lautet nach SCHLITGEN & STREITBERG (2001, S.31-33) wie folgt:

$T \subseteq \{1, 2, \dots, N\}$  ist eine nichtlineare Teilmenge von Zeitpunkten. Der linke Randpunkt  $t_{min}$  von  $T$  sei der kleinste, der rechte Randpunkt  $t_{max}$  der größte Wert von  $T$ . Alle anderen Punkte heißen innere Punkte von  $T$ . Dann steht  $T^<$  für  $T \setminus \{t_{max}\}$ . Für  $t \in T$  mit  $t > t_{min}$  bezeichnet  $t_L$  den linken Nachbarn von  $t$  in  $T$ , formal

$$t_L = \max\{t' : t' \in T, t' < t\}$$

und analog  $t_R$  den rechten Nachbarn von  $t$  in  $T$  für  $t < t_{max}$ .

Sei  $(x_t)_{t \in T}$  mit  $T_0 \subseteq \{1, 2, \dots, N\}$  eine Zeitreihe mit mindestens zwei Werten. Die durch den folgenden Algorithmus (SCHLITGEN & STREITBERG 2001, S.31-33) eindeutig bestimmten Werte  $p(t)$  heißen Trend-Umkehr-Potentiale.

1. Für alle  $t < t_{max}$  mit  $x_{t_R} - x_t = 0$  wird  $p(t) = 0$  gesetzt und  $t$  als gelöscht betrachtet. Sei  $T_1$  die Menge der nicht gelöschten Zeitpunkte.
2. Falls  $T_1$  nur ein Element enthält, wird  $p(t) = 0$  gesetzt und die Iteration abgebrochen. Für alle inneren Punkte  $t$  von  $T_1$  mit  $x_{t_L} < x_t < x_{t_R}$  bzw.  $x_{t_L} > x_t > x_{t_R}$  gilt  $p(t) = 0$  und es wird  $t$  als gelöscht betrachtet. Sei  $T_2$  die Menge der nicht gelöschten Zeitpunkte.
3. Sei  $t'$  der kleinste Zeitpunkt, an dem der minimale Abstand von je zwei aufeinanderfolgenden Beobachtungen in  $T_2$  beginnt:

$$t' = \min\left\{t : t \in T_2^<, |x_{t_R} - x_t| = \min\{|x_{s_R} - x_s| : s \in T_2^<\}\right\}.$$

- a) Falls  $t'$  und  $t'_R$  beides innere Punkte oder beides Randpunkte von  $T_2$  sind, wird ihr Potential definiert durch  $p(t') = |x_{t'_R} - x_{t'}|$ . Wobei anschließend  $t'$  und  $t'_R$  als gelöscht zu betrachten sind.
- b) Für  $t' = t_{min}$  und  $t'_R < t_{max}$  wird  $p(t') = x_{t'_R} - x_{t'}$  gesetzt und  $t'$  als gelöscht betrachtet. Für  $t'_R = t_{max}$  und  $t' > t_{min}$  wird  $p(t_{max}) = x_{t'_R} - x_{t'}$  gesetzt und  $t_{max}$  als gelöscht betrachtet.

Die Menge  $T_3$  stellt die nicht gelöschten Zeitpunkte dar.

4. Setze  $T_2 = T_3$  und gehe, falls  $T_2$  nicht leer ist, zurück zu Schritt 3.

Die mit diesem Algorithmus errechneten größten absoluten Werte für die Trend-Umkehrpotentiale  $p(t)$  weisen für die betrachtete Zeitreihe, bzw. innerhalb des Data-Clusters den stärksten Trend aus. Die Tabelle 4 aus SCHLITGEN & STREITBERG (2001, S. 33) illustriert den Algorithmus.

Tabelle 4: Beispielrechnung für die Potentialwerte  $p(t)$  aus SCHLITGEN & STREITBERG (2001, S. 33)

		Zeitpunkte											
		1	2	3	4	5	6	7	8	9	10	11	12
		Zeitreihenwerte											
nach Iterations-Schritt		2	1	1	6	5	9	8	4	5	5	5	2
1		2		1	6	5	9	8	4			5	2
2		2		1	6	5	9		4			5	2
3				1	6	5	9		4			5	2
4				1			9		4			5	2
5				1			9						2
6				1			9						
7													
		Potentialwerte											
		-1	0	8	-1	1	-8	0	1	0	0	-1	-7

Um das charakteristische Trendmuster eines Data-Clusters zu erhalten, wird zunächst die TUP-Methode auf die einzelnen Batches (aus der adaptierten SPC-Methode) eines Zeitbereichs angewendet. Aus der daraus entstehenden Menge der Potential-Werte für jeden Batch werden die größten Absolutwerte herausgesucht und als Trend-Umkehr-Punkte definiert. Die Anzahl der ausgewählten Trend-Umkehr-Punkte richtet sich nach dem jeweiligen Anwendungsfall. Generell gilt: je mehr Punkte, desto feiner und je weniger Punkte, desto markanter ist das resultierende Muster. An die Auswahl der Trend-Umkehr-Punkte schließt sich eine Gruppierung der Batches des Zeitbereiches an. Dabei sind die gewählten Trend-Umkehr-Punkte jeweils Endpunkte einer Gruppe. Für jede dieser Gruppen wird darauffolgend ein linearer Trend berechnet und somit ein Trend-Muster für einen Zeitbereich gebildet.

Das Ergebnis dieser Schrittfolge für die Beispiel-Zeitreihe aus Tabelle 4 ist in Abbildung 10 grafisch dargestellt. Als markante Trend-Umkehr-Punkte wurden der 3., 6. und 12. Wert der Zeitreihe ausgewählt und darauf aufbauend das Trend-Muster gebildet.




Abbildung 10: Trendmusterberechnung - Beispiel

Aus Abbildung 10 wird der Vorteil der Methode der Trend-Umkehr-Potentiale gegenüber einem einfachen linearen Trend deutlich. Während sich über die gesamte Zeitreihe ein leicht steigender Trend ergibt, zeigen die 3 Haupttrends für die Zeitreihe ein wesentlich differenzierteres Bild. Ein positiver Anstieg ist eigentlich nur zwischen den Werten 4 bis 6 vorhanden. Während dem Rest der Zeitreihe (für 9 von 12 Zeitreihenwerten) verläuft der Trend negativ. Für ein Materialflusssystem könnte ein solches Trend-Muster, bspw. für die aus den Ereignisdaten errechnete Kenngröße des LeistungsIndex der Transportzeiten<sup>16</sup> für alle Kanten des Knoten-Kanten-Modells im Betrachtungszeitraum, das Folgende bedeuten: Das System läuft zu 9 von 12 Zeiteinheiten mit negativem Trend, der aber durch eine starke zwischenzeitliche positive Entwicklung überdeckt wird. Die negativen Trends in Teilabschnitten werden somit nicht als Trend erkannt und fließen nicht in ggf. aktuelle Maßnahmen auf Basis der Prognose ein. Die SPC- Methode zur Identifikation von suboptimalem Verhalten würde dieses identifizieren, jedoch keine Prognose liefern.

Die Abbildung 11 zeigt das methodische Vorgehen für eine Online-Materialflussdiagnose mittels adaptierter SPC für das Data-Clustering und der Anomalie-Identifikation sowie der Nutzung von Trend-Umkehrpotentialen für die Prognose wiederkehrender Data-Cluster oder Muster innerhalb eines Clusters.

<sup>16</sup>  $LI(ND(k))$  für  $\forall k \in K$  in  $T$ ; vgl. 9. Symbole, Objekte und Kenngrößen.

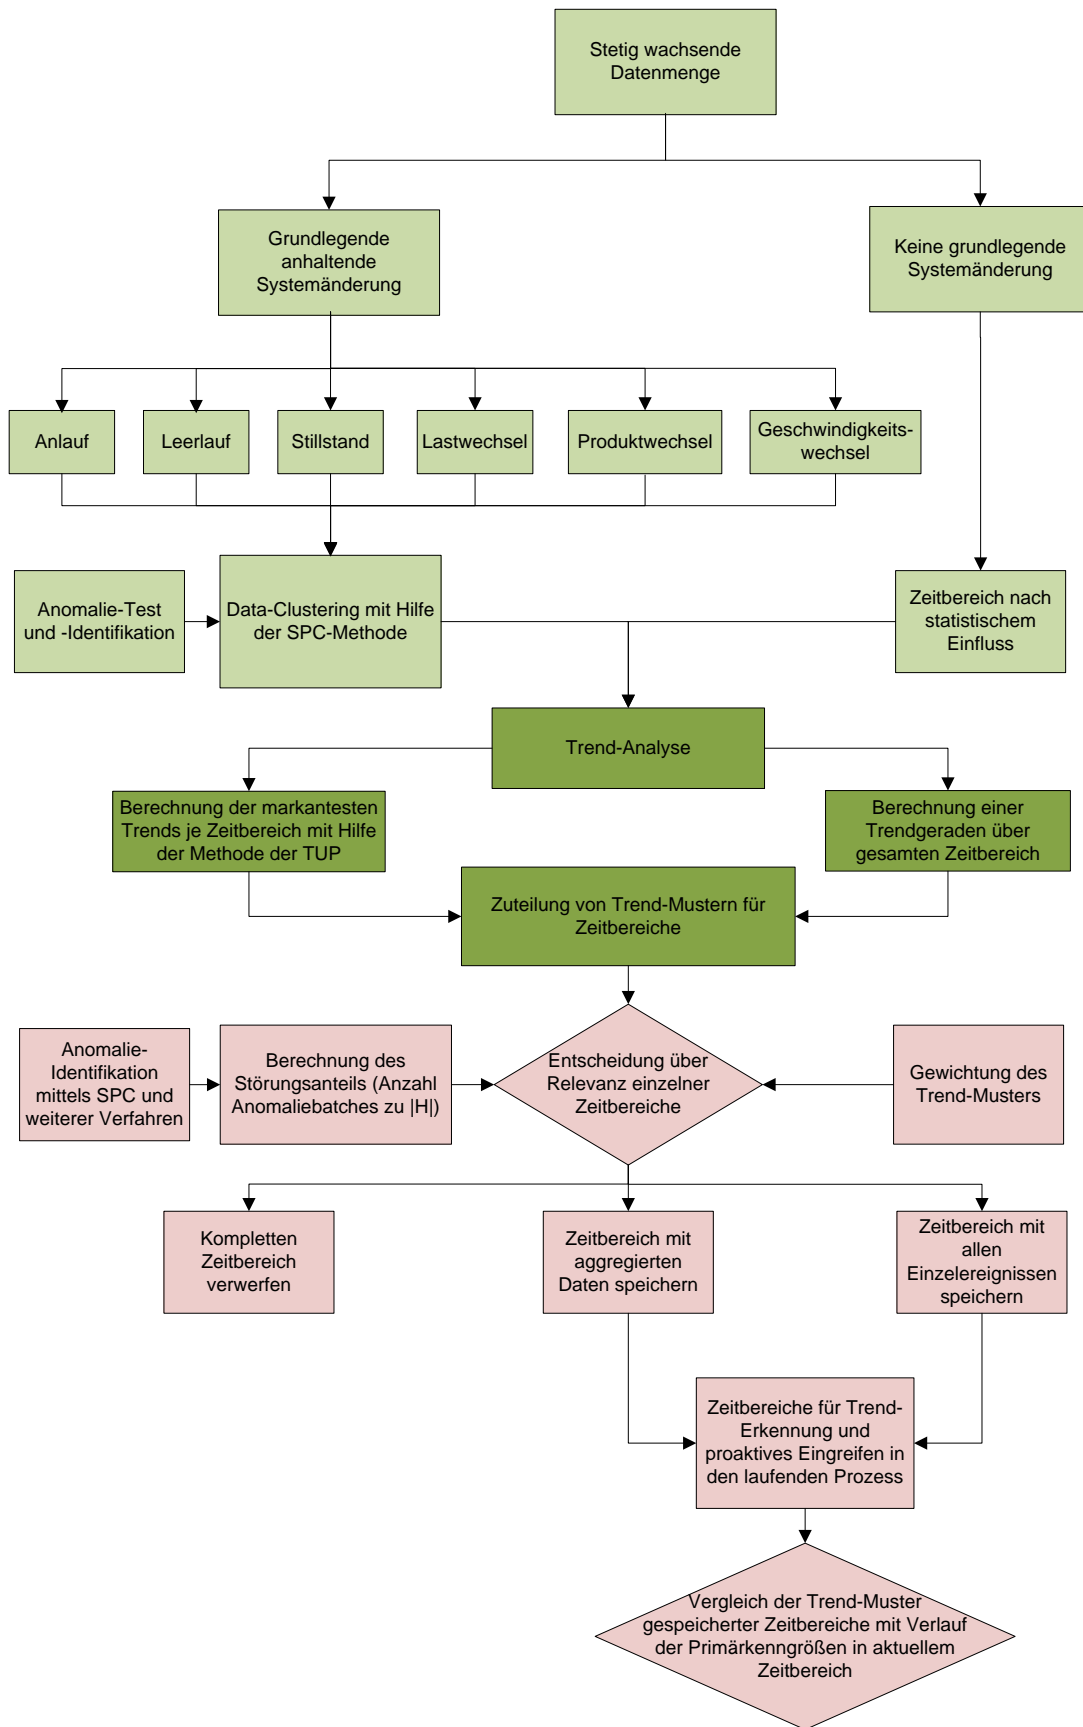


Abbildung 11: Vorgehen für die Online-Materialflussdiagnose mit SPC und TUP als wesentliche Methodenbausteine

## 4.2 Datenmanagement für Echtzeit-Datenströme

Anlagenbetreiber benötigen relevante Kenngrößen nicht erst nach zeitaufwendigen semimanuellen Auswertungen mit Hilfe mehrerer Softwerkzeuge, sondern ständig aktuelle Werte, die permanent auf einer Anzeige abgelesen werden können, um bei Problemen sofort die Ursache eingrenzen und reagieren zu können. Dafür ist es notwendig, einerseits effiziente Berechnungsalgorithmen zu verwenden. Andererseits sind Werkzeuge zur Verwaltung und wiederholten Ausführung von Analyseregeln sowie effiziente Verfahren zur dauerhaften Datenspeicherung und –abfrage nötig. Diese werden in den folgenden Abschnitten vorgestellt

### 4.2.1 Explizite und iterative Berechnung

Diese Anforderung bedeutet für den Berechnungsalgorithmus von Aggregaten (Durchschnittswerte, Abweichungen, Summen, Prognosen), dass es nicht mehr ausreicht, in großen zeitlichen Abständen aktuellen Aggregate über viele tausend Ereignisdaten auszurechnen, sondern, dass die Berechnung beim Eintreffen eines jeden neuen Events zu erfolgen hat. Weil bei kleinen Zwischeneventzeiten die Rechendauer zu groß wäre, muss die Berechnung mit Hilfe neuer angepasster sog. Online-Verfahren erfolgen. Das Wesen der schnellen Online-Verfahren besteht, darin dass der Aktuelle Aggregatwert nicht aus allen verfügbaren Originalwerten berechnet wird, sondern immer aus dem letzten Aggregatwert und dem neuen aktuellen Ereigniswert. D.h. der neue Ereigniswert wird mit dem alten Aggregatwert nur „verrechnet“. Der Unterschied bezüglich des Rechenaufwandes zwischen expliziter und rekursiver Verarbeitung wird anhand der formalen Beschreibung deutlich.

- Explizit: Bestimmung des Ergebnisses aus allen Originalwerten

$$m = \frac{\sum_{i=1}^N(x_i)}{N}$$

- Rekursiv: Bestimmung des Ergebnisses aus einem neuen Originalwert und altem Ergebnis

$$m_i(x_i, m_{i-1}) = \frac{[(m_{i-1}) * (i - 1) + x_i]}{i}$$

Neben der enorm verkürzten Rechendauer ist als weiterer Vorteil zu nennen, dass die Daten die einmal der Verarbeitung zugeführt wurden, für Folgeaufrufe der rekursiven Formel nicht mehr gespeichert werden müssen, eine erhebliche Erleichterung bei sehr großen Datenmengen. Allerdings gibt es ein Problem bei mehrpassigen Algorithmen. Mehrpassige Algorithmen sind solche, die einen Datensatz mehrfach verarbeiten müssen. Ein Beispiel sind die sog. Mehrpass-Suchen. Ein erster, grober, aber schneller „Pass“ (Suchlauf) schränkt den Suchraum zunächst ein. Ein Zweiter, langsamerer „Pass“ sucht dann den verbliebenen, kleineren Suchraum genauer ab und liefert die Ergebnisse.

Die meisten relevanten Aggregate sind onlinefähig, d.h. es existieren rekursive oder iterative Formeln. Es sind diese die Aggregate (min, max, avg, sum, std) von Kanten oder fördergutspezifischen Kenngrößen (Zwischenankunftszeit, Haltezeit, ZeitImSystem, Durchlaufzeit, Fördergutzähler, Nutzungsdauer, Kantenlast).

Komplexere Kenngrößen insbes. qualitativer Art sind nicht immer leicht online zu bestimmen. Beispiele sind Eigenschaften des Layoutgraphen wie Pfade, Kanten-(Knoten-)zentralität, Kanten-(Knoten)-Störpotential. Zwar kann der Graph iterativ bzw. rekursiv aufgebaut werden, aber es ist i.d.R. nicht leicht zu entscheiden, wann Knoten und Kanten aus dem Graph wieder entfernt werden sollen. Diese Entscheidung ist

Anwendungsfallabhängig. D.h. wenn eine Kante lange Zeit nicht befahren wurde könnte sie aus dem Graphen entfernt werden.

In der Praxis der Logistik verschwinden Kanten nicht, nur weil sie lange nicht befahren wurden. D.h. Knoten und Kanten sollen meist beibehalten werden. Im Gegensatz dazu können jedoch unbekannte Kanten als Fehler/Anomalien erkannt werden, wenn nämlich Sensoren verschmutzt sind, oder wenn Arbeiter Fördergüter manuell von einem Förderband zu einem weiter entfernten tragen.

Ein weiterer Aspekt der Online-Berechnungen ist die Vergangenheitstiefe. Mit einfacher rekursiven Formel ist mit Hilfe des letzten Berechnungsergebnisses nicht ersichtlich wie alt der erste Originalwert ist. Eine Lösung für dieses Problem ist die Fenstertechnik. Hier werden die Ergebnisse mit expliziten Formeln berechnet aber nur für die Größe des Fensters, z.B. die letzten 1000 Originalwerte. Fenster können gleitend oder springend sein. Im Projekt wurde die Technik der springenden Fenster erprobt. Dabei wurde zunächst das blockweise Einlesen von historischen Logdaten realisiert, um so das blockweise Aufkommen von Ereignisdaten zu emulieren. Diese Blöcke entsprechen Fensterausschnitten aus einem Datenstrom. Die Analyse wurde für jeden neuen Block erneut ausgeführt, sodass die Technik „Springendes Fenster“ umgesetzt wurde. Die Anzeige wurde nach Verarbeitung eines jeden Blockes aktualisiert. Auf diese Weise wurde ein „Dashboard“ verwirklicht.

#### **4.2.2 Complex Event Processing**

Eine junge sich in der Industrie rasch verbreitende Technologie für die Verarbeitung von Ereignissen, die mit sehr hoher Frequenz auftreten, ist das sog. Complex Event Processing (CEP). Dies ist mittlerweile die Kern-Technologie hinter einer neuen Generation von Echtzeit- Anwendungen, die durch die fortlaufende Verarbeitung von großen Datenströmen mit möglichst geringer Verzögerung eine schnellstmögliche Reaktion auf veränderte Situationen ermöglichen soll.

Dazu werden die zu berechnenden Aggregate (wie z.B. Durchschnittswerte, Standardabweichungen, Summen oder Prognosen) auf ständig aktualisierten Anzeigen, den sog. Dashboards (Armaturenbrett), angezeigt.

CEP Engines verwenden Datenströme (Streams) als Eingänge und werden mit Abfragen (Queries) für den jeweiligen Einsatzzweck bzw. Analysezzweck parametrisiert.

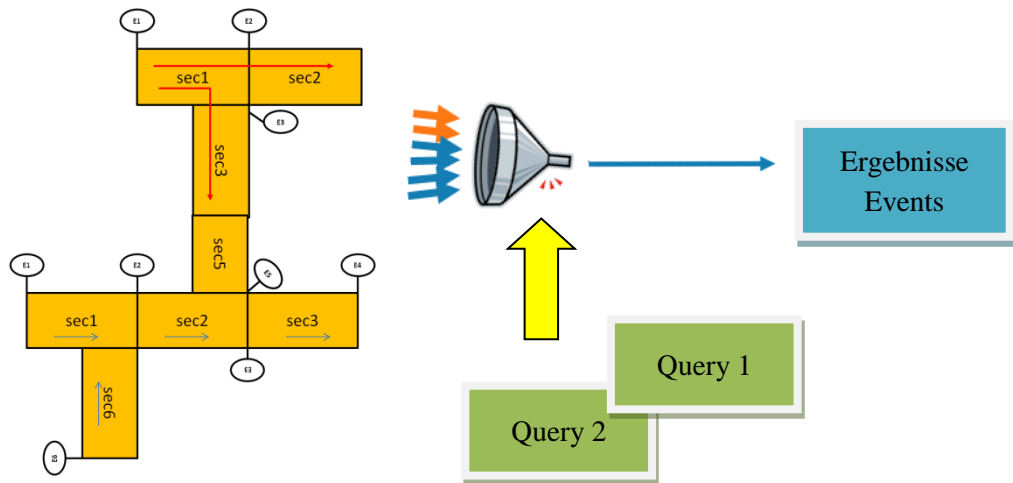


Abbildung 12: Prinzip des Complex Event Processing

### Beispiel einer CEP-basierten Echtzeit-Anwendung

Nachfolgend wird der RTM Analyzer stellvertretend für eine Vielzahl von CEP-Basierten kommerziellen sowie auch wissenschaftlichen Anwendungen vorgestellt, um Prinzip und Bedienung solcher Online-Anwendungen zu verdeutlichen. Das Werkzeug besteht aus einer Basis-Funktionalität mit CEP-Plattform, Data Integration und Management Cockpits (Dashboard). Die Basis der eingesetzten Anfragesprache ist SQL, die um zusätzliche Zeit-Konstrukte (z. B. zur Definition von Fenstern) und Ausdrücken zum Pattern Matching, zur Modellierung von inhaltlichen und zeitlichen Relationen zwischen Basisevents, erweitert wurde. Die Definition der Anfragen erfolgt in einem Text-Editor (siehe Abbildung 13). Die zentrale Applikation der RTM-Finanzdemo ist der „Analyzer Client“. Dieser beinhaltet neben einem integrierten „SQL Interface“ mit dem Query Editor und zwei Dashboard-Oberfläche namens „Statistics“.

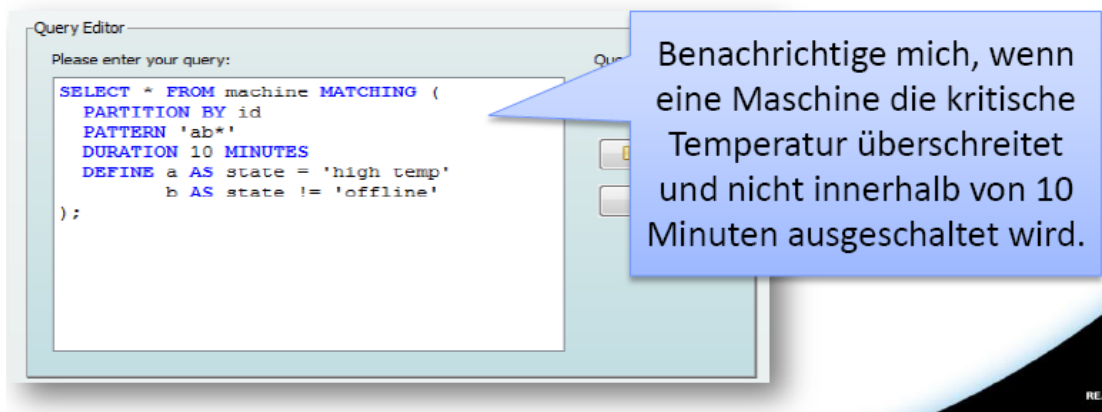


Abbildung 13: Query Editor für die Eingabe von Abfragen

Im „Statistics Monitor“ können unterschiedliche Statistiken über den Daten ausgewertet und angezeigt werden. Diese können auf verschiedene Fenster-Ausprägungen beschränkt werden und damit Vergleiche zwischen aktuellen und allgemeinen Werteverläufen angestellt werden. Das eingebaute Data Mining kann auch zur Erkennung von Trends und Ausreißern sowie für Live Prognosen (Vorhersagen aufgrund beobachteter statistischer Zusammenhänge und aktuellen Entwicklungen) genutzt werden.



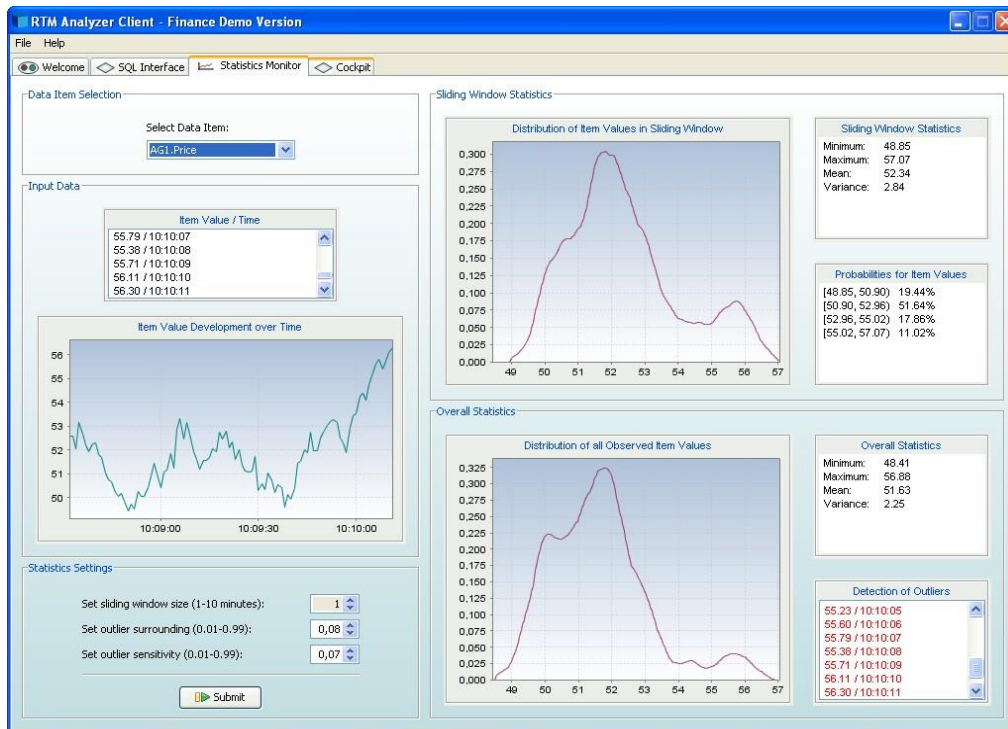


Abbildung 14 RTM Analyzer Client: Statistics Monitor

Das sog. Cockpit ermöglicht verschiedene, individuell auf unterschiedliche Benutzer und Nutzerrollen angepasste Darstellungen der Werteverläufe sowohl der Eingangsdaten als auch der definierten Anfragen inklusive zusätzlicher statistischer Informationen. Diese Dashboards können sowohl als Web-Anwendungen, in „Thin-Clients“ als auch in Stand-Alone Anwendungen genutzt werden.

### 4.2.3 Indizierung aufgezeichneter Daten mit Präfixbäumen

Die in den vorangegangenen Abschnitten beschriebenen Techniken basieren auf der Idee, nur so viele Daten aufzubewahren, wie für die Ausführung der nächsten Rechenschritte für Kenngrößen und Aggregate notwendig sind. Darüber hinausgehende Auswertungen, welche die ursprünglichen Ereignisdaten benötigen, können damit nicht unterstützt werden. Dies stellt sich als großer Nachteil heraus, wenn sich nach dem Entwurf des Diagnosesystems Anforderungen ändern (Aggregatfunktionen, Zeithorizont etc.). Als Alternative bieten sich Technologien an, welche sowohl die Rohdaten effizient persistent (dauerhaft) ablegen als auch schnellen Zugriff auf Rohdaten und vor allem Aggregate ermöglichen. Am Lehrstuhl TIS wurde ein Demonstrator entwickelt, der die hierfür sehr gut geeigneten Präfixbäume verwendet. Dadurch können insbesondere inkrementell berechenbare Aggregate aber auch solche, für die keine inkrementelle Berechnung bekannt ist über beliebige Zeitintervalle oder gruppierte Daten effizient berechnet werden. Dies ist für die Online-Fähigkeit der Diagnose von essentieller Bedeutung.

Um Präfixbäume zu nutzen, wurde zunächst die Struktur der zu speichernden Ereignisse als Java-Klasse dargestellt. Beim Eintreffen eines neuen Ereignisses wird dieses zunächst in ein Binärformat umgewandelt (serialisiert) und dauerhaft abgespeichert. Der Demonstrator sieht das Speichern in einer Datei und in einer Datenbank vor. Anschließend wird eine spezielle Indexdatenstruktur aktualisiert wobei die benötigten Aggregate rekursiv neu berechnet werden. Abbildung 15 zeigt ein Beispiel einer solchen Datenstruktur.

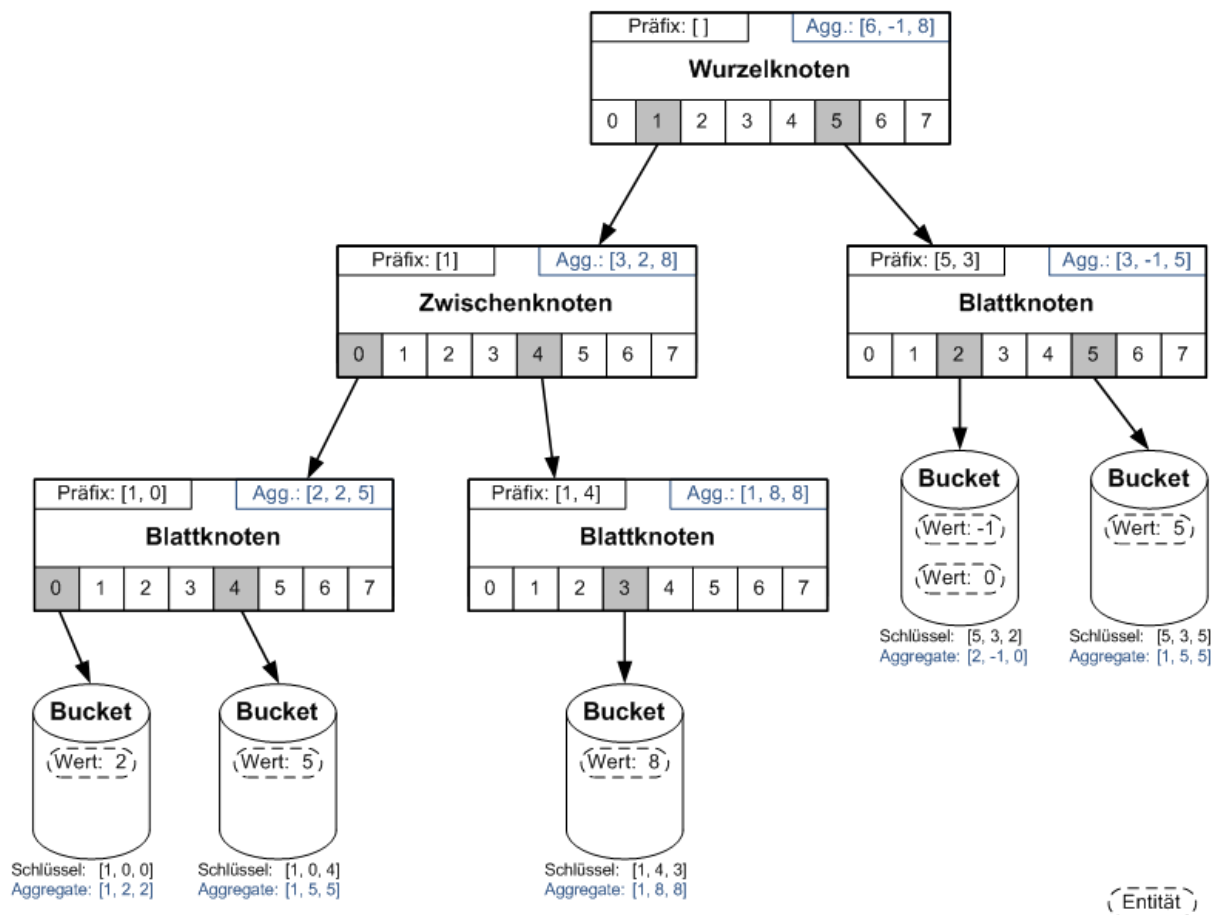


Abbildung 15: Beispiel eines Präfixbaums mit Aggregaten

Beim Aktualisieren entsteht zunächst ein höherer Aufwand als beim bloßen Abspeichern. Verweise zu den Rohdaten werden in den Blattknoten („Bucket“) der Struktur gespeichert. Für jeden Zwischenknoten auf dem Pfad zum neu eingefügten Verweis muss die Aktualisierung der Aggregatinformationen erfolgen. Allerdings ist die maximale Pfadlänge nur von der maximalen Schlüssellänge des Index abhängig. Beispielsweise ist für Ereignisse mit den wichtigsten Attributen Zeitstempel (millisekundengenaue Speicherung für 1 Jahr ; entspricht 35 Bit), Load (max. 1Mio Loads; entspricht 20 Bit Teilschlüssellänge) und State (max. 10000 States) eine Schlüssellänge von 75 Bit notwendig. Werden jeweils 5 Bit pro Knoten zusammengefasst (in Abbildung 15 sind es 3 Bit) ergibt sich eine maximale Pfadlänge von 15 Knoten und daraus eine Obergrenze von 15 Aggregatoperationen pro benötigtes Aggregat pro Einfügevorgang. Dessen Dauer ist somit unabhängig von der Anzahl der bereits eingefügten Ereignisse.

Es wurden verschiedene Experimente durchgeführt, um die Leistung des Ansatzes beim Einfügen für die Online-Diagnose zu überprüfen. Einige repräsentative Ergebnisse sind in Tabelle 5 zusammengefasst. Die Experimente wurden auf einem Intel Core 2 Duo E8300 mit 2.8GHz, 4GB RAM, 64 Bit Windows 7 mit Oracle Java JDK 1.7 durchgeführt.

Tabelle 5: Ergebnisse der Leistungsmessung für die Ereignisspeicherung auf Basis von Präfixbäumen

Einfügeoperationen [%]	Aggregat-abfragen [%]	Operationen pro Sekunde [1/s]
100	0	18018,02
90	50	16666,67
50	50	19607,84
50	90	23809,52
20	50	39840,64

Der Vorteil der Vorberechnung der Aggregate zeigt sich bei der Abfrage von Kenngrößen. Deren Berechnungsdauer ist *unabhängig* von der Anzahl der die Abfrage betreffenden Ereignisse sehr effizient möglich. Insbesondere können die aktuellsten Kennwerte sehr schnell abgefragt werden. Im Bedarfsfall ist aber dennoch der Zugriff sowohl auf jedes einzelne Ereignis als auch auf Aggregate über beliebige Datenbereiche effizient gewährleistet.

### 4.3 Algorithmen zur Online-Diagnose

Basierend auf der Erkennung von Anomalien mittels Regeln und Charts (siehe Abschnitt 4.1.3 und WUSTMANN et al. 2010) und der effizienten Verwaltung der Ereignisdatenströme wurden Diagnosemethoden mit besonderem Augenmerk auf deren Online-Fähigkeit entwickelt. Abbildung 16 zeigt eine generelle Klassifikation von Diagnosemethoden nach Venkatasubramanian (siehe VENKATASUBRAMANIAN et al. 2003) welche jedoch nicht zwischen Offline und Online Verfahren unterscheidet.

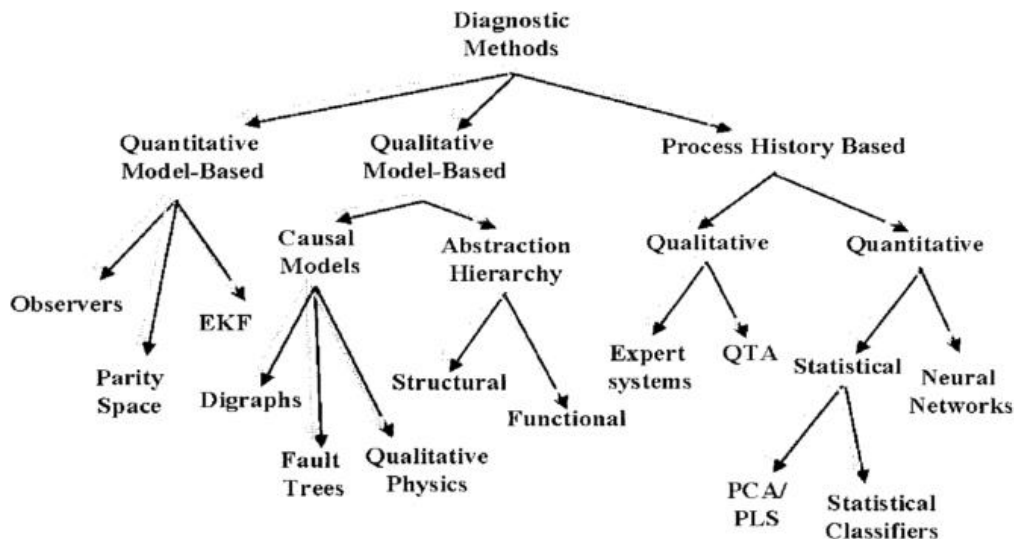


Abbildung 16: Klassifikation von Diagnosemethoden aus VENKATASUBRAMANIAN et al. 2003

Da detaillierte kausale oder quantitative Modelle des Anlagenverhaltens in der Praxis selten verfügbar sind wurden ausschließlich prozesshistorienbasierte Verfahren detailliert untersucht. Expertensysteme wie

beispielsweise RTM (siehe 4.2.2) oder Drools<sup>17</sup> sind für die Diagnose auf Basis einfacher qualitativer oder quantitativer Modelle gut einsetzbar. Für die Analyse komplexer transienter Phänomene mit teilweise unbeobachtbaren Einflüssen sind sie allerdings nicht geeignet. Hierfür wurden geeignete statistische Verfahren recherchiert und ihre Leistungsfähigkeit und Eignung für die Online-Diagnose bewertet. Im Folgenden werden die Ergebnisse kurz diskutiert.

Bei allen folgenden Verfahren wird davon ausgegangen, dass die Ereignisdaten zunächst in eine sogenannte *Indikatormatrix*  $I$  transformiert werden. Für jeden aufgetretenen Zustand wird dabei eine Spalte angelegt, für jedes Load eine Zeile. Die Zelle  $[i,j]$  enthält entweder die Anzahl des Auftretens des Zustands  $i$  bei Load  $j$  als Ganzzahl oder das Auftreten als Binärwert. Die gewählte Kenngröße wird als Vektor  $y$  mit einem Element pro Load dargestellt. Weiter setzen alle Verfahren Variabilität innerhalb der betrachteten Komponenten voraus. Werden bestimmte Komponenten (fast) immer oder (fast) nie benutzt, können sie mit diesen Verfahren nicht untersucht werden.

#### *Naiver Ansatz*

In der Praxis wird beim gehäuften Auftreten von Anomalien der betrachteten Güter oft zunächst untersucht, welche Zustände (Transportkomponenten) bei Gütern (Loads) mit aufgetretenen Anomalien besonders häufig eingenommen wurden. Da dieser Ansatz die generell a priori unterschiedliche Verwendungshäufigkeit von Zuständen missachtet, führt er jedoch häufig zu Fehlinterpretationen der Daten und wurde daher nicht detailliert untersucht.

#### *Varianzanalyse*

Bei dieser Klasse von Verfahren werden die Loads anhand der im Zeitverlauf eingenommenen Zustände gruppiert und die Gruppen mittels einfaktorier ANOVA oder dem *Kruskal-Wallis Test* verglichen. In der Praxis wird Kruskal-Wallis Test oft vorgezogen, da er geringere statistische Anforderungen an die Eingangswerte stellt. Wird als Gruppierungskriterium die Verwendung eines Zustands (binäre Entscheidung ja/nein) definiert, geben diese Verfahren Aufschluss über die Gleichheit der Varianz der gewählten Kenngröße in Abhängigkeit davon, ob der betreffende Zustand eingenommen wurde oder nicht. Unter Angabe einer maximalen Irrtumswahrscheinlichkeit (häufig werden 5% angesetzt) kann damit entschieden werden, ob der Zustand mit der Qualität der Loads in Verbindung steht oder nicht.

Die Hauptprobleme dieser Verfahrensklasse bei der Anwendung für die Online-Diagnose sind folgende.

- a) Verdeckte Zusammenhänge: Das Ergebnis dieser Verfahren kann ohne tiefe Kenntnisse über das Gesamtsystem nicht ohne weiteres als Hinweis auf eine Wurzelursache interpretiert werden.
- b) Fehlinterpretation aufgrund von vielen Durchführungen: Für jeden Ursachenkandidaten müssen diese Verfahren separat ausgeführt werden. Bei komplexen Systemen können hunderte oder tausende Kandidaten einbezogen werden, beispielsweise alle Komponenten eines Fördersystems. Im Zusammenhang mit der Irrtumswahrscheinlichkeit jeder einzelnen Durchführung erhöht sich mit zunehmender Anzahl der Kandidaten die Wahrscheinlichkeit, *irrtümlich* unterschiedliche Gruppenvarianzen als Fehlerursache zu interpretieren (sog. Typ 1 Fehler).

---

<sup>17</sup> <http://www.jboss.org/drools>

- c) Aussagekraft über die Qualität des Zusammenhangs: In der Praxis steht die Verwendung einzelner Komponenten häufig in *positivem* Zusammenhang mit der Kenngröße. In diesem Fall darf ein Unterschied in der Varianz der gebildeten Gruppen jedoch nicht als Fehlerursache interpretiert werden.

In die Berechnung der ANOVA-Teststatistiken gehen nur Berechnungen von Varianzen, Summen und Anzahlen ein, für welche inkrementelle Verfahren bekannt sind. Sie können daher effizient online berechnet werden. Für den Kruskal-Wallis Test ist jedoch eine Rangtransformation notwendig, welche nicht effizient inkrementelle durchgeführt werden kann. Mittels Indizierung der Rohdaten (siehe Abschnitt 0) ist jedoch trotzdem eine schnelle Berechnung gewährleistet.

#### *Korrelationsanalyse*

Rangkorrelationsverfahren wie der *Spearman-Test* haben sich als geeignet erwiesen, Zusammenhänge zwischen der Einnahme eines Zustands im Zeitverlauf und einer Kenngröße der Loads zu überprüfen. Hieraus resultiert die Stärke des Zusammenhangs, dessen Richtung und statistische Signifikanz. Bei Auftreten eines großen Korrelationskoeffizienten zwischen einer Transportsystemkomponente und einer zu minimierenden Qualitätskenngröße (beispielsweise transportbedingter Verschmutzung des Gutes) wird die betreffende Komponente als Ursache interpretiert. In Analogie zur Varianzanalyse kann auch bei diesen Verfahren eine Fehlinterpretation aufgrund vieler Durchführungen stattfinden. Es ist demnach notwendig, möglichst viele Kandidaten durch Ausnutzung von Wissen über das Transportsystem (vgl. Abschnitt 4.4) auszuschließen, eine möglichst kleine Irrtumswahrscheinlichkeit anzusetzen (bspw. mit der sog. Bonferroni-Korrektur) sowie die ermittelten Ursachenhypothesen in ihrer Gesamtheit zu bewerten.

Auch für den Spearman-Test ist eine Rangtransformation nötig. Analog zum Kruskal-Wallis Test ist demnach die Indizierung der Rohdaten notwendig, um eine schnelle nicht-inkrementelle Berechnung zu gewährleisten.

#### *Weitere Verfahren*

Eine große Anzahl Verfahren zur Fehlerdiagnose wurde in den letzten Jahren vorgestellt. Dazu gehören *Entscheidungsbäume*, hybride Techniken wie *CART*, *SERT*, *Conditional Inference Trees (CTree)*, *Conditional Inference Forest*, Anwendungen des Gibbs-Samplers sowie mehrere Verfahren auf Basis von Cluster-Techniken (beispielsweise nach ROKACH/HUTTER 2011). Unter den Autoren dieser Verfahren geht nur Rokach (siehe ROKACH/HUTTER 2011) auf die inkrementelle Berechenbarkeit ein.

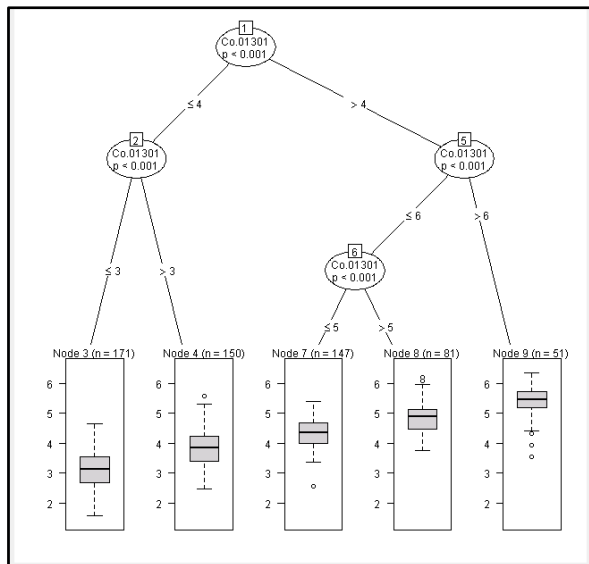
### **Experimentelle Bewertung**

Aufgrund des geringen hierfür vorgesehenen Zeitanteils konnten nur diejenigen Verfahren untersucht werden, für welche eine Implementierung bereits verfügbar war. Anhand gegebener Produktionspläne wurden Konfigurationen für die Simulation transportbedingter Verschmutzungen in Anwendungsfall 3 erzeugt. Für alle verfügbaren Verfahren wurde im Anschluss an die Simulation untersucht, ob die simulierte tatsächliche Ursache in der Menge der Ursachenhypothesen auftaucht und wie sie sich gegebenenfalls von weiteren Hypothesen abhebt. Tabelle 6 beschreibt die wichtigsten getesteten Konfigurationen.

Tabelle 6: Simulationskonfigurationen für die Bewertung statistischer Diagnosemethoden

Konfiguration	Beschreibung
0	Kleiner rein zufälliger Qualitätsverlust
1	Komponente „Co.01301“ (häufig verwendet) verursacht großen Fehler
2	Komponente „Co.01102“ (selten verwendet) verursacht großen Fehler
3	Komponente „Co.01301“ (häufig verwendet) verursacht kleinen Fehler

Im Rahmen der Experimente wurde festgestellt, dass sämtliche Verfahren bei einer Irrtumswahrscheinlichkeit von  $\alpha = 0.01$  zwar alle simulierten Anomalien aufdecken konnten, diese jedoch in vielen Fällen kaum von rein zufälligen Effekten unterscheidbar sind (Typ-1 Fehler). Daher wurde bei *Kruskal-Wallis Test*, *Rangkorrelation* und *CTree* eine konservative Irrtumswahrscheinlichkeit anhand der Bonferroni-Korrektur von  $\alpha = 2 * 10^{-05}$  angesetzt. Abbildung 17 zeigt exemplarisch das Ergebnis von CTree und Rangkorrelation nach Spearman auf Daten der Konfiguration 1.



Komponente	p	q
Co.01301	$9.7 \times 10^{-133}$	0.8
Co.00319	$3.2 \times 10^{-06}$	0.19
Co.00102	$1.8 \times 10^{-12}$	-0.28

Abbildung 17: Ergebnisse von CTree (links) und Rangkorrelation (rechts) für Konfiguration 1

Für die Online-Diagnose ist eine plausible automatische Interpretation der Ergebnisstruktur notwendig. Diese konnte allerdings nicht *allgemeingültig* ermittelt werden. Eine einfache Möglichkeit der Interpretation für CTree und andere baumbasierte Ergebnisstrukturen besteht darin, die auf jedem Pfad von einem Blatt zur Wurzel in den Knoten auftauchenden Komponenten als konjunktive Verknüpfung von Ursachen anzusehen. Dabei wird allerdings die Richtung des Zusammenhangs zwischen der Verwendungshäufigkeit und dem zugehörigen Median der Gruppe ignoriert. Diese Interpretation legt für die Beispielkonfiguration 1 nahe, dass die Verwendungshäufigkeit der Komponente „Co.01301“, und nur diese, die als Zielgröße verwendete Verschmutzung beeinflusst.

Im Gegensatz dazu ist die Interpretation für die Ergebnisse der Rangkorrelation unter Angabe einer benutzerdefinierten Schwelle  $q_{\min}$  für  $q$  (Stärke und Richtung des Zusammenhangs) allgemein möglich: Alle Komponenten mit  $p < \alpha$  und  $q < q_{\min}$  können als mögliche Fehlerursache interpretiert werden. Allerdings ist auch dabei Typ-1 Fehler aufgrund *zufällig* signifikant erscheinender Teststatistiken (siehe Zeile 2) nicht

ausgeschlossen. Dies lässt sich durch Verkleinerung von  $\alpha$  und Vergrößerung von  $q_{\min}$  verbessern, allerdings auf Kosten der Erkennungsleistung mit dem Risiko, dass *tatsächliche* Ursachen übersehen werden (Typ-2 Fehler).

Tabelle 7 zeigt die Ergebnisse aller Konfigurationen unter den oben angegebenen Interpretationen. Dabei steht „+“ für das richtige Ergebnis und „-“ für eine Abweichung mit der Anzahl Typ-1 Fehler („False Positive FP“) und Typ-2 Fehler („False Negative FN“). Als  $q_{\min}$  wurde 0.0 gewählt.

*Tabelle 7: Ergebnisse aller Konfigurationen*

<b>Konfiguration</b>	<b>CTree</b>	<b>Rangkorrelation</b>	<b>Kruskall-Wallis Test</b>
0	+	+	+
1	+	0 (1 FP)	0 (11 FP)
2	0 (1 FN)	+	0 (1 FN)
3	+	+	+

Aus den in Tabelle 7 zusammengefassten Experimenten geht hervor, dass keines der Verfahren ohne Anpassung der Parameter alle Konfigurationen richtig bewertet. Eine Vorauswahl der relevanten Komponenten anhand der in Abschnitt 4.4 beschriebenen Wissensbasis ist demnach in jedem Fall sinnvoll.

#### **4.4 Konzeption einer Wissensbasis zur Online-Materialflussdiagnose**

Die im Projektrahmen entworfene Wissensbasis besteht aus den drei wesentlichen Teilmodellen allgemeine Konzepte, das logistische System und Analyseverfahren. Als Rahmentechnologie zur Verarbeitung der Wissensbasis wurde OWL-DL (BECHHOFFER et al. 2004) ausgewählt, da diese Sprache als W3C-Empfehlung ausreichend ausdrucksstark ist, die Grundkonzepte wie Klassen, Instanzen, Relationen und Restriktionen auch für Domänenexperten verständlich sind und sie von vielen Softwarewerkzeugen unterstützt wird. Weiterhin steht zur Vereinfachung die sogenannte Manchester Syntax (HORRIDGE et al. 2006) zur Verfügung.

Als Grundlage für die Beschreibung allgemeiner Konzepte wurde ein Teil der an der RWTH Aachen entwickelten OntoCAPE Ontologie wiederverwendet (MORBACH 2009). Obwohl diese auf den Entwurf von Fertigungsprozessen abzielt, enthält sie eine Reihe wohldefinierter allgemeiner Komponenten als Basis für die spezielleren. Vor allem die Konzepte der Schichten *Meta Model* und *upper\_level* haben sich als nützlich erwiesen. Auch die Modellierung mathematischer Ausdrücke und benötigte abstrakte Konzepte wie physikalische Einheiten werden bereits unterstützt. Abbildung 18 zeigt schematisch relevante Teile von OntoCAPE und die verwendeten Teilmodelle.

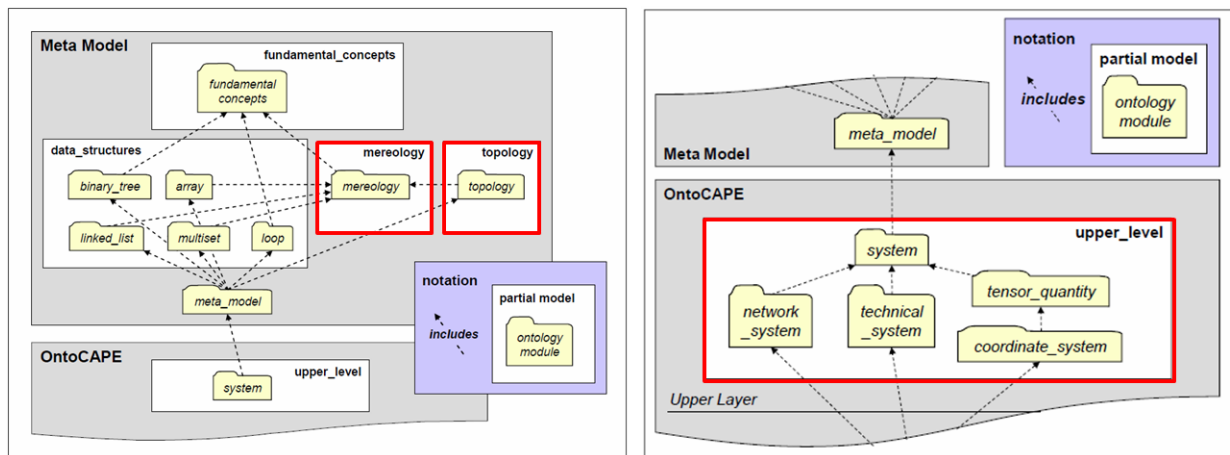


Abbildung 18: Verwendete Teile der OntoCAPE Ontologie (aus MORBACH 2009)

Auch für die Beschreibung des logistischen Systems konnten vorhandene Ansätze recherchiert werden. Es wurden die relevanten Konzepte aus MÖNCH et al. (2003), SIADAT et al. (2006) und MERDAN (2008) ausgewählt und ergänzt. Abbildung 19 zeigt einen Ausschnitt des im Use Case I betrachteten Fördersystems in der Draufsicht.

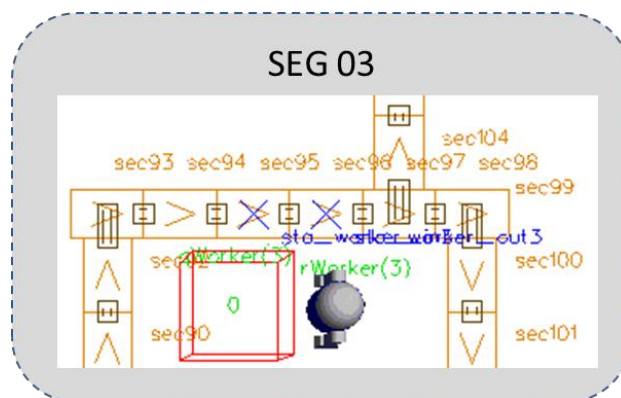


Abbildung 19: Ausschnitt des Fördersystems von Use Case I

Die einzelnen Komponenten wurden als Bandförderer (*BeltConveyorComponent*) modelliert. Dabei wurde entsprechend MERDAN (2008) in lineare Elemente und Kreuzungen (*Intersection*) unterteilt. Abbildung 20 stellt den entsprechenden Ausschnitt der resultierenden Taxonomie dar.



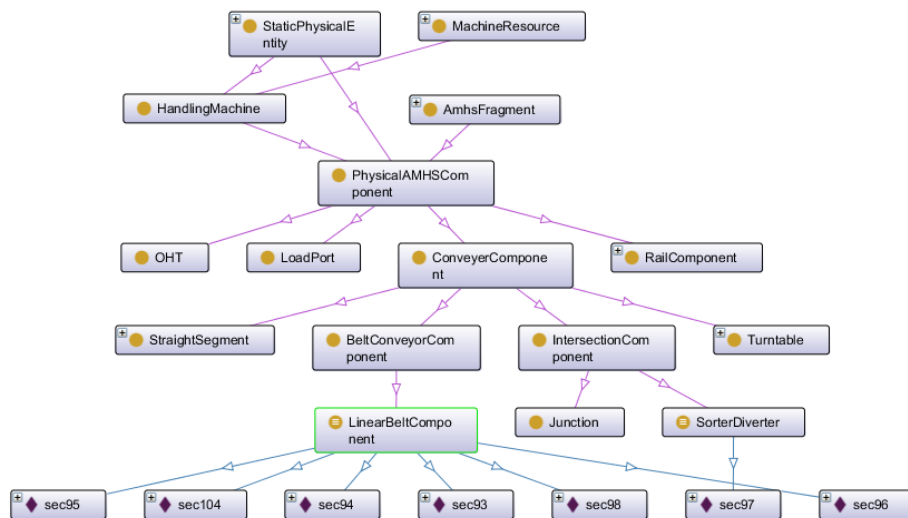


Abbildung 20: Ausschnitt aus der Komponentenklassifikation

Neben der reinen Klassifikation der Komponenten wurden deren logische Zusammenhänge modelliert. Analog zu OntoCAPE wurde die Topologie der Komponenten (Vorgänger/Nachfolgerbeziehungen) erfasst. Die direkte Verbindung zweier Elemente wurde mittels der Relationen *hasInput* und *hasOutput* realisiert. Diese sind nicht transitiv, jedoch von den abstrakteren Relationen *isSuccessorOf* bzw. *isPredecessorOf* abgeleitet, welche transitiv deklariert wurden. Daher können sowohl direkte als auch indirekte Beziehungen erfasst und abgeleitet werden. Ebenso wie die Topologie der Komponenten ist für logistische Systeme deren Mereologie (Zusammenhänge zwischen Teil und Ganzem) von Interesse. Dafür wurden die nicht-transitiven Relationen *directContainedIn* und *directContains* sowie *containedIn* und *contains* (transitiv) verwendet. Durch Auswertung dieser Relationen kann beispielsweise die Granularität der Betrachtung schrittweise verändert werden. Abbildung 21 zeigt ein Beispiel anhand Use Case I. Alle dargestellten Fördersektionen (sec...) gehören direkt zum Segment SEG\_03 (ausgedrückt durch die Relation *directContainedIn*). Dieses gehört direkt zum Bereich *OmfdSection01*, welcher wiederum direkt der Fabrik *OmfdFab1* zugeordnet ist. Da die Relation *directContainedIn* von der transitiven Relation *containedIn* abgeleitet ist, wird von einem OWL-Reasoner beispielsweise erkannt, dass alle Fördersektionen (indirekt) auch zur Beispielfabrik gehören.

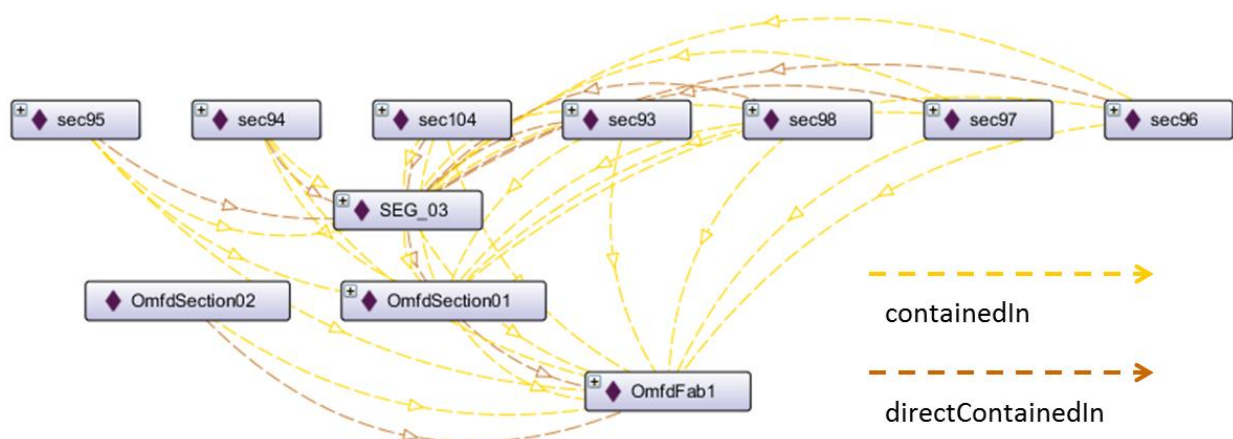


Abbildung 21: Mereologie des Modellausschnitts für Use Case I

Das oben beschriebene Systemwissen kann nun genutzt werden, um Ursache-Wirkungs-Zusammenhänge zu erfassen und damit die Aussagekraft von Diagnosehypothesen zu erhöhen. Ein formales Werkzeug hierfür beschreiben BESNARD et al. (2008). Allerdings überstieg die vollständige Umsetzung den dafür vorgesehenen Projektrahmen. Stattdessen wurde eine einfachere Einschränkung der zu betrachtenden Komponenten mittels OWL-Restriktionen vorgesehen.

Für Use Case 3 deuteten die Ergebnisse der Analyse *aller* Transportkomponenten bereits auf einen tatsächlich als problematisch identifizierten Transportabschnitt hin. Allerdings wurden viele als unwahrscheinlich klassifizierte Segmente ermittelt (Type-1 Fehler). Um die Wirksamkeit des Vorgehens zu zeigen, wurde daher der Use Case geringfügig erweitert. Es wurde eine Verunreinigung durch Ammoniak (NH<sub>3</sub>) angenommen, bedingt durch das offene Durchfahren der betroffenen Wafer durch einen kontaminierten Transportabschnitt. Mittels *directContainedIn* wurden die entsprechenden Segmente des Transportsystems Ihrem *WorkCenter* (siehe Use Case Beschreibung) zugeordnet. Anschließend wurde mit der Restriktion

```
WetChemistryCenter subClassOf (hasInput value NH3Input)
```

spezifiziert, dass jede Instanz von *WetChemistryCenter* an eine Versorgung mit Ammoniak angeschlossen ist. Abschließend konnte mit der Restriktion

```
ConveyerComponent and containedin some (WorkCenter that (hasInput value NH3Input))
```

die Menge der in Frage kommenden Komponenten des Transportsystems ermittelt werden. Diese stark eingeschränkte Komponentenmenge kann dann mit den in den vorigen Kapiteln beschriebenen Methoden weiter analysiert werden. Bei der Bewertung ist darauf zu achten, dass die Ergebnismenge aufgrund der Open World Assumption (OWA) nur dann vollständig sind, wenn das Domänenmodell entsprechend strikt aufgebaut ist.

## 4.5 Visualisierung und Protokollierung

### 4.5.1 Visualisierung

Der bereits im Vorgängerprojekt erstellte Demonstrator wurde um aussagekräftige Visualisierungsarten erweitert. Abbildung 22 zeigt die Ursachenwahrscheinlichkeit mittels Einfärben des Zustandsübergangsgraphen und als Tabelle (links) sowie intervallweise aggregierte und ebenfalls eingefärbte Kennwerte (mittlere Haltezeit und Pufferfüllstand). Die Semantik des Farbverlaufs von grün nach rot kann konfiguriert werden. In den dargestellten Fällen entspricht grün einem kleinen numerischen Wert (Ursachenwahrscheinlichkeit bzw. mittlerer Kennwert im Intervall) und rot einem großen.

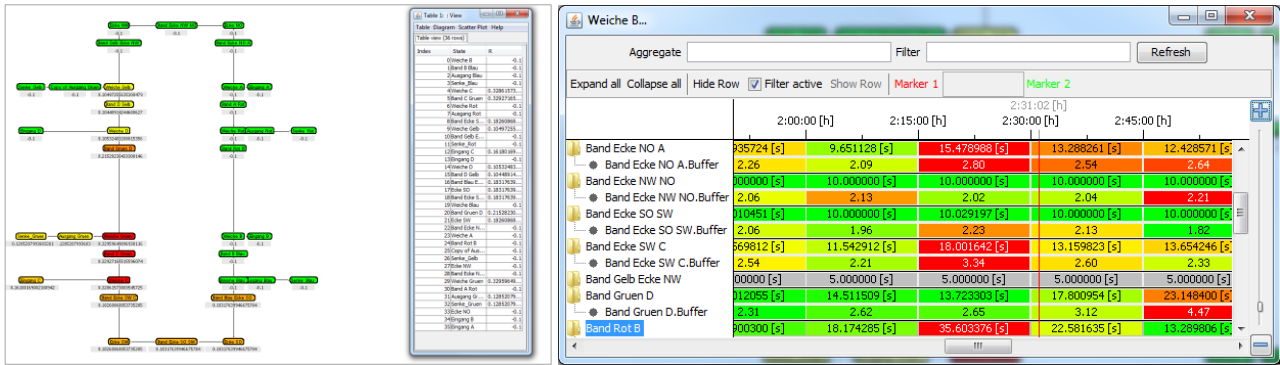


Abbildung 22: Visualisierung von Ursachenwahrscheinlichkeiten und Kennwertintervallen

Weiterhin können numerische Daten als Scatterplots und Zeitreihe dargestellt werden. Durch Einbindung des bekannten Statistikwerkzeuges „R“ über die im Demonstrator integrierte Python-Skript-Umgebung können auch die dort verfügbaren Visualisierungsarten (siehe Abbildung 17) verwendet werden.

#### 4.5.2 Leitfaden für Protokollierung

Folgende Schritte müssen generell unternommen werden um Datenaufzeichnung und Online-Auswertung sicherzustellen:

1. Bestimmung der relevanten Kenngrößen (abhängig von Anwendungsfall und Zielsetzung)
2. Aufzeichnen der Ereignisdaten
3. Analyse-Werkzeug Parametrieren
4. Beobachten

Im Detail gestalten sich diese Schritte generell wie im Folgenden beschrieben.

1. Bestimmung der relevanten Kenngrößen

Zuerst muss der Betreiber einer Anlage überlegen, welche Probleme oder Phänomene seine Anlage aufweisen könnte. Dementsprechend muss er dazu notwendige Kenngrößen notieren. Sind neben einfachen Aggregaten von Haltezeiten, Förderbandfüllständen oder Zwischenankunftszeiten auch komplexe graphenbasierte Kenngrößen von Interesse, so kann entweder das vom Projektteam entwickelte Software-Werkzeug eingesetzt werden oder weitere Werkzeuge an den entwickelten Demonstrator zur Ereignisspeicherung und -indizierung (siehe 4.2.3) angepasst werden. Andernfalls genügt auch eine herkömmliche Complex Event Processing Engine (siehe 4.2.2).

2. Aufzeichnen der Ereignisdaten
  - a. Aufzeichnen und Abspeichern in Logdateien

Zu idealen Datenformaten kann Folgendes gesagt werden: Für die Analyse historische Daten sind csv-Dateien in denen jede Zeile ein Ereignis darstellt am besten geeignet. Jede Zeile sollte dann mindestens Zeitstempel, Ereignisort (Förderband, Quelle, Senke, Maschine) und Identifikationsnummer eines Fördergutes (z.B. Barcode eines Koffers in der Gepäcklogistik) enthalten. Ereignisse die durch Bewegung oder Aktionen auslöst werden, können auch von Menschen herrühren. Bspw. kann ein Techniker verschiedene Wartungshandlungen ausführen, was registriert werden könnte. Die wesentlichste Minimal-Anforderung für die Aufzeichnung der Ereignisdaten betrifft die Orte. Für eine korrekte Analyse sind, wie bereits auch in BRANDAU & TOLUJEW (2010 und 2013) beschrieben, die Stellen kurz vor einer Verzweigung bzw. nach einer

Zusammenführung besonders relevant. Die jeweils gänzlich geänderten Materialströme sind spiegelt somit auch das aus den Daten erstellte Modell sehr gut wider. Für eine Betrachtung von bspw. Schaltzeiten (bspw. Drehtisch) oder Bearbeitungszeiten an Stationen innerhalb eines Produktionssystems, liegen im optimalen Fall Ereignisse zum Eintritt und Austritt in die Station vor. In allen anderen Fällen sind die aufgenommenen Zeiten in 2 Anteile zu unterteilen, deren Relation u.U. zusätzlich als Metainformation vorliegen muss.

In der csv-Datei ist es wichtig, dass die Spaltentrennzeichen wie. z.B. Semikolon, Tabulator, # oder % nicht in den Zahlenwerten als Dezimaltrennzeichen auftauchen. Sonst trennt der Einlese-Algorithmus (Parser) an den falschen Stellen (z.B. mitten im Zeitstempel).

Beispiel für den Inhalt einer csv-Datei für Ereignisse

TimeStamp	SystemName	LoadID	LoadType	EventPosition
0.000	CONV	Load 5 (lCarton(1))	lCarton(1)	sec1
0.000	CONV	Load 6 (lCarton(2))	lCarton(2)	sec3
0.000	CONV	Load 7 (lCarton(3))	lCarton(3)	sec5

Alternative ist XML zu empfehlen. Für XML sind Lese- und Schreib-Werkzeuge weit verbreitet. Nachteilig ist der erhöhte Speicherbedarf.

Beispiel für den Inhalt einer XML-Datei mit Ereignissen

```

<eventCollection>
  <event>
    <element>TimeStamp</element>
    <element>SystemName</element>
    <element>LoadID</element>
    <element>LoadType</element>
    <element>EventPosition</element>
  </event>
  <event>
    <element>0.000</element>
    <element>CONV</element>
    <element>Load 5(lCarton(1))</element>
    <element>lCarton(1)</element>
    <element>sec1</element>
  </event>
  <event>
    <element>0.000</element>
    <element>CONV</element>
    <element>Load 6(lCarton(2))</element>
    <element>lCarton(2)</element>
  </event>

```

```

        <element>sec3</element>
    </event>
    <event>
        <element>0.000</element>
        <element>CONV</element>
        <element>Load 7(1Carton(3))</element>
        <element>1Carton(3)</element>
        <element>sec5</element>
    </event>
</eventCollection>

```

#### b. Aufzeichnen und Absenden in Echtzeitereignissysteme

Echtzeitdatenströme werden idealerweise über sog. Enterprise Service Bussysteme (ESB) gesendet bzw. empfangen. Zwei weit verbreitete ESB sind das frei verfügbare ActiveMQ und das kostenpflichtige Webmethods von der Software AG. Um Signale von Feldbussen zu integrieren sind ggf. Middlewares einzusetzen. Die Ereignisse werden i.d.R. als Textdatentypen in den ESB ins sog. Queues oder Topics versendet. Topics versenden ihre eingehenden Ereignisse an alle registrierten Empfänger (Subscriber), Queues nur an bestimmte Empfänger. Die Empfänger besitzen i. Allg. eine CEP-Engine und die Datenströme aus verschiedenen Topics und Queues zu verknüpfen und zu analysieren. Dabei werden sog. Queries projiziert.

#### 3. Analyse-Werkzeug Parametrieren

Im vom Projektteam entwickelten Software-Werkzeug stehen die in der Logistik üblichen Kenngrößen in Kontextmenüs zur Verfügung (siehe Anhang). Damit können Aggregate angezeigt sowie die Kenngrößen einzelner Entitäten, wie z.B. State (Förderbandelement) oder Fördergut angezeigt werden. Alternativ können komplexere Auswertungen (wie z.B. ein Batchmittelwerttest) in einer Pythonkonsole formuliert werden, was einen enormen Fortschritt im Hinblick auf Flexibilität und Erweiterbarkeit darstellt. Fertige Pythonskripte sind auch als weitere Einträge im Kontextmenü der Graph-Entitäten (States und Transitionen) einbindbar.

In CEP-Engines sind entsprechende Queries (Abfragen) zu formulieren. Beispielsweise können einfach Aggregate wie z.B. Durchschnittliche Haltezeiten auf Förderbandelementen abgefragt werden. Die Grenzen der CEP-Queries sind erreicht, wenn komplexe komplexere Auswertungen (wie z.B. ein Batchmittelwerttest) formuliert werden. Dies ist oft nur mit Hilfe komplexere Kaskaden von Abfrage möglich oder gar nicht.

#### 4. Beobachten

Im vom Projektteam entwickelten Software-Werkzeug werden die in der Logistik üblichen Kenngrößen bei Auswahl über das Kontextmenü sofort in den Graphen eingeblendet oder in Tabellen ausgegeben. Ergebnisse sind Tabellen sind wieder anklickbar und bieten weitere Kontextmenüs. Dadurch ist ein besonders Interaktives Arbeiten möglich.

Die sog. Dashboards der CEP-Engine basierten Produkte ermöglichen verschiedene, individuell auf unterschiedliche Benutzer und Nutzerrollen angepasste Darstellungen der Werteverläufe sowohl der

Eingangsdaten als auch der definierten Abfragen inklusive zusätzlicher statistischer Informationen (z. B. Maximum, Durchschnitt und Standardabweichung). Die Anzeigen der Dashboards werden i.d.R. immer bei Eintreffen neuer Ereignisse aktualisiert.

## 5 Bewertung der Forschungsergebnisse

### 5.1 Zusammenfassung und Ausblick

Ziel des Forschungsvorhabens O-MFD war die Entwicklung von Online-Verfahren und -Methoden, um Materialflusssysteme anhand von Echtzeitdatenströmen semiautomatisch zu analysieren und zu bewerten.

Es ist gelungen, entsprechende Analyse- und Bewertungsverfahren für derartige Systeme zu erforschen bzw. weiterzuentwickeln, welche online Schwachstellen identifizieren, bewerten und mögliche Primärursachen ermitteln können. Dies beinhaltet darüber hinaus ein Verfahren zur Trendanalyse von betrachteten Kenngrößen. Weiterhin konnten Technologien ermittelt werden, welche die Online-Verarbeitung der benötigten Basisdaten, insbesondere deren Aggregation, überhaupt erst ermöglichen. Neben iterativen Verfahren zur Kenngrößenberechnung konnte gezeigt werden, dass durch geeignete Indizierung der Ereignisdaten auch nicht-iterative Aggregatfunktionen für die Kenngrößenberechnung verwendbar sind.

Darüber hinaus wurden Methoden entwickelt, welche zeitnah Ursachenhypothesen für transportsystem-bezogene Qualitätsmängel aufstellen. Die Aussagekraft dieser Hypothesen kann durch die Integration eines einfachen Modells kausaler Zusammenhänge erheblich erhöht werden.

Ein Modell des logistischen Systems sowie das Wissen über kausale Zusammenhänge kann mittels OWL als Ontologie strukturiert abgelegt werden. Dafür wurden geeignete Basisklassen und –relationen bereitgestellt. Damit wurde auch die Möglichkeit geschaffen, Analyseregeln auf unterschiedlicher Abstraktionsebene, von generisch bis speziell auf eine konkrete Anlage zugeschnitten, zu spezifizieren.

Alle entwickelten Verfahren wurden in einen Software-Demonstrator integriert und getestet. Dieser wurde außerdem um zahlreiche Visualisierungsformen ergänzt.

Obwohl im Rahmen des Forschungsvorhabens erhebliche Verbesserungen bei der semiautomatischen Analyse erzielt wurden, konnten praxisrelevante Themen identifiziert werden, welche Gegenstand weiterer Forschung sein sollten.

Wie bereits eingangs erwähnt, spielen für Anwendungen in Fertigungssystemen nicht nur optimal kurze Transportzeiten eine Rolle. Auch weitere Kriterien wie beispielsweise die hohe Auslastung von Maschinen bei gleichzeitig möglichst geringer Gesamtbearbeitungszeit der Werkstücke sollten in die Analyse einbezogen werden können und dafür entsprechende Kenngrößen und Regeln definiert werden. Der Fokus auf die Analyse von Produktionsdaten würde das Polylemma der Ablaufplanung in der PPS (Bestände & DLZ minimieren, Termineinhaltung & Auslastung maximieren) in den Betrachtungsfokus rücken, wodurch weitere Ereignisattribute erforderlich werden und die Analyse bzw. Diagnose erweitert werden müsste.

Weiterhin wurde von verschiedenen Praxispartnern die Notwendigkeit geäußert, Optionen für die Behebung von erkannten Schwachstellen eines Materialflusssystems möglichst effizient entweder numerisch oder in Form einer Simulation bewerten zu können. Die Ergebnisse der zu diesem Thema derzeit in Arbeit befindlichen Forschungsprojekte können wertvolle Erweiterungsmöglichkeiten für die Online-Materialflussdiagnose sein.

### 5.2 Nutzen und wirtschaftliche Bedeutung für kmU

Die Verfahren dienen allgemein der Materialfluss-Diagnose und einer darauf aufbauenden betriebsbegleitenden Überwachung/Optimierung, ohne Einschränkung auf bestimmte Branchen. Für alle

automatisierten Materialflusssysteme besteht der Bedarf nach Methoden zur Online-Analyse und –Diagnose, auch ohne die Simulation. Die Nutzung des Informationspotenzials in den Ereignisdaten von Materialflusssystemen im Online-Fall

- wird durch die entwickelten Methoden ermöglicht und kann damit eine interessante Alternative zur wartungsaufwendigen betriebsbegleitenden Simulation darstellen.
- wird durch die vielfältigen Analyseregeln und Bewertungsgrößen unabhängig vom Anwendungsfall und von der Datenstruktur gewährleistet (interaktive Oberfläche zur spezifischen Regelerstellung durch Anwender und Transfer in Wissensdatenbank). Durch die überwiegende Konzentration auf die sog. Standard-Ereignisattribute ist der potenzielle Anwenderkreis sehr groß.
- ermöglicht suboptimales Verhalten frühzeitig zu erkennen und nicht nur wie bisher reaktiv eine Fehlerwiederholung für analoge Situationen zu vermeiden. Hierdurch wird der ursprüngliche Anwendungsfokus auf die Unterstützung bei der Simulation auf bereits in Betrieb befindliche komplexe Materialflusssysteme erweitert.

Über den genannten Projektfokus auf die Diagnose von Materialflusssystemen hinaus sind die im Ergebnis entstandenen Verfahren und Methoden zur technischen Analyse sowie zur informationstechnischen Realisierung ebenso für beliebige Systeme außerhalb der Intra-logistik einsetzbar, welche anhand von Log-Files das systeminterne Verhalten protokollieren. So ist zum Beispiel auch die Anwendung bzw. Übertragung auf Produktionssysteme möglich. Auch eine Übertragung spezifischer Ergebnisse in die Auswertung von Daten, welche mittels Radio Frequency Identification Technologie (RFID) gewonnen wurden, ist vorstellbar. Hierzu wird derzeit bei einem Mitglied des projektbegleitenden Ausschusses, der LOGSOL GmbH in Dresden, motiviert durch die Ergebnisse in diesem Forschungsprojekt an einer firmeneigenen Realisierung gearbeitet.

Die untenstehende Zuordnung zu den einzelnen Fachgebieten bzw. Wirtschaftszweigen gemäß Vordruck 4.1.23 und 4.1.24 des „AiF-Leitfadens“ stellt die Breite der möglichen Ergebnisnutzung auf verschiedenen Gebieten zusammenfassend dar.

*Tabelle 8: Nutzen in Fachgebieten und Wirtschaftszweigen*

<b>Fachgebiete</b>	<b>Hauptsächliche Nutzung</b>	<b>Nutzung auch möglich</b>
Produktion	✓	
Mess-, Regel-, Automatisierungstechnik	✓	
Informations- und Kommunikationstechnik		✓
Betriebswirtschaft, Organisation	✓	
<b>Wirtschaftszweige</b>	<b>Hauptsächliche Nutzung</b>	<b>Nutzung auch möglich</b>
Maschinenbau (29)	✓	
Fahrzeugbau (34/35)	✓	
Erbringung von Dienstleistungen (72/74)	✓	

Die Ergebnisse des Forschungsprojektes tragen zur Steigerung der Leistungs- und Wettbewerbsfähigkeit von Unternehmen hinsichtlich der Anwenderkreise in unterschiedlicher Weise bei.

- Betreiber von Materialflusssystemen



Betreiber verfügen derzeit über keine einfache Möglichkeit, ihre Anlagen zu überwachen – geschweige denn die Funktionsgüte zu bewerten. Die Forschungsergebnisse zeigten dass eine Analyse systeminterner Transportprozesse in komplexen Materialflusssystemen machbar ist und Informationen für gezielte operative Maßnahmen liefern kann. Durch die Verfahren können den KMU Probleme und ihre Ursachen innerhalb der Systeme aufgezeigt werden, das Ausmaß der negativen Auswirkungen kann somit zeitnah reduziert werden. Damit können ebenfalls auch Leistungsreserven aufgedeckt werden – wie die SPC-Analyseergebnisse dies zeigen. Diese können dann gezielt genutzt werden, bevor über Neuinvestitionen nachgedacht werden muss. Auch ohne Einsatz der Simulation soll durch die Echtzeitfähigkeit der zu entwickelnden Verfahren den Unternehmen die Möglichkeit gegeben werden, die systeminterne Funktion ihrer Anlage zu verifizieren.

- Beratungsunternehmen

Die zahlreichen KMUs mit den Hauptgeschäftsfeldern Logistikplanung und Logistikberatung erhalten durch das Forschungsprojekt zusätzliches Wissen und Know-how, welches ihre Kompetenz im Bereich Intralogistik verstärkt und damit ihre Wettbewerbsposition verbessert.

Darüber hinaus stellt das entwickelte Konzept für eine Wissensbasis vor allem in dieser Branche ein enormes Potenzial dar. Projektspezifisches bzw. personengebundenes Wissen zur Analyse und Diagnose von Materialflusssystemen innerhalb der Unternehmen wird für alle Mitarbeiter einfacher zugänglich und „wächst“ mit jedem Projekt.

- Anbieter von Softwaresystemen

Anbieter von Softwaresystemen in der Materialflussteuerung können durch die Übernahme der entwickelten Methoden und Verfahren zur Diagnose eine Erweiterung der Funktionalität ihrer Produkte erreichen. Gerade KMU besetzen häufig fachspezifische Nischen in der Softwareentwicklung.

Konkret entwickelt derzeit die LOGSOL GmbH in Dresden (Mitglied des PA) ein Software-Tool, welches mittels Ereignisdaten den innerbetrieblichen Staplerverkehr und dessen Leistung anhand von RFID-Daten bewerten soll. Diese Entwicklung wurde zum Teil durch die Ergebnisse dieses Forschungsprojekt motiviert und greift spezifische Projektergebnisse auf, welche dieser Bericht darstellt.

### 5.3 Transfer der Forschungsergebnisse

Die durchgeführten Maßnahmen wurden in nachfolgender Tabelle zusammengefasst.

*Tabelle 9: Transfermaßnahmen*

Maßnahme	Beschreibung	Zeitraum
Projektbegleitender Ausschuss	ausführliche und fortlaufende Diskussion mit den Vertretern der Unternehmen im projektbegleitenden Ausschuss	fortlaufend

	Wustmann, David ; Schmalzer, Robert ; Schmidt, Thorsten: Relevante Zeitbereiche intralogistischer Datenströme - Grundlagen für die Optimierung im laufenden Betrieb. In: Vojdani, Nina (Hrsg.): 7. Fachkolloquium der Wissenschaftlichen Gesellschaft für Technische Logistik (WGTL), 2011, S. 194-206. - ISBN 978-3-86975-044-6	2011
Veröffentlichung	Schmidt, Wustmann & Schmalzer (2012): Process Analysis for Material Flow Systems. In: Progress in Material Handling Research: 2012	2012
	C. Schwenke, T. Wagner, A. Gellrich, K. Kabitzsch. Event Based Recognition and Source Identification of Transient Tailbacks in Manufacturing Plants, Proceedings of the 2012 Winter Simulation Conference (WSC'2012), Berlin, Dec. 09-12, 2012.	2012
Ansprache weiterer Unternehmen	Gewinnung zur Mitarbeit der Firmengruppe SBS (SBS Dresden GmbH & Co.KG und SBS Metalltechnik GMBH) zur Prüfung der Übertragbarkeit auf Produktionsdaten (aus der BDE)	2011/2012
	Unternehmen aus der Halbleiterfertigung wurden angesprochen (sowohl Hersteller als auch Dienstleister).	fortlaufend
Internetpräsentation	Darstellung des Forschungsvorhabens und der Ergebnisse auf den Internetseiten der Professur Technische Logistik	seit 2011
	Online Veröffentlichung des Abschlussberichtes auf den Seiten der BVL e.V.	Ab 2014
Vorträge	Poster-Präsentation auf dem Material Handling Research Colloquium	Juni 2012
	Poster-Vortrag auf dem Institutskolloquium des Instituts für Technische Logistik und Arbeitswissenschaften	Januar 2013
Beratung von Unternehmen	Beratung von Unternehmen bei der Anwendung der Mess- und Modellierungsmethodik (bspw. LogSol GmbH)	2012 /2013
Übernahme der Ergebnisse in die Lehre	Bereicherung der Lehrveranstaltungen Materialflusstechnik und Logistik sowie Logistik-Simulation	seit 2012
	Verbreitung neuer Technologien durch Absolventen der Professur Technische Logistik; Betreuung von 1 Diplomarbeit und 1 Studienarbeit bei TL	seit 2012
	Aufnahme der Ergebnisse in Pro- und Hauptseminare des Lehrstuhl TIS	seit 2012

#### **5.4 Gewerbliche Schutzrechte**

Im Rahmen dieses Forschungsprojekts wurden gewerbliche Schutzrechte weder erworben noch ist ihre Anmeldung beabsichtigt.

## 6 Beteiligte Forschungsstellen

---

<b>Forschungsstellen</b>	
Technische Universität Dresden Fakultät Maschinenwesen Institut für Technische Logistik und Arbeitsysteme Professur für Technische Logistik (*) 01062 Dresden	Technische Universität Dresden Fakultät Informatik Institut für Angewandte Informatik Professur für Technische Informationssysteme 01062 Dresden
<b>Leiter</b>	
Prof. Dr.-Ing. habil. Thorsten Schmidt Telefon: (0351) 463-32538 <a href="mailto:Thorsten.Schmidt@tu-dresden.de">Thorsten.Schmidt@tu-dresden.de</a>	Prof. Dr.-Ing. habil. Klaus Kabitzsch Telefon: (0351) 463-38289 <a href="mailto:Klaus.Kabitzsch@tu-dresden.de">Klaus.Kabitzsch@tu-dresden.de</a>

---

## 7 Literatur

Anderson & Darling (1954): A test of goodness of fit. In: *Journal of the American Statistical Association*, Bd. 49 (1954), Nr. 268, S. 765–769

Bamberg, Baur & Krapp (2008): *Statistik*. 14. Aufl. München; Wien : Oldenbourg. – ISBN: 9783486585650

Banks, Carson, Nelson & Nicol (2009): *Discrete-Event System Simulation*. 5. Aufl. Prentice Hall. – ISBN: 0136062121, 9780136062127

Bechhofer, van Harmelen, Hendler, Horrocks, McGuinness, Patel-Schneider & Stein (2004): OWL Web Ontology Language Reference. In: W3C Homepage, 2004. [Online]. – URL: <http://www.w3.org/TR/owl-ref> [Accessed: 20-Apr-2012]

Besnard, Cordier & Moinard (2008): Ontology-based inference for causal explanation. In: *Integrated Computer-Aided Engineering*, Bd. 15 (2008), Nr. 4, S. 351–367

Better, Glover & Laguna (2007): Advances in analytics: integrating dynamic data mining with simulation optimization. In: *IBM Journal of Research and Development*, Bd. 51 (2007), Nr. 3, S. 477–487

Bonnans & Shapiro (2000): *Perturbation analysis of optimization problems*. New York : Springer. – ISBN: 0387987053, 9780387987057

Brandau & Tolujew (2010): Logistics Event Management. In: *9./10.. Forschungskolloquium am Fraunhofer IFF*, S. 47–51. Magdeburg

Brandau & Tolujew (2013): Modelling and Analysis of Logistical State Data. In: *Transport and Telecommunication*, Bd. 14 (2013), Nr. 2, S. 102–115

Brandes & Erlebach (2005): *Network analysis: methodological foundations*. Springer. – ISBN: 9783540249795

Bratley, Fox & Schrage (1987): *A guide to simulation*. New York : Springer. – ISBN: 0387964673, 9780387964676

Burns & Wellings (2001): *Real Time Systems and Programming Languages: Ada 95, Real-Time Java and Real-Time C/POSIX*. 3. Aufl. London : Addison Wesley. – ISBN: 0201729881

Chrysler Corporation, Ford Motor Company & General Motors Corporation, Hrsg. (1995): *Statistical Process Control (SPC) - Reference Manual*. Chrysler Corporation, Ford Motor Company and General Motors Corporation, 1995

Croft (1987): Approaches to Intelligent Information Retrieval. In: *Information Processing and Management*, Bd. 23 (1987), Nr. 4, S. 249–254

Dangelmaier, Franke, Mueck & Fischer (2003): Komponenten zur aktiven Unterstützung der Analyse von Materialflusssimulationen in virtuellen Umgebungen. In: 2. *Paderborner Workshop Augmented & Virtual Reality in der Produktentstehung* (Paderborn, 2003), Bd. 123, S. 141–151

Faes (2009): *SPC - Statistische Prozesskontrolle: Eine praktische Einführung in die statistische Prozesskontrolle und deren Nutzung*. 2. Aufl. Norderstedt : Books on Demand GmbH. – ISBN: 3837051560

Fahrmeir, Kneib & Lang (2007): *Regression - Modell, Methoden und Anwendungen*. 2. Aufl. Heidelberg, Berlin : Springer Verlag. – ISBN: 9783540339328

Fishman (2001): *Discrete-event simulation*. New York : Springer. – ISBN: 0387951601, 9780387951607

Gordon & Kemper (2007): *On Clustering Simulation Traces*. In: (Edinburgh, Scotland, UK, 2007)

Günthner, Heinecker & Wilke (2002): Materialflusssysteme für wandelbare Fabrikstrukturen. In: *IN: Industrie Management*, Bd. 18 (2002), Nr. 5

Hanisch, Tolujew & Schulze (2005): Initialization of online simulation models. In: *WSC '05 Proceedings of the 37th conference on Winter simulation* (Orlando, Florida, 2005), S. 1795–1803. – ISBN: 0-7803-9519-0

Herz, Schlichter & Siegener (1993): *Angewandte Statistik für Verkehrs-und Regionalplaner*. Werner

Horridge, Drummond, Goodwin, Rector & Wang (2006): The Manchester OWL Syntax. In: *OWL Experiences and Directions Workshop (OWLED'06) at the ISWC'06* (Athens (USA), 2006)

James, Drijard, Roos, Sadoulet & Eadie (2006): *Statistical methods in experimental physics (2nd Edition)*. Singapore : World Scientific. – ISBN: 9789812567956

Jedermann, Lorenz, Gehrke & Lang (2006): Realisierung lokaler Selbststeuerung in Echtzeit - Der Übergang zum intelligenten Container. In: *Wissenschaft und Praxis im Dialog. Steuerung von Logistiksystemen - auf dem Weg zur Selbststeuerung* (2006), S. 145–166 (3. Wissenschaftssymposium in Dortmund)

Kemper & Tepper (2005): Trace based analysis of process interaction models. In: *Proceedings of the 37th conference on Winter simulation* (Orlando, Florida, 2005), S. 427–436. – ISBN: 0-7803-9519-0

Kemper & Tepper (2007): Automated Analysis of Simulation Traces - Separating Progress from Repetitive Behavior. In: *Proceedings of the Fourth International Conference on Quantitative Evaluation of Systems*, S. 101–110. – ISBN: 0-7695-2883-X. – DOI: 10.1109/QEST.2007.9

Kemper & Tepper (2009): Automated Trace Analysis of Discrete-Event System Models. In: *IEEE Transactions on Software Engineering*, Bd. 35 (2009), Nr. 2, S. 195–208. – DOI: 10.1109/TSE.2008.75

Kleijnen (1974): *Statistical techniques in simulation*. Bd. 1 (Marcel Decker Inc.). – ISBN: 082476157X

Klöpfer (2009): *Online-Optimierung: Was kostet es, die Zukunft nicht zu kennen?* Newsletter. Heinz Nixdorf Institut; Wirtschaftsinformatik, insbesondere CIM (Newsletter der Fachgruppe)

Kopetz (1998): *Real-time systems*. second print. Aufl. Norwell, Massachusetts : Kluwer Academic Publishers. – ISBN: 0792398947, 9780792398943

Lasch & Schulte (2009): *Quantitative Logistik-Fallstudien: Aufgaben und Lösungen zu Beschaffung, Produktion und Distribution Mit Planungssoftware auf CD-ROM*. 3. Aufl. Wiesbaden : Gabler Verlag

Law & Kelton (2000): *Simulation Modeling and Analysis*. 3. Aufl. McGraw-Hill Higher Education. – ISBN: 0070592926

Lemaignan, Siadat, Dantan & Semenenko (2006): MASON: A Proposal For An Ontology Of Manufacturing Domain. In: *Proceedings of the IEEE Workshop on Distributed Intelligent Systems: Collective Intelligence and Its Applications* (Prague, 2006), S. 195–200. – DOI: 10.1109/DIS.2006.48

Mahajan & Ingalls (2004): Evaluation of methods used to detect warm-up period in steady state simulation. In: *Proceedings of the 2004 Winter Simulation Conference*, hrsg v. Ingalls, Rossetti, Smith & Peters, S. 663–671. – ISBN: 0780387864

Melançon & Herman (1998): Circular Drawings of Rooted Trees. *Reports of the National Research Institute for Mathematics and Computer Science Amsterdam (NL)*

Merdan, Koppensteiner, Hegny & Favre-Bulle (2008): Application of an ontology in a transport domain. In: *2008 IEEE International Conference on Industrial Technology* (April 2008), S. 1–6. – DOI: 10.1109/ICIT.2008.4608572

Mönch, Stehli & Zimmermann (2003): FABMAS: An Agent-Based System for Production Control of Semiconductor Manufacturing Processes. In: *Holonic and Multi-Agent Systems for Manufacturing. Lecture notes in computer science : Lecture notes in artificial intelligence (2744)* (Berlin, Heidelberg, 2003), hrsg v. Mařík, S. 258–267. – ISBN: 978-3-540-40751-5

Montgomery (2005): *Introduction to statistical quality control*. Hoboken, N.J. : John Wiley. – ISBN: 0471656313 9780471656319 0471661228 9780471661221

Morbach (2009): *A Reusable Ontology for Computer-Aided Process Engineering*. Aachen : RWTH Aachen

Mosler & Schmid (2008): *Wahrscheinlichkeitsrechnung und schliessende Statistik*. 3. Aufl. Berlin; Heidelberg : Springer. – ISBN: 9783540778585 3540778586

Murray & Grubestic (2007): *Critical Infrastructure - Reliability and Vulnerability*. Berlin, Heidelberg, New York : Springer. – ISBN: 978-3-540-68055-0

Nakayama (2006): *Output analysis for simulations*. In: (Monterey, California, 2006), S. 36–46. – ISBN: 1-4244-0501-7

Neumann & Tomé (2007): *Wissensmanagement in der Logistik: Standortbestimmung und Potenzialanalyse*. In: (2007), S. 293–297 (Jahrbuch Logistik 2007)

Page & Liebert (1991): *Diskrete Simulation: Eine Einführung mit Modula-2*. Springer. – ISBN: 3540544216

Pfüller (2008): *Echtzeitsystemtechnik*. Vorlesung, Universität Rostock

Robinson (2002): A statistical process control approach for estimating the warm-up period. In: *Proceedings of the 2002 Winter Simulation Conference*, hrsg v. Yücesan, Chen, Snowdon & Charnes, Bd. 1, S. 439–446. – ISBN: 0780376145

Robinson (2007): A statistical process control approach to selecting a warm-up period for a discrete-event simulation. In: *European Journal of Operational Research*, Bd. 176 (2007), Nr. 1, S. 332–346

Rokach & Hutter (2012): Automatic discovery of the root causes for quality drift in high dimensionality manufacturing processes. In: *Journal of Intelligent Manufacturing*, Bd. 23 (2012), Nr. 5, S. 1915–1930. – DOI: 10.1007/s10845-011-0517-5

Rubinstein (1989): Sensitivity analysis and performance extrapolation for computer simulation models. In: *Oper. Res.*, Bd. 37 (1989), Nr. 1, S. 72–81

Schenk, Tolujew, Barfus & Reggelin (2007): Grundkonzepte zu logistischen Echtzeitsystemen: Monitoring, Event Management und Frühwarnung. In: *Jahrbuch Logistik 2007*, S. 222–226. Korschbroich, free beratung GmbH. – ISBN: 3-9809412-3-X

Schlittgen & Streitberg (2001): *Zeitreihenanalyse*. Oldenbourg Wissenschaftsverlag. – ISBN: 3486257250

Schruben (1982): Detecting initialization bias in simulation output. In: *Operations Research* (1982), S. 569–590

Schruben, Singh & Tierney (1983): Optimal tests for initialization bias in simulation output. In: *Operations Research*, Bd. 31 (1983), Nr. 6, S. 1167–1178

Schwenke, Wagner, Gellrich & Kabitzsch (2012): Event-based recognition and source identification of transient tailbacks in manufacturing plants. In: *Proceedings of the 2012 Winter Simulation Conference (WSC)* (Berlin, Germany, 2012), S. 1–12. – DOI: 10.1109/WSC.2012.6465013

Steven & Krüger (2003): Supply Chain Management für globale Logistikprozesse: Charakteristika, konzeptionelle Bestandteile und deren Umsetzung in Informationssysteme. In: *Logistik Management - Prozesse, Systeme, Ausbildung*, hrsg v. Spengler, Voss & Kopfer, S. 179–195. Heidelberg : Physica Verlag



- Struss & Ertl (2009): *Post-mortem Diagnosis of Bottling Plants Based on Recorded Data*. In: (Barcelona, 2009). – ISBN: 978-3-902661-46-3
- Taylor & D’Este (2007): Transport network vulnerability: a method for diagnosis of critical locations in transport infrastructure systems. In: *Critical infrastructure reliability and vulnerability*, hrsg v. Murray & Grubestic, S. 9–30. Berlin, New York : Springer Verlag (Advances in spatial science)
- Tinkl (2008): On the value of information lookahead in online programming. In: *International Conference Operations Research 2008 - OR and Global Business* (University Augsburg, Germany, 2008), S. 207–208
- Tolujew, Reggelin & Sermpetzoglou (2007): Simulation und Interpretation von Datenströmen in logistischen Echtzeitsystemen. In: *Management komplexer Materialflüsse mittels Simulation: State-of-the-Art und innovative Konzepte*, S. 215–231. 1. Aufl. Wiesbaden : Springer
- Venkatasubramanian, Rengaswamy, Yin & Kavuri (2003): A review of process fault detection and diagnosis: Part I: Quantitative model-based methods. In: *Computers & Chemical Engineering*, Bd. 27 (2003), Nr. 3, S. 293–311. – DOI: 10.1016/S0098-1354(02)00160-6
- Wegscheider (1993): *Hierarchische Trends*. Hamburg : Habilitationsschrift. Universität Hamburg (1993)
- Western Electric Company (1956): *Statistical quality control handbook*. Indianapolis : Western Electric Co.
- Wiendahl (2002): Messung der Leistungsfähigkeit logistischer Systeme. In: *Handbuch Logistik*, hrsg v. Arnold, Isermann, Kuhn & Tempelmeier, S. A1.22 – A1.32. Berlin, Heidelberg, New York : Springer. – ISBN: 3-540-41996-9
- Wilke (2008): Control concept for autonomous changeable material flow systems. In: *Logistics Journal*, Bd. 1 (2008), S. 1–6
- Wölker (2000): *Analyse logistischer Systeme mit selbstorganisierenden Merkmalskarten*. Dissertation, Universität Dortmund, Fakultät Maschinenwesen
- Wustmann, Vasyutynskyy & Schmidt (2009): Ansätze zur automatischen Analyse und Diagnose von komplexen Materialflusssystemen. In: *5. Fachkolloquium der Wissenschaftlichen Gesellschaft für Technische Logistik (WGTL) 2010* (Ilmenau, 2009), hrsg v. Scheid, S. 1–20. – ISBN: 978-3-939473-56-5
- Wustmann, Vasyutynskyy & Schmidt (2010): *Diagnose und Optimierung von Materialflussteuern*. Forschungsbericht zu 15770. Bundesvereinigung Logistik e. V. (BVL) im Auftrag der Arbeitsgemeinschaft industrieller Forschungsvereinigungen „Otto-von-Guericke“ e. V. (AiF)

## 8 Glossar

Begriff	Erläuterung
Anomalie	Abweichung vom Normal- bzw. Optimalfall (in beide Richtungen möglich); z.B. Stau, temporäre Blockierung im Kreuzungsbereich, Unter- oder Überlast, etc.
Anomalie-Ereignis(se)	Identifizierte Anomalie, beschrieben durch die entsprechenden Ereignisse, eine Anomalie auf der Kante $k(i; i+1)$ wird demnach durch das Ereignis an $i+1$ dargestellt.
Bewegte Objekte	Objekte oder Objektgruppen des Systems, welche nicht ortsgebunden sind; z.B. Fördergüter, etc.
Ereignisattribut	Information zum Ereignis; z.B. Zeitstempel, Ereignisort, Identifikationsnummer des Fördergutes, Gewicht des Fördergutes, Ziel/ Herkunft des Fördergutes, etc.
Ereignisort	Ort an dem das Ereignis stattgefunden hat, im Graphen sind die Ereignisorte durch Knoten repräsentiert, d.h. Ereignisort = Knoten
Fördergut / Load	Zu transportierendes Gut im System; z.B. Palette, Koffer, Produkt, Brief, etc.
Fördergutbezogen / load-bezogen	Sicht auf ein Fördergut, Verfolgung des Fördergutes durch das System
Knoten-Kanten-Modell (KKM)	Graph zur Modellierung der Beziehungsrelationen zwischen den Ereignisorten, die <b>Kanten</b> sind <b>zeitbehaftet</b>
Knowledge Discovery in Databases (KDD)	Erkenntnisgewinnung aus Datenbeständen
positionsbezogen	Sicht auf ein stationäres Objekt
Schwachstelle	Anomalie
Stationäre Objekte	Objekte oder Objektgruppen des Systems, welche ortsgebunden sind; z.B. Knoten, Kanten, etc.
strukturbezogen	Sicht (topologisch) auf das System bzw. den Graphen
Zustands-Übergangs-Modell (ZÜM)	Graph zur Modellierung der Beziehungsrelationen zwischen den Ereignisorten, die <b>Zustände</b> (entsprechen den Knoten im KKM) sind <b>zeitbehaftet</b>

## 9 Symbole, Objekte und Kenngrößen

### Allgemeine

$h$	Batch	Batches der Zeitreihe der betrachteten Kenngröße, gebildet durch das Batch-mittelwertverfahren $h \in H$
$H$	Menge von Batches	Menge der Batches $h$ mit $ H $ - Mächtigkeit der Menge $H$ ( $ H =b$ )
$J$	Klassenzahl	Klassenzahl für den <i>Chiquadrat-Anpassungstest</i> mit den Klassen ( $A1; \dots; AJ$ )
$k$	Batchgröße	Länge eines Batches
$\sigma_z$	Sigma-Kontrollgrenze	Sigma-Kontrollgrenze mit $z=1;2;3$
$\mu_h$	Batchmittelwert	Mittelwert eines Batches $\mu_h \in \bar{Y}$
$\hat{\mu}$	Mittelwert der Batchreihe	Mittelwert der Batchmittelwerte für $\bar{Y}$
$\hat{\rho}$	Standardabweichung	Standardabweichung der Batchmittelwerte für $\bar{Y}$
$G(I,K,A)$	Graph	Gerichteter, attributierter Graph, $I$ - Knotenmenge; $K$ – Kantenmenge; $A$ - Attributmenge
$QS$	Quelle-Senke-Relationen	Menge der Quelle-Senke-Beziehungen, welche von Fördergütern $fg$ „genutzt“ werden; $QS'$ für wegfallende Quelle-Senke-Relationen bei Ausfall einer Kante $k$ / eines Knotens $i$ ; $QS; QS' \in \mathcal{N}^+$
$T$	Betrachtungszeitraum	Betrachter Zeitraum im Gesamtzeitraum $T_{ges}$ ; $T \in T_{ges}$
$t(e)$	Zeitstempel	Zeitpunkt des Ereignisses $e$ ; $t(e) \in T$
$t_{akt}$	Betrachtungszeitpunkt	Aktueller Messpunkt im Betrachtungsraum $T$ ; $t_{akt} \in T$
$T_{ges}$	Gesamtzeitraum	Gesamter in den Daten vorliegender Zeitraum; $T_{ges} \in \mathcal{R}^+$ $ T_{ges} $ - Mächtigkeit der Menge $T_{ges}$
$Y_i$	Ereignis	Ereignis im Betrachtungszeitraum $T$ ; $Y_i \in Y$
$Y$	Ereignisvektor	Ereignisvektor im Betrachtungszeitraum $T$ ; $Y \in \mathcal{N}^+$
$\bar{Y}$	Reihe der Batchmittelwerte	

Objekte		
fg	FörderGut	Fördergut; $fg \in FG$
FG	Fördergut- menge	Menge an Fördergütern $fg$ ; $FG \in \mathcal{N}^+$
fgTyp	FördergutTyp	Typ des Fördergutes $fg$ , z.B. Produktgruppe, Leerbehälter, etc. (ist meist in der Fördergut-ID enthalten); $fgTyp \in \mathcal{N}^+$
i	Knoten	Repräsentiert im Graphen den Ort des Ereignisses, d.h. Knoten = Ereignisort, mit $i+I$ als direkte Nachfolgerknoten von $i$ ; $i \in I$
I	Knotenmenge	Menge an Knoten $i$ ; $I \in \mathcal{N}^+$
k	Kante	Direkte Verbindung zwischen Knoten $i$ und Knoten $i+I$ im Graphen (auch mit $k(i; i+I)$ bezeichnet); $k \in K$
K	Kantenmenge	Menge an Kanten $k$ ; $K \in \mathcal{N}^+$
kp(q;s)	Kürzester Pfad	SystemPfad $sp_x$ von einer Quelle $q$ zu einer Senke $s$ mit der geringsten Nutzungsdauer $minND(p(q;s))$ ; $kp(q;s) \in KP$
KP	Menge Kürzes- ter Pfade	Menge der Kürzesten Pfade zwischen allen in den Daten vorhandenen Quelle-Senke-Relationen $QS$ ; $KP'$ für wegfallende kürzeste Wege bei Ausfall einer Kante $k$ / eines Knotens $i$ ; $KP; KP' \in SP$
$p_x$	Pfad	Verbindung aus mehreren Kanten $k$ zwischen Knoten $i$ und Knoten $j$ im Graphen, auch mit $p_x(i;j)$ bezeichnet; mit $j=i+n$ für $n>1$ und $x$ für Wegalternativen; $p_x \in P$
P	Pfadmenge	Menge an Pfaden $p_x$ ; $P \in \mathcal{N}^+$
q	Quelle	Knoten im Graphen, welcher Systemquelle ist, es gilt $G^+(i=q)=0$ und $FgZ_T. ges(i=q) >> I$ ; $q \in I$
s	Senke	Knoten im Graphen, welcher Systemsenke ist, es gilt $G^-(i=s)=0$ und $FgZ_T. ges(i=s) >> I$ ; $s \in I$
$sp_x$	SystemPfad	Verbindung aus mehreren Kanten $k$ zwischen Quelle $i=q$ und Senke $j=s$ im Graphen, auch mit $sp_x(q;s)$ bezeichnet; mit $x$ für Wegalternativen $sp_x \in SP$
SP	Systempfad- Menge	Menge an SystemPfadern $sp_x$ ; $SP \in P$

Kenngrößensystem für Standardattribute

$\sigma_T$	Standard- abweichung	Standardabweichung einer Kenngröße im Betrachtungszeitraum $T$ ; $\sigma_T \in \mathcal{R}^+$
$Ai(i)$	Hansenindex	Erreichbarkeit des Knotens $i$ im Netzwerk; $Ai \in \mathcal{R}^+$
$AG_T()$	Anomalie- Gehalt	Verhältnis identifizierter Anomalien zur Anzahl möglicher Anomalien für ein Fördergut $fg$ , eine Gruppe von Fördergütern des Typs $fgTyp$ eine Kante $k$ , einen Pfad $p_x$ oder Systempfad $sp_x$ im Betrachtungszeitraum $T$ ; $AG_T() \in \mathcal{R}^+$
$AZ_T()$	AnomalieZahl	Anzahl von identifizierten Anomalien auf einer Kante $k$ oder einem Pfad $p_x$ im Betrachtungszeitraum $T$ ; $AZ_T() \in \mathcal{N}^+$
$amw_T()$	arithmet. Mittelwert	Arithmetisches Mittel einer Kenngröße im Betrachtungszeitraum $T$ ; $mw_T() \in \mathcal{R}^+$
$DLZ()$	Durchlaufzeit	Durchlaufzeit eines Fördergutes $fg$ ; $DLZ(fg) = ZIS(fg,s) \in \mathcal{R}^+$
$fgZ_T()$	Fördergut-	Zähler für Fördergüter $fg$ je Knoten $i$ , je Kante $k$ je Pfad $p_x$ oder je Sys-

	Zähler	tempfad $sp_x$ für den Betrachtungszeitraum $T$ ; $fgZ_T() \in \mathcal{N}^+$
G(i)	KnotenGrad	Anzahl der ein- und ausgehenden Kanten an einem Knoten $i$ ; $G(i) \in \mathcal{N}^+$
$G^-(i)$	Ausgangs-KnotenGrad	Anzahl ausgehender Kanten $k$ von einem Knoten $i$ ; $G^-(i) \in \mathcal{N}^+$
$G^+(i)$	Eingangs-KnotenGrad	Anzahl eingehender Kanten $k$ an einem Knoten $i$ ; $G^+(i) \in \mathcal{N}^+$
$KL_T(k)$	KantenLast	Anzahl der Fördergüter $fg$ welche sich im Betrachtungszeitraum $T$ (statistischer Wert) auf einer Kante $k$ befinden; $KL(k) \in \mathcal{N}^+$
$KL_{takt}(k)$	KantenLast	Anzahl der Fördergüter $fg$ welche sich zum Betrachtungszeitpunkt $t^{akt}$ (absoluter Wert) auf einer Kante $k$ befinden; $KL(k) \in \mathcal{N}^+$
$K_{zent}(k)$	Kanten-zentralität	Häufigkeit des Vorkommens einer Kante $k$ in kürzesten Wegen für alle Quelle-Senke-Relationen; $K_{zent} \in \mathcal{N}^+$
LI()	LeistungsIndex	Quotient aus Optimal- oder Normalwert zum tatsächlichen Wert einer Kenngröße; $LI() \in \mathcal{R}^+$ mit $LI()=[0,1]$ ; Bsp. $LI(ND(k)) = \frac{\min_T ND(k)}{ND(k)}$
$med_T()$	Median	Zentralwert einer Kenngröße im Betrachtungszeitraum $T$ ; $med_T() \in \mathcal{R}^+$
$min_T()$ $max_T()$	Minimum/ Maximum	Minimal-/ Maximal-Wert einer Kenngröße für den Betrachtungszeitraum $T$ ; $min_T() \in \mathcal{R}^+$ , $max_T() \in \mathcal{R}^+$
$mod_T()$	Modus	Häufigster Wert einer Kenngröße im Betrachtungszeitraum $T$ ; $mod_T() \in \mathcal{R}^+$
ND()	NutzungsDauer	Nutzungsdauer eines Fördergutes $fg$ für eine Kante $k$ , einen Pfad $p_x$ oder Systempfad $sp_x$ ; $ND() \in \mathcal{R}^+$
$NW_T()$	Normalwert	Normalwert einer Kenngröße im Betrachtungszeitraum $T$ ; $NW_T() \in \mathcal{R}^+$
$OB'_T()$	Grenzen des Optimalbereichs	Obere ( $OB^+_T$ ) bzw. untere Grenze ( $OB^-_T$ ) des Optimalbereichs einer Kenngröße im Betrachtungszeitraum $T$ ; $OB'_T() \in \mathcal{R}^+$
$NB_T()$	Normalbereich	normaler Wertebereich ( $NB_T()$ ) einer Kenngröße für den Betrachtungszeitraum $T$ ; $OB_T() \in \mathcal{R}^+$
$OW_T()$	Optimalwert	Optimaler Wert einer Kenngröße im Betrachtungszeitraum $T$ ; $OW_T() \in \mathcal{R}^+$
$qmw_T()$	quadrat. Mittelwert	Quadratisches Mittel einer Kenngröße im Betrachtungszeitraum $T$ ; $mw_T() \in \mathcal{R}^+$
$R_T()$	Spannweite	Statistisches Streuungsmaß (engl. Range), Distanz zwischen dem größten und dem kleinsten Wert einer Kenngröße im Betrachtungszeitraum $T$ ; $R_T() \in \mathcal{R}^+$
$TA_T()$	Transport-Anteil	Verhältnis „wegfallender Fördergüter“ $fgZ_T()$ (bei Wegfall der Kante $k$ oder des Knotens $i$ ) zur Gesamtzahl der Fördergüter $fgZ_T$ , ohne Berücksichtigung von Wegalternativen; $TA_T() \in \mathcal{R}^+$ mit $TA_T()=[0,1]$
$vark_T()$	Variationskoeffizient	Relative Standardabweichung einer Kenngröße für den Betrachtungszeitraum $T$ ; $vark_T() \in \mathcal{R}^+$
x	Index für Alternativen	Der Index $x$ einer Kenngröße bezeichnet eventuelle Alternativ-Werte einer Kenngröße, z.B. für alternative Pfade usw. (wird zum Zweck der Übersichtlichkeit im Text häufig weggelassen); $x \in \mathcal{N}^+$
Z()	Kanten-(Knoten-) Zentralität	Verhältnis „wegfallender Kürzester Pfade“ (bei Wegfall der Kante $k$ oder des Knotens $i$ ) zur Menge aller Kürzester Pfade $KP$ ; $Z() \in \mathcal{R}^+$ mit $Z()=[0,1]$
$ZAZ(fg,i)$	Zwischen-AnkunftsZeit	Zeitlicher Abstand des Fördergutes $fg$ zum Vorgänger-Fördergut ( $fg-I$ ) am Knoten $i$ ; $ZAZ(fg,i) \in \mathcal{R}^+$
$ZB_T$	Zeitbereich	Minimale Zeitbereiche je Kante $k(i,i+1)$ der Größe $minZAZ$ als Basis für das

(minZAZ) nach minZAZ		Binärsystem der Fördergut-Registrierung für den Betrachtungszeitraum $T$ ; nur ein Fördergut kann am Messpunkt $(i+1)$ jeweils registriert werden; $ZB_T(\text{minZAZ}) \in \mathcal{R}^+$
ZB(k)	(Nutzphasen) Zeitbereich	Zeitbereiche in den die Kante $k$ unterteilt wurde um die Nutzungsphasen für den Betrachtungszeitraum $T$ zu bestimmen; setzt sich aus mehreren $ZB_T(\text{minZAZ})$ zusammen; $ZB(k) \in \mathcal{R}^+$
ZiS(fg,i)	ZeitImSystem	Zeit in der sich das Fördergut $fg$ am Knoten $i$ im System befindet; $ZiS(fg,i) \in \mathcal{R}^+$