



Carl von Ossietzky Universität Oldenburg

Fakultät II – Informatik, Wirtschafts- und Rechtswissenschaften
Department für Informatik

***Prognoseverfahren für den elektrischen
Lastgang in maritimen Containerterminals***

Von der Fakultät für Informatik, Wirtschafts- und Rechtswissenschaften der Carl von Ossietzky
Universität Oldenburg zur Erlangung des Grades und Titels eines

Doktors der Naturwissenschaften (Dr. rer. nat)

angenommene Dissertation von

Norman Ihle, M.Sc.
geboren am 23.10.1980 in Hoya/Weser

Gutachter:

Prof. Dr.-Ing. Axel Hahn

Universität Oldenburg

Department für Informatik, Abteilung Systemanalyse und -optimierung

Weiterer Gutachter:

Prof. Dr. Sebastian Lehnhoff

Universität Oldenburg

Department für Informatik, Abteilung Energieinformatik

Tag der Disputation: 04. Oktober 2018

Zusammenfassung

Die Prognose des elektrischen Lastgangs wird in der Wissenschaft schon seit geraumer Zeit untersucht und verschiedenste Ansätze aus dem Bereich der Zeitreihenanalyse oder aus dem Bereich der Künstlichen Intelligenz wurden mit der Zeit entwickelt und publiziert. Den meisten Verfahren ist dabei gemein, dass sie für die Anwendung in elektrischen Netzen oder Teilnetzen mit einer Vielzahl von Verbrauchern entwickelt und getestet wurden. Mit dem Aufkommen von Demand Response und Demand Side Management in modernen Energiesystemen bekommt die kurzfristige Lastgangprognose (engl.: Short-Term Load Forecasting, kurz: STLF) für sogenannte Microgrids und für einzelne große Letztverbraucher einen erhöhten Stellenwert. Für Industriebetriebe und Logistiksysteme, die im Rahmen eines betrieblichen Energiemanagements und der Teilnahme an Demand-Side-Management-Maßnahmen ihren zukünftigen Verbrauch prognostizieren wollen, erscheint es vielversprechend, das Wissen über die eigenen geplanten Betriebsabläufe des nächsten Tages in den Prognoseprozess zu integrieren. Moderne Seehafencontainerterminals, als Beispiel für Logistiksysteme an der Schnittstelle zwischen maritimen und landgebundenen Verkehrsnetzwerken, haben inzwischen einen überwiegenden Teil ihrer Umschlagprozesse elektrifiziert. Die Planung der Betriebsprozesse der Terminals basiert in großen Teilen auf der Liste der Schiffsankünfte und -abfahrten und den damit verbundenen Containerumschlägen pro Schiff.

Die vorliegende Arbeit untersucht systematisch, wie die geplanten Betriebsdaten eines maritimen Containerterminals in verschiedene Lastgangprognoseverfahren integriert werden können. Dazu werden Ansätze aus dem Bereich der Zeitreihenanalyse, der Künstlichen Intelligenz und der Simulation betrachtet. Zusätzlich wird ein eigener Ansatz entwickelt, der die Methoden des Fallbasierten Schließens (engl.: Case-Based Reasoning) aufnimmt. Fallbasiertes Schließen, ein maschinelles Lernverfahren aus der Klasse der Lazy Learner, nutzt Domänenwissen während des Prognoseprozesses und benötigt eine entsprechende Modellierung.

Die Integration des Wissens über die zukünftigen Betriebsabläufe kann direkt aus den Schiffslisten oder nach einer Generierung eines Containerumschlagprofils erfolgen. Zudem können Kontextinformationen zu Wetterbedingungen und kalendarische Informationen für den Prognoseprozess auf unterschiedliche Weise genutzt werden. Sowohl die Auswirkungen der Wissensintegration als auch die Prognoseergebnisse der einzelnen Ansätze werden anhand einer Fallstudie miteinander verglichen. Neben der Prognosegüte werden auch Kriterien wie die Übertragbarkeit oder die Nachvollziehbarkeit der Ansätze betrachtet. Es kann gezeigt werden, dass die Integration von Wissen über die zukünftigen Betriebsprozesse eines Containerterminals die Prognosegüte erhöhen und insbesondere eine Prognose mittels Künstlicher Neuronaler Netze bessere Ergebnisse erzeugt als naive Methoden. Künstliche Neuronale Netze benötigen aber eine große Anzahl historischer Daten und sind damit nicht kurzfristig anpassbar an sich ändernde Gegebenheiten. Die Fallbasierte Lastgangprognose hat hingegen Vorteile bei der Nachvollziehbarkeit und Anpassbarkeit der Prognoseerstellung, während die Simulation neben der Lastgangprognose auch noch das Testen von verschiedenen Betriebsstrategien und deren Auswirkungen auf den Lastgang ermöglicht.

Abstract

The forecasting of the electrical load curve has been investigated in science for quite some time and various approaches from the field of time series analysis or from the field of artificial intelligence have been developed and published over time. Most methods have in common that they have been developed and tested for use in electrical networks or sub-networks with a large number of consumers. With the emergence of Demand Response and Demand Side Management in modern energy systems, short-term load forecasting (STLF) is becoming increasingly important for microgrids and individual end users with high consumption patterns. For industrial companies and logistics systems that want to forecast their future consumption within the framework of operational energy management and participation in demand side management measures, it seems promising to integrate knowledge of their own planned operating procedures for the next day into the forecasting process. Modern seaport container terminals, as an example of logistics systems at the interface between maritime and land-based transport networks, have meanwhile electrified a large part of their handling processes. The planning of operational processes of the terminals is largely based on the list of ship arrivals and departures and the associated container transshipment per ship.

This thesis systematically examines how the planned operating data of a maritime container terminal can be integrated into various load curve forecasting procedures. For this purpose, approaches from the fields of time series analysis, artificial intelligence and simulation are considered. Additionally, a new approach is developed and presented that is based on Case-Based Reasoning (CBR) methods. CBR as a lazy learner utilizes domain knowledge during the forecasting process and requires appropriate modeling.

The integration of knowledge about future operations can be done directly from the ship lists or after the generation of a container handling profile. In addition, contextual information on weather conditions and calendar information can be used in the forecasting process in different ways. Both the effects of knowledge integration and the forecast results of the individual approaches are compared using a case study. In addition to the quality of the forecast, criteria such as the transferability or comprehensibility of the approaches are also considered. It can be shown that the integration of knowledge about the future operating processes of a container terminal increases the forecasting quality and in particular a forecast using artificial neural networks produces better results than naive methods. Artificial neural networks, however, require a large amount of historical data and are therefore not adaptable to changing conditions at short notice. The case-based load curve forecast, however, has advantages in the traceability and adaptability of the forecast generation, while the simulation also enables the testing of various operating strategies and their effects on the load curve in addition to the load curve forecast.

Inhaltsverzeichnis

1 Einleitung.....	1
1.1 Motivation.....	2
1.2 Problemstellung.....	6
1.3 Ziel der Arbeit.....	16
2 Grundlagen.....	18
2.1 Prognose von Zeitreihen.....	18
2.2 Lastgangprognose im energiewirtschaftlichen Kontext.....	19
2.3 Methoden der Lastgangprognose.....	22
2.4 Fallbasiertes Schließen.....	30
2.5 Lastgangprognose als Prozess.....	37
2.6 Bewertung von Lastgangprognoseverfahren.....	38
3 Verwandte Arbeiten.....	42
3.1 Lastgangprognoseverfahren.....	42
3.2 Energetische Prozesse in Containerterminals.....	44
3.3 Fallbasiertes Schließen in der Energiedomäne.....	47
3.4 Fallbasiertes Schließen für die Prognose von Zeitreihen.....	50
4 Untersuchungen des Lastverhaltens eines Containerterminals.....	53
4.1 Meteorologische Einflüsse.....	53
4.2 Kalendarische Einflüsse.....	55
4.3 Einfluss der Betriebsprozesse	56
4.4 Langfristige Entwicklungen.....	58
4.5 Zusammenfassung.....	60
5 Konzepte für die Lastgangprognose maritimer Containerterminals.....	61
5.1 Betriebsdaten eines Containerterminals und deren Vorverarbeitung.....	61
5.2 Vergleichstagverfahren.....	70
5.3 Fallbasierte Lastgangprognose.....	71
5.4 Zeitreihenanalyse.....	92
5.5 Künstliche Neuronale Netze.....	99
5.6 Simulation.....	108
5.7 Zusammenfassung.....	116
6 Evaluation am Fallbeispiel Container Terminal Altenwerder.....	118
6.1 Umsetzung.....	118
6.2 Studie 1: Effekte der Wissensintegration.....	128
6.3 Studie 2: Prognosegüte.....	136
6.4 Studie 3: Effizienz und Robustheit.....	145
6.5 Zusammenfassende Bewertung	153
7 Rekapitulation und Ausblick.....	156

7.1 Rekapitulation.....	156
7.2 Ausblick.....	160
Anhang.....	162
A) Monatliche Prognoseergebnisse je Verfahren.....	162
B) Für die Implementierung genutzte Komponenten.....	165
Abkürzungsverzeichnis.....	166
Glossar.....	169
Abbildungsverzeichnis.....	175
Tabellenverzeichnis.....	177
Literaturverzeichnis.....	178

1 Einleitung

Die Dezentralisierung der Energieversorgung ist in Deutschland in vollem Gange. Mit dem Projekt Energiewende wird die Stromerzeugung auf Basis erneuerbarer Energien in Deutschland gefördert und nimmt inzwischen einen wesentlichen Anteil am Energiemix ein. Die neuen Kraftwerke sind dabei, zumindest aus traditioneller Sicht, klein dimensioniert und werden in verschiedenen Ebenen von elektrischen Netzen angeschlossen. Die Erzeugung von Strom mit Solar- und Windkraftwerken basiert dabei auf nicht beeinflussbaren Faktoren wie Sonneneinstrahlung oder Windgeschwindigkeit und ist derzeit nur sehr beschränkt steuerbar. Dies stellt vor allen Dingen die Netzbetreiber vor große Herausforderungen. Die Netze müssen die erzeugte Energie aufnehmen und auch bei schwankender Einspeisung über Netzebenen hinweg eine möglichst gleichbleibende Spannung aufrechterhalten. Zudem kommt zu dem Projekt Energiewende auch noch vermehrt das Projekt Verkehrswende hinzu, bei dem der Verkehr von Antrieben mit Verbrennungstechnik auf Antriebe mit batterie-elektrischem Antriebsstrang umgestellt wird. Auch dieses hat Auswirkungen auf die Stromnetze, die sich mit den Elektrofahrzeugen auf eine weitere, nur bedingt steuerbare Abnehmergruppe, einstellen müssen. Die flächendeckende Elektromobilität eröffnet aber auch Chancen für neue Vermarktungsstrategien und auch für die Integration der regenerativen Stromerzeugung.

Chancen bieten sich zusätzlich auch aus Sicht der Verbraucher. Stromversorger können zukünftig variabelere Tarife anbieten und ein aktives Energiemanagement auf Verbraucherseite fördern. Zudem können weitere Vergünstigungen oder Prämien angeboten werden, wenn der Verbraucher seine lokalen Speicherkapazitäten, welche sich unter anderem mit E-Fahrzeugen ergeben, dem Netzbetreiber zur Verfügung stellt oder einzelne Verbraucher durch den Netzbetreiber steuern lässt. Die zunehmende Digitalisierung unterstützt hier bei der Umsetzung entsprechender Konzepte. Ein wesentlicher Faktor für die Integration der Verbraucher in den Energiemarkt auf diesem Wege ist die Kenntnis des zu erwartenden Energiebedarfes und dessen Verlauf über die Zeit. Die Prognose des elektrischen Lastverlaufs (die sogenannte Lastgangprognose) stellt dabei die Grundlage sowohl für Beschaffungsentscheidungen für Lieferanten als auch für die Durchführung von Maßnahmen im Sinne eines aktiven Energiemanagements. Während es früher ausreichend war, den Lastgang eines Netzes oder eines Netzabschnittes zu prognostizieren, gewinnt die Prognose von Einzelverbrauchern zunehmend an Bedeutung [SR14].

Diese Arbeit beschäftigt sich mit der Lastgangprognose eines einzelnen Industriebetriebes aus der Logistikbranche. Mit der Einführung von Elektromobilität in Industriebetrieben erhält die Beschaffung von Strom und Energiemanagement eine deutlich erhöhte Relevanz, auch in Industriezweigen, bei denen die Strombeschaffung oder das Energiemanagement bisher kaum strategische Bedeutung hatte. Insbesondere im Bereich von Logistiksystemen, die einige ihrer Prozesse auf Elektromobilität umstellen, ergeben sich durch die Nutzung von flexiblen Strombezugsverträgen neue Möglichkeiten und Anwendungsfälle im Bereich Energie, die mit traditionellen Vollversorgungsverträgen nicht möglich waren. Beispiel eines solchen Logistiksystems ist ein Seehafencontainerterminal. Hier können Aufgaben des Containertransports von Dieselbetrieb auf batterie-elektrischen Betrieb umgestellt werden, woraus sich die erhöhte Bedeutung des Betriebsstoffes elektrische Energie ergibt. Mit Unterstützung durch Energiemana-

gementsysteme wird versucht eine möglichst effiziente Nutzung des Stroms zu erreichen. Zur Nutzung von sowohl ökonomischen als auch ökologischen Vorteilen verschiedener Anwendungsfälle im Bereich des Energiemanagements wird eine möglichst genaue Prognose des voraussichtlichen Lastverlaufs des Folgetags benötigt.

Im Laufe der Zeit wurde eine Vielzahl von Verfahren zur Erstellung von Lastgangprognosen entwickelt und produktiv bei Energieversorgungsunternehmen eingesetzt. Viele sind dabei auf spezifische Einsatzszenarien spezialisiert, manche folgen einem sehr generalistischen Ansatz. Gemein ist den Verfahren, dass sie meist für gesamte Netze oder große Gruppen von Verbrauchern ausgelegt sind, bei denen sich die Schwankungen einzelner Verbraucher im Durchschnitt ausgleichen und einen vergleichsweise regelmäßigen Verbrauch mit zyklischen Abfolgen ergeben. Mit der Energiewende und dem damit verbundenen Wechsel zu einer dezentraleren Energieversorgung kommt der Prognose von einzelnen kleinen Teilnetzen, den sogenannten Microgrids, und auch Einzelverbrauchern, eine zunehmende Bedeutung zu. Erfahrungswerte bei der Anwendung der etablierten Prognoseverfahren bei der Berechnung des kurzfristigen Strombedarfs eines Containerterminals als großem Einzelverbraucher liegen in der wissenschaftlichen Literatur nicht vor. Zwar lassen sich Verfahren mit generalistischem Ansatz für alle möglichen Anwendungsfälle nutzen, doch wurde die Güte solcher Verfahren bei der Anwendung auf die Strombedarfsprognose für ein Containerterminal noch nicht systematisch untersucht. Zudem erscheint es vorteilhaft, Wissen über die internen Prozessabläufe des jeweiligen Einzelverbrauchers, zum Beispiel eines Containerterminals, in den Prognoseprozess zu integrieren. Die vorliegende Arbeit versucht die bestehende Lücke zu schließen, indem sie einen eigenen Ansatz für die Lastgangprognose eines Containerterminals präsentiert und diesen Ansatz und dessen Prognosegüte mit weiteren, verbreiteten, Prognosemethoden vergleicht. Zugleich wird untersucht, wie Wissen über die geplanten Betriebsabläufe im Containerterminal in den Prognoseprozess integriert werden kann, um die Prognosegüte zu erhöhen.

Im Folgenden sollen dafür zuerst der energiewirtschaftliche Rahmen und die angesprochenen Anwendungsfälle eingeführt werden, bevor auf die spezifischen Details der Erstellung einer Lastgangprognose für ein Containerterminal detailliert eingegangen wird. Dazu wird ein schematischer Aufbau eines Containerterminals skizziert und anschließend die verschiedenen Hauptverbrauchsgruppen eines Containerterminals mit ihren jeweiligen energetischen Eigenschaften kurz vorgestellt. Über die Analyse der Energieverbrauchsprozesse anhand beispielhafter Lastverläufe wird die Problemstellung hergeleitet und anschließend das Ziel der Arbeit beschrieben.

1.1 Motivation

1.1.1 Liberalisierter Energiemarkt und Demand Side Integration

Mit Inkrafttreten der EU-Richtlinie 96/92/EG zum Elektrizitätsbinnenmarkt im Jahr 1996 begann die Liberalisierung der Märkte für die leitungsgebundene Energieversorgung mit Strom und Erdgas in Europa. Während vor der Liberalisierung Energieversorger zum Teil von der Erzeugung bis zur Lieferung alles aus einer Hand anbieten konnten, wurde mit der Liberalisierung die Auftrennung der Energieversorger nach sogenannten Marktrollen vorangetrieben

(„Unbundling“). Wurden zuerst nur der Netzbetrieb und der Vertrieb getrennt, so wurden die Unterscheidungen der verschiedenen Rollen mit der Zeit immer weiter verfeinert. So wurden zum Beispiel noch die zusätzlichen Rollen des Messstellenbetreibers und des Messdienstleisters definiert. Die Organisation der europäischen Transportnetzbetreiber ENTSO-E hat ein ganzes Netzwerk von spezifischen Rollen und deren Zusammenspiel definiert [Ent15]. Neben rechtlichen und operativen Unbundlingvorgaben war die Einführung eines Tagesbilanzierungsregimes in Deutschland ein wichtiger Schritt zur Öffnung des Strommarktes und dem diskriminierungsfreien Zugang zu den Stromnetzen.

Das derzeitige Bilanzierungsregime regelt, dass Stromhändler wie auch Stromlieferanten mit einer Vorlaufzeit von derzeit knapp einem Tag die voraussichtlichen Entnahmen aus den Stromnetzen mit entsprechenden Einspeisungen in das Netz ausgleichen. Die entsprechenden Mengen können in OTC (Over-the-counter) Geschäften erworben oder an der Strombörse EEX (European Energy Exchange) frei gehandelt werden und werden in einem Bilanzkreis hinterlegt. Gegenüber dem Übertragungsnetzbetreiber ist je Bilanzkreis ein Bilanzkreisverantwortlicher zu benennen, welcher die Verantwortung für die wirtschaftlichen Auswirkungen von Abweichungen zwischen Entnahme und Einspeisung im Bilanzkreis trägt.

Auf der physikalischen Seite ist der Regelzonenbetreiber verantwortlich für den sicheren Betrieb des Elektrizitätsnetzes. Um eine stabile Frequenz zu gewährleisten muss dieser jederzeit die Summe der Netzeinspeisungen mit der Summe der Netzausspeisungen in Übereinstimmung bringen. Kommt es zu Abweichungen zwischen Einspeisung und Ausspeisung so werden diese über Regelleistung ausgeglichen, welche vorher über Auktionen auf einer separaten Handelsplattform kontrahiert wurde. Die Kosten für die Regelleistung werden anschließend auf die Bilanzkreisverantwortlichen umgelegt.

Um Bilanzkreisabweichungen und damit auch den Bedarf von Regelleistung zu vermeiden gibt es prinzipiell zwei Möglichkeiten: Entweder kann die Einspeise- oder die Entnahmeseite an die aktuelle Situation angepasst werden [SRB10].

Nicht erst seit der Liberalisierung der Strommärkte befassen sich auch in Deutschland energieintensive Unternehmen mit der Optimierung ihres Strombezugsverhaltens. Spitzenlastmanagement und Verlagerung von Verbrauchsspitzen in Zeiträume mit vergünstigten Bezugspreisen wurden durch die Netzbetreiber mit der Einführung von leistungsbezogenen Tarifkomponenten und unterschiedlichen Tag- und Nachtтарifen unterstützt.

Energiemanagementsysteme übernehmen dabei die operative Überwachung und, wenn möglich, die Steuerung des Energiebezugs. Wird dabei auf externe Anreize reagiert, so spricht man von Demand Response [GC88]. Diese Anreize können variable Preissignale sein, z. B. abgeleitet von aktuellen Bezugspreisen an der Strombörse, aber auch weitere Anreizsignale um den Stromverbrauch zu reduzieren bzw. sogar zu erhöhen, wie z. B. bei Frequenzschwankungen im Transportnetz oder bei der Verfügbarkeit großer Mengen erneuerbarer Energien. Demand Side Management ergänzt diese verbraucherseitigen Reaktionen auf außenstehende Signale um allgemeine Maßnahmen wie Energieeffizienzmaßnahmen und verbraucherseitige Energiemanagementmaßnahmen (ohne dynamische Preisanreize) wie Spitzenkappung oder

Lastverlagerung [IEA03]. Die deutschen Verbände VDE¹ und BDEW² fassen die Begriffe Demand Response und Demand Side Management unter dem Oberbegriff Demand Side Integration zusammen [VDE12, BDE13].

Für die Integration des Endverbrauchers in die Anpassungen auf Verbraucherseite werden in verschiedenen Studien hohe Potenziale im Kontext von Demand Side Integration genannt. Allein in Deutschland wird das Potenzial für die Nutzung von flexiblen Lasten auf 2700 MW geschätzt [BDE13]. Dabei werden in verschiedenen Untersuchungen die stromintensiven Branchen (Aluminium, Chemie, Stahl, Papier, Zement) als Zielgruppe genannt [Klo07, DEN10, RG10] oder Möglichkeiten und Potenzial bei der Einbindung von Haushaltskunden untersucht [Kam09, ZE11]. Die Logistikbranche wird in keiner dieser Ausarbeitungen genannt oder betrachtet. Durch die Nutzung von Elektrotransportfahrzeugen, insbesondere in geschlossenen Transportsystemen wie maritimen Containerterminals, entstehen aber auch hier neue Potenziale [RIMB+14, SLIK15]. Aufgrund der hohen regulatorischen Anforderungen, z. B. für das Bereitstellen von Energiedienstleistungen wie Minutenreserveleistung, müssen Endverbraucher hier häufig noch auf einen Mittler zurückgreifen, der in Deutschland durch die noch neue Marktrolle des Aggregators ausgefüllt wird. Dieser kombiniert verschiedene, meist kleinere Erzeuger und flexible Verbraucher zu einem größeren Gesamtverbund, dem virtuellen Kraftwerk, um im Zusammenspiel der einzelnen Beteiligten verlässliche Energiedienstleistungen im regulatorischen Rahmen anbieten zu können.

1.1.2 Energiedienstleistungen von industriellen Großverbrauchern am Beispiel eines Containerterminals

Für Großverbraucher gibt es im Wesentlichen drei Möglichkeiten sich im Rahmen von Demand Side Integration am Energiemarkt zu beteiligen:

- Optimierung des Verbrauchs auf variable Preise
- Lastgangglättung
- Bereitstellung von Systemdienstleistungen (Regelleistung)

Das Angebot von Strombezugstarifen mit variablen Preisen setzt einen entsprechenden Stromliefervertrag oder eine eigene Beschaffung voraus. Lieferanten können die Preisgestaltung zum Beispiel von der Entwicklung des Day-Ahead-Preises der Strombörse abhängig machen oder sich an der Verfügbarkeit von Strom aus erneuerbaren Quellen orientieren. Dies gilt auch bei eigener Beschaffung des Stroms. Dabei ist der Verlauf der Preisentwicklung deutlich differenzierter als bei heutzutage bereits üblichen HT/NT-Tarifen³, die nur zwei Preiszonen kennen. Unter der Annahme, dass der Verbraucher seinen Verbrauch am Preisverlauf orientiert, hat der Lieferant dadurch den Vorteil, einen indirekten Einfluss auf das Verbrauchsverhalten des Kunden ausüben zu können. Für Verbraucher mit Flexibilität im Stromverbrauch ergibt sich die Chance, Teile des Stromverbrauchs in Zeiten mit günstigen Preisen zu verlagern.

Bei der Lastgangglättung geht es darum, auf Verbraucherseite Spitzen in der bezogenen elektrischen Leistung zu vermeiden, da diese eine wesentliche Preiskomponente in Lieferverträ-

1 Verband der Elektrotechnik Elektronik Informationstechnik e.V.

2 Bundesverband der Energie- und Wasserwirtschaft e.V.

3 Haupttarif/Nebentarif, Uhrzeit-abhängig

gen darstellen. In Kenntnis einer kommenden Leistungsspitze kann der Strombedarf einzelner flexibler Verbrauchssysteme reduziert oder komplett abgeregelt werden, damit die Spitze vermieden wird. Üblicherweise müssen die reduzierten Bedarfe an Strom zu späteren Zeiträumen nachgeholt werden. Durch eine intelligente Planung lässt sich eine Vergleichmäßigung des Abnahmeverhaltens erreichen, welche wiederum mit einer deutlichen Reduktion der Netzentgelte belohnt wird, die eine weitere nicht unwesentliche Preiskomponente in Strombezugsverträgen darstellen.

Die Bereitstellung von Systemdienstleistungen wie Regelleistung stellt die technisch aufwändigste Möglichkeit dar. Regelleistung wird benötigt, wenn die Spannung in einem Netz oder in einem Netzabschnitt bestimmte Grenzen unter- oder überschreitet. Dann können Bereitsteller von Regelleistung so gesteuert werden, dass sie ihren Stromverbrauch erhöhen oder verringern, um das Spannungsniveau zu unterstützen. Dies ist technisch aufwändig, da eine externe Steuerung der schaltbaren Lasten integriert werden muss, die eine Zuverlässigkeit von Schalthandlungen garantiert, die vorab im Rahmen einer sogenannten Präqualifizierung überprüft wird. Zudem muss eine gewisse Mindestleistung bereitgestellt werden. Regelleistung wird in Auktionen vorab von den Regelzonenverantwortlichen kontrahiert. Für kleinere Anbieter von Regelleistung ist es daher sinnvoll, sich einem virtuellen Kraftwerk anzuschließen, welches eine Bündelung verschiedener Anbieter vornimmt und auch die Vermarktung übernimmt.

Um Energiedienstleistungen im Sinne von Demand Response und Demand Side Integration bereitstellen zu können, aber auch für die innerbetriebliche Optimierung, ist insbesondere Wissen über zukünftige Lastverläufe erforderlich. Dieses wird benötigt um daraus Potenziale für das Zu- und Abschalten von Leistungsaufnahme bestimmen zu können. Neben den bereits genannten Energiedienstleistungen ist es insbesondere auch für den Lieferanten interessant, den Lastverlauf vorab möglichst gut zu kennen, um seine Einkaufsmengen entsprechen anpassen zu können.

Mit Kenntnis des zukünftigen Energieverbrauchs ist es möglich, Potenziale für das Angebot bestimmter Energiedienstleistungen von Endverbraucherseite aus auch kurzfristig bestimmen zu können. In einem Containerterminal basiert diese Flexibilität im Strombezug zum Beispiel auf der Möglichkeit, bei Nutzung von automatisierten Transportfahrzeugen (englisch: Automated Guided Vehicles, kurz: AGVs) mit batterie-elektrischen Antrieb für den Containertransport, Batterieladeprozesse zeitlich variabel zu gestalten [RIMB+14]. Bei Nutzung eines Batteriewechselkonzeptes ergibt sich hier Variabilität, da der Ladeprozess einer Batterie kürzer ist als die Aufenthaltszeit der Batterie in der Ladestation bis zum nächsten Gebrauch. Somit ist im Containerterminal mit Nutzung von Elektrotransportfahrzeugen neben einer Prognose der elektrischen Leistungsaufnahme auch die Prognose der Batteriewechselzeiten der Elektrotransportfahrzeuge relevant.

Die teilweise der Regulierung unterliegenden Prozessabläufe zur Bereitstellung dieser Energiedienstleistungen bedingen, dass die Lastgangprognose wie auch das Bestimmen der Flexibilität spätestens am Vortag der eigentlichen Erbringung erfolgen. So muss zum Beispiel ein Gebot für Minutenreserveleistung für den Folgetag am Vortag bis 10:30 Uhr auf der entsprechenden Auktionsplattform eingestellt werden oder eine Fahrplannominierung auf Basis der Lastgangprognosen bis 14:30 Uhr des Vortages erfolgen. Neben der externen Vermarktung

kann eine Lastgangprognose auch für Energiemanagementmaßnahmen innerhalb des Terminals genutzt werden, z. B. zum frühzeitigen Erkennen neuer Lastspitzen und der frühzeitigen Einleitung von Maßnahmen, um diese zu vermeiden. Mit Hilfe einer Vortagsprognose können mögliche Lastspitzen des Folgetages identifiziert werden und Maßnahmen zur Verschiebung von Lasten in Zeiträume mit niedriger Leistungsaufnahme fest in den Produktionsablauf eingeplant werden. Hier unterstützen interne Energiemanagementsysteme in der Planung und Durchführung entsprechender Maßnahmen.

Die Verpflichtung zur frühzeitigen Abgabe von Geboten für Minutenreserveleistung oder der Bereitstellung von Lastgangprognosen für die Fahrplannominierung bedingt ein Risiko für die Planerfüllung insbesondere in dynamischen Prozessfeldern wie dem eines Containerterminals, da die Wahrscheinlichkeit eines Eintritts einer Betriebsablaufstörung und damit einer Planabweichung hoch ist. Für mögliche Planabweichungen kommen mehrere Ursachen in Betracht. Ein Beispiel können verspätete Schiffsankünfte bedingt durch Witterungseinflüsse oder Verzögerungen im Vorhafen sein. Eine Auswertung der tatsächlichen Schiffsankunftszeiten des Containerterminals Altenwerder in Hamburg im Vergleich zu den am Vortag geplanten Ankunftszeiten für 19 Tage im Juni 2014 ergab, dass von 172 Schiffsankünften 71 Schiffe mindestens 60 Minuten und 12 Schiffe mehr als 240 Minuten verspätet waren. Die durchschnittliche Planabweichung pro Schiff lag in diesem Zeitraum bei 02:42 Stunden. Es wird vermutet, dass die Abweichungen in einem entsprechenden Winterzeitraum noch gravierender sind. Es muss also möglich sein, die zuvor erstellten Prognosen auch noch kurzfristig entsprechend anpassen zu können, um die Auswirkungen im Bereich Leistungsaufnahme beurteilen zu können. Zudem kann das Erkennen von Prognoseabweichungen dazu genutzt werden, um einem möglichen Energiedienstleister (z. B. in der Marktrolle Aggregator) auf entsprechende Änderungen hinzuweisen. Ein Prognoseverfahren sollte also entsprechend effizient arbeiten.

1.2 Problemstellung

Lastgangprognoseverfahren werden seit geraumer Zeit in der Energieversorgung erfolgreich eingesetzt. Hauptnutzer sind Energieversorger, die die Beschaffung und ihr Portfolio entsprechend der generierten Prognosen ausrichten. Ziel ist es die für einen Bilanzkreis eingekauften Mengen und den entsprechenden Verbrauch möglichst in Einklang zu bringen. In einem Bilanzkreis sind üblicherweise eine Vielzahl von Verbrauchern zusammengefasst, meistens sogar gesamte Netzabschnitte oder alle Verbraucher kompletter Verteilnetze. In einem solchen aggregierten Szenario gleichen sich tägliche Verbrauchsschwankungen einzelner Verbraucher aus und sich wiederholende Lastszenarien können mit der Zeit beobachtet werden und gegebenenfalls vorhandene Einflussfaktoren identifiziert werden, sodass die Prognoseverfahren entsprechend parametrisiert werden können und zufriedenstellende Ergebnisse liefern. Selten werden kleinere Gebiete mit vergleichsweise wenigen Verbrauchern und eventuell dezentralen Erzeugern, die sogenannten Microgrids, betrachtet [HBA+13, LQZ+14]. Diese weisen deutlich höhere Schwankungen im täglichen Verlauf auf und periodische Merkmale des Lastverhaltens sind aufwändiger zu bestimmen. Allgemein lässt sich sagen, dass die Prognostizierbarkeit von Lastgängen zunimmt, je mehr einzelne Verbraucher in diesem Lastgang aggregiert werden [Dan15]. Abbildung 1 zeigt beispielhaft Lastgänge auf verschiedenen Aggregations Ebenen. Deutlich sind die unregelmäßigen Verbrauchsschwankungen im Lastverlauf eines ein-

zelen Verbrauchers zu erkennen. Mit der zunehmenden Anzahl von Verbrauchskurven prägen sich Regelmäßigkeiten aus und die Lastkurve wird gleichmäßiger. Es muss aber ergänzt werden, dass dieser Effekt im Wesentlichen auftritt, wenn Lastgänge homogener Verbrauchergruppen aggregiert werden. Im Beispiel von Abbildung 1 handelt es sich um Einzelhaushalte. Schon bei 20 Verbrauchern sind deutliche Glättungseffekte bei steigenden Skalenwerten (in der Abbildung nicht dargestellt) erkennbar. Während Einzelhaushalte häufig nur mit einem durchschnittlichen Prognosefehler von 10 bis 20 % prognostiziert werden können, sinkt dieser Prognosefehler schnell ab. Bei etwa 80 Verbrauchern kann der Prognosefehler schon bis auf 4% im Durchschnitt gesenkt werden [Dan15]. Die Aggregationseffekte lassen sich auch in Bezug auf die zeitliche Auflösung beobachten. So ist die Prognostizierbarkeit von stündlichen durchschnittlichen Verbrauchswerten höher, als die von 15-minütigen Werten oder gar von minütlichen Werten.

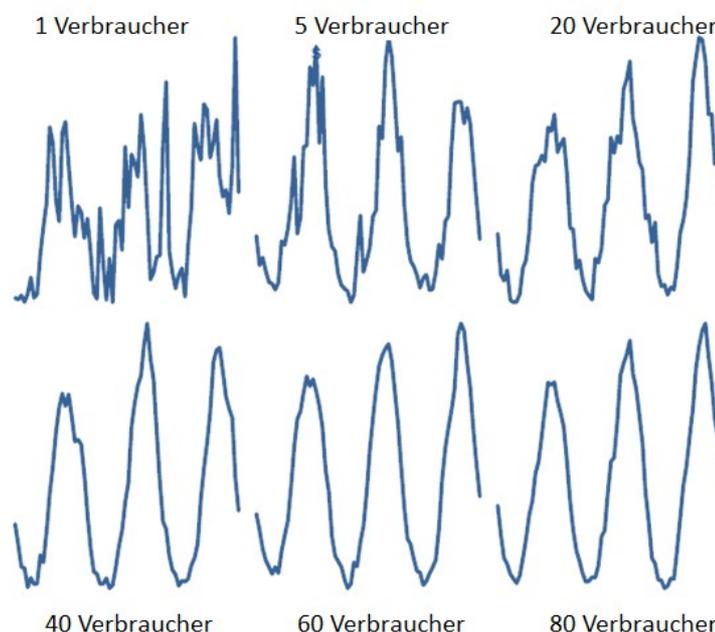


Abbildung 1: Lastverlauf auf verschiedenen Aggregationsstufen [SR18]

Im weitesten Sinne als Microgrid kann auch ein Containerterminal betrachtet werden: Verschiedene einzelne Verbraucher des Terminals aggregieren ihre spezifische Leistungsaufnahme über die Zeit zu einem Gesamtverbrauch. Mit der Einführung von Elektromobilität werden mögliche Speicherkapazitäten in das System integriert, zudem können Blockheizkraftwerke und Erzeugung aus erneuerbaren Energiequellen in das Gesamtsystem des Containerterminals integriert werden.

Primäre Aufgabe eines Containerterminals ist der Umschlag von standardisierten Containern. Dies kann zum Beispiel das Umladen eines Containers von einem Schiff auf ein weiteres Schiff sein, aber auch das Auf- und Abladen von Containern, die von LKWs oder per Bahn, der sogenannten Hinterlandanbindung, an- oder abtransportiert werden. Mit einem Umschlag verbunden ist in den allermeisten Fällen die Zwischenlagerung in sogenannten Blocklagern, in denen die Container bis zum nächsten Umschlagschritt gestapelt abgestellt werden. In den

folgenden Kapiteln sollen die dazu benötigten Umschlaggeräte kurz vorgestellt werden, da sie die Hauptverbrauchsanteile des Leistungsbedarfs darstellen. Dabei wird immer wieder auf die Besonderheiten des betrachteten Fallbeispiels, dem Container Terminal Altenwerder (CTA), eingegangen. Eine Besonderheit des CTA ist der besonders hohe Grad der Elektrifizierung des Umschlaggerätes, was dieses Terminal für die Bereitstellung von Energiedienstleistungen und eine entsprechende Untersuchung von Prognoseverfahren besonders interessant macht.

Neben den einzelnen Bereichen und Umschlaggeräten eines Containerterminals wird auch ein Blick auf die damit verbundenen Prozesse geworfen, um aus den Energieverbrauchern zu Methoden der Lastgangprognose, also der kurzfristigen Vorhersage des Energiebedarfs des Terminals, überzuleiten. Als eine zentrale Problemstellung dieser Arbeit wird die Frage bearbeitet, wie das Wissen über die einzelnen Energieverbraucher und die Ablaufprozesse eines Containerterminals in den Prognoseprozess des elektrischen Lastgangs integriert werden kann.

1.2.1 Energieverbraucher im Containerterminal

Ein Containerterminal besteht schematisch mindestens aus drei Funktionsbereichen:

- Umschlagbereich Schiff – Terminal
- Containerlagerbereich
- Umschlagbereich Terminal – Hinterland

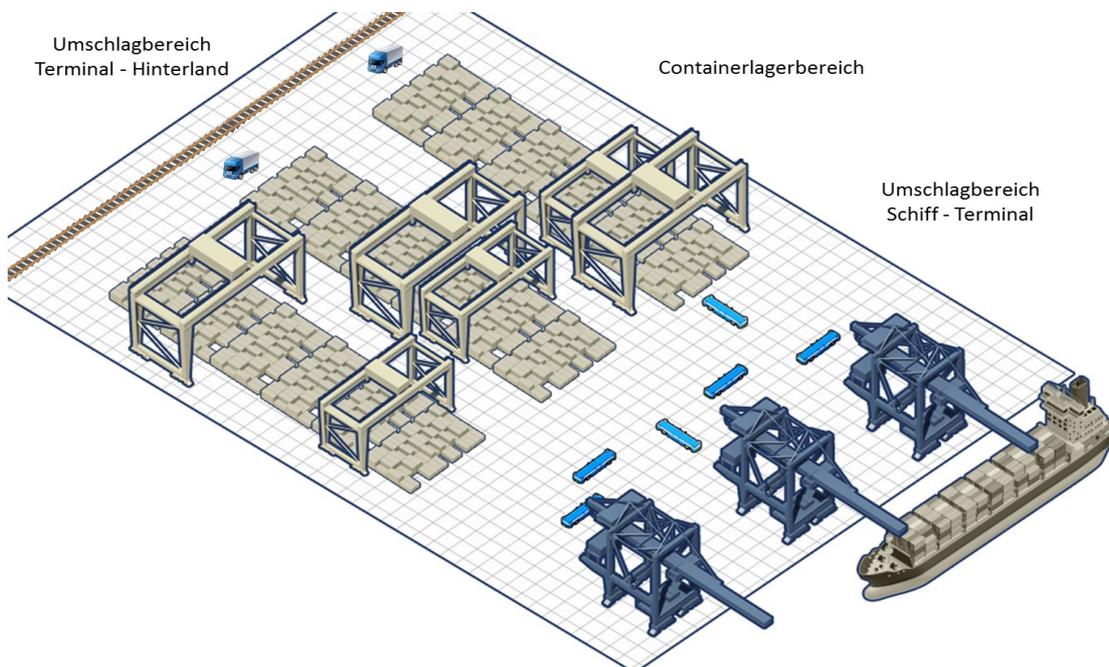


Abbildung 2: Schematischer Aufbau eines Containerterminals

Im ersten genannten Bereich werden die Containerschiffe be- und entladen. Containerbrücken sind in der Lage Container an der Landseite aufzunehmen, auf das Schiff zu verladen und auf dem Rückweg einen weiteren Container vom Schiff an die Landseite zu transportieren. Dort werden die Container von speziellen Fahrzeugen im Horizontaltransportbereich von den Con-

tainerbrücken zum Lagerbereich und vom Lagerbereich zu den Containerbrücken gebracht. Die speziellen Fahrzeuge können zum Beispiel von Menschen gesteuerte Straddle-Carrier oder automatische Transportfahrzeuge (AGVs) sein. Im Lagerbereich werden die Container mittels Portalkränen in das Lager eingelagert, ggf. während der Lagerung umgelagert und wieder ausgelagert. Die Portalkräne sind häufig schienengebunden und können vollständig automatisiert arbeiten. Soll der Container auf dem Landweg (LKW oder Bahn) weitertransportiert werden, so wird er von den Portalkränen aus dem Lager entnommen und im sogenannten Hinterlandanbindungsbereich auf einen LKW verladen oder zum Verladeterminale für den Schienenverkehr transportiert. Gleiches gilt für die Anlieferung von Containern auf dem Landweg. Für die Verladung der Container auf und von Zügen können wieder eigene Portalkräne zum Einsatz kommen. Die Umschlagfähigkeiten der einzelnen beteiligten Komponenten haben einen hohen Energiebedarf. Insbesondere in hochautomatisierten Containerterminals, bei denen viele Prozesse automatisch und elektrifiziert ablaufen, haben die einzelnen Komponenten unterschiedlichen Einfluss auf das Lastverhalten des Gesamtterminals. Die einzelnen Komponenten werden deshalb im Folgenden im Detail vorgestellt.

1.2.1.1 Containerbrücken

Die Be- und Entladung der Containerschiffe erfolgt durch Containerbrücken, die entlang der Kaimauer angeordnet sind. Idealerweise bildet die Kaimauer eine Gerade, was eine maximale Flexibilität bei der Liegeplatzzuordnung der Schiffe und der Zuordnung von Kränen zu Schiffen bietet. Große Seeschiffe werden heutzutage von bis zu fünf Kränen be- und entladen, für kleinere Feederschiffe genügen ein bis zwei Kräne.

Eine Containerbrücke ist ein großer, auf Schienen laufender Portalkran. Nach der Anzahl ihrer Laufkatzen kann man Containerbrücken in 1-Katz und 2-Katz-Brücken unterscheiden. Als Laufkatze oder Katze wird dabei der fahrbare Wagen am Ausleger des Krans bezeichnet.

Die manuelle 1-Katz-Brücke besitzt nur eine Laufkatze, die für das Entladen des Containers aus dem Schiff, den Transport zum Kai und das Absetzen auf dem Boden oder einem bereitgestellten Fahrzeug verantwortlich ist. Gesteuert wird die Krankatze von einem Brückenfahrer, der sich in einer Kabine des Krans oberhalb des Schiffsdecks befindet. Mit 1-Katz-Brücken können technisch 25-35 Containerbewegungen pro Stunde durchgeführt werden.

Um die Produktivität der Containerbrücken noch weiter zu erhöhen, wurden 2-Katz-Brücken entwickelt. Mit dieser Art von Containerbrücken können bis zu 45 Container in der Stunde umgeschlagen werden. Der Produktivitätsgewinn gründet sich auf eine teilweise Automatisierung der Brücke. Die seeseitige Hauptkatze wird dabei weiterhin manuell gesteuert, da für das zentimetergenaue Aufnehmen und Absetzen eines Containers in einem ständig schwankenden Schiff bisher noch keine technisch befriedigende vollautomatische Lösung gefunden wurde. Der Container wird jedoch nach Aufnahme im Schiff von der Hauptkatze nur bis zu einer sogenannten Laschplattform befördert und dort abgesetzt. Der Container wird von einer vollautomatischen Portalkatze übernommen. Die Portalkatze transportiert den Container zum Kai und stellt ihn auf einem dort wartenden Fahrzeug ab. Der kurze Fahrweg der Hauptkatze und der parallele Betrieb der beiden Katzen ermöglichen den 2-Katz-Brücken eine extrem geringe Umschlagdauer [Bri05].

Ein hoher Anteil der Energieaufnahme einer Containerbrücke entsteht bei dem Anheben und horizontalen Verschieben von einzelnen Containern. Dabei ist der tatsächliche Wirkleistungsbedarf abhängig von der jeweiligen Hubhöhe und dem Containergewicht. Zusätzlich verfügt eine Containerbrücke über eine Basisleistungsaufnahme, welche durch Beleuchtung, Klimatisierung, Hydraulikpumpen und Motorkühlung generiert wird. Eine Studie aus Schweden weist für Containerbrücken einen durchschnittlichen Energiebedarf von 6 kWh pro Containerumschlag aus [Joh10].

In vielen Containerterminals werden die Containerbrücken in einem Schichtsystem betrieben, um eine Be- und Entladung der Schiffe rund um die Uhr zu ermöglichen. Da die Containerbrücken einen sehr hohen Anteil an der Gesamtleistungsaufnahme des Terminals haben, führen die regelmäßigen Schichtwechsel, bei denen die Containerbrücken kurzzeitig nicht arbeiten, zu deutlichen Einbrüchen in der Leistungsaufnahme, häufig nur für einen Viertelstundenwert. Diese sind im Gesamtlastgang eines Tages deutlich zu erkennen, ebenso wie kurzfristige Ausfälle einzelner Kräne im Zuge von technischen Defekten oder Wartungsarbeiten.

1.2.1.2 Portalkräne

Portalkräne sind bei der Platzierung und Sortierung der Container in Blocklagern im Einsatz. Unterschieden wird zwischen Rubber-Tyred-Gantry-Cranes (RTG) und schienengebundenen Rail-Mounted-Gantry-Cranes (RMG). Die Kräne nehmen auf der Seeseite die Container, die von der Horizontaltransportflotte angeliefert werden, auf, überführen diese in das Blocklager und geben diese zu einem späteren Zeitpunkt an den Hinterlandbereich ab. Bei Anlieferung aus dem Hinterlandbereich erfolgt der Prozess andersherum. Zusätzlich übernehmen die Portalkräne wichtige Funktionen bei der Lageroptimierung. So werden Umstapler vorgenommen, um demnächst benötigte Container frühzeitig in eine Position zu bringen, von der aus sie gut erreichbar für den eigentlichen Umschlagvorgang sind.

In modernen elektrifizierten Containerterminals kommen RMG-Kräne zum Einsatz, die vollständig automatisiert und elektrifiziert sind. Pro Blocklager kommen dabei aus Effizienzgründen häufig zwei Kräne zum Einsatz, die sich gegenseitig überfahren können. Analog zur Containerbrücke hängt der Energiebedarf der Portalkräne im Wesentlichen von der Hub- und Verschiebeleistung je Containerbewegung ab. Wie bei den Brücken gibt es aber einen nicht unwesentlichen Anteil an Grundbedarf, der unabhängig von der Transportleistung ist. Im Unterschied zu den Containerbrücken sind die Portalkräne vollständig automatisiert, so dass zwischenzeitliche Schichtwechsel nicht stattfinden und somit auch kein entsprechender Ausschlag im täglichen Gesamtlastgang des Terminals von den Portalkränen verursacht wird.

1.2.1.3 Horizontaltransport

Für den Transport der Container zwischen dem Kai und der Lagerfläche im Terminal können verschiedene Typen von Flurfördergeräten eingesetzt werden. Man kann diese Fahrzeuge hinsichtlich ihrer Fähigkeit unterscheiden, Container selbständig auf- oder abzuladen bzw. ob diese Fahrzeuge aktiv gesteuert werden oder selbstfahrend sind.

In großen automatisierten Containerterminals, wie sie unter anderem in den Häfen von Rotterdam, Hamburg oder Los Angeles zu finden sind, werden selbstfahrende Transportfahrzeuge

eingesetzt, die den Containertransport zwischen Blocklagern und Containerbrücken vollständig automatisiert übernehmen. Diese sollen im Folgenden kurz vorgestellt werden, da sich durch die Nutzung dieser Fahrzeuge, mit für diese Fahrzeuggattung spezifischen Fahrprofilen, eine Nutzung mit batterie-elektrischem Antrieb besonders anbietet und diese Nutzung wiederum Einfluss auf die Bewirtschaftung des Stromportfolios eines Terminals hat.

Die hohen Personalkosten und die schwierige Planbarkeit der Fahrten bei Chassis-Systemen führten zur Entwicklung von fahrerlosen Transportsystemen, die auch im Terminal eingesetzt werden können. Ihr Fahrkurs besteht aus einem Gitter von in den Boden eingelassenen Transpondern oder Induktionsspulen, die logisch zu Spuren verschaltet werden. Die Fahrzeuge können den eigenen Standort im Fahrkurs bestimmen und werden über Funk gesteuert. Das gesamte Routing und die Verkehrsregelung, einschließlich des zentimetergenauen Einparkens an den Übergabepositionen, übernimmt ein Steuerungssystem. Fahrerlose Transportsysteme (AGVs) ermöglichen durch die hohe Planbarkeit und Präzision ein schnelleres und sichereres Auf- und Abladen der Container.

Ihre Transportgeschwindigkeit ist mit 6 m/s relativ gering, aber aufgrund der verbesserten Steuerbarkeit kann dies durch eine größere Fahrzeuganzahl ausgeglichen werden. Im Vergleich zu so genannten Single-Load-Carriern (SLC), die jeweils nur einen Container transportieren können, kann das Transportvolumen durch Multi-Load-Carrier (MLC) erhöht werden. Aktuell in Terminals eingesetzte Fahrzeuge können maximal zwei Standardcontainer gleichzeitig transportieren. Ein weiterer Vorteil von fahrerlosen Transportsystemen sind die geringen Personalkosten, die ihre hohen Anschaffungskosten gerade in Ländern mit einem hohen Lohnkostenniveau rechtfertigen. Hingegen können Fahrerlose Transportsysteme trotz der Automatisierung nicht den einen Nachteil außer Kraft setzen, der ihnen als passiven Flurfördergeräten anhaftet: Sie sind nicht in der Lage, Container selbständig auf- oder abzuladen. Gerade in einem so komplexen und dynamischen System wie einem Containerterminal ist dieses Fehlen von Puffern bzw. Entkopplungspunkten ein Risiko, das nur durch sehr zuverlässige und robuste Planung kompensiert werden kann [Bri05, WW11].

Im Container Terminal Altenwerder in Hamburg wurden inzwischen zehn Fahrzeuge auf batterie-elektrischen Betrieb umgestellt, auch das Containerterminal Maasvlakte (Rotterdam) und das Containerterminal Long Beach in den USA setzen entsprechende Fahrzeuge ein. Um Ausfälle in der Transportleistung weitestgehend zu vermeiden, die durch Batterieladeprozesse entstehen können, wurde eine Lösung mit automatisierten Batteriewechseln eingeführt. Fällt der Ladezustand einer Batterie in einem Fahrzeug unter ein bestimmtes Level, so fährt das Fahrzeug zu einer Batteriewechselstation, in der vollautomatisch innerhalb weniger Minuten die leere Batterie entnommen wird und eine neue vollgeladene Batterie in das Fahrzeug eingesetzt wird.

Durch den Einsatz von batterie-elektrischen Fahrzeugen trägt auch der Horizontaltransportbereich zum Gesamtwirkleistungsbedarf des Terminals bei, während bei rein dieselbetriebenen Flotten dieser Bereich keinen besonderen Einfluss auf den Gesamtlastgang hat. Insbesondere dadurch, dass durch die genutzten Batteriespeicher die eigentliche Energiebereitstellung für die Transportleistung von dem Zeitpunkt des Strombezugs (durch den Ladevorgang) entkoppelt wird, können neue Charakteristika im Gesamtlastgang eines Containerterminals vermutet

werden, welche ohne Batterieladevorgänge nicht auftreten würden. Insbesondere bei der Umstellung der gesamten Flotte an Fahrzeugen können sich durch Gleichzeitigkeitseffekte bei dem parallelen Laden vieler Batterien neue Lastgangverläufe und Verbrauchsspitzen ergeben.

1.2.1.4 Kühlcontainer

Kühlcontainer (englisch: Reefer) werden für Güter genutzt, die gekühlt oder gefroren transportiert werden müssen. Üblicherweise betrifft dies Lebensmittel wie Obst, Gemüse, Fleisch, Fisch oder Milchprodukte. Kühlcontainer entsprechen in der Bauform einem üblichen Container beinhalten aber zusätzlich eine Kühleinheit („Integralcontainer“), welche über eine elektronische Steuerung geregelt wird, sowie eine Wärmedämmung. Die Kühlcontainer werden sowohl während des Transports auf dem Schiff als auch bei der Lagerung im Hafen an eine Stromversorgung angeschlossen, um eine konstante Kühlleistung auch über einen längeren Zeitraum gewährleisten zu können. In einem Containerterminal werden dazu üblicherweise spezielle Bereiche in Blocklagern für das Abstellen der Kühlcontainer vorgesehen. Diese Bereiche sind dann mit einer Anschlussmöglichkeit für die Energieversorgung der Container versehen. Der Stromverbrauch der einzelnen Kühlcontainer ist dabei abhängig von der zu kühlenden Ladung, der benötigten Kühltemperatur und der Außentemperatur. In großen Terminals wie zum Beispiel dem Container Terminal Altenwerder in Hamburg werden 2200 Stellplätze für Kühlcontainer vorgehalten [Hhla16], im ECT Delta Terminal in Rotterdam sogar 3250 [Rot18].

1.2.1.5 Statische Verbraucher und Beleuchtung

Auch wenn ein Containerterminal nicht in Betrieb ist, was an nur wenigen Feiertagen im Jahr der Fall ist, so verbraucht das Terminal doch Energie über den Tag. An solchen Tagen lässt sich der Anteil an statischen Verbrauchern und der Beleuchtung deutlich am Lastgang ablesen. Zu den statischen Verbrauchern, die unabhängig von Betrieb und Auslastung des Terminals einen Energieverbrauch generieren, gehören die IT-Infrastruktur, die Gebäudetechnik und die Beleuchtung.

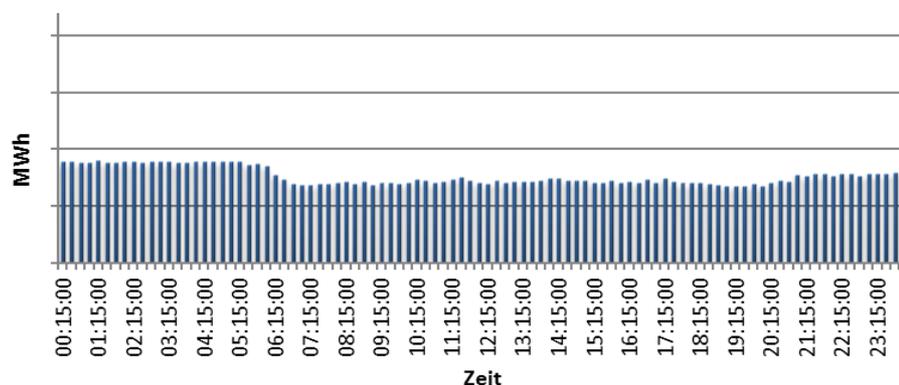


Abbildung 3: Verlauf eines Lastgangs an einem Feiertag

Das Terminalgelände wird zum Beispiel mit Flutlicht ausgeleuchtet um eine konstante Helligkeit auf dem Gelände zu gewährleisten. Dabei kann das Flutlicht in verschiedenen Hellig-

keitsstufen geregelt werden. Bei Sonnenaufgang wird diese Beleuchtung zurückgefahren und bei Sonnenuntergang wieder zugeschaltet.

Abbildung 3 zeigt als Beispiel den Verlauf des Gesamtlastgangs eines Containerterminals an einem Feiertag, an dem der Containerterminal nicht in Betrieb war. Das Absinken des Lastgangs zwischen 05:30 Uhr und 06:30 Uhr lässt sich auf das Rückfahren der Beleuchtung zurückführen, während ab 20:30 Uhr wieder ein Anstieg verzeichnet wird. Der Rest des Tages verläuft ohne signifikante Schwankungen, wie sie an einem Arbeitstag verzeichnet werden würden. Das durchschnittliche Mittel des Lastgangs liegt zudem deutlich unter dem Mittel eines Arbeitstages.

1.2.1.6 Zusammensetzung der Gesamtleistungsaufnahme

Die einzelnen Verbraucher haben einen unterschiedlichen Anteil am Gesamtleistungsbedarf des Terminals. Abbildung 4 zeigt beispielhaft eine Zusammensetzung eines Gesamtlastgangs aus verschiedenen Verbrauchsgruppen für ein mittelgroßes Terminal an einem typischen Arbeitstag. Dieser enthält noch keinen Verbrauchsanteil für batterie-elektrisch betriebene AGVs. In der Grafik ist deutlich zu erkennen, dass sowohl die Verbrauchsgruppe der Kai- als auch die der Lagerkräne für die wesentlichen Schwankungen im Gesamtlastgang verantwortlich sind. Dies sind die Verbraucher, die direkt mit den eigentlichen Umschlagvorgängen der Container in Verbindung stehen.

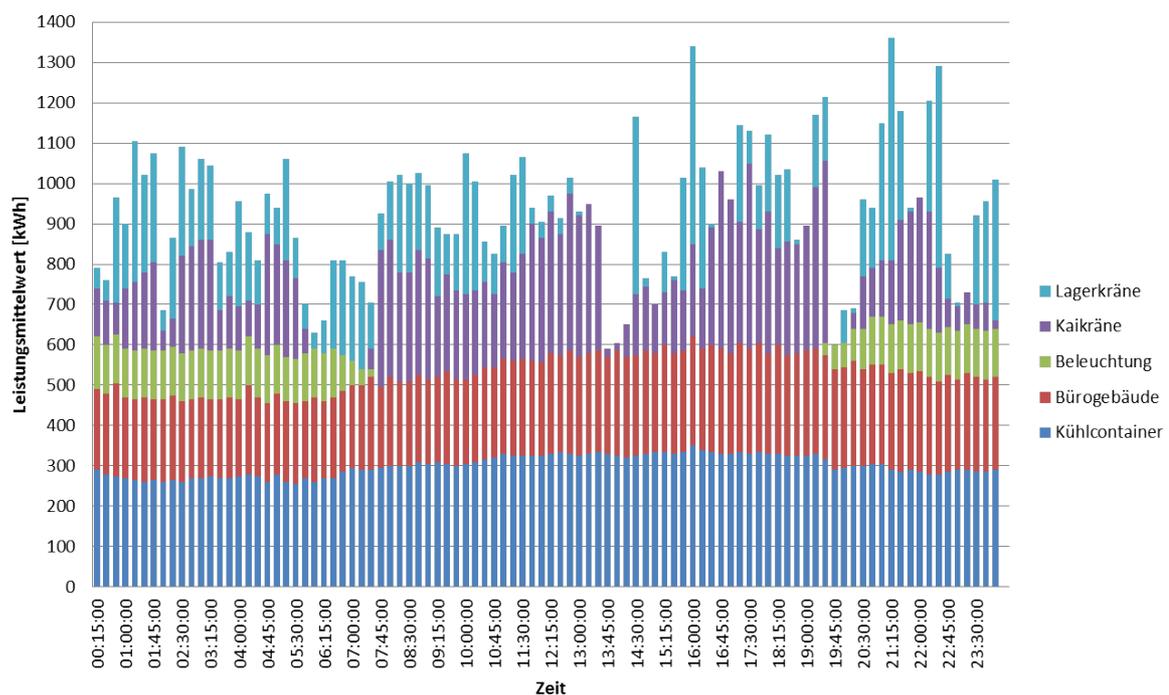


Abbildung 4: Zusammensetzung des Gesamtlastgangs aus Teilverbräuchen (nach [GTMM14])

Dagegen bleiben die Anteile der Kühlcontainer und des Bürogebäudes im Tagesverlauf relativ konstant, während der Anteil der Beleuchtung mit Sonnenauf- und -untergang variiert. Da die Daten für die Abbildung in einem kleineren Terminal erhoben wurden, ist davon auszugehen,

dass der Anteil der Kräne am Gesamtenergieverbrauch in größeren Terminals, wie zum Beispiel dem Container Terminal Altenwerder oder Rotterdam, höher ist. Aus der Abbildung kann abgeleitet werden, dass Wissen über die künftigen Umschlagvorgänge des Terminals bei der Prognose des Gesamtlastgangs aller Verbraucher eine wesentliche Unterstützung darstellen kann.

1.2.2 Lastgangprognoseverfahren für ein Containerterminal

Zur Prognose der Leistungsaufnahme über die Zeit haben sich in der Energieversorgungsindustrie verschiedene Verfahren wie kalendarische oder meteorologische Vergleichstage, mathematische Regressionsverfahren oder die Nutzung von neuronalen Netzen etabliert [SIM+13]. Diesen Ansätzen ist gemein, dass sie basierend auf historischen Lastverläufen eine Vorhersage für den zukünftigen Verbrauch herleiten, meistens aufgrund von Beobachtungen aus möglichst vergleichbaren Abschnitten oder den letzten x -Werten, häufig angereichert um Saison- oder Wetterinformationen. Allerdings basieren die Verfahren, wie bereits beschrieben, häufig auf wiederkehrenden und beobachtbaren Einflussgrößen, Wissen über Ablaufprozesse in Produktion und Verarbeitung bei Einzelverbrauchern wird nur selten integriert.

Bei industriellen Verbrauchern mit hoch variablem Leistungsbedarf, wie z. B. einem Containerterminal, bei denen kaum regelmäßig wiederkehrende Lastverläufe oder sonstige allgemeine Trends beobachtet werden können, ist eine Vorhersage der Leistungsaufnahme mittels Simulation der anstehenden Prozessdurchführung und deren Leistungsaufnahme möglich [GHI+14]. In einem Containerterminal basiert diese Simulation auf dem erwarteten Transportgeschehen des Folgetages, welches aus den prognostizierten Schiffsankünften und -abfahrten und den damit verbundenen Containerumschlagzahlen hergeleitet wird.

Die komplette Simulation der Abläufe eines Containerterminals hat den Nachteil, dass ein sehr hoher initialer Modellierungsaufwand betrieben werden muss, da alle logistischen Problemstellungen wie Liegeplatzzuweisung, Zuordnung von Kaikränen und Wegfindung von Transportfahrzeugen abgearbeitet werden müssen, um deren Einfluss auf die elektrische Leistungsaufnahme vorherzusagen. Neben dem einmaligen sehr hohen Modellierungsaufwand führt dies auch zu einem hohen Rechenaufwand bei der täglichen Prognose. Zudem ist das erstellte Modell nicht ohne weiteres auf ein anderes Containerterminal übertragbar.

Aufgrund des hohen Aufwands und der geringen Übertragbarkeit der simulationsbasierten Lastgangvorhersage ergibt sich die Frage nach alternativen Verfahren der Lastgangvorhersage für hochdynamische geschlossene Logistiksysteme wie dem eines Containerterminals. Dazu sollen in der vorliegenden Arbeit etablierte Verfahren für die Lastgangprognose dahingehend untersucht werden, ob sie geeignet sind den Verlauf des täglichen Leistungsbedarfs eines Terminal zu bestimmen und in wieweit Wissen über die geplanten Abläufe des Terminalbetriebs in den Prognoseprozess integriert werden kann. Sofern eine entsprechende Integration möglich ist, so ist zu untersuchen, welchen Einfluss auf die Prognosegüte diese hat. Da gezeigt werden kann, dass die elektrische Gesamtleistungsaufnahme des Terminals abhängig ist von der Auslastung und damit von dem erwarteten Transportaufkommen, sollen entsprechende Informationen aus dem Planungssysteme des Terminals in die Prognoseverfahren integriert werden.

Zu den etablierten Prognoseverfahren zählen die Methoden Vergleichstagverfahren aus dem Bereich der naiven Methoden, Zeitreihenanalyse aus dem Bereich der statistischen Verfahren, Künstliche Neuronale Netze aus dem Bereich der künstlichen Intelligenz sowie ein entsprechendes Simulationsmodell der vollständigen Abläufe des Terminals inklusive Energiebedarfsaufzeichnung.

Dies führt zu der ersten Forschungsfrage:

„Wie können etablierte Verfahren zur Lastgangprognose eines maritimen Containerterminals unter Berücksichtigung von Wissen über geplante Betriebsprozesse entwickelt und genutzt werden?“

Es geht bei dieser Fragestellung insbesondere darum, welche der Verfahren besonders geeignet sind, den Lastgang eines Containerterminals zu prognostizieren. Zudem soll zusätzlich ein eigenes Verfahren entwickelt werden, welches basierend auf Tagen der Vergangenheit mit ähnlichem Transportaufkommen den Lastgang prognostiziert. Hierzu soll die Methode des Fallbasierten Schließens (FBS) genutzt werden. Es muss ein Ähnlichkeitsmodell für die Domäne der Containerterminals erstellt werden, eine umfangreiche Fallbasis aus Vergangenheitsdaten aufgebaut werden und Adaptionsregeln für die Anpassung eines Lastgangs an aktuelle Situationen aufgestellt werden. Es sollen also Tage mit ähnlichem Transportaufkommen wie an dem zu prognostizierenden Tag gesucht und die darauf basierenden historischen Lastverläufe dieser Tage für die aktuelle Prognose angepasst werden.

Daraus ergibt sich die zweite Forschungsfrage:

„Wie kann ein fallbasiertes System zur Lastgangvorhersage eines maritimen Containerterminals entwickelt und genutzt werden?“

Der Einsatz des Fallbasierten Schließens bei der Lastgangvorhersage würde einige Vorteile bieten. So lässt sich Domänenwissen in das Prognoseverfahren integrieren, welches nicht nur für ein spezielles Containerterminal gültig wäre, wie es zum Beispiel bei der Prognose mittels Simulation der Fall ist, sondern für alle Containerterminals, bei denen die Zeitpunkte der Schiffsankünfte und Schiffsabfahrten direkten Einfluss auf die Umschlagintensität des Systems haben. Ähnliche Tage würden nicht wie beim Vergleichstagverfahren nur über ähnliche kalendarische und meteorologische Einflüsse definiert, sondern an tatsächlich auch im Tagesbetrieb relevanten Planungsdaten wie die Schiffsankunfts- und Containerbewegungsdaten, bei einem deutlich verringerten Modellierungsaufwand im Gegensatz zur Simulation. Das Verfahren würde zudem die Unregelmäßigkeiten in den Prozessabläufen besser berücksichtigen als es statistische Methoden der Zeitreihenanalyse tun könnten, da diese vor allen Dingen auf den zu beobachtenden Regelmäßigkeiten aufsetzen. Zusätzlich werden Schätzverfahren für die Abweichungen von diesen Regelmäßigkeiten angewendet und somit ist das Ergebnis auch unmittelbar von der Güte dieser Schätzmethoden abhängig. Es wird zudem erwartet, dass die Ergebnisse nachvollziehbarer sind als Ergebnisse, die ein entsprechend trainiertes Künstliches Neuronales Netz liefern würde. Um zu untersuchen, ob diese Vorteile auch wirklich zutreffen wird das zu entwickelnde FBS-System für die Lastgangprognose (im Folgenden auch „Fallbasierte Lastgangprognose“ genannt) mit weiteren Methoden der Lastgangprognose aus verschiedenen Verfahrensklassen verglichen.

Zum Vergleich der einzelnen Verfahren können statistische Gütemaße aus dem Bereich der Zeitreihenanalyse bzw. Prognose herangezogen werden. Etablierte Kennzahlen sind hier u. a. der mittlere absolute prozentuale Fehler (MAPE, *mean absolute percentage error*), die mittlere quadratische Abweichung (MSE, *mean squared error*) und die Wurzel des mittleren quadratischen prozentualen Fehlers (RMSPE, *root mean squared percentage error*). Neben diesen mathematischen Vergleichswerten sollen aber auch weitere „weiche“ Faktoren verglichen werden. Dies können zum Beispiel eine Bewertung des initialen Modellierungsaufwands, die Übertragbarkeit auf weitere Systeme und der Rechenaufwand der einzelnen Prognoseverfahren sein.

1.3 Ziel der Arbeit

In dieser Arbeit werden zur Beantwortung der in Kapitel 1.2.2 genannten Forschungsfragen, unter Einbeziehung von Wissen über operationelle Abläufe, Konzepte für sowohl bereits etablierte Lastgangprognoseverfahren, als auch ein neues Verfahren für Containerterminals erstellt, implementiert und Ergebnisse im Rahmen einer Fallstudie systematisch untersucht. Dabei soll diskutiert werden, welche Verfahren für die Prognose des täglichen Lastgangs eines Containerterminals geeignet sind und welche dabei in Betrachtung verschiedener Aspekte am besten abschneiden. Wesentliches Ziel ist es, Terminalbetreibern eine Entscheidungsunterstützung für die Auswahl von geeigneten Verfahren zu liefern. Dabei soll nicht nur das Kriterium der Prognosegüte betrachtet werden, sondern auch folgende Aspekte:

- Übertragbarkeit
- Einrichtungsaufwand
- Rechenaufwand für die Erstellung einer Prognose

Zur Erreichung dieser Ziele ist die Erstellung eines Artefaktes zur Lastgangprognose eines Containerterminals notwendig. Dieses erstellt mit den Methoden des Fallbasierten Schließens eine Vorhersage über den Verlauf des Lastgangs des nächsten Tages trifft. Insbesondere soll ein Ähnlichkeitsmodell für den Vergleich von Lastverläufen verschiedener Tage auf Basis der Schiffsankünfte und der Anzahl der geplanten Containerbewegungen entwickelt werden. Es wird davon ausgegangen, dass die Einbeziehung von Domänenwissen in den Prognoseprozess zu einer Verbesserung der Prognosegenauigkeit führt. Ergebnis des Artefakts ist eine Abschätzung des Gesamtenergiebedarfs des Containerterminals je Viertelstunde für den Folgetag.

Weitere Prognoseverfahren sollen in das Artefakt integriert werden, die den gleichen Zweck erfüllen. Es wird gezeigt, wie vorhandenes Wissen über die geplanten Betriebsabläufe des Folgetages genutzt werden, um den Prognoseprozess zu verbessern. Die Implementierung wird dabei für das Fallbeispiel Container Terminal Altenwerder (CTA) in Hamburg vorgenommen. Die Ergebnisse der verschiedenen Verfahren sollen auf Basis von Kennzahlen und weiterer Kriterien miteinander verglichen werden. Für die Evaluation liegen die Energieverbrauchsdaten der Jahre 2010 bis 2014 des CTA vor. Anhand dieser können Prognosen, die für einen Tag in diesen Jahren erstellt werden, den real aufgetretenen Verbrauchswerten gegenüber gestellt werden. So soll überprüft werden, wie sich ein fallbasiertes System im Verhältnis zu den weiteren Verfahren verhält. Dies soll aber nicht nur anhand von Kennzahlen für die Prognosegüte erfolgen, sondern auch anhand weiterer Kriterien, wie zum Beispiel der Über-

tragbarkeit auf weitere Containerterminals oder des benötigten Rechenaufwands für die Prognoseerstellung. Ziel ist es, eine möglichst objektive Bewertung der verschiedenen Verfahren, inklusive des eigenen Ansatzes, zur Prognose des Lastverlaufs zu erstellen, die nicht nur die Prognosegüte berücksichtigt, sondern auch die weiteren Faktoren wie Berechnungsaufwand und Übertragbarkeit. Damit kann eine Entscheidungsunterstützung für die Umsetzung von Prognoseverfahren für Containerterminals unter Berücksichtigung verschiedener Entscheidungskriterien geliefert werden und eine Vorlage für eine mögliche Implementierung in weiteren Containerterminals bereitgestellt werden.

Die vorliegende Arbeit gliedert sich in 7 Kapitel. Bereits beschrieben worden sind in den vorangegangenen Kapiteln die Motivation und Problembeschreibung, sowie die Definition des Ziels dieser Arbeit. Es folgt ein Kapitel zu wesentlichen Grundlagen und verwandten Arbeiten, die als Basis für die Entwicklung entsprechender Konzepte und deren Umsetzung benötigt werden. Für alle Konzepte und die mögliche Integration von Wissen über Abläufe im Terminal sind zudem allgemeine Erkenntnisse aus der Untersuchung des Lastverhaltens eines Terminals nützlich, die in Kapitel 5 vorgestellt werden. Anschließend werden die Konzepte für die Umsetzung der einzelnen Prognoseverfahren vorgestellt, wobei die fallbasierte Prognose einen Schwerpunkt einnimmt. Kapitel 6 umfasst die Evaluation der Konzepte anhand eines Fallbeispiels, für welches auch die konkrete Umsetzung beschrieben wird. Eine Bewertung der einzelnen Verfahren erfolgt auf Basis von Kennzahlen zur Prognosegüte und weiteren Kriterien. Die Arbeit schließt mit einer Rekapitulation und einem Ausblick.

Für die Erstellung dieser Arbeit wurden Daten des Container Terminal Altenwerder (CTA) in Hamburg als Fallstudie genutzt. Dies betrifft sowohl die Betrachtung von Containerumschlagzahlen und der Strombedarfswerte sowie deren viertelstündliche Verläufe. Insbesondere die letzteren Daten sind vertrauliche Daten des Terminals, weshalb in dieser Arbeit Lastgänge durchgehend ohne eine Beschriftung auf der y-Achse abgebildet werden und zum Teil mit einem Verlauf dargestellt werden. Zudem werden Betrachtungen von einzelnen Werten immer in einem relativen Bezug vorgenommen, um die Vertraulichkeit der vorliegenden Daten wahren zu können. Die Ergebnisse der Fallstudie basieren wiederum auf den tatsächlich gemessenen Daten des Terminals. Wo immer möglich wurden öffentlich zugängliche Daten für die Darstellung und Erläuterung von Sachverhalten genutzt.

2 Grundlagen

Im Folgenden werden als Grundlage für die Entwicklung von Prognoseverfahren verschiedene etablierte Methoden für die Lastgangvorhersage vorgestellt. Eine Methode aus dem Bereich der künstlichen Intelligenz, die noch nicht häufig im Bereich der Energiewirtschaft zur Anwendung kommt, aber für sehr dynamische Logistiksysteme, wie das eines Containerterminals, vielversprechend zu sein scheint, ist Fallbasiertes Schließen (englisch: Case-Based Reasoning, kurz: FBS). Die Methode wird im Folgenden ebenfalls kurz eingeführt, bevor anschließend relevante Forschungsfragen aus dem Bereich Lastgangprognoseverfahren für ein Containerterminal formuliert werden.

2.1 Prognose von Zeitreihen

Unter einer Prognose wird im Allgemeinen eine systematische Vorgehensweise zur Ermittlung von Aussagen über zukünftige Zustände eines Systems anhand des gegenwärtigen Zustandes und der Kenntnis der vergangenen Entwicklung dieses Systems verstanden [Vog15]. Einen besonderen Fall stellt dabei die Prognose von Zeitreihen dar. Eine Zeitreihe ist eine geordnete Folge $(y_t)_{t \in T}$ von beobachteten Daten, die in regelmäßigen Abständen erhoben wurden. Für jeden Zeitpunkt t einer Menge T von Beobachtungszeitpunkten liegt dabei genau ein Datum vor [SS01]. Üblicherweise ist die Menge von Zeitpunkten endlich und diskret und im eigentlichen Sinne die Realisierung eines stochastischen Prozesses. Beispiele für Zeitreihen sind zum Beispiel Börsenkurse, Umsatzzahlen von Unternehmen oder Temperaturverläufe. Die Prognose von Zeitreihen beschäftigt sich mit Aussagen über den weiteren Verlauf der Reihe, d. h. über den Zeitraum mit vorliegenden Daten hinaus gehend. Dabei kann zwischen qualitativen und quantitativen Prognosemethoden unterschieden werden [Vog15].

Einführung 1: Zeitreihen und deren Prognose

Eine Zeitreihe y_t mit $t = 1, 2, \dots, n$ ist eine zeitlich geordnete Folge von beobachteten Werten. Die systematische Vorhersage der Weiterführung dieser Folge über t_n hinaus, ohne dass die Beobachtungen für den entsprechenden Zeitraum vorliegen, wird Prognose genannt. Die Prognose der Zeitreihe \hat{y}_t mit $t = n+1, n+2, \dots, n+h$ ist dabei aufgrund der Analyse von Vergangenheitsdaten und ggf. weiteren Zusammenhängen in der Vergangenheit empirisch fundiert.

h beschreibt den Prognosehorizont, d. h. den zeitlichen Rahmen der Weiterführung.

Auf Basis des stochastischen Prozesses können Aussagen über die zeitabhängigen Merkmale gemacht werden, die auch über die konkrete Zeitreihe hinausgehen können. Mit diesem Thema beschäftigt sich das Gebiet der Zeitreihenanalyse, welches die Beschreibung, Modellierung und Zerlegung von Zeitreihen umfasst. Eine wichtige Aufgabe der Zeitreihenanalyse ist aber auch über den weiteren Verlauf, d. h. über den vorliegenden Zeitraum mit vorliegenden Daten hinausgehend, Aussagen zu treffen und damit eine Prognose zu erstellen.

Die Zeitreihenanalyse gehört damit zu den Entwicklungsprognosen, die nicht direkt beeinflussbare Variablen (z. B. die Zeit), als abhängige Größen untersuchen. Dem gegenüber stehen

die Wirkungsprognosen, bei der kausale Effekte von beeinflussbaren Variablen untersucht werden. Zu dem zweiten Typ der quantitativen Prognosen zählt zum Beispiel die Regressionsanalyse. Für diese Arbeit relevant sind aber im Wesentlichen die Methoden der Entwicklungsprognose, denen unter anderem auch Prognosen mittels Künstlicher Neuronaler Netze zuzuordnen sind.

Obwohl Werte aus Zeitreihen in diskreten zeitlichen Abständen erhoben werden, werden sie häufig in einem Liniendiagramm dargestellt.

2.2 Lastgangprognose im energiewirtschaftlichen Kontext

Im liberalisierten Energiemarkt erfolgen der Einsatz der Kraftwerke und der Betrieb der Netze auf der Basis von Fahrplänen (siehe Einführung 2), die von den Bilanzkreisverantwortlichen (BKV) für jede Viertelstunde des nachfolgenden Tages erstellt werden. Die Aufstellung der Fahrpläne erfolgt auf der Basis von historischen Daten für typische Tage, Wetterprognosen und sonstigen Ereignissen, die den Lastverlauf beeinflussen können.

Während Fahrpläne auf die Zukunft ausgerichtet sind, werden für Kunden mit einem Jahresverbrauch von mehr als 100.000 Kilowattstunden (üblicherweise Industriekunden oder große gewerbliche Verbraucher) Einrichtungen zur registrierenden Leistungsmessung installiert. Diese speichern alle 15 Minuten den aktuellen Verbrauchswert. Der Verlauf der 15-minütigen Verbrauchswerte über die Zeit wird Lastgang genannt und vom Messdienstleister mehrmals am Tag per Datenfernübertragung ausgelesen und an den Netzbetreiber übermittelt, u. a. um das Bilanzgleichgewicht zwischen Ein- und Ausspeisung bestimmen zu können. Dadurch ergibt sich für Stromlieferanten die Möglichkeiten auch noch kurzfristig auf Fahrplanabweichungen zu reagieren und so die Kosten für Ausgleichsenergie zu vermeiden, welche bei entsprechenden Abweichungen zu zahlen wären.

Einführung 2: Lastgang/Lastprofil und Fahrpläne

Ein Lastgang, auch Lastprofil genannt, ist eine geordnete Zeitreihe, die den Verlauf von gemessenen Energiemengen über die Zeit beschreibt. Ein einzelner Zeitabschnitt wird auch Zeitscheibe genannt. In einem Lastgang wird jeder Zeitscheibe ein gemessener Energieverbrauch zugeordnet.

Im Bereich Strom werden dazu üblicherweise die Energiemengen in der Einheit kWh alle 15 Minuten aufgezeichnet. Der Lastgang eines Tages d (auch Tageslastgang genannt) besteht damit aus 96 Werten. Der erste Wert beschreibt die gemessene Energiemenge von 00:00:00 Uhr des Tages bis 00:14:59 Uhr des Tages. Die folgenden Werte entsprechend die darauffolgenden Viertelstunden.

Enthält ein Lastprofil Leistungsvorgaben für Steuerung von Energieanlagen oder für Mengenangaben im Energiehandel, so spricht man von Fahrplänen.

$$LG(d) = \{kWh_{q1}, kWh_{q2}, kWh_{q2}, \dots, kWh_{q96}\}$$

Zum Vergleich: Im Bereich Gas werden Lastgangwerte nur alle 60 Minuten erfasst, somit enthält ein Tageslastgang auch nur 24 Verbrauchswerte.

Für Kunden mit weniger als 100.000 Kilowattstunden Jahresverbrauch werden Standardlastprofile eingesetzt, die, verbunden mit einem kundenindividuellen Faktor, den 15-minütigen Lastverlauf über den Tag annähern sollen. Dazu sind in den Standardlastprofilen für bestimmte Verbrauchsgruppen standardisierte Lastverläufe hinterlegt. Diese werden zusätzlich noch nach verschiedenen Wochentagen unterschieden.

Verantwortlich für die Messung der Verbrauchswerte ist im Energiesektor der Messdienstleister, der die gemessenen Werte an den Netzbetreiber übermittelt. Häufig werden die Marktrollen Messdienstleister, Messstellenbetreiber und Netzbetreiber von einer rechtlichen Einheit, z. B. einem Stadtwerk erbracht. Der Netzbetreiber hat Kenntnis, welcher Lieferant die Messstelle beliefert und leitet die Messwerte an den entsprechenden Lieferanten weiter.

Die Kenntnis über den zukünftigen Bedarf an elektrischer Energie (Lastgangprognose) spielt eine grundlegende Rolle bei der Planung und Strukturierung von Infrastrukturmaßnahmen und der Bedarfsdeckung für Energieversorgungsunternehmen (EVU) und industrielle Großverbraucher. Die Lastgangprognose kann für unterschiedliche Zeithorizonte erfolgen und unterscheidet sich damit auch in den Zwecken, für welche sie erfolgt. Tabelle 1 zeigt eine entsprechende Klassifikation, wie sie in der wissenschaftlichen Literatur häufig vorgenommen wird (z. B. [MWE97] oder [Hon10]). Während bei den kurzfristigen Lastgangprognosen der Verlauf der Werte innerhalb eines Tages im Vordergrund steht, sind bei der mittel- und langfristigen Prognose häufig aggregierte Werte auf Tages-, Monats- oder Jahresbasis von Interesse, die auch langfristige Kennzahlen zu ökonomischen oder sozialen Entwicklungen in die Berechnung mit einbeziehen.

Name	Englischer Begriff	Abkürzung	Zeithorizont	Zweck
Sehr kurzfristige Lastgangprognose	Very Short Term Load Forecasting	VSTLF	Minuten bis Stunden	Netzsteuerung, Intraday-Handel
Kurzfristige Lastgangprognose	Short Term Load Forecasting	STLF	Stunden bis einige Tage	Day-Ahead-Handel, Bilanzkreisführung, Demand Side Integration Maßnahmen
Mittelfristige Lastgangprognose	Medium Term Load Forecasting	MTLF	Wochen bis Monate	Einkauf und Bedarfsdeckung, Portfoliooptimierung
Langfristige Lastgangprognose	Long Term Load Forecasting	LTLF	Jahre	Planung von Infrastrukturmaßnahmen (z. B. Netzauslegung)

Tabelle 1: Klassifikation der Lastgangprognose nach Zeithorizont

Der Lastgangprognose im Allgemeinen und ihrer Qualität im Besonderen kommt in diesem Zusammenhang eine mit der Liberalisierung des deutschen Elektrizitätsmarktes gestiegene Bedeutung zu. Zum Ersten wurden die traditionellen Möglichkeiten Eigenerzeugung und Vollstromversorgung um neue Bezugsplattformen erweitert. Mit der Entwicklung eines liquiden Großhandelsmarktes eröffneten sich für die Marktteilnehmer wie Energieversorgungsunternehmen und industrielle Großkunden, Alternativen der Energiebeschaffung und des Energieabsatzes. Zum Zweiten legten die Regulierungsbehörden Kriterien und Instrumente zur Abwicklung und Abrechnung von Energielieferungen fest. Insbesondere der Kurzfristprognose

se für den Lastverlauf des Folgetags kommt eine besondere Bedeutung zu, da diese bei der Bewirtschaftung von Bilanzkreisen die Möglichkeit einer letzten Portfolioanpassung bietet, bevor die Prognose als Fahrplan fest in den Bilanzkreis eingestellt wird („Nominierung“).

Einführung 3: Lastgangprognose

Im Sinne dieser Arbeit wird unter einer Lastgangprognose die quantitative Vorhersage des Lastverlaufes über einen Tag verstanden. Die Lastgangprognose in der Sparte Strom umfasst somit 96 Werte für einen Zeitraum für den keine gemessenen Werte vorliegen.

Üblicherweise wird eine Lastgangprognose am Tag vor der eigentlichen Lieferung $D-1$ für den Tag der Lieferung D erstellt. Am Tag nach der Lieferung $D+1$ kann die Prognose mit den tatsächlich gemessenen Werten vom Liefertag verglichen werden.

Je genauer die Prognose des Verbrauchsverhaltens, desto gezielter ist der Lieferant oder der Großverbraucher, in der Lage, ggf. über einen Händler, den Einkauf, also die Beschaffung, abzuwickeln. Bei Prognoseabweichungen droht die Zahlung für Ausgleichsenergie, die als Abweichung zwischen den tatsächlich beschafften und den verbrauchten Werten in den Bilanzkreis eingestellt wird. Die Preise für Ausgleichsenergie werden nach einem einheitlichem Verfahren von dem Transportnetzbetreiber für alle Bilanzkreisverantwortlichen einheitlich festgelegt und liegen üblicherweise über den typischen Beschaffungspreisen. Daher hat der Lieferant bzw. Großverbraucher ein hohes Interesse an einer möglichst genauen Prognose für den zukünftigen Verbrauch seiner Endkunden, insbesondere der leistungsgemessenen Kunden.

Auf Endkundenseite haben Verbraucher, insbesondere industrielle Großverbraucher, mit einer Lastgangprognose des zukünftigen Leistungsbedarfs die Möglichkeit, das eigene Abnahmeverhalten auf die zwischen ihnen und einem Stromlieferanten vereinbarten Tarifbedingungen einzustellen. Dies bedeutet zum Beispiel, den Stromverbrauch in der Aufteilung auf einen Haupt- und Nebentarif zu optimieren. Natürlich wünscht sich ein Stromlieferant, dass sich der flexible Verbraucher in der Weise auf das Tarifgebilde – sei es eine Kombination von tageszeit- oder von lastabhängigen Tarifmerkmalen – einstellt und dass sich sein Lastgangverhalten wiederholt und es sich statistisch besser abschätzen lässt. Wenn sich das Abnahmeverhalten seines flexiblen Endkunden als langfristig stabil annehmen lässt, hat der Stromlieferant die Möglichkeit, sich recht frühzeitig an den Terminmärkten einzudecken. In jedem Fall nimmt der Lieferant eine Lastgangprognose von seinem Endkunden gerne entgegen, um besser über das Abnahmeverhalten informiert zu sein. Die Informationen von Endkundenseite sind wertvoll für den Lieferanten, da es ansonsten nur statistische Ansätze zur Einschätzung des Abnahmeverhaltens aus der eingeschränkten Perspektive des Lieferanten gibt. Für den Stromlieferanten wird das Energiemengenrisiko im Übergang vom langfristigen zum kurzfristigen Handel auf den Elektrizitätsmärkten reduziert.

Auch für die Bereitstellung von Energiedienstleistungen im Rahmen von Demand Response oder Demand Side Management-Maßnahmen spielt die kurzfristige Lastgangprognose eine entscheidende Rolle: Sie ermöglicht die Bestimmung von Flexibilität im Lastverlauf und die Einplanung einer solchen für Lastverschiebemaßnahmen oder das Angebot der Flexibilität am Energiemarkt über einen Aggregator bzw. als Teil eines virtuellen Kraftwerks.

In Deutschland ist es für die Teilnahme am Day-Ahead-Markt für den Energiehandel oder an der Ausschreibung für Minutenreserveleistung erforderlich, dass entsprechende Prognosen bis 10:00 Uhr (Angebotsfrist für Minutenreserveleistung) bzw. 12:00 Uhr (Gebotsfrist für Day-Ahead-Auktion) des Vortages vorliegen, damit an den angesprochenen Märkten teilgenommen werden kann. In diesen Fällen ist zu beachten, dass es nicht unbedingt ausreicht, den folgenden Tag zu prognostizieren, sondern auch der weitere Verlauf des aktuellen Tages unbekannt ist und in den Prognosehorizont integriert werden sollte, wie in Abbildung 5 dargestellt.



Abbildung 5: Darstellung des Prognosezeitpunkts für die Teilnahme an Ausschreibungen am Minutenreservemarkt

Noch kurzfristiger ist der Handel im Intraday-Markt. Hier können Stunden- und Viertelstundenprodukte noch bis 5 Minuten vor Lieferzeitpunkt gehandelt werden. Liegen also kurzfristig Erkenntnisse vor, dass die bisher vorliegende Prognose angepasst werden muss, so kann dies bis zu einem Zeitpunkt sehr kurzfristig vor dem Lieferzeitpunkt erfolgen.

2.3 Methoden der Lastgangprognose

Die Relevanz einer möglichst exakten Prognose resultiert in einer Vielzahl an Methoden und Verfahren, die zur Lastgangprognose angewendet werden und deren Ursprünge in unterschiedlichen wissenschaftlichen Bereichen liegen (vgl. Kapitel 3.1).

Während für eine lange Zeit die Verbesserung der Genauigkeit der Lastgangprognose im Fokus von Forschungstätigkeiten in diesem Bereich war, hat inzwischen auch die Effizienz der Berechnung entsprechender Prognosen an Bedeutung gewonnen. Dannecker [Dan15] führt aus, dass dies insbesondere in der immer weiter aufkommenden Notwendigkeit begründet liegt, einen immer kurzfristigeren Ausgleich zwischen Erzeugung und Verbrauch auch auf der Marktebene herstellen zu müssen. Reichte es früher in vielen Fällen eine einzelne Prognose für den Folgetag zu erstellen, so ist es mit Integration der fluktuierenden Erzeugung von Energie aus erneuerbaren Quellen notwendig, dies auch untertäglich zu tun, um immer die aktuellsten Messwerte und Prognosewerte von Einflussfaktoren berücksichtigen zu können. Wie bereits im vorhergehenden Kapitel beschrieben, hat sich inzwischen an der Strombörse dazu entsprechend auch der Intraday-Markt etabliert, bei dem Produkte bis kurz vor der Lieferung gehandelt werden können.

Eine Klassifikation von Verfahren zur Erstellung einer Lastgangprognose kann nach deren zugrunde liegenden Methoden erfolgen. Hirsch [Hir15] nimmt eine Aufteilung in die drei Klassen „Klassische Verfahren“, „Künstliche Intelligenz“ und „Referenzbasierte Verfahren“ vor (vgl. Abbildung 6). Basierend auf mathematischen Modellen beschreiben die klassischen Verfahren den Zusammenhang zwischen der Last und mindestens einer unabhängigen Eingangsgröße. Diese Modelle nutzen dabei meist die zurückliegende Entwicklung des Lastverlaufs für die Berechnung der zukünftigen Verbrauchswerte. Neben Kalman-Filtern, die eine Reihe von Messungen verwenden, um statistisches Rauschen und andere Ungenauigkeiten beobachten und Schätzungen unbekannter Variablen zu erzeugen, werden hier häufig Methoden der Regressions- und der Zeitreihenanalyse genutzt. Dabei kann die Zeitreihenanalyse noch einmal in Verfahren des exponentiellen Glättens und in ARMA-Modelle („Autoregressive-moving average“) aufgeteilt werden. Meist ohne analytische Modellierung kommen dagegen die Verfahren der künstlichen Intelligenz aus, bei denen versucht wird, menschliches Lernverhalten nachzubilden. Dadurch werden die Verfahren weitestgehend tolerant gegenüber nicht-linearem Verhalten und Unsicherheiten. Neben den häufig genutzten Künstlichen Neuronalen Netzen finden sich auch Fuzzy-Systeme, die vages Wissen formalisieren und approximative Schlüsse daraus ziehen, Support Vector Machines, welche eine Menge von Objekten unter Nutzung von Hyperebenen in unterschiedliche Klassen einteilen, und Expertensysteme. Letztere versuchen das Wissen von Menschen, häufig ausgehend von einer Wissensbasis mit Regelsystemen, nachzubilden. Fallbasiertes Schließen (vgl. Kapitel 2.4) ist eine Methode, die genutzt werden kann, um Funktionen eines Expertensystems zu implementieren. Am einfachsten anzuwenden sind die referenzbasierten Prognosemethoden. Hier ist kein komplexes theoretisches Modell nötig, welches erst erstellt oder angepasst werden muss.

Für die kurzfristige Prognose von einzelnen, nicht leistungsgemessenen, Kunden werden im deutschen Marktmodell repräsentative Standardlastprofile (SLP) genutzt, die das Verbraucherverhalten bestimmter Kundengruppen abbilden sollen. Die Werte der SLP werden mit einem individuellen Verbrauchsfaktor verrechnet und so für die Zuordnung von Verbräuchen zu einzelnen Abnahmestellen genutzt („Allokation“). Nicht aufgeführt in der Abbildung 6 ist die Prognose mit Hilfe von Simulation, da Simulation im Bereich der (kurzfristigen) Lastgangprognose nicht weit verbreitet ist. Dies liegt unter anderem daran, dass die Abbildung des zu prognostizierenden Ausschnitts der Realität häufig zu komplex ist. Trotzdem kann es sinnvoll sein, insbesondere in geschlossenen dynamischen Systemen, das reale System in einer entsprechenden Simulationsumgebung nachzubilden und entsprechende Lastverhalten zu hinterlegen, zu beobachten und aufzuzeichnen, um Aussagen auch über zukünftiges Lastverhalten treffen zu können. Daher wurde die Auflistung der Simulation in der Kategorie der weiteren Verfahren aufgenommen, zu der auch die Schätzung durch einen Experten gezählt werden kann.

Im Folgenden werden einige ausgewählte Methoden kurz vorgestellt. Bei der Auswahl der Methoden wurde Wert darauf gelegt, dass diese eine weite Verbreitung innerhalb des Energiesektors haben und in der Praxis tatsächlich angewendet werden. Eine der häufigsten Anwendungsformen ist dabei das Vergleichstagverfahren, welches sich aufgrund seiner Einfachheit ohne großen Aufwand auf Basis historischer Lastgangdaten implementieren lässt, aber weitere Einflussfaktoren auf den Lastverlauf weitestgehend außer Acht lässt.

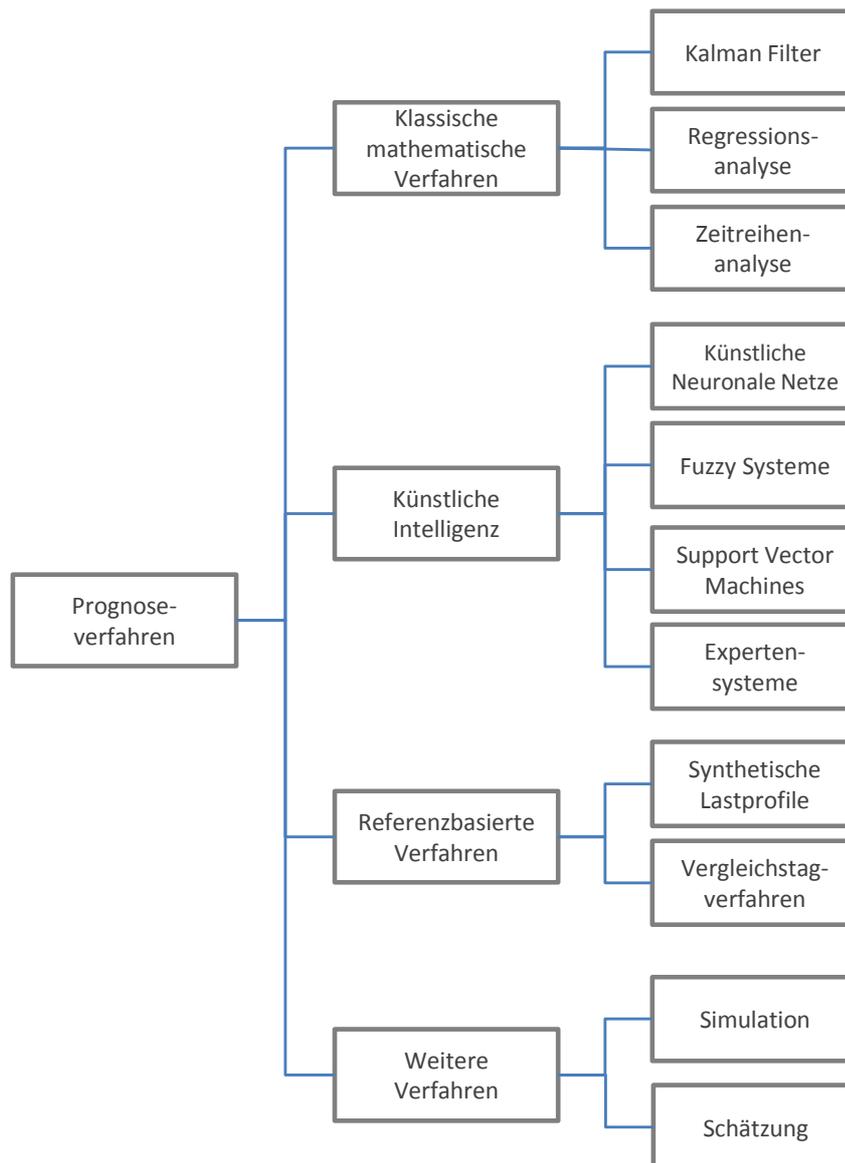


Abbildung 6: Klassifikation der Verfahren zur Lastgangprognose (in Anlehnung an [Hir15])

Eine Vielzahl von Arbeiten findet sich zur Lastgangprognose auf Basis von Modellen aus der Zeitreihenanalyse und der Künstlichen Neuronalen Netze. Eine umfangreiche Erhebung von Hernandez et al. aus dem Jahr 2014 [HBA+14] führt an, dass die sogenannten linearen Modelle, zu denen die Modelle aus dem Bereich der Zeitreihenanalyse in der Studie gezählt werden, in jüngeren Jahren in nur wenigen wissenschaftlichen Veröffentlichungen zum Thema Lastgangprognose zu finden sind. Im Gegensatz dazu steht ein in den vergangenen Jahren erheblich gesteigener Anteil an wissenschaftlichen Arbeiten, welche ein Modell aus dem Bereich der Künstlichen Neuronalen Netze für die Lastgangprognose nutzen. Wenn der Lastverlauf für ein überschaubares System mit abbildbaren Zusammenhängen prognostiziert werden soll, so kann das entsprechende System in einer Simulationsumgebung abgebildet werden und die Stromverbrauchseigenschaften der einzelnen Bestandteile des Systems über die Zeit abgebildet werden. Solche Systeme können zum Beispiel einzelne Verbraucher wie kommerzielle Gebäude, Gewerbebetriebe oder einzelne industrielle Fertigungsstätten sein.

2.3.1 Vergleichstagsverfahren

Die Prognose mit Vergleichstagen zählt zu den referenzbasierten Verfahren der Lastgangprognose und wird auch als naive Methode bezeichnet. Das Verfahren basiert auf der Fortschreibung von historischen Messdaten vergleichbarer Tage in die Zukunft [Kau03]. Vergleichstage werden dabei über gleiche kalendarische Eigenschaften definiert (z. B. gleicher Wochentag der Vorwoche oder gleicher Tag des Vorjahres), eventuell ergänzt um meteorologische Eigenschaften (gleicher Wochentag der Vergangenheit mit einem ähnlichen Temperaturverlauf).

Häufig wird eine Anzahl n an Vergleichstagen als Referenztage gewählt um Fehler zu glätten [FG05]. Die Referenztage können unterschiedlich mit den Anteilen $b=1,\dots,n$ gewichtet werden, um Messwerte aus der Vergangenheit unterschiedlich stark in die Berechnung einfließen zu lassen. Dadurch ist es zum Beispiel möglich, kalendarisch nähere Referenztage höher zu gewichten, als solche die weiter in der Vergangenheit liegen. Hier kann zum Beispiel eine geometrische Reihe genutzt werden. Die Anzahl der Tage d , um die dabei zurückgegangen wird, ist frei parametrierbar. Üblicherweise werden hier je nach Anwendungsfall der Vortag, die Vorwoche oder der gleiche Tag im Vorjahr genutzt. Der prognostizierte Wert \hat{y}_t ergibt sich dementsprechend nach folgendem Ansatz:

$$\hat{y}_t = b_1 * y_{t-d_1} + b_2 * y_{t-d_2} + \dots + b_n * y_{t-d_n} \quad (1)$$

Dabei steht y_{t-d_n} für den Messwert des entsprechenden Zeitpunktes in der Vergangenheit. Für besondere Tage wie Feier-, Sonn-, und Brückentage werden dabei häufig andere Kriterien für die Referenztagauswahl zugrunde gelegt als für Werktage. Zum Beispiel wird derselbe Feiertag aus dem Vorjahr als Basis genommen oder ein vergangener Sonntag.

Da die Verfahren mit Vergleichstagen einfach umzusetzen sind, haben diese auch heute noch eine weite Verbreitung in Energieversorgungsunternehmen.

2.3.2 Zeitreihenanalyse

Aus dem Bereich der mathematischen Methoden stammen verschiedene Modelle der Zeitreihenanalyse und Regressionsanalysen. Sie stellen den klassischen Ansatz der Prognose von Lastverläufen dar.

Als Zeitreihe wird ganz allgemein eine Sammlung von numerischen Werten bezeichnet, welche in regelmäßiger zeitlicher Folge beobachtet und festgehalten wurden. Ein Lastgang ist damit eine Ausprägung einer Zeitreihe.

Mit ARMA („Autoregressive-moving-average“) wird eine Klasse linearer Modelle für stationäre, zeitdiskrete stochastische Prozesse bezeichnet, die genutzt werden, um Eigenschaften von Zeitreihen abzubilden. Ein etabliertes Beispiel stellt z. B. das Modell ARIMA („Autoregressive-integrated moving average“) dar. Dabei werden autoregressive Prozesse (AR) mit gleitenden Mittelwertmodellen (MA) zusammengeführt. Der Begriff autoregressiv beschreibt stochastische Modelle, welche die Zielvariable z_t auf die Linearkombination der Werte zu früheren Zeitpunkten und einen aktuellen Fehlerterm ε zurückführen. Ein autoregressives Modell kann somit durch die Gleichung

$$z_t = \alpha_0 + \alpha_1 z_{t-1} + \alpha_2 z_{t-2} + \dots + \alpha_p z_{t-p} + \varepsilon_t \quad (2)$$

beschrieben werden, wobei p die Ordnung angibt und somit wie viele Zeitschritte die herangezogenen Vergangenheitswerte zurückliegen.

Bei Moving-Average-Modellen (MA-Modelle) geht man davon aus, dass die Zeitreihe nicht aus sich selbst, sondern aus den vorangegangenen Störungen erklärt werden kann. Als Störungen werden dabei die Abweichungen der einzelnen beobachteten Werte vom Durchschnitt μ der Zeitreihe bezeichnet. Ein MA-Modell der Ordnung q kann formal als

$$z_t = \mu + \varepsilon_t - \beta_1 \varepsilon_{t-1} - \beta_2 \varepsilon_{t-2} - \dots - \beta_q \varepsilon_{t-q} \quad (3)$$

dargestellt werden. Bei beiden Modellen geht es darum, die Gewichte α bzw. β der einzelnen Terme zu schätzen. Dies kann zum Beispiel mittels der Methode der kleinsten Quadrate oder der Maximum-Likelihood-Methode erfolgen.

Ein Autoregressive Moving Average Model (ARMA) wird durch die Kombination dieser beiden Terme erreicht, so dass sich

$$z_t = \alpha_0 + \alpha_1 z_{t-1} + \dots + \alpha_p z_{t-p} + \varepsilon_t - \beta_1 \varepsilon_{t-1} - \dots - \beta_q \varepsilon_{t-q} \quad (4)$$

ergibt. Um die entsprechenden Werte für die Berechnung und Prognose von Zeitreihenwerten zu nutzen, wird als Voraussetzung die Stationarität der Zeitreihen, das heißt die Befreiung von Trend- und Saisoneinflüssen und eines um Null angesiedelten Durchschnitts, gefordert. Dies kann durch Komponentenzerlegung und Differenzierung der Zeitreihe erreicht werden. Eine Differenzbildung wird durch die Subtraktion eines Wertes mit seinem Vorgänger erreicht. Zudem kann auch die Nutzung des Logarithmus auf die Zeitreihenwerte angewandt werden. Die Anzahl der Differenzbildungen, die benötigt werden, um einen stationären Prozess zu erlangen wird als Integration der Ordnung d bezeichnet. Man erhält damit ein sogenanntes ARIMA[p,d,q]-Modell [Sch01]. Dieses Modell kann noch um sogenannte exogene Variablen x_t ergänzt werden. Diese beschreiben äußere Einflüsse, die auf die Zeitreihe, welche bisher nur in Bezug auf sich selbst betrachtet wurde, einwirken. Ein Beispiel dafür sind meteorologische Einflüsse auf eine elektrische Lastkurve. Ein ARIMAX-Modell („Autoregressive-integrated moving average with exogenous input“) kann beschrieben werden als

$$z_t = \alpha_0 + \alpha_1 z_{t-1} + \dots + \alpha_p z_{t-p} + \varepsilon_t - \beta_1 \varepsilon_{t-1} - \dots - \beta_q \varepsilon_{t-q} + \gamma_r x_{r,1} + \dots + \gamma_{r,t} \quad (5)$$

wobei r für eine der R - Einflussgrößen steht [Swi06].

Ein verbreitetes Vorgehen zur Modellbestimmung und Anwendung von ARMA-Modellen beschreiben Box und Jenkins [BJ76].

Methoden der Zeitreihenanalyse werden häufig für die Lastgangprognose angewandt und sind entsprechend verbreitet umgesetzt. Dazu wird auf Basis der vorliegenden beobachteten Werte ein Modell bestimmt, welches anschließend zur Extrapolation der zukünftigen Werte genutzt wird. Teilweise werden die Verfahren dabei auch mit weiteren Methoden kombiniert.

2.3.3 Künstliche Neuronale Netze

Aus dem Bereich der künstlichen Intelligenz stammt das Modell der Künstlichen Neuronalen Netze (KNN). Bei Künstlichen Neuronalen Netzen handelt es sich um informationsverarbeitende Systeme, die sich an biologischen Nervensystemen orientieren. Analog zum biologischen Vorbild bestehen KNN aus einer sehr großen Anzahl parallel arbeitender Einheiten, den sogenannten Neuronen, die im Vergleich zum Gesamtsystem jeweils sehr einfach aufgebaut sind. Diese Neuronen sind untereinander hochgradig verbunden. Durch gerichtete Verbindungen können sie sich deshalb nach vorgegebenen Regeln untereinander aktivieren, wodurch die Informationsverarbeitung stattfindet. Auf diese Weise ist es möglich, durch KNN mittels einfacher arithmetischer Funktionen sehr komplexe Eingabe-Ausgabe-Zusammenhänge abzubilden. Ein fundamentaler Unterschied zwischen KNN und konventionellen Algorithmen ist die Eigenschaft von KNN, zur Bearbeitung eines Problems lediglich eine Struktur und ein Lernverfahren zu benötigen. Das bedeutet, dass nicht jeweils ein problemspezifisches Programm geschrieben wird, sondern, dass sich das Netz für die Bearbeitung eines vorliegenden Problems in einem Lernprozess anhand von Trainingsbeispielen selbstständig konfigurieren muss. Mithilfe der Trainingsbeispiele ist das neuronale Netz in der Lage auf unbekannte Eingaben zu generalisieren. Durch die Lernfähigkeit (die Fähigkeit, sich in einem adaptiven Prozess auf die jeweiligen Erfordernisse einzustellen, ohne dass die jeweilige Konfiguration explizit vorgegeben werden muss) werden reale Vorgänge eines Nervensystems imitiert.

Die meist große Anzahl von Neuronen in einem künstlichen neuronalen Netz wird dabei in Schichten angeordnet. Die Eingabeschicht dient als Schnittstelle für Eingabedaten, wobei die Dimension des Eingabevektors die Anzahl der benötigten Neuronen in dieser Schicht vorgibt.

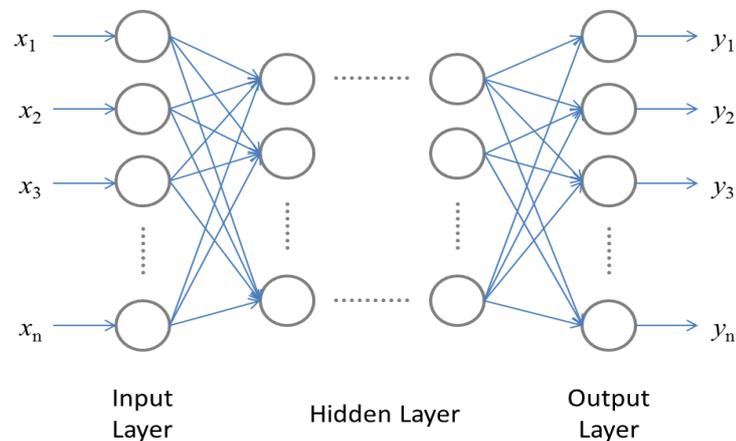


Abbildung 7: Schematischer Aufbau eines Multilayer-Perceptrons (MLP)

Die Signale der Eingabeneuronen werden an alle direkt verbundenen Neuronen weitergegeben. Analog der Eingabeschicht gibt es eine Ausgabeschicht, die die Ausgabe des KNN darstellt. Jedes Neuron der Ausgabeschicht steht dabei für einen Ausgabewert. Die eigentliche Informationsverarbeitung findet in den sogenannten verborgenen Schichten (Hidden Layer) statt. Hierbei handelt es sich um eine beliebige Anzahl von Schichten, die zwischen der Eingabe- und der Ausgabeschicht angeordnet werden. Die Anzahl der verborgenen Schichten sowie die Anzahl der Neuronen jeder dieser Schichten sind dabei freie Parameter eines jeden

Netzes [Eis05]. Ist das Netz aus mehr als einer verborgenen Schicht aufgebaut, so wird dieses Netz auch als Multilayer-Perceptron (MLP) bezeichnet. Abbildung 7 zeigt den schematischen Aufbau eines solchen MLPs. Die Werte $x_1, x_2, x_3, \dots, x_n$ werden in die Eingabeschicht eingegeben, durch die vorgegebene Anzahl von verborgenen Schichten prozessiert und am Ende werden die Werte $y_1, y_2, y_3, \dots, y_n$ von der Ausgabeschicht ausgegeben. Für die Prognose von Zeitreihenwerten wird üblicherweise ein solches Netz mit mehreren verborgenen Schichten genutzt.

Der wichtigste Bestandteil eines KNN ist das für jede Verbindung jeweils individuell festgelegte Gewicht. Durch das Gewicht $w_{i,j}$ wird die Stärke des übertragenen Signals für die Verbindung von Neuron i zu Neuron j erfasst. Es unterscheidet sich in der Regel von den Gewichten der anderen Verbindungen. Während des Lernprozesses von Künstlichen Neuronalen Netzen geht es hauptsächlich um die Veränderung und Anpassung dieser Gewichte, wobei verschiedene Lernverfahren wie Backpropagation, Hebb- oder Delta-Regel zur Anwendung kommen können.

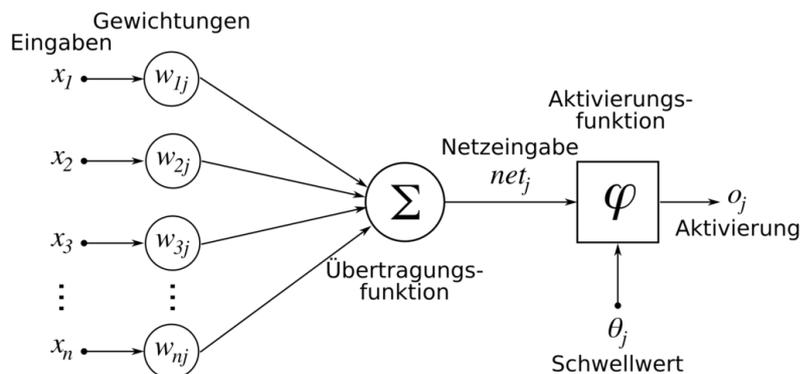


Abbildung 8: Parameter innerhalb eines neuronalen Netzes [Chri05]

Um das Netz zu trainieren ist es notwendig, diejenige Kombination der einzelnen Gewichte zu finden, bei der der Netzfehler minimal ist. Jedem Neuron sind üblicherweise drei Funktionen zugeordnet: eine Netzeingabefunktion, eine Aktivierungsfunktion und eine Ausgabefunktion. Diese Funktionen werden während der Berechnung jeweils mit einer (reellwertigen) Zahl belegt. Ein Eingabeneuron besitzt zusätzlich noch eine vierte Zustandsgröße, die die externe Eingabe ext_u repräsentiert [KBK+11]. Ein Neuron j übernimmt die Eingabe seiner i Vorgängerneuronen, berechnet eine gewichtete Summe über die Eingabewerte, subtrahiert einen Schwellwert θ_i und wendet eine Aktivierungsfunktion a an. Ein Beispiel für eine solche Aktivierungsfunktion ist die Formel

$$y_i = a\left(\sum_{k=1}^n w_{i,k} x_k - \theta_i\right) \quad (6)$$

Mit der Zeit wurden verschiedene Arten von Künstlichen Neuronalen Netzen entwickelt. Diese können unterschieden werden, in KNN, die mit überwachten Lernregeln trainiert werden, wie zum Beispiel das Multilayer-Perceptron und Netze die mit unüberwachten Lernverfahren arbeiten, wie zum Beispiel Kohonen-Maps. Neueste Künstliche Neuronale Netze bestehen aus einer sehr hohen Anzahl von verschiedensten Schichten. Solche Netze werden dem Deep

Learning zugerechnet. Diese werden erfolgreich für die Bildverarbeitung eingesetzt. Im Bereich der Zeitreihenprognose haben Rekurrente Netze erfolgreiche Ansätze gezeigt.

Künstliche Neuronale Netze, u.a. auf der Basis von MLP, werden erfolgreich für die Lastgangprognose in Energieversorgungsunternehmen eingesetzt (vgl. Kapitel 3.1.2). Dabei werden sie nicht nur für kurzfristige Prognosen, sondern auch für mittel- und langfristige Prognosen erfolgreich angewandt. Ein Nachteil der KNN ist jedoch, dass aufgrund der komplexen inneren Struktur eine genaue Interpretation der Modellparameter und ihrer Zusammenhänge so gut wie nicht möglich ist. Die internen Abläufe eines KNN entsprechen bei der Anwendung weitestgehend einer Black-Box. Für die Parametereinstellungen eines Netzes liegen daher in der Literatur auch keine allgemeingültigen Regeln vor.

2.3.4 Simulation

Simulation ist eine Problemlösemethode, die die Nachbildung eines Systems in einem ablauffähigen Modell zum Ziel hat, um mittels systematischer Parameterwahl zu Erkenntnissen zu gelangen, die auf die Wirklichkeit übertragen werden können. Der Vorteil im Vergleich zu analytischen Methoden liegt insbesondere in der Modellierung der systemspezifischen dynamischen Abhängigkeiten und Wechselwirkungen über die Zeit und in der Berücksichtigung stochastischer Aspekte bei der Abbildung des Systemverhaltens [WCBR08]. Die Nachbildung des Verhaltens eines Systems mit einem Modell über einen bestimmten Zeitraum wird Simulationslauf oder Experiment genannt.

Im Bereich der Lastgangvorhersage werden Simulationsmodelle häufig für Mittel- bis Langfristprognosen eingesetzt. Hier können lastbeeinflussende Trends wie zum Beispiel Bevölkerungs- und Wirtschaftsentwicklung oder Wettermodelle und deren Auswirkungen auf das zukünftige Lastverhalten ausgewertet und darauf basierend unter anderem Schlüsse für den Netzausbau gezogen werden.

In der Industrie werden Materialflusssimulationen häufig eingesetzt, um logistische Abläufe in der Produktion zu analysieren. Der Energiebedarf spielt dabei meist nur eine untergeordnete Rolle, allerdings wurden inzwischen bei einzelnen verbreiteten Simulationsplattformen Erweiterungen vorgenommen, die den Leistungsbedarf einzelner Simulationssystemkomponenten je nach Ereignis anpassen. Auf diesem Wege wird es möglich einen Überblick über den Leistungsbedarf über die Zeit bei verschiedenen Szenarien zu bekommen [HTK+11]. Nutzt man Produktionspläne für den nächsten Tag innerhalb eines Simulationsmodells, so gewinnt man auch eine Lastgangvorhersage für den nächsten Tag auf Basis der simulierten Ereignisse in dem entsprechenden System.

Ein Nachteil von Simulationsmodellen liegt darin, dass das entsprechende Modell immer erst mit sehr hohem Modellierungsaufwand auf das abzubildende System möglichst exakt angepasst werden muss und dass das Nachstellen aller Ereignisse über die Zeit sehr rechenaufwändig ist. Durch die möglichst exakte Modellierung handelt es sich bei einem Simulationsmodell um ein hochspezialisiertes System zur Prognose.

2.4 Fallbasiertes Schließen

Fallbasiertes Schließen ist keine klassische Methode für die Prognose von Lastgangdaten. In der vorliegenden Arbeit soll die Methode genutzt werden, um ein Lastgangprognosesystem aufzubauen, daher sollen in diesem Kapitel die Grundlagen von Fallbasiertem Schließen ausführlicher vorgestellt werden.

FBS ist eine Methode aus dem Bereich der künstlichen Intelligenz (KI), die auf die Theorien des „Dynamic Memory“ von Schank [Sch83] zurückgeht. Beim Fallbasierten Schließen wird davon ausgegangen, dass ähnliche Probleme auch ähnliche Lösungen haben. Ist eine ähnliche Lösung gefunden, so wird diese an die aktuelle Situation angepasst. Der grundsätzliche Aufbau basiert darauf, dass Erfahrungen, die gemacht wurden, als Fall in einer Fallbasis gespeichert werden. Für ein aktuelles Problem wird versucht in der gegebenen Speicherstruktur mit entsprechenden Retrievalverfahren einen ähnlichen Fall zu finden. Die gefundene Erfahrung wird dann so, wie sie vorliegt oder bereits an die Suche angepasst, herangezogen, um sie zur Lösung des aktuellen Problems wiederzuverwenden [AP94]. Im Gegensatz zu generellen Problemlöse-Ansätzen der KI ist Fallbasiertes Schließen immer domänenabhängig, denn es nutzt spezifisches Wissen über die jeweilige Domäne.

Mit der ständigen Weiterentwicklung des Fallbasierten Schließens haben sich verschiedene Ansätze für die Technik herausgebildet. Hauptsächliche Unterscheidungsmerkmale sind die Art der Fallrepräsentation und des Findens der Fälle in der Fallbasis (Retrieval). Jeder Ansatz hat spezifische Vor- und Nachteile für verschiedene Anwendungsbereiche, im Folgenden soll der Ansatz des strukturellen FBS vorgestellt werden. Strukturelles FBS ist der klassische Ansatz des Fallbasierten Schließens. Ein Fall besteht dabei immer mindestens aus einem Problem (in Form von Symptomen) und einer dazu passenden Lösung. Die zugrunde liegende Idee ist es, die Fälle mit einem strukturierten Vokabular oder einem Domänenmodell darzustellen. Dieses Vokabular ist die Grundlage zur Darstellung aller Zusammenhänge und benötigten Informationen, meist auf Basis der Darstellung als Attribut-Wert-Beziehungen oder in Objekten. Die einzelnen Attribute, mit denen das Problemfeld beschrieben wird, besitzen je nach darzustellender Entität verschiedene Wertebereiche und Ausprägungen und bilden das Vokabular des fallbasierten Systems.

Einführung 4: Ein Fall als Attribut-Wert Darstellung

Ein Fall F (englisch: case) ist die Beschreibung einer in der Realität aufgetretenen Situation bzw. Problemstellung (englisch: description, kurz: *descr*) und der dazugehörigen validierten Lösung (englisch: solution, kurz: *sol*). Eine Anfrage (englisch: *query*) an ein fallbasiertes System stellt einen speziellen Fall dar, der nur die Problemstellung enthält.

$$\begin{aligned} F_{case} &= (descr, sol) \\ F_{query} &= (descr) \end{aligned} \quad (7)$$

Ein Fall enthält eine eindeutige Kennung und eine Anzahl von Informationseinheiten (*IEs*). Eine Informationseinheit ist dabei definiert als „[...] atomare Wissensseinheit der Domäne, d.h. eine Informationseinheit repräsentiert jeweils die feinste Granularität der Wissensrepräsentation für Fälle und Anfragen“ [Len99]. Am häufigsten werden Attribut-Wert-Paare zur Falldarstellung genutzt. Jedem Attribut A ist dabei ein Wertebereich bzw. Typ $T(A)$ zugeordnet. Ein Fall F ist somit ein n -stelliger Vektor [Ric03]:

$$F = (a_1, \dots, a_n) \in T_1 \times \dots \times T_n \quad (8)$$

In dieser Arbeit wird weiterhin zur Unterscheidung von Anfragefall und Fall aus der Fallbasis folgende Notation genutzt:

$$F_{query} = (q_1, \dots, q_n) \in T_1 \times \dots \times T_n \quad (9)$$

beschreibt die Attributwerte der Anfrage,

$$F_{case} = (c_1, \dots, c_n) \in T_1 \times \dots \times T_n \quad (10)$$

beschreibt die Attributwerte eines Falles aus der Fallbasis.

Eine weitere Art der Darstellung, welche insbesondere in komplexen Domänen vorteilhaft ist, ist die objektorientierte Darstellung, die als Erweiterung der Attribut-Wert-Darstellung gesehen werden kann. Diese orientiert sich an den Prinzipien der objektorientierten Softwareentwicklung und unterstützt „is-a“ und „part-of“-Beziehungen, sowie das Prinzip der Vererbung. Ein Fall besteht hier aus einer Menge von Objekten, welche unter anderem mittels Attributen beschrieben werden können [Ber02].

Eine Anfrage F_{query} (englisch: query) an das FBS-System wird als spezieller Fall angesehen, der nur die Situationsbeschreibung und keinen Lösungsteil enthält [Len99]. Ein Vorteil dieses Ansatzes besteht darin, dass nach Erstellung des Wissensmodells der Aufwand für Betrieb und Wartung des Systems gering sind. Häufig können Fälle aus bestehenden Datenbanken übernommen werden, indem deren Felder direkt den Attributen oder Objekten des Wissensmodells zugeordnet werden. Der Nachteil besteht in dem Anfangsaufwand zur Modellierung der Domäne [Ber02]. Die Menge aller gespeicherten Fälle ergibt die Fallbasis CB (englisch: case base).

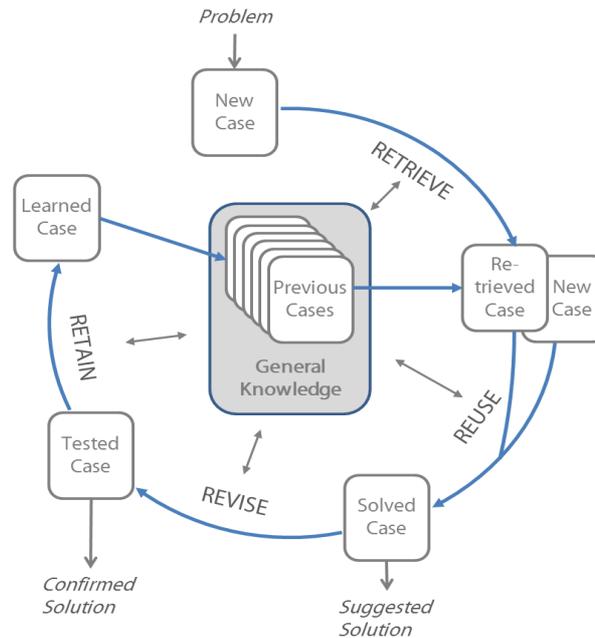


Abbildung 9: Das Ablaufmodell des Fallbasierten Schließens (in Anlehnung an [AP94])

Das Ablaufmodell nach Aamodt & Plaza ist die am weitesten verbreitete Nutzungsform des Fallbasierten Schließens. Es umfasst die vier Phasen [AP94]: *Retrieve*, *Reuse*, *Revise* und *Retain* (vgl. Abbildung 9). In der *Retrieve*-Phase wird aus der Fallbasis nach einem zur Problemstellung ähnlichen Fall bzw. nach einer Menge von ähnlichen Fällen gesucht. Eine zentrale Bedeutung hat dabei der Begriff der Ähnlichkeit. Die Ähnlichkeit hat die Aufgabe, die Nützlichkeit eines Falles für den aktuellen Kontext zu approximieren. Dabei wird die Ähnlichkeit auf die Problembeschreibung bezogen. Die Nützlichkeit ergibt sich erst bei Anwendung des Lösungsteiles eines Falles [BRS+01].

Einführung 5: Distanzmaß

Ein Distanzmaß berechnet die statistische Entfernung zwischen Merkmalsausprägungen einzelner Attribute.

Sei $A = \{a_1, \dots, a_n\}$ eine Menge von n Attributen.

Die Funktion $\text{dist}: A \times A \rightarrow \mathbb{R}$ heißt **metrisches Distanzmaß**, wenn

$$\text{dist}(a_i, a_i) = 0 \quad (\text{Normierung})$$

$$\text{dist}(a_i, a_j) \geq 0 \quad (\text{Nichtnegativität})$$

$$\text{dist}(a_i, a_j) = \text{dist}(a_j, a_i) \quad (\text{Symmetrie})$$

(11)

und bei 3 oder mehr Attributen:

$$\text{dist}(a_i, a_j) \leq \text{dist}(a_i, a_k) + \text{dist}(a_k, a_j) \quad (\text{Dreiecksungleichung})$$

für alle $i, j, k = 1, \dots, n$ gilt.

Ein häufig verwendetes Distanzmaß ist die euklidische Distanz.

Zur Berechnung von Ähnlichkeiten können dabei beliebige Ähnlichkeitsmaße verwendet werden, die ein numerisches Ergebnis liefern. Häufig werden dabei Distanzmaße als Grundlage

verwendet. Die Distanz zwischen zwei Merkmalsausprägungen ist abhängig von der Skala der Merkmalsausprägungen. Zwei gleiche Merkmalsausprägungen haben eine Distanz von 0.

Ein Ähnlichkeitsmaß ist dabei definiert als eine mathematische Funktion, deren Wert zunimmt, wenn die Ähnlichkeit der untersuchten Entitäten zunimmt. Bei Verwendung eines Distanzmaßes als Grundlage des Ähnlichkeitsmaßes gilt daher: je geringer die Distanz, desto höher die Ähnlichkeit. Die Ähnlichkeit ist dabei meist auf einen Wertebereich zwischen 0 und 1 normiert. Zusätzliche Eigenschaften, wie die Monotonie bei geordneten Objekten können gefordert werden. Beispiele für Ähnlichkeitsmaße sind der Simple Matching Coefficient oder das Ähnlichkeitsmaß nach Tversky. Eine ausführliche Diskussion verschiedener, im Kontext von Fallbasiertem Schließen anwendbarer Ähnlichkeitsmaße kann in [Ber02] und [Cun09] gefunden werden.

Einführung 6: Ähnlichkeitsmaß

Die Ähnlichkeit im Kontext von Fallbasierten Schließens hat die Funktion, die Nützlichkeit eines Falles für die Lösung des Problems der Anfrage zu approximieren [Ber02].

Sei $A = \{a_1, \dots, a_n\}$ eine Menge von n Attributen.

Die Funktion $\text{sim}: A \times A \rightarrow [0,1]$ heißt **Ähnlichkeitsmaß** bzw.

Ähnlichkeitsfunktion, wenn

$$\begin{aligned} \text{sim}(a_i, a_i) &= 1 && \text{(Normierung)} \\ \text{sim}(a_i, a_j) &\geq 0 && \text{(Nichtnegativität)} \\ \text{sim}(a_i, a_j) &= \text{sim}(a_j, a_i) && \text{(Symmetrie)} \\ \text{sim}(a_i, a_j) &\leq \text{sim}(a_i, a_k) + \text{sim}(a_k, a_j) && \text{(Dreiecksungleichung)} \end{aligned} \quad (12)$$

für alle $i, j, k = 1, \dots, n$ gilt.

Die Ähnlichkeit kann durch die Berechnung von lokalen Ähnlichkeiten zwischen einzelnen Informationseinheiten oder Attributen und anschließender Aggregation der Einzelähnlichkeiten zu einer globalen Ähnlichkeit auf Ebene der Fälle bestimmt werden. Eine verbreitete Vorgehensweise ist dabei die die Gewichtung der einzelnen Attribute. Die Gewichtung repräsentiert dann das Domänenwissen über die Relevanz der einzelnen Attribute in der Gesamtbeurteilung. Die gewichtete Summe über alle Attribute eines Falles kann entsprechend dann als globales Ähnlichkeitsmaß genutzt werden. Dieses Vorgehen wird auch lokal-global Prinzip genannt.

Einführung 7: lokale und globale Ähnlichkeitsmaße (nach [Ber02])

Ein *lokales Ähnlichkeitsmaß* ist ein Ähnlichkeitsmaß für ein einzelnes Attribut A_i , definiert durch:

$$sim_{A_i}: T_{i_{range}} \times T_{i_{range}} \rightarrow [0,1] \quad (13)$$

Dabei stellt $T_{i_{range}}$ den Wertebereich des Typs von A_i dar.

Ein *globales Ähnlichkeitsmaß* Sim_Φ wird zusammengesetzt aus lokalen Ähnlichkeitsmaßen:

$$Sim_\Phi(F_{query}, F_{case}) = \Phi(sim_{A_1}(x_1, y_1), \dots, sim_{A_n}(x_n, y_n)) \quad (14)$$

Die Funktion $\Phi: [0,1]^n \rightarrow [0,1]$ wird *Aggregationsfunktion* genannt und muss folgende Eigenschaften erfüllen:

- $\Phi(0, \dots, 0) = 0$
- Φ ist monoton steigend

In Bezug auf eine Anfrage q kann für alle Fälle c der Fallbasis CB ein Ähnlichkeitswert berechnet werden und die Fälle nach Ähnlichkeit absteigend sortiert werden (sequentielles Retrieval). Eine vorgegebene Menge k der Fälle mit den höchsten Ähnlichkeitswerten wird als Ergebnis des Retrievals bereitgestellt und in den weiteren Schritten des Ablaufmodells verarbeitet. Für große Fallbasen stehen verschiedene optimierte Retrieval-Techniken zur Verfügung, die es vermeiden, die Ähnlichkeit für alle Fälle der Fallbasis berechnen zu müssen. Beispiele hierfür sind u. a. kd-Bäume [WAD94], Fish and Shrink [Sch96] oder Case Retrieval Netze [Len99].

Einführung 8: Retrieval-Ergebnis

Basierend auf einer Fallbasis $CB = (c_1, c_2, \dots, c_m)$, einer Anfrage q und einer definierten globalen Ähnlichkeitsfunktion Sim_Φ ist ein Retrieval-Ergebnis eine Teilmenge

$$C_k(q, CB) = c_1, \dots, c_k \quad (15)$$

der Größe k mit $Sim_\Phi(q, c_i) \geq Sim_\Phi(q, c_j)$ für $\forall i, j$ mit $1 \leq i < j \leq k$.

Im *Reuse*-Schritt des FBS-Prozessmodells wird die Lösung des im *Retrieve*-Schritt gefundenen Falls an das Ausgangsproblem angepasst. In vielen fallbasierten Systemen wird diese Lösungstransformation dem Benutzer überlassen, was auch als „copy“ oder „null adaptation“ bezeichnet wird. Bei der Adaption geht es hingegen um die automatische Lösungstransformation. Je nach Komplexität der Aufgabe können verschiedene Techniken dafür zum Einsatz kommen. Verbreitet wird hierfür der Ansatz der Transformational Adaption genutzt. Dabei werden einzelne (atomare) Teile der Lösung des gefundenen Falles so umgewandelt, dass diese auf das Ausgangsproblem passen. Dazu können Lösungselemente neu angeordnet und einzelne Elemente ersetzt, hinzugefügt, verändert oder gelöscht werden. Dies geschieht häufig regelbasiert, wozu domänenspezifisches Wissen benötigt wird. Man spricht auch von Adaptionregeln. Diese bestehen, wie bei wissensbasierten System üblich, aus einer (Vor-)Bedin-

gung und einer Folgerung. Mit Hilfe der Adaptionregeln wird aus dem Fall, der mit der Anfrage definiert wurde und dem Fall, der während der Retrieval-Phase als der ähnlichste bestimmt wurde, ein neuer Fall, der die Lösung beschreibt (Zielfall oder target case).

Ein weiterer Ansatz ist die Generative Adaption, bei der versucht wird die Lösungsmethodik (statt die Lösung selber) des ähnlichsten Falls zu übernehmen und gegebenenfalls anzupassen. Dazu müssen die Fälle zusätzliche Informationen über die zur Problemlösung benutzte Methodik enthalten. Ein allgemeiner Problemlöser wird benötigt, der die Methodik anwenden kann. Da dies rechnerisch aufwändig ist, wird dieser Ansatz nur selten verfolgt.

Einführung 9: Adaptionregel

Eine Anpassungsregel ist eine Regel, die beschreibt, wie die Lösung (*sol*) eines gefundenen ähnlichen Falles (F_{case}) angepasst werden muss, um der Situation der Anfrage (F_{query}) noch besser zu entsprechen und somit die Nützlichkeit der Lösung für die Anfrage zu erhöhen.

$$adaptation = ((F_{case}, sol(F_{case})), F_{query}) \rightarrow sol(query) \quad (16)$$

Der durch den *Reuse*-Schritt generierte Lösungsvorschlag wird nun im *Revise*-Schritt überprüft. Hier wird zum Beispiel durch eine Simulation in einem Modell oder eine Überprüfung in der Realität (d. h. außerhalb des Systems) die Korrektheit der durch den *Reuse*-Schritt angebotenen Lösung validiert. Auch eine Überprüfung der Qualität der Lösung wird durchgeführt. Stimmt die Überprüfung nicht mit den Erwartungen überein, so kann die Lösung erneut angepasst werden. Abschließend wird die Problemsituation, das heißt der neue Fall, ergänzt um eine überprüfte Lösungsbeschreibung in die Fallbasis aufgenommen (*Retain*). Dies bedarf üblicherweise einer Überprüfung der Relevanz der neuen Lösung. Konnte die Nützlichkeit der Lösung nicht bestätigt werden, so wird der Fall nicht aufgenommen. Mit der Aufnahme eines neuen Falles steht der Fall für zukünftige Anfragen zur Verfügung. Das System hat eine Erfahrung „gelernt“.

Für Fallbasiertes Schließen und FBS-Systeme wird an verschiedenen Stellen Wissen benötigt und verwendet. Um dieses strukturiert darzustellen wurde das Konzept der Wissenscontainer entwickelt [Ric98]. Die Idee dahinter unterscheidet sich von dem Modulkonzept der Softwareentwicklung. Im Gegensatz zu den Modulen, die jeweils eigenständig bestimmte Teilaufgaben lösen, sind an der Lösung einer Aufgabe beim Fallbasierten Schließen immer mehrere Wissenscontainer beteiligt. Sie enthalten das zur Problemlösung benötigte Wissen. Für FBS-Systeme werden folgende Wissenscontainer identifiziert (vgl. Abbildung 10):

- *Repräsentationssprache und Vokabular*
- *Ähnlichkeitsmaße*
- *Fallbasis*
- *Lösungstransformation/Adaption*

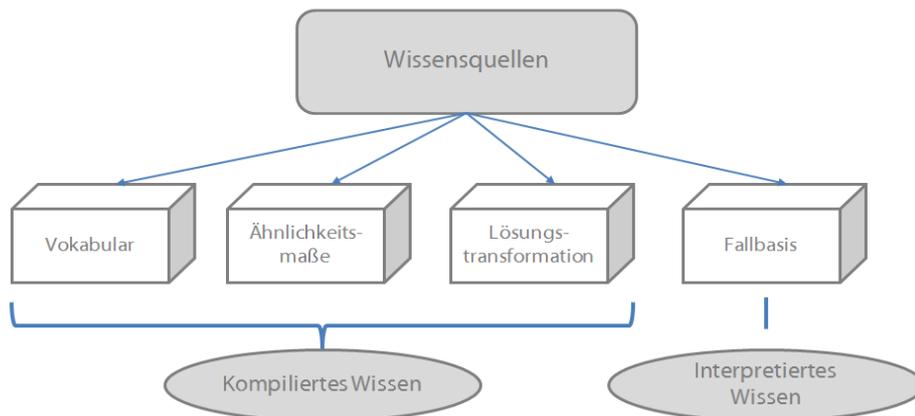


Abbildung 10: Verteiltes Wissen in einem fallbasierten System (in Anlehnung an [Ric95])

Das Vokabular wird zur Repräsentation von Entitäten des Anwendungsbereichs der FBS-Anwendung benötigt. Mit diesem werden die Fälle, das sogenannte Fallformat, beschrieben. Im Bereich der wissensbasierten Systeme wird dies auch als Domänenmodell bezeichnet. Es dient als Basis für die anderen Container. Die Fallbasis dient zur Speicherung der einzelnen Fälle. Eine Fallbasis enthält immer eine endliche Menge an Fällen, die in dem zuvor definierten Fallformat strukturiert sind. Um beim Retrieval ähnliche Fälle zum aktuellen Problem zu finden werden Ähnlichkeitsmaße benötigt. Die Ähnlichkeit soll, wie bereits beschrieben, die Nützlichkeit des gefundenen Falls für die Lösung des aktuellen Problems möglichst gut approximieren. Wissen zur Lösungstransformation, auch Adaptionwissen genannt, wird benutzt, um die Lösung eines zur Anfrage ähnlichen Falls an die Anfrage anzupassen und eine Lösung abzuleiten. Bei der Transformational Adaption erfolgt diese Anpassung zum Beispiel regelbasiert. Die Regeln bestehen aus einer Vorbedingung und einem Aktionsteil und können in drei verschiedene Arten unterteilt werden:

- *Filterregeln*: Werden während der Anfrage vom Benutzer eingegeben und beschreiben Ausschlusskriterien für die gesuchten Fälle.
- *Vervollständigungsregeln*: Werden während der Systementwicklung angelegt. Sie enthalten entweder Wissen, das die Berechnung des Ähnlichkeitsmaßes beeinflusst oder enthalten Wissen, wie durch Inferenz zusätzliche Informationen aus den bekannten Fakten des aktuellen Falls oder der aktuellen Anfrage extrahiert werden können.
- *Anpassungsregeln*: Werden auch während der Systementwicklung angelegt. Sie beschreiben wie ein Fall angepasst werden kann, um möglichst korrekt zur aktuellen Anfrage zu passen.

Da aber nur die Vervollständigungs- und Adaptionregeln im System kompiliert werden, stellen diese den eigentlichen Wissenscontainer für Adaptionwissen dar.

Im Prinzip kann jeder Container (fast) das komplette Wissen enthalten. Ist jeder mögliche Fall in der Fallbasis, so ist das Wissen hier vollständig vorhanden. Für gewöhnlich wird aber das Wissen über die verschiedenen Container verteilt. Unterschieden wird zwischen kompiliertem Wissen und interpretiertem Wissen. Das kompilierte Wissen (Vokabular, Ähnlichkeitsmaß und

Lösungstransformation) wird während des Entwicklungsprozesses in das System integriert, während relevante Fälle aus der Fallbasis zur Laufzeit extrahiert werden [Ric03].

Der Ansatz des Fallbasierten Schließens hat sich als besonders erfolgreich erwiesen in Domänen, bei denen die Problemkomplexität hoch ist, aber nur wenig über die Problemzusammenhänge, die für die Lösung nötig wären, bekannt ist [OHH+08].

2.5 Lastgangprognose als Prozess

Aufgrund der hohen Relevanz von Lastgangprognoseverfahren für sowohl die technische Regelung von Elektrizitätsnetzen als auch für die ökonomische Abwicklung von Stromhandel und -lieferung wurden im Laufe der Zeit unterschiedliche Methoden zur Lastgangprognose entwickelt (vgl. Kapitel 3.1). Neben statistischen Verfahren sind dabei inzwischen auch Methoden des maschinellen Lernens und der künstlichen Intelligenz populär. Eine Auswahl wurde im vorherigen Kapitel vorgestellt. Trotz der unterschiedlichen Herangehensweisen der verschiedenen Methoden an den Prognoseprozess, lassen sich die durchzuführenden Schritte zur Anwendung der Methoden in zwei wesentlichen Schritten zusammenfassen: die Modellbildung und die eigentlichen Berechnung der Prognosewerte.

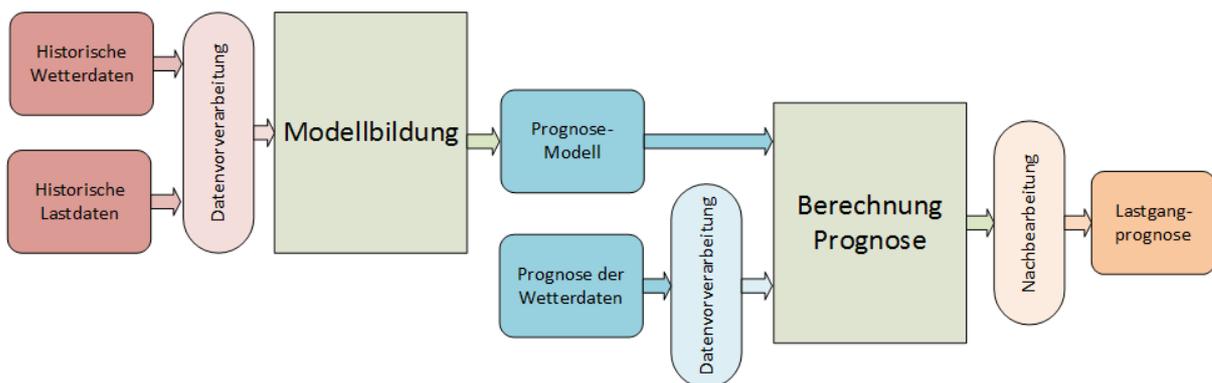


Abbildung 11: Verallgemeinerter Prozessablauf von Prognosesystemen

Die Modellbildung ist ein vorbereitender Schritt, der in der Regel nicht bei jeder Durchführung einer Prognoseberechnung durchgeführt werden muss. Üblicherweise erfolgt eine initiale Modellbildung bei Implementierung eines Prognosesystems und hat längerfristig Bestand. In manchen Fällen erfolgt eine Anpassung des Modells in regelmäßigen Abständen oder bei Änderung von wesentlichen Einflussfaktoren auf die Charakteristik eines Lastgangs. Für die Modellbildung werden, sofern vorhanden, historische Daten genutzt. In klassischen Systemen sind dies Lastgangdaten aus der Vergangenheit und die korrespondierenden Wetterdaten. Diese werden genutzt, um Parameter der jeweilig gewählten Prognosemethode anzupassen. Dabei kann ein Prognosemodell auch mehrere Einzelmodelle umfassen, indem jeweils ein Modell für jeden Tag der Woche erstellt wird oder zwischen „normalen“ Arbeitstagen und „besonderen“ Ausnahmetagen (z. B. Feiertagen) unterschieden wird. Während die Modellbildung häufig manuelle Eingriffe und Kontrollen erfordert und von Experten im Bereich Prognose durchgeführt wird, ist die Berechnung der eigentlichen Prognose meist automatisiert und erfordert nur wenig Überwachung.

Im Fall von Künstlichen Neuronalen Netzen erfolgt die Modellbildung durch die Auswahl der Netztopologie und das Training des Netzes mit der Vorgabe der entsprechenden Eingabedaten und der erwarteten Ausgabedaten. Im Fall von Methoden der Zeitreihenanalyse geht es um eine möglichst genaue Schätzung der Parameter des genutzten Modells. Einen Sonderfall stellt hier die Simulation dar, bei der je nach Ausprägung häufig auch noch deutlich mehr Einflussfaktoren Berücksichtigung finden. In allen Fällen ist die Modellbildung der deutlich aufwändigere Schritt.

Das erstellte Prognosemodell kann anschließend für die Berechnung der eigentlichen Prognosedaten genutzt werden. Hierfür werden nur begrenzt historische Daten herangezogen. Größerer Einfluss hat hier zum Beispiel die Prognose des Wetters für den zu prognostizierenden Tag, da das Wetter, insbesondere die Temperatur, in den allermeisten Fällen einen nachweisbaren Einfluss auf die Verbrauchscharakteristik hat. Dies gilt ebenso für die Prognose der Stromerzeugung aus erneuerbaren Energiequellen. Abbildung 11 zeigt die einzelnen Prozessschritte und deren Eingaben noch einmal vereinfacht in einem Diagramm (in Anlehnung an [Hon10]). Sowohl bei der Modellbildung als auch bei der eigentlichen Berechnung der Prognose kommt den genutzten Daten eine wesentliche Bedeutung zu. In der wissenschaftlichen Literatur werden zu der Herkunft und Auswahl der Daten bei der Beschreibung von Verfahren zur Modellbildung nur selten detaillierte Angaben gemacht. In den meisten Fällen wird davon ausgegangen, dass ein mehr oder weniger homogener Datensatz in einer Datenbank oder einer weiteren einfach zugreifbaren Quelle vorhanden ist. Für die Modellbildung ist dabei ein ausreichend großer Datensatz erforderlich, der häufig aufgeteilt wird in Trainingsdaten und Testdaten. Die historischen Trainingsdaten werden zur Modellbildung genutzt und die historischen Testdaten dienen dabei zur Überprüfung des aktuellen Modells. Wichtig ist es hier, das Modell nicht zu nah an die vorhandenen Daten zu modellieren, um eine Überanpassung (englisch: overfitting) zu vermeiden. Definierte Stopp-Kriterien und Kreuzvalidierung sind Methoden um dies zu vermeiden. Nur selten wird in der wissenschaftlichen Literatur beschrieben, inwieweit fehlende oder inkonsistente Daten die Modellbildung beeinflusst haben. Vorverarbeitungsschritte, die durchaus häufig als Teil der Prognose genannt werden, sind dagegen die Normalisierung der Daten, um den Wertebereich der Daten in ein einheitliches Skalenniveau zu bringen und die Dekomposition der Daten, um verschiedene berechenbare Teilfunktionen aus einer Zeitreihe zu extrahieren. Erfolgen solche Vorverarbeitungsschritte vor der Berechnung der Prognose, so muss anschließend auch eine Rücktransformation der Daten in ihr ursprüngliches Format inklusive aller Teilfunktionen erfolgen um eine anwendbare Lastgangprognose zu erhalten.

Sowohl als Teil der Modellbildung, als auch im Nachgang der Berechnung der Prognose kann eine Überprüfung der Prognosegüte erfolgen, wofür verschiedene Gütemaße angewendet werden können. Bei Überschreitung von definierten Genauigkeitswerten kann eine Anpassung der Modellbildung erfolgen, sodass sich ein iterativer Prozess ergibt.

2.6 Bewertung von Lastgangprognoseverfahren

Wesentliches Merkmal zur Bewertung von Lastgangprognoseverfahren ist der quantitative Vergleich der prognostizierten Daten mit den tatsächlich gemessenen Daten, sobald diese vor-

liegen. Daneben gibt es aber noch weitere Kriterien für die Bewertung. [Sch12] nennt vier zu bewertende Anforderungen an Verfahren für kurzfristige Prognosen:

- Genauigkeit der Prognose
- Reagibilität und Stabilität des Verfahrens
- Eingriffsmöglichkeiten in des Verfahrens
- Rechenzeit und Speicherplatzbedarf

Diese Anforderungen sollen im Folgenden kurz erläutert werden und Bewertungskriterien genannt werden, sofern möglich. Ergänzt werden sollen die genannten noch um die Anforderung der Übertragbarkeit des Verfahrens.

2.6.1 Genauigkeit der Prognose

Die Genauigkeit einer Prognose, auch Prognosegüte genannt, beschreibt die Übereinstimmung zwischen prognostizierten und realisierten Werten einer Variablen und kann immer nur in einer ex-post-Betrachtung bewertet werden. Trotzdem stellt die Genauigkeit eines der wesentlichen und meistgenutzten Kriterien für die Bewertung eines Prognoseverfahrens dar [Kue12]. Es ist im Allgemeinen zu beachten, dass eine Erhöhung der Genauigkeit eines Verfahrens immer mit zusätzlichem Aufwand verbunden ist. Es gilt also, diesen Aufwand möglichen Ersparnissen oder Verbesserungen durch das Vorliegen einer genaueren Prognose gegenüber zu stellen. Für die Bewertung der Genauigkeit wurden verschiedene Gütemaße entwickelt, welche nicht nur den Vergleich der Verfahren in einem Anwendungsfall, sondern zum Teil auch über verschiedene Anwendungsfälle hinweg ermöglicht. Je kleiner die entsprechenden Maßzahlen ausfallen, desto näher liegen die prognostizierten Werte an den beobachteten Werten ([Vog15, Kue12, FK15]).

$$ME = \frac{1}{h} \sum_{t=n+1}^h \hat{y}_t - y_t \quad (17)$$

Der mittlere Fehler (englisch: Mean Error, *ME*) in (17) stellt dabei das einfachste und intuitivste Gütemaß dar. Es berechnet die mittlere Abweichung zwischen den prognostizierten Werten \hat{y}_t und den beobachteten Werten y_t . Zu beachten ist, dass sich bei diesem einfachen Gütemaß positive und negative Abweichungen gegenseitig aufheben können. Dies kann eine Prognosegenauigkeit vortäuschen, die bei Betrachtung von Einzelwerten nicht gegeben ist. Das Vorzeichen des Ergebnisses dieses Gütemaßes weist darauf hin, ob die prognostizierten Werte die beobachteten Werte im Mittel über- oder unterschätzen.

$$MAE = \frac{1}{h} \sum_{t=n+1}^h |\hat{y}_t - y_t| \quad (18)$$

Die gesamte Abweichung der Prognosewerte von den beobachteten Werte ermittelt der mittlere absolute Fehler (englisch: Mean Absolute Error, *MAE*) durch die Nutzung der Absolutwerte der Abweichungen. Dadurch ist ein Vergleich zwischen verschiedenen Verfahren für denselben Anwendungsfall bereits möglich. Allerdings sind die Ergebnisse dieses Gütemaßes (ebenso wie die Ergebnisse des mittleren Fehlers) abhängig von der Größenordnung der gemessenen Werte und eignen sich damit nicht für den Vergleich von Prognoseverfahren von zwei Anwendungsfällen. Dafür eignen sich relative Fehlermaße.

$$MPE = \frac{100}{h} \sum_{t=n+1}^h \frac{\hat{y}_t - y_t}{y_t} \quad (19)$$

Der mittlere prozentuale Fehler (englisch: Mean Percentage Error, *MPE*) ist ein solches relatives Fehlermaß, welches die Abweichungen der Prognose prozentual darstellt. Dieses Gütemaß summiert wieder positive wie negative Abweichungen auf und kann damit anzeigen, ob ein Prognoseverfahren die tatsächlichen Werte im Mittel über- oder unterschätzt. Durch die Nutzung des relativen Maßes ist es dafür geeignet auch Prognosen in verschiedenen Anwendungsfällen zu vergleichen. Allerdings ist zu beachten, dass es nicht für Nullwerte geeignet ist, da eine entsprechende Division nicht durchgeführt werden kann.

$$MAPE = \frac{100}{h} \sum_{t=n+1}^h \left| \frac{\hat{y}_t - y_t}{y_t} \right| \quad (20)$$

Der mittlere absolute prozentuale Fehler (englisch: Mean Absolute Percentage Error, *MAPE*) nutzt wieder absolute Werte für die Abweichungen und ermittelt damit einen prozentualen Gesamtfehler. MAPE ist eines der am häufigsten genutzten Gütemaße zur Bewertung von Prognoseverfahren. Allerdings gilt auch hier, dass eine Division durch Null nicht möglich ist und Prognosen nahe dem Nullwert schnell zu sehr hohen Werten führen.

$$MSE = \frac{1}{h} \sum_{t=n+1}^h (\hat{y}_t - y_t)^2 \quad (21)$$

Quadratische Fehlermaße wie der mittlere quadrierte Fehler (englisch: Mean Squared Error, *MSE*) gewichten große Abweichungen höher und können damit darstellen, ob es sich bei den Fehlern um viele kleine Fehler handelt oder ob Ausreißer in den Prognosedaten (oder den beobachteten Daten) vorhanden sind. Dazu werden die einzelnen Abweichungen quadriert bevor sie aufsummiert werden.

$$RMSE = \sqrt{\frac{1}{h} \sum_{t=n+1}^h (\hat{y}_t - y_t)^2} \quad (22)$$

Berechnet man die Wurzel des MSE (englisch: Root Mean Square Error, *RMSE*), so hat dies den Vorteil, dass der Wert wieder die gleiche Maßeinheit repräsentiert wie die Ausgangswerte der Prognose unter Beibehaltung der Betonung von großen Abweichungen.

$$RMSPE = 100 * \sqrt{\frac{1}{h} \sum_{t=n+1}^h \frac{(\hat{y}_t - y_t)^2}{y_t^2}} \quad (23)$$

Unter demselben Aspekt, aber mit einem prozentualen Wert, arbeitet die Wurzel aus dem mittleren quadratischen Fehler (englisch: Root Mean Square Percentage Error, *RMSPE*). Durch die relative Betrachtung ergibt sich hier auch wieder die Möglichkeit des Vergleichs von Ergebnissen aus verschiedenen Anwendungsfällen.

2.6.2 Stabilität, Reagibilität und Eingriffsmöglichkeiten

Die Stabilität eines Prognoseverfahrens beschreibt, wie es auf Änderungen in den beobachtbaren Daten reagiert. Abweichungen zwischen den prognostizierten und den tatsächlichen Daten werden kontinuierlich auftreten und es muss erkannt werden, ob es sich um eine zufällige Än-

derung handelt oder um eine tatsächliche Veränderung im Verhalten der Zeitreihe. Eine hohe Stabilität des Verfahrens kann zum Beispiel erreicht werden, indem eine Vielzahl von historischen Daten für die Prognose genutzt wird und so das Ergebnis geglättet wird und nicht jede zufällige Schwankung als langfristige Änderung interpretiert wird. Sollten die Prognoseergebnisse mit der Zeit immer stärker von den tatsächlichen Werten abweichen, so sollte das Prognoseverfahren überprüft und gegebenenfalls angepasst werden. Eine schnelle automatisierte Anpassung wird als Reagibilität beschrieben. Diese geht aber häufig auf Kosten der Stabilität. Es gilt also einen Kompromiss zu finden, der die Stabilität des Verfahrens bei Zufallsabweichungen gewährleistet, aber auch entscheidende Änderungen in den Zeitreihendaten erkennt und behandelt [Sch12]. Ist aus der Vergangenheit bekannt, dass sich das Verhalten nur selten ändert, ist lediglich eine periodische Überprüfung des Prognosemodells nötig. Ist die Stabilität aber unsicher, so wird ein Verfahren benötigt, welches möglichst einfach an neue Umstände angepasst werden kann und entsprechende Eingriffsmöglichkeiten auch für den Nutzer bereitstellt. Es kann durch Überprüfen von vorliegenden Prognosezeitreihen und den entsprechenden beobachteten Werten erkannt werden, ob Regelmäßigkeiten oder spezifische Abweichungen vorliegen. Der Nutzer ist einfacher in der Lage, Besonderheiten in der Entwicklung der Zeitreihen zu erkennen, insbesondere wenn diese optisch visualisiert werden.

Ein objektives Maß für die Stabilität und Reagibilität eines Prognoseverfahrens existiert allerdings nicht. Eine Beurteilung muss durch eine Untersuchung von Beispielprognosen erfolgen, die gegebenenfalls konstruiert werden müssen, um bestimmte Situationen zu erzeugen und bewerten zu können.

2.6.3 Rechenzeit und Speicherplatzbedarf

Rechenzeit und Speicherplatzbedarf sind quantifizierbare Aufwände, die für eine Prognose anfallen, die allerdings aufgrund der fortschreitenden Entwicklung der Informationstechnologie an Bedeutung verloren haben, soweit es die Lastgangprognose betrifft. Die Kosten für hohe Prognoseabweichungen überwiegen. Der Aufwand für die Berechnung einer Prognose wird durch die Anzahl der Prognosen, den Prognosehorizont und das gewählte Prognoseverfahren bestimmt. So ist es für ein Energieversorgungsunternehmen ein deutlicher Unterschied, ob eine Lastgangprognose auf Netzebene oder für Teilnetze erfolgen soll oder ob eine Prognose auf Einzelkundenebene benötigt wird. Davon hängt wiederum ab, wie viele verschiedene Prognosemodelle benötigt werden. Steigt die Anzahl der erforderlichen Prognosen, so steigt auch automatisch der Speicherplatzbedarf. In einem solchen Fall ist zu prüfen, ob eine Prognose auf Basis von aggregierten Daten möglich ist. Dies erfolgt in der Energiewirtschaft bereits mit den sogenannten Standardlastprofilen, die Endkunden mit einem Stromverbrauch von weniger als 100.000 kWh zugeordnet werden. Dabei wird lediglich nach bestimmten Kundengruppen unterschieden und die Werte des Standardlastprofils, multipliziert mit einem Faktor der den Jahresverbrauch repräsentiert, aufsummiert. Über die Aggregation einer Vielzahl von Kunden wird dadurch eine ausreichende Genauigkeit bei noch vertretbarem Rechenaufwand und einem überschaubaren Speicherplatzbedarf erreicht.

3 Verwandte Arbeiten

Im Gegensatz zu der Lastprognose in elektrischen Verteil- oder Transportnetzen ist die Untersuchung des täglichen Strombedarfs und entsprechender Prognosen in hochdynamischen Prozessumfeldern, insbesondere im Bereich der Logistik, noch ein relativ junges Forschungsgebiet. Entsprechend sollen dazu im Folgenden verwandte Bereiche der Forschung vorgestellt werden. Zuerst stehen dabei die Lastprognoseverfahren an sich im Mittelpunkt. Da es eine sehr hohe Anzahl von wissenschaftlichen Veröffentlichungen zum Thema der kurzfristigen Lastgangprognose gibt, kann hier nur ein Überblick gegeben und einzelne Beispiele vorgestellt werden. Anschließend wird für den weiteren Bereich dieser Arbeit zunächst mit einem Blick auf Themen aus dem Bereich der logistischen und energetischen Prozesse in Containerterminals begonnen, bevor Ansätze vorgestellt werden, bei denen bereits Techniken des Fallbasierten Schließens in verwandten Bereichen der Lastgangprognose eingesetzt werden. Da dies bisher aber nur sehr selten der Fall war, wird hier auch noch der verwandte Bereich der Zeitreihenprognose mit betrachtet, für welchen Fallbasiertes Schließen schon deutlich häufiger eingesetzt wurde.

3.1 Lastgangprognoseverfahren

Die kurzfristige Lastgangprognose ist aufgrund ihrer immensen Bedeutung für Energieversorger im Bereich Stromlieferung und Netzbetrieb ein vieldiskutiertes Thema in der gängigen wissenschaftlichen Literatur. Ausführliche Literatur- und Methodenreviews können zum Beispiel in [Hon10], [SIM+13], [SS12] und [AN02] gefunden werden. Den beschriebenen Methoden ist gemein, dass sich die Prognoseverfahren weitestgehend auf Teilnetze oder aggregierte Kundengruppen konzentrieren und nicht unbedingt einzelne Verbraucher im Blick haben. Werden einzelne große Verbraucher betrachtet, so werden häufig Algorithmen zur Mustererkennung angewandt. Eine Arbeit, die sich mit der Energieverbrauchsprognose von Containerterminals beschäftigt, findet sich in der wissenschaftlichen Literatur nur im Rahmen der Nutzung eines Simulationsmodells welches in [GHI+14], [RIA+14] und [Gru16] beschrieben wird und im Rahmen dieser Arbeit mit untersucht wird. Dieses Simulationsmodell wird insbesondere in Kapitel 5.6 näher beschrieben.

3.1.1 Zeitreihenanalyse für die Lastgangprognose

Methoden der Zeitreihenanalyse basieren auf der Annahme, dass die einer Zeitreihe zugrunde liegenden Daten eine interne Struktur haben. Dies können zum Beispiel saisonale Komponenten, Trends oder auch Korrelationen mit sich selbst zu einem früheren Zeitpunkt sein. Bei der Prognose mit Hilfe von Methoden der Zeitreihenanalyse geht es daher darum, die entsprechenden Strukturen zu entdecken und zu untersuchen. Methoden der Zeitreihenanalyse werden schon seit langer Zeit im Bereich der Wirtschaftswissenschaften, der Signalverarbeitung und auch im Bereich der Lastgangprognose genutzt. ARMA und ARIMA-Modelle (vgl. Kapitel 2.3.2) nutzen Vergangenheitsdaten von Zeitpunkt und Last als einzige Eingabeparameter. Durch die Abhängigkeit von weiteren Einflussgrößen wie zum Beispiel des Wetters sind die häufigsten Modelle für die Lastgangprognose ARIMAX-Modelle [FG05].

[JYGM99] beschreiben ein ARIMA-Modell für die stündliche Lastprognose bei dem der Verbrauch in der vorangegangenen Stunde sowie der Verbrauch in derselben Stunde des Vortages als wichtigste Einflussfaktoren identifiziert wurden. Ebenfalls mit einbezogen wurden Werte der Vorwoche und Temperaturwerten. Die Autoren argumentieren, dass der Einfluss aber nicht linear über den Tag ist, sondern höher ist in Zeiten mit einer hohen Last auf dem Netz, da sich entsprechende Effekte aggregieren. Dennoch können die Werte gewichtet über den Tag verteilt werden und so in das Modell integriert werden. Die Ergebnisse für die Anwendung als Prognose werden anhand der Prognose der nächsten sechs Stunden des stündlichen Lastverlaufs in einem mittelspanischen Elektrizitätsnetz evaluiert. Die Autoren merken an, dass bei der Anwendung in der realen Umgebung der Fehlerwert der Prognose mit steigendem Prognosehorizont ebenfalls steigt.

[Amj01] präsentiert ein ARIMA-Modell zur Prognose des stündlichen Lastverlaufs, welches so abgewandelt wurde, dass eine Expertenschätzung für den zu prognostizierenden Lastverlauf in die Prognose integriert werden kann. Bei der Modellbestimmung werden die zugrunde liegenden Vergangenheitsdaten um den Schätzwert ergänzt, also um den Wert für $n+1$ erweitert. Der Autor argumentiert, dass durch die Expertenschätzung der Einfluss des Fehlerterms im aufgestellten Modell deutlich verringert werden kann. Eine Expertenschätzung muss dabei allerdings für jede Prognose erfolgen. In der Evaluation wird ein deutlich verringerter Fehlerwert sowohl gegenüber der Expertenschätzung an sich als auch gegenüber herkömmlichen ARIMA-Modellen erreicht. Mit einer geringfügigen Umstellung und Neubestimmung des Modells kann auf gleiche Weise auch die tägliche Lastspitze prognostiziert werden.

3.1.2 Künstliche Neuronale Netze für die Lastgangprognose

Die Nutzung von Künstlichen Neuronalen Netzen ist eine der am weitesten verbreiteten Methoden sowohl für die kurzfristige, als auch für die mittel- und langfristige Prognose. Die Fähigkeit der Netze, nicht-lineare Zusammenhänge aus Eingabe- und dazugehörigen Ausgabedaten zu erkennen und zu generalisieren und damit auch auf neue Eingaben anzuwenden, trägt zu ihrer Popularität entscheidend bei. Dabei kommen verschiedene Arten von Künstlichen Neuronalen Netzen zum Einsatz, bereits einfache Netzmodelle erreichen einen hohen Genauigkeitsgrad. In der wissenschaftlichen Literatur vorgestellte Systeme nutzen den klassischen Ansatz der Multilayer-Perceptrons (MLP), als Ausprägung eines Feedforward-Netzes, andere nutzen Radial Basis Functions-Netzwerke (RBF), Rekurrente Neuronale Netzwerke (RNN), Self-Organizing-Maps (SOM) oder Kombinationen von Netzen (z. B. [Bax92], [NUA12]). Im Rahmen des aktuellen Trends zum Deep Learning erhalten derzeit insbesondere die Rekurrenten Netze eine erhöhte Aufmerksamkeit.

Im Bereich der Energiewirtschaft präsentieren [PEM+91] ein frühes, einfach gehaltenes neuronales Feedforward-Netz mit einem Ausgabeneuron, welches für die Prognose der Lastspitze, der kumulierten Gesamtlast des Tages, sowie der stündlichen Last genutzt werden kann. Um eine Lastgangprognose zu erhalten muss hier jede Stunde einzeln prognostiziert werden. Die Eingabe umfasst dabei die Last der beiden Stunden zuvor, die Temperaturwerte der beiden Stunden zuvor sowie die vorhergesagte Temperatur für die zu prognostizierende Stunde. Angewandt wurde das KNN für die Prognose des Verteilnetzes in Seattle und Tacoma in den USA. Die durchschnittliche prozentuale Abweichung der Prognosen schwankte zwischen 1,5

und 3 Prozent in Abhängigkeit der Zeit, welche ausgehend von der aktuellen Stunde prognostiziert wurde.

[AEM97] präsentieren ein System aus zwei hintereinander geschalteten Künstlichen Neuronalen Netzen zur Vorhersage des halbstündigen Lastgangs des kuwaitischen Stromsystems. Das erste Netz dieses Systems übernimmt eine Prognose der Lastspitze, des Lastminimums und des Gesamtenergieverbrauchs. Die Eingabedaten dafür sind neben Wetterdaten (Durchschnittstemperatur und -luftfeuchtigkeit) und kalendarischen Daten (Monat, Wochentag) die Verbrauchswerte des vergangenen Tages inklusive der maximalen und minimalen Leistung. Die drei im ersten Netz prognostizierten Werte sind dann Eingabedaten für das zweite Netz, zusammen mit den halbstündlichen Lastgangdaten des Vortages und den stündlichen Wetterdaten. Ergebnis sind 48 Leistungswerte, die den Lastgang des prognostizierten Tages repräsentieren. Der durchschnittliche absolute Fehler in einer Fallstudie für ein Jahr wurde mit 3,18 % beziffert.

[HBA+13] präsentieren eine Architektur für ein System auf Basis eines einfachen MLP für die Prognose des Lastverhaltens in Microgrids. Als Eingabeparameter kommen die stündlichen Verbrauchswerte des Vortages, der Wochentag, der Monat und eine Prognose des Gesamtverbrauchs des Folgetages, welcher über ein weiteres einfaches vorgeschaltetes Neuronales Netzwerk ermittelt wurde. Werte liegen hier für die vergangenen drei Jahre vor. Eine Besonderheit des Ansatzes ist, dass die periodischen Werte für Wochentag und Monat als Cosinus und Sinus-Werte eingegeben werden. Nach Angaben der Autoren verbessert dies die Vorhersagequalität erheblich. Die Ergebnisse der Prognose kommen auf einen durchschnittlichen mittleren absoluten prozentualen Fehler von circa 2,5 %. Allerdings weist sowohl die prognostizierte, als auch die real gemessene Lastkurve trotz Anwendung in einem Microgrid-Szenario täglich kaum fluktuierende Lastverläufe auf.

3.2 Energetische Prozesse in Containerterminals

Der Untersuchung von einzelnen Prozessbereichen und Planungsproblemen in Containerterminals wird in der gängigen Literatur zu Terminallogistik eine hohe Bedeutung beigemessen. Häufig diskutierte Probleme betreffen zum Beispiel die Liegeplatzzuweisung oder die Kaikranzuordnung (für eine Übersicht sei hier auf [SV08] verwiesen). Um die entwickelten Lösungsstrategien für diese Logistikfragestellungen ganzheitlich testen zu können, werden häufig Simulationsmodelle genutzt. Simulationsmodelle bestehen dabei typischerweise aus den Subsystemen Schiffsliegeplatzbereich, Kaikranbereich, landseitiger Horizontaltransportbereich, Blocklagerbereich und dem sogenannten Hinterlandbereich für den landseitigen Weitertransport der Container per LKW oder Bahn. [MSW+01] entwickeln zum Beispiel ein Simulationsmodell für das Container Terminal Altenwerder in Hamburg. Dieses Modell legt den Schwerpunkt auf den Liegeplatz- und den Kaikranbereich. Das Modell wurde genutzt um Ergebnisse der Anwendung bioanaloger Verfahren bei der Optimierung von Kaikranschlägen und Horizontaltransporten zu untersuchen. In einer Machbarkeitsstudie wird gezeigt, dass es möglich ist auf diesem Wege Liegeplatzgebühren zu sparen. [MGCP03] entwickeln einen Algorithmus für die Vorhersage und die Vermeidung von Blockadesituationen in Containerumschlagssystemen. Sie legen den Schwerpunkt auf ein Systemdesign für automatisierte Trans-

portfahrzeuge (AGVs) mit einem komplexen Layout der Fahrspuren und einer hohen Anzahl von Fahrzeugen. Sie zeigen, dass es in ihrem Modell in vielen Situationen zu nicht-auflösbaren Blockierungen („deadlocks“) von Fahrspuren durch die Fahrzeuge kommen kann, die durch koordiniertes AGV-Routing vermieden werden können. Um ihren graph-basierten Algorithmus zur Erkennung von AGV-Deadlocks zu testen, erstellten sie ein Simulationsmodell mit dem Werkzeug AutoMed. [SLCT12] entwickeln ein komplettes Simulationswerkzeug speziell zur Abbildung typischer Prozesse eines Containerterminals und deren Zusammenspiel. Das event-basierte System nutzt eine Multiagentenarchitektur für die Ablaufkoordination. Für die Funktionsschicht der Plattform wird eine Programmierschnittstelle angeboten, ebenso wie für die Anwendungsschicht. In einer Fallstudie zeigen die Autoren die Anwendung ihrer Simulationsplattform für die Abbildung des Containerterminals in Singapur und testen verschiedene Strategien zur Produktivitätssteigerung im Terminal. Weitere Simulationsmodelle existieren. Einen Vergleich von verschiedenen Simulationsmodellen nehmen [AB11] vor.

Keines der Simulationsmodelle berücksichtigt jedoch explizit die Leistungsaufnahme des Gesamtterminals. Lediglich für Teilkomponenten des logistischen Systems wird die Leistungsaufnahme untersucht. So betrachtet [Mul09] die Leistungsaufnahme eines Blocklagerkrans und entwickelt anhand eines weitestgehend statischen Modells der Leistungsaufnahme verschiedene Strategien um die Energieeffizienz des Krans zu verbessern. [Le12] nutzt ein Simulationsmodell für die Untersuchung der Leistungsaufnahme von Blocklagerkränen und [Wil04] wertet statistisch die Leistungsaufnahme von Kühlcontainern aus, die einen nicht unbeträchtlichen Anteil an der Gesamtleistungsaufnahme eines Containerterminals darstellt. Diese Auswertung wird genutzt, um ein Vorhersagemodell für den Spitzenlastbedarf der Kühlcontainer einer Schiffsladung zu entwickeln.

Einen ganzheitlichen Ansatz zur Betrachtung der energetischen Prozesse eines Containerterminals bietet [Tra12]. Über zwei Jahre wurden Leistungsaufnahmedaten aller Verbraucher und die Gewichte der einzelnen umgeschlagenen Container des Containerterminals Melbourne aufgezeichnet. Daraus wird ein mathematisches Modell zur Berechnung der möglichen Maximallast entwickelt, welches zur Bestimmung der Auslegung des Netzanschlusses des Terminals genutzt werden kann. [S+13] präsentieren in einem Projektbericht die beobachteten Leistungsaufnahmewerte verschiedener kleinerer Containerterminals im Mittelmeerraum und die statische Aufteilung der Leistungsaufnahme auf verschiedene Verbrauchsgruppen innerhalb des jeweiligen Terminals. Neben der Leistungsaufnahme wird auch der Verbrauch weiterer Energieträger wie Treibstoff beschrieben, um darauf basierend CO₂-Emissionen zu ermitteln und Strategien für deren Reduzierung zu entwickeln.

Einen simulationsbasierten Ansatz für die kurzfristige Vorhersage der Gesamtleistungsaufnahme auf Basis der geplanten bzw. tatsächlichen logistischen Prozesse präsentieren [RIH+14] und [GHI+14]. Das Simulationswerkzeug „Plant Simulation“ wird um eine ereignisdiskrete Aufzeichnung von Leistungsaufnahmewerten einzelner Verbraucher erweitert, bei der sowohl die Zustände einzelner Einheiten, als auch die Prozesse für die Leistungsaufnahme berücksichtigt werden. Dieses wird genutzt, um sowohl die logistischen als auch die energetischen Prozesse des Container Terminal Altenwerder in Hamburg möglichst vollständig abzubilden. Das Modell ist dabei aufgeteilt in die Hauptbereiche Blocklager, Horizontaltransport, Kaikräne und Schiffsliegeplätze. Im Bereich des Horizontaltransports wird zusätzlich noch die Si-

mulation von batterie-elektrisch betriebenen Transportfahrzeugen ermöglicht. Basierend auf der Liste der geplanten Schiffsankünfte und -abfahrten für den nächsten Tag können sowohl ein Gesamtlastgang für das Terminal als auch Teillastgänge einzelner Verbrauchsgruppen prognostiziert werden.

3.2.1 Zusammenfassung und Bewertung

Es gibt eine Vielzahl von Literatur zu Prozessen und Abläufen in Containerterminals. Meistens wird dazu aus Sicht des Operations Research versucht, einzelne komplexe Problemstellungen des Terminals zu lösen bzw. vorhandene Lösungen zu optimieren. Beliebtes Hilfsmittel dafür sind Simulationsmodelle für Containerterminals, welche die Abläufe möglichst exakt nachstellen und über die Zeit ablaufen lassen. So lassen sich einzelne Optimierungseffekte am Modell erkennen. Energetische Prozesse werden meist nicht betrachtet. In der Literatur beschränkt sich die Betrachtung meistens nur auf Einzelkomponenten eines Terminals oder auf den maximalen Bedarf für die Gesamtauslegung.

	Martinsen et al. 2001; Moorthy et al. 2003; Sun et al. 2012	Muller 2009	Le 2012	Wild 2004	Tran 2012	Sapina et al. 2013	Runge et al. 2014
Verfahren	Simulation	Analytisch	Simulation	Analytisch	Analytisch	Analytisch	Simulation
Schwerpunkt	Prozess- optimierung	Leistungs- aufnahme Blocklagerkran	Leistungs- aufnahme Blocklagerkran	Kühlcontainer	Spitzenlast- bedarf	CO2- Emissionen	Energie- verbrauchs- prozesse
Berücksichtigung Gesamtterminal	+	-	-	-	+	+	+
Berücksichtigung Energieverbrauch	-	+	+	+	+	+	+
Nutzung für Lastgangprognose möglich	-	-	0	0	-	-	+

Tabelle 2: Vergleich der verwandten Arbeiten aus dem Bereich der energetischen Prozesse in Containerterminals

Nur ein Simulationsmodell betrachtet ein Containerterminal als Gesamtsystem und versucht auch alle Energieverbrauchsprozesse mit abzubilden. Durch Nutzung von zukünftigen Schiffsankunftslisten können hier auch Prognosen eines zukünftigen Lastgangverlaufs getroffen werden. Nachteil dieser Lösung ist jedoch der extrem hohe Aufwand für die Erstellung des Simulationsmodells und die damit einhergehende Spezialisierung auf das Containerterminal, für das das Modell erstellt wurde. Eine Übertragung auf weitere Containerterminals bedarf wieder einer neuen Modellbildung. Da das erstellte Modell für das Container Terminal Altenwerder erstellt wurde und der Autor dieser Arbeit an der Erstellung beteiligt war, soll es als ein Modell für die Lastgangprognose mittels Simulation genutzt und wird daher in Kapitel 2.3.4 noch einmal detaillierter vorgestellt werden.

3.3 Fallbasiertes Schließen in der Energiedomäne

Fallbasiertes Schließen wird in einer Vielzahl von Domänen angewendet, insbesondere in den Bereichen Planung, Diagnose und Konfiguration [Stahl03]. Eine breite Anwendung findet die Methode unter anderem in medizinischen Entscheidungsunterstützungssystemen [BAF+11]. In einigen neueren Entwicklungen wird Fallbasiertes Schließen auch im weitesten Sinne in der Energiedomäne eingesetzt, die entsprechenden Ansätze sollen im Folgenden kurz vorgestellt werden.

[USR+10] präsentieren ein Diagnosesystem zur Überwachung von Energieflüssen und Energieeffizienzkennzahlen in Produktionsumgebungen. Das Teilsystem wird als Unterstützungssystem im Rahmen eines Energiemanagement-Lebenszyklus eingeordnet und ist eingebettet in eine Systemumgebung die zusätzlich noch die Einführung neuer Produktionsumgebungen und deren kontinuierliche Verbesserung in Hinsicht auf Energieeffizienz unterstützt. Fallbasiertes Schließen wird dabei für die Problemlösung im Falle der Abweichung der Energieflüsse und -kennzahlen von den erwarteten Werten genutzt. Dazu ist es möglich das System über Middleware mit verschiedenen Messeinrichtungen und dem Energiemanagementsystem der Produktionsumgebung zu verbinden. Die aktuellen Umgebungskennzahlen werden dadurch kontinuierlich erfasst und ggf. zu sogenannten „Energy Use Parameters“ aggregiert und gefiltert. Bei Abweichungen des Verlaufs der erfassten Kennzahlen von dem erwarteten vorgegebenen Verlauf werden die aktuellen Kennzahlen analysiert und basierend darauf Lösungen vorgeschlagen, die auf bereits gelösten Problemen bei einem ähnlichen Kennzahlenverlauf basieren. Diese sind in einer zentralen Wissensdatenbank abgelegt, in der auch die gemessenen Daten festgehalten werden. Ob eine Anpassung der vorgeschlagenen Lösungen nach dem Retrieval noch erfolgt, bleibt offen.

[DMD+09] und [TXWP+10] stellen ein System zur Spannungsregelung von regionalen Verteilnetzen vor. Für die Spannungsregelung wird Fallbasiertes Schließen als alternative Methode zu Constraint Programming und Optimal Power Flow-Berechnungen dargestellt und evaluiert. Werden Spannungsabweichungen im Verteilnetz erkannt, so wird in einer vorab durch Simulationsstudien gefüllten Fallbasis nach den ähnlichsten fünf Situationen gesucht und die darin vorgeschlagenen Steuerungsmöglichkeiten als mögliche Lösungsvorschläge präsentiert. Eine Besonderheit ist, dass zu jedem Fall in der Fallbasis durch Simulation mehrere Lösungsmöglichkeiten bereitgestellt werden. Um eine bevorzugte Lösung zu ermitteln, wurde jede Art von Schalthandlung, die in einer Lösung beinhaltet sein kann, zusätzlich von dem Netzbetreiber mit einem Faktor bewertet, anhand dessen die beste Lösung aus dessen Sicht bestimmt werden kann. Die gefundenen Lösungen werden durch ein Online-Verifikationstool, welches anhand einer Lastflusssimulation die neuen Spannungswerte ermittelt, evaluiert. Ist die Evaluation erfolgreich so wird die Lösung mit den bevorzugten Schalthandlungen gewählt. Sollte die Evaluation fehlschlagen, so wird die zweitbeste mit dem Fall verbundene Lösung getestet. Dieses Vorgehen bietet Performanzvorteile, da die Spannungsregelung in Verteilnetzen ein zeitkritischer Vorgang ist und eine erneute Suche nach ähnlichen Fällen vermieden werden kann. Die Gewichtung der einzelnen Attribute erfolgt auf Basis von verfügbarem Expertenwissen, wobei nur zwischen wichtigen Attributen mit einer Gewichtung von 1 und weniger wichtigen Attributen mit einer Gewichtung von 0,9 unterschieden wird. Erste Ergebnisse zeigen eine erfolgreiche Anwendung der Methodik. Insbesondere die hohe Performance und die

Möglichkeit der Verifizierung eines Lösungsvorschlags werden als Vorteile der beschriebenen Lösung genannt.

[VM04] nutzen Fallbasiertes Schließen als Teil eines Systems zur Ermittlung der mittelfristigen Lastentwicklung in Peru. In ihrem System FUTURA wird die elektrische Lastentwicklung für die kommenden Monate zuerst mittels polynomialer Ausgleichsrechnung, einer numerischen Methode auf Basis von historischen Daten und des minimalen quadratischen Fehlers, bestimmt. Dabei werden auf Basis vergangener Verbrauchsspitzen für einzelne Umspannstationen eine höchste, eine niedrigste und eine durchschnittliche Lösung bestimmt. Anschließend wird diese Ausgangslösung mit Methoden des Fallbasierten Schließens angepasst. Dabei wird nach einem ähnlichen Monat in der Vergangenheit gesucht, wobei die Kriterien für die Ähnlichkeit, angelehnt an das Vergleichstagverfahren, hauptsächlich auf kalendarischen Aspekten beruhen. Wetterdaten werden als nicht ausreichend relevant für die Verwendung in Peru gesehen, da die Wetterverhältnisse eher stabil sind. Die Werte eines so gefundenen Monats werden genutzt, um die gemittelten Werte der einzelnen Wochentage zur Anpassung der Ausgangslösung zu nutzen. So soll die analytisch ermittelte Ausgangslösung um in der Vergangenheit aufgetretene Schwankungen im Lastverlauf angepasst werden. Dazu werden die Werte zusätzlich auf Basis der erwarteten Höchstlast des Tages normalisiert. Besondere Tage wie Feiertage oder Tage mit besonderen Ereignissen (z. B. Finalsporte im Fußball) werden ausgelassen um die Durchschnittsbildung nicht zu beeinflussen. Anschließend wird mittels eines weiteren Expertensystems noch ein allgemeiner Anpassungsfaktor ermittelt, der sozioökonomische Faktoren wie Bevölkerungsentwicklung, geografische Aspekte und das Lastverhalten spezieller Industriezweige berücksichtigt. Dieser wird regelbasiert ermittelt und kann eine Anpassung der Lastkurve um bis zu 20 % Prozent bewirken.

[Wan06] präsentiert einen Ansatz für die Prognose von Lastspitzen in einem Verteilnetz. Dazu nutzt er Fallbasiertes Schließen und als Attribute den Wochentag, Wochentagstyp und verschiedene Wetterdaten. Die Fallbasis wird mittels Self-Organising-Maps (SOM) geclustert, um ein effizienteres Retrieval zu ermöglichen. Die Gewichtung der einzelnen Attribute erfolgt auf Basis der Rough-Set-Technik, mit deren Hilfe die Anzahl der benötigten Attribute reduziert wird, indem nur die aktuell relevanten Attribute betrachtet werden und die Relevanz der einzelnen Attributklassen bestimmt wird. Das Retrieval erfolgt über einen k-Nächste-Nachbarn-Ansatz mit einer gewichteten Summe der Ähnlichkeit zwischen den einzelnen Attributen der Anfrage und dem eines Clusters. Aus dem Cluster mit der größten Ähnlichkeit wird anschließend der ähnlichste Fall bestimmt. Die Spitzenlast dieses Tages wird als Spitzenlast für den neuen Tag übernommen, angepasst um einen Faktor, der die jährliche Steigerungsrate in der Gesamtlast des betrachteten Netzes entspricht. In einer Fallstudie wird gezeigt, dass die vorgeschlagene Lösung im Durchschnitt besser abschneidet, als ein Vergleichstagverfahren oder ein Ansatz mit Künstlichen Neuronalen Netzen. Eine exakte Auswertung dazu bleibt aber offen.

[MAC13] präsentieren eine Methode zur Energieverbrauchsvorhersage von Bürogebäuden basierend auf Methoden des Fallbasierten Schließens. Die Ähnlichkeit wird hier hauptsächlich über Wetterdaten bestimmt, wobei Gewichte einzelner Parameter je nach Saison und Wetterlage dynamisch angepasst werden können. Aus einem Subset der ähnlichsten Lösungen wird eine Prognose für den Leistungsbedarf der nächsten drei Stunden gebildet, der auch eine Vor-

hersage darüber beinhaltet, ob in diesem Zeitraum eine neue Lastspitze auftritt. Die Evaluation der präsentierten Lösung zeigt eine erfolgreiche Anwendung bei einer durchschnittlichen mittleren quadratischen Abweichung von 12 bis 14 Prozent. Abhängigkeiten in der Wahl der Gewichte von den Zeiten der Aufzeichnung der Fälle bleiben aber offen. [PMZ15] erweitern diesen Ansatz auf die Prognosefähigkeit für sechs Stunden in die Zukunft und präsentieren eine Online-Implementierung der Lösung. Die Autoren präzisieren dabei auch die Eingabeparameter, die sie für ihr System nutzen. Dazu gehören neben den Wetterdaten und den aktuellen Stromverbrauchsdaten auch aktuelle Leistungsangaben der im Gebäude befindlichen Heiz- und Klimageräte sowie Innenraumtemperaturen. Als Online-Fähigkeit wird hier bezeichnet, dass das System ohne vorhandene Fälle in der Fallbasis starten kann, was ein Vorteil bei neu erbauten Gebäuden ist. Dies hat zwar den Nachteil, dass die anfänglichen Lösungen nicht sehr präzise sind (Abweichungen > 44 %), der Vorhersagefehler (MAPE) aber schnell mit steigender Anzahl von Fällen sinkt. Bereits nach 16 Stunden hat sich der Vorhersagefehler halbiert, bevor er sich nach über 400 Stunden bei ca. 12 % einpendelt, was von den Autoren als akzeptables Maß nach kanadischen Gebäuderichtlinien beschrieben wird.

3.3.1 Zusammenfassung und Bewertung

Fallbasiertes Schließen ist eine Problemlösemethode, die erfolgreich in vielen Domänen Anwendung findet. Im Bereich Energie gibt es allerdings nur wenige Arbeiten, die Fallbasiertes Schließen einsetzen. Häufig wird dabei Fallbasiertes Schließen nur in einem Teilsystem eingesetzt, wobei der Schwerpunkt auf dem Retrieval ähnlicher Lösungen basiert. Die ersten beiden vorgestellten Systeme sind jeweils ein Beispiel dafür. Das erste dient der Entscheidungsunterstützung bei auftretenden Problemen in einem maschinellen Produktionsprozess. Der Fokus liegt hier auf Fragestellungen der Energieeffizienz. Das zweite vorgestellte System dient der automatischen Reaktion auf Spannungsabweichungen in einem Verteilnetz, wobei ein Fall immer mehrere Lösungen haben kann. Die Lösungen werden nach einer Verifikation mit Hilfe von Simulation über einen vom Netzbetreiber vorgegebenen Faktor sortiert.

Erst die weiteren vorgestellten Ansätze beschäftigen sich tatsächlich mit der Prognose von Energieverbrauchswerten mit Hilfe der Methoden des Fallbasierten Schließens. FUTURA dient zur Prognose des mittelfristigen Lastverlaufs in Peru. Für die Ähnlichkeit werden hier hauptsächlich kalendarische Parameter herangezogen. Die gefundene Lösung wird genutzt, um eine Ausgangslösung anzupassen. Die so entstandene Lösung wird nochmals mit Hilfe eines Expertensystems angepasst. Wang prognostiziert zukünftige Lastspitzen in einem Verteilnetz. Wichtigste Parameter sind hier ebenfalls kalendarische Attribute, aber auch Wetterdaten. Für ein effizientes Retrieval werden Verfahren aus dem Data Mining-Bereich genutzt. Der letzte präsentierte Ansatz wird für die sehr kurzfristige Prognose von Lastverläufen in Bürogebäuden genutzt. Auch hier spielen kalendarische Aspekte und Wetterdaten eine wichtige Rolle bei der Ähnlichkeitsbestimmung. Zusätzlich werden aktuelle Messwerte aus dem Gebäudeinneren genutzt. Vergangene Lastverläufe werden dabei direkt als Prognosezeitreihe genutzt, eine Anpassung erfolgt nicht.

Keine der vorgestellten Arbeiten beschäftigt sich mit der Prognose von industriellen Großverbrauchern. Die Lösung für die Lastgangprognose für ein Bürogebäude nutzt lediglich Wetter und aktuell gemessene Sensordaten für die Prognose. Informationen über eine mögliche Ge-

bäudebelegung oder weitere externe Faktoren werden nicht genutzt. Damit unterscheiden sich die Ansätze von dem zu entwickelnden System, bei dem das geplante Logistikprogramm für den Folgetag als Basis für die Suche nach ähnlichen Tagen dienen soll. Tabelle 3 gibt einen Überblick über die verschiedenen vorgestellten Ansätze und eine Kategorisierung für die Einschätzung in Bezug auf die vorliegenden Anforderungen für das zu entwickelnde System.

	<i>Urosevic et al. 2010</i>	<i>Davidson et al. 2009 Taylor et al. 2010</i>	<i>Vilcahuaman et al. 2004</i>	<i>Wang 2006</i>	<i>Monfét et al. 2013</i>
Zweck	EUS für Energieeffizienz in Produktion	Spannungsregelung in Verteilnetzen	Mittelfristige Lastprognose	Prognose von Lastspitzen	Lastgangprognose für Bürogebäude
Basis für Ähnlichkeitsbestimmung	Messwerte der Produktionsumgebung	Messwerte von Unterstationen	Kalendarische Faktoren	Kalendarische Faktoren und Wetterdaten	Wetterdaten, aktuellen Sensorwerte
Prognose	-	-	+	+	+
Nutzung von Produktionsplänen	-	-	-	-	-

Tabelle 3: Vergleich der verwandten Arbeiten aus dem Bereich Fallbasiertes Schließen in der Energiedomäne

3.4 Fallbasiertes Schließen für die Prognose von Zeitreihen

Bereits früh wurde ein genereller Ansatz für die Prognose von Zeitreihen beschrieben [Nak-h94]. Für die Prognose eines Zeitreihenwertes Y_{n+1} wird ein Merkmalsvektor aufgestellt, mit Merkmalen, die die Zeitreihenwerte signifikant beeinflussen. Anschließend wird mit Hilfe der k-Nearest Neighbor Methode eine Anzahl von ähnlichen Fällen gefunden und deren Werte gemittelt, um diese als Prognosewert zu nutzen. Weitere Details werden nicht genannt. Neben diesem sehr generalistischen Ansatz werden weitere Ansätze für die Prognose von Zeitreihen beschrieben und eine Kombination der Verfahren kurz diskutiert. Die beschriebene Evaluation von verschiedenen Methoden bringt keine klare Präferenz für eines der Verfahren hervor.

Einen weiteren, von der Energiedomäne unabhängigen Ansatz präsentiert [Kur09] mit dem System *CuBaGe* (Curve Base Generator). Die Idee hinter dem System ist es, dass aktuell für die Entscheidungsunterstützung vorliegende Zeitreihen mit ähnlichen Zeitreihen aus der Vergangenheit verglichen werden, um aus deren Verlauf und den darauf folgenden Daten Schlüsse über den zukünftigen Verlauf der aktuellen Zeitreihe ziehen zu können. Dabei wird versucht die Verbindungen zwischen den einzelnen Punkten der aktuellen Zeitreihe durch ein Polynom zu interpolieren um eine Kurve zu erhalten. Auf Basis dieser Interpolation wird anschließend die Distanz zwischen der aktuellen Zeitreihe und den Zeitreihen aus der Fallbasis berechnet, für die ebenfalls eine solche Interpolation vorliegt. Dabei werden die Zeitreihen

mithilfe kubischer Splines dargestellt und interpoliert. Die Ähnlichkeit kann dann als Intervall zwischen den Kurven berechnet werden, wobei quadratische Funktionen genutzt werden, um die Intervalle von sich kreuzenden Kurven korrekt berechnen zu können.

Einen weiteren interessanten Ansatz stellen [CL01] vor. Sie beschreiben ein System zur Prognose der Wasserzusammensetzung in Ozeanen über die Zeit. Diese basiert hauptsächlich auf den aktuellen Temperaturen des Wassers im Umkreis der zu prognostizierenden Region des Gewässers, der Region und der Jahreszeit, da diese auch Einfluss auf die Zusammensetzung hat. Mit Hilfe der *k*-Nearest Neighbor Methode wird eine Anzahl ähnlicher Fälle extrahiert. Diese gefundenen Fälle werden dann genutzt um ein Künstliches Neuronales Netz zu trainieren. Als Künstliches Neuronales Netz wird hier ein Radial Basis Function Netzwerk verwendet, welches den Vorteil hat, dass bei einem erneuten Training die vorhandenen Kantengewichte erhalten bleiben und lediglich anhand der neuen Trainingsdaten angepasst werden. Ein vollständiges neues Training wird damit nicht benötigt, trotzdem werden die Gewichte an die jeweilige Situation angepasst. Die mit Hilfe der ähnlichen Fälle und über das neuronale Netzwerk generierte Lösung wird anschließend dahingehend überprüft, ob bestimmte Plausibilitätsgrenzen eingehalten werden. Die Güte der so generierten Lösungen wird als besser beschrieben, als jeder andere Ansatz, den die Autoren ausprobiert hätten.

3.4.1 Zusammenfassung und Bewertung

Schon relativ früh wurde die Nutzung von Fallbasiertem Schließen für die Prognose von Zeitreihen allgemein beschrieben. Obwohl dies als generalistischer Ansatz formuliert wurde, wurde dieser von dem wissenschaftlichen Umfeld nur wenig genutzt. Die zwei weiteren im vorangegangenen Kapitel genannten Arbeiten gehören dazu, sind aber die Ausnahme. Allerdings muss angemerkt werden, dass sich dieser generalistische Ansatz des Fallbasierten Schließens für die Prognose von Zeitreihen lediglich auf ein Retrieval der ähnlichsten Fälle mit Hilfe der *k*-Nearest Neighbor Methode beschränkt. Eine Anpassung erfolgt lediglich durch eine Mittelwertbildung über die Werte der gefundenen ähnlichsten Fälle. Weitere Aspekte des Fallbasierten Schließens wie Aufbau der Fälle, die Nutzung unterschiedlicher Ähnlichkeitsmaße oder die Aufnahme neuer Fälle in die Fallbasis werden nicht näher benannt. Es wird beschrieben, dass hier Forschungsbedarf besteht.

Das System *CuBaGe* untersucht dabei für die Prognose die Zeitreihen nur anhand seiner Messpunkte und nutzt keine weiteren eventuell vorliegenden Informationen. Es werden die *k*-ähnlichsten Kurven für die Vorhersage eines Kurvenverlaufs genutzt. Eine weitere Anpassung der Verläufe erfolgt nicht.

Bei der Prognose der Wasserzusammensetzung von Ozeanen über die Zeit kommt ebenfalls ein einfaches Retrievalverfahren zum Einsatz. Allerdings werden die so gefundenen Ergebnisse genutzt, um ein neuronales Netz zu trainieren bzw. anzupassen, welches ein vielversprechender Ansatz ist, sofern das Training des Netzes auf Basis von wenigen Fällen effektiv durchgeführt werden kann.

Tabelle 4 zeigt die Arbeiten noch einmal im Überblick.

	<i>Nakhaeizadeh 1994</i>	<i>Kurbalija 2009</i>	<i>Corchades & Lees 2001</i>
Zweck	Generelle Beschreibung eines möglichen Vorgehens (kNN)	Finden von Vergleichskurven	Prognose von Wasserzusammensetzungen über die Zeit
Vorgehen	Vergangenheitswerte als Prognose	Ähnlichkeit auf Basis der Intervalle zwischen den Kurven	Ähnlichkeitsbasierte Suche, Training eines neuronalen Netzwerks
Anpassung der Werte	-	-	+
Überprüfung der Werte	-	-	+

Tabelle 4: Vergleich der Arbeiten aus dem Bereich Fallbasiertes Schließen für die Prognose von Zeitreihen

4 Untersuchungen des Lastverhaltens eines Containerterminals

Vor Beginn der eigentlichen Modellierung der einzelnen Methoden für die Lastgangprognose wurden vorbereitend verschiedene Untersuchungen zu dem Lastverhaltens des Terminals durchgeführt, um darauf basierend eine entsprechende Modellierung durchführen zu können. Dazu werden operationelle, kalendarische und meteorologische Einflussfaktoren untersucht. Es wird die Annahme getroffen, dass die auf den Daten des Fallbeispiels Container Terminal Altenwerder basierenden Auswertungen in ähnlicher Form auch auf weitere Terminals zutreffen. Dabei ist zu beachten, dass für den Stromverbrauch die gemessenen 15-minütigen Werte vorliegen, die Anzahl der Containerumschläge aber immer nur angenäherte Werte darstellen können, die über die Gesamtanzahl der zu ladenden und zu entladenden Container pro Schiff über den Zeitraum des Festmachens im Terminal gemittelt und ggf. abgegrenzt wurden. 15-minütig gemessene Werte für die Anzahl der Containerumschläge lagen für die durchgeführten Auswertungen nicht vor.

4.1 Meteorologische Einflüsse

Es kann gezeigt werden, dass der durchschnittliche Stromverbrauch pro Containerumschlag bezogen auf den Gesamtstromverbrauch des Terminals in Sommermonaten, also in Monaten mit einer erhöhten Durchschnittstemperatur und längeren Abschnitten mit Tageslicht, geringer ist als in Wintermonaten mit niedriger Temperatur. Abbildung 12 zeigt eine entsprechende Auswertung über zwei Jahre (2012 und 2013). Dabei ist der Durchschnittsverbrauch pro Containerumschlag relativ gesetzt zu dem höchsten auftretendem Durchschnittsverbrauch in diesem Zeitraum, welcher im Dezember 2013 auftritt und damit für diesen Monat den Wert 1 annimmt.

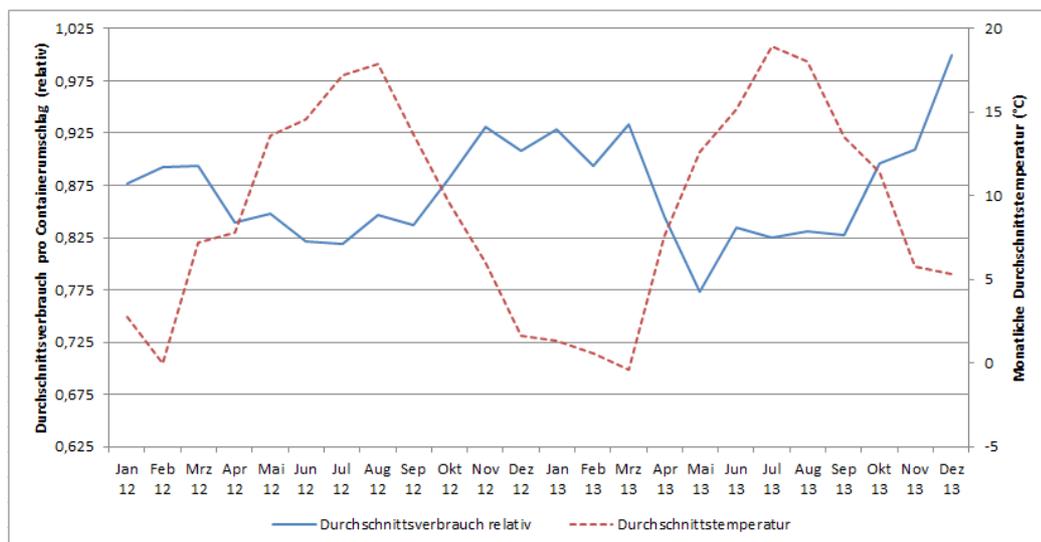


Abbildung 12: Verhältnis von monatlicher Durchschnittstemperatur zu Energieverbrauch pro Containerumschlag

Um den durchschnittlichen Stromverbrauch pro Containerumschlag zu berechnen, wurden für diese Auswertung alle Containeranlieferungen und Containeraufnahmen der Schiffe, so wie sie in den jeweiligen Segellisten gespeichert wurden, aufsummiert und durch die Summe des Stromverbrauchs des dazugehörigen Monats geteilt. Es ist deutlich zu erkennen, dass die durchschnittlichen Verbrauchswerte im Frühling (Monate März/April) deutlich absinken, während die Durchschnittstemperatur sich deutlich erhöht. Gleiches gilt für den Herbst mit den Monaten Oktober und November. Hier sinken die Temperaturen stark und der durchschnittliche Strombedarf pro Containerumschlag erhöht sich wieder. Tabelle 5 zeigt dies beispielhaft für vergleichbare Tage über vier Jahre hinweg. Für jedes Jahr wurde ein Tag im Sommer gewählt und ein entsprechender Tag im Winter mit einer ähnlichen Anzahl von Containerumschlägen. Dabei wurden sowohl die Anzahl der Umschläge, als auch der Verbrauch des jeweiligen Sommertages als relativer Referenzwert für den Wintertag gesetzt. Es ist deutlich zu erkennen, dass der Verbrauch an den Wintertagen bis zu mehr als 20 % höher liegt als an Sommertagen. Dabei muss aber bedacht werden, dass dieser Mehrverbrauch nicht alleine auf einen Temperaturunterschied zurückgeführt werden kann, sondern auch die geringere Anzahl von Stunden mit verfügbarem Tageslicht hierbei eine wesentliche Rolle spielt. Trotzdem lässt sich bereits rein auf Basis der Betrachtung von Tagesdurchschnittstemperaturen und dem dazugehörigen Lastverhalten ein erhöhter Strombedarf pro Container bei deutlich kälteren Temperaturen ableiten.

Datum	Wochentag	Tagesdurchschnittstemperatur (°C)	Container relativ	Verbrauch relativ
2010				
Sommertag 2010	Samstag	27,0	100%	100%
Wintertag 2010	Samstag	-3,0	97%	127%
2011				
Sommertag 2011	Samstag	20,0	100%	100%
Wintertag 2011	Samstag	2,0	104%	109%
2012				
Sommertag 2012	Samstag	13,0	100%	100%
Wintertag 2012	Samstag	2,0	100%	118%
2013				
Sommertag 2013	Samstag	12,0	100%	100%
Wintertag 2013	Samstag	3	97%	113%

Tabelle 5: Beispielhafte Vergleiche von Tagen mit ähnlichen Containerumschlagzahlen und dem entsprechenden relativen Verbrauch über vier Jahre

Die unterschiedlich langen Tageslichtphasen beeinflussen den Strombedarf wesentlich. So muss im Winter deutlich mehr Leuchtkraft im Terminal zur Verfügung gestellt werden. Hier

spielt neben dem späteren Sonnenauf- und früheren -untergang auch die häufigere Bewölkung eine wichtige Rolle. Während zum Beispiel die durchschnittliche tägliche Sonnenscheindauer im Januar 2013 in Hamburg 0,65 Stunden betrug (niedrigster Wert des Jahres), waren es im Juli als Monat mit dem höchsten durchschnittlichen Wert 9,64 Stunden. Die Beleuchtung trägt in der Regel ca. 10% zum Gesamtenergieverbrauch des Terminals bei (vgl. Abbildung 4). Dieser Leistungsbedarf fällt allerdings nur an, wenn die Beleuchtung auch tatsächlich genutzt wird. Tagsüber, wenn die Tageslichtverhältnisse es ermöglichen, wird die Beleuchtung heruntergefahren bzw. vollständig ausgestellt. Es wird davon ausgegangen, dass der erhöhte Bedarf an Beleuchtung bereits in den durchschnittlichen Leistungsbedarfen wie in Abbildung 12 gezeigt enthalten ist. Somit kann der Anstieg des durchschnittlichen Leistungsbedarfs nicht nur mit Temperaturunterschieden erklärt werden, sondern kann auch auf den erhöhten Beleuchtungsaufwand in den entsprechenden Monaten zurückgeführt werden.

Neben den Temperaturen haben die monatlichen durchschnittlichen Windgeschwindigkeiten einen Einfluss auf die Verbrauchswerte. Die durchschnittlichen Windgeschwindigkeiten eines Monats haben dabei einen ähnlichen Verlauf wie die Temperaturkurve aus Abbildung 12. Es wird davon ausgegangen, dass die Temperatur und die Windgeschwindigkeit damit einen unmittelbaren Einfluss auf den Strombedarf im Terminal haben, wobei der Einfluss der Tages-temperatur höher bewertet wird als die entsprechenden Windgeschwindigkeiten.

4.2 Kalendarische Einflüsse

Untersucht wurde auch, ob es wesentliche Unterschiede zwischen dem Strombedarf an Werktagen und an Wochenend- oder Feiertagen gibt. Regelmäßige Unterschiede zwischen dem kumulierten Gesamtstrombedarf an einem Werktag und dem Strombedarf an einem Wochentag konnten nicht festgestellt werden. Hier war die Vermutung, dass am Wochenende ein veringertes Energiebedarf vorhanden sein könnte, da die Verwaltung des Terminals an diesen Tagen nicht voll besetzt ist und somit die Last, die vom Bürobetrieb erzeugt wird, verringert wird. Trotzdem ist der Verlauf des Lastgangs am Wochenende häufig unregelmäßiger als an Werktagen. Abbildung 13 zeigt zwei beispielhafte Lastverläufe von zwei zufällig ausgewählten Tagen. Die Lastverläufe wurden dabei für die Darstellung angepasst, da die Originalwerte nicht öffentlich sind, geben aber einen Eindruck von möglichen Verläufen, wie sie in der Realität vorkommen können.

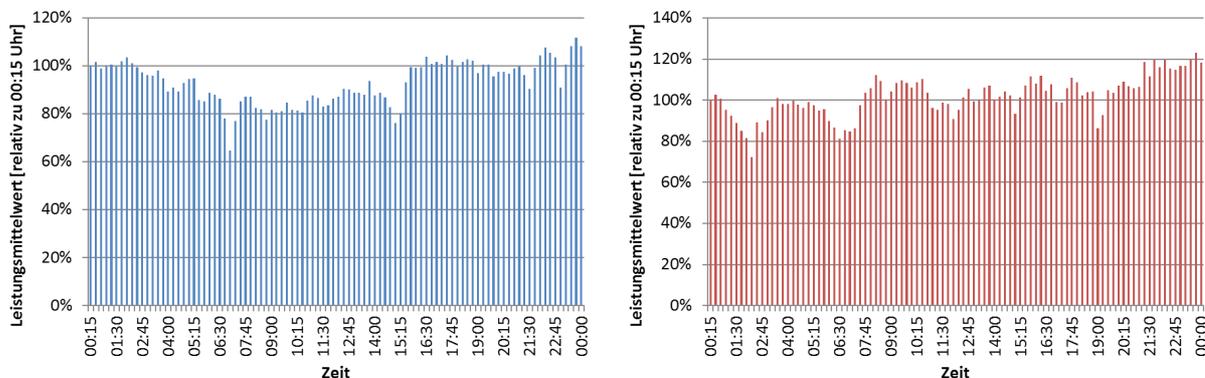


Abbildung 13: Beispielhafte Lastverläufe

In der Abbildung ist jeweils der Wert von 00:15 Uhr als Bezugspunkt auf 100 % gesetzt. Schwankungen von mehr als 20 % innerhalb eines Tages sind täglich festzustellen. Gewisse Regelmäßigkeiten ergeben sich aus Schwankungen, die zum Beispiel auf Schichtwechsel beruhen, bei denen der Betrieb kurzfristig eingestellt wird, aber anschließend sofort wieder aufgenommen wird. Einen deutlichen Einfluss haben allerdings Feiertage, an denen das Terminal halbtags oder den gesamten Tag den Betrieb einstellt. Hier fällt der Strombedarf auf eine Grundlast zurück und schwankt lediglich deutlich bei Zu- oder Abschaltung der Beleuchtung an dem Tag. Das Container Terminal Altenwerder stellt allerdings nur an ausgewählten Feiertagen den Betrieb vollständig ein. An einigen gesetzlichen und kirchlichen Feiertagen wird durchgearbeitet. Wird für einen gesamten Tag der Betrieb des Terminals vollständig eingestellt, so hat dies auch Einfluss auf den Tag vor dem Feiertag und den Folgetag des Feiertags.

Abbildung 14 zeigt beispielhaft den Verlauf des Lastgangs⁴ an einem Feiertag, an dem das Terminal den Betrieb komplett einstellt. Es ist deutlich zu erkennen, dass bereits am Vortag mit der Mittagsschicht der Betrieb eingestellt wird. Der Lastgang ab der Viertelstunde 26 deutlich ab und ist etwa bei Viertelstunde 51 auf einem Grundlastniveau angekommen unter das er bis zur Wiederaufnahme des Betriebs nicht mehr deutlich sinkt. Diese Absenkungen der Leistungsaufnahme erfolgt noch am Vortag zum eigentlichen Feiertag. Gut zu erkennen ist in diesem Lastgang die im vorherigen Absatz beschriebene Zuschaltung der Beleuchtung im Terminal. Diese startet etwa bei Viertelstunde 60 und endet ab Viertelstunde 96. Am Folgetag startet der Betrieb erst wieder mit der Frühschicht am Folgetag, ab etwa Viertelstunde 190. Hier ist ein deutlicher Anstieg des Lastgangs erkennbar. Ab etwa Viertelstunde 205 hat er sich wieder auf einem üblichen Niveau eingependelt. Konsequenz dieser Beobachtung ist es, dass sowohl Feiertage an denen das Terminal den Betrieb einstellt, als auch die jeweiligen Vor- und Folgetage besonders behandelt werden müssen.

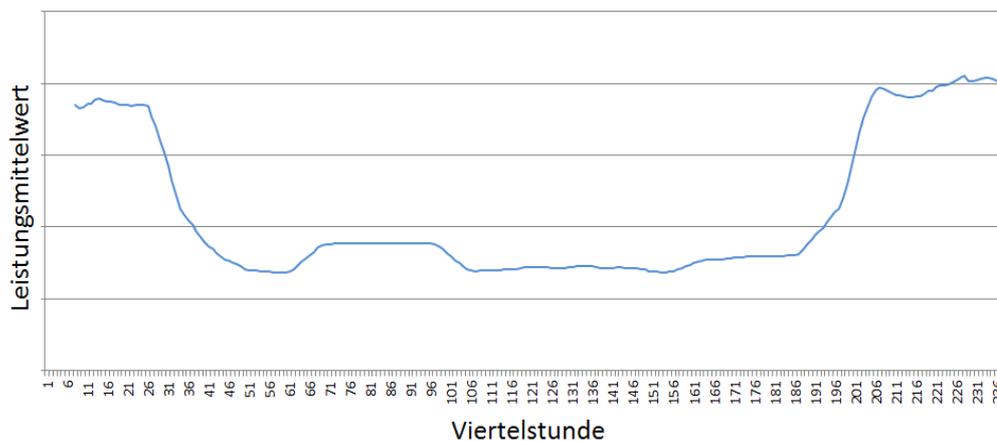


Abbildung 14: Beispielhafter Lastverlauf eines Feiertags mit Vor- und Folgetag

4.3 Einfluss der Betriebsprozesse

Der Energieverbrauch eines Containerterminals ist in großem Maße abhängig von der Anzahl der umgeschlagenen Container. Abbildung 15 zeigt eine Auswertung über die tägliche Anzahl

⁴ Der Lastverlauf wird als gleitender Durchschnitt dargestellt um einzelne Schwankungen zu glätten und nur die wesentlichen Eigenschaften des Lastverlaufs darzustellen.

von Containerumschlägen und den dazugehörigen Leistungsbedarf des jeweiligen Tages über einen Ausschnitt eines Jahres für ein beispielhaftes Containerterminal⁵.

Deutlich zu erkennen sind dabei die geringen Energieverbrauchswerte an Feiertagen (z. B. Ostern und Tag der Arbeit), die einhergehen mit einer sehr geringen Anzahl von Containerbewegungen. Üblicherweise einen Betrieb an 24 Stunden an 7 Tagen die Woche bereitstellend, lässt das Containerterminal an einigen wenigen Feiertagen im Jahr den Betrieb vollständig ruhen. Dass in der Abbildung Containerbewegungen verzeichnet sind und die Anzahl nicht bei Null liegt, liegt an der angewandten Berechnungsmethode der Containerbewegungen. Da eine exakte tageweise Auswertung der Containerbewegungen nicht vorliegt, teilt die genutzte Methode die Anzahl der zu be- und entladenen Container pro Schiff über die gesamte Schiffs Liegezeit auf. Über die Feiertage können Schiffe am Kai liegen, diese werden aber im operativen Geschäft in dieser Zeit nicht gelöscht, während dies in der vereinfachten Berechnung nicht berücksichtigt wird. Ebenso ist es möglich, dass Schiffe an Feiertagen im Terminal ankommen und festmachen, aber auch hier gilt, dass die Löschung des Schiffes erst mit dem Beginn der nächsten regulären Schicht am Folgetag beginnt.

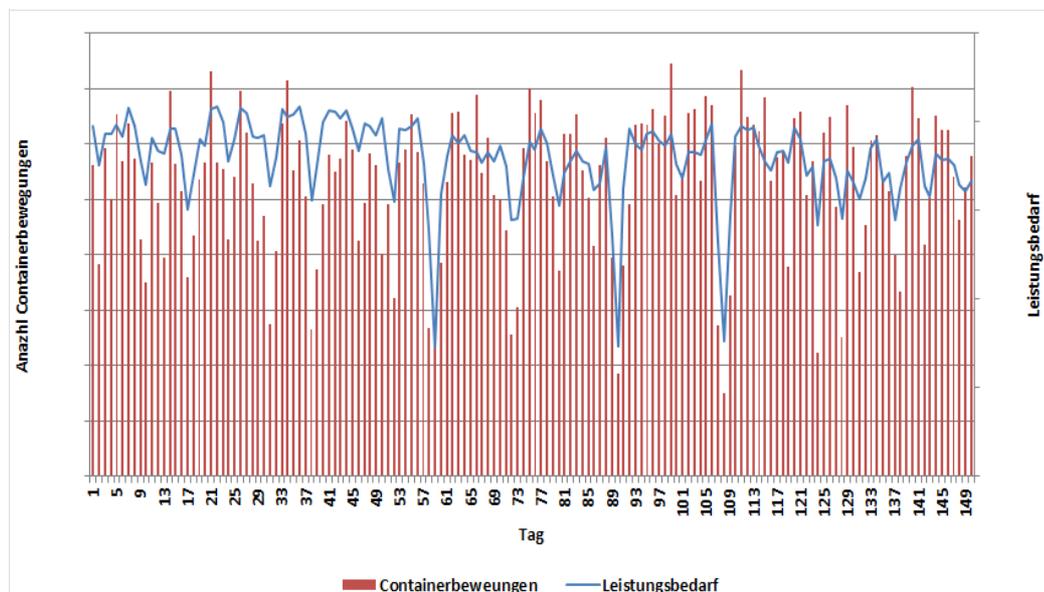


Abbildung 15: Verhältnis von Containerbewegungen zu Energieverbrauch

Daneben ist noch zu erkennen, dass es an Wochenenden ebenfalls häufig zu einer geringeren Anzahl von Containerbewegungen kommt, der Lastgang hier aber nicht ganz so stark abfällt wie an Feiertagen. Dies liegt daran, dass der Terminal auch am Wochenende in vollem Betrieb ist und die geringere Auslastung unter anderem dazu genutzt wird die Lagerhaltung zu optimieren, in dem zum Beispiel die Container in den Blocklagern umgestapelt werden. Zudem ist sonntags der Hinterlandverkehr per LKW im Terminal nicht vorhanden, da aufgrund des Sonntagsfahrverbots die Anlieferung und Abholung von Containern nur per Bahn möglich ist.

Berechnet man den Zusammenhang zwischen den täglichen Containerumschlagzahlen auf der einen Seite und dem dazugehörigen Energieverbrauch auf der anderen Seite, so kann dieser

⁵ Die Anzahl der Containerumschläge und der Leistungsbedarf sind jeweils nur beispielhaft angenähert an tatsächliche Werte dargestellt.

Zusammenhang auch statistisch gezeigt werden. Dazu wird der empirische Korrelationskoeffizient (Bravais-Pearson-Korrelationskoeffizient) nach (24) genutzt.

$$\rho_{xy} = \frac{\sum_{i=1}^n ((x_i - \bar{x})(y_i - \bar{y}))}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 (y_i - \bar{y})^2}} \quad (24)$$

Berechnet man diesen zum Beispiel für das Jahr 2013, so erhält man einen Wert von 0,78 für den Korrelationskoeffizienten. Üblicherweise wird ab einem Wert von 0,5 von einem mittlerem linearen Zusammenhang gesprochen und ab einem Wert von 0,8 von einem starken Zusammenhang. Da der Wert von 0,78 dem Wert 0,8 nahe kommt, wird hier ebenfalls von einem deutlichen Zusammenhang zwischen dem täglichen Energieverbrauch und den täglichen Containerumschlagzahlen ausgegangen.

Einführung 10: Korrelationskoeffizient

Die Korrelation ist ein statistisches Maß für die Quantifizierung der linearen Abhängigkeit zwischen zwei Variablen. Diese Variablen können zum Beispiel Messreihen beschreiben.

Der Korrelationskoeffizient ρ berechnet sich über die Kovarianz der beiden betrachteten Größen, welche durch das Produkt der beiden Standardabweichungen geteilt wird. Er kann einen Wert zwischen -1 und 1 annehmen. $\rho=1$ bedeutet, dass es einen positiven linearen Zusammenhang zwischen beiden Größen gibt, $\rho=0$ weist darauf hin, dass es keinen statistischen Zusammenhang zwischen den beiden Größen gibt.

Der Wert der Korrelation basiert auf den täglichen Werten, sagt aber noch nichts über den Verlauf des Leistungsbedarfs des Containerterminals über den Tag aus. Betrachtet man den Verlauf eines Lastgangs über einen Tag, so können auch hier einige Regelmäßigkeiten erkannt werden. Insbesondere die bereits in Kapitel 4.3 beschriebenen Schichtwechsel der Containerkranbesetzungen sind deutlich in einem Abstand von acht Stunden als Ausschlag nach unten zu erkennen (z. B. gegen 06:30 Uhr). Mit dem Stopp der Containerkräne in diesem Zeitraum stockt auch der Horizontaltransport und damit die Arbeit der Blocklager, so dass der Ausschlag signifikant ist und an fast allen Arbeitstagen eindeutig nachvollzogen werden kann. In den Zeiträumen zwischen den Schichtwechseln kommt es zu einem schwankenden Verbrauch, der abhängig von der jeweiligen momentanen Arbeitsintensität innerhalb des Terminals ist. Zudem können in der Grundlast Unterschiede zwischen dem Verbrauch im Sommer und dem Verbrauch im Winter festgestellt werden (vgl. Kapitel 4.2).

4.4 Langfristige Entwicklungen

Der Umschlag von Containern ist ein weltweiter Wachstumsmarkt. Abgesehen vom Jahr 2009, welches aufgrund der Finanzkrise eine Besonderheit darstellt, steigt die Anzahl der

weltweit umgeschlagenen Container kontinuierlich und auch die Prognosen verweisen auf weiter steigende Zahlen (vgl. Abbildung 16).

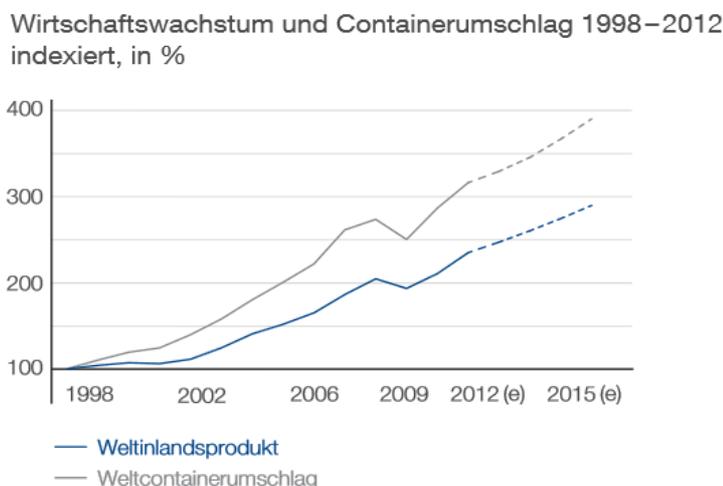


Abbildung 16: Wirtschaftswachstum und Containerumschlag 1998-2012 [Hhla12]

Durch den Zusammenhang zwischen den in einem Terminal umgeschlagenen Containern und dem Stromverbrauch eines Terminals, ist somit für einzelne Terminals auch ein steigender Stromverbrauch zu erwarten. Zwar werden zunehmend generell Maßnahmen zur Steigerung der Energieeffizienz von Umschlaggeräten durchgeführt, allerdings gleichen diese den Anstieg nicht vollständig aus. Zudem wird Umschlaggerät weiter elektrifiziert und einzelne Ausbaumaßnahmen erweitern die Terminalkapazität.

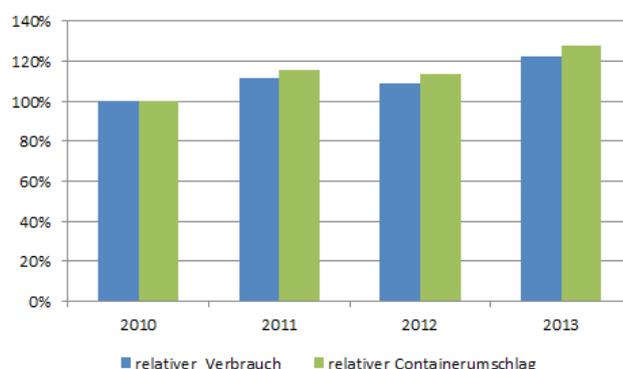


Abbildung 17: Steigerung von Strombedarf und Containerumschlag relativ zum Jahr 2010

Betrachtet man zum Beispiel sowohl die Containerumschlagzahlen, als auch den Gesamtenergieverbrauch des Container Terminals Altenwerder über mehrere Jahre, so lässt sich feststellen, dass sowohl die Containerumschlagzahlen, als auch der Gesamtleistungsbedarf steigt. Abbildung 17 zeigt den Verlauf der Containerumschläge und des Strombedarfs des Container Terminals Altenwerder über den Zeitraum von vier Jahren, wobei das Jahr 2010 als Basis für diese relative Betrachtung gesetzt wurde. Es ist zu erkennen, dass die Steigerung des Strombedarfs dem Containerumschlag folgt, aber nicht im vollumfänglichen Maße. Aus der Beobachtung der vier Jahre lässt sich aber der Schluss ziehen, dass bei einem Ausblick auf gestei-

gerte Umschlagzahlen im Folgejahr, wie sie zum Beispiel aus den Geschäftsberichten hervorgehen, sich auch ein insgesamt erhöhter Strombedarf für das Jahr ergibt.

Das Beispiel des Container Terminal Altenwerder zeigt, dass es lohnenswert ist, sich auch die langfristige Entwicklung des Strombedarfs eines Terminals anzuschauen, insbesondere, wenn langfristig historische Daten zur Lastprognose herangezogen werden sollen.

4.5 Zusammenfassung

In den vorangegangenen Kapiteln wurden anhand von Beispielen des Container Terminals Altenwerder verschiedene Einflussfaktoren auf den Lastgang diskutiert. Es konnte gezeigt werden, dass eine Korrelation zwischen den täglichen Containerumschlagzahlen und dem täglichen Stromverbrauch des Terminals herrscht und damit die Containerumschläge einen wesentlichen Einfluss auf den Leistungsbedarf haben. Aber auch Witterungseinflüsse und verschiedene Tagestypen beeinflussen den Lastgang. Dabei muss beachtet werden, dass die Einflüsse der Außentemperatur im mitteleuropäischen Raum andere sein können als in Containerterminals in deutlich wärmeren Regionen, bei denen es aufgrund von vermehrter Kühlung in Sommermonaten einen höheren Verbrauch gibt. Entsprechende Effekte sind daher vor Nutzung der entsprechenden Einflussfaktoren als Eingabeparameter für Prognoseverfahren immer individuell nachzuvollziehen. Es wird allerdings davon ausgegangen, dass sie unabhängig von der Lokalisation des Containerterminals immer einen Einfluss auf das Lastgangverhalten haben. Dies gilt auch für langfristige Entwicklungen. Neben Trends in der Containerlogistik im Allgemeinen, kann auch die vermehrte Nutzung von elektrifiziertem Umschlaggerät Einfluss auf den Lastgangverlauf haben.

5 Konzepte für die Lastgangprognose maritimer Containerterminals

In den folgenden Kapiteln sollen für verschiedene Prognoseverfahren Konzepte entwickelt werden, die beschreiben, wie diese Verfahren für die Lastgangprognose von Containerterminals genutzt werden zu können. Dabei soll nicht nur gezeigt werden, wie die Verfahren an sich genutzt werden können, sondern auch wie die jeweils geplanten Betriebsdaten des Terminals in den Prognoseprozess integriert werden können.

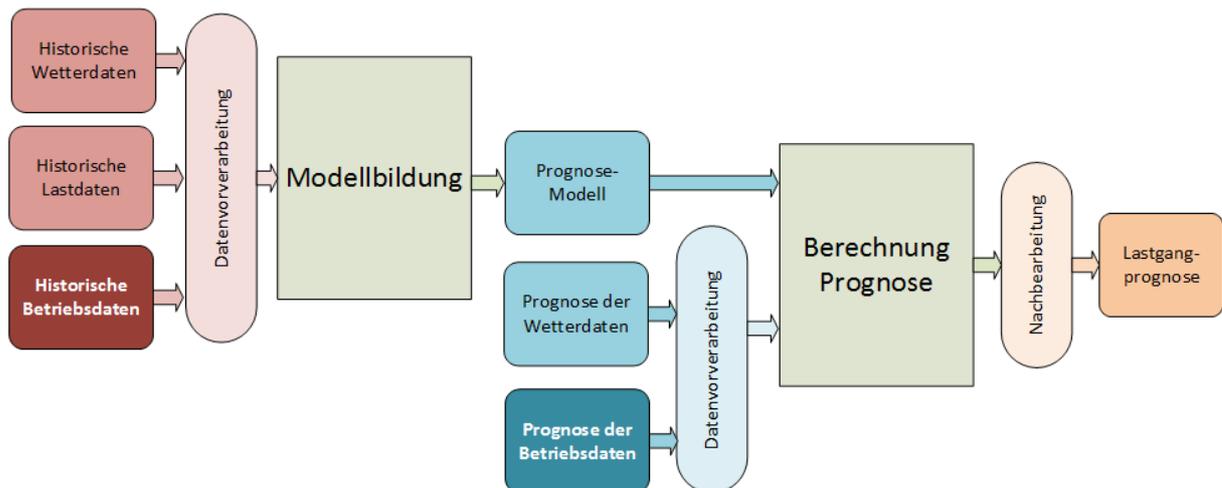


Abbildung 18: Prognoseprozessschritte mit Integration von Betriebsdaten

Wie in Kapitel 4 gezeigt, haben die Betriebsprozesse einen wesentlichen Einfluss auf das Lastverhalten des Terminals, weshalb diese im Prognoseprozess berücksichtigt werden sollen. Entsprechend sind die Betriebsdaten sowohl bei der Modellbildung zu berücksichtigen, als auch bei der eigentlichen Berechnung der Prognose, wie in Abbildung 18 ersichtlich wird.

Für die Konzeptbildung wird in diesem Kapitel zuerst die Vorverarbeitung der vorliegenden Betriebsdaten beschrieben. Diese ist notwendig, um eine Einbindung in den Prognoseprozess zu ermöglichen. Wie diese Einbindung in die verschiedenen Methoden erfolgen kann wird in den anschließenden Kapiteln konzeptuell dargestellt.

5.1 Betriebsdaten eines Containerterminals und deren Vorverarbeitung

Für den operativen Betrieb eines Containerterminals sind sowohl die derzeit an der Kaimauer liegenden Schiffe und die zukünftigen Schiffsankünfte von essentieller Bedeutung. Die Schiffe und deren Reedereien melden regelmäßig an den nächsten anzufahrenden Hafen ihre aktuellsten Ladungs- und nautischen Daten. Dazu gehören u.a. die Abfahrtszeit am Vorhafen, die berechnete Fahrzeit bis zum Zielhafen und aktuelle Ladelisten. Auf Basis dieser Daten führt das Containerterminal im Zielhafen seine operative Planung durch. Dazu gehört, dass dem Containerschiff ein Liegeplatz zugewiesen wird, Containerbrücken für die Entladung dem Schiff zugeordnet werden und auf das Schiff zu ladende Container, welche im Blocklager

schon eingelagert sind, vorsortiert werden, um eine möglichst effiziente Be- und Entladung der Container des Schiffs zu gewährleisten.

HHLA - Hamburg

Ergebnisse: 2424														
Ankunft(soll)	Ankunft	Terminal	Funkcode	Schiffsname	Importreise	Exportreise	Löschbeginn	Löschende	Ladebeginn	Ladeende	Abfahrt(soll)	Abfahrt	Schiffstyp	
07.08.2017 03:00	07.08.2017 02:30	CTA	ECKEL	KAHN ECKELMANN		706551				07.08.2017 02:55	07.08.2017 04:45	07.08.2017 07:00	07.08.2017 04:50	Kahn
07.08.2017 03:00	07.08.2017 03:45	CTA	C4YG2	PANTONIO	706528	706528	07.08.2017 05:00	07.08.2017 08:15	07.08.2017 07:30	07.08.2017 07:35	07.08.2017 10:00	07.08.2017 10:00	Feeder	
07.08.2017 03:00	07.08.2017 03:50	CTB	SBGV2	HANNA							07.08.2017 06:00	07.08.2017 06:00	Seeschiff	
07.08.2017 06:02	07.08.2017 06:00	CTB	ECKEL	KAHN, ECKELMANN	706518		07.08.2017 06:50	07.08.2017 07:50			07.08.2017 07:02	07.08.2017 07:50	Kahn	
07.08.2017 07:00	07.08.2017 06:45	CTA	SBLS2	VLADIMIR	208LVS	211LVN	07.08.2017 07:20	07.08.2017 12:50	07.08.2017 10:45	07.08.2017 13:05	07.08.2017 13:00	07.08.2017 13:15	Feeder	
07.08.2017 07:00	07.08.2017 06:30	CTB	FWQZ	CC FORT ST GEORGES	238EUN	249EUS	07.08.2017 06:50	07.08.2017 16:50	07.08.2017 08:50	07.08.2017 21:15	07.08.2017 22:00	07.08.2017 22:00	Seeschiff	
07.08.2017 07:00	07.08.2017 07:30	CTB	SBVN3	HEINRICH SCHEPERS	706481	706481	07.08.2017 07:45	07.08.2017 13:35	07.08.2017 10:00	07.08.2017 13:05	07.08.2017 14:00	07.08.2017 13:45	Seeschiff	
07.08.2017 07:00	07.08.2017 08:10	CTB	CHARLY	BCF CHARLY	706557	706557	07.08.2017 09:00	07.08.2017 09:05	07.08.2017 08:50	07.08.2017 09:30	07.08.2017 09:30	07.08.2017 09:30	Kahn	
07.08.2017 07:00	07.08.2017 06:50	CTB	A8VD9	CPO BALTIMORE	003N	003S	07.08.2017 06:50	07.08.2017 19:40	07.08.2017 10:20	07.08.2017 21:00	07.08.2017 22:00	07.08.2017 22:00	Seeschiff	
07.08.2017 07:00	07.08.2017 06:30	CTB	SBGV2	HANNA	1730W	1731E	07.08.2017 06:50	07.08.2017 09:25	07.08.2017 09:25	07.08.2017 13:30	07.08.2017 14:00	07.08.2017 13:40	Seeschiff	
07.08.2017 07:00	07.08.2017 07:00	CTB	LAUK	KAHN, LAUK		706543				07.08.2017 07:50	07.08.2017 08:10	07.08.2017 08:30	07.08.2017 08:10	Kahn
07.08.2017 07:00	07.08.2017 07:00	CTB	KDBR	KAHN DBR	706533	706533	07.08.2017 09:50	07.08.2017 11:20	07.08.2017 11:20	07.08.2017 12:30	07.08.2017 12:02	07.08.2017 12:30	Kahn	
07.08.2017 07:00	07.08.2017 05:45	CTT	D5L6	NORDIC LUEBECK	230PVW	239PVN	07.08.2017 07:30	07.08.2017 12:20	07.08.2017 09:05	07.08.2017 13:30	07.08.2017 14:30	07.08.2017 14:30	Feeder	

Eurogate – Hamburg, Bremerhaven, Wilhelmshaven

Datum	Zeit	Abfahrt (Etd)	Schiffsname	Callsign	Liegeplatz	Lö/La	SchiffNr	ReiseNr	Auslieferbeg.	Status	Makler
06.11.2017	01:12	06.11.2017 04:00	BIANCA RAMBOW	DIFT	1 / 2	Löschen	9717	541	06.11.2017 03:31	✓	UNIFEEDER GERMANY
					1 / 2	Laden	9718	541		✓	
	02:51	06.11.2017 14:51	MSC MADRID	A8ZV2	5 / 6	Löschen	9441	NT744A	06.11.2017 12:12	✓	MSC GERMANY
					5 / 6	Laden	9442	NT744A		✓	
	06:40	06.11.2017 10:10	BCF GLUECKAUF	DB2700	1 / 2	Löschen	9681	9681	06.11.2017 08:55	✓	BOERDE CONTAINER FEEDER GBR
					1 / 2	Laden	9682	9682		✓	
	10:45	06.11.2017 14:15	SCHUTE LAUK	LAUK	1 / 2	Löschen	9713	9713	06.11.2017 13:45	✓	WALTER LAUK
					1 / 2	Laden	9714	9714		✓	
	14:59	06.11.2017 19:50	HANSE	DC9353	5 / 6	Löschen	9723	1423591	06.11.2017 18:00	✓	DEUTSCHE BINNENREEDEREI
					5 / 6	Laden	9724	1423521		✓	

Port of Rotterdam

Name	ETA	IMO-Nummer	Liegeplatz	Rufzeichen	Länge	Breite	Tiefgang	Deadweight	Flagge	Baujahr
AWTAD	7-11-2017 16:48	9519717	5E PET TEAM 3	D5LA5	333.13	60 m	22.6 m	317660 t	LBR	2011
CELSIUS	7-11-2017	9408798	CALANDK HBR	V7XD3	147.83	24.2	9.77 m	20866 t	MHL	2008
MEXICO	16:51		P 83 OOST		m	m				
NORTHSEA	7-11-2017	9334301	CHEMIEH	9HWC8	109.1	16 m	6.36 m	6124 t	MLT	2007
LOGIC	16:59		VOPAK 3		m					

Abbildung 19: Beispiele von Segellisten verschiedener Hafengebiete

Zukünftige Schiffsankunfts- und Schiffsaufenthaltsdaten werden in einer sogenannten Segelliste zusammengefasst und für weitere Planungen bereitgestellt. In Teilen werden die Daten im Internet veröffentlicht, um zum Beispiel Speditionen die Möglichkeit zu geben, aktuelle Schiffsankunftsdaten abzurufen. Abbildung 19 zeigt als Beispiele die unterschiedlichen Formate für Segellisten, wie sie von den jeweiligen Hafen- bzw. Terminalbetreibern auf deren Websites veröffentlicht werden⁶. Nicht öffentlich zur Verfügung gestellt wird die zu jedem Eintrag in der Segelliste zugehörige Anzahl von umzuschlagenden Containern, da diese einen Rückschluss auf die Auslastung und die Produktivität des jeweiligen Terminals schließen lässt. Diese Daten liegen im Terminalleitsystem (englisch: Terminal Operation System; kurz: TOS) vor, mindestens in der Auflösung in zu löschende und zu ladende Container pro Schiff vor. Weitere Details wie Anzahl der Kühl-, Leer- oder Sondercontainer können in diesem System ebenfalls vorliegen. Für die weitere Arbeit wird davon ausgegangen, dass mindestens die Informationen zu der Anzahl der zu be- und entladenden Container zu jedem Segellisteneintrag vorliegen.

Am Vortag eines Tages haben die Einträge der Segelliste für den Folgetag eine solche Genauigkeit erreicht, dass von zuverlässigen Daten für die Planung ausgegangen werden kann. Die-

⁶ Der Abruf der abgebildeten Auszüge der Segellisten erfolgte am 07.11.2017.

se Angaben können damit auch für eine Lastgangprognose herangezogen werden. Dafür wird eine einfache Segelliste (SL) definiert, die Datenfelder enthält, welche üblicherweise auch in verschiedenen Formaten von Segellisten enthalten sind und für den Zweck der Lastgangprognose relevant sind:

- Schiffsnummer JSNR
- Schiffstyp
- Geplante Ankunftszeit
- Geplante Abfahrtszeit
- Anzahl der zu löschenden Container
- Anzahl der zu ladenden Container

Abbildung 20 zeigt einen beispielhaften Auszug aus einer solchen einfachen Segelliste inklusive Containerumschlagzahlen.

JSNR	Schiffsname	Schiffstyp	Erwartete Ankunft	Erwartete Abfahrt	Laden	Löschen
345555	ELBE	Feeder	04.09.2013 15:45	05.09.2013 04:30	333	244
345672	SHANGHAI	Seeschiff	05.09.2013 00:30	05.09.2013 16:35	1400	16
345565	MARINE	Feeder	05.09.2013 08:00	06.09.2013 07:00	439	555
345567	KAHN LAUK	Kahn	05.09.2013 15:55	05.09.2013 16:30	0	5
345668	NORDERNEY	Feeder	06.09.2013 07:45	07.09.2013 00:55	404	333
345669	JAPAN	Seeschiff	06.09.2013 17:55	09.09.2013 14:00	2524	3031
345698	STOCKHOLM	Feeder	06.09.2013 15:15	06.09.2013 19:45	22	72

Abbildung 20: Auszug aus einer einfachen Segelliste mit Beispieldaten

Die JSNR (kurz für Jahresschiffsnummer) identifiziert eine Schiffsankunft eindeutig. Eine Schiffskennung wäre hier nicht ausreichend, da ein Schiff regelmäßig innerhalb eines Jahres im Hafen festmachen kann. Der Schiffsname ist in der Liste eher informativ genannt. Bei den Schiffstypen wird im Wesentlichen zwischen drei verschiedenen Kategorien unterschieden:

- Kahn
- Feeder
- Seeschiff

Während Kähne für den Zubringerverkehr zwischen den einzelnen Terminals des Hafens verantwortlich sind, übernehmen Feederschiffe die küstennahe Verteilung von an- oder abzuliefernden Containern auch über größere Entfernungen. So übernehmen zum Beispiel im Hamburger Hafen Feederschiffe unter anderem den wichtigen Weitertransport der Container zu osteuropäischen Häfen, deren Ansteuerung für ein großes Containerschiff nicht lohnend wäre. Unter der Kategorie Seeschiff sind die hochseetauglichen Schiffe zusammengefasst, zu denen auch die großen Containerschiffe für den Asien- oder Amerikaverkehr gehören. Einige der

Containerschiffe befahren dabei feste Routen im sogenannten Linienverkehr. Ist ein Schiff einer entsprechenden Linie zugeordnet, so ist in der Segelliste anstatt der Schiffskategorie die entsprechende Linie benannt. Es kann dabei davon ausgegangen werden, dass nur Seeschiffe einer Linie zugeordnet werden können. Die geplanten Ankunfts- und Abfahrtszeiten spiegeln die zum Zeitpunkt der Erstellung der Segelliste aktuellsten Informationen zu den voraussichtlichen Liegezeiten der einzelnen Schiffe wieder.

Definition 1: Einfache Segelliste

Wesentliche Betriebsdaten eines Containerterminals gehen aus den Liegezeiten eines Schiffes am Kai hervor. Ein Schiffsaufenthalt sa_i kann durch folgende Daten beschrieben werden:

- Jahresschiffsnummer (JSNR): SA_{JSNR} (Datentyp: Integer)
- Schiffstyp: SA_{TYPE} (Datentyp: String)
- Ankunftszeit: SA_{AR} (Datentyp: DateTime)
- Abfahrtszeit: SA_{DEP} (Datentyp: DateTime)
- Anzahl der zu löschenden Container: SA_{IMPT} (Datentyp: Integer)
- Anzahl der zu ladenden Container: SA_{EXPT} (Datentyp: Integer)

Der Vektor dieser Daten $sa_i = \{SA_{JSNR}, SA_{TYPE}, SA_{AR}, SA_{DEP}, SA_{IMPT}, SA_{EXPT}\}$ bildet somit alle Daten zu genau einem Schiffsaufenthalt i ab. Diese Daten werden vor dem eigentlichen Schiffsaufenthalt an das Terminal übermittelt.

Eine Segelliste $SL(d)$ enthält alle Daten zu Schiffsaufenthalten, bei denen die Abfahrtszeit an Tag d oder einen der folgenden Tage $d+x$ liegt und die Daten an d bekannt sind.

$$SL(d) = \{sa_1, \dots, sa_n\} \text{ mit } sa_i(SA_{DEP}) \geq d$$

Diese Daten sind aber Schwankungen unterworfen. Verpasst zum Beispiel ein großes Containerschiff auf den Weg zum Hamburger Hafen aufgrund von Wettereinflüssen eine Einfahrt bei Hochwasser, so muss dieses Schiff vor der Elbmündung bis zum nächsten Hochwasser warten, da ansonsten die Wassertiefe der Elbe nicht für eine Einfahrt in den Hafen ausreichend sein könnte. Zudem ist die Ankunfts- und Endzeit nicht in jedem Fall gleichzusetzen mit der Anfangs- und Endzeit der Tätigkeiten am Schiff zur Be- und Entladung von Containern. So werden im Allgemeinen nach Anlegen des Schiffs erst einmal Tätigkeiten wie das Vertäuen des Schiffes und ggf. kurzfristige Wartungsarbeiten durchgeführt, bevor mit der Entladung begonnen werden kann. Auch hier können meteorologische Einflüsse den Start der Arbeiten verzögern. Ein Beispiel hierfür ist die Bildung von Eis- und Schneeschichten auf der obersten Containerreihe aufgrund entsprechender Witterung. Die Eis- und Schneeschicht muss erst entfernt werden, bevor mit den Be- und Entladeprozessen begonnen werden kann. Ebenso wie bei der Einfahrt in den Hafen kann es nach Beendigung der Be- und Entladetätigkeiten noch

zu einer Verzögerung der Abfahrt eines Schiffes kommen, sollte gerade Niedrigwasser herrschen und auf das nächste Hochwasser gewartet werden müssen.

Die Anzahl der zu ladenden und zu löschenden Container steht dagegen auch am Tag vor der eigentlichen Ankunft des entsprechenden Schiffes schon relativ stabil fest. Hier können Verzögerungen bei der Anlieferung der zu ladenden Container eine Rolle spielen, aber üblicherweise werden die zu ladenden Container eines Schiffes bereits vor der Ankunft des Schiffes im Hafen angeliefert und in die Blocklager eingelagert. Über Ladepläne ist sogar bekannt, welche Arten von Container vom Schiff ent- bzw. auf das Schiff geladen werden müssen: 20-Fuss-, 40-Fuss-, Übergroßen-, Leer- oder Kühlcontainer werden hier unterschieden. In den meisten Fällen liegt in der Segelliste nur der aggregierte Wert vor. Die Informationen der Segellisten können aus dem Terminalleitsystem exportiert und weiteren Systemen für die Verarbeitung bereitgestellt werden.

Die Segellisten umfassen sowohl die zum Zeitpunkt der Erstellung im Hafen liegenden Schiffe als auch die Schiffsaufenthalte im Vorausblick über mehrere Tage. Bei einzelnen Einträgen kann es vorkommen, dass das Datum des Ankunftsstages und das Datum des Abfahrtsstages nicht übereinstimmen. Das ist immer der Fall, wenn ein Schiffsaufenthalt die Tagesgrenze überschreitet. Für eine spätere Nutzung der Segellistendaten für die Prognose des Lastganges für den folgenden Tag, werden die Daten der Segelliste tagesscharf abgegrenzt benötigt. Tagesscharf meint in diesem Zusammenhang, dass die Daten exakt einem Zeitraum zwischen dem Beginn des Tages um 00:00 Uhr und dem Ende um 23:59 Uhr zugeordnet sind. Um die Segellisten dahingehend korrekt abbilden zu können bzw. einzelne Segellisteneinträge exakt einem Tag zuordnen zu können, müssen die Einträge in der Segelliste, die über Tagesgrenzen hinweg gehen, entsprechend vorverarbeitet werden.

Ein solcher Fall liegt in der Abbildung 20 als Beispiel bei dem Eintrag mit der JSNR 345669 vor. Bei der Überprüfung von einzelnen Zeilen der Segellistendaten auf Überschreitung von Tagesgrenzen sind, ausgehend von einem Stichtag, der betrachtet wird, vier Fälle zu unterscheiden:

- *Fall 1:* Das Schiff kommt am Stichtag an und verlässt den Terminal am Stichtag auch wieder (keine Überschreitung der Tagesgrenze).
- *Fall 2:* Das Schiff kommt an einem Tag vor dem Stichtag an und verlässt das Terminal am Stichtag.
- *Fall 3:* Das Schiff kommt am Stichtag an und verlässt das Terminal an einem Tag nach dem Stichtag.
- *Fall 4:* Das Schiff kommt vor dem Stichtag im Terminal an und verlässt das Terminal nach dem Stichtag.

Um diese vier Fälle korrekt abbilden zu können, wird die einfache Segelliste mit den einzelnen Schiffsankünften modifiziert. Schiffsaufenthalte im Terminal, welche über die Tagesgrenze hinausgehen werden so aufgeteilt, dass es keine Aufenthalte über Tagesgrenzen hinweg mehr gibt. Es werden also aus einem Schiffsaufenthalt, der eine Tagesgrenze überschreitet mindestens zwei Segellisteneinträge erstellt. Ein Eintrag der die Schiffsankunft von der An-

kunft bis zur Tagesgrenze und ein weiterer Eintrag, der den Zeitraum von der Tagesgrenze bis zur Abfahrt repräsentiert. Dies kann realisiert werden durch die Einführung von virtuellen Abfahrten („virtual departure“, VD) am Ende des Tages um 23:59 Uhr und einer virtuellen Ankunft („virtual arrival“, VA) desselben Schiffs am Start des nächsten Tages um 00:00 Uhr. Der späteste Eintrag erhält wiederum die geplante Abfahrtszeit des Originaleintrages als Abfahrtszeit zugeordnet.

345669	JAPAN	Seeschiff	06.09.2013 17:55	09.09.2013 14:00	3024	3630
345669a	JAPAN	Seeschiff	06.09.2013 17:55	06.09.2013 23:59		
345669b	JAPAN	Seeschiff	07.09.2013 00:00	07.09.2013 23:59		
345669c	JAPAN	Seeschiff	08.09.2013 00:00	08.09.2013 23:59		
345669d	JAPAN	Seeschiff	09.09.2013 00:00	09.09.2013 14:00		

Abbildung 21: Beispiel eines tagesscharf aufgeteilten Segellisteneintrages ohne Containerzahlen

Bei der Erstellung der neuen virtuellen Segellisteneinträge können die Felder für den Schiffsnamen und die Bezeichnung von dem Originaleintrag übernommen werden. Für die Ankunftszeit und die Abfahrtszeit werden die Datumsangaben bei jeder Überschreitung einer Tagesgrenze auf den Tagesbeginn bzw. auf das Tagesende angepasst. Für den Eintrag mit der JSNR 345669 aus Abbildung 20 ergeben sich somit vier neue tagesscharf abgegrenzte Segellisteneinträge wie in Abbildung 21 gezeigt.

Differenzierter müssen allerdings die Spalten für die umzuschlagenden Container betrachtet werden. Für die Be- und Entladungsrate der Container ist die Anzahl der Kaikräne maßgeblich, die dem entsprechenden Schiff zugeordnet wurden. Für die Zuweisung von Containerbrücken zu Schiffen für eine optimale Entladung wurden unter dem Stichwort „quay crane allocation“ und „quay crane scheduling“ unterschiedliche Ansätze entwickelt. Entsprechend nutzen unterschiedliche Containerterminals auch verschiedene Verfahren und ein erfahrener Terminalmitarbeiter prüft in der Regel die Ergebnisse und passt diese gegebenenfalls anschließend noch an. So kann keine allgemeingültige Regel für die Aufteilung der Container generiert werden.

Eine Auswertung von verschiedenen Be- und Entladevorgängen auf Basis von Simulationsdaten eines Containerterminals, welche für diese Arbeit angefertigt wurde, hat ergeben, dass bei der Aufteilung der zu ladenden und der zu entladenen Container zwischen unterschiedlichen Schiffstypen unterschieden werden kann. Bei Kähnen und Feederschiffen sind sowohl die Containerumschlagzahlen, als auch die allgemeinen Aufenthaltsdauern geringer als bei Seeschiffen, die durchaus einige Tage an der Kaimauer liegen können. Aufgrund der Schiffslänge von Seeschiffen ist es prinzipiell möglich mehrere Kaikräne für den Containerumschlag bereit zu stellen. Allerdings kann in den Simulationsdaten beobachtet werden, dass die Umschlagzahlen nach einer Weile absinken. Dies liegt in dem im Simulationsmodell hinterlegten Algorithmus zur Kaikranzuordnung begründet, bei dem einzelne Kräne nach und nach abgezogen

werden, da die Verteilung der Container auf dem Schiff über die gesamte Länge sinkt und zum Teil die Kräne anderen zu löschenden Schiffen zugeordnet werden. Die beobachteten Daten können als eine Annäherung an ein tatsächliches Lade-/Entladeverhalten gesehen werden, da die tatsächlich genutzten Verfahren nicht veröffentlicht werden und sich von Terminal zu Terminal unterscheiden können.

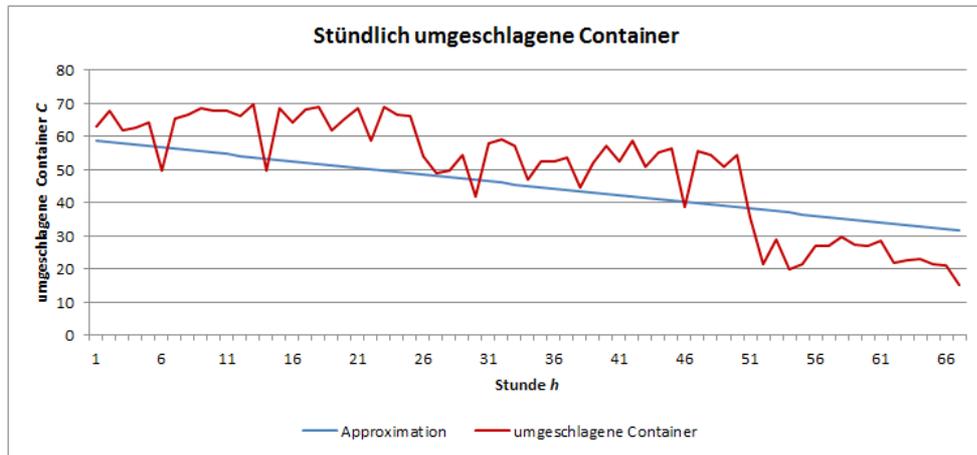


Abbildung 22: Beispiel der Be- und Entladerate eines Schiffes über die Liegedauer

Für Seeschiffe wurde aus den vorliegenden Simulationsdaten folgende Formel abgeleitet, mit der sich die Gesamtanzahl der zu be- und entladenden Container C_{total} für jede Stunde h_i der Liegedauer eines Schiffes ermitteln lässt:

$$C_{h_i} = \left(1,3 - \frac{0,6}{h_n - 1}\right) * \frac{C_{total}}{h_n} \quad \text{mit } h_i = 1, \dots, h_n \quad (25)$$

n entspricht hier der Gesamtanzahl der vollen Stunden der gesamten Liegedauer und h_n bezeichnet entsprechend die n -te volle Stunde der gesamten Liegedauer. Abbildung 22 zeigt, dass die Formel die Be- und Entladerate des Beispiels JSNR 345669 zumindest approximiert. Durch die Zuordnung der einzelnen vollen Stunden zu Tagen der Gesamt Liegedauer und der Addition der entsprechenden Containerzahlen können mit Formel 25 die zu be- und entladenden Container tagesscharf annähernd bestimmt werden.

345669	JAPAN	Seeschiff	06.09.2013 17:55	09.09.2013 14:00	3024	3630
345669a	JAPAN	Seeschiff	06.09.2013 17:55	06.09.2013 23:59	346	415
345669b	JAPAN	Seeschiff	07.09.2013 00:00	07.09.2013 23:59	1236	1484
345669c	JAPAN	Seeschiff	08.09.2013 00:00	08.09.2013 23:59	1000	1200
345669d	JAPAN	Seeschiff	09.09.2013 00:00	09.09.2013 14:00	442	531

Abbildung 23: Beispiel eines tagesscharf aufgeteilten Schiffsaufenthaltes mit Containerzahlen

Es ist zu beachten, dass die gezeigte Formel nur ein Beispiel ist und keine Allgemeingültigkeit besitzt. Es hat hier für einzelne Terminals jeweils eine Herleitung anhand der tatsächlichen

Lade- und Entladeraten zu erfolgen. Abbildung 23 zeigt das Ergebnis des aufgeteilten Beispiels inklusive der auf die Tage des Aufenthalts abgegrenzten Containerumschlagzahlen des Schiffes mit Hilfe der oben beschriebenen Formel.

Für Kähne und Feederschiffe, mit ihren deutlich kürzeren Aufenthaltszeiten, der geringeren Anzahl von umzuschlagenden Containern pro Schiff und ihrer geringeren Länge, die bedingt, dass nur wenige Kaikräne für den Umschlag zugeordnet werden können, kann die Aufteilung einfacher erfolgen. Die jeweils umzuschlagenden Container werden entsprechend des Verhältnisses des Aufenthaltszeitraums innerhalb eines Tages zu der Gesamtaufenthaltszeit aufgeteilt. Dazu werden für die virtuellen Aufenthalte die Tagesanfangszeiten (VA_{SOD}) und Tagesendzeiten (VD_{EOD}) genutzt, sowie die original geplanten Ankunfts- (SA_{AR}) und Abfahrtszeiten (SA_{DEP}). Entsprechend der am Anfang dieses Kapitels vorgestellten Fallunterscheidung erfolgt die Berechnung wie folgt:

- *Fall 1:* Keine Aufteilung notwendig, $ContainerRate = 1$
- *Fall 2:* $ContainerRate = (SA_{DEP} - VA_{SOD}) / (SA_{DEP} - SA_{AR})$
- *Fall 3:* $ContainerRate = (VD_{EOD} - SA_{AR}) / (SA_{DEP} - SA_{AR})$
- *Fall 4:* $ContainerRate = (VD_{EOD} - VA_{SOD}) / (SA_{DEP} - SA_{AR})$

Sowohl die ursprüngliche Zahl der zu entladenden als auch der zu beladenden Container wird mit der *ContainerRate* multipliziert um den Anteil der Container an dem jeweiligen Tag für den entsprechenden Segellisteneintrag zu erhalten. Mit den so aufgeteilten Segellisteneinträgen ist es möglich jeden Eintrag genau einem Tag zuzuordnen und so alle Einträge eines Tages zu einer Tagessegelliste zusammen zu fassen. Diese Tagessegelliste enthält die Betriebsdaten in der Form, wie sie für die Lastgangprognose des entsprechenden Tages für bestimmte Verfahren benötigt wird.

Definition 2: Tägliche Segelliste

Die tägliche Segelliste $tSL(d)$ enthält alle tagesscharf abgegrenzten Schiffsankunftsdaten für den Tag d . Tagesscharf in diesem Sinne bedeutet, dass sowohl die Ankunftszeit als auch die Abfahrtszeit innerhalb eines Tages liegen. Bei längeren Schiffsaufhalten wurden alle Schiffsaufenthaltsdaten entsprechend abgegrenzt.

$$tSL(d) = \{sa_1, \dots, sa_n\} \text{ mit } sa_i(SA_{AR}) \geq d \wedge sa_i(SA_{DEP}) \leq d$$

Das Vorgehen zur Abgrenzung der einzelnen Einträge einer Segelliste, wie in Kapitel 5.1 beschrieben, kann so ausgebaut werden, dass die Containerumschläge eines Tages über die Zeit analog eines Lastgangs aufgeteilt werden. Dazu werden alle Einträge einer täglichen Segelliste genutzt. Die Containerumschlagzahlen (zu löschende und zu ladende Container) werden dafür auf die Aufenthaltsdauer aufgeteilt. Bei Kähnen und Feedern erfolgt diese Aufteilung gleichmäßig über die Anzahl der Stunden des Aufenthalts. Bei Seeschiffen kann auch eine detaillierte Aufteilung erfolgen, wie sie zum Beispiel in Formel 25 vorgeschlagen wird. So kann für jeden Eintrag der Segelliste ein Vektor mit Containerumschlagzahlen pro Stunde des Auf-

enthaltszeitraums erstellt werden. Dieser Vektor soll im Folgenden als Containerumschlagprofil bezeichnet werden. Nach Aufteilung aller Einträge können die jeweiligen Containerumschläge je Stunde addiert werden, um ein entsprechendes Containerumschlagprofil $Cup(d)$ eines Tages zu erstellen.

Definition 3: Containerumschlagprofil eines Tages

Das Containerumschlagprofil eines Tages enthält alle stundenscharf abgegrenzten Containerumschläge für den Tag d , aggregiert über alle in der jeweiligen Stunde relevanten Schiffsaufenthalte. Die Containerumschläge umfassen sowohl die zu löschenden als auch die zu ladenden Container der Schiffsaufenthalte des entsprechenden Tages.

$$Cup(d) = \{Cu_1, \dots, Cu_{24}\} \text{ mit } Cu_n = \sum_{SA_1}^{SA_n} SA_{IMPT_n} + SA_{EXPT_n}$$

SA_{IMPT_n} und SA_{EXPT_n} beschreiben dabei die jeweils stündlich abgegrenzten Containerzahlen eines Schiffsaufenthalts der Segelliste, der für die jeweilige Stunde relevant ist.

Abbildung 24 zeigt beispielhaft ein solches Containerumschlagprofil. Gut zu erkennen ist der deutlich Containerumschlag am Ende des Tages. Dies kann so interpretiert werden, dass im Laufe des Tages ein großes Seeschiff zwischen 16:00 Uhr und 18:00 Uhr den Hafen verlassen hat. Das Löschen und Beladen dieses Seeschiffs machte einen Großteil des Gesamtcontainerumschlags des entsprechenden Tages aus. Eine genauere zeitliche Auflösung der Daten ist nur dann sinnvoll, wenn genaue Informationen über das Umschlagverhalten des Terminals vorliegen. Sollte dies nicht der Fall sein und ist gewünscht, mit dem Containerprofil einen in der Auflösung äquivalenten Bezug zu den viertelstündlichen Werten des elektrischen Lastgangs herzustellen, so kann der stündliche Wert durch 4 geteilt werden. So entsteht ein Containerumschlagprofil mit 96 Werten, welches in der Auflösung auch dem Lastgang mit 96 Werten entspricht.

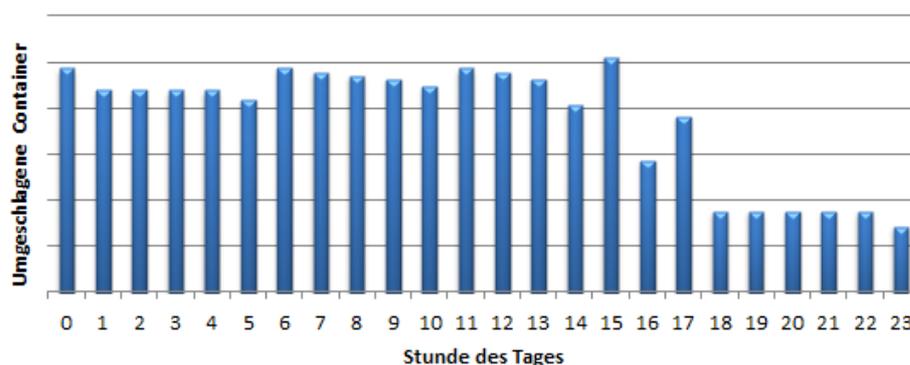


Abbildung 24: Beispiel eines Containerumschlagprofils für einen Tag

5.2 Vergleichstagverfahren

Das Vergleichstagverfahren (kurz: VTV) ist eines der am einfachsten umzusetzenden Prognoseverfahren und daher entsprechend verbreitet in der praktischen Anwendung. Durch den Rückgriff auf Vortages- oder Vorwochendaten wird eine Prognose generiert, ohne weitere Faktoren oder Betriebsdaten zu berücksichtigen. Eine Nutzung von Vorjahreswerten ist ebenfalls denkbar. Es ist zudem möglich, mehrere Tage der Vergangenheit zu nutzen und diese entsprechend zu gewichten (vgl. Kapitel 2.3.1). Üblicherweise werden hierfür bis zu vier Tage der Vergangenheit ausgewählt. Tabelle 6 stellt vier mögliche Varianten des Vergleichstagverfahrens vor. Aufgrund der Übersichtlichkeit soll sich in der weiteren Betrachtung auf diese vier Varianten beschränkt werden.

Name	Referenz	Anzahl Referenztage	Gewichtung der Referenztage
VTV Vortag	Vortag	1	-
VTV Vorwoche	Vorwoche	1	-
VTV 4 Vortage	Vortag	4	Geometrische Reihe
VTV 4 Vorwochentage	Vorwoche	4	Geometrische Reihe

Tabelle 6: Verschiedene Varianten des Vergleichstagverfahrens

Die einfachste Version ist die Nutzung des letzten vollständig vorliegenden Lastgangs vom Vortag als Prognose für den Folgetag. Ist der Tag der Erstellung der Prognose (Tag D) ein Dienstag, so wird der Lastgang von Montag (Tag D-1) für Mittwoch (Tag D+1) genutzt, da der Lastgang für Tag D zum Zeitpunkt der Erstellung der Prognose noch nicht vollständig vorliegt. Bei der Nutzung des Vorwochentages als Referenztag wird der Lastgang des gleichen Wochentags der Vorwoche als Referenztag genutzt. Wird die Prognose also wieder an einem Dienstag (Tag D) für Mittwoch (Tag D+1) erstellt, so wird der Mittwoch der Vorwoche (Tag D-6) genutzt.

Werden mehrere Tage als Referenztage genutzt, wie in den VTV4-Varianten, so werden üblicherweise die weiter zurück liegenden Tage weniger stark gewichtet, als die Tage, welche näher am Prognosedatum liegen. Hier können auch wieder unterschiedliche Methoden der Gewichtung angewandt werden. Für die Lastgangprognose für Containerterminals soll hier der Ansatz der geometrischen Reihe angewendet werden, der auch im Bereich der Gasversorgung häufig angewendet wird [BVG11]. Die Gewichtung erfolgt nach folgendem Schema:

$$\hat{y}_t = \frac{1 * y_{t-d_1} + 0,5 * y_{t-d_2} + 0,25 * y_{t-d_3} + 0,125 * y_{t-d_4}}{1 + 0,5 + 0,25 + 0,125} \quad (26)$$

Dadurch wird gewährleistet, dass vor kurzem eingetretene Einflüsse auf den Lastgang stärker gewichtet werden, als weiter zurück liegende Einflüsse, deren Auswirkungen inzwischen eventuell schon wieder abgeflaut sind.

Eine besondere Behandlung erfährt die Prognose von Lastgängen für Feiertage sowie die Tage vor und nach einem Feiertag. Hier sollte sinnvollerweise auf die entsprechenden Vorjahres-

werte des Feiertages und des Vor- bzw. Folgetags zurückgegriffen werden. Dies ist auch bei terminlich flexiblen Feiertagen (z. B. Ostern) sinnvoll und möglich, da das Datum des Termins von Jahr zu Jahr in einen ähnlichen Zeitraum fällt, sich nur geringfügig verschiebt und das Datum herleitbar ist.

5.2.1 Zusammenfassung: Nutzung als Prognoseverfahren für den Lastgang eines Containerterminals

Durch die Einfachheit des Verfahrens kann eine geeignete Variante des Verfahrens durch einfaches Testen auf Basis von Vergangenheitsdaten für jede Implementierung in einem Containerterminal einzeln ermittelt werden. So ist sichergestellt, dass Besonderheiten des Terminals im Lastverlauf berücksichtigt werden, soweit dies mit diesem Verfahren möglich ist. Bei besonders großen, regelmäßig beobachtbaren Unterschieden, z.B. zwischen Wochentagslastgang und Lastgangverlauf am Wochenende, kann es zudem sinnvoll sein, verschiedene Instanzen des Verfahrens zu nutzen (z.B. eine Instanz für Wochentage und eine für Tage des Wochenendes). Weitere Eigenschaften eines Containerterminals und dessen Betriebsprozessen werden in diesem einfachen Verfahren nicht berücksichtigt.

5.3 Fallbasierte Lastgangprognose

Im Rahmen dieser Arbeit wird ein fallbasiertes System zur Lastgangprognose eines Containerterminals konzeptioniert und entwickelt. Dieses wird im Folgenden auch als Fallbasierte Lastgangprognose referenziert. Dazu wird zuerst ein Konzept für ein solches System ausführlich beschrieben. Den wichtigsten Teil des Konzeptes macht dabei die Datenmodellierung und Bestimmung der Ähnlichkeitsmaße aus. Diese werden ausführlich beschrieben. Im Sinne des FBS-Zyklusses (vgl. Kapitel 2.4) werden die basierend auf dem Daten- und Ähnlichkeitsmodell gefundenen ähnlichsten Fälle auf die aktuelle Situation angepasst. Strategien dazu werden ebenfalls vorgestellt.

5.3.1 Modellbildung

Die Modellbildung ist beim Fallbasierten Schließen einer der aufwändigsten Schritte. Es gilt das Format der Fälle zu bestimmen, passende Ähnlichkeitsmaße zu wählen und Adaptionsregeln und -strategien zu entwerfen. Im Sinne der Wissenscontainer aus Kapitel 2.4 wird hier also das kompilierte Wissen hinterlegt, welches später bei Anfragen an das System genutzt wird, um das Wissen, welches in den eigentlichen Fällen vorhanden ist, zu interpretieren.

5.3.1.1 Fallmodellierung

Erster Schritt in der Modellbildung ist die Definition des Fallformats. Die Idee für die Modellierung zu Zwecken der Lastgangprognose ist es, die tägliche Segelliste für die Problembeschreibung zu nutzen, ergänzt um allgemeine Informationen zu dem entsprechenden Tag und den Lastgang des jeweiligen Tages als Lösung zu nehmen. Ausgehend von der sehr allgemeinen Definition eines Falles als Problem und Lösungsbeschreibung (vgl. Kapitel 2.4) und der Fallmodellierung als Attribut-Wert-Abbildung, kann die Modellierung zum großen Teil dem

vorgegebenen Format der Segelliste folgen. Abbildung 25 zeigt dieses prinzipielle Konzept für die Fallmodellierung.

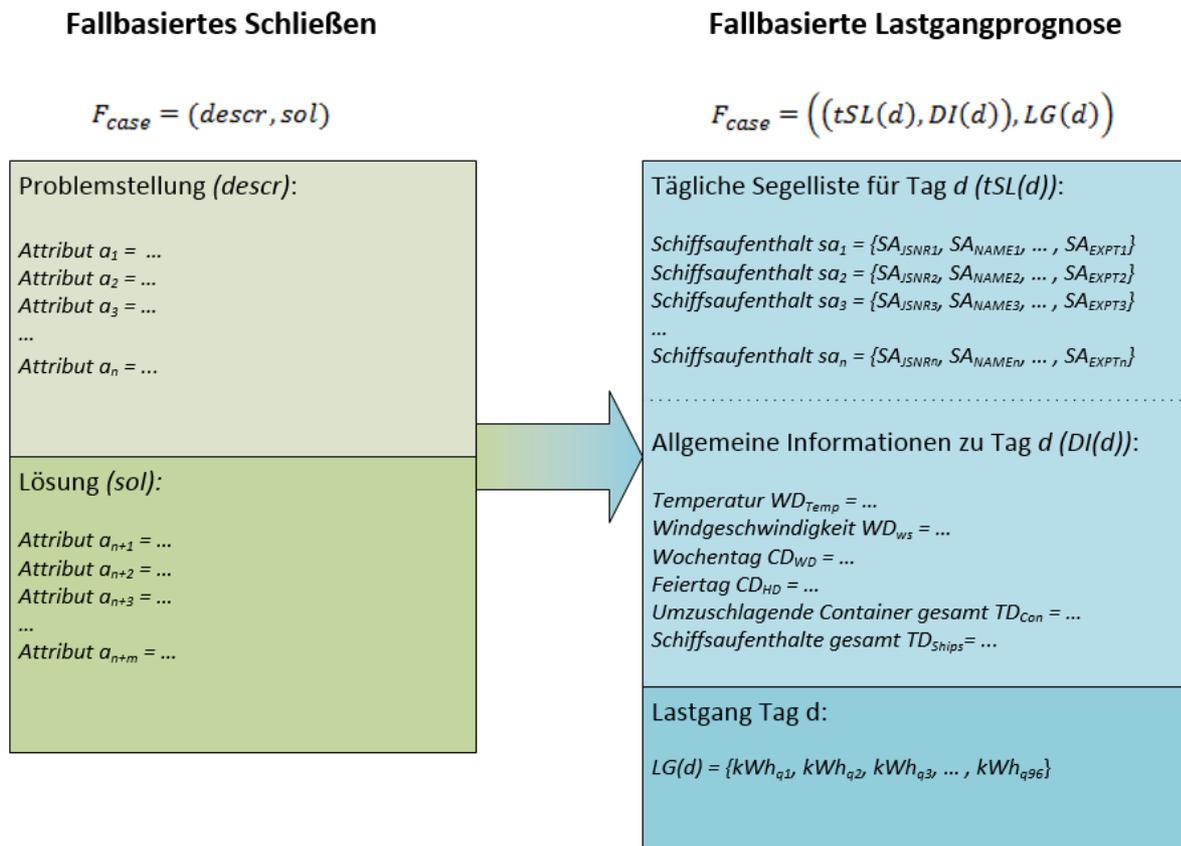


Abbildung 25: Darstellung der Idee des prinzipiellen Aufbaus des Fallformats als Ableitung eines Falls als Problem und Lösung

Der eigentliche Aufbau der Fälle erfolgt zweistufig. In der ersten Stufe werden die Daten der Segellisteneinträge als eigenes Fallformat definiert. Dabei ist jede Zeile der Segelliste ein eigener Fall. In der zweiten Stufe wird ein Fallformat für die Abbildung der täglichen Segelliste und zusätzlicher Informationen den Tag betreffend („Daily Information“, kurz DI) definiert. Dieses Vorgehen hat den Vorteil, dass die Segellistendaten, einmal als Fall definiert und erstellt, dazu genutzt werden können, entsprechende aggregierende Attribute als allgemeine tägliche Informationen ableiten zu können.

Für die Repräsentation eines Segellisteneintrags und den dazugehörigen Informationen wird eine Attribut-Wert-Darstellung genutzt, wie sie in Kapitel 2.4 schon einmal vorgestellt wurde. Ein Attribut ist dabei definiert durch seinen Namen und durch einen dazugehörigen Datentyp. Zusätzlich können für einzelne Datentypen noch gültige Wertebereiche definiert werden. Dies ermöglicht es, Ausreißer, die außerhalb des Wertebereiches liegen, leicht zu erkennen und ggf. gesondert zu behandeln. Zudem können die Wertebereiche bei der Parametrisierung der Ähnlichkeitsmaße hilfreich sein.

Attribut	Entsprechendes Datum der Segelliste	Datentyp	Möglicher Wertebereich
CS_{JSNR}	SA_{JSNR}	Integer	1 bis 999.999
CS_{Name}	SA_{NAME}	String	beliebige Zeichen
CS_{Type}	SA_{TYPE}	Enumeration	festgelegte Werte
CS_{Ar}	SA_{AR}	Datum	nach Anwendungskontext
CS_{Dep}	SA_{DEP}	Datum	nach Anwendungskontext
CS_{Ber}	-	Integer	0 bis 1440
CS_{Imp}	SA_{IMPT}	Integer	0 bis $max(\text{Containerumschläge Import})$
CS_{Exp}	SA_{EXPT}	Integer	0 bis $max(\text{Containerumschläge Export})$

Tabelle 7: Attribute eines Falles zur Repräsentation der einzelnen Segellisteneinträge

Für einzelne Segellisteneinträge werden die Einträge der Segelliste direkt in Attribute des Falls übernommen. Tabelle 7 listet die Attribute mit dem entsprechenden Datentyp und Wertebereich auf, die für die Abbildung der Segellisteneinträge genutzt werden können. Dabei sind die Wertebereiche nur als ein Vorschlag für eine mögliche Ausprägung zu sehen. Der konkrete Wertebereich ist abhängig von den Bedingungen im jeweiligen Containerterminal und den für die Lastgangvorhersage zur Verfügung stehenden Daten.

Die Attribute CS_{JSNR} , CS_{Imp} und CS_{Exp} lassen sich als ganzzahlige Werte (Datentyp Integer) darstellen. Die Attribute CS_{Ar} und CS_{Dep} enthalten sowohl Datums- als auch Zeitinformationen. Als konkretes Format wurde sich hier an der Darstellung von vorliegenden Beispiel-Segellisten orientiert, so wie sie von Containerterminals genutzt werden: Tag, Monat, Jahr und nach einem Leerzeichen die Stunden und Minuten, alle Angaben jeweils zweistellig. Aus der Ankunfts- und der Abfahrtszeit lässt sich die Liegedauer eines Schiffes am Kai einfach herleiten. Da eine Gesamtliegedauer in Hinblick auf eine spätere Ähnlichkeitsbetrachtung von zwei einzelnen Schiffsankünften interessant erscheint, wurde das Attribut CS_{Ber} mit in die Modellierung aufgenommen. Die Liegedauer kann als Differenz zwischen Abfahrts- und Ankunftszeit als ganzzahliger Wert in Minuten bei Erstellung des Falls berechnet werden. So kann vermieden werden, dass diese Berechnung zum Zeitpunkt einer Anfrage erst erfolgen muss. Das Attribut CS_{Ber} stellt insofern eine Besonderheit dar, da es nicht direkt Bestandteil der Segelliste ist, sondern aus den jeweiligen Daten zu Ankunfts- und Abfahrtszeit abgeleitet wird. Das Attribut beschreibt die Gesamtliegedauer am Kai des Terminals und wird als Datentyp Integer mit dem Wertebereich 0 bis 1440 definiert. Es wird in das Fallformat aufgenommen, um neben den Zeitangaben der Ankunft und Abfahrt einen weiteren Indikator für die zeitliche Bewertung des betrachteten Schiffsaufenthaltes zu haben. So kann trotz eventuell verschobener Ankunfts- und Abfahrtszeiten in der Betrachtung von zwei Schiffsankünften eine Ähnlichkeit über eine kaum abweichende Liegedauer noch bestimmt werden. Neben Attributen mit Standarddatentypen wird das Attribut CS_{Type} als Aufzählung aller Schiffstypen modelliert, die für das entsprechende Terminal relevant sind. Eine minimale Einteilung kann zum Beispiel in die drei Typen Kahn, Feeder und Seeschiff erfolgen, wie sie in deutschen Containerterminals üb-

lich ist. Üblicherweise sind aber weitere Schiffstypen in Terminals bekannt. Daher kommt den Typen Kahn, Feeder und Seeschiff eine besondere Rolle zu, da sie eine Verallgemeinerung darstellen und jeweils eine übergeordnete Kategorie zu weiteren spezifizierten Schiffstypen darstellen. Zum Beispiel sind in den Segellisten für Schiffstypen zum Teil auch Namen von Liniendiensten eingetragen, auf denen bestimmte Schiffe regelmäßig verkehren. Diese Information ist ebenfalls für eine spätere Ähnlichkeitsbetrachtung interessant.

Definition 4: Segellisteneintrag als Fall

Ein einzelner Datensatz einer Segelliste mit den Daten JSNR, Schiffsname, Schiffstyp, Ankunftszeit, Abfahrtszeit, Importcontainern und Exportcontainern, wird abgebildet auf einen entsprechenden Attributsvektor $F_{Arrival}$, der einen Fall definiert:

$$F_{Arrival} = \{CS_{JSNR}, CS_{Name}, CS_{Type}, CS_{Ar}, CS_{Dep}, CS_{Ber}, CS_{Imp}, CS_{Exp}\}$$

In einem zweiten Schritt wird ein weiteres Fallformat F_{Day} definiert, welches alle Informationen zu einem Tag (Daily Information, DI) enthält. Dieses verweist auf alle Fälle entsprechend der täglichen Segelliste tSL des betrachteten Tages sowie daraus abgeleitete Informationen, Wetterdaten und kalendarische Informationen.

Zur Darstellung aller Einträge der täglichen Segelliste wird ein Verweis auf die Segellisteneinträge $F_{Arrival}$ in das Fallformat aufgenommen. Das bedeutet, dass der entstehende Fall nur die Werte des eindeutig identifizierenden Attributs CS_{JSNR} der $F_{Arrival}$ -Fälle enthält. Dies hat den Vorteil, dass bei einer späteren Ähnlichkeitsberechnung die Ähnlichkeiten von Segellisteneinträgen einzeln berechnet werden können. Der daraus entstehende aggregierte Ähnlichkeitswert für alle Segellisteneinträge kann dann für einen globalen Ähnlichkeitswert einzeln gewichtet werden.

Aus den einzelnen Segellisteneinträgen können Werte für die Anzahl der Schiffsankünfte und die Gesamtanzahl der umzuschlagenden Container des Tages einfach abgeleitet werden. Die Werte werden von den Attributen TD_{Ships} und TD_{Con} repräsentiert. Diese beiden Attribute werden im Hinblick auf eine Ähnlichkeitsmodellierung genutzt, um ähnliche Tage nicht nur über die Ähnlichkeit der Einzelankünfte untereinander bestimmen zu können, sondern auch durch die aggregierten Werte eines Tages, die eine Verallgemeinerung der Einzelankünfte darstellen. Es wird davon ausgegangen, dass die Gesamtanzahl der umgeschlagenen Container eines Tages den durchschnittlichen Strombedarf je Viertelstunde des Lastgangs beeinflusst, da entsprechende nachgelagerte Prozesse zum Umschlag (z. B. Umlagerung und Auslagerung) auch mit der Anzahl der umzuschlagenden Container zusammenhängen. Damit wird zum Beispiel ein Vergleich von einem Tag mit 1000 umgeschlagenen Containern, verteilt auf 5 Feederschiffe, mit einem Tag mit 1000 umgeschlagenen Containern bezogen auf ein Seeschiff ermöglicht.

Einen entscheidenden Einfluss auf den durchschnittlichen Strombedarf eines Tages haben, neben den Containerumschlagzahlen, die meteorologischen Daten („Weather Data“, kurz: WD) des zu prognostizierten Tages. Diese liegen bei Tagen in der Vergangenheit als gemessene Werte vor. Für Lastprognosen müssen diese als Vorhersage von entsprechenden Wetterdienst-

leisten bezogen werden. Die Untersuchungen des Lastverhaltens in den vorhandenen Bestandsdaten haben ergeben, dass bei ähnlichen Umschlagzahlen an zwei Tagen der Energieverbrauch je Viertelstunde an deutlich kälteren Tagen höher ist als an wärmeren Tagen (vgl. Kapitel 4.1). Zur Repräsentation der Wetterdaten in einem Fall werden Attribute für die tägliche Durchschnittstemperatur WD_{Temp} und die durchschnittliche Windgeschwindigkeit pro Tag WD_{Ws} definiert.

Attribut	Datentyp	Möglicher Wertebereich
WD_{Temp}	Float	-20,0 bis 40,0
WD_{Ws}	Float	0,0 bis 15,0
CD_{Wd}	Enumeration	festgelegte Werte
CD_{Date}	Date	nach Anwendungskontext
TD_{Con}	Integer	0 bis $max(Containerumschlag)$
TD_{Ships}	Integer	0 bis $max(Schiffsabfertigungen\ pro\ Tag)$

Tabelle 8: Attribute für Tagesinformationen zu einem Fall

Aus den Untersuchungen zum Lastverhalten in Kapitel 4 geht auch hervor, dass kalendarische Informationen einen besonderen Einfluss auf das Lastverhalten des Terminals haben. Um kalendarische Daten (Calendar Data, CD) aufzunehmen werden Attribute CD_{Wd} für den Wochentag und CD_{Date} für das Datum des Tages genutzt. Der Wochentag kann automatisch aus dem Datum abgeleitet werden. Es ist aber zu prüfen, ob das Datum einen Feiertag beschreibt, oder ob auf den Tag ein Feiertag folgt bzw. der Tag einem Feiertag folgt. Bei den Feiertagen ist zusätzlich noch zu unterscheiden zwischen Feiertagen, an denen das Terminal seinen Betrieb einstellt und solchen Feiertagen, die zwar Auswirkungen auf das Terminal haben können (z. B. durch ein LKW-Fahrverbot und weniger Anlieferungen von Feederschiffen), der Betrieb des Terminals aber aufrechterhalten bleibt. Erstere werden als Sonntag eingestuft, zweite erhalten einen eigenen Wert in der Aufzählung, ebenso wie die Tage vor und nach einem Feiertag, an dem der Betrieb eingestellt wird.

Definition 5: Tagesablaufinformationen als Fall

Ein Fall mit Tagesablaufinformationen ist eine Menge von Einträgen mit dem Datum des Tages CD_{Date} , zu der Anzahl der Schiffsaufenthalte des Tages TD_{Ships} , der Summe aller zu löschenden und zu ladenden Container des Tages TD_{Con} , der Tagesdurchschnittstemperatur WD_{Temp} , der durchschnittlichen Windstärke des Tages WD_{Ws} und dem Tagestyp CD_{Wd} . Zusätzlich enthält ein entsprechender Fall einen Verweis auf die einzelnen Segellisteneinträge des entsprechenden Tages aus der täglichen Segelliste. Ein Fall mit Tagesablaufinformationen des Containerterminals F_{Day} kann beschrieben werden als:

$$F_{Day} = \{CD_{Date}, CD_{Wd}, TD_{Con}, TD_{Ships}, WD_{Temp}, WD_{Ws}, n * F_{Arrival}\}$$

mit n = Anzahl der Datensätze in der täglichen Segelliste

Das Datum des Tages, den der Fall repräsentiert wird als Zeiger auf den Lastgang mit gespeichert. Die Lastgangdaten werden nicht mit in den Fällen gespeichert, sondern sind in einer Datenbank hinterlegt, aus der sie im Bedarfsfall extrahiert werden können. Durch den hohen Umfang der Lastgangdaten kann dadurch der Speicherbedarf für die Fallbasis gering gehalten werden.

Tabelle 8 listet die einzelnen Attribute mit den tagesgültigen Informationen noch einmal auf. Die möglichen Wertebereiche sind hier nur als Vorschlag zu sehen, sie müssen auf entsprechende Situationen in einem Terminal angepasst werden. Der Wertebereich für den Wochentag umfasst neben eindeutigen Bezeichnern für die sieben Wochentage auch Bezeichner für Feiertage sowie Tage vor und nach Feiertagen.

Der Vorteil des Aufbaus einer vorgeschalteten Fallbasis ist, dass so für die spätere Ähnlichkeitsmodellierung die Möglichkeit geschaffen wird, relativ einfach die Ähnlichkeit zwischen zwei Schiffsankünften bestimmen zu können und so die Ähnlichkeitsmodellierung für diese Klasse zu optimieren. Auf Basis der Fälle der ersten Fallbasis wird eine zweite Fallbasis aufgebaut, die die täglichen Schiffsankünfte, tagesscharf abgegrenzt auf die entsprechenden Tagesdaten und angereichert um die meteorologischen Daten, enthält. Ein Fall in dieser Fallbasis lässt sich eindeutig über das Attribut CD_{Date} identifizieren. Für jeden repräsentierten Tag darf es entsprechend nur einen Fall in der Fallbasis geben, welcher auf die einzelnen Einträge der Segelliste für diesen Tag verweist.

5.3.2 Ähnlichkeitsmodellierung

Ähnlichkeitsmaße und deren Anwendung stellen einen zentralen Teil der Methode des fallbasierten Schließens dar. Die Anwendung kann nach dem lokal-global-Prinzip erfolgen, bei dem jedem Attribut ein eigenes Ähnlichkeitsmaß zugeordnet wird. Die einzelnen Ähnlichkeitsmaße werden über eine sogenannte Aggregationsfunktion zu einem globalen Ähnlichkeitsmaß zusammengeführt (vgl. Kapitel 2.4).

5.3.2.1 Lokale Ähnlichkeitsmaße

Für unterschiedliche Typen von Attributen können entsprechend unterschiedliche lokale Ähnlichkeitsmaße oder unterschiedlich parametrisierte lokale Ähnlichkeitsmaße angewandt werden. Bei der Entwicklung eines fallbasierten Systems zur Lastgangprognose soll jedem für die Ähnlichkeitsberechnung relevanten Attribut ein entsprechendes parametrisiertes Ähnlichkeitsmaß zugewiesen werden.

Wie in Kapitel 5.3.1.1 beschrieben, werden zwei Fallbasen aufgebaut, wobei die Fallbasis mit den einzelnen Schiffsankünften die Grundlage für die Fallbasis mit der tageweisen Betrachtung der Fälle ist, bei denen die abgegrenzten Schiffsankünfte noch um weitere Daten angereichert werden. Tabelle 9 listet die einzelnen Attribute zu den Einträgen in der Segelliste auf und zeigt, welche Attribute für die Ähnlichkeitsbetrachtung relevant sind. Das nicht relevante Attribut CS_{JSNR} dient der eindeutigen Identifizierung eines Schiffsaufenthalts im Terminal und kann zusätzlich genutzt werden, um von verschiedenen virtuellen Schiffsankünften (vgl. Kapitel 5.1) wieder auf den ursprünglichen Eintrag in der Segelliste des Terminals zu schlie-

Ben. Das Attribut CS_{Name} hat weitestgehend informativen Charakter und wird für die Ähnlichkeitsberechnung nicht betrachtet.

Attribute $F_{Arrival}$							
CS_{JSNR}	CS_{Name}	CS_{Type}	CS_{Ar}	CS_{Dep}	CS_{Ber}	CS_{Imp}	CS_{Exp}
nicht relevant	nicht relevant	relevant	relevant	relevant	relevant	relevant	relevant

Tabelle 9: Relevanz der Attribute von $F_{Arrival}$ für die Ähnlichkeitsbetrachtung

Bei den Attributen von F_{Day} , die Kontextdaten für den Tag enthalten, ist das Attribut CD_{Date} dasjenige Attribut, welches nicht in die Ähnlichkeitsberechnung mit einfließt. Es dient lediglich als Zeiger auf die Lastgangdaten des entsprechenden Tages.

Ein großer Teil der definierten Attribute lässt sich auf ganzzahlige Werte zurückführen. Bei einigen muss vorher eine entsprechende Umwandlung erfolgen, dies betrifft die Attribute CS_{Ar} und CS_{Dep} welche beide die Datumsangabe inklusive der Uhrzeit von Ankunft und Abfahrt enthalten. Bei dem Vergleich zweier Schiffsaufenthalte an verschiedenen Tagen ist lediglich die Zeitangabe relevant, um zu bestimmen, ob die Schiffe ähnliche Ankunfts- und Abfahrtszeiten haben. Da jeder Fall tagesscharf abgegrenzt ist, können die Zeitangaben in einen numerischen Wert umgewandelt werden, indem die Zeit als Minuten, die seit dem Start des Tages um 00:00 Uhr vergangen sind, angegeben wird.

Numerische Werte haben bei der Ähnlichkeitsberechnung den Vorteil, dass auf ihnen bereits eine Ordnung definiert ist und so mit einfachen Mitteln eine Distanz zwischen zwei gegenübergestellten Werten ermittelt werden kann. Diese Distanz kann dann die Grundlage für einen Ähnlichkeitswert bilden, indem von dem Grundsatz ausgegangen wird, dass die Ähnlichkeit zwischen zwei Objekten größer ist, je kleiner deren Distanz ist.

Bergmann führt dazu eine Anzahl von verschiedenen Ähnlichkeitsmaßen auf, die den Wertbereich des Maßes im Intervall von 0 bis 1 haben, wobei 1 der höchsten Ähnlichkeit entspricht und 0 der geringsten Ähnlichkeit [Ber02]. Neben formalen Gesichtspunkten werden drei pragmatische Auswahlkriterien für Ähnlichkeitsmaße genannt:

- Das Ähnlichkeitsmaß kann mit einem angemessenen Aufwand modelliert werden.
- Das Ähnlichkeitsmaß ist nicht zu rechenintensiv.
- Das Ähnlichkeitsmaß erlaubt ein Indexieren der Fallbasis, um auch eine große Menge von Fällen effektiv bearbeiten zu können.

Für numerische Attribute werden üblicherweise Funktionen verwendet, die auf der symmetrischen Differenz der lokalen Werte des betrachteten Attributs basieren:

$$sim_{A_i}(q, c) = f(\Delta(q, c)) \quad \text{mit } \Delta(q, c) = |q - c| \quad (27)$$

q und c beschreiben hierbei die Werte des Attributes aus der Anfrage (q) und einem Fall der Fallbasis (c), für die die Ähnlichkeit berechnet werden soll. Weitere Arten der Differenzbildung sind möglich, z. B. die Nutzung des Quotienten aus q und c oder eine Differenzbildung im logarithmischen Bereich, sind aber nur für spezielle Fälle geeignet und werden im

Folgenden nicht weiter betrachtet. Konkret werden vier Basisfunktionen für numerische Attribute genannt, die weit verbreitet angewendet werden. Diese werden in Abbildung 26 dargestellt.

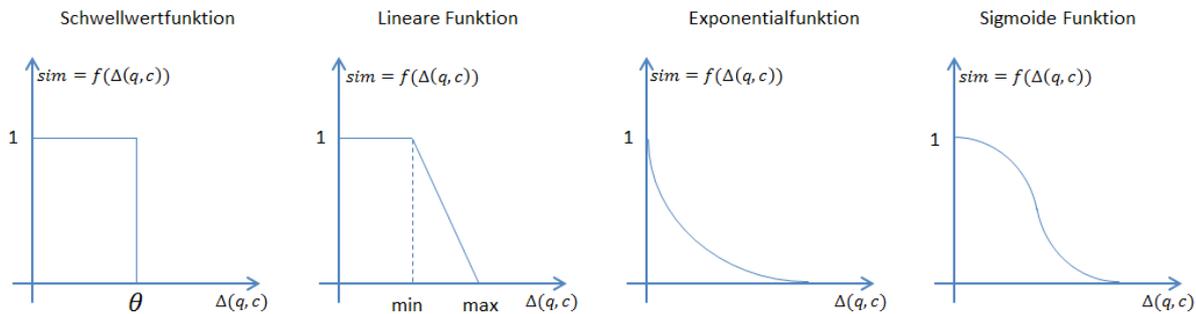


Abbildung 26: Basis-Ähnlichkeitsmaße für numerische Attribute (nach [Ber02])

Die lineare Funktion und die Schwellwertfunktion sind für einfache Ähnlichkeitsberechnungen geeignet. Im Prinzip bildet die Schwellwertfunktion ein binäres Ähnlichkeitsmaß mit den Werten ähnlich/nicht ähnlich, das bei Über- bzw. Unterschreiten eines vorher bestimmten Schwellwerts, bezogen auf $\Delta(q, c)$, den Wert ändert. Bei der Nutzung der linearen Ähnlichkeitsfunktion kann der Ähnlichkeitswert als Kehrwert des Betrages der Differenz der beiden Werte betrachtet werden, wobei auch definiert werden kann, dass bei Überschreiten eines Wertes immer der festgelegte Maximalwert gilt und bei Unterschreiten eines Wertes immer der festgelegte Minimalwert.

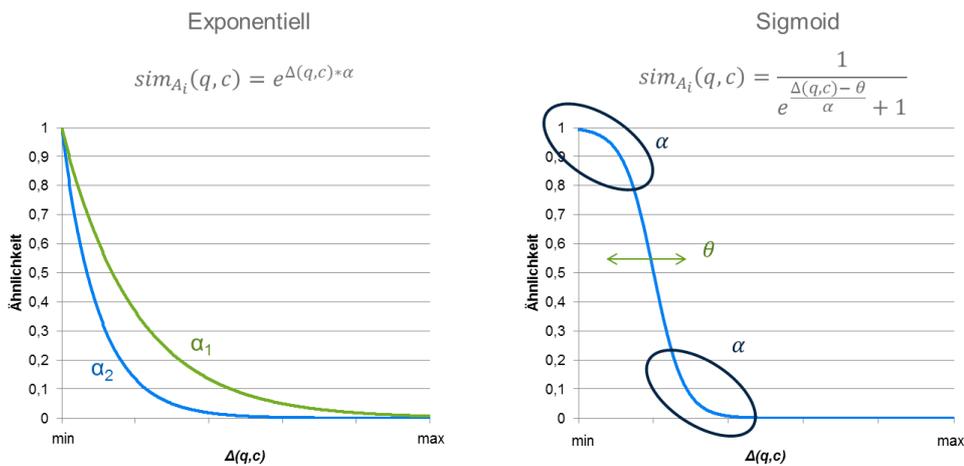


Abbildung 27: Parameter der exponentiellen und sigmoiden Ähnlichkeitsfunktion

Differenziertere Betrachtungen lassen die exponentielle und die sigmoide Funktion zu, die eine weitergehende Interpretation bei der Zuweisung von Ähnlichkeitsmaßen zu Attributen erlauben und deren Parametrisierung entscheidenden Einfluss auf den Verlauf der Ähnlichkeitsbewertung haben, wie beispielhaft in Abbildung 27 gezeigt wird. Ein exponentielles Ähnlichkeitsmaß bedeutet semantisch, dass bereits geringe Unterschiede in den zu vergleichenden Werten zu einem starken Abfall des Ähnlichkeitswertes führen. Über den Parameter α lässt

sich dabei die Steigung der Kurve beeinflussen. Dabei sollten die Werte für α im negativen Bereich gewählt werden, um die gezeigte Form zu erreichen. In Abbildung 27 hat α_1 den doppelten Wert von α_2 . Ähnliche Effekte wie mit dem exponentiellen Ähnlichkeitsmaß können auch mit einem polynomialen Ähnlichkeitsmaß erreicht werden. Bei einem ähnlichen Verlauf der Ähnlichkeitswerte kann auch hier die Steigung über den Parameter α beeinflusst werden.

Definition 6: Exponentielles und polynomiales Ähnlichkeitsmaß

Ein exponentielles Ähnlichkeitsmaß hat die Form

$$\text{sim}(q, c) = e^{\Delta(q, c) * \alpha} \quad (28)$$

Eine ähnliche Abbildung kann durch ein polynomiales Ähnlichkeitsmaß erreicht werden. Dieses ist leichter berechenbar und hat die Form:

$$\text{sim}(q, c) = \left(\frac{\Delta(q, c)}{\max(\Delta(q, c))} + 1 \right)^\alpha \quad (29)$$

Einen Parameter mehr hat die sigmoide Ähnlichkeitsfunktion. Diese bietet sich an, wenn es einen Bereich der Werte gibt, in denen die Ähnlichkeit als hoch eingestuft wird, aber schon etwas abfallend sein soll. Nach diesem Bereich fällt die Ähnlichkeitsfunktion stark ab. Der Parameter θ legt fest, bei welcher Differenz die Ähnlichkeitsfunktion den Wert 0,5 annimmt. Wie auch bei dem exponentiellen Ähnlichkeitsmaß, beeinflusst der Parameter α die Steigung der Funktion.

Definition 7: Sigmoides Ähnlichkeitsmaß

Ein sigmoides Ähnlichkeitsmaß hat die Form

$$\text{sim}(q, c) = \frac{1}{e^{\frac{\Delta(q, c) - \theta}{\alpha}} + 1} \quad (30)$$

Bezogen auf die numerischen Werte der Fallmodellierung lassen sich die beiden vorgestellten Ähnlichkeitswerte gut verwenden.

Für die Ähnlichkeitsberechnung der Containerumschlagzahlen der einzelnen Schiffsdaten der Segelliste (Attribute CS_{Imp} und CS_{Exp}) bietet sich das sigmoide Ähnlichkeitsmaß für die Berechnung der Ähnlichkeit an. Damit können geringe Unterschiede in der Differenz mit einer hohen Ähnlichkeit bewertet werden, ohne einen Unterschied zu vernachlässigen. Allerdings sollte bei dieser Auswahl für unterschiedliche Schiffstypen eine unterschiedliche Parametrisierung vorgenommen werden, da die drei Hauptschiffstypen Kahn, Feeder und Seeschiff sich deutlich in der Anzahl der umzuschlagenden Container pro Schiff unterscheiden. Bei der Betrachtung von zwei Feederschiffen, die üblicherweise bis ungefähr 1000 Container geladen haben, mag eine Differenz von 100 Containern noch zu einer relativ hohen Ähnlichkeit führen, während eine Differenz von 100 Containern bei Kähnen schon einen wesentlichen Unterschied macht, da Kähne üblicherweise überhaupt nur bis zu 100 Container transportieren, im Mittel sogar deutlich weniger. Noch deutlicher wird dies bei der Betrachtung von Seeschiffen,

die bis zu über 10.000 Container pro Aufenthalt in einem Hafen umschlagen. Für die Wahl des Parametersatzes sollte dabei immer der Schiffstyp der Anfrage an das System führend sein, um eine möglichst exakte Berücksichtigung des entsprechenden Anfragekontextes zu ermöglichen.

Für die Gesamtanzahl der Containerumschläge eines Tages (Attribut TD_{Con}) bietet sich entsprechend auch ein sigmoides Ähnlichkeitsmaß an, welches geringe Differenzen zwischen der Anfrage und dem Fall mit einer hohen Ähnlichkeit bewertet, anschließend aber deutlich abfällt. Dasselbe gilt für die Wetterdaten des Tages (Attribute WD_{Temp} und WD_{Ws}) und die Anzahl der Schiffe, die an diesem Tag insgesamt vor Anker liegen (Attribut TD_{Ber}).

Für die Ähnlichkeitsbetrachtung der Datumswerte der beiden Attribute CS_{Ar} und CS_{Dep} ist lediglich die Zeitangabe interessant. Diese kann auf die Anzahl der vergangenen Minuten seit dem Beginn des Tages zurückgeführt werden. Für die Ankunfts- und Abfahrtszeiten stehen sowohl Datums- als auch Zeitangaben zur Verfügung. Für die Ähnlichkeitsbetrachtung werden nur die Zeitangaben betrachtet, da die Ähnlichkeit zwischen verschiedenen Ankunfts- bzw. Abfahrtszeiten von Interesse ist und die kalendarische Zuordnung auf ein bestimmtes Datum darauf keinen Einfluss hat. Um eine Ähnlichkeit für die angegebenen Zeiten zu berechnen wurden die angegebene Stunde und Minute in eine Ganzzahl umgewandelt. Dazu wird der Wert der Stunde mit 60 multipliziert und die entsprechende Minute hinzuaddiert. Mit dem so erstellten Minutenwert kann dann wieder ein Ähnlichkeitsmaß für Ganzzahlen genutzt werden, um den Ähnlichkeitswert zwischen zwei Ankunfts- bzw. zwei Abfahrtszeiten bestimmen zu können.

Hier kann für die Ähnlichkeitsberechnung eine exponentielle Funktion genutzt werden. Diese hat den Vorteil, dass sie so konfiguriert werden kann, dass die Ähnlichkeit zwischen zwei Werten bereits bei geringen Unterschieden deutlich sinkt. Semantisch bedeutet dies, dass Einträge in der täglichen Segelliste nur dann ähnlich sind, wenn sie sowohl eine Ankunftszeit im Zeitraum der Ankunftszeit der Anfrage, als auch eine Abfahrtszeit im Zeitraum der Anfrage haben. Schiffsankünfte, die zum Beispiel mehr als 60 Minuten auseinander liegen, gelten dann, bezogen auf die Zeitpunkte nicht mehr als ähnlich. Da die Zeitpunkte eine hohe Bedeutung bei der Ähnlichkeitsbewertung haben, da von einer Schiffsankunft ein anschließender Anstieg des Energiebedarfs des Terminals ausgehen kann und ebenso mit der Abfahrt bzw. mit der Beendigung des Lösch- und Ladevorgangs eines Schiffes der Energiebedarf abfallen kann, sollten diese Attribute für die Aggregationsfunktion entsprechend gewichtet werden.

Ein exponentielles Ähnlichkeitsmaß kann ebenfalls für die Aufenthaltsdauer eines Schiffes im Terminal (Attribut CS_{Ber}) genutzt werden. Hier ist der Wertebereich von 0 bis 1440 relativ breit, wobei der Wert 60 semantisch schon einer Liegedauer entspricht, die in dem betrachteten Fall eine Stunde kürzer oder länger ist als in der Anfrage und damit bereits eine nicht mehr allzu große Ähnlichkeit darstellt.

Die zwei Attribute CS_{Type} und CS_{Wd} repräsentieren keine numerischen Werte, sondern festgelegte Begriffe. Für das Attribut CS_{Wd} welches die Wochentage inklusive Feiertage repräsentiert, kann, aufgrund der überschaubaren Anzahl von möglichen Werten, die Ähnlichkeit zwischen zwei Werten direkt in einer Tabelle festgelegt werden. Damit können die Beobach-

tungen zu den kalendarischen Einflüssen aus Kapitel 4.2 direkt in feste Ähnlichkeitswerte bei dem Vergleich zweier verschiedener Werte des Attributes übernommen werden. Bei der Bestimmung der Ähnlichkeit wird direkt der in der Tabelle hinterlegte Wert als Ähnlichkeit genutzt.

Definition 8: Ähnlichkeitstabelle (nach [Stahl03])

Sei Attribut A ein Attribut mit definiertem symbolischem Bezeichner als Wertebereich:
 $T(A) = (\text{String}_1, \text{String}_2, \text{String}_3, \dots, \text{String}_n)$.

Eine $n \times n$ -Matrix mit Einträgen $s_{i,j} \in [0,1]$, welche die Ähnlichkeit zwischen dem Bezeichner String_i und dem Bezeichner String_j festlegt, wird Ähnlichkeitstabelle für $T(A)$ genannt.

Die Ähnlichkeitstabelle definiert ein reflexives Ähnlichkeitsmaß, dessen Diagonale für $s_{i,i}$ den Wert 1 definiert. Für symmetrische Ähnlichkeitsmaße gilt $s_{i,j} = s_{j,i}$.

Die Anzahl der Schiffstypen, die durch das Attribut CS_{Type} repräsentiert werden, ist für jedes Terminal unterschiedlich und hängt von dem jeweiligen betrachteten Terminal ab. In einer einfachen, sehr allgemeinen Betrachtung gibt es die Einteilung in die Kategorien Feeder, Seeschiff und Kahn, welche weitverbreitet vorgenommen wird. Es können aber in der Segelliste weitere Typen genannt werden, die eine grobe Zuordnung zu den drei genannten Kategorien ermöglichen. Ein guter Hinweis auf die entsprechende Kategorie ist in allen Fällen die Anzahl der umzuschlagenden Container, die weitestgehend je Schiffskategorie bestimmte Grenzen einhält. Für die Ähnlichkeitsbewertung bietet es sich daher an, eine Taxonomie der möglichen Schiffstypen eines Containerterminals zu erstellen. Eine Taxonomie ist ein ungerichteter Graph, bei dem zwischen Knoten K mit nur einer Kante (Blätter) und inneren Knoten mit mehreren Kanten unterschieden wird. Die Blätter enthalten konkrete Werte, während innere Knoten immer eine Aggregation der darunterliegenden Knoten darstellen. Eine Taxonomie der Schiffstypen kann zum Beispiel vom Terminal vorgegeben werden oder automatisch aus vorhandenen historischen Segellistendaten extrahiert werden, indem wie beschrieben die Containerumschlagzahlen für die Einordnung in die Struktur des zu erstellenden Baumes genutzt werden. Die erstellte Taxonomie repräsentiert so das Wissen über die Zusammenhänge der einzelnen Schiffstypen. Je tiefer in der Struktur der Taxonomie zwei Werte einen gemeinsamen inneren Knoten haben, desto mehr Eigenschaften haben sie gemeinsam. Dieses lässt sich für die Berechnung eines Ähnlichkeitswertes nutzen. Eine häufig genutzte Funktion dazu wurde in [Res95] definiert. Diese basiert auf der Idee, dass der Informationsgehalt eines Attributwerts mit einer negativen Log-Likelihood-Funktion der Form $-\log(p(c))$ beschrieben werden kann, wobei $p(c)$ die Wahrscheinlichkeit beschreibt, mit der der Attributwert c in einem Fall enthalten ist. Dieser Wert basiert auf der Fallbasis, welche als Trainingsdaten hierfür verwandt werden kann. Dabei wird im Prinzip gezählt, wie oft ein bestimmter Attributwert in den Fällen der Fallbasis vorhanden ist. Dabei gilt, dass der Informationsgehalt eines untergeordneten Knotens immer größer ist, als der des übergeordneten Knotens. Der Informationsgehalt des Wurzelknotens wird mit 0 festgelegt. Die Ähnlichkeit zwischen zwei Werten x und y kann dann wie in Definition 9 beschrieben werden.

Definition 9: Ähnlichkeitsmaß für Taxonomien (nach [Res95])

Ein Ähnlichkeitsmaß für Taxonomien hat die Form

$$sim(q, c) = \max [-\log p(a)] \text{ mit } a \in K(q, c) \quad (31)$$

wobei $K(q, c)$ den inneren Knoten beschreibt, der Verbindung zu beiden Werten von q und c hat und am tiefsten in der Baumstruktur angeordnet ist.

Eine alternative Ähnlichkeitsfunktion für symbolische Werte wie die Schiffstypen kann über Darstellung der Schiffstypen als eine geordnete Liste erreicht werden. Für die Ordnung kann zum Beispiel die Schiffslänge, die maximale Containerkapazität oder die Bruttoreaumzahl genutzt werden. Anhand dieser Größen kann mit Hilfe eines Basisähnlichkeitsmaßes wieder eine Ähnlichkeit bestimmt werden.

Attribut	Lokales Ähnlichkeitsmaß	Bemerkung
CS_{Ar}	sigmoid	Minuten als ganzzahlige Werte
CS_{Dep}	sigmoid	Minuten als ganzzahlige Werte
CS_{Ber}	exponentiell	
CS_{Imp}	sigmoid	Unterschiedliche Parametrisierung je Schiffskategorie
CS_{Exp}	sigmoid	Unterschiedliche Parametrisierung je Schiffskategorie
CS_{Type}	Taxonomie	Alternativ: Geordnete Liste
WD_{Temp}	sigmoid	
WD_{Ws}	sigmoid	
CD_{Wd}	Tabelle	Direkte Zuweisung
TD_{Con}	sigmoid	
TD_{Ships}	exponentiell	

Tabelle 10: Konzept für Ähnlichkeitsmaße der einzelnen Attribute

Tabelle 10 listet die verschiedenen lokalen Ähnlichkeitsmaße für die relevanten Attribute noch einmal zusammenfassend auf.

5.3.2.2 Globales Ähnlichkeitsmaß

Die Aggregation der einzelnen lokalen Ähnlichkeitsmaße kann über eine gewichtete Summe erfolgen. Hierbei ist zu beachten, dass bei dem beschriebenen Konzept zwei Aggregationen von lokalen Ähnlichkeitsmaßen erfolgen. Die erste Aggregation erfolgt für die Einträge der täglichen Segelliste. Diese werden als gewichtete Summe aggregiert und fließen als ein Wert in die Aggregation der täglichen Werte ein.

Definition 10: Gewichtetes arithmetisches Mittel als Aggregationsfunktion

Zur Berechnung der globalen Ähnlichkeit kann ein gewichtetes arithmetisches Mittel der lokalen Ähnlichkeiten genutzt werden. Diese wird definiert als:

$$Sim_{\Phi}(F_{query}, F_{case}) = \frac{\sum_{i=1}^n w_i * sim_{A_i}(q, c)}{\sum_{i=1}^n w_i} \quad (32)$$

w_i ist das Attributgewicht für Attribut A_i .

$\vec{w} = (w_1, w_2, \dots, w_n)$ ist der Gewichtsvektor für alle Attribute des Beschreibungsteils eines Falles F_{case} .

Es gilt: $w_i \in [0, 1]$ und $\sum_{i=1}^n w_i = 1$

Für die Festlegung der Gewichtung der einzelnen Attribute wurden im Laufe der Zeit verschiedene Methoden entwickelt. Ein guter Startpunkt ist immer die Festlegung durch einen Experten des jeweiligen Gebietes. Für eine weitere Verfeinerung oder zur automatisierten Festlegung der Gewichtung wurden bereits einige Lernalgorithmen entworfen. Viele davon wurden speziell für Klassifikationsaufgaben im FBS-Umfeld entwickelt. Diese setzen voraus, dass die Richtigkeit einer Lösung einfach bestimmt werden kann. Diese sind für die fallbasierte Lastgangprognose nicht nutzbar, da die Prognose einer Zeitreihe nicht als korrekte oder nicht korrekte Lösung bestimmt werden kann.

Eine vom Einsatzzweck unabhängige Methode, basierend auf der relativen Nützlichkeit einzelner Attribute, hat Stahl in [Stahl03] beschrieben. Er nutzt Methoden des Introspective Reasoning und eines Gradientenabstiegsverfahrens, um aufgrund der Nützlichkeit eines Falles im Vergleich zu einem weiteren Fall die einzelnen Gewichtungen der Attribute eines Falles zu erhöhen oder zu verringern. Dazu wird eine Fehlerfunktion definiert, die über die partielle Ableitung dieser in Richtung des Gefälles verändert wird. Diese Methode kann etwas angepasst auch für die Festlegung der Attributgewichte für die fallbasierte Lastgangprognose genutzt werden. Die Nützlichkeit $u(c, q)$ (englisch: utility) wird dabei definiert als eine reellwertige Zahl, die in einer a-posteriori-Betrachtung nach der Anwendung des Lösungsteils eines Falls auf die Situation der Anfrage gebildet wird. Auf Basis dieser Zahl können die gefundenen Fälle nach ihrer Nützlichkeit geordnet werden. Stahl verweist darauf, dass diese Bewertung in vielen Fällen von einem Domänenexperten manuell durchgeführt werden muss.

Definition 11: MAPE als berechenbare Nützlichkeitsfunktion u

Die Nützlichkeit u eines Falles c in Bezug auf eine Anfrage q kann für die fallbasierte Lastgangprognose durch das Gütemaß MAPE aus Formel (19) approximiert werden. Es gilt:

$$u(q, c_i) = \frac{1}{MAPE(q, c_i)} \quad \text{für alle } c_i \in CB \quad (33)$$

Für die Fallbasierte Lastgangprognose kann eines der Gütemaße zur Bewertung von Lastprognosen (vgl. Kapitel 2.6.1) als Nützlichkeitsfunktion gesetzt werden. Damit kann die Nützlichkeitsbewertung vollständig automatisiert werden, da dieser Wert berechenbar ist. Es bietet sich der mittlere absolute prozentuale Fehler (MAPE) an, da er unabhängig von der Skala funktioniert und absolute Werte nutzt. Dabei muss beachtet werden, dass die Nützlichkeitsbewertung höher ist, je geringer der MAPE-Wert ausfällt. Zur Bestimmung des MAPE-Wertes werden die gemessenen Lastgangwerte benötigt.

Mit dieser Definition der Nützlichkeitsfunktion ist es nun möglich, die Fälle nicht nur nach ihrer Ähnlichkeit zu sortieren, sondern auch nach einem objektiven Maß für die Nützlichkeitsbewertung verglichen werden. Dies macht es möglich, den Algorithmus von Stahl ([Stahl03]) für das Lernen der Gewichtung anzuwenden, an dem sich auch die folgende Herleitung orientiert. Es wird eine Feedback-Funktion fb definiert, die 1 zurückgibt, wenn der Ähnlichkeitswert eines Falles c_1 in Bezug auf eine Anfrage q größer ist als der Ähnlichkeitswert eines Falles c_2 , aber die berechnete Nützlichkeitsbewertung in Bezug auf die Anfrage q von c_2 größer ist als die von c_1 .

Definition 12: Feedback-Funktion

Für eine Anfrage q und zwei Fälle c_1 und c_2 mit $Sim_\phi(q, c_1) > Sim_\phi(q, c_2)$ aus einem entsprechenden Retrieval-Ergebnis $C_k(q, CB)$ wird folgende Funktion fb definiert:

$$fb(q, (c_1, c_2)) := \begin{cases} 1 & \text{wenn } u(q, c_1) < u(q, c_2) \\ 0 & \text{sonst} \end{cases} \quad (34)$$

Mit Hilfe dieser binären Feedback-Funktion ist es möglich eine partiell ableitbare Fehlerfunktion zu definieren, die für das Gradientenabstiegsverfahren genutzt werden kann. Diese basiert, wie auch die Feedback-Funktion selber, auf der paarweisen Betrachtung von zwei Fällen c_1 und c_2 aus einem Retrieval-Ergebnis zu einer Anfrage q . Der Fehlerwert ergibt sich aus der Differenz der globalen Ähnlichkeiten der beiden Fälle.

Durch die Multiplikation mit dem Ergebnis der Feedback-Funktion ergibt sich ein Fehlerwert ungleich Null nur, wenn die Feedback-Funktion den Wert 1 annimmt und damit die Ordnung der Ähnlichkeitswerte eine andere ist, als die Ordnung der Nützlichkeitswerte. Bei der Betrachtung von zwei Fällen aus dem Ergebnis können wir nun wie in Definition 13 dargestellt einen Fehlerwert berechnen, der durch Nutzung der Feedback-Funktion immer dann einen Wert ungleich Null annimmt, wenn der Fall mit der höheren Ähnlichkeit eine geringere Nützlichkeitsbewertung hat, als der Fall mit der geringeren Ähnlichkeit. Als Wert wird im einfachsten Fall die Differenz der beiden globalen Ähnlichkeitswerte genutzt.

Definition 13: Fehlerfunktion für die paarweise Fallbetrachtung

Für eine Anfrage q und zwei Fälle c_1 und c_2 mit $Sim_\phi(q, c_1) > Sim_\phi(q, c_2)$ aus einem entsprechenden Retrieval-Ergebnis $C_k(q, CB)$ wird ein Ähnlichkeitsfehler E_{Sim} für die globale Ähnlichkeit der beiden Fälle definiert:

$$E_{Sim}(q, (c_1, c_2)) = (Sim(q, c_1) - Sim(q, c_2)) * fb(q, (c_1, c_2)) \quad (35)$$

Diese Funktion kann noch weiter faktorisiert werden, sodass eine ableitbare Funktion mit Betrachtung von lokalen Ähnlichkeiten entsteht:

$$E_{Sim}(q, (c_1, c_2)) = \left(\sum_{i=1}^n w_i * (sim_{(A_i)}(q, c_1) - sim_{(A_i)}(q, c_2)) \right) * fb(q, (c_1, c_2)) \quad (36)$$

Aufbauend auf dieser Betrachtung von zwei Fällen des Retrieval-Ergebnisses, kann jetzt auch eine Berechnung eines Gesamtfehlers für das Retrieval-Ergebnis erfolgen. Das Index-Distanz-Gewicht ist ein Maß für die „Unordnung“ des Retrievalergebnisses in Bezug auf die Nützlichkeit. Je weiter innerhalb der Ordnung des Ergebnisses ein Fall mit einer höheren Nützlichkeit von einem Fall entfernt ist, der eine höhere Ähnlichkeit aufweist, desto größer wird dieses Gewicht. Zusätzlich kann dieses Gewicht noch mit dem Faktor α beeinflusst werden. Je größer α gewählt wird, desto größer ist der Einfluss des Abstandes.

Definition 14: Fehlerfunktion für ein Retrieval-Ergebnis

Für eine Anfrage q und ein entsprechendes Retrieval-Ergebnis $C_r(q)$ kann eine Fehlerfunktion E_{Sim}^α wie folgt definiert werden:

$$E_{Sim}^\alpha(q, C_r(q)) = \sum_{g=1}^{r-1} \sum_{h=g+1}^r E_{Sim}(q, (c_g, c_h)) * (h-g)^\alpha \quad (37)$$

$(h-g)^\alpha$ wird als Index-Distanz-Gewicht bezeichnet und kann über den Parameter $\alpha \geq 0$ beeinflusst werden.

Um eine möglichst ideale Gewichtung für das globale Ähnlichkeitsmaß zu bekommen, kann die Fehlerfunktion $E_{Sim}^\alpha(q, C_r(q))$ minimiert werden, idealerweise, bis der Fehler den Wert 0 erreicht. Allerdings hat dies den Nachteil, dass nur eine Anfrage und ein Retrieval-Ergebnis für diese Optimierung betrachtet werden würde und somit eine Überanpassung („Overfitting“) an genau diese Anfrage erfolgen würde. Um die Fehlerfunktion mit einer globaleren Sicht zu optimieren sollte diese Optimierung in Bezug auf eine Menge von Anfragen und deren jeweilige Ergebnisse erfolgen. Diese Menge von Anfragen und entsprechenden Ergebnissen wird Retrieval-Collection genannt.

Definition 15: Retrieval-Collection

Für eine Anzahl von Anfragen $Q_s = \{q_1, \dots, q_s\}$ und entsprechenden Retrieval-Ergebnissen wird $\hat{C}(Q_s)$ eine Retrieval-Collection genannt. Es gilt:

$$\hat{C}(Q_s) = \{(q_1, C_{r_1}(q_1)), \dots, (q_s, C_{r_s}(q_s))\} \quad (38)$$

C_{r_j} entspricht dabei dem Retrieval-Ergebnis zu der Anfrage q_j

Mit Hilfe der Retrieval-Collection kann nun ein Fehlermaß für eine entsprechende Anzahl von Anfragen definiert werden, der durchschnittliche Ähnlichkeitsfehler wie er in Definition 16 dargestellt wird.

Definition 16: Durchschnittlicher Ähnlichkeitsfehler

Ein durchschnittlicher Ähnlichkeitsfehler für eine Retrieval-Collection wird definiert als:

$$\begin{aligned} \hat{E}_{Sim}^\alpha(\hat{C}(Q_s)) &= \frac{1}{s} * \sum_{j=1}^s E_{Sim}^\alpha(q_j, C_{r_j}(q_j)) \\ &= \frac{1}{s} \sum_{j=1}^s \sum_{g=1}^{r_j-1} \sum_{h=g+1}^{r_j} E_{Sim}(q_j, (c_g, c_h)) * (h-g)^\alpha \\ &= \frac{1}{s} \sum_{j=1}^s \sum_{g=1}^{r_j-1} \sum_{h=g+1}^{r_j} \left(\sum_{i=1}^n w_i * (sim_{A_i}(q_j, c_g) - sim_{A_i}(q_j, c_h)) \right) * fb(q_j, (c_g, c_h)) * (h-g)^\alpha \end{aligned} \quad (39)$$

Mit der Minimierung des durchschnittlichen Ähnlichkeitsfehlers ist es möglich, die Gewichtung für das globale Ähnlichkeitsmaß umfassend und automatisiert zu optimieren. Die Anzahl von Anfragen Q_s und die dazugehörigen Retrieval-Ergebnisse in ihrer Gesamtheit können als Trainingsdaten TD für den Optimierungsalgorithmus bezeichnet werden. Für die Optimierung werden folgende Voraussetzungen benötigt:

- ein initiales Ähnlichkeitsmaß Sim mit einem Gewichtsvektor $\vec{w} = (w_1, \dots, w_n)$
- eine Anzahl von definierten Anfragen Q_s
- eine Fallbasis CB
- eine berechenbare Nützlichkeitsfunktion U
- ein definierter Wert $\alpha \geq 0$

Dazu wird noch eine Lernrate λ definiert, die die Schrittweite der Anpassungen der einzelnen Gewichte definiert. Sind die Voraussetzungen erfüllt, kann der Lernalgorithmus von Stahl angewendet werden. Dieser ist in Listing 1 beschrieben.

Im Wesentlichen nimmt der Algorithmus zuerst ein Retrieval mit einem vorhandenen globalen Ähnlichkeitsmaß vor, dieses wird dann über die partielle Ableitung des durchschnittlichen Ähnlichkeitsfehlers über den Gewichtsvektor angepasst und generiert so ein neues globales Ähnlichkeitsmaß. Das Ergebnis des Retrievals mit dem neuen Ähnlichkeitsmaß wird über das Fehlermaß mit dem Ergebnis des Retrievals mit dem ursprünglichen Ähnlichkeitsmaß verglichen. Hat sich das Ergebnis verbessert, so wird das neue Ähnlichkeitsmaß übernommen und

für den nächsten Durchlauf als vorhandenes Ähnlichkeitsmaß gesetzt. Ist keine Verbesserung aufgetreten, so wird die Lernrate halbiert. Das Abbruchkriterium *stop-predicate* kann dabei entweder so definiert werden, dass dieses auf `true` wechselt, wenn die Lernrate einen bestimmten Wert unterschreitet oder nach einer bestimmten Anzahl von Durchläufen keine Veränderungen an dem Gewichtsvektor vorgenommen wurden. Der Gewichtsvektor \vec{w} kann dabei gleichförmig initialisiert sein, also jedes Gewicht den gleichen Wert annehmen, oder bereits von einem Domänenexperten festgelegt worden sein.

Listing 1: Lernalgorithmus nach Stahl [Stahl03]

```

procedure gradient_descent_algorithm( $TD(Q)$ ,  $Sim$ )
  1.   initialize weight-vector  $\vec{w}$ 
  2.   initialize learning rate  $\lambda$ 
  3.   start retrieval for  $Q_s$ , determine  $\hat{C}(Q_s)$ 
  4.   compute average similarity error  $\hat{E}_{Sim}^\alpha(\hat{C}(Q_s))$ 
  5.   stop-predicate = false
  6.   while stop-predicate = false do
      (a)   generate new  $Sim'$ :  $\forall i w_i' := w_i - \frac{\partial \hat{E}_{Sim}^\alpha(\hat{C}(Q_s))}{\partial w_i} * \lambda$ 
      (b)   normalize  $w_i' := \frac{w_i}{\sum_{j=1}^n w_j}$ 
      (c)   start retrieval for  $Q_s$ , determine  $\hat{C}'(Q_s)$ 
      (d)   compute average similarity error  $\hat{E}_{Sim'}^\alpha(\hat{C}'(Q_s))$ 
      (e)   if  $\hat{E}_{Sim'}^\alpha(\hat{C}'(Q_s)) < \hat{E}_{Sim}^\alpha(\hat{C}(Q_s))$ 
           then  $Sim := Sim'$ 
           else  $\lambda = \frac{\lambda}{2}$ 
      (f)   stop-predicate := evaluate_stop-predicate()
  7.   return new similarity measure  $Sim$ 

```

Das Ergebnis ist ein optimierter Gewichtsvektor (in Bezug auf die Trainingsdaten TD) für das globale Ähnlichkeitsmaß.

5.3.3 Adaptionsstrategien

Für die Adaption der Lastgänge ähnlicher Tage können zwei Arten unterschieden werden:

- Adaption auf Basis von allgemeinem Wissen
- Adaption auf Basis von fallbasiertem Wissen

Die Adaption auf der Basis von allgemeinem Wissen basiert auf Wissen über meteorologische und kalendarische Einflüsse, wie sie bei den Untersuchungen des Lastverhaltens eines Containerterminals (vgl. Kapitel 4) festgestellt wurden. Das fallbasierte Wissen basiert dagegen auf

dem direkten Vergleich der Fälle und den darin enthaltenen Betriebsdaten. In beiden Fällen kann die Implementierung regelbasiert erfolgen.

Eine erste einfache Regel für die Adaption auf Basis von allgemeinem Wissen betrifft den Unterschied des Stromverbrauches an Sommertagen und an Wintertagen, wie er in Kapitel 4.2 beschrieben wurde. Für eine mögliche Adaption des Lastgangs des ähnlichsten Falls in Bezug auf die Anfrage werden zwei Kriterien zugrunde gelegt: der Monat als Unterscheidungsmerkmal für Sommer und Winter und der tatsächliche Temperaturunterschied zwischen dem Tag der Anfrage und dem dazu gefundenen ähnlichsten Tag. Eine Sommer-/Winter-Adaption erfolgt nur, wenn der ähnlichste Fall im Sommerzeitraum und der Anfragefall im Winterzeitraum liegen oder vice versa. Der Sommer- bzw. Winterzeitraum wird über die Zuordnung von Monaten festgelegt. Für nicht definierte Zeiträume wie Frühling oder Herbst erfolgt keine Adaption nach dieser Regel. Gleiches gilt, wenn sowohl der Anfragefall als auch der ähnlichste Fall im gleichen Zeitraum liegen. Soll jedoch eine Anpassung erfolgen, so kann der Lastgang der beiden relevanten Tage um einen Faktor erhöht werden. Dieser Faktor kann je nach Höhe der Differenz der Durchschnittstemperaturen der beiden Tage abgestuft werden. Geringere Differenzen führen zu geringeren Anpassungen, während größere Differenzen zu entsprechend weniger Anpassung führen bzw. keine Anpassung durchgeführt wird. In Listing 2 wird dies durch die Funktion *chooseFactor(diff)* realisiert, die in Abhängigkeit von der Höhe der Temperaturdifferenz einen Faktor zurückgibt, der anschließend von dem Lastgang des ähnlichsten Tages subtrahiert oder dazu addiert wird, je nachdem, ob der Anfragefall im Sommer liegt oder im Winter.

Listing 2: Adaptionsregel Sommer-/Winteranpassung

```

procedure summerWinterAdaptation(LG, q, c)
  1.   if  $q_{CD_{Date}} \subset \text{summer} \wedge c_{CD_{Date}} \subset \text{winter}$ 
  2.   then
      (a)   diff := calculateDifference(  $q_{WD_{Temp}}, c_{WD_{Temp}}$  )
      (b)   factor := chooseFactor(diff)
      (c)   LG := subtractFactor(factor, LG)
  3.   else if  $q_{CD_{Date}} \subset \text{winter} \wedge c_{CD_{Date}} \subset \text{summer}$ 
  4.   then
      (a)   diff := calculateDifference(  $q_{WD_{Temp}}, c_{WD_{Temp}}$  )
      (b)   factor := chooseFactor(diff)
      (c)   LG := addFactor(factor, LG)
  5.   return LG

```

Mit dieser Adaptionsregel werden die Werte des Lastgangs angehoben oder gesenkt, der eigentliche Verlauf des Lastgangs aber nicht beeinflusst.

Um den Lastgang bezogen auf viertelstündliche Entwicklungen differenzierter und auch im Verlauf anzupassen, bietet es sich an, die Segellistendaten der beiden Fälle näher zu betrachten, insbesondere die Zahlen zum Containerumschlag, wie in Abbildung 28 beispielhaft dargestellt. Ergeben sich bei der Betrachtung innerhalb einer Stunde bedeutende Unterschiede, so kann es sinnvoll sein, den Verlauf des Lastgangs für diese Stunde entsprechend zu senken

oder zu erhöhen. Von einer höheren zeitlichen Auflösung des Containerumschlags als eine Betrachtung pro Stunde, z. B. eine Betrachtung pro 15-Minuten Intervall, sollte abgesehen werden, da entsprechende Daten nicht vorliegen und bereits die Betrachtung pro Stunde nur mit Näherungswerten erfolgen kann. Bei statistischen Auswertungen dieser stündlichen Unterschiede des Containerumschlags und deren Auswirkungen auf den Lastgang sind folgende Punkte aufgefallen:

- Ein Unterschied zu Beginn und zum Ende des Tages hat einen höheren Einfluss als Unterschiede im Tagesverlauf.
- Bei der Betrachtung der Unterschiede in einzelnen Stunden sind die Unterschiede in der Stunde vor der betrachteten Stunde und nach der betrachteten Stunde ebenfalls zu berücksichtigen.

Der erste Effekt kann darin begründet liegen, dass die erste Stunde des Tages noch sehr abhängig von den letzten Lastgangwerten und ist vom durchschnittlichen Lastniveau des Vortages bzw. das Ende des Tages schon vom Folgetag beeinflusst wird, der bei dem fallbasierten Ansatz nicht berücksichtigt wird. Es findet also eine Anpassung an das Niveau der umliegenden Tage statt, um ggf. stattfindende Nachholprozesse oder vorgezogene Prozesse auszugleichen. Bei dem zweiten Punkt geht es darum, festzustellen, ob einzelne Spitzen in den Unterschieden längerfristige Effekte haben oder ob es sich nur um eine temporäre Spitze handelt, die eventuell auch in der Art und Weise der Berechnung der stündlichen Containerumschläge begründet liegen kann und damit weniger Auswirkungen auf den Lastgang hat. Ist eine deutliche Differenz in den Umschlagzahlen auch in der Stunde vor und nach der aktuell betrachteten Stunde vorhanden, so ist die Wahrscheinlichkeit deutlich höher, dass der Lastgang sich hier entsprechend anders verhalten hat, als bei Differenzen, die nur für eine Stunde relevant sind. Daher muss hier eine erhöhte Anpassung erfolgen.

	Hour 0 00:00 – 00:59	Hour 1 01:00 – 01:59	Hour 2 02:00 – 02:59	Hour 3 03:00 – 03:59	...
query	207	216	295	188	...
case	304	287	304	312	...

Abbildung 28: Vergleich von Zahlen zum stündlichen Containerumschlag

Um die stündliche Betrachtung zu ermöglichen, wird für jeden Eintrag der täglichen Segelliste der Containerumschlag pro Stunde der Liegedauer des entsprechenden Tages bestimmt. Dies kann bei Kähnen und Feederschiffen über eine lineare Aufteilung der zugeordneten Containerumschläge auf die Stunden erfolgen. Für Seeschiffe kann dafür die in Kapitel 5.1 eingeführte Formel (25) für die Aufteilung auf einzelne Stunden genutzt werden. In diesem Fall ist allerdings der gesamte Schiffsaufenthalt der originären Segelliste bei der Betrachtung zu beachten und nicht der bereits tagesscharf abgegrenzte Eintrag der täglichen Segelliste, um die über die Zeit abnehmenden Anzahl von Umschlägen adäquat zu berücksichtigen. Ergebnis der Aufteilung ist jeweils eine Liste mit Gesamtcontainerumschlägen pro Stunde eines Tages, sowohl für die Anfrage q , als auch für den ähnlichsten Fall c . Diese Zahlen können jetzt stun-

denweise betrachtet und die entsprechende Differenz zwischen den beiden Werten gebildet werden. Je nach Höhe der Differenz kann wieder ein Faktor bestimmt werden, der auf die entsprechenden vier Werte des Lastgangs für diese Stunde angewendet wird. Dieser Faktor sollte so gestaltet sein, dass er abhängig ist von der betrachteten Stunde und wenn möglich auch von der Differenz in der vorangegangenen Stunde und der nachfolgenden Stunde. Die Höhe des Faktors hängt dabei von den lokalen Gegebenheiten eines Terminals und dessen Lastverlauf ab und ist individuell auszuwerten. Die Anpassungsfaktoren können mit ihren Bedingungen in einer Liste gespeichert werden, aus der sie dann bestimmt werden. Dabei können auch negative Faktoren genutzt werden, um die Absenkung eines Lastgangs darzustellen. Listing 3 stellt das Vorgehen dazu noch einmal dar. Dabei beschreibt $LG[i]$ die vier viertelstündlichen Werte des Lastgangs in der i -ten Stunde.

Listing 3: Adaptionregel Differenz stündlicher Containerumschlag

```

procedure hourlyDifffenceAdaptation(LG, q, c)
  1.   List hcq := determineHourlyHandlings(q)
  2.   List hcc := determineHourlyHandlings(c)
  3.   for each hour i do
      (a)   diff := determineDifference(hcq[i], hcc[i])
      (b)   if  $i \geq 1 \wedge i \leq 23$ 
      (c)   then
      (d)       diffPh := determineDifference(hcp[i-1], hcc[i-1])
      (e)       diffFh := determineDifference(hcp[i+1], hcc[i+1])
      (f)       factor := chooseFactor(diff, diffPh, diffFh)
      (g)   else
      (h)       factor := chooseFactor(diff)
      (i)   List loadValues = LG[i]
      (j)   for each loadValue x in loadValues do
      (k)       x := x + factor
      (l)   LG[i] := loadValues
  4.   return LG

```

Um mögliche starke Schwankungen oder einmalige Effekte in einem Lastverlauf des ähnlichsten Falles auszugleichen können die Lastverläufe der X ähnlichsten Fälle als Aggregation genutzt werden (Top X-Ansatz). Es kann sowohl der einfache Durchschnitt der X ähnlichsten Fälle genutzt werden, als auch ein gewichtetes arithmetisches Mittel, bei dem der ähnlichste Fall eine höhere Gewichtung erhält als die Fälle mit einer geringeren Ähnlichkeit.

Eine weitere Adaptionregel betrifft kalendarische Einflüsse und besagt lediglich, dass sowohl für Feiertage, als auch für Tage vor und nach Feiertagen die Werte des Lastgangs des Vorjahres für den entsprechenden Feiertag und die umliegenden Tage genutzt werden. Dies liegt darin begründet, dass das Lastgangverhalten insbesondere an den Tagen vor und nach einem Feiertag sehr individuell ist und aufgrund der geringen Anzahl von Feiertagen hier nicht adäquat in der Fallbasis repräsentiert wird, denn die Zeitpunkte der Einstellung bzw. der Wiederaufnahme des Terminalbetriebes variieren ebenso pro Feiertag, wie auch die übrigbleibende Grundlast zwischen Feiertagen im Sommer und Feiertagen im Winter nicht unbedingt vergleichbar ist.

Definition 17: Top X-Adaption

Seien $c_1, c_2, \dots, c_X \in C_k(q, CB)$ mit $Sim_\phi(q, c_1) > Sim_\phi(q, c_2) > \dots > Sim_\phi(q, c_X)$ und $X < k$ die X ähnlichsten Fälle zu einer Anfrage, dann ist das gewichtete arithmetische Mittel der den Fällen zugeordneten Lastgänge das Ergebnis der Top X-Adaption.

$$LG_{TopX} = \frac{\sum_{i=1}^X w_i * c_{i_{LG}}}{\sum_{i=1}^X w_i} \quad (40)$$

Im weiteren Verlauf dieser Arbeit wird diese Adaption auch als *Top X-Ansatz* referenziert.

5.3.4 Revise & Reuse-Phase

Für die Fallbasierte Lastgangprognose stellt jeder Tag einen Fall dar, der eine in der Realität aufgetretene Situation beschreibt. Die Nützlichkeit eines Lastverlaufs eines ähnlichen Tages kann erst nach Ablauf des Tages vollständig bestimmt werden, sobald alle Messwerte dazu vorliegen. Hierzu können die in Kapitel 2.6.1 beschriebenen Gütemaße genutzt werden. Über die Zeit steigende Fehlerwerte können ein Hinweis darauf sein, dass sich Gegebenheiten im Terminal geändert haben und dass eine Anpassung des Modells an die neuen Gegebenheiten erfolgen sollte, um die Prognoseergebnisse zu verbessern.

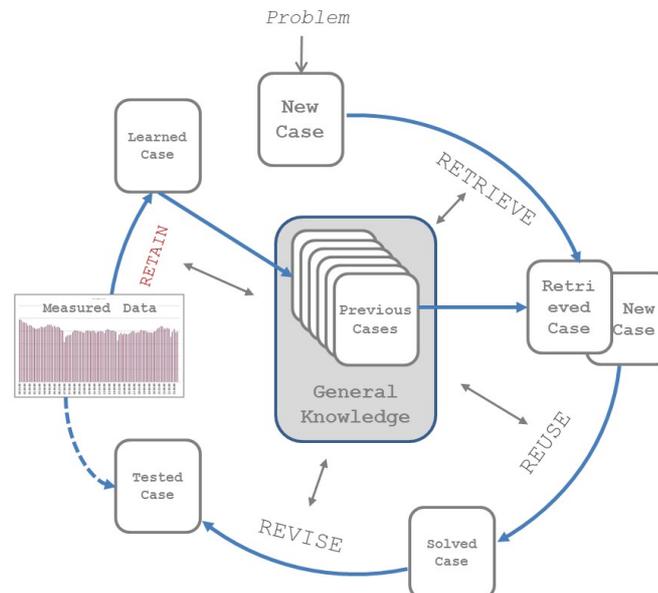


Abbildung 29: Angepasster FBS-Zyklus für die Fallbasierte Lastgangprognose

Aufgrund der extrem hohen Anzahl von möglichen auftretenden Situationen, sei es durch die verschiedenen Zeitpunkte von Schiffsankünften, die unregelmäßigen Anfahrten an ein Terminal oder die einem Schiff jeweils zugeordneten Containerumschläge, ist es äußerst unwahrscheinlich, dass zwei gleiche Problembeschreibungen im Laufe der Zeit auftreten. Gleiches gilt für den Lösungsteil der Fälle. Auch hier ist es äußerst unwahrscheinlich, dass exakt gleiche Lastverläufe auftreten. Daher erscheint es sinnvoll, möglichst jeden neuen Tag auch als

Fall in dem beschriebenen Format in die Fallbasis mit aufzunehmen. Dadurch können jeweils mehr Situationen dargestellt werden und das in die Fallbasis integrierte Wissen steigt stetig an. Ausnahmen hiervon sollten nur gemacht werden, wenn es sich bei dem Tag um eine Besonderheit handelt, z. B. weil eine längerfristige Wartung ansteht oder eine sonstige Störung das Terminal betrifft. Somit ist, wie in Abbildung 29 gezeigt, der FBS-Ablauf nicht mehr vollständig durchgängig, da unabhängig davon, ob der gefundene ähnlichste Fall Grundlage eines guten Prognoseergebnisses war oder nicht, ein neuer Fall mit den gemessenen Lastgangwerten erstellt wird. Dies ist möglich, sobald die gemessenen Daten vorliegen.

5.3.5 Zusammenfassung: Nutzung als Prognoseverfahren für den Lastgang eines Containerterminals

In den vorangegangenen Kapiteln wurde ein Konzept für die Fallbasierte Lastgangprognose vorgestellt. Das Konzept basiert auf Methoden des Fallbasierten Schließens und nutzt daher immer auch Domänenwissen. Dieses wird bei der Spezifizierung des Fallformats, bei der Auswahl und Parametrisierung der Ähnlichkeitsmaße und für die Adaption benötigt. Entsprechend wurde das Konzept schon speziell für die Fallbasierte Lastgangprognose eines Container-Terminals ausgerichtet. Wesentliche Eingabeparameter entstammen der täglichen Segelliste, ergänzt um Kontextinformationen. Teile der Parametrisierung, z. B. der lokalen Ähnlichkeitsmaße, haben für jeden Anwendungsfall individuell zu erfolgen. Für die praktische Nutzung ist aber der Aufbau einer möglichst umfassenden Fallbasis unumgänglich. Je breiter in der Fallbasis mögliche Szenarien über Schiffsaufenthalte eines Tages und den dazugehörigen Lastverläufen hinterlegt sind, desto besser können ähnliche Situationen gefunden werden und anschließend eine erfolgreiche Adaption durchgeführt werden.

5.4 Zeitreihenanalyse

Die Methoden der Zeitreihenanalyse gehören zu den klassischen und weit verbreiteten Prognosemethoden. ARIMA-Modelle werden vielfach erfolgreich angewendet. Größte Herausforderung bei der Anwendung ist dabei die erfolgreiche Modellschätzung. Im Folgenden sollen zuerst einige Begriffe aus der Statistik als Grundlage eingeführt werden, auf denen aufbauend die Box-Jenkins-Methode als eine Vorgehensweise zur Modellentwicklung eingeführt wird. Anschließend wird als Kern des Konzepts ein Algorithmus zur automatisierten Modellschätzung vorgestellt, der für Prognosezwecke umgesetzt wird.

5.4.1 Grundlagen

Im Bereich der Zeitreihenanalyse der Statistik wird eine Zeitreihe als eine Folge von Realisationen eines stochastischen Prozesses Y_t aufgefasst, wobei der Index t einen Zeitpunkt beschreibt. Einige wichtige Begriffe, die für die Prognose mit Funktionen der Zeitreihenanalyse benötigt werden, sollen im Folgenden kurz eingeführt werden (in Anlehnung an [Sch01] und [Vog15]):

- **Lag:** Ein Lag τ beschreibt die Zeitdifferenz zwischen zwei Zeitpunkten t_1 und t_2 :

$$\tau = t_1 - t_2$$

- **Mittelwertfunktion:** Die Mittelwertfunktion ist für jeden Zeitpunkt gleich dem Erwartungswert von Y_t : $\mu(t) = E(Y_t)$. Sie gibt eine durchschnittliche Reihe an, um welche die tatsächlichen Beobachtungen des stochastischen Prozesses schwanken. Üblicherweise wird für den Erwartungswert der Mittelwert der Reihe gebildet ($\hat{\mu} = \bar{y}$).
- **Varianzfunktion:** Die Varianzfunktion gibt für jeden Zeitpunkt an, wie stark die Zufallsvariable Y_t um den Wert der Mittelwertfunktion schwankt:

$$\sigma^2(t) = \text{Var}(Y_t) = E[(Y_t - \mu(t))^2]$$

Über den Mittelwert geschätzt ergibt sich $\hat{y}(0) = \frac{1}{n} \sum_{t=1}^n (y_t - \bar{y})^2$

- **Autokovarianz:** Die Autokovarianz untersucht den Zusammenhang zwischen Realisationen einer Zufallsvariablen zu unterschiedlichen Zeitpunkten:

$$\gamma(t_1, t_2) = \text{Cov}(Y_{t_1}, Y_{t_2}) = E[(Y_{t_1} - \mu_{t_1})(Y_{t_2} - \mu_{t_2})]$$

Über den Mittelwert geschätzt ergibt sich $\hat{y}(\tau) = \frac{1}{n} \sum_{t=1}^{n-\tau} (y_t - \bar{y}_t)(y_{t+\tau} - \bar{y}_t)$

Aus dem Bereich der Zeitreihenanalyse stammen die ARIMA und ARIMAX-Modelle, deren Grundlagen bereits in Kapitel 2.3.2 vorgestellt wurden. Aus den Abweichungen von vorhergehenden Fehlerwerten vom Mittelwert (Moving-Average-Teilprozess) und dem Einfluss der Vorwerte auf den nächsten Wert (Autoregressiver-Teilprozess) wird eine Fortführung der Zeitreihe errechnet. Voraussetzung für die Anwendung von ARMA-Modellen ist die Stationarität der Zeitreihe. Die Stationarität kann durch Differenzierung erreicht werden, bei dem zu jedem Wert die Differenz zum Vorgängerwert gebildet wird ($\Delta Y_t = Y_t - Y_{t-1}$). Die Differenzierung nichtstationärer Zeitreihen erzwingt später die Rückrechnung durch Summierung (Integrated-Teilprozess). Eine Zeitreihe heißt stationär, wenn folgende Bedingungen erfüllt sind:

- Der Erwartungswert ist konstant: $E(Y_t) = \mu \quad \forall t \in \mathbb{Z}$
- Die Varianz ist endlich und zeitunabhängig: $\text{Var}(Y_t) = \sigma^2 \quad \forall t \in \mathbb{Z}$
- Die Autokovarianz hängt nur von dem Abstand der Zeitpunkte ab:

$$\gamma(Y_t, Y_{t+\tau}) = \gamma_\tau$$

Die Stationarität ist auch eine Voraussetzung für die Schätzung über den Mittelwert wie oben angegeben. Für die detaillierte Analyse eines stationären Prozesses wird die Autokorrelationsfunktion (ACF) und die partielle Autokorrelationsfunktion (PACF) genutzt. Die Autokorrelationsfunktion ist ein Maß für die Abhängigkeit von zwei Prozessvariablen, die um ein bestimmtes Lag auseinander liegen. Sie wird berechnet aus der Kovarianz dividiert durch die Varianz. Als Schätzer über den Mittelwert ergibt sich die empirische Autokovarianz aus Formel 41.

$$\hat{\rho}(\tau) = \frac{\hat{y}(\tau)}{\hat{y}(0)} = \frac{\sum_{t=1}^{n-\tau} (y_t - \bar{y})(y_{t+\tau} - \bar{y})}{\sum_{t=1}^n (y_t - \bar{y})^2} \quad (41)$$

Die Funktion nimmt Werte zwischen 1 (stark korreliert) und -1 (gegenläufig) an. Ein Wert um die Null beschreibt eine nicht vorliegende Korrelation. Die partielle Autokorrelationsfunktion beschreibt den Zusammenhang zwischen Y_t und $Y_{t+\tau}$ unter Ausschaltung des linearen Einflusses der dazwischen liegenden Werte. Im Gegensatz zur Autokorrelationsfunktion kann die partielle Autokorrelation nicht durch eine einzelne Gleichung bestimmt werden, sondern kann über den Einsatz von Yule-Walker-Gleichungen oder der Levinson-Durbin-Rekursion geschätzt werden. ACF- und PACF-Werte werden über sogenannte Korrelogramme dargestellt und sind ein wichtiger Bestandteil der Bildung von ARIMA-Modellen nach dem Box-Jenkins-Ansatz.

Zeitreihen können häufig, insbesondere bei nicht vorliegender Stationarität in verschiedene Komponenten aufgeteilt werden. Ziel ist es, einzelne Komponenten zu extrahieren, die eine einfache Möglichkeit bieten diese Komponenten in die Zukunft zu extrapolieren. Üblicherweise wird von folgenden Komponenten ausgegangen:

- Trend g_t : eine langfristige systematische Veränderung des Mittelwerts der Zeitreihe (glatte Komponente)
- Saisonkomponente s_t : regelmäßige zyklische Schwankung
- Restkomponente ϵ_t : nicht zu erklärende Einflüsse oder Störungen

Die Erkennung und Bereinigung von Trend- und Saisoneffekten erfolgt im Wesentlichen mit Methoden der linearen Regression, in vielen Fällen kann die Methode der kleinsten Quadrate angewendet werden. Für weiterführende Details zum Vorgehen sei auf [Sch01] und [Vog15] verwiesen. Unterschieden wird der additive Ansatz, bei dem die einzelnen Komponenten summiert werden ($y_t = g_t + s_t + \epsilon_t$), und der multiplikative Ansatz, bei dem die Komponenten multipliziert werden ($y_t = g_t * s_t * \epsilon_t$). Für gleichmäßige Schwankungen empfiehlt sich das additive Modell. Wenn die Größe der Schwankungen mit dem Niveau der betrachteten Zeitreihe zunimmt, sollte das multiplikative Modell genutzt werden.

5.4.2 Die Box-Jenkins Methode für die Modellbildung

Box und Jenkins [BJ76] haben einen iterativen Prozess zur Bildung von ARIMA-Modellen formuliert, der Grundlage vieler gängiger Verfahren der Zeitreihenanalyse ist. Die Methode kann sowohl für stationäre als auch für nicht-stationäre Prozesse eingesetzt werden. Der Prozess besteht aus den folgenden drei Schritten, die solange durchlaufen werden, bis ein akzeptables Ergebnis erreicht wird:

- Schritt 1: Modellidentifikation
- Schritt 2: Parameterschätzung
- Schritt 3: Modellüberprüfung

Im ersten Schritt wird die Zeitreihe durch grafische Aufbereitung oder statistische Tests auf ihre Eigenschaften hin untersucht. Lineare Trends und zyklische Schwankungen sind häufig schon durch Betrachtung des Zeitreihenverlaufs zu erkennen. Liegen solche deterministische Trends und/oder Saisoneffekte vor, so kann eine Komponentenzerlegung vorgenommen wer-

den, um die Trend- und Saisonkomponenten aus der Zeitreihe zu entfernen. Ist dies erfolgt, so können die Parameter p, d, q (vgl. Kapitel 2.3.2) eines ARIMA-Modells bestimmt werden.

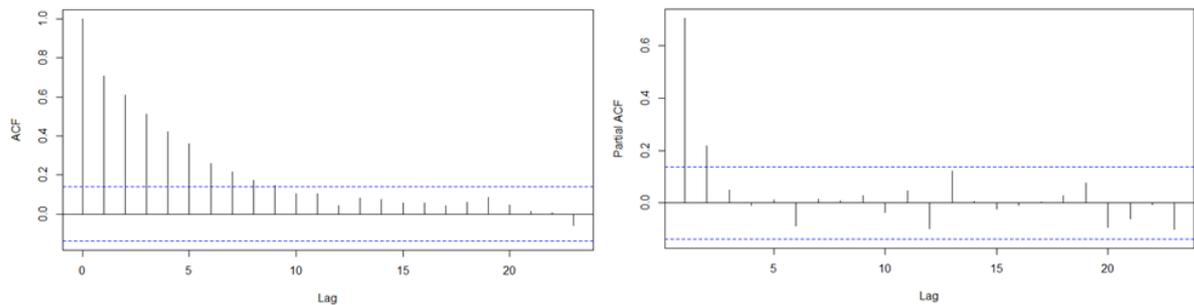


Abbildung 30: Korrelogramme der ACF- und PACF-Werte eines beispielhaften AR[2]-Prozesses

Für die Bestimmung nutzen Box und Jenkins die Autokorrelations- und die partielle Autokorrelationsfunktion. Für bestimmte Modelle sind verschiedene Verhaltensmuster der entsprechenden Funktionen zu erwarten. Für den Autoregressiven Teil und damit für den Parameter p eines ARIMA[p, d, q]-Modelles ist ein exponentielles Abklingen im Erscheinungsbild der empirischen Autokorrelationsfunktion erkennbar. Über die partielle Autokorrelationsfunktion wird geprüft, ab wann die PACF-Werte innerhalb der Grenzen der doppelten Standardabweichung bleiben. Der letzte Wert außerhalb dieser Grenzen bestimmt die Ordnung p . Abbildung 30 zeigt Korrelogramme der ACF- und PACF-Werte eines beispielhaften AR[2]-Modells. Die gestrichelten blauen Linien entsprechen grob der doppelten Standardabweichung, in deren Grenzen die Werte keine wesentlichen Autokorrelationen aufweisen. Im ACF-Plot sind die Werte anfangs stark abfallend und die PACF-Werte überschreiten bis zum Lag 2 die gestrichelte 95%-Signifikanzgrenze.

Ein anderes Bild ergeben reine Moving Average-Prozesse für den Parameter q . Hier sind die PACF-Werte exponentiell abklingend und die ACF-Werte, welche größer als die Ordnung q des Prozesses sind, bleiben innerhalb der Grenzen. Haben sowohl ACF, als auch PACF exponentiell fallende Werte, so handelt es sich um einen ARMA-Prozess mit sowohl AR, als auch MA-Anteil. Im Rahmen des Box-Jenkins-Ansatzes betrachtet man zuerst die ACF-Werte und anschließend die PACF-Werte und versucht typische Modellmuster zu erkennen, was nicht immer eindeutig ist. Hat man sich für ein Modell entschieden, so kann die Analyse der Residuen Aufschluss darüber geben, ob die Wahl korrekt ist [Sch15].

	AR[p]	MA[q]	ARMA[p,q]
ACF	Exponentiell fallend	Nach Lag q keine Relevanz mehr	Exponentiell fallend
PACF	Nach Lag p keine Relevanz mehr	Exponentiell fallend	Exponentiell fallend

Tabelle 11: Typisches Verhalten von ACF- und PACF-Werten nach Box-Jenkins

Eine Vielzahl von Zeitreihen weist allerdings auch nach einer Komponentenzerlegung eine stochastische Trendkomponente auf. Durch das Integrieren der Ausgangsreihe mittels Differenzierung erhält man einen ARIMA-Prozess, für den allerdings zusätzlich der Grad der Differenzbildung d bestimmt werden muss. Auch hierfür wird im Box-Jenkins-Ansatz die ACF genutzt. Sofern nur sehr langsam fallende ACF-Werte vorliegen, so weist dies auf den Bedarf für eine Differenzbildung hin.

Ist ein Modell bestimmt, so kann die Parameterschätzung vorgenommen werden, d. h. die Schätzung der Parameter α und β aus Formel 4. Hierfür kommen die Methode der kleinsten Quadrate oder eine Schätzung anhand der Maximum-Likelihood-Methode in Frage. Bei der Methode der kleinsten Quadrate werden die quadrierten Abstände zwischen den vorliegenden Werten und der Regressionsfunktion minimiert. Das Quadrat der Abstände wird verwendet, um negative und positive Abstände gleich zu behandeln und zu vermeiden, dass diese sich gegenseitig aufheben. Zudem werden größere Fehler stärker gewichtet. Bezogen auf ein ARMA-Modell ergibt sich:

$$\min \left(\sum_{t=1}^n y_t - \hat{y}_t \right)^2 = \min \left(\sum_{t=1}^n (y_t - \alpha_1 y_{t-1} - \dots - \alpha_p y_{t-p} + \beta_1 \epsilon_t + \dots + \beta_q \epsilon_t - q)^2 \right) \quad (42)$$

Da allerdings nicht alle benötigten Werte zum Zeitpunkt der Schätzung bekannt sind, kann man diese Startwerte auf 0 setzen (conditional least squares, kurz: CLS) oder aus der Zeitreihe selbst über eine sogenannte Rückwärtsprognose schätzen (unconditional least squares, kurz: ULS). Hierbei wird davon ausgegangen, dass ein rückwärts (in die Vergangenheit) laufender ARMA-Prozess dieselbe Autokovarianzfunktion hat wie der vorwärts laufende und daher dieselben Parameter genutzt werden können.

Die Schätzung mit Hilfe der Maximum-Likelihood-Methode (englisch: maximum likelihood estimation, kurz: MLE) setzt die Annahme einer bestimmten Verteilung der Werte der Zeitreihe voraus. Die unbekannt Parameter der Verteilung sind so zu wählen, dass die bekannten Werte der Zeitreihe am wahrscheinlichsten zu der Verteilung passen. Die Wahrscheinlichkeit des Erhaltens der gewünschten Werte wird also maximiert. Üblicherweise wird dabei die Normalverteilung vorausgesetzt. Für einen gaußschen Prozess ist die Likelihood-Funktion der Zeitreihe die Dichte der n -dimensionalen Normalverteilung [Vog15]. Für die Berechnung werden alle ARMA-Modellparameter in einem Vektor $\theta = [c, a_1, \dots, a_p, \beta_1, \dots, \beta_2, \sigma^2]$ zusammengefasst und unter der Verteilungsannahme eine gemeinsame Dichtefunktion berechnet. Diese Dichtefunktion wird dann als Funktion mit unbekanntem Parametervektor aufgefasst: $L(\theta) = f_{Y_t, Y_{t-1}, \dots, Y_1}(y_t, y_{t-1}, \dots, y_1; \theta)$. Die Schätzung erfolgt jetzt durch die Maximierung des natürlichen Logarithmus der sogenannten Likelihood-Funktion und wird in der Regel mittels iterativer Methoden durchgeführt, für die auch die erste und zweite Ableitung der Likelihood-Funktion benötigt werden. Die zweite Ableitung liefert insbesondere auch die Standardfehler für die geschätzten Koeffizienten.

Sind die Parameter geschätzt, wird das spezifizierte Modell überprüft. Hierzu werden im Wesentlichen die Residuen untersucht. Ist das spezifizierte Modell ein geeignetes Modell, so sollten die Residuen unkorreliert mit Erwartungswert Null und konstanter Varianz auftreten (White Noise). Es kann eine Überprüfung der Residuen anhand der ACF- und PACF-Werte

erfolgen. Sind darin noch deutlich von Null verschiedene Korrelationen oder partielle Korrelationen vorhanden, so weist dieses darauf hin, dass noch weitere Koeffizienten in das konstruierte Modell aufgenommen werden sollten. Ein weiterer Test auf nicht vorhandene Korrelation der Residuen ist der Ljung-Box-Test. Er basiert auf der Berechnung von:

$$Q = N(N+2) \sum_{\tau=1}^k \frac{\tilde{\rho}_{\tau}^2}{N-\tau} \quad (43)$$

$\tilde{\rho}_{\tau}^2$ beschreibt dabei die ACF der Residualreihe und N die Anzahl der vorliegenden Werte. Unter der Nullhypothese, dass die Autokorrelationen Null sind, folgt der Wert Q einer χ^2 -Verteilung mit k -Freiheitsgraden. Überschreitet der Wert Q den kritischen Wert aus der Verteilung, so kann die Nullhypothese abgelehnt werden und das Modell muss weiter angepasst werden. Als dritten Weg zur Überprüfung des konstruierten Modells können noch die Residuen auf Normalverteilung getestet werden. Dies ist insbesondere bei Nutzung der Maximum-Likelihood-Schätzung empfohlen, da diese auf der Annahme einer Normalverteilung basiert. Abweichungen deuten darauf hin, dass entweder die Ausgangszeitreihe noch einmal transformiert werden muss oder dass das Modell noch Verbesserungsbedarf aufweist [Sch15]. In diesem Fall sind die drei Schritte Modellidentifikation, Parameterschätzung und Modellüberprüfung erneut zu durchlaufen. Ist ein adäquates Modell gefunden, so kann dieses zu Prognosezwecken angewendet werden, indem die Modellparameter genutzt werden, um die Prozesswerte in die Zukunft fortzuschreiben.

5.4.3 Automatisierung der ARIMA-Modellbildung

Die im vorhergehenden Kapitel vorgestellte Box-Jenkins-Methode lässt sich in ihrer ursprünglichen Form, insbesondere mit der Berücksichtigung der ACF- und PACF-Werte, noch nicht vollständig automatisieren. Im Laufe der Zeit wurden aber verschiedene Tests und Kriterien entwickelt, mit denen eine weitestgehend automatisierte Modellbildung möglich ist.

Eine Prüfung auf Stationarität stellt der Augmented-Dickey-Fuller-Test (kurz: ADF) dar. Dafür wird eine Differenzierung der Zeitreihe durchgeführt und folgendes Regressionsmodell aufgestellt:

$$y'_t = \Phi y_{t-1} + \beta_1 y'_{t-1} + \beta_2 y'_{t-2} + \dots + \beta_k y'_{t-k} \quad (44)$$

Dabei bezeichnet y'_t den Wert der ersten Differenzierung. k ist die Anzahl der betrachteten Lags, die in dem Regressionsmodell berücksichtigt werden. Die Nullhypothese des ADF-Tests ist, dass die Zeitreihe nicht stationär ist. Entsprechend gilt: Ergibt sich ein Koeffizient $\hat{\Phi}$ nahe Null, sollte die ursprüngliche Zeitreihe differenziert werden. Ist die Zeitreihe bereits stationär, so nimmt $\hat{\Phi}$ einen Wert kleiner Null an. Im Gegensatz zum ADF-Test nutzt der Kwiatkowski-Philips-Schmidt-Schin-Test (KPSS) die Nullhypothese, dass eine Reihe stationär ist und prüft diese gegen die Alternative des Vorliegens einer Einheitswurzel (unit root), die auf das Vorliegen einer Nichtstationarität hinweist.

Für die Parameterschätzung ist das Akaike Information Criterion (AIC) nutzbar. Dieses nutzt die Log-Likelihood-Funktion, deren Wert größer ist, je besser das Modell die abhängige Variable erklärt. Auch hier wird von einer Normalverteilung der Daten ausgegangen. Um das Prin-

zip der sparsamen Parametrisierung zu berücksichtigen, enthält das Kriterium noch einen Strafterm, der die Anzahl der Parameter berücksichtigt:

$$AIC(k) = -2\hat{l}_k + 2|k| \quad (45)$$

In der Formel steht k für die Anzahl der im Modell enthaltenen Parameter p und q . \hat{l} repräsentiert den Wert der Log-Likelihood-Funktion. Das Modell mit dem kleinsten AIC-Wert stellt die beste Alternative aller getesteten Modelle dar.

Listing 4: Hyndman-Khandakar-Algorithmus zur ARIMA-Modellbildung

```

procedure buildArima(ts)
  1.   d = 0
  2.   while (KPSS(ts) → !stationary ) do
      (a)   ts = diff(ts)
      (b)   d = d+1
  3.   AIC1 = calculateAIC(ARIMA(2,d,2))
  4.   AIC2 = calculateAIC(ARIMA(0,d,0))
  5.   AIC3 = calculateAIC(ARIMA(1,d,0))
  6.   AIC4 = calculateAIC(ARIMA(0,d,1))
  7.   currentModel = chooseModel(min(AIC1, AIC2, AIC3, AIC4))
  8.   newModel = vary(currentModel)
  9.   while (newModel.AIC < currentModel.AIC) do
      (a)   currentModel = newModel
      (b)   newModel = vary(currentModel)
  10.  bestModel = currentModel
  11.  return bestModel

```

Hyndman und Khandakar [HK07] kombinieren in einem Algorithmus den KPSS-Test, die Minimierung des AIC und die Maximum-Likelihood-Schätzung zu einer automatisierten Möglichkeit ARIMA-Modelle zu bilden. Der Algorithmus ist in Listing 4 abgebildet und entspricht für die Modellauswahl einem effizienten Durchprobieren verschiedener Modelle und der Auswahl anhand des AIC. In Listing 4 entspricht der Parameter ts den Werten der betrachteten Zeitreihe. Die Anzahl der benötigten Differenzierungen und damit der Wert von d wird über wiederholte KPSS-Tests ermittelt und die entsprechenden Differenzierungen durchgeführt (Schritt 2). Anschließend werden die AIC-Werte von vier Startmodellen ermittelt (Schritte 3 bis 6). Ausgehend von dem Startmodell mit dem geringsten AIC-Wert werden p und q variiert, indem p und/oder q dekrementiert und inkrementiert werden, und so neue Modelle generiert (Schritt 8 und 9b) werden. Für die so entstandenen neuen Modelle wird ebenfalls der AIC-Wert berechnet und das Modell mit dem geringsten AIC-Wert ausgewählt. Ist dieser Wert geringer als der des Ursprungsmodells, so wird das Modell weiter variiert. Ist dies nicht der Fall, so wird abgebrochen und das gefundene Modell wird als bestgeeignetes Modell vom Algorithmus ausgewählt.

5.4.4 Zusammenfassung: Nutzung als Prognoseverfahren für den Lastgang eines Containerterminals

ARIMA-Modelle nutzen den Verlauf vergangener Werte einer Zeitreihe, um den weiteren (zukünftigen) Verlauf der Zeitreihe zu berechnen. Die gemessenen Werte einer Zeitreihe werden allerdings häufig von weiteren Faktoren beeinflusst. Um diesen gerecht zu werden, kann ein ARIMA-Modell gemäß Formel (5) auch um Einflüsse von außen ergänzt werden. Diese exogenen Variablen werden als zusätzliche lineare Regressoren modelliert, die als weitere Zeitreihe bzw. Zeitreihen in das Modell einfließen. Dabei müssen sowohl Vergangenheitsdaten, als auch Daten für den Prognosezeitraum vorliegen. Auch hier kann die Parameterschätzung analog zu der ARMA-Parameterschätzung mit der Methode der kleinsten Quadrate erfolgen (vgl. Kapitel 5.4.2). Es gelten dieselben Voraussetzungen wie bei der ARMA-Modellbildung.

Für die Prognose des Lastgangs eines Containerterminals sind folgende externe Regressoren relevant und sollen als Kandidaten für das ARIMA-Modell untersucht werden:

- Containerumschlagprofil
- Tagestypen
- Wetterdaten

Dabei sollen sowohl Modelle mit nur einem externen Regressor, als auch Modelle unter Berücksichtigung aller drei Einflüsse kombiniert aufgestellt werden, um die Einflüsse der einzelnen Regressoren getrennt beurteilen zu können. Zur Modellbildung wird dazu der Hyndman-Khandakar-Algorithmus aus dem vorangegangenen Kapitel, ergänzt um die Schätzung der Parameter für die externen Regressoren, genutzt.

5.5 Künstliche Neuronale Netze

Künstliche Neuronale Netze haben den Vorteil, Zusammenhänge zwischen Eingaben („Features“) und den dazugehörigen Ausgaben („Labels“) selbstständig zu entwickeln und so nicht-lineare Zusammenhänge zwischen den jeweiligen Variablen darstellen zu können. KNN benötigen daher keine Modellierung der den Daten zugrunde liegende Domäne, diese wird durch eine Trainingsphase erlernt. Dabei ist eine breite Palette von Festlegungen zu treffen, unter anderem ([HK98], [KB96]):

- *Datenauswahl und Datenaufbereitung:*
 - Identifikation der Einflussgrößen
 - Normierung der Einflussgrößen
 - Auswahl der Lerndaten
- *Netzstruktur:*
 - Anzahl verdeckter Schichten
 - Anzahl der Neuronen
 - Transferfunktion und Verknüpfung der Neuronen
- *Modellanpassung:*
 - Wahl des Lernverfahrens

- Wahl der Lernrate
- Maximale Anzahl von Lernschritten

Trotz des vielfältigen Einsatzes von Künstlichen Neuronalen Netzen ergibt eine Literaturrecherche nur wenige Vorgehensmodelle um ein entsprechendes System zu konstruieren und diese Festlegungen systematisch zu treffen. Da ein solches Vorgehensmodell aber für eine strukturierte Konzeption hilfreich ist, sollen in diesem Kapitel zuerst einige Vorgehensmodelle kurz diskutiert werden, um darauf basierend ein Vorgehensmodell zu entwerfen, an welchem sich diese Arbeit und die Beschreibung des Konzepts für die Lastgangprognose dann in den Folgekapiteln orientiert.

5.5.1 Vorgehensmodell für die Konstruktion Künstlicher Neuronaler Netze

Wie bereits beschrieben ergibt eine Literaturrecherche nur wenige Vorgehensmodelle für die Konstruktion von Künstlichen Neuronalen Netzen. Kaastra und Boyd [KB96] führen acht Schritte auf, die benötigt werden, um ein Prognosesystem auf Basis von KNN zu erstellen. Die ersten vier Schritte umfassen die Datenvorverarbeitung und sind unterteilt in Variablenauswahl, Datensammlung, Datenvorverarbeitung und die Einteilung der Daten in Trainings-, Test- und Validierungsmenge. Erst der fünfte Schritt beschäftigt sich mit dem eigentlichen Netz und beschreibt die Festlegung der Parameter des Netzes. Hier beschränkt sich das Vorgehen auf die Festlegung der Anzahl von Schichten, deren Anzahl von Neuronen und der Transferfunktion der Neuronen. Für die Festlegung der Anzahl von Neuronen in der verborgenen Schicht werden einige Regeln aus der wissenschaftlichen Literatur zitiert, aus denen sich aber kein einheitliches Vorgehen ableiten lässt. In den Folgeschritten werden die Evaluationskriterien bestimmt, die Trainingsparameter festgesetzt und anschließend die eigentliche Implementierung vorgenommen. Die Autoren weisen darauf hin, dass die aufgezählten Schritte nicht nur einmal linear durchlaufen werden, sondern dass Rücksprünge möglicherweise notwendig sind.

Backhaus et al. [BEW15] beschreiben eine anwendungsorientierte Vorgehensweise zur allgemeinen Konstruktion und Anwendung von Künstlichen Neuronalen Netzen, bestehend aus folgenden fünf Schritten:

- Problemstrukturierung und Netztypauswahl
- Festlegung der Netztopologie
- Informationsverarbeitung in den Neuronen
- Trainieren des Netzes
- Anwendung des trainierten Netzes

Allerdings fehlt diesem Modell die Möglichkeit nach Abschluss eines Schrittes wieder zu einem der vorherigen Schritte zurückzukehren, um Anpassungen zur Verbesserung zum Beispiel durch die Änderung von einzelnen Parametern durchzuführen. Auch in den Ausführungen zu den einzelnen Schritten wird diese Möglichkeit nicht diskutiert.

Hufendiek und Kaltschmitt [HK98] betonen dagegen in ihrem Vorgehensmodell zur schematisierten und zumindest in Teilen automatisierten Konstruktion von Künstlichen Neuronalen Netzen zur Lastgangprognose die Bedeutung der Daten an sich. So beginnt das Modell mit den zwei separaten Schritten Datenanalyse und Datenaufbereitung, bevor die Netzarchitektur

festgelegt wird. Zudem führen sie nach dem Lernen einen Validierungsschritt ein, nach dessen Ausführung ein Rückkanal zur Festlegung der Netzarchitektur folgt.

Hagan et al. [HDB+14] beschreiben den Konstruktionsprozess als vollständig iterativen Prozess, mit dem Schritt der Datenvorverarbeitung als Eingangspunkt in den sich wiederholenden Ablauf. Es folgen die Schritte der Auswahl eines entsprechenden Netzwerktyps und der Architektur und die Auswahl des Trainingsalgorithmus. Anschließend werden die Gewichte initialisiert und das Neuronale Netz trainiert. Nach der Analyse der Leistung des Netzwerkes wird entweder wieder mit der Datenvorverarbeitung begonnen oder bei entsprechenden Leistungswerten die Iterationen beendet und das Netzwerk genutzt. Zu diesem Modell ist anzumerken, dass die Anpassung der Datenvorverarbeitung in jedem Durchlauf des Prozesses nicht immer nötig scheint, da der Trainingsprozess auch einmal festgelegte Daten erstmal verbessern kann. Lediglich, wenn das Netzwerk auch mit verschiedensten Parameterkombinationen keine zufriedenstellende Leistung mit den vorverarbeiteten Daten erbringt, scheint es notwendig die Datenauswahl und -vorverarbeitung noch einmal anzupassen.

Die diskutierten Vorgehensweisen zur Konstruktion eines Künstlichen Neuronales Netzes sollen hier in einem Vorgehensmodell mit fünf Schritten konsolidiert werden, so wie es in Abbildung 31 gezeigt wird. Es besteht aus folgenden Schritten:

- Problemstrukturierung und Datenvorverarbeitung
- Festlegung der Netztopologie und der Hyperparameter
- Training des Netzes
- Validierung des Netzes
- Anwendung des trainierten Netzes

In Punkt 1 des Vorgehensmodells wird bestimmt, welche Art von Problem gelöst werden soll und wie dazu benötigte Daten bereitgestellt werden können. Dieser Schritt ist insbesondere

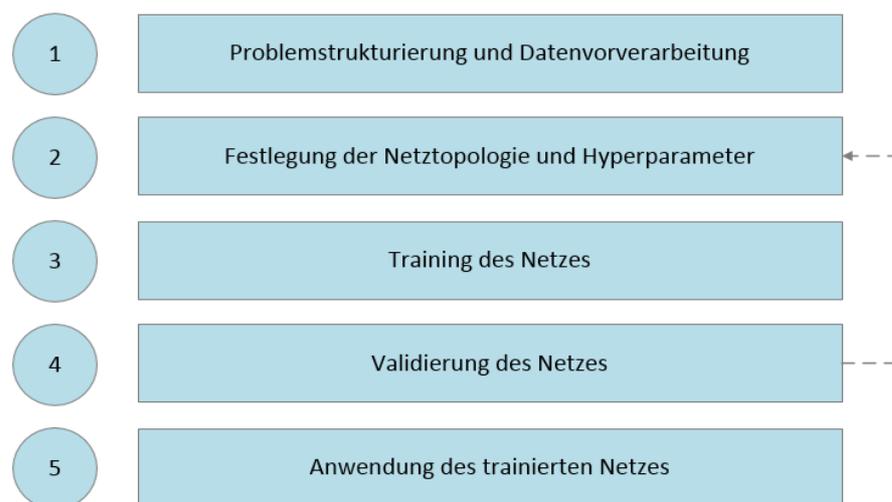


Abbildung 31: Vorgehensmodell für die Konstruktion Künstlicher Neuronaler Netze

wichtig, da die Struktur der Daten einen wesentlichen Einfluss auf das Ergebnis hat. Neurna-

le Netze entdecken die Strukturen in den Daten während der Trainingsphase (Schritt 3) und sind hier auf entsprechend strukturierte Daten angewiesen. Der vierte Schritt, die Validierung des Netzes, erlaubt hierbei wieder einen Rücksprung zum zweiten Schritt, der Auswahl und Festlegung der Netztopologie und Hyperparameter, da dieser Schritt entscheidend ist, um auf Ergebnisse der Validierung reagieren zu können und einzelne Parameter zur Verbesserung der Leistung des Netzes zu modifizieren. Dieses Modell soll für das Lastgangprognosesystem auf Basis von Künstlichen Neuronalen Netzen angewendet werden. Die folgende Konzeption orientiert sich an dem Vorgehensmodell.

5.5.2 Problemstrukturierung und Datenvorverarbeitung

Kern des Konzeptes für die Nutzung von Neuronalen Netzen für die Lastgangprognose eines Containerterminals ist die Nutzung der viertelstündlichen Containerumschlagzahlen (Containerprofil) eines Tages als wesentliche Eingabeparameter und die entsprechenden 96 Werte des Lastgangs als Ausgabeparameter („Labels“).

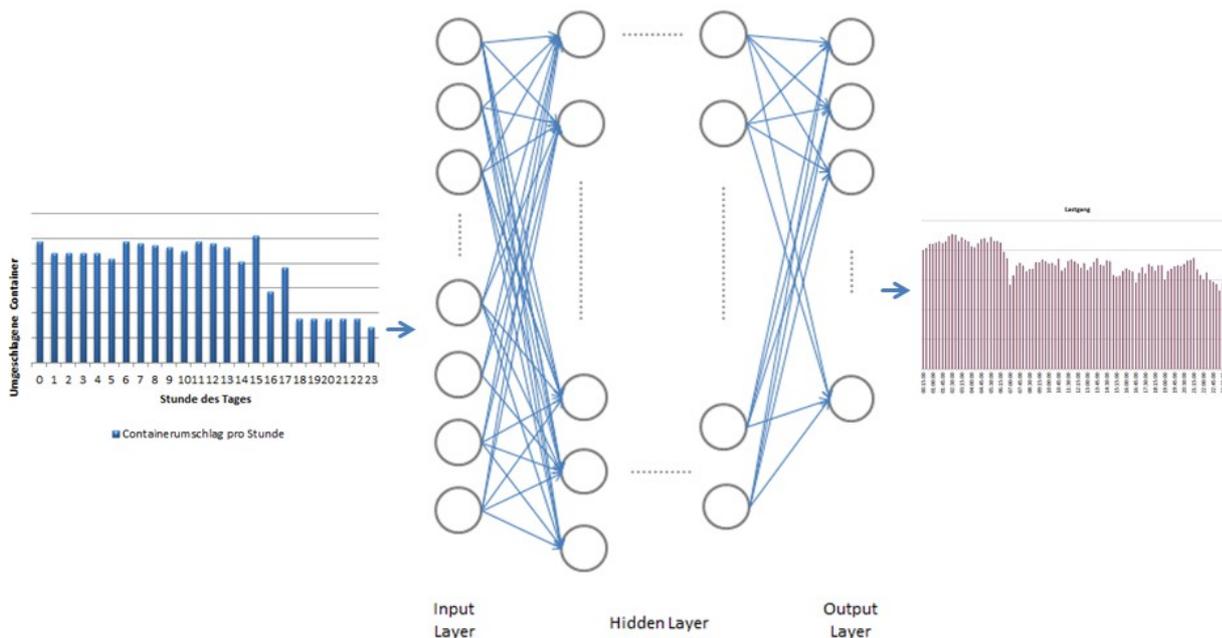


Abbildung 32: Schematische Darstellung des Konzepts für die Lastgangprognose mit Künstlichen Neuronalen Netzen

Es handelt sich also nicht um die sequentielle Einzelprognose von 96 Werten, sondern um die Prognose des gesamten Lastgangs mit einem Durchlauf. Dieses Vorgehen wird gewählt, um die Beziehungen der einzelnen Viertelstundenverbrauchswerte auf die entsprechenden Vorgänger und Nachfolgewerte mit zu berücksichtigen und durch das Künstliche Neuronale Netz lernen zu lassen. Die Vorgehensweise zum Erstellen eines Containerumschlagprofils wurde bereits in Kapitel 5.1 beschrieben. Zusätzlich können Parameter für Wetter- und Kalenderinformationen als Eingabe ergänzt werden. Abbildung 32 zeigt schematisch den Aufbau eines solchen Netzes.

Während eine Korrelation zwischen den Containerumschlagzahlen und dem Lastgang bereits gezeigt werden konnte, wird dieser Zusammenhang in diesem Konzept von einem Künstlichen Neuronales Netz gelernt. Zusätzlich soll geprüft werden, ob weitere Daten wie Temperatur, Windgeschwindigkeit oder Tagestypinformationen den Lernerfolg des Netzes verbessern. Alle diese Daten sind positive numerische Werte, haben aber einen unterschiedlichen Wertebereich. So bewegen sich die Containerzahlen pro Stunde häufig im zwei- und dreistelligen Bereich, während für die Darstellung der verschiedenen Tagestypen einstellige Zahlen ausreichend sind. Daher ist es notwendig sowohl die Eingabedaten, als auch die vorhandenen Ergebnisdaten auf ein Wertenniveau zu normieren. Abhängig von der später im Netz verwendeten Aktivierungsfunktion eines Neurons sollte die Normierung (auch Normalisierung genannt) auf einen Wertebereich zwischen -1 und 1 (bei Nutzung der tanh-Funktion) oder 0 bis 1 (bei Nutzung der logistischen Sigmoidfunktion). Bei Anwendung einer sigmoiden Aktivierungsfunktion erreichen aufgrund des asymptotischen Verlaufs der Funktion nur Werte, die gegen Unendlich streben die äußeren Grenzen des Intervalls. Deshalb sollte das Zielintervall etwas geringer gewählt werden, um die äußeren Bereiche der Sigmoidfunktion auszusparen ([-0,9;0,9] bzw. [0,1;0,9]) [ZPH98]. Eine häufig genutzte Funktion für die Normalisierung ist dabei die Min-Max-Normalisierung [HDB+14] wie in Formel (46) beschrieben.

$$z_i = \frac{(x_i - \min(x)) * (MAX - MIN)}{(\max(x) - \min(x)) + MIN} \quad (46)$$

Dabei ist x_i der aktuell betrachtete Wert, $\min(x)$ der kleinste Wert der Wertemenge, $\max(x)$ der höchste Wert der Wertemenge und MIN und MAX jeweils die äußeren Grenzen des Intervalls, in dem der normalisierte Wert liegen soll. Dieses Vorgehen zur Normalisierung muss dabei für die einzelnen Eingabeparameter einzeln durchgeführt werden, um die unterschiedlichen Wertebereiche zu berücksichtigen („Along channel normalization“). Da sich sowohl die Eingabe-, als auch die Ausgabedaten zum überwiegenden Teil im positiven Wertebereich befinden (lediglich bei den Temperaturwerten sind negative Werte möglich), soll während der Datenvorverarbeitung eine Normalisierung auf das Intervall [0,1;0,9] erfolgen.

5.5.3 Festlegung der Netztopologie und Hyperparameter

Für die Festlegung der Netztopologie und der entsprechenden Hyperparameter ist ein Trial-and-Error-Prozess nicht unüblich [BEW15]. Für die Lastgangprognose soll ein vollständig verbundenes Feed-Forward Multilayer Perceptron (MLP) Netz genutzt werden, wie es vielfach für Prognosefunktionen im Energiebereich genutzt wird [FG05]. Für die meisten Problemstellungen sind dabei Neuronale Netze mit einer oder zwei verdeckten Schichten ausreichend [HDB+14]. Sämtliche vorliegende Daten sind nach der Datenvorverarbeitung und der Normalisierung auf ein entsprechendes Intervall positive numerische Werte, sodass die logistische Sigmoidfunktion (vgl. Formel 47) als Aktivierungsfunktion genutzt werden kann. Die sigmoide Aktivierungsfunktion hat gegenüber linearen Aktivierungsfunktionen den Vorteil, dass durch die asymptotische Annäherung an 0 und 1 die Aktivierungslevel nach oben bzw. nach unten begrenzt sind. Im Gegensatz zu binären Aktivierungsfunktionen ist sie dabei an allen Stellen differenzierbar und somit ohne Einschränkungen für ein Lernverfahren auf Basis eines Gradientenabstiegs nutzbar.

$$f(z) = \frac{1}{1 + e^{-z}} \quad (47)$$

Nach der Festlegung der Aktivierungsfunktion sind die Anzahl der Neuronen je Schicht sowie die Anzahl der verborgenen Schichten zu bestimmen. Für die Anzahl der Neuronen gibt es keine feste Vorschrift, lediglich eine Anzahl von verschiedenen Daumenregeln für Startwerte, von denen ausgehend die Anzahl der Neuronen entweder erweitert oder verringert werden kann. Die Daumenregeln orientieren sich dabei an der Anzahl der Eingabeparameter und reichen von $n/2$ Neuronen für die verborgene Schicht [Kan92] bis zu $2n+1$ Neuronen [Lip87]. Zhang et al. 1997 [ZPH98] berichten in ihrem Review von verschiedensten Prognoseanwendungen von KNN, dass Neuronale Netze, die etwa eine Anzahl von verborgenen Neuronen im Bereich der Anzahl der Eingabeneuronen haben, die besseren Prognosegenauigkeiten erreichen als andere Konfigurationen. Weitere Hyperparameter, die es zu bestimmen gilt betreffen schon das eigentliche Lernverfahren. Im Wesentlichen sind das die Lernrate und die Anzahl der Lernschritte. Auch für die Festlegung der Lernrate gibt es verschiedenste Ansätze. Die Lernrate bestimmt die Schrittweite der Anpassungen in einem Trainingsdurchlauf, liegt üblicherweise im Intervall zwischen 0 und 1 und ist wesentlich für den Trainingserfolg entscheidend, da von ihr abhängt, inwieweit der Lernalgorithmus konvergiert. Wird die Lernrate zu klein gewählt, so wird der Trainingsaufwand groß und es besteht die Gefahr in einem lokalen Optimum (vgl. folgendes Kapitel) stecken zu bleiben. Wird die Lernrate zu groß gewählt, so kann das Optimum übersprungen werden und als Ergebnis des Lernprozesses daher nicht das globale Optimum erreicht wird. Die Wahl der Lernrate hat damit auch einen Einfluss auf die Anzahl der Lernschritte. Ein häufig verwendetes Vorgehen für die Bestimmung der Lernschritte ist das sogenannte „Early Stopping“, bei dem nach einer bestimmten Anzahl von Trainingsschritten, nach denen die Zielfunktion des Netzes sich nicht verbessert hat, der Trainingsvorgang abgebrochen wird. Auch hier besteht wieder die Gefahr, in einem lokalen Optimum zu bleiben.

Es existieren einige Ansätze zur gemeinsamen Optimierung der Hyperparameter eines Künstlichen Neuronalen Netzes. Neben einer zufallsbasierten Suche werden genetische Algorithmen und Rastersuche dafür genutzt. Für die Lastgangprognose soll der Ansatz der statistischen Versuchsplanung („Design of Experiments“, DoE) aufgenommen werden, einer Methode zur effizienten Planung und Auswertung von Versuchsreihen. Ausgehend von einer Liste der möglichen Parameter, Faktoren genannt, wird ein Versuchsplan erstellt, der den Faktorraum, also alle möglichen Kombinationsmöglichkeiten der Faktoren, gleichmäßig untersucht und den Einfluss der einzelnen Faktoren auf die beobachteten Merkmale untersucht. Jeder Parameter wird dabei mit mindestens zwei unterschiedlichen Einstellungen, genannt Stufen, getestet. Wesentlicher Bestandteil der statistischen Versuchsplanung ist dabei die Konstruktion von Versuchsplänen, welche möglichst orthogonal und ausgewogen erstellt werden müssen und mit möglichst wenigen Versuchen auskommen sollen, ohne dass es zu einem nennenswerten Informationsverlust kommt [SVH12]. Bei außerordentlich vielen Einstellungsmöglichkeiten und unterschiedlichen Einschränkungen in den Faktorräumen muss auf sogenannte Kandidaten von Einstellungen zurückgegriffen werden. Gängig ist hierfür ein sogenanntes D-optimales Design für den Versuchsplan, bei dem die Anzahl der Versuche und die jeweiligen Faktorstufen frei wählbar sind. Aus allen Faktoren und Faktorstufen wird ein n -dimensionales

Gitter gebildet, die Design-Matrix X . Die Determinante $X'X$ stellt das Gesamtmaß der Informationen der Design-Matrix im Sinne der Fisher-Information [MMB97] dar, die es zu maximieren gilt. Für die D-optimale Versuchsplanung werden für die Faktoren zweckmäßige Abstufungen bestimmt, die für jeden Faktor unabhängig sein können und nicht über das gesamte Intervall die gleichen Abstände aufweisen müssen. Dies erfolgt in den meisten Fällen aufgrund der Komplexität des Optimierungsproblems auf Basis von entsprechenden Algorithmen [Kle14].

Tabelle 12 zeigt die Struktur eines möglichen Versuchsplans. Zu den einstellbaren Faktoren zählen die Anzahl der Neuronen in der verborgenen Schicht, die Lernrate und die Anzahl der Lernschritte pro vollständigem Trainingsdurchlauf. Die Auswirkungen verschiedener Faktorkombinationen auf die Prognosegüte sollen untersucht werden. Dazu wird das Gütemaß MAPE über den Zeitraum von einem Jahr als beobachteter Faktor definiert. Die statistische Versuchsplanung ermöglicht mit der D-optimalen Auswahl der zu testenden Faktorkombinationen eine systematische Auswahl der Testreihen zur Ermittlung einer Kombination der Parameter, welche zu einer möglichst hohen Prognosegüte des Künstlichen Neuronalen Netzes führt. Um zu prüfen, ob eine verborgene Schicht ausreichend ist oder eine weitere verborgene Schicht Vorteile bringt, kann die Versuchsreihe mit beiden Konfigurationen des KNN durchgeführt werden und die Ergebnisse verglichen werden.

Einstellbare Faktoren			Beobachtete Faktoren
Anzahl Neuronen	Lernrate	Lernschritte	MAPE
50	0.1	1000	
60	0.1	1000	
...	

Tabelle 12: Beispielhafte Struktur eines Versuchsplans nach dem Prinzip der statistischen Versuchsplanung

5.5.4 Training des Netzes

Der am häufigsten für das Training eines Feedforward Neuronalen Netzes verwendete Trainingsalgorithmus ist Backpropagation aus der Klasse der überwachten Lernverfahren [RN95]. Backpropagation ist ein Gradientenabstiegsverfahren, bei dem die Gewichte der einzelnen Verbindungen zwischen den Neuronen angepasst werden. Eine detaillierte Beschreibung des Lernverfahrens inklusive mathematischer Fundierung kann zum Beispiel in [RN95], [KBK+11] oder [HDB+14] gefunden werden. Im Wesentlichen lässt sich das Verfahren in drei Schritte einteilen, die iterativ durchlaufen werden:

- Die Vorwärts-Propagierung mit Berechnung der Ausgabewerte.
- Die Berechnung des Netzfehlers.
- Die Rückwärts-Propagierung der Fehlerwerte und die darauf basierende Anpassung der Gewichte.

Jeder Durchlauf entspricht einem Trainingsschritt und wird im englischen häufig als „Epoch“ bezeichnet. Nach einer initialen Belegung der Gewichte $w_{i,j}$ zwischen den Neuronen werden dem Netz zwei Vektoren mit den Eingaben und den darauf basierenden erwarteten Ausgaben präsentiert. In jedem Durchlauf werden die Daten des Eingabevektors genutzt, um die Ausgabewerte auf Basis der aktuellen Netzkonfiguration und den entsprechenden Gewichten zu berechnen (Vorwärts-Propagierung). Die berechneten Ausgaben werden mit den erwarteten Ausgaben verglichen und so der Netzfehler durch die Fehlerfunktion E_p bestimmt. Dies wird für alle vorhandenen Eingabe- und Ausgabevektoren (Trainingsbeispiele) durchgeführt und der durchschnittliche Gesamtfehler als Mittelwert der Fehler E_p bestimmt. In der Regel wird dazu eine quadratische Fehlerfunktion genutzt, damit sich die Abweichungen mit unterschiedlichen Vorzeichen nicht gegenseitig aufheben (z. B. MSE, vgl. Kapitel 2.6.1). Der Backpropagation-Algorithmus versucht nun durch die Anpassung der Gewichte für jedes Trainingsbeispiel den Fehler zu minimieren. Mit Hilfe des Gradientenverfahrens wird berechnet, in welcher Richtung die Gewichtsänderung erfolgen muss, um den Fehler zu minimieren. Der Durchschnitt aller Gewichtsänderungen für die Trainingsbeispiele soll den Gesamtfehler minimieren. Um auch den Gradienten für die der Ausgabeschicht vorgelagerten verborgenen Schichten berechnen zu können, wird unter Anwendung der Kettenregel und der partiellen Ableitung der Netzeingabe rekursiv, ausgehend von der Ausgabeschicht, der Beitrag der vorgelagerten Schichten zum Netzfehler berechnet. Die darauf basierende Gewichtsänderung hängt von der Lernrate, dem berechneten Fehlerwert und der einzelnen Eingabewerte in das Neuron ab. Nach Anpassung der Gewichte erfolgt eine weitere Präsentation der Trainingsbeispiele an das Netz mit den angepassten Gewichten und eine erneute Bestimmung des Netzfehlers. Das Vorgehen wird solange wiederholt bis ein vorher bestimmtes Abbruchkriterium erreicht ist. Ein solches Abbruchkriterium kann das Erreichen eines festgelegten minimalen Netzfehlers sein oder ein Abbruch nach dem Durchlauf von einer vordefinierten Anzahl von Trainingsschritten.

Um eine Überanpassung (englisch: „overfitting“) des Netzes an die Trainingsdaten zu vermeiden können verschiedene Strategien angewendet werden. Eine der wichtigsten ist die Einteilung der vorliegenden Daten in Trainings-, Validierungs- und Testdaten. Eine häufige Empfehlung für die Einteilung der Daten ist, dass ca. 80 % der vorhandenen Datenmenge als Trainingsdatenmenge verwendet werden. 10 % werden als Validierungsdaten verwendet, anhand derer die Fehlerfunktion des Backpropagation-Algorithmus ermittelt wird. Dadurch wird die Fehlerfunktion vom Trainingsdatensatz gelöst. Zur endgültigen Bestimmung der Güte des Netzes wird anschließend das Netz mit dem Testdatensatz getestet [BEW15]. Dabei empfiehlt es sich, die Auswahl der Trainings- und Validierungsdaten aus den Gesamtdaten während des Trainings zu wechseln („Cross-Validierung“), um Anpassungseffekte zu vermeiden. Allerdings ist bei Zeitreihendaten zu beachten, dass die Trainingsdaten immer zeitlich vor dem Validierungsdaten liegen müssen und der Trainingsdatensatz dabei nicht zu klein gewählt wird. Das Vorgehen dazu entspricht einem rollierenden Verfahren [HA13]. Ein weiteres Verfahren zur Vermeidung der Überanpassung ist das sogenannte Dropout [SHK+14]. Dabei werden in jedem Trainingsdurchlauf eine gewisse Anzahl von Neuronen ausgeschaltet und nicht verwendet. Die übrigen Neuronen müssen in diesem Durchlauf die fehlenden Neuronen kompensieren. Im nächsten Durchlauf werden andere Neuronen zufällig ausgeschaltet. Dadurch werden

die jeweils verbleibenden Neuronen dahingehend trainiert, dass sie eine höhere Fähigkeit zur Verallgemeinerung haben.

Eine Weiterentwicklung des Backpropagation-Algorithmus ist der sogenannte Resilient Backpropagation Algorithmus (RPROP). Im Gegensatz zu dem ursprünglichen Verfahren hängt hier die Gewichtsveränderung jedoch nur vom Vorzeichen des Gradienten, nicht seinem tatsächlichen Wert ab [RB93]. So wird das „vanishing gradient“-Problem, die exponentielle Abnahme des Gradienten bei der Rückführung durch die Netzschichten, umgangen. Bei Verwendung von Backpropagation kann dies zur Stagnation des Lernfortschritts in vorderen Schichten führen. Der Algorithmus ist sowohl in Hinblick auf Zeit- als auch Speicherkomplexität effizienter als der ursprüngliche Backpropagation-Algorithmus.

Für die Lastgangprognose eines Containerterminals mittels Künstlicher Neuronaler Netze soll also ein Feedforward-Netz erstellt werden, welches mittels Resilient Backpropagation trainiert wird. Wesentliche Parameter des Netzes werden über einen Versuchsplan ermittelt. Das Training basiert auf ca. 80 % der zur Verfügung stehenden Daten und die Validierung auf ca. 10% der Daten. Dabei wird Dropout angewendet um ein Overfittig zu vermeiden. Die Prognosegüte des Netzes wird anschließend auf Basis der verbleibenden Testdaten ermittelt.

5.5.5 Anwendung des trainierten Netzes

Ist ein Netz fertig trainiert, so wird dieses mit den ermittelten Gewichtungen gespeichert und für die Anwendung bereitgestellt. In der Anwendungsphase werden neue, zuvor nicht bekannte Eingabedaten an das Netz angelegt, welches daraus die entsprechenden Ergebnisse berechnet. Handelt es sich bei der Anwendung um eine Prognosefunktion, wie bei der Lastgangprognose für Containerterminals, so kann die Prognosegüte erst nach der Ermittlung der tatsächlichen Werte erfolgen. Die Prognosegüte des Netzes sollte regelmäßig überwacht werden, um systematische Abweichungen und Veränderungen zu erkennen. Ändern sich zum Beispiel Rahmenbedingungen für den Terminalbetrieb, zum Beispiel durch die Installation von zusätzlichem Umschlagequipment, so kann ein erneutes Training des Netzes zur Anpassung an die neue Situation nötig sein. Hierbei kann das vorhandene Netz als Ausgangskonfiguration genutzt werden, um den Trainingsaufwand gering zu halten.

5.5.6 Zusammenfassung: Nutzung als Prognoseverfahren für den Lastgang eines Containerterminals

In den vorangegangenen Kapiteln wurde ein Konzept für die Erstellung eines Künstlichen Neuronalen Netzes beschrieben. Künstliche Neuronale Netze eignen sich für eine Vielzahl von Anwendungsfälle und sind erstmal domänenunabhängig anwendbar. Erst durch das Training mit Daten aus einer bestimmten Domäne entsteht eine gewisse Domänenabhängigkeit. Für die Prognose des Lastgangs eines Containerterminals wird dazu das Containerprofil eines Tages als Eingabe und der dazugehörige Lastgang des Tages als Ausgabe genutzt. Es ist zu prüfen, inwieweit weitere Kontextinformationen als Eingabe das Prognoseergebnis beeinflussen. Für das Training eines Künstlichen Neuronalen Netzes wird ein umfangreicher Datensatz an Containerprofilen und dazugehörigen Lastgängen benötigt. Die Daten von einigen Wochen sind hier sicherlich nicht ausreichend, um zum Beispiel Temperaturabhängigkeiten im vollen

Umfang zu berücksichtigen. Sinnvoll ist ein Datensatz, der mehrere Jahre umfasst, um möglichst viele, eventuell vorhandene Saisoneffekte berücksichtigen zu können. Damit eignet sich ein KNN nicht für neu errichtete oder vor kurzem umgebaute Containerterminals.

5.6 Simulation

Bei der Simulation werden dynamische Prozesse eines Systems so exakt wie möglich in einem Modell nachgebildet. Insbesondere die Wechselbeziehungen unterschiedlicher Elemente eines Systems können so anhand eines Modells getestet werden, bevor eine Umsetzung in der Realität erfolgt. Simulationsmodelle werden üblicherweise in kontinuierliche und ereignisdiskrete Modelle eingeteilt, wobei im Bereich der Logistik, zu dem auch Containerterminals zu rechnen sind, ereignisdiskrete Modelle relevant sind und dort häufig als Materialflusssimulationen bezeichnet werden. Bei ereignisdiskreten Simulationsmodellen werden Änderungen an Modellzuständen Ereignisse genannt, die zu bestimmten Zeitpunkten stattfinden. Durch die Ereignisse werden wiederum Aktivitäten ausgelöst oder beendet, wobei eine Anzahl von Aktivitäten einen Prozess bildet [Ele12].

Für die Abbildung von Energieverbräuchen in ereignisdiskreten Simulationsmodellen können drei verschiedene Arten von Ansätzen unterschieden werden [HTK+11]:

- *Gekoppelte Ansätze*: Die ereignisdiskrete Simulation liefert Zustandsinformationen von Materialflussobjekten an ein externes Energiebewertungstool, welches darauf basierend eine Bewertung des Energiebedarfs vornimmt.
- *Kombinierte Ansätze*: Verschiedene Simulationsmethoden und externe Energiebewertungstools werden genutzt.
- *Integrierte Ansätze*: Simulation und Energiebewertung werden in einem Framework zusammen betrachtet.

Den vorhandenen Ansätzen ist gemein, dass die Leistungsaufnahme an den Betriebszustand (z. B. „An“, „Aus“ oder „Wartend“) der entsprechenden dargestellten Einheit gekoppelt wird. Jeder abgebildete Zustand hat einen zugeordneten Wert der Leistungsaufnahme.

Aufgrund der Komplexität großer Logistiksysteme und der damit verbundenen zu lösenden Planungsprobleme werden diese häufig in Simulationsmodellen abgebildet, um den Betrieb strategisch zu planen und einzelne Optimierungsansätze zu evaluieren. Dies gilt auch für Containerterminals. Die Modelle sind häufig unterteilt in verschiedene Subsysteme, abhängig von dem Grad der Automatisierung, den beteiligten Umschlaggeräten und dem Layout des Terminals. Ein Simulationsmodell eines Containerterminals betrachtet üblicherweise die logistischen Prozesse im Bereich der Kaimauer, des Horizontaltransports der Container, des Blocklagerbereichs und des Zufahrtsbereichs des Terminals für LKWs und Züge.

Tabelle 13 benennt einige Planungsprobleme für die entsprechenden Terminalbereiche. Für eine detaillierte Erörterung verschiedener Strategien zur Lösung der Planungsprobleme sei hier auf entsprechende Literatur aus dem Bereich des Operation Research (z. B. [SV08]) verwiesen.

Terminalbereich	Planungsprobleme (Auszug)
Kaimauer	<ul style="list-style-type: none"> • Liegeplatzzuweisung • Kaikranzuordnung
Horizontaltransport	<ul style="list-style-type: none"> • Fahrzeugallokation • Routenfindung
Blocklagerbereich	<ul style="list-style-type: none"> • Lagerblock- und Stellplatzauswahl • Lageroptimierung/Umstapelung
Terminalzufahrtsbereich	<ul style="list-style-type: none"> • Zulaufsteuerung • Containerallokation

Tabelle 13: Terminalbereiche und damit verbundene Planungsprobleme (Auszug)

Die Anforderungen an einen hohen Grad an Automatisierung und Produktivität haben dazu geführt, dass viele spezialisierte Simulationsmodelle für Containerterminals entstanden sind. Eine Auflistung ist zum Beispiel in [RIH+14] zu finden. Die Leistungsaufnahme und der Energiebedarf erfuhren dabei in der Gesamtbetrachtung der jeweiligen Terminals keine Beachtung. Erst die Arbeiten von Grundmeier, Ihle et al. [GHI+14], Runge, Ihle et al. [RIA+14] und Grundmeier [Gru16] stellten Konzepte für die Berücksichtigung von Leistungsaufnahme, integriert in ein Simulationsmodell für Containerterminals, auf. Die weiteren Ausführungen dieses Kapitels basieren auf diesen Arbeiten, wobei an einigen Stellen Ergänzungen oder Anpassungen vorgenommen wurden, um eine korrekte Darstellung im Sinne dieser Arbeit zu ermöglichen.

5.6.1 Zustandsbasierte Abbildung von Energieverbrauchsprozessen in ereignisdiskreten Simulationen

Runge, Ihle et al. und Grundmeier führen an, dass drei Punkte bei vorhandenen Simulationsansätzen, die Energieverbrauchsprozesse berücksichtigen, fehlen. Diese sind allerdings für eine vollständige Betrachtung der Energieaufnahme von Containerterminals relevant:

- *Allgemeine Verbraucher:* Die (meist recht konstante) Grundlast eines Containerterminals wird durch die Leistungsaufnahme von allgemeiner Infrastruktur eines Terminals wie IT, Beleuchtung, Verwaltungsgebäude, etc. generiert und kann bis zu 20 % der gesamten Leistungsaufnahme eines Terminals betragen. Diese ist aber nicht in den Materialfluss eingebunden und fehlt daher in entsprechenden Modellen.
- *Ressourcenenergie:* Die Energie, die durch die am Prozess beteiligten Komponenten (Sensoren, Aktoren, Steuerungen, etc.) benötigt wird, ist für eine differenzierte Betrachtung der Leistungsaufnahme relevant, insbesondere, wenn die Ressourcenenergie einen hohen Anteil an der Gesamtleistungsaufnahme eines Verbrauchers bzw. eines Prozesses hat.

- *Äußere Faktoren:* Materialflusssimulationen basieren auf vordefinierten Maschinenzuständen. Daher ist es nicht möglich, den Leistungsbedarf nach Einflussfaktoren (z. B. Witterungsbedingungen, Größe eines Werkstücks) zu differenzieren, die keine intrinsischen Faktoren des Materialflusses sind.

Um das Fehlen dieser Punkte auszugleichen wird die Herleitung der Leistungsaufnahme über den Betriebszustand erweitert in die Herleitung über den Betriebs-, Prozess- und Ressourcenzustand. Jeder Verbraucher hat dabei verschiedene Modi für den Betrieb. Je nach Modus werden unterschiedliche Ressourcen aktiviert und bestimmte Modi sind eine Voraussetzung für die Ausführung von Prozessen. Jedem Betriebsmodus wird ein bestimmter Betriebszustand („state“) zugeordnet. Um einen bestimmten Prozess durchführen zu können, werden Ressourcen benötigt, welche ebenfalls unterschiedliche Zustände (z. B. „aktiv“ oder „nicht aktiv“) haben können. Nur bei einem eingeschalteten bzw. aktiven Zustand einer Ressource wird eine bestimmte Leistungsaufnahme der Ressource zugeordnet. Dies kann auf Basis eines fest vorgegebenen Verbrauchs oder aufgrund einer analytischen Ermittlung erfolgen. Bei der analytischen Ermittlung können Attribute für äußere Faktoren der beweglichen Elemente (wie z. B. Gewicht, Größe, etc.) berücksichtigt werden. Die Leistungsaufnahme muss immer dann neu bestimmt werden, wenn ein Prozess- oder ein Ressourcenzustand verändert wird.

Der Ablauf der Bestimmung einer Leistungsaufnahme ist also wie folgt:

1. Ein Materialflussereignis der Simulationsumgebung oder ein Steuersignal eines übergeordneten Systems lösen einen Prozess aus.
2. Auf Basis des durchzuführenden Prozesses werden Prozesszustände gesetzt und ggf. der Betriebsmodus des Verbrauchers geändert.
3. Abhängig vom gesetzten Betriebsmodus und den Prozesszuständen werden benötigte Ressourcen aktiviert oder deaktiviert. Hierfür wird auf hinterlegte Kombinationen aus Ressourcenzuständen zurückgegriffen, die für einen Betriebsmodus oder Prozesszustand benötigt werden. In einer sogenannten Überföhrungsfunktion ist die Kombination aus Betriebsmodi und Ressourcenzuständen hinterlegt. Üblicherweise sind in einem Betriebsmodus bestimmte Ressourcen bereits aktiviert. Für die Durchführung eines Prozesses werden zusätzliche Ressourcen aktiviert, die nach Beendigung des Prozesses wieder deaktiviert werden, sodass wieder nur die ursprünglichen Ressourcen für die Erreichung eines Betriebszustands aktiviert sind.
4. Die Leistungsaufnahme des Verbrauchers wird bestimmt. Diese wird über die benötigten Leistungsaufnahmewerte der Ressourcen und zusätzlich über die des Prozesses bestimmt. Für den Prozess kann ebenso wie bei den Ressourcen ein fester Wert oder eine analytische Methode mit Berücksichtigung der Beschaffenheit der äußeren Faktoren für die Ermittlung des Leistungsbedarfs hinterlegt sein.
5. Die aktuelle Leistungsaufnahme wird an eine zentrale Komponente, den sogenannten Energiebeobachter, übermittelt.

Eine Besonderheit stellen die allgemeinen Verbraucher dar. Hier erfolgt die Änderung der Betriebszustände über eine definierte Liste von Zeitpunkten. So können zum Beispiel das Ein-

bzw. Ausschalten der Beleuchtung oder typische Bürozeiten abgebildet werden. Eine Betrachtung von Prozessenergie erfolgt für diese Verbrauchsgruppe nicht.

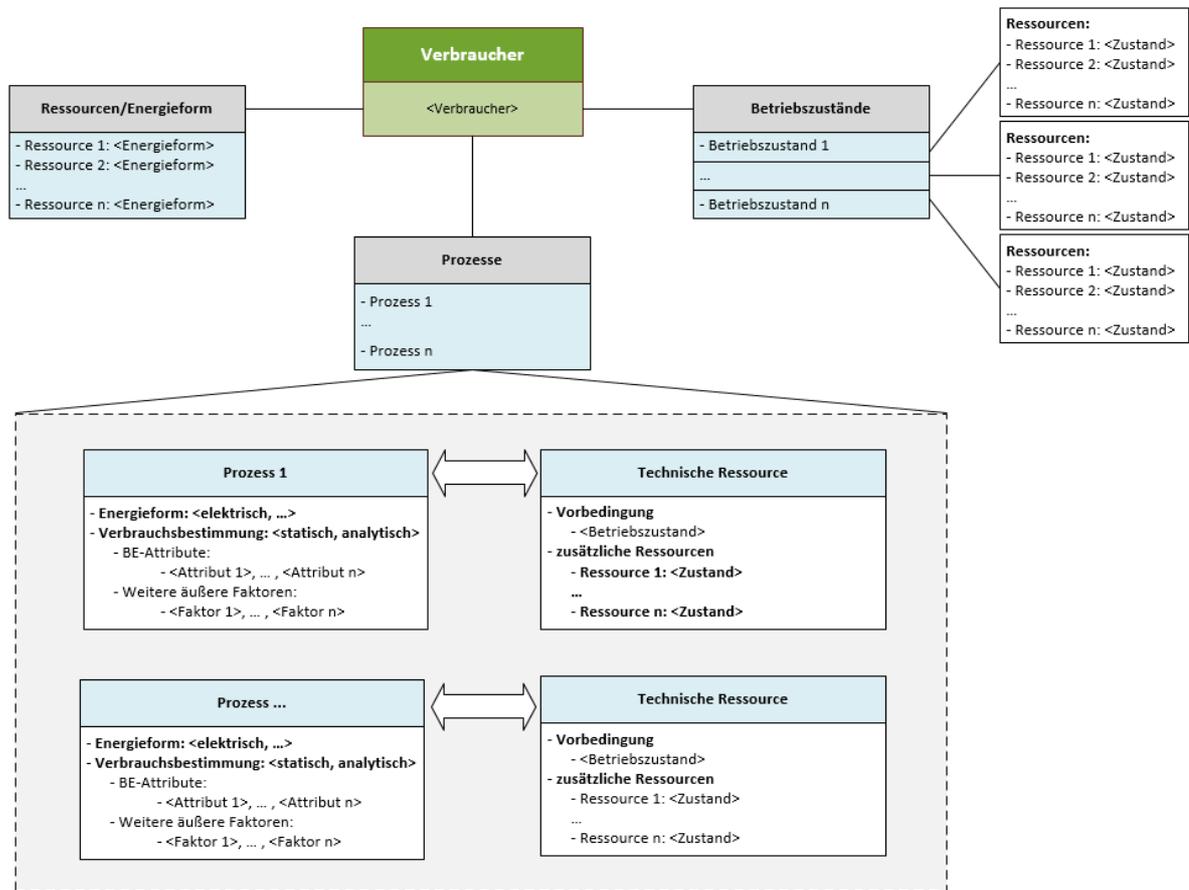


Abbildung 33: Generisches Beschreibungsschema eines Verbrauchers (in Anlehnung an [Gru16])

Der Energiebeobachter sammelt, aggregiert und visualisiert alle Daten zur elektrischen Leistungsaufnahme des Simulationsmodells. Dazu werden bei Änderung des Betriebsmodus oder des Prozesszustands entsprechende Daten wie etwa die Simulationszeit, also der Zeitpunkt der Änderung, Ressourcen oder Prozesse und entsprechende Leistungsaufnahmen für einzelne Verbraucher übermittelt. Über Verbraucherklassen (z. B. Krane) lassen sich die Daten für einzelne Verbrauchsgruppen aggregieren, bevor eine Gesamtaggregation erfolgt. Über das Bilden von 15-minütigen Zeitscheiben kann der Lastgang sowohl der einzelnen Verbraucher, als auch der Verbrauchsgruppen und insgesamt ermittelt werden.

Abbildung 33 zeigt ein Beschreibungsschema für die an der Ermittlung der Leistungsaufnahme beteiligten Komponenten und Prozesse. In der obersten Ebene, der technischen Ebene, steht der Verbraucher im Mittelpunkt. Diesem sind Ressourcen, Prozesse und Betriebszustände zugeordnet. Ressourcen repräsentieren die Systemkomponenten, die je nach Betriebszustand aktiviert oder deaktiviert werden. Für die Durchführung eines Prozesses können dann zum Start des Prozesses zusätzliche Ressourcen für die Durchführung benötigt werden. Für diese können dann Attribute der beweglichen Elemente (BE) und weitere äußere Faktoren berücksichtigt werden.

Vereinfachtes Beispiel: Kaikran

Für einen Kaikran können unter anderem die Ressourcen Fahrmotor, Hubmotor, Steuerung, Motorkühlung, Beleuchtung und Heizung modelliert werden. Im Betriebszustand „Aus“ ist keine der Ressourcen aktiv. Im Betriebszustand „Standby“ ist die Steuerung und die Beleuchtung im Zustand „Umfeldbeleuchtung“ aktiviert. Wechselt der Betriebszustand in „Betriebsbereit“, so werden Motorkühlung und Heizung aktiviert und die Beleuchtung wechselt in den Zustand „Flutlicht“. Für den Prozess „Containerumschlag“, der mit dem Eintreffen eine BE „Container“ startet und für den die Vorbedingung gilt, dass der Betriebszustand „Betriebsbereit“ gilt, wird die zusätzliche Ressource „Hubmotor“ benötigt. Die Leistungsaufnahme des Hubmotors ist dabei abhängig von der Hubhöhe und von der Größe und dem Gewicht des Containers. Sie wird analytisch in Abhängigkeit der Attributwerte ermittelt. Verlässt die BE „Container“ den Kaikran, so endet der Prozess und die ermittelte Leistungsaufnahme wird mit den Zeitstempeln des Starts und des Endes des Prozesses an den Energiebeobachter übermittelt.

Zusätzlich zu den Daten der obigen Abbildung wird eine Tabelle benötigt, in der für jeden Prozess und jede Ressource entweder ein fester Verbrauchswert oder eine Formel für die analytische Ermittlung der Leistungsaufnahme hinterlegt ist.

5.6.2 Das Power Consumption Terminal Modell

Das generische Konzept der zustandsbasierten Abbildung von Energieverbrauchsprozessen in ereignisdiskreten Simulationen kann genutzt werden, um darauf aufbauend ein Simulationsmodell eines Containerterminals zu erstellen, welches die Logistik- und Energieverbrauchsprozesse integriert abbildet. Grundlage für einen Simulationslauf sind dabei die Daten einer Segelliste, die für den entsprechenden Simulationszeitraum hinterlegt sein müssen. Die Daten der Segelliste bestimmen die Zeitpunkte der Schiffsankünfte und die Gesamtliegедauer, die für den Umschlag der Container, die diesem Schiff zugeordnet sind, zur Verfügung steht. Jedes Terminal hat ein eigenes Layout, d. h. eine eigene Anordnung der Zu- und Abfahrten, der Lagerbereiche, der Schiffsliegепläтze und internen Transportbereiche. Unter Berücksichtigung dieses Layouts müssen vier Kernbereiche modelliert werden:

- *Schiffsankunftsbereich* mit den Objekten:
 - Kaimauer
 - Containerschiff
 - Container
 - Containerbrücke
- *Lagerbereich* mit den Objekten:
 - Blocklager
 - Kühlcontainerlager
 - Portalkran
- *Horizontaltransportbereich* mit den Objekten:
 - Wegenetz
 - Transportfahrzeug
- *Hinterlandanbindung*

Der Schiffsankunftsbereich enthält die Liegeplätze der Schiffe an der Kaimauer und die Containerbrücken, welche für das Be- und Entladen der Containerschiffe verantwortlich sind. Ankommenden Schiffen wird ein eindeutiger Liegeplatz an der Kaimauer zugeordnet. Im Lagerbereich werden die Blocklager mit den Portalkränen abgebildet. Besondere Lagerbereiche sind für Kühlcontainer vorzusehen. Diese müssen auch speziell überwacht werden, denn ihre Leistungsaufnahme ist zum Teil abhängig von der Außentemperatur. Der Horizontaltransportbereich stellt die Schnittstelle zwischen Schiffsankunftsbereich und Lagerbereich dar, in dem Transportfahrzeuge den Containertransport übernehmen. Das Wegenetz des Terminals kann als Graph hinterlegt werden. Im Hinterlandbereich erfolgt der An- und Abtransport der Container per LKW oder Bahn.

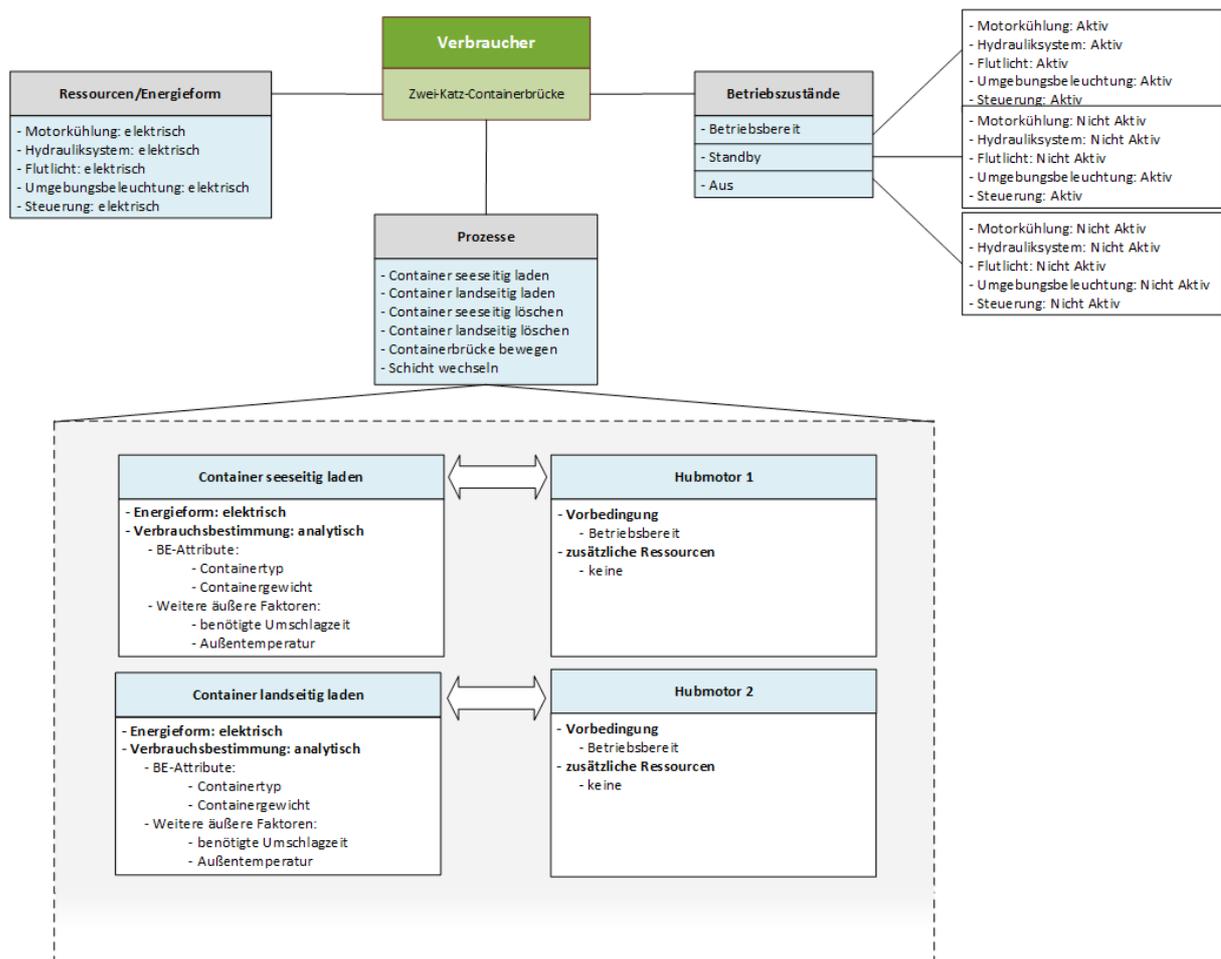


Abbildung 34: Beschreibung einer Zwei-Katz-Containerbrücke als Verbraucher (Auszug)

Abbildung 34 zeigt beispielhaft einen Auszug aus der Beschreibung einer Zwei-Katz-Containerbrücke aus dem Schiffsankunftsbereich. Für die drei definierten Betriebszustände sind jeweils die Zustände der Ressourcen hinterlegt. Von den sechs definierten Prozessen sind zwei beispielhaft auf der Prozessebene dargestellt. Jeder Prozess benötigt einen anderen Motor. Der Prozess „Containerbrücke bewegen“ benötigt noch die dritte technische Ressource „Fahrmotor“. Für eine detaillierte Beschreibung der Modellierung einzelner Entitäten aus den verschiedenen Bereichen sei hier auf [Gru16] verwiesen.

Neben den vier Kernbereichen müssen Generatoren, Steuerungen und allgemeine Verbraucher ebenfalls im Simulationsmodell abgebildet werden. Die Generatoren sind dafür zuständig basierend auf der Segelliste die Containerschiffe und die darauf befindlichen Container für die Entladung zur richtigen Simulationszeit zu generieren. Container, die per LKW oder Bahn an bzw. abtransportiert werden können heuristisch basierend auf Vergangenheitsdaten generiert werden oder zufällig unter Berücksichtigung ihres Umschlagzeitpunkts. Die Steuerungen kapseln Aufgaben des Terminal Operating System (TOS) und übernehmen das Lösen der Planungsprobleme aus Tabelle 13. Dazu sind entsprechende Algorithmen oder Regeln zu hinterlegen.

Abbildung 35 zeigt den Simulationsablauf in Bezug auf das Abfertigen eines Containerschiffs⁷ als UML-Aktivitätsdiagramm. Erreicht die Simulationszeit einen Zeitpunkt zu dem in der initial hinterlegten Segelliste eine Schiffsankunft aufgeführt ist, so wird das entsprechende Objekt „Containerschiff“ erstellt und mit ihm alle zu entladenden Container als bewegliche Einheiten. Das Containerschiff bekommt einen Liegeplatz zugewiesen und für den Containerumschlag benötigte Kaikräne werden dem Schiff an dem entsprechenden Liegeplatz zugeordnet. Da zu diesem Zeitpunkt alle beteiligten Kräne und Containerinstanzen bekannt sind, werden den Kränen die Umschlagaufträge zugeordnet. Für die Fahrzeuge des Horizontaltransportbereichs werden Transportaufträge von den entsprechenden Übergabepunkten an den Kränen erstellt. Sind die Kaikräne in Position und warten Fahrzeuge an den Übergabepunkten bei den Kränen, erfolgt der Umschlag eines Containers. Die Allokation der Transportaufträge erfolgt in Abhängigkeit der jeweils zu dem Zeitpunkt jeweils zu transportierenden Container und dem Start- und Zielübergabepunkt. Dabei kann ein Transportauftrag auch aus einzelnen Teilaufträgen bestehen. Ist einem Fahrzeug aktuell kein Transportauftrag zugeordnet, so fährt es in einen Wartebereich und steht von dort aus für weitere Aufträge aus zur Verfügung. Fahrten zum Nachladen der Antriebsenergie (z. B. Diesel tanken oder Batterie laden bzw. tauschen) unternimmt ein Fahrzeug selbstständig, sobald ein bestimmter Füllstand unterschritten wird. Der Umschlag und Transport der Container erfolgt so lange, bis alle dem Containerschiff zugeordneten Container umgeschlagen sind. Ist dies erfolgt, wird die Instanz des Objektes „Containerschiff“ gelöscht.

Abbildung 35 zeigt als Ausschnitt nur einen wesentlichen Ausschnitt des Prozessablaufs des Modells und verweist auf weitere detailliertere Unterprozesse (Kranbewegung, Ausführung von Transportaufträgen, etc.). Weitere Prozesse, die es abzubilden gilt, sind u. a. die Anlieferung der Container per Bahn oder LKW, die Energiebereitstellung für die Transportfahrzeuge oder das Ein- bzw. Auslagern von Kühlcontainern.

7 Auf die Darstellung der Entscheidungsparameter bei Verzweigungen in der Abbildung wurde zu Gunsten der Übersichtlichkeit verzichtet.

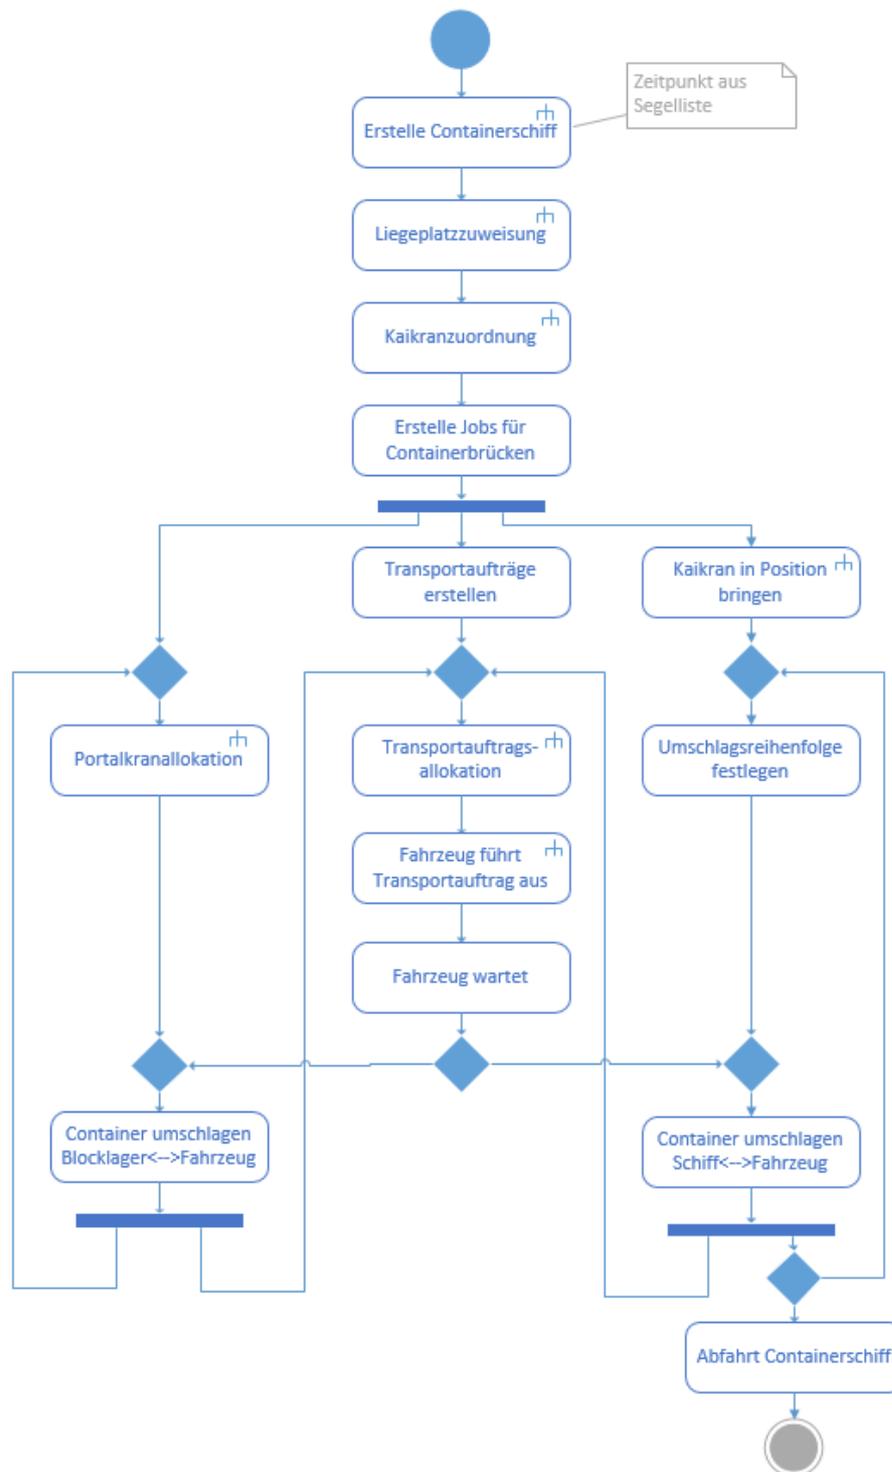


Abbildung 35: Simulationsablauf für die Abfertigung eines Schiffes

Für die zu lösenden Planungsprobleme sind dabei immer die Umschlagprozesse aller vor Anker liegenden Containerschiffe zu beachten. So kann es sein, dass bei Ankunft eines zusätzlichen Schiffes Kaikräne von einem in diesem Moment bearbeiteten Schiff abgezogen werden, da der Umschlag am anderen Schiff eine höhere Priorität einnimmt. In diesem Fall muss die

Umschlagreihenfolge für die übrigen Kräne neu angepasst werden und die Transportauftragsallokation entsprechend geändert werden. Die Strategien für die Problemlösung können für jedes Terminal individuell sein und sollten sich so weit wie möglich an den tatsächlich implementierten Strategien des abgebildeten Terminals orientieren. Es ist auch möglich verschiedene Strategien für die Problemlösung zu hinterlegen, um die Auswirkungen dieser Strategien am Simulationsmodell zu testen. Das betrifft sowohl die Auswirkungen auf die logistischen Prozesse als auch die Prozesse für die damit verbundenen Leistungsaufnahmewerten.

5.6.3 Zusammenfassung: Nutzung als Prognoseverfahren für den Lastgang eines Containerterminals

In den vorangegangenen Kapiteln wurde ein Konzept für die Erstellung eines Simulationsmodells eines Containerterminals für die Lastgangprognose vorgestellt. Das Simulationsmodell bildet die logistischen Prozesse und den damit einhergehenden Lastverlauf basierend auf der Segelliste ab. Ein Simulationslauf muss dabei immer auch vorhergehende Tage betrachten, um einen sinnvollen Zustand am Start des zu prognostizierenden Tages durch Abbildung der Vortagsprozesse abzubilden.

Die Erstellung eines Simulationsmodells für die Prognose des täglichen Lastgangs ist mit einem hohen Aufwand verbunden. Neben einer möglichst umfassenden Abbildung der Logistikprozesse eines Containerterminals müssen auch Daten oder Heuristiken über den Einfluss einzelner Prozessschritte auf den Energiebedarf des an dem Prozess beteiligten Umschlaggerätes bekannt sein und modelliert werden. Damit ist ein Simulationsmodell eines Containerterminals immer höchst individuell auf das abgebildete Terminal zugeschnitten und kann nicht für andere Terminals eingesetzt werden. Der hohe Aufwand für die Modellierung wird mit einer sehr detaillierten Aufschlüsselung der Prognose über die Zusammensetzung des Lastgangs aus Einzelverbräuchen und Verbrauchsgruppen belohnt. So ermöglicht die Simulation zusätzlich eine Analyse der Auswirkung von verschiedenen Betriebsstrategien auf den Lastverlauf, welche mit den anderen, bisher vorgestellten Verfahren nur schwer umsetzbar wären. So kann mit Hilfe eines Simulationsmodells zusätzlich zu den Auswirkungen von verschiedenen Strategien im Bereich der Logistik auch bereits vorab die Auswirkungen von Demand Response- oder Demand Side Management-Maßnahmen überprüft werden.

5.7 Zusammenfassung

In den vorangegangenen Kapiteln wurden Konzepte für die Lastgangprognose von maritimen Containerterminals vorgestellt. Zuerst wurde die Lastgangprognose innerhalb der Architektur eines Energiemanagementsystems verortet.

Die Vorverarbeitung der Betriebsdaten ist ein entscheidender Schritt im Rahmen der Erstellung der Prognose und für fast alle Verfahren relevant. Es wurde erläutert, wie man über die Segelliste als zentrales Planungselement für die Betriebsabläufe eines Containerterminals zu einem Containerprofil kommen kann, welches die Containerbewegungen über die Zeit darstellt. Sowohl die Segelliste an sich, die tägliche Segelliste als auch das Containerprofil können als Eingabeparameter für verschiedene Prognoseverfahren genutzt werden, die dann in den folgenden Kapitel konzeptionell vorgestellt wurden.

Prognoseverfahren	Wesentliche Eingabedaten für die Prognoseerstellung	Weitere genutzte Eingabedaten für die Prognoseerstellung	Wissen über Betriebsabläufe wird im Modell integriert über ...
Vergleichstag	Historische Lastgangdaten	-	-
Fallbasierte Prognose	Tägliche Segelliste	Wetterdaten, Kalenderdaten, Containerprofil (für Adaption), langfristige Entwicklung	Ähnlichkeitsmodellierung, Fallbasis, Adaptionsregeln
Künstliche Neuronale Netze	Containerprofil	Wetterdaten, Kalenderdaten, langfristige Entwicklung	Gelernte Strukturen aus Vergangenheitsdaten
Statistische Verfahren (ARIMA)	Historische Lastgangdaten	Containerprofil, Wetterdaten, Kalenderdaten	Externe Regressoren (Containerprofil)
Simulation	Segelliste	Historische Lastgangdaten, Daten zur Hinterlandanbindung	Simulationsmodell

Tabelle 14: Zusammenfassung der genutzten Eingabedaten der verschiedenen Prognoseverfahren

Für die einzelnen Verfahren zeigt Tabelle 14 in der Übersicht die genutzten Daten. Das Vergleichstagsverfahren nutzt lediglich historische Lastgangdaten für die Prognose. Die ARIMA-Modelle, die den weiteren Verlauf einer Zeitreihe aus den autoregressiven Zusammenhängen der historisch gemessenen Zeitreihen herleiten, nutzen neben den historischen Lastgängen weitere Eingabedaten als externe Regressoren, die jeweils für den historischen Zeitraum, als auch für den Prognosezeitraum zur Verfügung stehen müssen. Dies sind das Containerprofil, Informationen zum Tagestyp und Wetterdaten. Die Fallbasierte Prognose nutzt die Daten der täglichen Segelliste, angereichert mit Kontextinformationen zu Temperatur, Windgeschwindigkeit, Tagestyp und aus der Segelliste abgeleitete Werte für eine ähnlichkeitsbasierte Suche. Für die nachgelagerte Adaption werden das Containerprofil und Wetterdaten genutzt und zudem können Faktoren die die langfristige Entwicklung berücksichtigen, eingebracht werden. Das Künstliche Neuronale Netz nutzt für die eigentliche Prognoseerstellung das Containerprofil, Informationen zum Tagestyp und Wetterdaten als Eingabedaten. Für das vorgelagerte Training werden diese als historische Daten benötigt und die entsprechenden Lastgangdaten als gewünschte Ergebnisse. Die Simulation nutzt die unbearbeitete Segelliste für den Simulationslauf und zusätzlich Daten für die Hinterlandanbindung. Historische Lastgangdaten werden benötigt, um die Grundlast auf Basis von Vortagesdaten zu kalibrieren.

6 Evaluation am Fallbeispiel Container Terminal Altenwerder

Die Evaluation der verschiedenen Lastgangprognoseverfahren soll am Fallbeispiel des Container Terminal Altenwerder (CTA) in Hamburg durchgeführt werden. Das Terminal zeichnet sich durch einen besonders hohen Grad der Automatisierung und Elektrifizierung ab und galt bei seiner Eröffnung im Jahr 2002 als das modernste Terminal in Europa. Für die Evaluation der oben konzeptionierten Verfahren liegen die Segellisten mit entsprechenden Containerumschlagzahlen pro Schiff für die Jahre 2010 bis 2014 vollständig vor. Gleiches gilt für die Lastgänge der entsprechenden Jahre, diese liegen in einer 15-minütigen Auflösung vor.

6.1 Umsetzung

Im Folgenden wird die Umsetzung der einzelnen Verfahren nach der Konzeption aus Kapitel 5 beschrieben. Damit sollen die spezifischen Eigenschaften für die Implementierung des Fallbeispiels dargestellt werden und nachvollziehbar gemacht werden.

6.1.1 Vergleichstagverfahren

Für die Evaluation wurde das Vergleichstagverfahren in vier verschiedenen Varianten umgesetzt, wobei D immer den eigentlichen Tag der Prognoseerstellung beschreibt und D+1, den Tag, für den die Prognose erstellt wird, also den direkten Folgetag von D:

- *Vergleichstag Vortag (D-1)*: In dieser Variante wird am Tag D der Lastgang des vergangenen Tages (D-1) als Prognose für D+1 genutzt.
- *Vergleichstag Vorwochentag (D-6)*: In dieser Variante wird am Tag D der Lastgang desselben Wochentages (D-6) als Prognose für D+1 genutzt.
- *Gewichtete Vortage*: In dieser Variante werden am Tag D die Lastgänge der vier Vortage (D-1, D-2, D-3, D-4) genutzt um die Prognose für D+1 zu erstellen. Die einzelnen Lastgänge der Vortage werden mit der geometrischen Reihe gewichtet.
- *Gewichtete Vorwochentage*: In dieser Variante werden am Tag D, die Lastgänge der vier Vorwochentage (D-6, D-13, D-20, D-27) genutzt um die Prognose für D+1 zu erstellen. Die einzelnen Lastgänge der Vorwochentage werden mit der geometrischen Reihe gewichtet (vgl. Formel 26).

Ausnahmen in der Umsetzung erfolgten für Feiertage und Tage vor und nach den Feiertagen. Hier wurde in allen Varianten auf die Vorjahreswerte des gleichen Feiertags zurückgegriffen. Der Lastgang des entsprechenden Vorjahrestages wurde hierbei in allen Varianten als Prognose genutzt.

6.1.2 Fallbasierte Lastgangprognose

Um die Anwendbarkeit des im Kapitel 5.3 beschriebenen Konzepts zu überprüfen, wurde ein fallbasiertes System entwickelt. Dieses setzt die beschriebenen Vorgehensweisen um. Als Da-

tengrundlage dienen die vorliegenden Daten des Container Terminal Altenwerder für die Jahre 2010 bis 2014. Für die Umsetzung des Konzeptes wurde auf das Software Development Kit (SDK) des Tools myCBR [Dfki17] zurückgegriffen, welches als Open Source Software verfügbar ist. myCBR unterstützt die Datenmodellierung durch vordefinierte Datentypen und durch integrierte Bausteine für einfache Ähnlichkeitsmaße. Allerdings stehen nicht für alle Datentypen Ähnlichkeitsmaße zur Verfügung, die Integration von eigenen Ähnlichkeitsmaßen ist aber problemlos möglich.

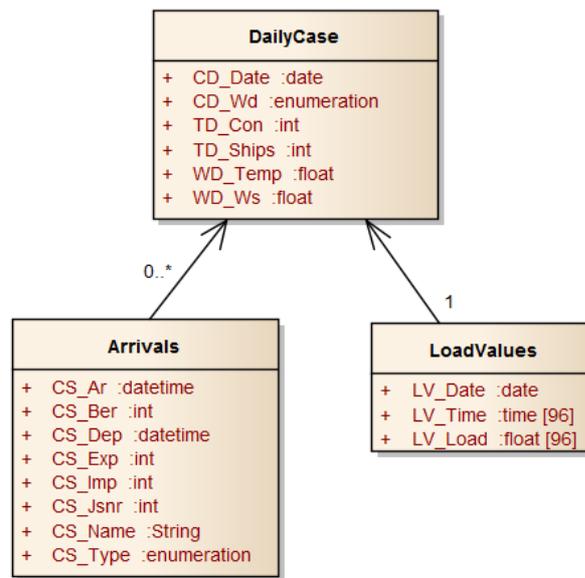


Abbildung 36: Datenmodellierung für die Fallbasis

Die Fallmodellierung wurde entsprechend dem Konzept vorgenommen, wonach zuerst die Segellisteneinträge importiert wurden und anschließend tagesgültige Fälle erstellt wurden. Die Daten wurden direkt aus csv-Dateien in das Fallformat importiert und die Fallbasis gefüllt. Ausnahme bilden die Lastgangdaten, die in einer Datenbank hinterlegt wurden, von der aus sie effizient abgefragt werden können. Für die Wetterdaten der Fälle wurde auf historische Wetterdaten vom Deutschen Wetterdienst zurückgegriffen. Um für Anfragen auch Wetterprognosen zu berücksichtigen, wurde zusätzlich eine Webservice-Schnittstelle zu einem Wetterdienstleister implementiert, von dem die Wetterdaten für Anfragen abgerufen werden. Abbildung 36 stellt das implementierte Fallformat noch einmal exemplarisch dar. Nach Übernahme aller Daten für die Jahre 2010 bis 2014 besteht die Fallbasis aus mehr als 24.000 einzelnen Einträgen der täglichen Segelliste und 1825 Fällen, die jeweils einen Tag repräsentieren.

Die verwendeten Ähnlichkeitsmaße und deren Parameter sind in Tabelle 15 aufgeführt. Auch hier wurde sich an das zuvor beschriebene Konzept gehalten. Für die Schiffstypen wurde eine geordnete Liste zur Verfügung gestellt, der eine Auswertung der durchschnittlichen Anzahl von Containerumschlägen pro Schiffstyp zugrunde liegt. Dieses Vorgehen wurde gewählt, da in den vorhandenen Datensätzen lediglich verschiedene Typen von Seeschiffen unterschieden wurden. Im Gegensatz dazu wurden Kähne und Feeder nicht weiter unterteilt, sodass sich

durch den Aufbau einer vollständigen Taxonomie und einer darauf basierenden Berechnung der Ähnlichkeiten keine Vorteile erwarten ließen.

Für die Wochentage wurde eine Ähnlichkeitstabelle erstellt, die manuell mit Ähnlichkeitswerten befüllt wurde. Die Ähnlichkeitswerte basierten auf einer Auswertung der Lastgangdaten für das Jahr 2012, wonach Wochentage wenige Unterschiede im Lastgang aufwiesen, sich zu Tagen am Wochenende aber im Lastverlauf unterschieden. Am Wochenende waren zwischen Samstag und Sonntag auch noch deutliche Unterschiede im durchschnittlichen Lastverlauf zu erkennen. Von diesen Tagen komplett verschieden verhalten sich die Feiertage und die Tage vor und nach Feiertagen (vgl. Kapitel 4.2). Die Ähnlichkeitstabelle wurde dabei symmetrisch gehalten.

Attribut	Datentyp	Ähnlichkeitsmaß	Parameter
CS_{JSNR}	Integer	Nicht relevant	
CS_{Name}	String	Nicht relevant	
CS_{Type}	Enumeration	Geordnete Reihe	Durchschnittliche Anzahl von Containerumschlägen pro Schiffstyp
CS_{Ar}	Datum	Sigmoid	$\alpha = 10, \theta = 50$
CS_{Dep}	Datum	Sigmoid	$\alpha = 10, \theta = 50$
CS_{Ber}	Integer	Exponentiell	$\alpha = 5$
CS_{Imp}	Integer	Sigmoid	$\alpha = 100, \theta = 500$
CS_{Exp}	Integer	Sigmoid	$\alpha = 100, \theta = 500$
WD_{Temp}	Float	Exponentiell	$\alpha = 2$
WD_{Ws}	Float	Exponentiell	$\alpha = 1,5$
CD_{Wd}	Enumeration	Tabellarisch	
CD_{Date}	Date	Nicht relevant	
TD_{Con}	Integer	Exponentiell	$\alpha = 3$
TD_{Ships}	Integer	Linear	

Tabelle 15: Ähnlichkeitsmaße und deren Parameter für das Fallbeispiel CTA

Für die Gewichtung des globalen Ähnlichkeitsmaßes wurde der Lernalgorithmus von Stahl auf die Daten des Jahres 2012 angewendet. Dafür wurden verschiedene Varianten gebildet, für die ein rein ähnlichkeitsbasiertes Retrieval durchgeführt wurde, ohne nachgelagerte Adaption. Abbildung 37 zeigt den Verlauf für die Variante G01_2_2012. Bei dieser Variante wurden zum Start alle Attribute für die Aggregationsfunktion des globalen Ähnlichkeitsmaßes gleich gewichtet. Die initiale Lernrate wurde auf 0,1 festgesetzt und Alpha auf 2 gesetzt, um die Unterschiede in den Entfernungen bezüglich der Reihenfolge der Fälle zu betonen. In dem Diagramm ist deutlich zu erkennen, wie der durchschnittliche Ähnlichkeitsfehler (englisch: Average Similarity Error) zu Beginn recht schnell abfällt und anschließend konvergiert. In einigen Fällen steigt er wieder um geringe Werte. Die entsprechenden Gewichtsvektoren bei steigendem Ähnlichkeitsfehler werden wieder verworfen und es wird mit einer geringeren Lernrate

fortgefahren. Dies ist auch im letzten Durchgang der Fall, weshalb der Gewichtsvektor aus Durchgang 26 das Ergebnis dieser Variante darstellt. Das Unterschreiten einer bestimmten Lernrate wurde als Abbruchkriterium für den Algorithmus festgesetzt.

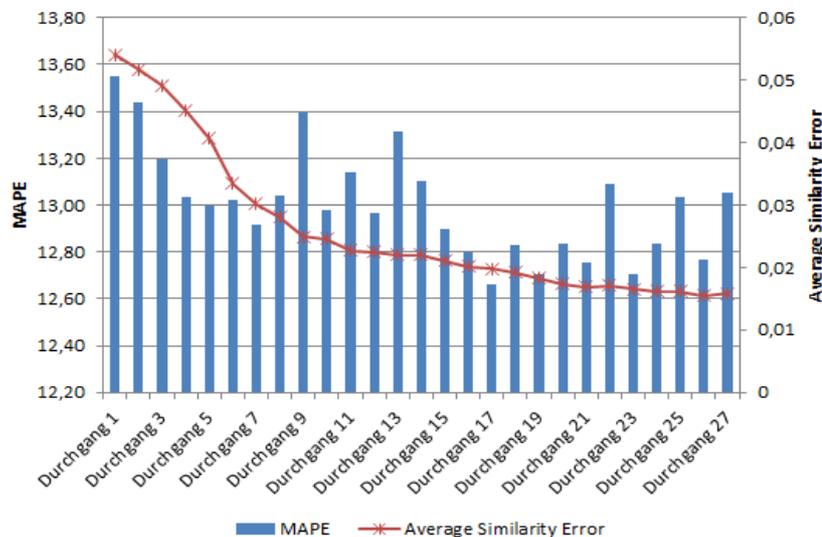


Abbildung 37: Verlauf des MAPE und des Average Similarity Error für Variante G01_2_2012

In dem Diagramm ist auch zu erkennen, dass sich die durchschnittliche prozentuale Abweichung des Prognoseergebnisses (MAPE) nicht immer im Einklang mit dem sinkenden Ähnlichkeitsfehler befindet. Besonders deutlich wird dies in Durchgang 9 in Abbildung 37. Dies lässt sich vermutlich darauf zurückführen, dass bereits sehr gering unterschiedliche Werte einzelner Attribute schon zum Ähnlichkeitsfehler beitragen und diese sehr geringen Unterschiede bereits das Ergebnis verfälschen können. Nichtsdestotrotz ist zu erkennen, dass mit einer optimierten Gewichtung die durchschnittliche prozentuale Abweichung der Prognose von den tatsächlich gemessenen Werten gesenkt werden kann. Weitere Varianten wurden mit einer veränderten Startgewichtung („Expertengewichtung“), einer anderen Lernrate oder einem veränderten Alpha durchgeführt. Die Verbesserungen des Prognoseergebnisses über die Durchgänge waren dabei bei einem Start mit einer gleichförmigen Gewichtung höher als die Verbesserungen bei dem Start mit einer vorgegebenen Gewichtung. Letztendlich wurde der Durchschnitt der drei Gewichtsvektoren mit den geringsten MAPE-Werten als Gewichtsvektor für das globale Ähnlichkeitsmaß gesetzt.

Für die Regeln zur fallbasierten Adaption, basierend auf den Unterschieden der Containerprofile der beiden betroffenen Tage, wurde eine systematische Auswertung über das Jahr 2012 vorgenommen. Dabei stellte sich heraus, dass eine zweigeteilte Betrachtung der Anpassung mit unterschiedlichen Faktoren für die Anfangs- und Endstunden des Lastgangs und für die mittleren Stunden eines Tages vorgenommen werden muss. Während an den Anfangs- und Endstunden des Tages Schwankungen der viertelstündlichen Leistungsaufnahme eher abhängig sind von Unterschieden in den Containerprofilen für diese Zeiträume, reagiert die Leistungsaufnahme in mittleren Tagesstunden träger. Daher wurde hier bei der Anpassung unterschieden. Abbildung 38 zeigt hinterlegte Regeln und Werte für die zweite Stunde des Tages

(02:00-03:00 Uhr) auf der linken Seite und für die achte Stunde (08:00-09:00 Uhr) des Tages auf der rechten Seite.

<i>hour i</i>	d_i	d_{i-1}	d_{i-2}	d_{i+1}	<i>factor</i>
2	>200	>150	> 0	>150	0.4
2	>150	>100	> 0	>100	0.3
2	>100	> 50	> 0	> 50	0.2
2	> 50	> 30		> 30	0.1
2	< -50	< -30		< -30	-0.1
2	< -100	< -70	< 0	< -70	-0.2
2	< -150	< -120	< 0	< -120	-0.3
2	< -200	< -150	< 0	< -150	-0.4

<i>hour i</i>	d_i	d_{i-1}	d_{i+1}	<i>factor</i>
8	>200	>150	>150	0.4
8	>150	>120	>120	0.3
8	>100	> 70	> 70	0.2
8	> 50	> 20	> 20	0.1
8	< -50	< -20	< -20	-0.1
8	< -100	< -70	< -70	-0.2
8	< -150	< -120	< -120	-0.3
8	< -200	< -150	< -150	-0.4

Abbildung 38: Anpassungsregeln und -werte für die Adaption auf Basis von Containerprofilen

d_i beschreibt die Differenz in den Containerprofilen des Anfragefalls und des gerade betrachteten ähnlichen Falls in der aktuellen Stunde, d_{i-1} und d_{i-2} die Unterschiede in der Stunde bzw. in zwei Stunden vor der betrachteten Stunde und d_{i+1} die Unterschiede in der Folgestunde. *factor* ist der Wert, der für die Lastgangwerte der betroffenen Stunde hinzuaddiert wird. Durch die Berücksichtigung der vorhergehenden und nachfolgenden Stunden wird sichergestellt, dass kurzzeitige Unterschiede in den Containerprofilen in den Auswirkungen gedämpft werden und dadurch keine kurzfristigen Spitzen entstehen.

Für die Auswertung der Prognoseergebnisse wurden in einem ersten Schritt aus den Daten der Jahre 2010 bis 2012 die Fälle für die Fallbasis generiert, es standen also anfangs lediglich 1096 Fälle zur Verfügung. Um das FBS-Ablaufmodell von Aamodt und Plaza (vgl. Abbildung 9) zu vervollständigen, wurden vor Durchführung einer Prognose die Segelliste und die echten Messdaten des zwei Tage vor dem Prognosetag liegenden Tages als neuer Fall in die Fallbasis mit aufgenommen. Zum Beispiel wurde vor der Prognose des 16.06.2013, der Fall für den 14.06.2013 in die Fallbasis integriert. Die Fallbasis stellt bei einer chronologischen Durchführung einer Prognose somit immer den aktuellsten Stand mit echten Messdaten zur Verfügung.

6.1.3 Zeitreihenanalyse

Das Vorgehen der Zeitreihenanalyse beginnt mit einer additiven Komponentenzerlegung der Zeitreihe mittels des Verfahrens „Seasonal Decomposition of Time Series by Loess“ (STL) [CCMT90]. Die Bestimmung der Saisonkomponente erfolgt durch Durchschnittsbildung über die einzelnen Zeitscheiben eines Tage für die vorhandenen Werte. Die Trendbestimmung erfolgt als geglättete lokal gewichtete Regression.

Abbildung 39 zeigt eine solche Zerlegung für die Lastgangdaten eines Monats. Der Lastgang an sich ist ganz oben als *data* abgebildet, darunter finden sich die extrahierten Saison- und Trendkomponenten der Zeitreihe. Die verbleibenden Werte („remainder“) sind die Abweichungen von den Trend- und Saisonwerten. Die saisonbereinigten Werte sind es, für die anschließend ein ARIMA-Modell angepasst wird. Dabei werden die weiteren Daten wie Wetter-

daten oder Wochentagsfaktoren als externe Regressoren genutzt. Der Vorteil in der vorangehenden Komponentenzerlegung liegt darin, dass bei der anschließenden Suche nach einem passenden ARIMA-Modell mit dem Hyndman-Khandakar-Algorithmus saisonale ARIMA-Modelle vernachlässigt werden können und damit der Algorithmus deutlich schneller zu einer Lösung kommt, da nur nicht-saisonale ARIMA-Modelle getestet werden. Für die Saisonkomponente wird davon ausgegangen, dass der Verlauf stabil ist, sodass eine naive Prognose für den weiteren Verlauf der Saisonkomponente ausreichend ist.

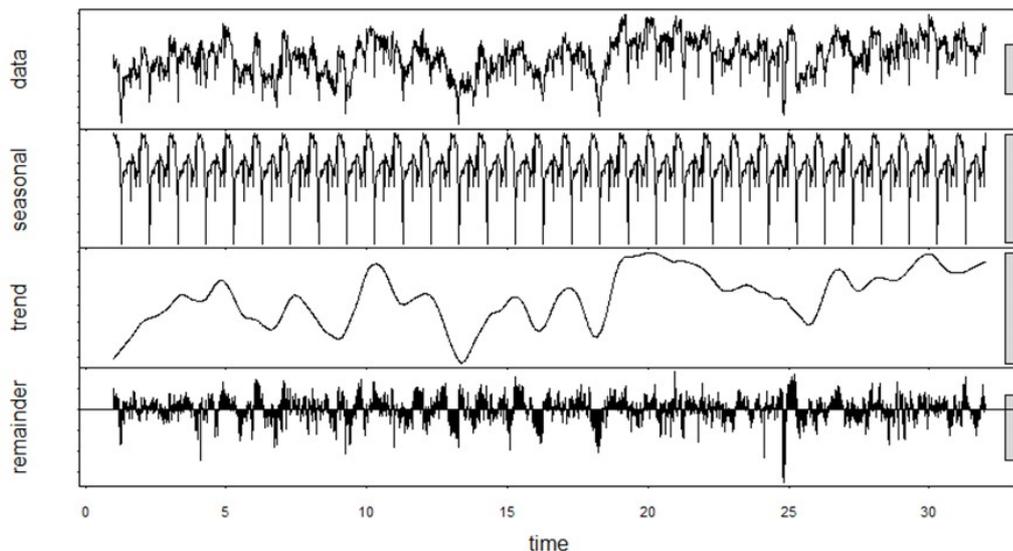


Abbildung 39: Zerlegung der Zeitreihe in Saison-, Trend- und verbleibende Komponente

Die ARIMA-Modellbestimmung erfolgt dynamisch neu mit jeder Prognose, um aktuelle Entwicklungen in den Lastverläufen adäquat zu berücksichtigen. Keine generelle Aussage gibt es dazu, wie weit zurück die historischen Werte der Zeitreihe sinnvollerweise betrachtet werden sollen. Hyndman [Hynd14] führt an, dass ARIMA-Modelle bei Zeitreihen mit besonders vielen historischen Werten Schwächen aufweisen, da die gebildeten Modelle aufgrund der Datenmenge zu weit von den tatsächlichen Daten abweichen, um alle Effekte des zugrunde liegenden Prozesses abbilden zu können. Um dies zu überprüfen wurden verschiedene Testreihen mit einer unterschiedlichen Anzahl von historischen Lastgängen sowohl für das gesamte Jahr 2013, als auch für das Jahr 2014, durchgeführt. Die Ergebnisse sind in Abbildung 40 aufgeführt und beinhalten noch keine externen Regressoren. Um dem Umstand gerecht zu werden, dass an einem Tag D die Prognose für den Folgetag ($D+1$) erstellt wird, die eigentlichen Lastgangdaten für D aber noch nicht vollständig vorliegen, wurde der historische Lastgang nur bis einschließlich dem jeweiligen Vortag ($D-1$) genutzt. Es wurde also eine Prognose für den Zeitraum von jeweils zwei Tagen in die Zukunft erstellt und nur der zweite prognostizierte Tag in den Auswertungen betrachtet.

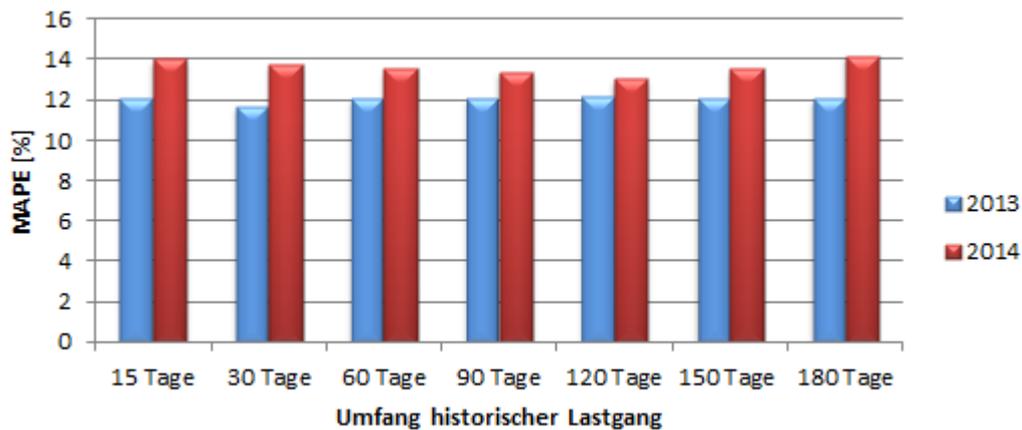


Abbildung 40: Entwicklung der ARIMA-Prognosegüte in Abhängigkeit der Anzahl vergangener Tage

Zu erkennen ist, dass es keinen systematischen Zusammenhang zwischen der Anzahl der berücksichtigten Lastgänge der Vergangenheit und der Prognosegüte gibt. Während in 2013 bei der Berücksichtigung von Lastgängen der vergangenen 30 Tage im Durchschnitt die beste Prognosegüte erreicht wird, ist dies für 2014 bei 120 Tagen der Fall. Die Unterschiede in der Prognosegüte sind allerdings über die verschiedenen Längen des historischen Lastgangs gering. Lediglich 15 Tage und 180 Tage lieferten durchweg schlechtere Ergebnisse. Auch historische Lastgänge der Werte eines ganzen Jahres oder von zwei Jahren brachten keine weiteren Vorteile. Dies gilt sowohl für die reinen ARIMA-Modelle, dessen Daten in Abbildung 40 gezeigt werden, als auch für die Modelle bei denen externe Regressoren integriert wurden. Auf diese Modelle wird in Kapitel 6.2.3 noch näher eingegangen. Das Ergebnis der Auswertungen zeigt, dass eine regelmäßige Überprüfung der Modellparameter notwendig ist und in der Betrachtung der historischen Prognosewerte eine Anpassung erfolgen kann, die aber nicht immer unbedingt eine erfolgreiche Verbesserung der Prognosegüte für die Zukunft versprechen kann.

6.1.4 Künstliche Neuronale Netze

Für die Prognose des Lastgangs des Container Terminal Altenwerder wurde entsprechend des in Kapitel 5.5 beschriebenen Vorgehens ein zweischichtiges Feedforward-Netz aufgespannt. In der Ausgangskonfiguration wurde für das Training des Netzes mittels des Resilient Backpropagation-Algorithmus das Containerumschlagprofil jeweils eines Tages mit viertelstündlichen Eingabewerten an die Input-Neuronen angelegt, der dazugehörige Lastgang als erwartete Ausgabe genutzt. Weitere Eingabewerte für den Tagestyp, die durchschnittliche Tagestemperatur und die Windgeschwindigkeit wurden sukzessive ergänzt. Für alle verwendeten Daten wurde eine Min/Max-Normalisierung auf das Intervall 0 bis 1 durchgeführt, bevor sie für das Netz genutzt wurden. Der positive Wertebereich, auf den die Daten über die Normalisierung einheitlich abgebildet wurden, führte zu einer Nutzung der sigmoiden Aktivierungsfunktion. Für eine Trainingsepoche wurden auf diese Weise alle Tage der Jahre 2010 bis 2012 für das Training genutzt. Mit diesem Modell wurde das Jahr 2013 getestet. Für die Tests des Jahres 2014 wurde das Netz mit allen zur Verfügung stehenden Daten der Jahre 2010 bis 2013 trainiert. Im Zuge des Trainings wurden die Daten für die Validierung, welche auf ca. 10 % der

Gesamtmenge der Trainingsdaten festgelegt wurden, regelmäßig gewechselt, um eine Überanpassung zu vermeiden. Für die Festlegung der Hyperparameter des Netzes wurde der Design of Experiment-Ansatz gewählt und über eine D-optimale Verteilung der folgenden Parameter eine entsprechende Auswertung durchgeführt:

- *Anzahl Trainingsepochen:* zwischen 1000 und 5000
- *Lernrate:* zwischen 0,05 und 0,5
- *Anzahl Neuronen in den verdeckten Schichten:* 30 bis 190

Die Wertebereiche für die Anzahl der Trainingsepochen wurden vorab durch verschiedene Trainingsläufe auf sinnvolle Werte eingegrenzt, die Wertebereiche für die Lernrate und die Anzahl der Neuronen in der verdeckten Schicht orientieren sich an diversen Daumenregeln, die für diese Art von Neuronalen Netzen aufgestellt wurden.

Im Zuge des Design-of-Experiment-Ansatzes wurde das Künstliche Neuronale Netz mit 24 verschiedenen Parameterkombinationen trainiert. Als Optimierungsziel wurde der MAPE-Wert für das Jahr 2013 genutzt. Die Experimente wurden bei gleicher Parameterkonstellation sowohl für ein Netz mit nur einer verdeckten Schicht, als auch für ein Netz mit zwei verdeckten Schichten durchgeführt und die Ergebnisse verglichen.

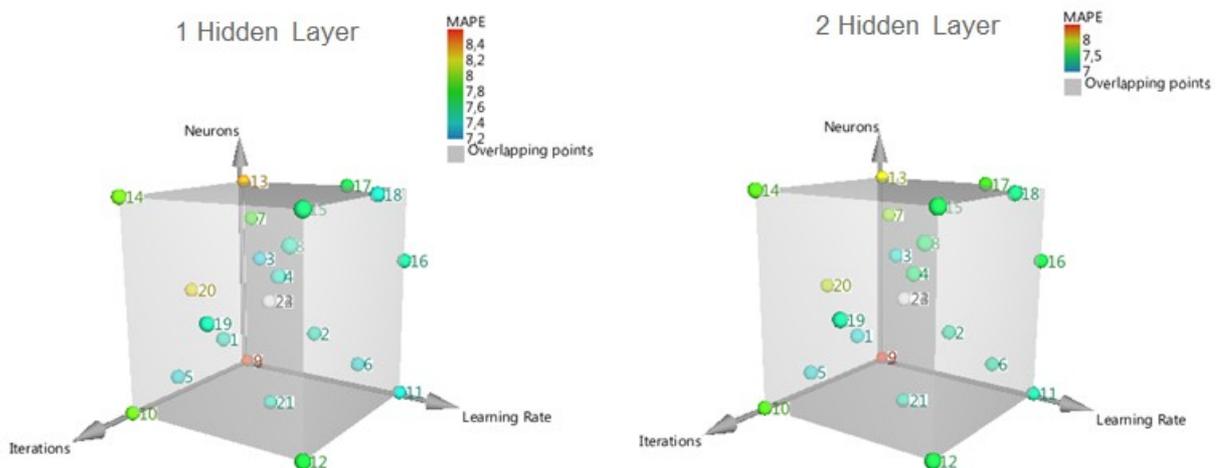


Abbildung 41: Darstellung der Auswertung zu verschiedenen Parameterkombinationen des KNN

Abbildung 41 zeigt die Auswertung der durchgeführten Experimente. Diese wurden mit den zusätzlichen Eingabedaten zum Tagestyp, der Temperatur und Windgeschwindigkeit durchgeführt. Die Darstellung zeigt, dass die Ergebnisse der Prognose bei der Verwendung von zwei verdeckten Schichten stabiler waren. Lediglich bei der Kombination der kleinstmöglichen Parameterwerte (30 Neuronen in der verdeckten Schicht, Lernrate 0,05 und 1000 Trainings-schritte) ist der Fehlerwert des KNN mit einer verdeckten Schicht geringer als der des KNN mit zwei verdeckten Schichten. Die Werte dieser Parameterkombination sind auch gleichzeitig die beiden höchsten Fehlerwerte in den durchgeführten Experimenten, wie aus Tabelle 16

hervorgeht. Dies liegt daran, dass die Anzahl der Trainingsschritte bei einer so geringen Lernrate nicht ausreicht, um die Neuronen bei zwei verdeckten Schichten ausreichend anzupassen.

	1 verdeckte Schicht		2 verdeckte Schichten	
	MAPE	Parameter ⁸	MAPE	Parameter
Niedrigster Fehlerwert	7,302	136/0,2/2333	7,203	83/0,2/3666
Höchster Fehlerwert	8,335	30/0,05/1000	8,473	30/0,05/1000

Tabelle 16: Höchste und niedrigste Fehlerwerte der KNN mit einer und zwei verdeckten Schichten

Hingegen unterscheiden sich die niedrigsten Fehlerwerte auch in der Parameterkombination. Hierbei ist auffällig, dass der niedrigste Fehlerwert bei einer verdeckten Schicht eine deutlich höhere Anzahl von Neuronen in der verdeckten Schicht aufweist, als bei zwei verdeckten Schichten. Dies ist darauf zurückzuführen, dass es bei zwei verdeckten Schichten insgesamt über die beiden Schichten eine deutlich höhere Anzahl von Neuronen und deren Verbindungen untereinander gibt als bei nur einer verdeckten Schicht. Dies spiegelt sich auch in der Anzahl der Lernschritte: Bei zwei verdeckten Schichten wurde überwiegend bei einer hohen Anzahl von Lernschritten ein gutes Ergebnis hervorgebracht. Beide Netzkonfigurationen erreichten den besten Fehlerwert bei einer Lernrate von 0,2. Die Konfiguration mit 83 Neuronen in zwei verdeckten Schichten erzielte nach einem Training mit 3666 Schritten bei einer Lernrate von 0,2 das beste Ergebnis und wurde damit als Konfiguration für die Hyperparameter gewählt.

6.1.5 Simulation

Für die Simulation des Container Terminal Altenwerder wurde das im Rahmen des Projektes BESIC [Bes16] erstellte und in [GHI+14] und [Gru16] beschriebene Simulationsmodell des Terminals genutzt. Im Rahmen der Entwicklung wurde das Power Consumption Terminal Modell auf der Simulationsplattform „Plant Simulation“ instanziiert. Die Simulationsplattform wurde dazu um die Energiebeobachter-Komponente erweitert. Abgebildet wurden entsprechend des Terminallayouts vier Schiffsliegeplätze, 14 Containerbrücken, ein AGV-Bereich für den Horizontaltransport mit 86 Transportfahrzeugen, einer Tankstelle und einer Batteriewechselstation, sowie 26 Blocklager mit jeweils zwei automatischen Portalkränen. Zusätzlich wurden Elemente für die Hinterlandanbindung, Beleuchtung und eine Grundlast eingebaut, um alle wesentlichen Verbraucher des CTA zu repräsentieren. Für die Planungsprobleme des Terminals wurden Strategien hinterlegt, die so weit wie möglich dem operativen Vorgehen des Terminals entsprechen.

Der Horizontaltransport wird im CTA mit AGVs abgewickelt, die einem vorgegebenen Fahrlayout folgen. Dieses wurde entsprechend nachgebildet. Bei den AGVs wurden sowohl Fahrzeuge mit diesel-elektrischem Antrieb, als auch Fahrzeuge mit batterie-elektrischem Antrieb abgebildet, wobei das Verhältnis von batterie-elektrischen AGV zu Diesel-AGV per Parameter

⁸ Die Parameter entsprechen in der Auflistung „Anzahl Neuronen in der verdeckten Schicht“/„Lernrate“/„Trainingsschritte“.

einstellbar ist, um den Ausbau der Flotte hin zu mehr batterie-elektrische AGV abbilden zu können. Für die Energiebereitstellung der Batteriefahrzeuge wurde eine Batteriewechselstation modelliert, die über eine eigene Fahrspur verfügt und entsprechend der Anzahl von Batterie-AGV auch Lagerplätze und Ladegeräte bereitstellt. Für das Laden der Fahrzeugbatterien wurde eine Strategie zum sofortigen Laden bei Kontaktierung des Ladegerätes implementiert.

Den Kränen des Modells wurden als Ressourcen die vom Containerumschlag unabhängige Leistungsaufnahme Beleuchtung, Klimaanlage, Hydraulikpumpen und Flutlicht zugeordnet, die je nach Betriebsart einen konstanten Wert annehmen. Für den Umschlag eines Containers wurden auf Basis von historischen Daten durchschnittliche Verteilungen von 20- und 40-Fuß-containern und deren Gewichte ermittelt. Aus einer Auswertung der Containerumschläge von Kaikränen am CTA und den dazugehörigen Leistungsaufnahmen, wurde der durchschnittliche Energiebedarf, sowie die durchschnittliche Zeit für einen Containerumschlag ermittelt. Auf Basis dieser historischen Daten wurde eine lineare Funktion abgeleitet, auf deren Grundlage die Leistungsaufnahme eines Containerumschlags beim Entladen von einem Containerschiff bzw. beim Beladen eines Containerschiffs während eines Simulationslaufes ermittelt wird. Zusätzlich wurde eine Wahrscheinlichkeitsverteilung der Zeit angenommen, die für den Umschlag eines Containers benötigt wird. Diese ist abhängig von der Klasse des zugeordneten Containerschiffes (Kahn, Feeder oder Seeschiff), um die unterschiedlichen Umschlagzeiten der Schiffstypen zu berücksichtigen. Gleiches gilt für die Ein- und Auslagerung in die Blocklager mittels Portalkran, wobei hier nur eine Wahrscheinlichkeitsverteilung hinterlegt wurde.

Kühlcontainer besitzen eine schwankende Leistungsaufnahme, die von verschiedenen Faktoren abhängt. Da diese Faktoren zum Durchführungszeitraum der Simulation nicht zur Verfügung stehen, wird eine durchschnittliche Leistungsaufnahme angenommen. In der durchschnittlichen Leistungsaufnahme werden statistische Ein- und Abschaltwahrscheinlichkeiten der Kühlaggregate berücksichtigt. Mit der Einlagerung eines Kühlcontainers in den Lagerbereich des Terminals beginnt auch die damit verbundene Leistungsaufnahme. Sobald ein Kühlcontainer eingelagert wurde, wird von der Instanz des entsprechenden Lagers ein Einlagerungssignal an eine Komponente „ReeferManager“ übermittelt. Bei der Auslagerung eines Kühlcontainers wird ein entsprechendes Auslagerungssignal übermittelt. Nach einem Ein- oder Auslagerungssignal und der Erhöhung oder Verminderung des Kühlcontainerbestandes wird die Gesamtleistungsaufnahme aller in den Lagern befindlicher Kühlcontainer bestimmt.

Der Beleuchtung als allgemeinem Verbraucher wird ein konstanter Energieverbrauchswert zugeordnet. Es wird dabei zwischen dem Verbrauch am Tag und dem Verbrauch in der Nacht unterschieden, der höher ist als am Tag. Zum Sonnenauf- bzw. -untergang wird der Energieverbrauchswert innerhalb einer Dreiviertelstunde um drei Stufen gesenkt bzw. erhöht. Der obere und untere Leistungsaufnahmewert ist dabei vorgegeben. Die Zeiten des Sonnenauf- bzw. Sonnenuntergangs werden analytisch bestimmt.

Um frühe Prognosezeitpunkte am Tag der Durchführung zu berücksichtigen wurde der Simulationsablauf in drei Phasen aufgeteilt (vgl. Abbildung 42). Dabei wird davon ausgegangen, dass die Prognoseerstellung vormittags an einem Tag vor dem eigentlichen Prognosetag erfolgt, um die Prognose noch für Maßnahmen im Day-Ahead-Handel oder Minutenreserveauktionen rechtzeitig bereitstellen zu können (vgl. Kapitel 2.2). Die simulierten Prozesse basieren

dabei im Wesentlichen auf den geplanten Schiffsankünften und Containerzahlen, wie sie in der Segelliste hinterlegt sind. So ist einer der ersten Schritte im Simulationsablauf immer der Import der hinterlegten Segelliste, auf dessen Basis bewegliche Objekte generiert werden.

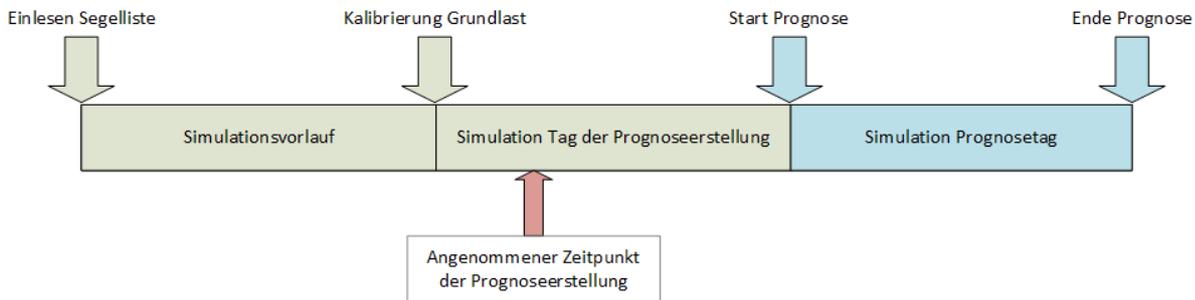


Abbildung 42: Ablaufschema eines Simulationslaufs für die Lastgangprognose

In der ersten Phase des Simulationsablaufs findet der Vorlauf statt. Dieser ist notwendig, damit sich zum Startzeitpunkt eines Simulationslaufs alle abgebildeten Objekte in einem definierten Startzustand befinden. Über einen Tag werden die definierten Prozesse so abgefahren, dass sich ein Zustand des Simulationsmodells des Terminals ergibt, der nicht allein von der Startkonfiguration zu Beginn des Simulationsablaufs abhängig ist. Da davon ausgegangen wird, dass die tatsächlichen Messwerte für den Zeitraum des Simulationsvorlaufs vorliegen, also für den Tag vor dem Tag der Prognoseerstellung, wird am Ende des Vorlaufs eine Kalibrierung der Grundlast vorgenommen. Dabei werden die von der Simulation zum Ende des Vorlaufs generierten Leistungsaufnahmewerte mit den tatsächlichen Messwerten abgeglichen. Liegen die simulierten Werte deutlich unter den gemessenen Werten, so wird die Anzahl der Kühlcontainer und die Leistungsaufnahme der Büro-IT erhöht. Andersherum, wenn die simulierten Werte über den gemessenen Werten liegen, wird die Anzahl der Kühlcontainer und die Leistungsaufnahme der Büro-IT verringert. Dieses Vorgehen wurde gewählt, da keine entsprechenden Daten über die Anzahl der Kühlcontainer in den Lagern des CTA und über den Leistungsbedarf der Bürogebäude vorliegen. Durch die Kalibrierung wird damit sichergestellt, dass sich das Niveau der Leistungsaufnahme zu dem ersten Zeitpunkt zu dem keine gemessenen Werte vorliegen, in einem realistischen Bereich befindet. Anschließend erreicht der Simulationszeitpunkt den Tag des Prognosezeitpunkts. Die Prozesse dieses Tages werden ebenso vollständig simuliert wie die Prozesse des folgenden Tages, der den eigentlichen Prognosetag darstellt. Der am Ende des Simulationslaufes ausgegebene Lastgang umfasst die aggregierte Leistungsaufnahme dieses Prognosetages.

6.2 Studie 1: Effekte der Wissensintegration

6.2.1 Vergleichstagverfahren

Das Vergleichstagverfahren basiert lediglich auf der Wiederholung von vergangenen Lastverläufen. In dem einfachen Vergleichstagverfahren ist die Integration von externen Wissensquellen konzeptionell nicht vorgesehen. Lediglich die Änderung der Vergleichskriterien von Datumswerten z. B. auf Temperaturwerte (z. B. im Bereich Erdgasversorgung) wird gelegentlich

praktiziert. Im Folgenden soll sich lediglich auf die in Kapitel 6.1.1 beschriebenen Varianten konzentriert werden. Bei der Auswahl der Varianten spielt das Wissen über die Wiederholung bestimmter Lastverläufe eine entscheidende Rolle. In einigen Branchen wiederholen sich die Lastverläufe in kurzen Intervallen, in anderen finden sich Regelmäßigkeiten auf Basis von Wochenrhythmen. Eine weitere Einbindung von „Wissen“ kann daher nur über die Nutzung von weiteren zurückliegenden Lastgängen erfolgen, wie das in den zwei Varianten mit vier gewichteten historischen Lastgängen der Fall ist. Bei einem Containerterminal mit schwankender Auslastung kann erwartet werden, dass durch das Einbeziehen von mehreren Lastgängen einzelne Schwankungen ausgeglichen werden und verschiedene Auslastungsszenarien durch das Einbeziehen von mehreren Lastgängen mit abgebildet werden. Um diese Effekte zu beobachten, wurden die vier Varianten sowohl für das Jahr 2013, als auch 2014 hinsichtlich ihrer durchschnittlichen jährlichen Prognosegüte getestet um eine Vergleichbarkeit herzustellen.

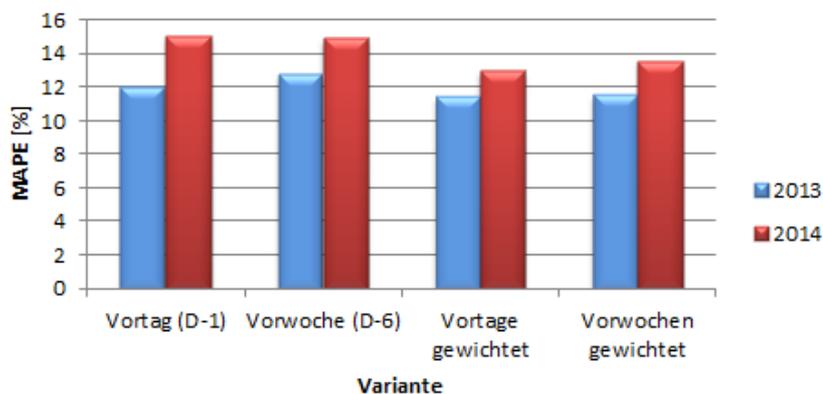


Abbildung 43: Durchschnittliche Prognoseabweichungen der Varianten des Vergleichstagsverfahrens

Abbildung 43 zeigt die Prognoseergebnisse der verschiedenen Varianten des Vergleichstagsverfahrens gemittelt jeweils über die Jahre 2013 und 2014. Es ist zu erkennen, dass der Einbezug von mehreren historischen Lastgängen einen Vorteil gegenüber der Berücksichtigung von nur einem historischen Lastgang hat. In beiden Jahren erzielt dabei die Berücksichtigung von Vortagen eine höhere Prognosegüte als die Lastgänge der Vorwochen. Dies kann darauf zurückgeführt werden, dass insbesondere große Seeschiffe mit einer besonders hohen Anzahl von umzuschlagenden Containern häufig mehrere Tage vor Anker liegen und entsprechende Anlieferungen und Abholungen der entsprechenden Container in den Tagen davor und danach anfallen, so dass eine gewisse Ausstrahlung des Verbrauchs in die Vortage erfolgt, der nicht unbedingt eine Woche zurückreicht. Zudem können Temperaturen bei den weiter zurückliegenden Vorwochenlastgängen einer größeren Schwankung unterliegen, die wiederum jeweils Einfluss auf das Niveau des Lastgangs haben können.

6.2.2 Fallbasierte Lastgangprognose

Für die Beschreibung der Wissensintegration in fallbasierte Systeme wurde das Konzept der Wissenscontainer entworfen (vgl. Kapitel 2.4), welche das Wissen eines solchen Systems in

vier Kategorien einteilen: Repräsentationssprache und Vokabular, Ähnlichkeitsmaße, Fallbasis und Lösungstransformation. Bei der Fallbasierten Lastgangprognose liegt der Fokus auf der Fallbasis, den Ähnlichkeitsmaßen und der Lösungstransformation. Repräsentationssprache und Vokabular haben nur eine untergeordnete Bedeutung, da es sich bei den Fallattributen im Wesentlichen um numerische Attribute handelt, nicht um text-basierte Fälle, wie es zum Beispiel im medizinischen Bereich häufig der Fall ist. Die Fallbasis mit den einzelnen Fällen und die modellierten Ähnlichkeitsmaße sind zentraler Bestandteil der Fallbasierten Lastgangprognose, ohne die das System nicht funktionieren würde. Beide zusammen ermöglichen eine ähnlichkeitsbasierte Suche auf domänenspezifischen Daten. Prinzipiell könnte diese ähnlichkeitsbasierte Suche als eine stark erweiterte Version des Vergleichstagverfahrens angesehen werden. Der Einsatz von Wissen zur Lösungsanpassung (Adaption) macht aus dieser ähnlichkeitsbasierten Suche ein System, welches den Methoden des Fallbasierten Schließens vollständig entspricht und die Wissenscontainer vollständig abbildet. Um die Effekte der Integration des Adaptionwissens zu untersuchen, wurden vier Varianten der Fallbasierten Lastgangprognose und deren durchschnittliche Prognosefehler über die Jahre 2013 und 2014 untersucht:

- *Ähnlichkeitsbasierte Suche*: Es wird lediglich eine Suche nach dem ähnlichsten Fall vorgenommen. Der Lastgang des ähnlichsten Falles wird als Prognose genutzt. Eine Anpassung des Lastgangs erfolgt nicht.
- *Ähnlichkeitsbasierte Suche mit den drei ähnlichsten Fällen (Ähnlichkeitsbasierte Suche Top 3)*: Es wird eine Suche nach den ähnlichsten Fällen vorgenommen. Der Mittelwert der Lastgänge der drei ähnlichsten Fälle wird als Prognoselastgang genutzt.
- *Fallbasierte Lastgangprognose*: Es wird eine Suche nach dem ähnlichsten Fall vorgenommen. Der Lastgang des ähnlichsten Falles wird anschließend an die aktuelle Situation adaptiert.
- *Fallbasierte Lastgangprognose mit den drei ähnlichsten drei Fällen (FBS Top 3 mit Adaption)*: Es wird eine Suche nach den ähnlichsten Fällen vorgenommen. Der Mittelwert der adaptierten Lastgänge der drei ähnlichsten Fälle wird als Prognoselastgang genutzt.

Eine erste Auswertung der Prognoseergebnisse der Fallbasierten Lastgangprognose (mit Adaption) ergab, dass die prognostizierten Werte die tatsächlichen Lastgänge systematisch unterschätzen. Eine Auswertung ergab, dass auf langfristige Sicht der Strombedarf in den betrachteten Jahren stärker stieg als der Containerumschlag (vgl. dazu auch Kapitel 4.4). Um dieser Entwicklung gerecht zu werden, wurde für die Adaption noch ein Faktor eingeführt, der in der ursprünglichen Konzeption nicht enthalten war. Dieser Faktor repräsentiert den jährlichen Anstieg des Strombedarfs über die Jahre, der auf Basis der vorhandenen Datengrundlage nicht mit einem steigenden Containerumschlag begründet werden kann. Am CTA kann dies zum Beispiel auf den vermehrten Einsatz von batterie-elektrischen Fahrzeugen zurückgeführt werden, deren Einsatz in diesen Jahren gestiegen ist. Der Faktor beschreibt also den Wert, mit dem der Lastgang, basierend auf dem Jahr, aus dem er stammt, multipliziert wird. Tabelle 17 zeigt die entsprechenden festgelegten Werte des Anpassungsfaktors.

Jahr	2010	2011	2012	2013	2014
Adaptionsfaktor	1,09	1,06	1,03	1,00	1,00

Tabelle 17: Nachträglich eingefügte Anpassungsfaktoren

Abbildung 44 zeigt die Auswertung der Prognoseergebnisse vor und nach Einführung dieses Anpassungsfaktors. Während das Fehlermaß MAPE als absolutes Maß keinen Rückschluss auf eine systematische Über- oder Unterschätzung des tatsächlichen Verbrauchs zulässt, kann ein nicht-absolutes Fehlermaß wie der MPE genutzt werden, um solche zu erkennen, da Über- und Unterschreitungen der tatsächlichen Werte gegeneinander aufgerechnet werden. So ist auf der linken Seite der Abbildung zu erkennen, dass der MPE-Wert der monatlichen Prognoseauswertung für 2013 für alle Monate im negativen Bereich liegt. Durch die Einführung der Anpassungsfaktoren wurde dieses korrigiert und auch die absoluten Ergebnisse verbessert. Trotzdem ist auf der rechten Seite der Abbildung zu erkennen, dass in der zweiten Jahreshälfte weiterhin die Prognose dazu tendiert, den tatsächlichen Verbrauch zu unterschätzen, insbesondere im Oktober. Da aber mit Ausnahme des Oktobers der systematische Anteil der Unterschätzung am Gesamtfehler insgesamt gering ist, wurde auf eine weitere Anpassung dieses Faktors verzichtet. Für 2014 ergab die Integration des Faktors keine wesentliche Verbesserung der Prognosegüte. Hier kann die Integration der Fälle von 2013 in die Fallbasis positive Auswirkungen haben, die den Effekt des Faktors vernachlässigbar erscheinen lassen.

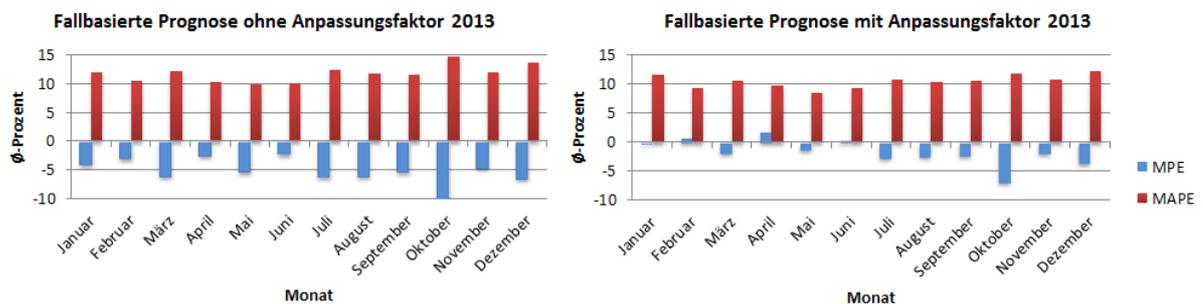


Abbildung 44: MPE und MAPE der Fallbasierten Lastgangprognose mit und ohne Anpassungsfaktor

Abbildung 45 zeigt die durchschnittliche mittlere prozentuale Abweichung der Prognoseergebnisse zu den tatsächlich gemessenen Leistungsaufnahmewerten für die vier eingangs beschriebenen Szenarien (für die fallbasierte Lastgangprognose nach Integration des Anpassungsfaktors). Die Reduzierung des fallbasierten Schließens auf eine ähnlichkeitsbasierte Suche, wie sie in den Szenarien ohne Adaption vorgenommen wurde, zeigt deutliche Nachteile gegenüber den Ergebnissen, bei denen die Lastgänge der ähnlichsten Fälle angepasst wurden, um der aktuellen Situation gerecht zu werden. Sowohl im Szenario mit nur dem Lastgang des ähnlichsten Tages als Lösung, wie auch in dem Szenario, bei dem die drei ähnlichsten Fälle für die adaptierte Lösungsfindung genutzt wurden, verbessert die Adaption das Gesamtergebnis über ein Jahr gesehen um jeweils mehr als einen Prozentpunkt. Damit kann gezeigt werden, dass es lohnenswert ist eine Adaption durchzuführen und dass die hinterlegten Adaptionsregeln mit ihren Faktoren korrekt angewandt wurden.

Gegenüber der Nutzung nur des ähnlichsten Falles zeigt die Nutzung des Mittelwerts der drei ähnlichsten Fälle (Top 3-Ansatz) wiederum deutliche Vorteile. Die Prognosegüte kann sowohl im Jahr 2013 als auch im Jahr 2014 um mehr als zwei Prozentpunkte verbessert werden und ist damit als bevorzugte Variante bei der Nutzung der Fallbasierten Lastgangprognose zu behandeln. Die Durchschnittsbildung aus drei Lastgängen kann einzelne Schwankungen innerhalb des Lastverlaufs ausgleichen. Dies hat Vorteile, da nicht alle einzelnen Schwankungen in den Viertelstundenwerten nur auf die Umschlagstätigkeiten zurückgeführt werden können, sondern auch nicht erklärbare Komponenten enthalten sind, wenn zum Beispiel kurzfristig größere Verbraucher in Betrieb genommen werden, beispielsweise in der Werkstatt des Terminals.

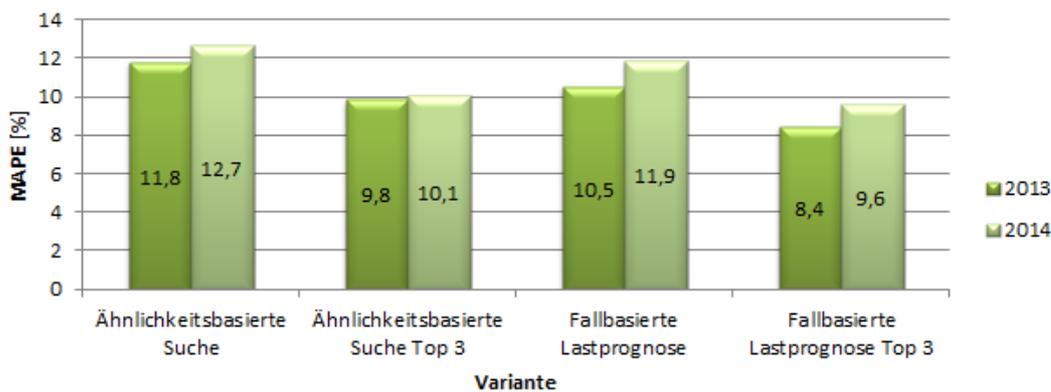


Abbildung 45: Prognosegüte verschiedener fallbasierter Varianten der Lastgangprognose für 2013 und 2014

Bereits die Auswertung des Vergleichstagverfahrens ließ darauf schließen, dass es vorteilhaft ist, mehrere Tage der Vergangenheit zu mitteln. Auf eine Gewichtung der drei Lastgänge der ähnlichsten Tage wurde hier verzichtet, da die Unterschiede in den Ähnlichkeitswerten der besten Ergebnisse überwiegend nur gering waren. Eine Mittelwertbildung bei der Lastgang des ähnlichsten Tages höher gewichtet wird, als die weiteren Lastgänge (z. B. in Relation zu den Unterschieden in den Ähnlichkeitswerten) ist aber denkbar.

6.2.3 Zeitreihenanalyse

Für die Zeitreihenanalyse wurden, ausgehend von einem reinen ARIMA-Modell, lediglich basierend auf den vergangenen Lastgangdaten, die Containerprofile, Wetterdaten und Wochentagsdaten als externe Regressoren dem Modell hinzugefügt. Dabei müssen für die Prognose nicht nur die historischen Daten bereitgestellt werden, sondern zusätzlich die prognostizierten Werte für die jeweiligen Regressoren. Wie bei den anderen Verfahren auch, wurden die zukünftigen Containerprofile aus den geplanten Segellisten heraus erstellt.

Abbildung 46 zeigt die Ergebnisse der verschiedenen Modelle. In allen Jahren verbessert das Hinzufügen von externen Regressoren die Prognosegüte im Durchschnitt. Insbesondere die Berücksichtigung der Containerprofile ist hier das entscheidende Merkmal, welches allein schon zu einer Verbesserung der Prognosegüte von mehr als einem Prozent in 2013 folgt. Insbesondere zusammen mit den Temperaturdaten wird das Prognoseergebnis noch weiter ver-

bessert werden, während die Berücksichtigung des Wochentages nur zu einer geringen Verbesserung in 2013 führt. In 2014 kommt es gegenüber der alleinigen Berücksichtigung des Containerprofils sogar zu einer Verschlechterung der Prognoseergebnisse, wobei diese marginal ausfällt und in der Abbildung durch Rundungseffekte größer wirkt. Der nur geringe, z. T. nicht vorhandene Einfluss der Wochentagstypen kann auf die erfolgte Komponentenzersetzung zurückgeführt werden. Hier werden saisonale Effekte wie zyklische Einbrüche des Gesamtverbrauchs an Wochenenden durch verringerte Nutzung von Büro-IT und Sonntagsfahrverbot bereits vor der Erstellung des ARIMA-Modells aus der Zeitreihe herausgerechnet und später wieder hinzuaddiert, sodass eine Regression auf die Tagestypen daher nicht oder nur kaum zu einer Verbesserung der Prognosegüte beiträgt.

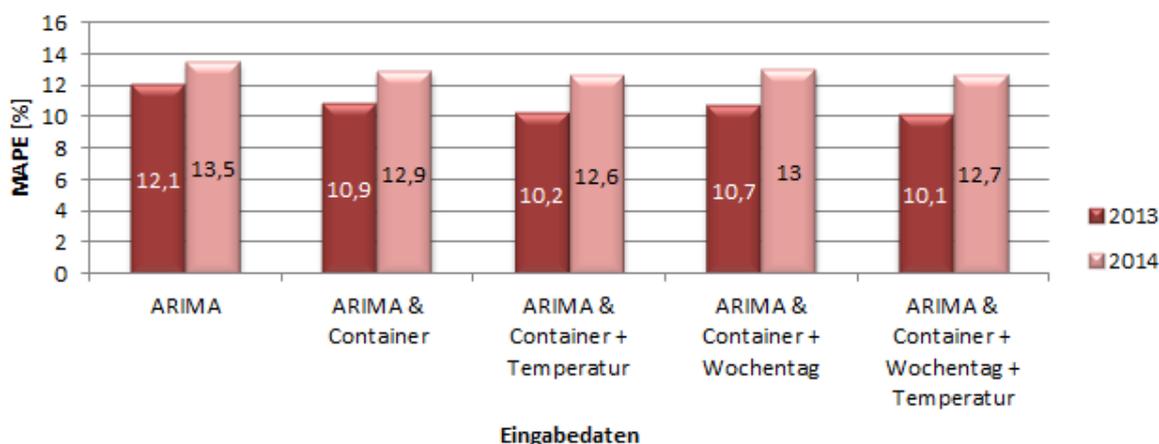


Abbildung 46: Prognosegüte der ARIMA-Modelle mit verschiedenen externen Regressoren

Die Temperaturen werden bei der Komponentenzersetzung nur insoweit berücksichtigt, sofern sie in ihrer Auswirkung auf den Lastgang einem langfristigen Trend folgen. Dies kann zum Beispiel im Frühjahr bei langsam steigenden Temperaturen und im Herbst bei langsam fallenden Temperaturen der Fall sein. Da aber die Auswertungen der Umsetzung der Modelle ergeben hat, dass die Berücksichtigung von historischen Zeitreihen über ein Jahr oder mehr in die Vergangenheit keinen Mehrwert ergibt (vgl. Kapitel 6.1.3), bieten die Temperaturen einen Mehrwert an, der sich auch niederschlägt, wenn nur einige Monate in der historischen Betrachtung hinzugezogen werden. Dass das Containerprofil als externer Regressor einen hohen Einfluss auf den Lastgang hat, wird durch die Ergebnisse der Jahre 2013 und 2014 bestätigt.

6.2.4 Künstliche Neuronale Netze

Für die Auswertung der Prognoseergebnisse des Künstlichen Neuronales Netzes wurden wieder verschiedene Szenarien aufgestellt und ausgewertet. In den verschiedenen Szenarien wurden die Eingabedaten variiert, während die wesentliche Parametrisierung des Netzes beibehalten wurde. In dem grundlegenden Szenario wurden die Daten des Containerprofils eines Tages als Eingabedaten genutzt. Diese Eingabedaten wurden nach einer entsprechenden Auswertung erweitert, zuerst um Wetterdaten (Temperatur und Windgeschwindigkeit) bzw. den Tagestyp, bevor sowohl Tagestyp als auch Wetter als Eingabedaten genutzt wurden. Aufgrund der bereits angesprochenen Steigerungen des Strombedarfs des Terminals wurde zuletzt ein

Faktor mit eingeführt. Entsprechend dem Adaptionsfaktor aus der Fallbasierten Lastgangprognose (vgl. Kapitel 6.1) wurden die Lastgangdaten der zurückliegenden Jahre mit einem über die Jahre abfallenden Faktor multipliziert, um die langfristige Entwicklung des Gesamtleistungsbedarfs zu repräsentieren.

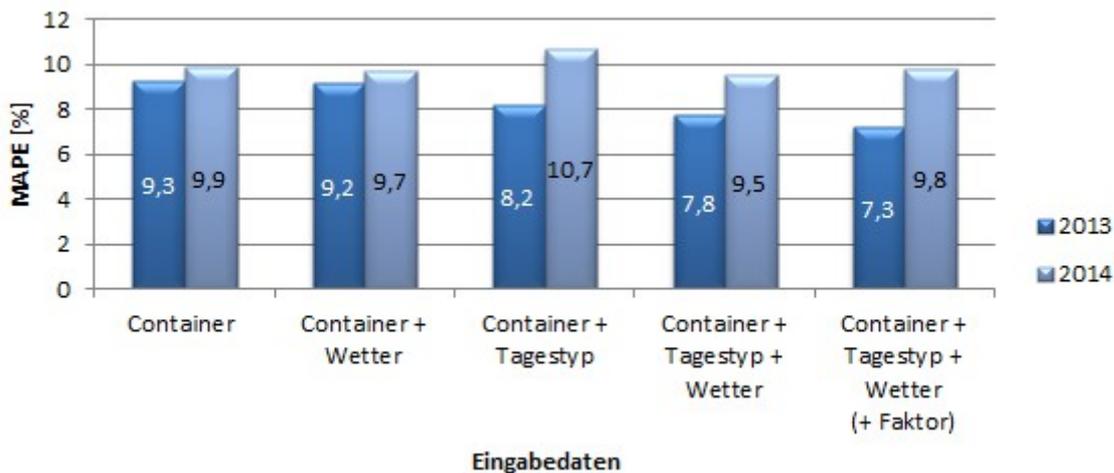


Abbildung 47: Prognosegüte verschiedener KNN-Varianten für 2013 und 2014

Abbildung 47 zeigt die Prognoseergebnisse der verschiedenen Szenarien gemittelt für die Jahre 2013 und 2014. Es ist zu erkennen, dass insbesondere in 2013 zusätzliche Eingabedaten zu einer deutlichen Verbesserung des Prognoseergebnisses führen. Insbesondere die Berücksichtigung der Tagestypen verbessert das Prognoseergebnis um fast einen Prozentpunkt. Dagegen führt die Nutzung der Tagestypen in 2014 sogar zu einer Verschlechterung der Prognosegüte in nicht unerheblichem Maße. Dies lässt die Vermutung zu, dass sich die Charakteristika des Lastgangs in Bezug auf die Regelmäßigkeit in sich wöchentlich zyklisch wiederholenden Vorgängen geändert haben. Die Ergebnisse der Fallbasierten Lastgangprognose als auch der Zeitreihenanalyse wiesen diese Tendenz ebenfalls auf.

Während das alleinige Hinzufügen der Wetterdaten nur zu einer sehr geringen Verbesserung der Prognoseergebnisse führt, so verbessert die Eingabe des Containerprofils zusammen mit Tagestypinformationen und Wetterinformationen die Prognosegüte nochmals. Wird das Netz nun auf Basis der mit einem Faktor erhöhten historischen Lastgänge trainiert, verbessert sich die Prognosegüte des Netzes auf 7,25 %, was mehr als 2 % besser ist als die Prognose auf Basis eines Netzes, welches nur das Containerprofil als Eingabeparameter erhielt und mit den nicht-angepassten Lastgangdaten trainiert wurde. Aus diesen Daten lässt sich ableiten, dass der Tagestyp bei der Nutzung eines KNN einen deutlich höheren Einfluss auf die Prognosegüte hat, als die Wetterdaten. Allerdings kann erst in der Kombination der beiden Eingabeparameter die Prognose für 2013 noch einmal erheblich verbessert werden. Für 2014 unterstützt die Anwendung des Faktors die Prognosegüte nicht. Die im Lernprozess hinzugekommenen Container- und Lastgangdaten scheinen ausreichend zu sein, die Effekte der allgemeinen Steigerung der Leistungsaufnahme zu repräsentieren, sodass der Faktor in 2014 nicht mehr angewendet wird.

6.2.5 Simulation

Bei der Umsetzung des Simulationsmodells wird das Wissen über die Prozessabläufe so exakt wie möglich in dem Simulationsmodell nachgebildet. Die Eingabedaten für das untersuchte Simulationsmodell bestehen aus den Segellisten (ohne weitere Bearbeitung), historischen Daten für die An- und Auslieferungen über die Hinterlandanbindung und historische Lastgangdaten.

Die einzelnen Prozessabläufe in einer Materialflusssimulation eines Containerterminals bedingen einander. Einzelne Komponenten können somit nicht ohne weiteres aus dem Modell herausgetrennt werden und bei gleichbleibenden Eingabedaten die Effekte betrachtet werden. Simulationsmodelle ermöglichen es dagegen verschiedene Betriebsstrategien für die Prozesse zu untersuchen. So können zum Beispiel die wesentlichen Planungsprobleme (vgl. Kapitel 5.6) unterschiedlich gelöst werden und die Effekte mit einem Simulationsmodell überprüft werden. Im Rahmen dieser Untersuchung soll aber nicht der Effekt verschiedener Strategien zur Lösung der einzelnen Planungsprobleme betrachtet werden. Die Planungsprobleme wurden in dieser Arbeit zu Grunde liegenden Simulationsmodell dem tatsächlichen Vorgehen des CTA nachempfunden (soweit bekannt) oder die gängigste Lösungsstrategie für das jeweilige Planungsproblem umgesetzt.

Im Gegensatz zu allen anderen in dieser Arbeit betrachteten Prognoseverfahren ermöglicht die Nutzung eines Simulationsmodells die Betrachtung von Teillastgängen, da alle wesentlichen Verbraucher im Modell hinterlegt sind und so verschiedene Aggregationsstufen für die Bildung eines Lastgangs möglich sind. Grundmeier [Gru16] untersucht in seiner Arbeit verschiedene Varianten des Vergleichstagverfahrens für die Integration von An- und Auslieferungsdaten der Hinterlandanbindung. Über eine Auswertung von einer Vielzahl von Varianten kommt er zu dem Schluss, dass 19 Vorwochentage die geringste durchschnittliche Abweichung (MAPE von 110,8 % bei Auslieferungen) gegenüber den tatsächlichen An- und Auslieferungen haben. Inwieweit die Prognose der An- und Auslieferungen über die Hinterlandanbindung einen Einfluss auf die Güte der Prognose des gesamten Leistungsbedarfs hat bleibt allerdings offen. Eigene Auswertungen ergaben einen geringen Effekt auf die Prognose des Gesamtlastgangs und werden daher an dieser Stelle nicht weitergehend betrachtet.

Das Simulationsmodell berücksichtigt keine Wochentagstypen und keine Temperatur- oder Winddaten. Diese sind für den eigentlichen Ablauf der Materialflusssimulation nicht relevant. Ihr Fehlen wird durch die Anpassung des Lastgangs an bereits bekannte Lastgangwerte kompensiert. Hier wird der benötigte Vorlauf der Simulation zum eigentlichen Prognosetag genutzt, um den simulierten Lastgang des Vortages (D-1) mit dem bereits vorliegenden tatsächlichen Lastgangwerten zu vergleichen. Bei wesentlichen Unterschieden wird der Teillastgang „Grundlast“ des Simulationsmodells für die Folgetage erhöht bzw. erniedrigt (vgl. Kapitel 6.2.5). Da der Simulationsvorlauf unabhängig von der Anpassung der Grundlast benötigt wird, um die Prozesse in einen realitätsnahen Zustand zu versetzen, führt dieses Vorgehen nicht zu einer Ausweitung des Simulationszeitraums, was zusätzlich benötigte Zeit für die Prognoseerstellung bedeutet hätte. Allerdings können so keine grundsätzlich unterschiedlichen Lastverläufe an Wochentagen und Wochenenden berücksichtigt werden.

6.3 Studie 2: Prognosegüte

Im Folgenden werden die Prognoseergebnisse bezüglich ihrer Prognosegenauigkeit, d. h. ihrer Güte, untersucht. Dazu werden die relativen Kennzahlen MAPE, MPE und RMSPE für 2013 und 2014 in Diagrammen dargestellt und für jedes Verfahren kurz diskutiert. Die Darstellung in den Diagrammen enthält für alle Verfahren im oberen Teil die monatlichen durchschnittlichen absoluten Prognoseabweichungen in Prozent (MAPE). Zusätzlich ist in den oberen Diagrammen die Spannweite der täglichen MAPE-Werte für den jeweiligen Monat dargestellt, d. h. der durchschnittliche Monatswert wurde aus Werten mit den an ein Box-Plot-Diagramm angelehnten Antennen ermittelt. Die Enden der Antennen sind die monatlichen Minimal- und Maximalabweichungen eines einzelnen Tages. Im Diagramm darunter werden jeweils die monatlich durchschnittlichen MPE- und RMSPE-Werte dargestellt. Über die monatliche relative Abweichung (MPE) lässt sich erkennen, ob eine systematische Abweichung der Prognose über oder unter die tatsächlichen Messwerte erfolgt ist. Die quadrierten absoluten Abweichungen (RMSPE) geben einen Hinweis darauf, ob es starke Ausreißer in der Prognosegüte gab. Ist dies nicht der Fall, so sollte der Verlauf der RMSPE-Werte dem Verlauf der MAPE-Werte in etwa folgen. Nach der Darstellung und Diskussion der Ergebnisse der einzelnen Verfahren werden diese anschließend miteinander verglichen und Besonderheiten dargestellt.

6.3.1 Vergleichstagverfahren

Die durchschnittlichen monatlichen Prognoseergebnisse des Vergleichstagverfahrens in der Variante gewichtete Vortage werden in Abbildung 48 für die Jahre 2013 und 2014 gezeigt. Es ist zu erkennen, dass insbesondere in den Wintermonaten die Prognosegenauigkeit nachlässt. Die Abweichungen betragen 2013 im November fast 50 %, 2014 sogar mehr als 50 %. Es scheint also in beiden Jahren im November eine besonders hohe Schwankung in den täglichen Lastverläufen zu geben, da bei diesem Verfahren die Lastgänge der Vortage den Prognoselastgang bilden. Dabei ist auffällig, dass die Tage mit der schlechtesten Prognosegüte in beiden Jahren an einem Wochenende in der Mitte des Monats liegen. In allen Fällen kann anhand der nicht absoluten Fehlerwerte erkannt werden, dass an diesen Tagen der tatsächliche Verbrauch massiv überschätzt wurde. Es kann daher vermutet werden, dass an diesem Wochenende jeweils jährliche Wartungsmaßnahmen vorgenommen wurden, die nur einen Teilbetrieb des Terminals zulassen. Entsprechend dem niedrigen Leistungsbedarf an diesen Wochenenden wurden die Folgetage des jeweiligen Wochenendes deutlich unterschätzt, da die Tage mit dem niedrigen Verbrauch mit einer hohen Gewichtung in die Berechnung der neuen Prognosewerte einfließen. Auch im Oktober 2014 fällt auf, dass zwei Wochenendtage deutlich überschätzt wurden. Lediglich im Februar 2014 fallen die Tage mit den größten Abweichungen nicht auf ein Wochenende sondern auf einen Montag und Dienstag. Im Dezember 2014 ist auffällig, dass der RMSPE den höchsten Wert in diesen beiden Jahren annimmt, die Maximalwerte für die Abweichung in diesem Monat aber nicht zu den höchsten gehören. Dies weist darauf hin, dass es innerhalb der Schwankungen doch relativ hohe Ausreißer nach oben oder nach unten gibt. Dies kann auf die Tage zwischen den Weihnachts- und Jahreswechselfeiertagen zurückgeführt werden. Da die eigentlichen Weihnachtsfeiertage aufgrund des grundsätzlich anderen Lastverlaufs an Feiertagen nicht in die Betrachtung der Vortage einbezogen wurden, werden hier die Lastgänge von vor den Feiertagen als Referenzlastgänge genutzt. Zudem ist davon

auszugehen, dass obwohl das Terminal zwischen den Feiertagen in Betrieb ist, nur ein eingeschränkter Umschlag stattfindet und die Verwaltung nicht vollständig besetzt ist, sodass eine andere Lastcharakteristik vorliegt als sonst üblich.

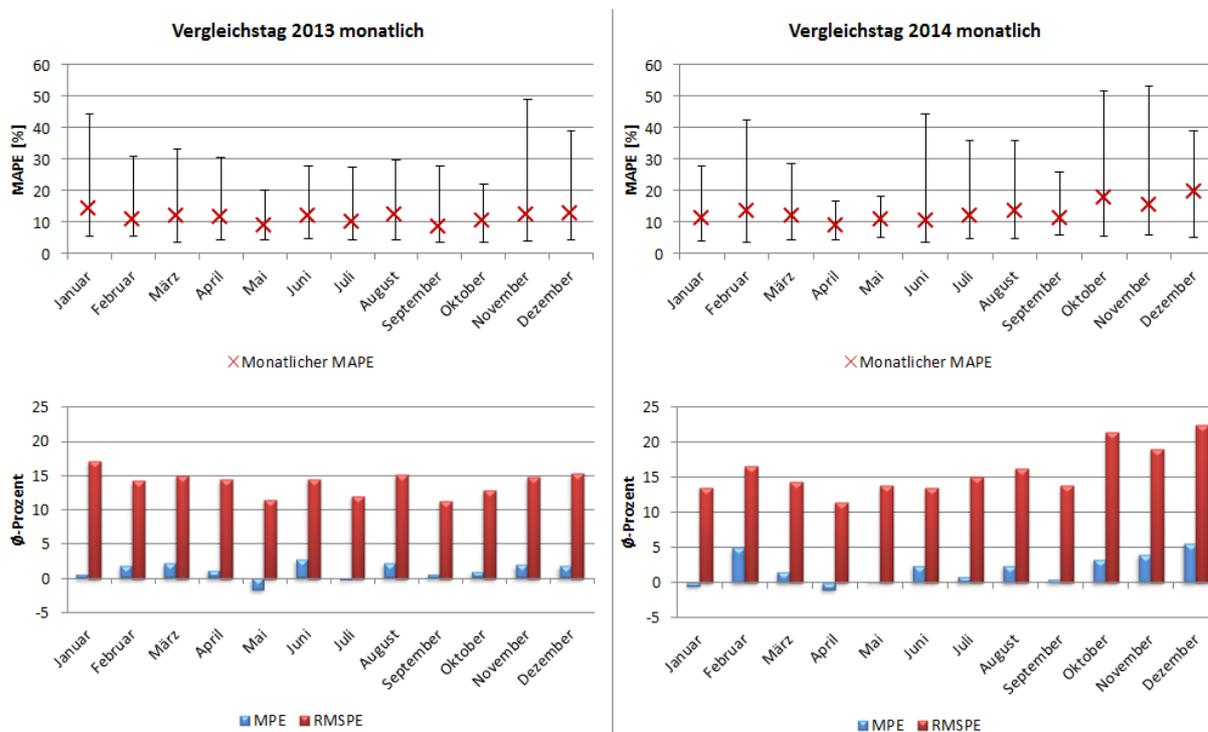


Abbildung 48: Monatliche Prognoseergebnisse des Vergleichstagsverfahrens

Insgesamt betrachtet bewegen sich die MAPE-Werte in 2013 unterhalb der MAPE-Werte von 2014, was dafür spricht, dass in 2013 der Lastverlauf etwas weniger Schwankungen unterlag als 2014. Lediglich in zwei Monaten im Jahr 2013 (Mai und September) und nur einem Monat im Jahr 2014 (April) liegen die durchschnittlichen Prognoseabweichungen im einstelligen Prozentbereich. Die maximalen Abweichungen sind in einigen wenigen Monaten mit 20 % gering, dem gegenüber stehen aber die Monate mit einer Prognoseabweichung von teilweise über 50 %. Diese hohen Abweichungen lassen die Nutzung dieses Verfahrens ohne manuelle Anpassungen oder Berücksichtigung weiterer Faktoren im Produktiveinsatz nicht sinnvoll anwendbar erscheinen.

6.3.2 Fallbasierte Lastgangprognose

Die monatlichen durchschnittlichen Prognoseergebnisse der Fallbasierten Lastgangprognose in der Variante mit der Mittelwertbildung der adaptierten Lastgänge der drei ähnlichsten Tage werden in Abbildung 49 grafisch gezeigt. Während in 2013 die Prognosegüte nur im Oktober knapp in den zweistelligen Bereich kommt, ansonsten aber im einstelligen Bereich zwischen 7,0 % und 9,3 % schwankt, so steigen die Abweichungen zum Ende des Jahres 2014 deutlich an. An den MPE-Werten lässt sich ablesen, dass in den Monaten November und Dezember eine deutliche Überschätzung der tatsächlichen Werte erfolgt und die starken Abweichungen, repräsentiert durch die RMSPE-Werte, deutlich zunehmen. Dies steht im Gegensatz zu dem

Jahr zuvor, bei dem in der zweiten Jahreshälfte überwiegend eine zu niedrige Prognose die Ergebnisse bestimmt und die RMSPE-Werte kaum Schwankungen unterliegen. Auch insgesamt gesehen lässt sich beobachten, dass in der Tendenz die Prognose im Wesentlichen unter den tatsächlich gemessenen Werten bleibt, während sich dieses 2014 umdreht und die Prognosewerte durchschnittlich über den tatsächlich gemessenen Werten liegen.

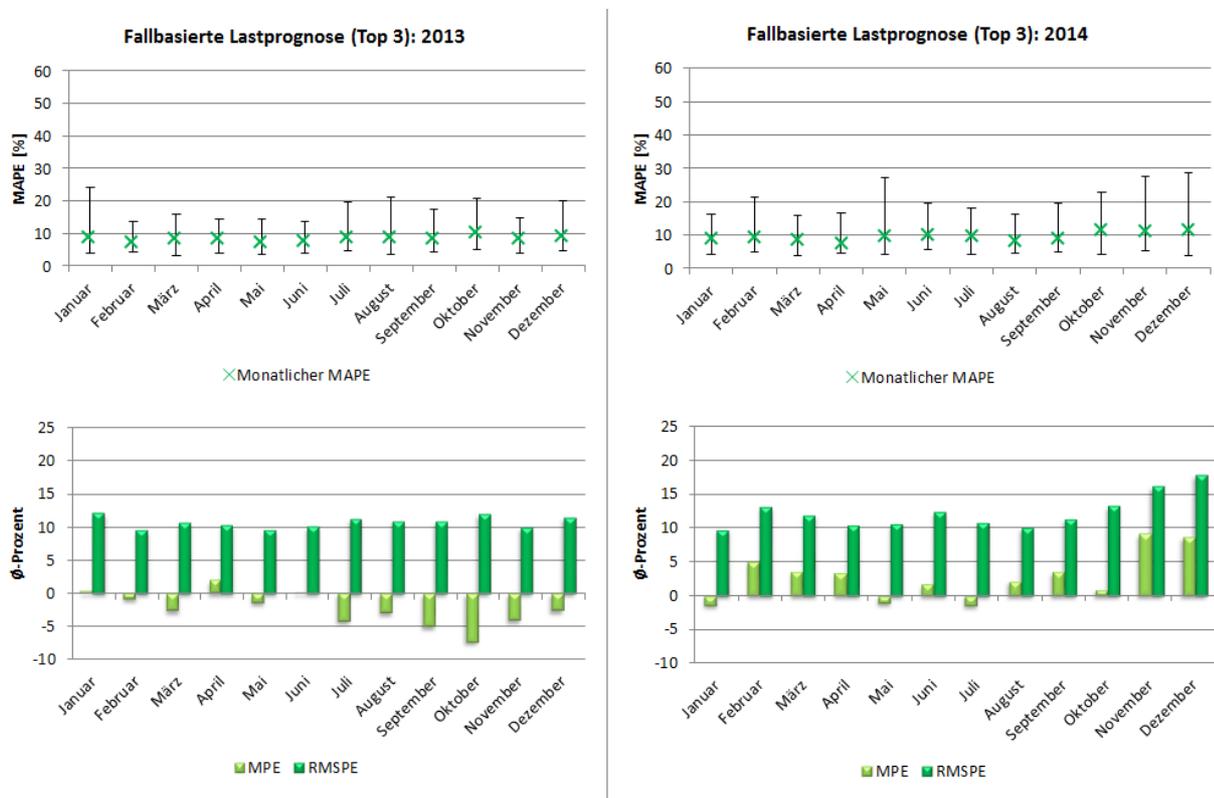


Abbildung 49: Monatliche Prognoseergebnisse der Fallbasierten Lastgangprognose

Im Vergleich zum Vergleichstagverfahren fällt neben den insgesamt durchschnittlich besseren Prognoseergebnissen insbesondere die deutlich niedrigere Spanne der Prognoseabweichungen innerhalb eines Monats auf. Im Jahr 2013 ist der Januar der Monat mit der höchsten Spannungsbreite, während 2014 der Mai und die beiden letzten Monate des Jahres besonders hohe Schwankungen aufweisen. Für 2013 liegt die höchste Abweichung bei 24 %, in 2014 bei 28 % und damit etwa bei der Hälfte der jeweiligen höchsten Abweichungen des Vergleichstagverfahrens.

Im Mai 2014 gibt es einen Ausreißer in der maximalen Prognoseabweichung. Dieser liegt an einem Sonntag, bei dem nach dem ersten Schichtwechsel des Tages das Niveau des Gesamtlastgangs deutlich ansteigt. Hier ist zu vermuten, dass zusätzliches Personal eingesetzt wurde, um ein ankommendes Seeschiff schneller zu entladen. Eventuell galt es hier eine Verspätung des Schiffes aufzuholen oder ähnliches, während ein regulärer Ablauf nicht zu einer solch starken Steigerung des Stromverbrauchs geführt hätte. Während andere Prognoseverfahren, u. a. das Vergleichstagverfahren, den Lastgang vor dem ersten Schichtwechsel deutlich überschätzen, danach aber in etwa das Niveau des Gesamtlastgangs erreichen, bleibt die Fallbasierte Prognose hier auf einem zu niedrigen Niveau, wobei alle ähnlichsten Tage aus dem Jahr

2010 stammen. In der Gesamtheit der Abweichungen, die der Charakteristik des Lastgangs nur in sehr geringem Maße folgen, stellt dieser Tag für die Fallbasierte Lastgangprognose eher eine Ausnahme dar.

6.3.3 Zeitreihenanalyse

Die ARIMA-Modelle der Zeitreihenanalyse basieren wie das Vergleichstagverfahren im Wesentlichen auf den vergangenen Lastgängen. Sie nutzen weitere Eingaben wie das Containerprofil als externen Regressor. Dieser externe Regressor wird auf die saison- und trendbereinigte Zeitreihe angewandt, wobei für die Prognose hier ebenfalls Prognosewerte für die externen Daten genutzt werden.

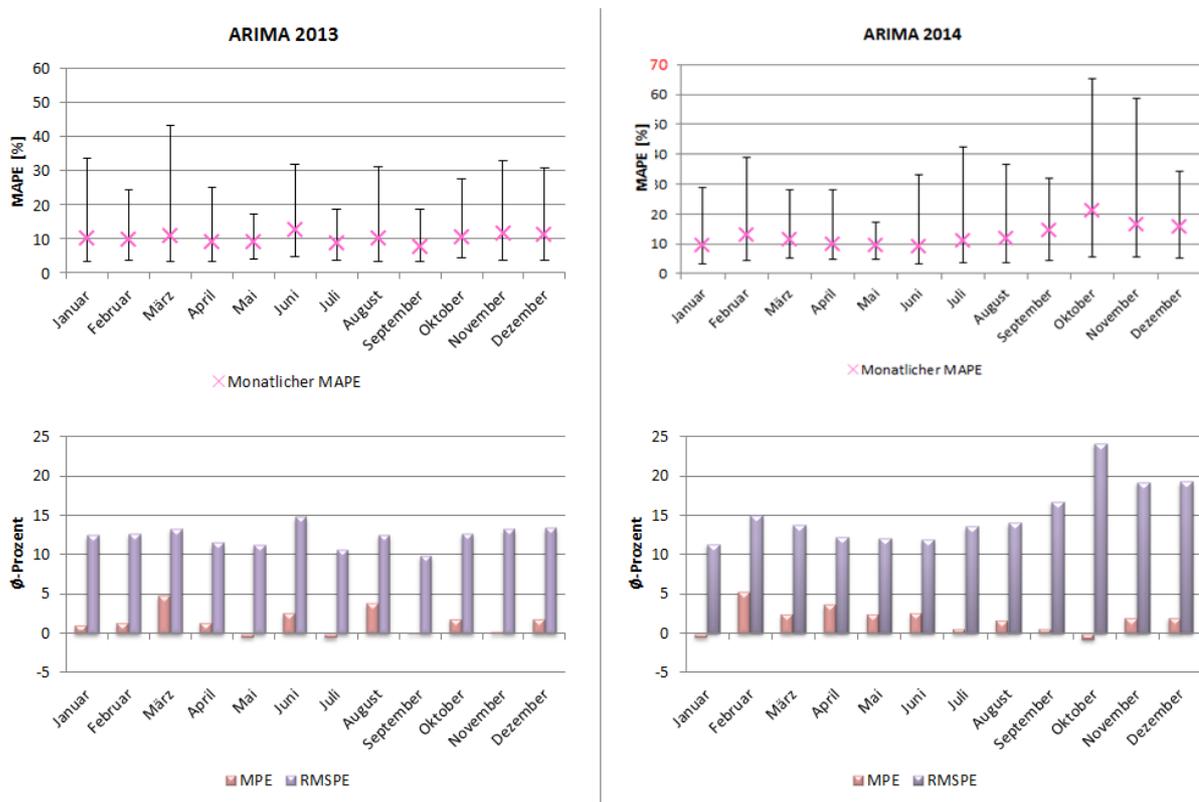


Abbildung 50: Monatliche Prognoseergebnisse der ARIMA-Modelle

Obwohl die Bestimmung der ARIMA-Modelle einen hohen Rechenaufwand erfordert und für die Prognose mit den externen Regressoren mehr Informationen zur Verfügung stehen, weisen die Ergebnisse der ARIMA-Modelle zum Teil ähnliche Merkmale wie die Ergebnisse des Vergleichstagverfahrens auf, insbesondere was die Spanne der Prognosegüte angeht. Im Jahr 2013 weist insbesondere der März eine hohe maximale Abweichung auf, die an einem Sonntag auftritt. Mit durchschnittlich mehr als 43 % Abweichung ist diese fast doppelt so hoch wie die zweithöchste Abweichung in diesem Monat. Eine Analyse der Entwicklung ergibt, dass an dem Tag, an dem die höchste Abweichung auftrat (Tag 3 in Abbildung 51), eine besonders geringe Auslastung des Terminals herrschte. Während an den Tagen zuvor fast doppelt so viele Container umgeschlagen wurden, halbierte sich die Zahl an dem Sonntag, bevor sie sich am

Folgetag sofort wieder erholte. Zudem kommt verstärkend hinzu, dass an einem Sonntag die Grundlast aufgrund von LKW-Fahrverbot und weniger ausgelasteten Büroräumen der Leistungsbedarf insgesamt üblicherweise geringer ausfällt. Während zum Start (Tag 1 in Abbildung 51), sich überhöhte und zu niedrige Prognosen pro 15 Minuten die Waage halten und der MPE-Wert von 2,7 % unauffällig ist, steigt dieser mit sinkender Containerumschlagszahl deutlich an.

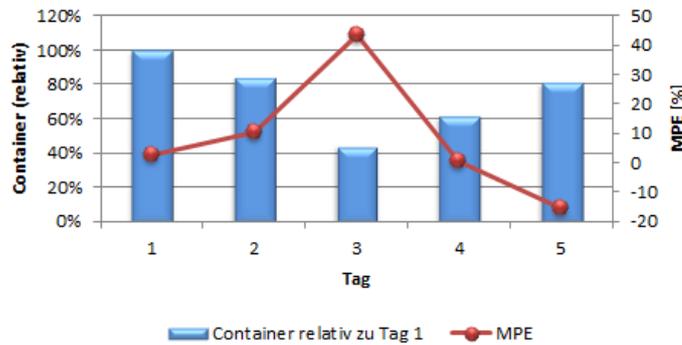


Abbildung 51: Analyse der maximalen Abweichung der ARIMA-Prognose im Jahr 2013

Der Sonntag mit der geringen Auslastung wird über den gesamten Lastgang hinweg als zu hoch prognostiziert. Dies hat auch Auswirkungen auf die Folgetage, insbesondere auf den übernächsten Tag (Tag 5), da hier der Sonntag (Tag 3) den ersten Tag darstellt, bei dem die gemessenen Werte dieses Tages die letzten gemessenen Werte des historischen Lastgangs darstellen, auf denen die Prognose aufbaut. Diese sind hier im zweistelligen Bereich negativ, das heißt, die Prognose setzt den Lastgang zu niedrig an. Das weist darauf hin, dass das ARIMA-Verfahren trotz der Berücksichtigung von Containerprofilen und Wochentagstypen als externe Regressoren träge auf kurzfristige Schwankungen in der Auslastung reagiert. Dabei spielt sicherlich auch eine Rolle, dass die Prognose zwei Tage in die Zukunft erfolgt und die Ergebnisse des zweiten prognostizierten Tages die relevanten Ergebnisse darstellen.

Auch 2014 sind ähnliche Konstellationen zu finden. Insbesondere gegen Ende des Jahres, wenn die Schwankungen im Lastverlauf insgesamt steigen, was sich auch in den Prognoseergebnissen der anderen Verfahren zeigt, gibt es Abschnitte, an denen sich deutlich zu hohe Prognoseergebnisse mit etwas später folgenden deutlich zu niedrigen Prognoseergebnissen abwechseln (vgl. Abbildung 52).

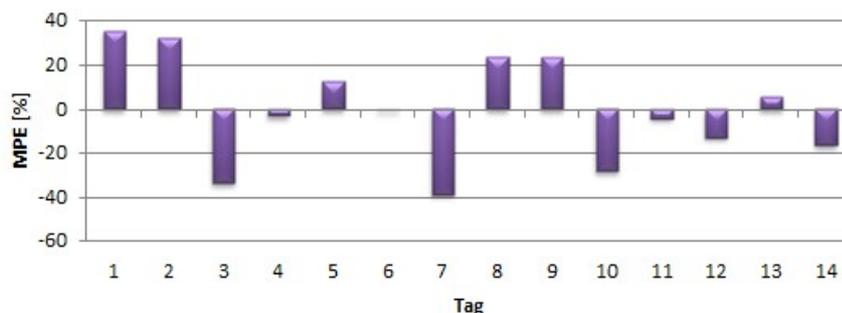


Abbildung 52: MPE-Verlauf für 14 Tage im Oktober 2014

Auch das Auslassen der Komponentenerlegung, um Saison- oder Trendeffekte nicht im Vorhinein zu bestimmen, sondern auch unabhängig von der STL-Zerlegung über Saisonale-ARIMA-Modelle abzubilden, erbrachte keine wesentliche Verbesserung der durchschnittlichen Prognoseergebnisse in diesen Monaten. Die hohe Schwankungsbreite der Prognoseergebnisse hatte auch einen deutlichen Einfluss auf die durchschnittliche Prognosegüte der Monate. Im Oktober liegen die Abweichungen bei über 20 % und mit in der Spitze 65 % sogar höher als bei der Anwendung des Vergleichstagverfahrens in diesem Monat. Dem gegenüber stehen aber auch Monate wie der Mai, in dem die Güte der Prognosewerte kaum schwankt. Bei einer gleichmäßigeren Auslastung des Terminals eignen sich ARIMA-Modelle damit durchaus für Prognosezwecke.

6.3.4 Künstliche Neuronale Netze

Die Prognoseergebnisse des Künstlichen Neuronales Netzes, die in Abbildung 53 gezeigt werden, erweisen sich im Vergleich der einzelnen Prognoseverfahren am stabilsten. Die monatlichen durchschnittlichen Werte für die Prognosegüte liegen für 2013 alle unter 8 % Abweichung, auch die RMSPE-Werte überschreiten nur im Juni knapp die 10 %, es gibt also wenige Ausreißer. Im September des Jahres bleibt die maximale prozentuale Abweichung sogar im einstelligen Bereich, der Februar ist mit einer maximalen Abweichung von 10,1 % nicht viel schlechter.

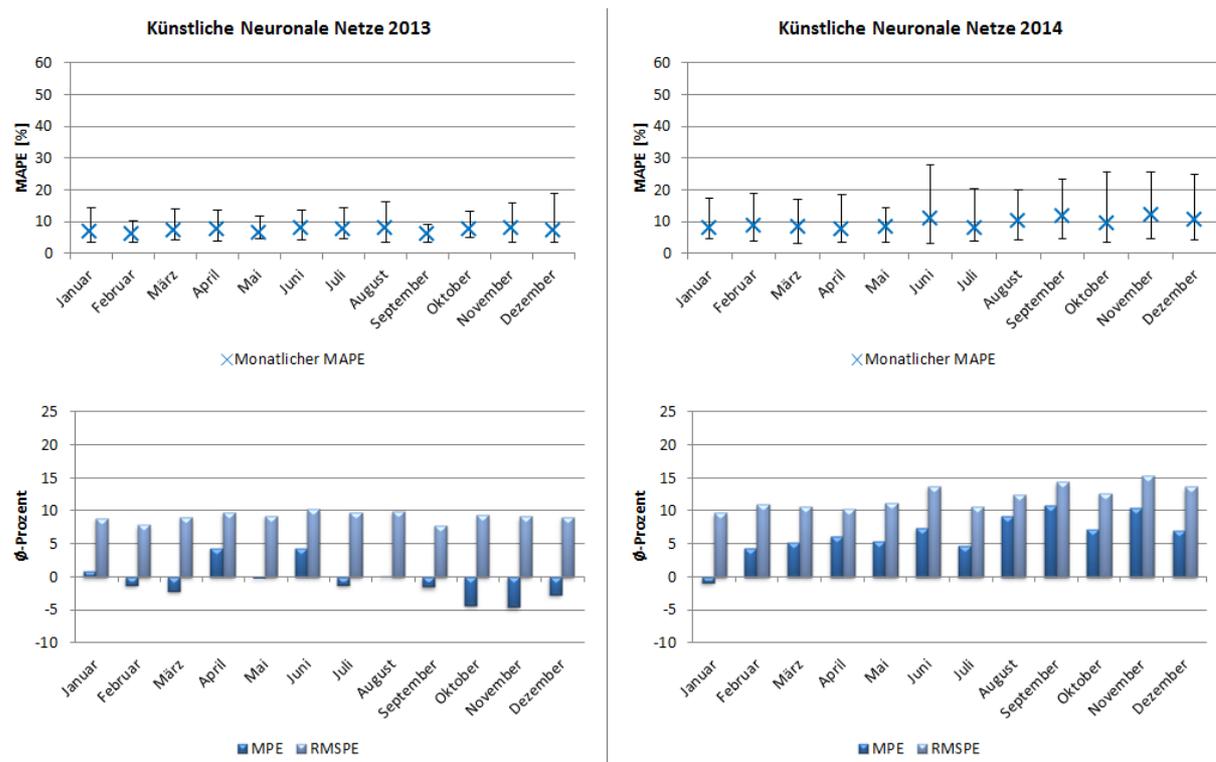


Abbildung 53: Monatliche Prognoseergebnisse der Künstlichen Neuronalen Netze

Insgesamt fallen nur an wenigen Tagen zweistellige Abweichungen an, viele davon an Wochenenden, an denen der Lastverlauf mehr Unregelmäßigkeiten aufweist als an Wochentagen.

Die höchste Abweichung des Jahres findet sich mit 18,9 % im Dezember. Die MPE-Werte des Jahres 2013 weisen auf keine systematisch überhöhten oder zu niedrigen Prognosewerte hin. Etwas anders stellen sich die Ergebnisse des Jahres 2014 dar. Hier steigt die Spanne der Abweichungen insbesondere in der zweiten Jahreshälfte an, in der die maximalen Abweichungen jeweils über 20 % liegen. Trotzdem liegen die durchschnittlichen monatlichen Ergebnisse überwiegend noch im einstelligen Bereich. Auffällig sind die MPE-Werte für 2014, die auf eine systematisch zu hohe Prognose gegenüber den tatsächlichen Werten hinweisen. Eine Erklärung dafür konnte nicht gefunden werden, insbesondere, da die Ergebnisse ohne den Steigerungsfaktor für die Vorjahre ermittelt wurden und ein deutlich niedrigerer Strombedarf im Gegensatz zu den Vorjahren in der Gesamtheit nicht vorliegt. Dies zeigt eine der Schwierigkeiten auf, die ein Künstliches Neuronales Netz, trotz der hohen Prognosefähigkeit aufweist: Die geringe Nachvollziehbarkeit der Ergebnisbildung. Das Zustandekommen der Werte einer Prognose bleibt für den Anwender intransparent.

Die geringeren Schwankungen in den Abweichungen hängen auch damit zusammen, dass die einzelnen Tage isoliert betrachtet werden und die Leistungswerte und die Umschlagintensität der Vortage für die eigentliche Prognoseerstellung keine wesentlichen Eingabeparameter darstellen. Somit können kurzfristige tageweise Schwankungen in der Umschlagintensität und den entsprechenden Lastgängen, wie sie im Vergleichstagverfahren und in Verfahren der Zeitreihenanalyse problematisch sind, vermieden werden, da das KNN als wesentliche Eingabedaten das Containerprofil hat und nicht die Lastgangdaten der vergangenen Tage. Gleiches gilt auch für die Fallbasierte Lastgangprognose, die die abgegrenzte Segelliste als maßgebliche Eingabeparameter nutzt.

6.3.5 Simulation

Die Simulation ist von der Modellierung her die aufwändigste Prognosemethode der in dieser Arbeit betrachteten Verfahren. Einige Auswertungen bezüglich der Prognosegüte des genutzten Simulationsmodell sind auch in der Arbeit von Grundmeier [Gru16] zu finden, allerdings liegt der Schwerpunkt dort auf der Evaluierung der Modellierung auf Basis von Terminaldaten des Jahres 2013, die auch außerhalb des Fokus der Lastgangprognose liegen.

Abbildung 54 zeigt die monatlichen Prognoseergebnisse für die Jahre 2013 und 2014. Im Jahr 2013 liegen die durchschnittlichen Prognoseergebnisse durchgängig im einstelligen Bereich, lediglich im Dezember liegt der Wert knapp über 10 %. Dabei liegen die maximalen Abweichungen eines Tages in der Hälfte der Monate über 20 %. Auch hier ist auffällig, dass die Tage mit den höchsten Abweichungen überwiegend am Wochenende liegen. Hier spielt sicherlich eine Rolle, dass das Simulationsmodell keine Tagestypen kennt und Wochenendtage in den Abläufen nicht von den Wochentagen unterscheidet, obwohl hier geringere Grundlasten und leicht verringerte Umschlagintensitäten aufgrund des Sonntagsfahrverbot (keine An- und Abfahren per LKW) festgestellt werden können. Im Jahr 2014 bleibt die durchschnittliche monatliche Abweichung lediglich im Januar im einstelligen Bereich, in den folgenden Monaten bleibt sie im Bereich von 10 %, bevor sie ab Oktober bis zum Jahresende ansteigt.

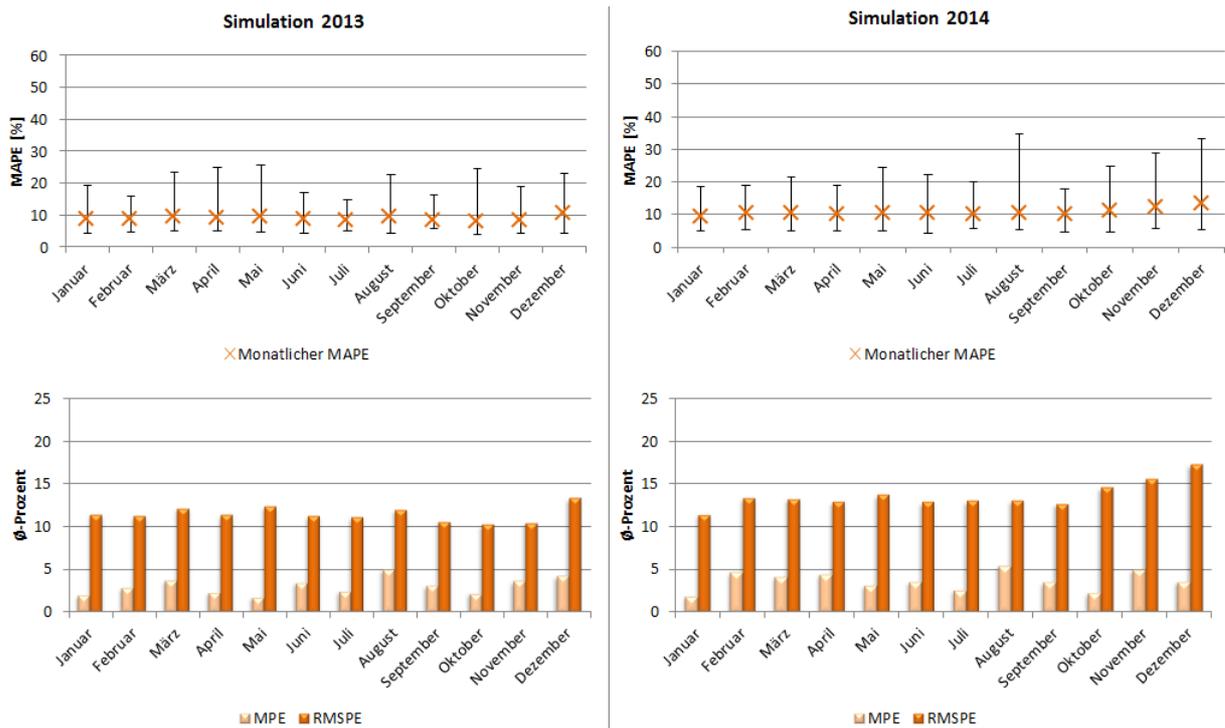


Abbildung 54: Monatliche Prognoseergebnisse der Simulation

Auffällig im Jahr 2014 ist eine hohe maximale Abweichung von über 30 % beim MAPE im August, die bei den weiteren Verfahren so isoliert nicht auftritt. Der betroffene Samstag zeigt über den Tag hinweg eine fallende Tendenz im Leistungsbedarf des Terminals. Während die Prognose des KNN diesen Verlauf in seiner Tendenz gut abbildet, erreicht die Fallbasierte Lastgangprognose zumindest das Mittel des Lastgangs. Die Prognose des Lastgangs folgt an diesem Tag am ehesten dem Vergleichstagesverfahren. Dies ist ungewöhnlich, da die Grundlage des Simulationsablaufs die Segellisteninformationen sind, die prinzipiell auch die Grundlage für die KNN- und die Fallbasierte Prognose bilden. Eine Erklärung für dieses Verhalten konnte nicht gefunden werden und bildet auch eine Ausnahme. In der Gesamtheit gelingt es der Simulation gut den Verlauf des tatsächlichen Lastgangs zu prognostizieren, das Problem liegt eher in der Bestimmung des mittleren Niveaus. Die MPE-Werte weisen hier auf systematisch zu hohe Prognosewerte hin, wenn auch in einigen Monaten nicht in einem signifikanten Bereich.

6.3.6 Verfahrensübergreifender Vergleich und Analyse

Während in den vorangegangenen Kapiteln die monatsweise Betrachtung der Prognoseergebnisse der einzelnen Verfahren vorgenommen wurde, zeigt Abbildung 55 die jährlichen MAPE-Werte aller Verfahren noch einmal in einer Gegenüberstellung. Sowohl im Jahr 2013, als auch im Jahr 2014 erreicht das KNN-Verfahren das durchschnittlich beste Prognoseergebnis, gefolgt von der Fallbasierten Prognose.

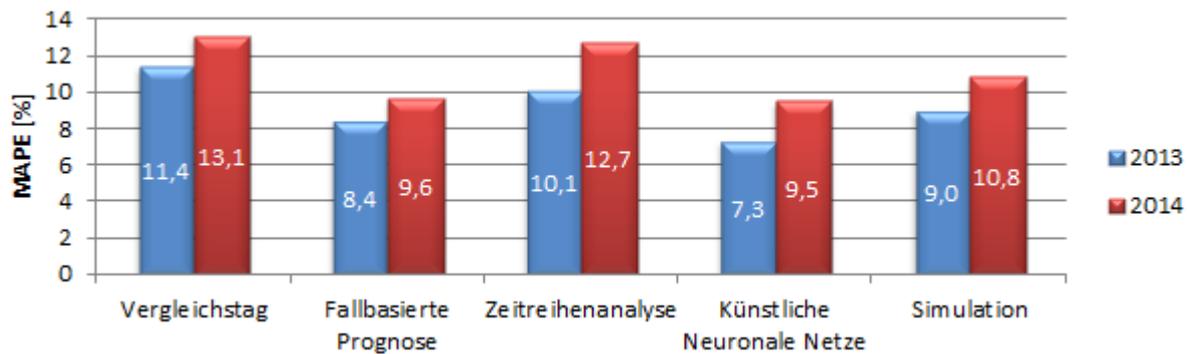


Abbildung 55: Vergleich der jährlichen durchschnittlichen MAPE-Werte aller Verfahren

Im Gegensatz zu dem einfachen Verfahren des Vergleichstags erscheint eine Steigerung der Prognosegüte um ca. 4 % durch das KNN-Verfahren erst einmal gering. Betrachtet man allerdings die maximalen Abweichungen der einzelnen Verfahren, so können diese durch ein erweitertes Verfahren halbiert werden, insbesondere, wenn es zu erhöhten Schwankungen kommt und die Prognose dadurch allgemein schwieriger wird, wie zum Ende des Jahres 2014. Dies ist auch im Kontext von Demand Response wiederum interessant, denn eine deutlich erhöhte Prognose mit einzelnen Spitzen könnte zu vorbeugenden Maßnahmen der Lastgangglättung oder Spitzenlastvermeidung führen. Mit einer genaueren Prognose können diese ggf. vermieden werden. Am robustesten gegenüber den Schwankungen verhielt sich die Fallbasierte Lastgangprognose. Hier erhöhte sich die Abweichung im Jahresvergleich um lediglich 1,2 %, bei allen anderen Verfahren erhöhten sich die Werte stärker. Auch das KNN konnte in der Betrachtung von 2014 von dem Training mit einer höheren Anzahl historischer Daten (einschließlich den Werten von 2013) nicht profitieren. Mehr Daten boten hier keinen besonderen Vorteil, da sich die Struktur der Lastverläufe etwas geändert hat, wie die durchgängige Verschlechterung der Prognosegüte über alle Verfahren vermuten lässt.

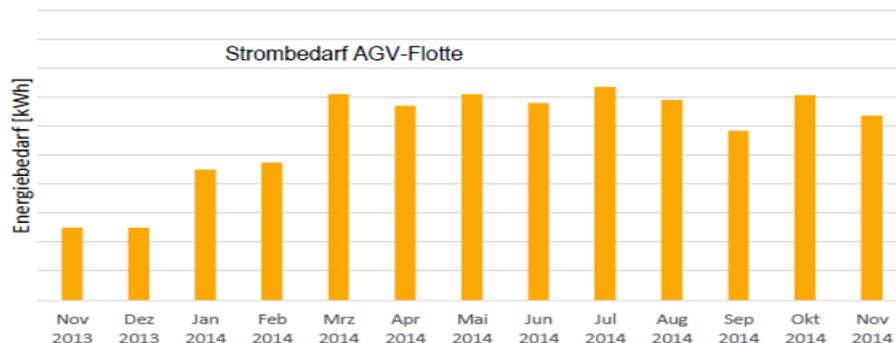


Abbildung 56: Strombedarf der batterie-elektrischen AGV im CTA [Bes16]

Eine Erklärung für die durchweg schlechteren Prognosewerte im Jahr 2014 könnte der erhöhte Strombedarf der AGV-Flotte sein. So erhöhte sich der Bedarf der batterie-elektrisch betriebenen AGV ab Januar 2014 und blieb dann auf einem relativ konstant hohen Niveau, wie in Abbildung 56 gezeigt. Während für die in dieser Arbeit konzipierten Prognoseverfahren davon ausgegangen wurde, dass ein direkter Zusammenhang zwischen den Umschlagstätigkeiten innerhalb des Terminals und dem Verlauf des Lastgangs besteht, so führt die Nutzung bat-

teriebetriebener Fahrzeuge zu einer Entkopplung der erbrachten Fahrleistung vom Energiebedarf für den Ladeprozess der Batteriesysteme, der immer nur im Nachhinein erfolgt. Dies steht im Gegensatz zu zum Beispiel den Kränen, die direkt für das Heben und Senken der Container den Leistungsbedarf benötigen.

Während 2013 die Batterieladevorgänge nur zu einem geringen Anteil Einfluss auf den Gesamtlastgang hatten, wurde dieser Einfluss durch die Inbetriebnahme weiterer Fahrzeuge und Batteriesysteme deutlich gesteigert, sodass die Annahme, dass die Umschlagfähigkeit direkten Einfluss auf den Lastbedarf hat, nicht mehr in dem Maße zutrifft. Hier würde eine zweite Prognose der Zeitpunkte für Batterieladevorgänge benötigt, welche mit der Prognose auf Basis der Umschlagintensität zusammen gebracht werden könnte. Im Rahmen der Fallbasierten Lastgangprognose könnte dies als Adaptionverfahren realisiert werden, bei Künstlichen Neuronalen Netzen könnte ein zweites Prognoseverfahren zum Beispiel auf Basis der prognostizierten Fahrleistung der Fahrzeuge integriert werden. Allerdings würden dazu die entsprechenden Daten zu Fahrleistungen und Batteriewechselzeitpunkten benötigt werden. Bei der Simulation ist eine direkte Integration in den Simulationsablauf bereits erfolgt, allerdings gab es für den Abgleich der echten Ladezustandswerte der Batteriesysteme mit den Werten der Simulation im Rahmen dieser Arbeit keine Möglichkeit, sodass die Zeitpunkte der Batterieladevorgänge als überwiegend zufällig angesehen werden müssen. Dies ist insbesondere dahingehend bedeutend, als dass für jede tägliche Prognose die Batteriesysteme der AGV in der Simulation mit unterschiedlichen Ladezuständen initialisiert wurden. Eine wesentliche Verbesserung der Prognoseergebnisse der Simulation konnte durch das Hinzufügen oder Entfernen von weiteren batterie-elektrischen AGV nicht erreicht werden.

6.4 Studie 3: Effizienz und Robustheit

Während die Prognosegüte in den überwiegenden Fällen der entscheidende Faktor bei der Wahl eines Prognoseverfahrens ist, können gerade in Konzernen oder großen Betrieben mit mehreren Standorten auch weitere Faktoren eine Rolle spielen. So ist zum Beispiel das Container Terminal Altenwerder Teil des Hafens Hamburg, in dem noch weitere Containerterminals des Betreibers HHLA anzutreffen sind, der auch für CTA verantwortlich ist. Die Nutzung der gleichen Prognoseverfahren über verschiedene Standorte hinweg bietet die Möglichkeit eines zentralen Kompetenzaufbaus und zur Nutzung von Synergieeffekten. Auch spielen die Effizienz, insbesondere der Zeitbedarf der einzelnen Verfahren eine noch bedeutendere Rolle, wenn die Prognose mehrfach (für verschiedene Standorte) durchgeführt werden muss. Im Folgenden sollen daher verschiedene Aspekte der Effizienz und Übertragbarkeit der unterschiedlichen Verfahren betrachtet werden. Zur Herstellung der Vergleichbarkeit der einzelnen Aspekte und um später eine Entscheidungsunterstützung bei der Wahl eines Verfahrens bieten zu können, sollen die einzelnen Aspekte jeweils in die Klassen gering, mittel oder hoch eingeteilt werden. Dabei basiert diese Einteilung auf der Umsetzung und den Daten des Fallbeispiels CTA. Es wird davon ausgegangen, dass die Kriterien für andere Containerterminals ähnlich beurteilt werden würden.

6.4.1 Rechenzeit

Die Rechenzeit für die Erstellung einer Prognose ist aufgrund der gestiegenen Leistungsfähigkeit moderner Computer kontinuierlich gesunken. Im Bereich der Haushaltskunden beispielsweise erfolgt eine Prognose des Energieverbrauchs von Haushaltskunden mit einem Standardlastprofilverfahren, bei dem pro Haushalt ein Faktor für den Jahresverbrauch mit den vorgegebenen Standardlastprofilwerten multipliziert wird. Für Großkunden mit registrierender Leistungsmessung erfolgt die Prognose häufig mit Hilfe des Vergleichstagverfahrens. Neben dem Fehlen von weitergehenden Daten liegt dies häufig in der einfachen Berechenbarkeit der Prognose begründet. Liegen zusätzliche Daten vor und kann die Prognose eines Einzelverbrauchers mit Hilfe von weitergehenden Verfahren erfolgen, so gibt es hier auch Unterschiede in der benötigten Rechenzeit für die Prognoseerstellung.

Prognoseverfahren	Rechenaufwändiger Teilprozess	Dauer Prognoseerstellung 1 Tag	Dauer Prognoseerstellung 30 Tage	Kategorie Rechenzeit
Vergleichstag	Berechnung gewichteter Wert	< 1 Sek.	< 10 Sek.	gering
Fallbasierte Prognose	Retrieval	< 5 Sek.	< 90 Sek.	gering
Künstliche Neuronale Netze	Datenvorverarbeitung	< 1Sek.	< 5 Sek.	gering
Statistische Verfahren (ARIMA)	Modellbestimmung	< 60 Sek.	< 10 Min.	mittel
Simulation	Simulationslauf	< 5 Min.	< 90 Min.	hoch

Tabelle 18: Übersicht zur Bewertung der Rechenzeit

Tabelle 18 zeigt exemplarische Ergebnisse für die implementierten Prognoseverfahren für das Container Terminal Altenwerder. Die Ergebnisse wurden dabei auf einem durchschnittlichen Arbeitsplatzrechner⁹ bestimmt. Performanceoptimierung der einzelnen Verfahren wie zum Beispiel die Nutzung von mehreren Prozessorkernen wurden nicht vorgenommen. Die angegebenen Zeiten umfassen neben der eigentlichen Prognoseberechnung noch die Zeiten für die Datenbankabfrage der benötigten Daten und die Datenvorverarbeitung und sollen anstatt einer genauen Zeitangabe eine grobe Einordnung der benötigten Rechenzeit ermöglichen. Das Feld mit der Prognosezeit für 30 Tage soll dabei weniger einen tatsächlichen Anwendungsfall darstellen, als beispielhaft die Zeitrelation im Vergleich der Verfahren bei der Durchführung mehrerer Prognosen bei dem entsprechenden Verfahren erlauben. Erwartungsgemäß finden sich die rechnerisch schnellsten Verfahren in dem Vergleichstagverfahren und dem Künstlichen Neuronalen Netz. Beim Vergleichstagverfahren erfolgen nur eine einfache gewichtete Mittelwertberechnung auf der Basis von vier Vortagslastgängen, sodass die Datenbankabfrage der benötigten Daten bereits einen großen Teil der benötigten Zeit einnimmt. Bei den Künstlichen Neuronalen Netzen erfolgt die Prognoseerstellung auf Basis eines bereits trainierten Modells eines Künstlichen Neuronalen Netzes, bei dem anhand der Eingabewerte die Aktivierungs-

⁹ Intel core i5-Prozessor mit 2,3 Ghz, 8 GB Arbeitsspeicher

werte der einzelnen Neuronen berechnet werden. Dass trotz der benötigten Vorverarbeitung der Eingabedaten (Erstellung Containerprofil, Normalisierung der Daten, etc.) die Berechnung noch schneller erfolgt als die Berechnung des Vergleichstagsverfahrens spricht für die effiziente Implementierung des Künstlichen Neuronalen Netzes und der spezialisierten Datenstrukturen, wie sie von dem genutzten Werkzeug für die Erstellung von KNN vorgegeben wurden. Dagegen wurde bei der Implementierung des Vergleichstagsverfahrens weitgehend auf Standardbausteine der genutzten Programmiersprache Java zurückgegriffen, inklusive einiger Datums- und Zeichenkettenvergleichen, die als ineffizient in Bezug auf Rechenzeit bekannt sind.

Im Vergleich länger dauert die Prognoseerstellung bei der Fallbasierten Prognose. Hier ist der größte Aufwand das Retrievalverfahren, bei dem die Ähnlichkeitswerte für alle Fälle der Fallbasis berechnet werden (sequentielles Retrieval). Hier liegt aus Perspektive der Rechenleistung noch Optimierungspotenzial durch Nutzung von spezialisierten Retrievalverfahren vor. Zu beachten ist bei der Fallbasierten Prognose zudem, dass die Fälle der Fallbasis vorab in den Hauptspeicher geladen werden. Diese Initialisierung ist einmal bei Programmstart durchzuführen und wurde bei der Berechnung der Dauer der Prognoseerstellung nicht berücksichtigt. Trotzdem erfolgt die Berechnung einer Prognose noch im Sekundenbereich und ist damit eines der Verfahren mit einem geringen Rechenaufwand.

Im Gegensatz zu den anderen Verfahren ist der Rechenaufwand von ARIMA-Modellen für die Prognose nicht konstant, sofern für jeden Prognosetag ein eigenes ARIMA-Modell bestimmt wurde, wie es hier der Fall war. Dies liegt in der vorab bekannten Schwankungsbreite der Lastgangwerte begründet, die eine Festlegung auf ein spezifisches ARIMA-Modell für alle Prognosetage nicht sinnvoll erscheinen lassen. Dass für verschiedene Tage auch verschiedene beste Modelle nach der in Kapitel 5.4 beschriebenen Methode gefunden werden, spricht für diese Vorgehensweise. In der Regel werden die Modelle deutlich schneller bestimmt, als in Tabelle 18 angegeben, nur kann es an einzelnen Tagen zu deutlichen Abweichungen kommen, wie die Auswertung für einen exemplarischen Monat in Abbildung 57 zeigt. Dadurch kann keine konstante Prognosezeit garantiert werden.

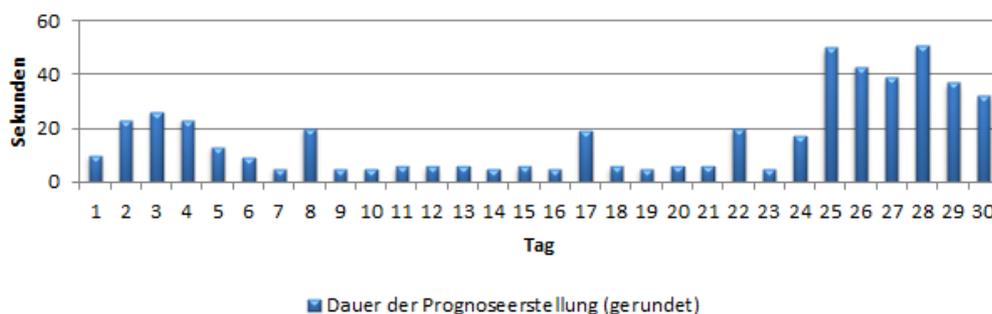


Abbildung 57: Dauer der Prognoseerstellung mit ARIMA-Modellbestimmung

Insgesamt gesehen bleibt die Zeit für die Erstellung einer Prognose mit den ARIMA-Modellen aber im Zeitbereich unter einer Minute, weshalb eine Kategorisierung der Rechenzeit in „mittel“ erfolgt ist. Dies liegt auch in der Nutzung der Komponentenerlegung vorab zur Modellbestimmung begründet. Ohne die Komponentenerlegung müssen auch saisonale ARIMA-Modelle bei der Modellfindung berücksichtigt werden, was den Aufwand durch die stark

erhöhte Anzahl an möglichen Modellen deutlich vergrößert. Deutlich am meisten Zeit beansprucht die Simulation, bei der für die Prognoseerstellung ein Simulationslauf über mehrere Tage durchgeführt werden muss und alle logistischen Prozesse des Terminals nachgestellt werden. Mit dem erstellten Simulationsmodell benötigt ein Simulationslauf für die Prognoseerstellung knapp fünf Minuten, weshalb die Simulation in Bezug auf die Rechenzeit mit der Kategorie „hoch“ bewertet wurde. Für eine massenhafte Prognose ist die Simulation damit nicht geeignet, allerdings ist es auch unwahrscheinlich, dass diese im Bereich der Containerterminals benötigt wird. Soll eine Prognose für verschiedene Containerterminals durchgeführt werden, so besteht die Möglichkeit, diese auf mehrere Rechner zu parallelisieren, sollte eine zeitkritische Erstellung der Prognosen erforderlich sein.

6.4.2 Modellierung und historische Daten

Unter dem Begriff Modellierung sollen in diesem Kapitel die vorbereitenden Tätigkeiten für die Prognoseerstellung betrachtet werden, welche im Regelfall nur einmalig oder als Wartungsmaßnahme in großen zeitlichen Abständen erfolgen müssen. Bei der Nutzung des Vergleichstagverfahrens ist der Aufwand für die Parametrisierung gering. Die Erstellung von Prognosen mit diesem Verfahren kann mit einfachen Hilfsmitteln durchgeführt werden und verschiedene Varianten ausprobiert werden, um eine geeignete Variante auf Basis von historischen Daten zu wählen. Soll eine Gewichtung von mehreren Vergleichstagen erfolgen, so kann entweder ein einfacher Durchschnitt gewählt werden oder auf vorhandene Gewichtungsmethoden zurückgegriffen werden. Für die Prognoseerstellung werden je nach gewählter Variante einzelne historische Tageslastgänge benötigt. In der einfachsten Variante wird dabei nur ein historischer Lastgang benötigt. Damit ist das Vergleichstagverfahren auch mit einer äußerst kleinen Datenbasis in der Lage Prognosen zu erstellen und eignet sich somit auch für die Nutzung bei Einführung von Energiemanagementsystemen in Szenarien, bei denen keine oder kaum historische Messdaten zur Verfügung stehen.

Prognoseverfahren	Aufwändigste Teile der Parametrisierung des Prognoseverfahrens	Kategorie Modellierungsaufwand
Vergleichstag	Bestimmung eines Verfahrens mit geeigneter Gewichtung	gering
Fallbasierte Prognose	Parametrisierung Ähnlichkeitsmaße Optimierung Gewichtung globales Ähnlichkeitsmaß Aufbau Fallbasis	hoch
Künstliche Neuronale Netze	Bestimmung optimale Netzkonfiguration Training des Netzes	mittel
Statistische Verfahren (ARIMA)	Bestimmung benötigte Anzahl historischer Daten Datenvorverarbeitung	mittel
Simulation	Exakter Aufbau des Simulationsmodells mit möglichst exakter Parametrisierung aller Prozesse	hoch

Tabelle 19: Übersicht zur Bewertung des Modellierungsaufwandes

Bei der Fallbasierten Prognose besteht der wesentliche Aufwand vorab in der Erstellung des Domänenmodells. Dieses umfasst die Definition eines geeigneten Fallformats, einer Ähnlichkeitsmodellierung für das Retrieval und die Definition von Adaptionstrategien und -regeln. Damit wird im Vorfeld umfangreiches Domänenwissen genutzt, um das System zu erstellen. Bleibt es in dem jeweiligen Anwendungsszenario bei einem Fallformat in Attribut-Wert-Darstellung, wie es auch für die Fallbasierte Prognose genutzt wird, so finden sich insbesondere für numerische Attribute häufig genutzte Ähnlichkeitsmaße, die allerdings für jedes Attribut einzeln parametrisiert werden müssen. Adaptionstrategien können weitestgehend nur innerhalb einer Domäne angewendet werden. Generelle Problemlöser sind hier noch zu ineffizient. Zusätzlich gilt es auf Basis des definierten Fallformats eine möglichst umfangreiche Fallbasis aus historischen Daten zu erstellen. Da Szenarien für die Lastgangprognoseerstellung in vielen Fällen, so auch bei der Prognose des Lastgangs eines Containerterminals, eine gewisse Temperaturabhängigkeit aufweisen, so erscheint eine minimale Daten- bzw. Fallbasis von einem Jahr sinnvoll, um möglichst diverse Fälle in der Fallbasis zu haben. Somit eignet sich die Fallbasierte Prognose nur für Containerterminals, die bereits historische Logistik- und Energieverbrauchsdaten zur Verfügung haben.

Prognoseverfahren	Umfang der benötigten historischen Daten	Kategorie Umfang historischer Daten
Vergleichstag	Mindestens ein Tag	gering
Fallbasierte Prognose	Umfangreiche Fallbasis benötigt	hoch
Künstliche Neuronale Netze	Umfangreiche historische Daten für Training des Modells	hoch
Statistische Verfahren (ARIMA)	Einige Tage bis Monate	gering
Simulation	Keine historischen Daten	gering

Tabelle 20: Übersicht zum Umfang der benötigten historischen Daten

Von den Anforderungen an die bereits vorhandene Datenbasis liegt die Prognose mit Hilfe von KNN über dem Niveau der Fallbasierten Prognose. Während bei der Fallbasierten Prognose die dem Retrieval nachgelagerten Adaptionregeln und -strategien eine Anpassung des Lastgangs ermöglichen und damit auch bei einer „kleinen“ Fallbasis nutzbare Ergebnisse erzeugt werden können, wird für das Training des KNN eine möglichst große Datenbasis an historischen Daten benötigt, die möglichst viele verschiedene Szenarien abdeckt. Ansonsten droht das trainierte Modell bisher unbekannte Situationen nicht korrekt zu bewerten. Dem gegenüber steht der im Gegensatz zur Fallbasierten Prognose geringere Modellierungsaufwand, da das Künstliche Neuronale Netz die Struktur der Daten selbstständig im Rahmen des Lernprozesses entdeckt und nutzbar macht.

Die statistischen Verfahren benötigen ebenfalls nur ein eher geringes Maß an Modellierung, da hier, zumindest bei der Nutzung von ARIMA-Modellen, die eigentliche Modellfindung aus den vorhandenen Daten erfolgt, im Wesentlichen aus den historischen Lastgangdaten. Als externe Regressoren können u. a. Containerprofile genutzt werden. Die vorgenommenen Auswertungen haben ergeben, dass bereits ein oder zwei Monate an historischen Daten ausrei-

chend sind, um entsprechend sinnvolle Prognoseergebnisse zu erzielen und mehr historische Daten nicht zu einer Verbesserung der Prognosegüte beitragen.

Den höchsten Modellierungsaufwand der verglichenen Verfahren hat mit Abstand die Nutzung einer Simulation zur Prognoseerstellung. Nicht nur wird hier die Infrastruktur des jeweiligen Terminals in großen Teilen modelliert, sondern auch entscheidende Algorithmen der Prozessabläufe, wie zum Beispiel die Kaikranzuordnung, die Transportauftragszuweisung oder die Strategien zur Ein- und Auslagerung der Container, müssen implementiert werden. Hierbei sind historische Daten hilfreich, um das erstellte Modell gegen reale Daten testen zu können, aber nicht zwingend notwendig. So können die Prozesse mit Hilfe des Simulationsmodells bereits vorab simuliert werden und die Daten aus dem Modell heraus selbst generiert werden. Hier liegt auch ein Vorteil eines detaillierten Simulationsmodells: Einzelne Abläufe der Prozesse oder Strategien im logistischen Bereich können geändert werden und deren Auswirkungen auf den Lastgang analysiert werden, ohne dass diese dazu tatsächlich umgesetzt werden müssen. So ist eine a-priori-Bewertung von Anpassungen im Terminalbetrieb in Hinblick auf die Auswirkungen auf den Lastgang einfach möglich. Zusätzlich erstellt das Simulationsmodell nicht nur einen Gesamtlastgang, durch die detaillierte Modellierung ist es ebenfalls möglich das lastgangbezogene Verhalten einzelner Verbrauchsgruppen zu analysieren.

6.4.3 Übertragbarkeit und Möglichkeit zur Anpassung an geänderte Bedingungen

Containerterminals sind dynamische Systeme, die in ihren Prozessen Änderungen unterworfen sind. Einzelne Prozesse können in ihren Abläufen verändert bzw. optimiert werden, die Infrastruktur kann erweitert oder eingeschränkt werden oder neue Technologien wie zum Beispiel Elektromobilität können Einzug erhalten. Um sich an geänderte Rahmenbedingungen anzupassen, sind für die untersuchten Prognoseverfahren verschiedene Vorgehensweisen denkbar, die eine unterschiedlich schnelle Anpassung an Veränderungen ermöglichen. Im Vergleichstagsverfahren erfolgt die Anpassung automatisch.

Prognoseverfahren	Möglichkeiten zur Anpassung	Kategorie Anpassbarkeit	Kategorie Anpassungsaufwand
Vergleichstag	Nicht benötigt	gering	gering
Fallbasierte Prognose	Faktor für höhere Gewichtung aktuellerer Fälle Adaptionsregel	mittel	mittel
Künstliche Neuronale Netze	Nachgelagerte Adaption der Prognose Erneutes Training	gering	hoch
Statistische Verfahren (ARIMA)	Nachgelagerte Adaption der Prognose	gering	gering
Simulation	Anpassung Simulationsmodell	hoch	hoch

Tabelle 21: Übersicht zur Bewertung der Anpassbarkeit

Je nach Variante sind die Anpassungen nach zwei Tagen oder spätestens nach einer Woche bei der Prognoseerstellung berücksichtigt. In der Fallbasierten Lastgangprognose bietet es sich an, bei der Ähnlichkeitsberechnung einen Faktor einzufügen, der aktuellere Fälle (die nach der Änderung erstellt wurden) gegenüber älteren Fällen (von vor der Änderung) höher gewichtet und damit die Wahrscheinlichkeit erhöht, dass die Änderung durch den ähnlichsten Lastgang schon mit berücksichtigt ist. Sind die Auswirkungen der Veränderung auf den Lastgang vorab bekannt, so kann auch eine Adaptionregel eingeführt werden, die eine Anpassung des entsprechenden gefundenen ähnlichsten Lastgang vornimmt, wenn dieser noch aus einer Zeit vor der Veränderung stammt. Diese nachgelagerte Anpassung durch Adaption ist auch eine der schnell umsetzbaren Möglichkeiten, die Prognose eines Künstlichen Neuronales Netzes an geänderte Bedingungen anzupassen. Als weitere Möglichkeit kann aufbauend auf dem bereits trainierten Netz kontinuierlich auch mit neuen Daten trainiert werden, allerdings wird eine gewisse Menge an Lastgängen mit geänderten Bedingungen benötigt, bis sich das Modell weitestgehend an die geänderten Bedingungen angepasst hat. ARIMA-Modelle nehmen die Veränderungen dagegen schnell auf. Durch die Komponentenzersetzung werden bestimmte Trends frühzeitig berücksichtigt und die aktuellsten historischen Lastgänge haben einen hohen Einfluss auf die Prognoseerstellung, sodass hier nur für einen sehr kurzen Zeitraum manuelle Anpassungen wie eine nachträgliche Adaption durchgeführt werden müssten. In der Simulation hingegen können Änderungen an Prozessabläufen oder in der Infrastruktur schon vorab hinterlegt werden. Wie bereits im vorherigen Kapitel beschrieben, werden bei der Simulation nicht zwingend historische Daten benötigt, sodass hier auch mögliche Auswirkungen der Änderungen vorab getestet werden können und damit eine Grundlage für die Adaption von Lastgangprognosen in anderen Verfahren sein können.

Prognoseverfahren	Nötige Anpassungen bei Übertragung auf anderes Terminal	Kategorie Übertragbarkeit
Vergleichstag	Keine Anpassung notwendig	hoch
Fallbasierte Prognose	Anpassung Parametrisierung Ähnlichkeitsmaß Anpassung Adaptionregeln (optional)	mittel
Künstliche Neuronale Netze	Training eines neues Modells Bestimmung optimaler Netzkonfiguration (optional) Bestimmung Werte der Hyperparameter (optional)	mittel
Statistische Verfahren (ARIMA)	Geänderte Modellbestimmung (optional)	hoch
Simulation	Anpassung Simulationsmodell	gering

Tabelle 22: Übersicht zur Bewertung der Übertragbarkeit

Anders sieht es bei der Übertragbarkeit der Verfahren von einem Containerterminal zu einem anderen aus. Es wird davon ausgegangen, dass die gleichen Datenstrukturen bei beiden Terminals identisch sind. In diesem Fall muss bei der Nutzung der Simulation ein neues Simulationsmodell erstellt werden, welches die unterschiedlichen Terminalinfrastrukturen berücksich-

tigt. Eventuell können einige Implementierungen von operativen Strategien wiederverwendet werden, trotzdem bleibt der Aufwand für die Erstellung eines Simulationsmodells eines weiteren Terminals sehr hoch. Für die Fallbasierte Prognose muss überprüft werden, ob die Grundlagen und Annahmen, die bei Erstellung des Domänenmodells eines Terminals galten, auch für das neue Terminal gelten. Prinzipiell wurde die Modellierung sehr generisch gehalten. Ggf. sind einige Parameter der Ähnlichkeitsmaße anzupassen und das globale Ähnlichkeitsmaß neu zu gewichten. Zu überprüfen ist ebenfalls, ob die Annahmen über die klimatischen Auswirkungen auf den Lastgang und der Einfluss der Unterschiede in verschiedenen Containerprofilen auf den Lastgang weiterhin so gelten, oder ob hier einzelne Parameter in der Adaption anzupassen sind. Zudem ist die Fallbasis auf Grundlage des anderen Terminals komplett neu aufzubauen. Bei der Nutzung der Künstlichen Neuronalen Netze für die Prognose reicht es ein neues Modell zu trainieren und es ist zu überprüfen, ob für ein anderes Terminal geeignetere Netzkonfigurationen vorhanden sind, die wiederum neu bestimmte Werte für die Hyperparameter benötigen.

Vergleichstagverfahren und statistische Verfahren sind ohne großen Aufwand zu übertragen, ggf. ist ein neues ARIMA-Modell zu bestimmen, sofern man die Bestimmung statisch gestaltet und nicht dynamisch.

6.4.4 Nachvollziehbarkeit

Der Vorteil der detaillierten Prozessabläufe des Simulationsablaufs liegt darin, dass das Zustandekommen der Werte der Lastgangprognose bis ins Detail nachvollzogen werden kann. Es können Lastgänge von einzelnen Verbrauchern ebenso erstellt werden wie für einzelne Verbrauchsgruppen und deren Verbrauch bei Bedarf isoliert betrachtet oder verwertet werden. Weniger detailliert, aber in der Art und Weise der Erstellung der Prognose und dem Zustandekommen einzelner Werte trotzdem nachvollziehbar ist das einfachste Verfahren, das Vergleichstagverfahren. Hier werden lediglich aus vergangenen Lastgängen gewichtete arithmetische Mittel gebildet. Mit ein paar Einschränkungen ist die Nachvollziehbarkeit des Zustandekommens bei der Fallbasierten Prognose behaftet. Über einen Ähnlichkeitswert kann die Auswahl eines ähnlichsten Tages beschrieben werden, allerdings bleibt die Berechnung der einzelnen Ähnlichkeiten aufgrund der Vielzahl der Parameter im Verborgenen, es ist schwierig für einen Nutzer schnell zu überprüfen, ob es nicht doch einen noch ähnlicheren Fall gab. Allerdings wird mit dem ähnlichsten Tag der verbundene Lastgang als Grundlage für die Prognoseerstellung genutzt und die Anpassungen, die für diesen Lastgang vorgenommen werden, können entsprechend erklärt werden, erfolgen sie doch regelbasiert.

Für den Nutzer nicht unmittelbar nachvollziehbar ist dagegen das Zustandekommen der Prognose bei Nutzung der statistischen ARIMA-Modelle und des Künstlichen Neuronalen Netzes. Hier fungieren die Prognosemethoden gegenüber einem Nutzer als Black-Box und die durchgeführten Berechnungen können nur mit einem sehr hohen Aufwand nachvollzogen werden.

6.5 Zusammenfassende Bewertung

In den vorangegangenen Kapiteln wurden die verschiedenen implementierten Prognoseverfahren anhand einer Fallstudie auf die Effekte der Wissensintegration in die Prognoseerstellung und die jeweils erreichte Prognosegüte untersucht. Zudem wurden weitere Faktoren wie die benötigte Rechenzeit oder Aufwände für Anpassungen diskutiert. Zwei der Verfahren, Simulation und die Fallbasierte Prognose nutzen ein hohes Maß an Domänenwissen. Das Vergleichstagsverfahren, die statistischen Modelle und die Künstlichen Neuronalen Netze nutzen lediglich domänenspezifische Eingabedaten, bei den KNN werden für das Training der Modelle auch zugehörige Ausgabedaten, also Lastgangdaten, benötigt.

In allen Verfahren mit Ausnahme des Vergleichstagsverfahrens hat der Containerumschlag einen wesentlichen Einfluss auf die Prognose. Dabei kann der Containerumschlag über die Segelliste oder dem daraus abgeleiteten Containerprofil genutzt werden. Für die Verfahren konnte zudem gezeigt werden, dass eine höhere Anzahl von Eingabedaten in den meisten Fällen auch zu besseren Prognoseergebnissen führt. Insbesondere für das Künstliche Neuronale Netz konnte durch die Integration weiterer Eingabedaten die Prognosegüte für das Jahr 2013 um etwa 2 % gesteigert werden. Eine Ausnahme stellt hier die Simulation dar, da in einem Simulationsmodell das Wissen über das jeweilige Containerterminal und die Prozessabläufe vollständig kompiliert sind und verschiedene Stufen der Wissensintegration nur schwer zu untersuchen sind.

Bei der Prognosegüte ergab sich für alle Verfahren eine durchgängig geringere Prognosegüte für das Jahr 2014 als für 2013. Als Ursache hierfür kommt die Einführung einer batterie-elektrischen Schwerlastfahrzeugflotte in Betracht, die im Bereich des Horizontaltransports die logistischen Abläufe des Terminals von der Leistungsaufnahme entkoppelt und somit als vom aktuellen Umschlag unabhängiger Großverbraucher auftritt und damit die Charakteristika des Lastgangs verändert. Mit der Fallbasierten Prognose und den Künstlichen Neuronalen Netzen konnte trotzdem im Jahresdurchschnitt ein durchschnittlicher Prognosefehler von unter 10 % erreicht werden, während die weiteren Verfahren diese Grenze überschritten. Auch hier stellt die Simulation insoweit eine Besonderheit dar, als hier eine Integration der Flotte möglich ist, für eine sinnvolle Integration in den Prognoseprozess aber eine Synchronisierung der Batterie-ladezustände und Fahraufträge der aus batterie- und diesel-betriebenen Fahrzeugen bestehenden Mischflotte mit den Echtzeiten notwendig wäre. Durch dieses zusätzliche Wissen könnte die Prognosegüte erhöht werden, allerdings konnte dies im Rahmen dieser Arbeit nicht überprüft werden. Zudem waren nicht alle Strategien des CTA für den Umgang mit den Planungsproblemen eines Terminals bekannt, sodass hier noch Optimierungspotenzial vorhanden ist. Die Untersuchung der Prognoseergebnisse zeigte auch, dass die Fallbasierte Prognose, die Künstlichen Neuronalen Netze und die Simulation einzelne maximale Abweichungen deutlich reduzieren können und damit im Durchschnitt besser abschneiden als die Verfahren, die im Wesentlichen auf den Lastgangdaten der jüngeren Vergangenheit basieren.

Die Prognosegüte ist als ein wesentlicher Faktor bei der Bewertung von Prognoseverfahren zu sehen, es gibt aber auch weitere Entscheidungskriterien, die die Auswahl eines Prognoseverfahrens beeinflussen. Davon wurden einige diskutiert, angefangen mit der benötigten Rechenzeit für eine Prognoseerstellung, die exemplarisch zwischen Sekunden bei Vergleichstagsver-

fahren und KNN liegt und bis zu 5 Minuten für einen Simulationslauf. Die Simulation benötigt auch mit Abstand den höchsten Modellierungsaufwand, kommt aber im Gegenzug prinzipiell ohne historische Daten aus, was sie auch bei der Beurteilung verschiedener Szenarien und Strategien für die logistischen Prozesse und deren Auswirkung auf den Lastgang macht. Möglichst viele historische Daten werden für die Fallbasierte Prognose und das Training eines KNN benötigt, was diese Verfahren wiederum träge gegenüber Veränderungen im logistischen Bereich des Terminals macht. Einige Ideen, um trotzdem kurzfristig auf Veränderungen zu reagieren wurden diskutiert.

Tabelle 23 zeigt die Bewertung der Verfahren auf Basis der Implementierung für die Fallstudie als Zusammenfassung. Dass hier das KNN-Verfahren in Bezug auf die Prognosegüte mit „hoch“ bewertet wurde, liegt maßgeblich in den guten Prognoseergebnissen für das Jahr 2013 begründet. Bei geänderten Lastgangcharakteristika im Jahr 2014 zeigte sich insbesondere die Fallbasierte Prognose relativ robust und erzielte in Bezug auf die Prognosegüte ein nur in geringem Maße abweichendes Prognoseergebnis.

Prognoseverfahren	Prognosegüte	Rechenzeit	Modellierungsaufwand	Umfang benötigter historischer Daten	Anpassbarkeit	Anpassungsaufwand	Übertragbarkeit	Nachvollziehbarkeit
Vergleichstag	gering	gering	gering	gering	gering	gering	hoch	hoch
Fallbasierte Prognose	mittel	gering	hoch	hoch	mittel	mittel	mittel	mittel
Künstliche Neuronale Netze	hoch	gering	mittel	hoch	gering	hoch	mittel	gering
Statistische Verfahren (ARIMA)	gering	mittel	mittel	gering	gering	gering	hoch	gering
Simulation	mittel	hoch	hoch	gering	hoch	hoch	gering	hoch

Tabelle 23: Zusammenfassende Übersicht der Bewertung der Verfahren

Insgesamt lässt sich aus den Bewertungen ableiten, dass die Nutzung von Künstlichen Neuronalen Netzen vorteilhaft erscheint. Voraussetzung ist hier allerdings das Vorhandensein einer ausreichend umfassenden historischen Datenbasis und eine stabile Infrastruktur ohne häufige Änderungen in den Verbrauchscharakteristika der Hauptverbrauchsgruppen. Liegt keine historische Datenbasis vor, so kann die Nutzung der Simulation als vorteilhaft angesehen werden. Auch bei geplanten wesentlichen Veränderungen in den einzelnen Verbrauchsgruppen kann die Simulation genutzt werden, um bereits vorab mögliche Auswirkungen zu testen.

Gute Möglichkeiten zur Anpassung bietet auch die Fallbasierte Lastgangprognose, die über die der ähnlichkeitsbasierten Suche nachgelagerten Adaptionsregeln Anpassungen ermöglicht,

um geänderten Rahmenbedingungen gerecht zu werden. Insgesamt gesehen hat sich in der Fallstudie ergeben, dass ein fallbasiertes System für den Einsatz als Prognosesystem eines Einzelverbrauchers geeignet ist. Zwar fallen die Prognoseergebnisse in einem geringen Maße schlechter aus als bei dem Einsatz von KNN. Dafür ist das Zustandekommen der Ergebnisse nachvollziehbarer und die Anpassungsmöglichkeiten vielfältiger.

Die beiden Verfahren, die ihre Prognose im Wesentlichen auf historischen Lastgangdaten aufbauen, das Vergleichstagverfahren und die statistischen Verfahren in Form der ARIMA-Modelle, können die häufigen unregelmäßigen Schwankungen nur unzureichend darstellen. Dies wird durch die hohen maximalen Abweichungen gezeigt. Wird nur eine ungefähre Prognose des zukünftigen Lastgangverlaufs benötigt, so scheint das Vergleichstagverfahren aufgrund seiner Einfachheit ausreichend, allerdings sollte bei der Nutzung beachtet werden, dass in der Spitze sehr hohe Abweichungen zwischen dem prognostizierten und dem tatsächlichen Verbrauch auftreten können.

7 Rekapitulation und Ausblick

Im Folgenden sollen die Ausführungen dieser Arbeit noch einmal zusammengefasst werden und ein Ausblick auf weitere mögliche Themen mit Bezug zu Prognoseverfahren für den Lastgang in maritimen Containerterminals gegeben werden, die im Rahmen dieser Arbeit nicht betrachtet wurden.

7.1 Rekapitulation

Ein maritimes Containerterminal stellt eine wichtige Schnittstelle in den logistischen Prozessen des weltweiten Handels dar. Um effiziente Prozessabläufe zu gewährleisten werden moderne Containerterminals zunehmend mit automatisiertem elektrifiziertem Umschlaggerät ausgestattet. Dadurch ist ein Containerterminal ein Großverbraucher im Energiesystem. Dieses Energiesystem ist derzeit durch die zunehmende Integration von Erzeugern aus erneuerbaren Energiequellen und damit einhergehender Dezentralisierung vielfältigen Änderungen unterworfen in deren Zuge auch einzelnen Verbrauchern eine größere Rolle zukommt. Während diese im traditionellen Energiesystem eine passive Rolle hatten, können insbesondere Großverbraucher nun eine aktivere Rolle einnehmen. Neben der innerbetrieblichen Optimierung des Stromverbrauchs können auch Flexibilitätspotenziale offen gelegt werden und aktiv im Energieversorgungssystem genutzt werden, um zum Beispiel die Integration von erneuerbaren Energien zu unterstützen. Eine Voraussetzung sowohl für innerbetriebliche Maßnahmen im Rahmen des Energiemanagements als auch bei der aktiven Beteiligung am Energieversorgungssystem ist eine Prognose des Lastverlaufs, um Potenziale für Flexibilität aufdecken, Lastspitzen vermeiden und Lastverschiebemaßnahmen planen zu können.

Mit der vorliegenden Arbeit sollte dies aufgegriffen werden und die Frage beantwortet werden, wie etablierte Verfahren zur Lastgangprognose eines maritimen Containerterminals unter Berücksichtigung von Wissen über die geplanten Betriebsprozesse entwickelt und genutzt werden können. Zudem sollte ein eigenes, nicht-etabliertes Verfahren auf Basis von Fallbasiertem Schließen entwickelt werden. Auch hier war die Frage zu beantworten wie ein solches System entwickelt und genutzt werden kann. Entsprechend der zweiten Frage nahm die Einführung des Fallbasierten Schließens und die Konzeption und Umsetzung der darauf basierenden Fallbasierten Prognose einen wesentlichen Teil der Arbeit ein.

Um die genannten Fragen beantworten zu können wurden nach einer Motivation und der Vorstellung von einzelnen großen Verbrauchern innerhalb des Terminals die Grundlagen der Lastgangprognose vorgestellt und in den energiewirtschaftlichen Kontext eingeordnet. Einzelne etablierte Methoden wurden allgemein eingeführt. Als etablierte Methoden wurden das Vergleichstagverfahren (als Referenz), aus dem Bereich der statistischen Verfahren ARIMA-Modelle, aus dem Bereich der Künstlichen Intelligenz die Künstlichen Neuronalen Netze und die Simulation ausgewählt. Das neu zu konzipierende Verfahren basiert auf Fallbasiertem Schließen, weshalb diese Methode in der Einführung ausführlicher betrachtet wurde. Anschließend wurde der Prozess der Lastgangprognose vorgestellt und Bewertungsmöglichkeiten von Prognoseverfahren diskutiert.

Ein Blick auf verwandte Arbeiten zeigte, dass die Lastgangprognose an sich ein viel diskutiertes Thema in der Wissenschaft ist, die Prognose von einzelnen Großverbrauchern allerdings kaum betrachtet wird. Auch energetische Prozesse in Containerterminals sind nur rudimentär untersucht, ebenso wie die Nutzung des Fallbasierten Schließens für Prognosezwecke. Bei der Untersuchung des Lastverhaltens eines Containerterminals ist die wichtigste Erkenntnis, dass die Schwankungen im Verlauf des Lastgangs im Wesentlichen auf die Krantätigkeiten im Terminal zurückzuführen sind. Entsprechend konnte eine Korrelation zwischen den Containerumschlagzahlen und dem Lastgang gezeigt werden, welche eine wesentliche Grundlage für diese Arbeit bildete. Aber auch meteorologische und kalendarische Einflüsse konnten anhand von Beispielen aufgezeigt werden.

Im Folgenden wurde die Vorverarbeitung der vorhandenen Betriebsdaten besprochen. Grundlage für die Betriebsdaten bildet die Segelliste, welche die geplanten Schiffsankünfte und -abfahrten enthält und pro Schiff die zu ladenden und zu löschenden Container enthält. Die Daten der Segelliste können tagesscharf abgegrenzt werden (Tagessegellisten) und darauf basierend ein Containerprofil erstellt werden, welches die umzuschlagenden Container über die Zeit repräsentiert. Auf Basis dieser Daten wurden die einzelnen Verfahren und die Möglichkeiten zur Einbindung dieser Betriebsdaten in diese Verfahren beschrieben. Bei der Fallbasierten Lastgangprognose erfolgt eine ähnlichkeitsbasierte Suche über den Vergleich von einzelnen Tagessegellisten, angereichert um weitere Kontextdaten wie Kalender- und Wetterinformationen. Anschließend wird der gefundene Lastgang des ähnlichsten Tages auf Basis eines Vergleichs der Containerprofile und Unterschiede in den Kontextdaten an die aktuelle Situation angepasst. Bei der Nutzung der Künstlichen Neuronalen Netze wird das Modell auf Basis der historischen Containerprofile und den Kontextdaten sowie dem jeweils dazugehörigen Lastgang trainiert. Bei der Simulation werden die Infrastruktur des Containerterminals und die Prozessabläufe in einem Simulationsmodell nachgestellt. Die Prozesse werden dann auf Basis der Segelliste simuliert und der damit verbundene Energieverbrauch der einzelnen Verbraucher über die Zeit aufgezeichnet und aggregiert. Im Wesentlichen auf den historischen Lastgangdaten basieren das Vergleichstagverfahren und die ARIMA-Modelle. Beim Vergleichstagverfahren erfolgt lediglich eine Gewichtung mehrerer historischer Lastgänge und der gewichtete Mittelwert wird ohne Berücksichtigung weiterer Daten als Prognose genutzt. ARIMA-Modelle versuchen über die Autokorrelation den zukünftigen Lastverlauf aus dem historischen Lastverlauf herzuleiten. Das Containerprofil und weitere Kontextdaten können als externe Regressoren genutzt werden, um die Prognosefunktionalität zu unterstützen.

Die Konzepte zu diesen Verfahren wurden für das Fallbeispiel Container Terminal Altenwerder in Hamburg umgesetzt. Hierfür lagen die Segellisten und die Lastgangdaten der Jahre 2010 bis 2014 vor, die für die Umsetzung genutzt wurden. Die Daten der Jahre 2010 bis einschließlich 2012 wurden für den Aufbau der Verfahren genutzt. Auf dieser Datenbasis wurden die KNN trainiert, die Fallbasis für die Fallbasierte Prognose aufgebaut und das Simulationsmodell kalibriert. In drei Studien wurden die Ergebnisse dann für die Jahre 2013 und 2014 untersucht, wobei zum Teil die jeweils weiteren verfügbaren Daten für erneute Trainings oder die Erweiterung der Fallbasis genutzt wurden.

Die erste Studie befasste sich mit den Effekten der Wissensintegration in den Prognoseprozess und der damit einhergehenden Verbesserung der Prognosegüte. Für die ARIMA-Modelle und

das Künstliche Neuronale Netz konnte dabei eine stufenweise Einbindung der Daten durchgeführt werden und untersucht werden, ob mehr Eingabeparameter auch zu besseren Prognoseergebnissen führen, was überwiegend der Fall war. Für die Fallbasierte Prognose wurde untersucht, welchen Effekt die nachträgliche Adaption des gefundenen ähnlichsten Lastgang hat, indem die Ergebnisse mit und ohne Adaption verglichen wurden und damit die Verbesserung der Ergebnisse durch die Adaption gezeigt werden konnten. Zudem wurde gezeigt, dass sich die Nutzung des Durchschnitts der drei ähnlichsten Fälle vorteilhaft gegenüber der Nutzung lediglich eines einzelnen ähnlichsten Falles verhält. Auch für das Vergleichstagverfahren konnte gezeigt werden, dass eine Mittelwertbildung über mehrere historische Lastgänge die Prognosegüte erhöht. Bei der Simulation ist das gesamte Wissen über das Containerterminal und seine Abläufe in das Simulationsmodell eingebracht worden, sodass hier keine abgestuften Vergleiche mit verschiedenen Ansätzen der Wissensintegration durchgeführt werden konnten.

In der zweiten Studie wurden die Prognoseergebnisse der jeweils besten Varianten der einzelnen Verfahren für die Jahre 2013 und 2014 untersucht. Hierbei wurden sowohl die durchschnittlichen mittleren absoluten Abweichungen betrachtet, wie auch die maximalen und minimalen Abweichungen innerhalb eines Monats diskutiert. Zudem wurde erörtert, ob es zu systematischen Über- oder Unterschätzungen des tatsächlichen Lastverlaufes kommt. Mit dem Vergleichstagverfahren und den ARIMA-Modellen erzielten die Verfahren, welche im Wesentlichen auf den historischen Lastgangdaten aufbauten, die geringsten durchschnittlichen Prognosegüten, wobei die ARIMA-Modelle etwas besser abschnitten als das Vergleichstagverfahren. Auffällig waren bei beiden Verfahren maximale Abweichungen für einzelne Tage von bis zu über 50 %, welche eine Nutzung als Prognosemethode nicht empfehlenswert erscheinen lassen. Insbesondere bei kurzfristigen, täglichen starken Schwankungen im Verbrauchsverhalten ergaben sich diese Abweichungen. Bessere Prognoseergebnisse erzielten dagegen die Simulation und die Fallbasierte Lastgangprognose, wobei diese insbesondere für 2014 durchschnittlich bessere Ergebnisse erzielte. Insbesondere die maximalen Abweichungen wurden gegenüber den anderen Verfahren sehr deutlich reduziert, insbesondere die Simulation zeigte sich hier sehr stabil. Durchgängig die besten Prognoseergebnisse zeigte das Künstliche Neuronale Netz, sowohl was die durchschnittlichen Prognoseabweichungen, als auch die maximalen Abweichungen angeht. Für das Jahr 2014 lag das KNN allerdings nur knapp vor der Fallbasierten Prognose. Für alle Verfahren galt, dass die Prognoseergebnisse sowohl im Durchschnitt als auch in den maximalen Werten in 2014 höhere Abweichungen von den tatsächlichen Lastgängen aufwiesen. Dies kann auf die erweiterte Einführung von batterie-elektrischen Schwerlastfahrzeugen zurückgeführt werden, die mit den Ladeprozessen für die Batteriesysteme neben der Einführung einer neuen wesentlichen Verbrauchsgruppe auch die elektrische Leistungsaufnahme durch die Energiespeicherung in den Batterien und der nachgelagerten Abgabe dieser Energie, die Umschlagprozesse von der Leistungsaufnahme entkoppeln, zumindest für den Horizontaltransportbereich. Hier werden weitere Methoden benötigt, die den Zeitpunkt der Ladeprozesse prognostizieren und deren Ergebnisse in die hier implementierten Verfahren integriert werden müssen.

In der dritten Studie wurden weitere Kriterien für Prognoseverfahren untersucht beziehungsweise diskutiert. Es erfolgte jeweils eine Einteilung in eine von drei Klassen. Beim Vergleich

des Rechenaufwands benötigten das KNN und das Vergleichstagverfahren die kürzeste Zeit, die Simulation benötigte hier mit Abstand die längste Zeit. Den geringsten manuellen Modellierungsaufwand weist das Vergleichstagverfahren auf, da es so gut wie keine individuelle Modellierung benötigt. Alle anderen Verfahren binden die Betriebsdaten des Terminals ein, die eine entsprechende Vorverarbeitung nötig machen. Während bei der Fallbasierten Prognose Domänenwissen in Ähnlichkeitsmaße, Fallbasis und Adaptionenregeln integriert wird, entdeckt das KNN die Zusammenhänge selbstständig, muss dafür aber aufwändig trainiert werden. Für diesen Trainingsprozess wiederum müssen die entsprechenden Parameter, die sogenannten Hyperparameter, vorab bestimmt werden. Die aufwändigste Modellierung erfordert die Simulation, hier müssen die Infrastruktur und die Prozesse des Terminals möglichst exakt nachgebildet werden. Dafür kommt die Simulation prinzipiell ohne historische Daten aus, während die Fallbasierte Prognose und die Künstlichen Neuronalen Netze auf eine möglichst große Basis von historischen Daten angewiesen sind. Entsprechend träge reagieren beide Verfahren auch auf Änderungen im Lastgangverhalten. Während die Fallbasierte Prognose hier mit dem Prinzip der Adaption noch Anpassungsmöglichkeiten bietet, benötigt das KNN hier erst eine ausreichende Datenbasis, bevor das Modell im Rahmen eines neuen Trainings angepasst werden kann. Besonders hoch ist der Aufwand für Anpassungen bei der Simulation, allerdings bietet sich hier die Möglichkeit, Auswirkungen von verschiedenen Änderungen der Infrastruktur oder an den Prozessabläufen vorab zu testen. Das Vergleichstagverfahren und die ARIMA-Modelle reagieren im Rahmen der Berücksichtigung der historischen Lastgänge selbstständig auf Veränderungen und haben damit keinen oder nur geringen Anpassungsaufwand bei Änderungen. Entsprechend hoch ist deren Übertragbarkeit von einem Containerterminal auf einen anderen Containerterminal, während bei wissensintensiven Verfahren wie der Fallbasierten Prognose und insbesondere bei der Simulation umfangreiche Anpassungen vorgenommen werden müssen. Dafür bieten diese beiden Verfahren wiederum eine Nachvollziehbarkeit des Vorgangs der Prognoseerstellung, die insbesondere bei Künstlichen Neuronalen Netzen nicht gegeben ist. Diese funktionieren als Black-Box.

Im Rahmen dieser Arbeit wurde damit gezeigt, wie Wissen über die Betriebsabläufe eines maritimen Containerterminals in verschiedene Prognoseverfahren des elektrischen Lastgangs integriert werden kann und dass dies positive Effekte auf die Prognosegüte hat. Bezogen auf die Ergebnisse der Prognose schneidet die Prognose mit einem Künstlichen Neuronale Netz am besten ab und stellt damit ein geeignetes Verfahren für die kurzfristige Lastgangprognose dar. Es konnte zusätzlich gezeigt werden, dass Verfahren basierend auf Fallbasiertem Schließen ebenfalls erfolgreich für die Prognose des Lastgangs eingesetzt werden können und somit die Verfahren aus dem Bereich der Künstlichen Intelligenz die besten Prognoseergebnisse erzielen. Die dafür benötigte Modellierung für den Aufbau der Fallbasis, der benötigten Ähnlichkeitsmaße und einige nutzbare Anpassungsregeln wurden vorgestellt. Das aufwändigste Verfahren, die Simulation, hat insbesondere Vorteile, wenn nur wenige oder keine historischen Daten vorliegen oder Änderungen in der Infrastruktur oder den Prozessabläufen des Terminals mit Auswirkungen auf den Lastgang bevorstehen, da eine Vorab-Abschätzung der Auswirkungen möglich ist.

7.2 Ausblick

Im Rahmen dieser Arbeit wurden verschiedene Lastgangprognoseverfahren vorgestellt, implementiert und miteinander verglichen. Dabei wurden insbesondere die Möglichkeiten und Effekte der Integration von Wissen über Betriebsabläufe eines Containerterminals in die Prognoseverfahren untersucht. Während der Implementierung sind einige Punkte aufgefallen, die in Folgearbeiten weiter untersucht werden könnten. Diese werden im Folgenden kurz beschrieben:

- *Integration der Elektromobilität:* Im Rahmen der Evaluation auf Basis der Fallstudie wurde festgestellt, dass die Prognoseergebnisse durchgängig für alle Verfahren für 2014 schlechter waren als für 2013. Gleichzeitig geht aus dem Projektendbericht des Projektes BESIC [Bes16] hervor, dass sich in 2014 die Leistungsaufnahme der batterie-elektrischen AGV deutlich erhöht hat. Dieses kann als eine Ursache für die verschlechterten Prognoseergebnisse ausgemacht werden. Da mit der Nutzung von Batterietechnik und der damit verbundenen Speicherung und zeitversetzten Nutzung der Energie, die eigentliche Umschlagfähigkeit von der Leistungsaufnahme entkoppelt wird, benötigt es einen anderen Ansatz, um die Batteriewechselzeitpunkte und die anschließenden Ladevorgänge zu prognostizieren. Dies ist insbesondere herausfordernd in gemischt-betriebenen Schwerlastflotten, bei denen Teile der Flotte batterie-elektrisch und andere Teile diesel-elektrisch betrieben werden. Hier müssen vermutlich genaue Transportzuweisungen zu einzelnen Fahrzeugen berücksichtigt werden. Daten hierfür lagen im Rahmen dieser Arbeit nicht vor. Die entsprechende Prognose der Batterieladezeiten könnte dann in die Prognoseverfahren des Gesamtlastgangs integriert werden.
- *Nutzung von anderen Retrieval-Techniken für die Fallbasierte Prognose:* Im Rahmen dieser Arbeit wurde ein sequentielles Retrieval implementiert, was für die vorhandene Anzahl von Fällen noch ausreichend ist. Mit einer wachsenden Fallbasis sollten aber spezialisierte Retrievaltechniken wie Case-Retrieval-Netze oder Fish-and-Shrink (vgl. Kapitel 2.4) genutzt werden, um eine ausreichende Effektivität zu gewährleisten und die Rechenzeit für die Erstellung einer Prognose nicht zu lang werden zu lassen.
- *Nutzung von Techniken des Deep Learning:* Im Rahmen dieser Arbeit wurde für die Künstlichen Neuronalen Netze ein Feed-Forward-Netz mit zwei verdeckten Schichten genutzt und mittels Backpropagation trainiert. Derzeit erlebt Deep Learning eine hohe Beachtung, bei dem Netze mit deutlich mehr und verschiedenen Schichten genutzt werden. Für die Prognose von Zeitreihen haben sich insbesondere Rekurrente Netze als erfolgreich erwiesen. Diese haben die Fähigkeit, bestimmte Werte über mehrere Schichten hinweg zu speichern und bei späteren Durchläufen auf diese vorherigen Werte mit zurückzugreifen. Die Konfiguration und das Training eines Rekurrenten Netzes benötigt aber spezielle Techniken, die den Rahmen dieser Arbeit überstiegen hätten. Ein Vergleich der Prognosegüte eines „klassischen“ KNN, wie in dieser Arbeit genutzt, mit einem Deep Learning KNN auf Basis von Rekurrenten Netzen wäre aber sicherlich von wissenschaftlichem Interesse.

- *Nutzung von Prognose-Ensembles:* Im Rahmen dieser Arbeit wurden die einzelnen Prognoseverfahren separat betrachtet und miteinander verglichen. Erfolgversprechend könnte auch die Kombination verschiedener Verfahren sein. So könnte der Mittelwert aus den zwei Verfahren mit der besten Prognosegüte, dem KNN und der Fallbasierten Prognose, noch einmal zu einer Steigerung der Prognosegüte führen und auch dazu beitragen, dass hohe Abweichungen im Einzelnen noch weiter vermieden werden können.
- *Untersuchung der Übertragbarkeit auf andere Hafentypen:* Wesentliche Grundlage für die Berücksichtigung der Betriebsprozesse des Containerterminals war die Segelliste mit den pro Schiffsaufenthalt geplanten Umschlagzahlen für Container. Andere Typen von Frachthäfen, wie zum Beispiel Stückgutterminals oder Häfen für Massenschüttgüter nutzen ebenfalls Segellisten für die Planung der Betriebsabläufe. Es ist zu untersuchen, inwieweit hier die andere Art des Umschlags, auf weniger standardisierte Weise als bei einem Containerterminal, auch den Zusammenhang zwischen den jeweiligen Umschlagstätigkeiten und dem Verlauf des Lastgangs herleiten lässt.

Insgesamt ergeben sich damit noch Anknüpfungspunkte an diese Arbeit, die weitere Untersuchungen ermöglichen. Inzwischen hat das Container Terminal Altenwerder angekündigt, die gesamte Flotte seiner AGVs auf batterie-elektrischen Antrieb umzustellen und statt des bisherigen Batteriewechselprinzips auf Ladesäulen zu setzen. Die Auswirkungen dieser Entscheidung und damit einhergehend die Prognostizierbarkeit des Gesamtlastgangs sind zu untersuchen. Insbesondere ergeben sich durch die deutlich erhöhte Anzahl von Fahrzeugen und die damit verbundenen Batterieladevorgänge erweiterte Möglichkeiten für die Nutzung der Flexibilität der Ladevorgänge in einem energiewirtschaftlichen Kontext. Als Basis dafür wird weiterhin die Prognose des Gesamtlastgangs eine wesentliche Rolle spielen.

Anhang

A) Monatliche Prognoseergebnisse je Verfahren

Vergleichstaggerfahren						
	2013			2014		
	MPE	MAPE	RMSPE	MPE	MAPE	RMSPE
Januar	0,507	14,450	17,102	-0,515	11,278	13,542
Februar	1,784	11,056	14,181	4,898	13,626	16,505
März	2,140	12,014	14,957	1,423	11,944	14,300
April	1,105	11,710	14,495	-1,040	8,895	11,424
Mai	-1,668	9,074	11,492	0,113	10,836	13,783
Juni	2,653	12,050	14,498	2,434	10,589	13,517
Juli	-0,239	9,941	12,032	0,802	12,110	15,077
August	2,167	12,278	15,121	2,426	13,532	16,144
September	0,615	8,603	11,240	0,508	11,306	13,764
Oktober	0,964	10,604	12,837	3,269	17,770	21,369
November	1,935	12,566	14,743	3,956	15,617	19,001
Dezember	1,813	12,689	15,263	6,396	19,683	23,871

Fallbasierte Lastgangprognose						
	2013			2014		
	MPE	MAPE	RMSPE	MPE	MAPE	RMSPE
Januar	0,227	8,922	12,055	-1,451	9,080	9,689
Februar	-0,907	7,161	9,475	4,937	9,330	13,039
März	-2,731	8,462	10,715	3,492	8,688	11,914
April	1,893	8,522	10,243	3,284	7,397	10,377
Mai	-1,455	7,069	9,542	-1,101	9,661	10,514
Juni	0,130	7,478	9,998	1,632	10,130	12,377

Juli	-4,220	8,864	11,234	-1,492	9,728	10,830
August	-3,015	8,794	10,891	2,114	8,052	10,041
September	-5,088	8,256	10,798	3,498	8,913	11,325
Oktober	-7,353	10,264	11,919	0,893	11,316	13,214
November	-4,127	8,248	9,946	9,074	11,211	16,101
Dezember	-2,688	9,307	11,445	8,600	11,547	17,823

Zeitreihenanalyse						
	2013			2014		
	MPE	MAPE	RMSPE	MPE	MAPE	RMSPE
Januar	0,976	10,241	12,435	-0,472	9,512	11,267
Februar	1,313	9,871	12,670	5,183	12,937	14,972
März	4,726	10,882	13,272	2,420	11,420	13,740
April	1,404	9,136	11,477	3,585	9,711	12,249
Mai	-0,452	9,009	11,228	2,411	9,333	12,093
Juni	2,503	12,621	14,825	2,515	9,086	11,874
Juli	-0,553	8,755	10,608	0,500	11,150	13,520
August	3,807	10,213	12,526	1,696	11,714	14,019
September	0,132	7,656	9,835	0,628	14,575	16,709
Oktober	1,866	10,618	12,698	-0,767	21,021	24,117
November	0,264	11,504	13,266	2,019	16,310	19,164
Dezember	1,853	11,088	13,427	2,024	15,617	19,250

Künstliche Neuronale Netze						
	2013			2014		
	MPE	MAPE	RMSPE	MPE	MAPE	RMSPE
Januar	0,925	6,950	8,790	-0,928	7,845	9,619
Februar	-1,318	6,123	7,822	4,360	8,634	10,866
März	-2,221	7,322	9,010	5,181	8,339	10,673
April	4,343	7,499	9,753	6,118	7,695	10,286
Mai	-0,152	6,681	9,177	5,291	8,402	11,208

Juni	4,344	7,831	10,190	7,389	10,831	13,664
Juli	-1,245	7,681	9,704	4,722	8,178	10,537
August	0,048	7,973	9,941	9,178	10,283	12,474
September	-1,509	6,168	7,778	10,820	11,774	14,308
Oktober	-4,349	7,614	9,277	7,128	9,544	12,622
November	-4,610	7,867	9,074	10,355	12,107	15,213
Dezember	-2,677	7,428	8,986	6,951	10,712	13,620

Simulation						
	2013			2014		
	MPE	MAPE	RMSPE	MPE	MAPE	RMSPE
Januar	1,894	8,883	11,401	1,800	9,290	11,411
Februar	2,774	8,718	11,241	4,536	10,603	13,305
März	3,679	9,651	12,121	4,043	10,583	13,245
April	2,236	8,943	11,335	4,386	10,247	12,885
Mai	1,674	9,637	12,312	3,034	10,606	13,686
Juni	3,389	8,767	11,257	3,479	10,471	12,859
Juli	2,404	8,529	11,119	2,531	10,219	12,994
August	4,953	9,519	11,949	5,373	10,699	13,076
September	3,042	8,473	10,582	3,424	10,146	12,666
Oktober	2,132	7,998	10,169	2,157	11,443	14,575
November	3,566	8,322	10,430	4,897	12,555	15,516
Dezember	4,153	10,594	13,291	3,497	13,552	17,308

B) Für die Implementierung genutzte Komponenten

Software-Integrationsplattform für alle Verfahren:

- Java SE Deveopment Kit 7
- OSGi-Framework, Version 6
- Jollyday, Version 0.4.9 & Joda Time API, Version 2.8.1
- SQLite, Version 3.10

Zusätzliche Softwarekomponenten je Verfahren:

- Fallbasierte Lastgangprognose:
 - myCBR, Version 3
- Zeitreihenanalyse:
 - R, Version 3.3.1 mit Paketen „tseries“, Version 0.10-35 & „forecast“, Version 7.1
 - JRI – Java/R Interface, Version 0.5-0
- Künstliche Neuronale Netze:
 - Deeplearning4j, Version 0.9.1
- Simulation:
 - Tecnomatix Plant Simulation 11 TR3

Wetterdaten:

- Historische Wetterdaten:
 - Deutscher Wetterdienst, Station 1975
- Prognose Wetterdaten:
 - Wunderground.com, Locationkey: zmw:00000.1.10147

Abkürzungsverzeichnis

ACF	Autokorrelationsfunktion
ADF	Augmented-Dickey-Fuller-Test
AGV	Automated Guided Vehicles
AIC	Akaike Information Criterion
AR	Autoregressive Prozesse
ARIMA	Autoregressive-integrated moving average
ARIMAX	Autoregressive-integrated moving average with exogenous input
ARMA	Autoregressive-moving-average
BDEW	Bundesverband der Energie- und Wasserwirtschaft e.V.
BE	Bewegliche Einheit
BESIC	Batterie-elektrische Schwerlastfahrzeuge im intelligenten Terminalbetrieb
BKV	Bilanzkreisverantwortlicher
CTA	Container Terminal Altenwerder
DI	Daily information
DoE	Design of Experiments
ECT	Europe Container Terminals Rotterdam
EEX	European Energy Exchange, europäische Energiebörse
ENTSO-E	Verband Europäischer Übertragungsnetzbetreiber
EU	Europäische Union
EVU	Energieversorgungsunternehmen
FBS	Fallbasiertes Schließen
HT/NT	Haupttarif/Nebentarif
IT	Informationstechnologie

JSNR	Jahresschiffsnummer
KI	Künstliche Intelligenz
KNN	Künstliche Neuronale Netze
KPSS	Kwiatkowski-Philips-Schmidt-Schin-Test
kWh	Kilowattstunde
LTLF	Long term load forecasting
MA	Gleitende Mittelwertmodelle (moving average)
MAE	Mean absolute error
MAPE	Mean absolute percentage error
ME	Mean error
MLC	Multi-Load-Carrier
MLE	Maximum likelihood estimation
MLP	Multilayer-Perceptron
MPE	Mean percentage error
MSE	Mean squared error
MTLF	Medium term load forecasting
MWh	Megawattstunden
OTC	Over-the-counter
PACF	Partielle Autokorrelationsfunktion
RBF	Radial Basis Functions-Netzwerke
RMG	Rail-Mounted-Gantry-Crane
RMSE	Root mean square error
RMSPE	Root mean squared percentage error
RNN	Rekurrente Neuronale Netzwerke
RTG	Rubber-Tyred-Gantry-Crane
SA	Schiffsaufenthalt

SDK	Software Development Kit
SL	Segelliste
SLC	Single-Load-Carrier
SLP	Standardlastprofil
SOM	Self-Organizing-Maps
STL	Seasonal decomposition of time series by Loess
STLF	Short term load forecasting
TOS	Terminal Operation System
ULS	Unconditional least squares
VA	Virtual arrival
VD	Virtual departure
VDE	Verband der Elektrotechnik Elektronik Informationstechnik e. V.
VSTLF	Very short term load forecasting
VTV	Vergleichstagverfahren

Glossar

Adaptionsregel: Im Bereich des Fallbasierten Schließens ist eine Adaptionsregel eine Vorschrift, wie ein gefundener ähnlicher Fall aus der Fallbasis an die aktuelle Situation (Kontext) angepasst wird.

Ähnlichkeitsmaß: Die Ähnlichkeit im Kontext von Fallbasierten Schließens hat die Funktion, die Nützlichkeit eines Falles für die Lösung des Problems der Anfrage zu approximieren. Lokale Ähnlichkeitsmaße beschreiben die Ähnlichkeit von einzelnen Attributen zueinander, globale Ähnlichkeitsmaße basieren auf der Aggregation von lokalen Ähnlichkeitsmaßen und beschreiben die Ähnlichkeit von Fällen.

Autokovarianz: Die Autokovarianz untersucht den Zusammenhang zwischen Realisationen einer Zufallsvariablen zu unterschiedlichen Zeitpunkten.

Automated Guided Vehicle (AGV): Transportfahrzeug, welches automatisch gesteuert wird. In Containerterminals dienen AGVs dem vollautomatischen Containertransport zwischen den Containerbrücken an der Kaimauer und dem Lagerbereich. Die Be- und Entladung mit Containern erfolgt automatisiert über die entsprechenden Kransystemen an den entsprechenden Bereichen.

Autoregressive Prozeß: Der Begriff autoregressiv beschreibt stochastische Modelle, welche die Zielvariable auf die Linearkombination der Werte zu früheren Zeitpunkten und einen aktuellen Fehlerterm zurückführen.

Backpropagation: Backpropagation ist ein überwachtes Lernverfahren, welches während des Trainings eines Künstlichen Neuronalen Netzen verwendet wird, um einen Gradienten zu berechnen, der für die Berechnung der im Netz zu verwendenden Gewichte benötigt wird. Anhand des Gradienten erfolgt eine Anpassung der Gewichte des Netzes (Fehlerrückführung).

Betriebsprozesse: In einem maritimen Containerterminal bestehen die Betriebsprozesse im Wesentlichen aus dem Umschlag von Containern zwischen verschiedenen Teilen der Logistikkette (Schiff, Bahn, LKW), der Ein-, Aus- und Umlagerung der Container sowie dem Transport der Container innerhalb des Terminalgeländes.

Bilanzkreis: Ein Bilanzkreis ist ein virtuelles Energiemengenkonto, welches alle tatsächlichen physikalischen Einspeisungen und Entnahmen den virtuellen Energieflüssen auf der Handelsebene innerhalb einer Regelzone gegenüberstellt. Der Bilanzkreisverantwortliche ist für einen ausgeglichenen Saldo und verbleibende Abweichungen verantwortlich. Für die Bilanzkreisführung ist täglich eine Lastprognose der dem Bilanzkreis zugeordneten Einspeise- und Entnahmestellen zu erstellen.

Containerbewegung: siehe Containerumschlag

Containerbrücke: Eine Krananlage zum Be- und Endladen von Containerschiffen in maritimen Containerterminals. Eine Containerbrücke besteht üblicherweise aus der eigentlichen Krananlage, ein oder zwei Laufkatzen und einer Schienenanlage aus Kranschienen zum seitlichen versetzen der Krananlage.

Containerumschlag: Ein Containerumschlag beschreibt den Transport von einem Schiff in ein landseitiges Lager oder von einem landseitigen Lager auf ein Schiff. Alternativ kann ein Containerumschlag auch als Containerbewegung bezeichnet werden.

Containerumschlagprofil: Das Containerumschlagprofil eines Tages enthält alle stundenscharf abgegrenzten Containerumschläge für den Tag d , aggregiert über alle in der jeweiligen Stunde relevanten Schiffsaufenthalte. Die Containerumschläge umfassen sowohl die zu löschenden als auch die zu ladenden Container der Schiffsaufenthalte des entsprechenden Tages.

DateTime: Datentyp, der sowohl Datums-, als auch Zeitinformationen speichert.

Demand Response: Demand Response ist eine kurzfristige und planbare Veränderung der Leistungsaufnahme eines Verbrauchers als Reaktion auf Preissignale im Markt oder auf eine Aktivierung im Rahmen einer vertraglichen Reserveleistungserbringung.

Demand Side Integration: Überbegriff, der Demand Response und Demand Side Management zusammenfasst.

Demand Side Management: Energieeffizienzmaßnahmen und verbraucherseitige Energiemanagementmaßnahmen, ergänzt um Reaktion auf äußere Anreize zur Anpassung des aktuellen Leistungsbezugs.

Distanzmaß: Ein Distanzmaß beschreibt die statistische Entfernung zwischen Merkmalsausprägungen einzelner Attribute.

Energiemanagement: Energiemanagement ist die vorausschauende und systematisierte Koordinierung der Beschaffung, und Nutzung von Energie innerhalb eines Unternehmens mit dem Ziel der Reduktion des Energieverbrauchs und der damit verbundenen Energiekosten. Die Norm DIN EN ISO 50001 beschreibt Anforderungen zur Umsetzung eines systematischen Energiemanagementsystems in Unternehmen.

Exportcontainer: Container, der von einem landseitigem Lager auf ein Schiff transportiert werden soll.

Fahrplan: In Leistungsmittelwerten vereinbarte Zeitreihe über die Lieferung bzw. den Bezug von elektrischer Energie in einem bestimmten Zeitraum.

Fall: Ein Fall ist die Beschreibung einer in der Realität aufgetretenen Situation bzw. Problemstellung und der dazugehörigen validierten Problemlösung. Ein Anfragefall ist ein spezieller Fall, der keinen Lösungsteil enthält. Fälle können u. a. als Attribut-Wert-Vektor dargestellt werden.

Fallbasiertes Schließen: Maschinelles Lernverfahren, welches versucht, neue Probleme auf Basis von ähnlichen vergangenen und gespeicherten Problemen und den bei der Problemlösung gemachten Erfahrungen zu lösen. Die vergangene Problemlösung wird als Fall bezeichnet, der zusammen mit weiteren Fällen die Fallbasis bildet. Bei der Lösung wird aus dieser Fallbasis ein ähnlicher Fall abgerufen, ggf. an die aktuelle Situation angepasst und anschließend zur Problemlösung herangezogen. Ist diese erfolgreich, so kann der aktuelle Fall ebenfalls zur Fallbasis hinzugefügt werden.

Feeder: Ein Feederschiff (kurz: Feeder) ist ein Containerschiff, welches im Zuliefer- und Verteilerverkehr für große Seehäfen genutzt wird. Große Feederschiffe können mehr als 1000 TEU aufnehmen.

Float: Datentyp, der Gleitkommazahlen speichert.

Geometrische Reihe: In dieser Arbeit wird die geometrische Reihe zur gewichteten Mittelwertbildung von Referenztagen im Rahmen des Vergleichstagverfahren genutzt. Dabei werden weiter zurück liegende Tage geringer gewichtet (wie z. B. im Bereich der Gasversorgung üblich).

Grundlast: Die Grundlast bezeichnet die Belastung eines Stromnetzes oder Teilnetzes, die während eines Tages nicht unterschritten wird. In einem Containerterminal ist die Grundlast, die Leistungsaufnahme, welche unabhängig von der Durchführung logistischer Prozesse ist. Tage an denen nur die Grundlast auftritt, sind zum Beispiel Feiertage, an den das Terminal seinen Betrieb einstellt.

Hinterlandverkehr: Der Hinterlandverkehr beschreibt den An- und Abtransport von Containern auf dem Landweg (Bahn oder LKW) zum Terminal bzw. von dort weg. Eine genauere Bezeichnung lautet Seehafenhinterlandverkehr.

Hyperparameter: Im Bereich des maschinellen Lernens sind Hyperparameter Parameter, die bereits vor Beginn des Trainings des entsprechenden Modells festgelegt werden. Im Gegensatz dazu, werden Werte von Parametern während des Trainingsprozesses bestimmt.

Importcontainer: Container, der von einem Schiff in ein landseitiges Lager transportiert werden soll.

Integer: Datentyp, der ganzzahlige Werte eines endlichen Wertebereichs speichert.

Kahn: Ein Kahn ist ein Wasserfahrzeug zum Gütertransport ohne eigenen Antrieb

Korrelation: Die Korrelation ist ein statistisches Maß für die Quantifizierung der linearen Abhängigkeit zwischen zwei Variablen.

Künstliches Neuronales Netz: Informationsverarbeitendes System mit einer großen Anzahl parallel arbeitenden und miteinander verbundenen einfachen Einheiten (Neuronen). Die Neuronen können in verschiedenen verarbeitenden Schichten angeordnet sein. Ein KNN konfiguriert sich für die Bearbeitung eines Problems in einem Lernprozess anhand von

Trainingsbeispielen selbstständig. Dafür können verschiedene Lernverfahren zum Einsatz kommen (z. B. Backpropagation)

Lag: Ein Lag beschreibt in der Zeitreihenanalyse die Zeitdifferenz zwischen zwei Zeitpunkten.

Last: Die Last beschreibt verallgemeinert die elektrische Leistung, die durch einen oder mehrere Verbraucher an einem Stromanschluss (z.B. an das örtliche Verteilnetz) entnommen wird.

Lastgang: Gemessene Energiezeitreihe, die über die Integration der Leistung pro Abrechnungsperiode bestimmt wird. Im Bereich Energie beträgt die Abrechnungsperiode 15 Minuten für den Bereich Strom.

Leistung (elektrisch): Elektrische Leistung ist im physikalischen Sinne das Produkt aus Strom und Spannung. Die Messung erfolgt in der Grundeinheit Watt (W).

Leistung: Die elektrische Leistung ist eine physikalische Größe. Die elektrische Leistung entspricht dem Produkt von Stromstärke und Spannung.

Leistungsspitze: Die von einem Verbraucher maximal bezogene elektrische Leistung in einem definierten Zeitraum (z.B. ein Jahr). Normalerweise wird diese über 15 Minuten gemittelt.

Marktrolle: Marktrollen entstanden durch die Liberalisierung des Energiemarktes

Microgrid: Eine lokale Gruppe von Energieverbrauchern (Lasten) und Energieerzeugungseinheiten innerhalb klar definierter elektrischer Grenzen, die als eine einzige steuerbare Einheit in Bezug auf das Netz fungiert.

Moving Average: Bei Moving-Average-Modellen geht man davon aus, dass die Zeitreihe nicht aus sich selbst, sondern aus den vorangegangenen Störungen erklärt werden kann. Als Störungen werden dabei die Abweichungen der einzelnen beobachteten Werte vom Durchschnitt der Zeitreihe bezeichnet

Netzbetreiber: Privat- oder öffentlich-rechtlich organisiertes Unternehmen, das die Dienstleistungen zum Betrieb der Netze für die leitungsgebundene Energieversorgung erbringt. Im Bereich Strom wird zwischen Übertragungsnetzbetreiber (Hoch- und Mittelspannung) und der Verteilnetzbetreiber (Mittel- und Niederspannung) unterschieden.

Normierung: Normierung (oder Normalisierung) bedeutet in der Statistik die Skalierung des Wertebereichs einer Variablen auf einen bestimmten Bereich, üblicherweise zwischen 0 und 1.

Nützlichkeit: Die Wiederverwendung eines ähnlichen Falles im Zusammenhang mit einem bestimmten Problem soll dazu nutzen, den aktuellen Fall erfolgreich zu lösen. Die Nützlichkeit eines ähnlichen Falles kann immer erst nach Anwendung bestimmt werden (a

posteriori). Die Ähnlichkeit hat die Funktion die Nützlichkeit vorab zu approximieren (a priori).

Prognosegüte: Die Prognosegüte ist ein Maß der Übereinstimmung zwischen prognostizierten und realisierten Werten einer Variablen. Für die Prognosegüte existieren verschiedene Statistische Kennzahlen (z. B. MAPE).

Reagibilität: Reagibilität beschreibt eine (schnelle) automatisierte Anpassung an ein geändertes Verhalten einer Zeitreihe. Reagibilität geht häufig zu Lasten der Stabilität.

Regelleistung: Automatisch oder manuell abrufbare Leistung, die der Netzbetreiber nutzen kann, um unvorhergesehene Leistungsschwankungen in seinem Stromnetz auszugleichen. Es wird zwischen positiver und negativer Regelleistung unterschieden. Wenn die ins Netz eingespeiste Energie die zum selben Zeitpunkt entnommene Energie übersteigt, benötigt der Netzbetreiber negative Regelenergie durch Stromabnehmer, die dem Netz kurzfristig Strom entziehen. Bei nicht prognostizierter, erhöhter Stromnachfrage ist positive Regelenergie erforderlich. Der Netzbetreiber benötigt in diesem Fall kurzfristig zusätzliche Einspeisung von Energie in sein Netz oder eine entsprechende Reduzierung des Energieverbrauchs.

Regression: Regression versucht mittels statistischer Analyseverfahren einen Zusammenhang zwischen zwei oder mehr Variablen darzustellen. Dabei ist eine Variable abhängig von einer oder mehreren (unabhängigen) Variablen. Regressionsanalysen werden insbesondere verwendet, wenn Zusammenhänge quantitativ zu beschreiben oder Werte der abhängigen Variablen zu prognostizieren sind.

Seeschiff: Schiff, welches aufgrund seiner Bauweise dazu geeignet ist, nicht nur in Küsten- und Binnengewässern zu verkehren, sondern auch auf hoher See. Große Containerschiffe sind Seeschiffe mit einer Kapazität von bis zu über 20.000 TEU.

Segelliste: Auflistung von Daten zu Schiffsankünften und -abfahrten eines Frachthafens. In einem Containerterminal kann die Segelliste auch mit Containerumschlagszahlen pro Schiff angereichert werden. Die einfache Segelliste enthält Informationen zu allen derzeit vor Anker liegenden Schiffen und den geplanten Schiffsaufenthalten im Hafen. Die tägliche Segelliste enthält die entsprechenden Daten abgegrenzt für genau einen Tag.

Simulation: Simulation beschreibt die Nachbildung eines Systems mit dynamischen Prozessen in einem ablauffähigen Modell. Simulation ermöglicht die Modellierung von systemspezifischen Abhängigkeiten und Wechselwirkungen über die Zeit. Zudem können stochastische Aspekte bei der Abbildung des Systemverhaltens berücksichtigt werden.

Stabilität: Die Stabilität eines Prognoseverfahrens beschreibt, wie es auf Änderungen in den beobachtbaren Daten, also dem Verhalten der Zeitreihe, reagiert.

Stationarität: Eine Zeitreihe deren Erwartungswert und Varianz endlich und zeitunabhängig ist und deren Autokovarianzen lediglich von der zeitlichen Verschiebung, d.h. von der

Länge des Lags zwischen zwei Realisationen des Prozesses abhängen, wird als (schwach) stationär bezeichnet.

String: Datentyp, der eine endliche Folge von Zeichen eines definierten Zeichensatzes speichert.

Top X-Adaption: Adaptionsregel, bei der das Ergebnis der x -ähnlichsten Fälle als gewichtete arithmetisches Mittel berechnet und als Lösung herangezogen wird.

Vergleichstag: Ein Referenztag, der aufgrund bestimmter Merkmale (z.B. kalendarisch oder wetterbasiert) vergleichbar zu einem betrachteten Tag ist. Typische Vergleichstage sind Vortage, Vorwochentage oder Vorjahrestage.

Verteilnetz: Elektrizitätsnetz, üblicherweise im Bereich der Mittel- und Niederspannung, zum Zwecke der Belieferung von Letztverbrauchern mit Elektrizität.

Zeitreihenanalyse: Die Zeitreihenanalyse ist ein Spezialfall der Regressionsanalyse und untersucht die Entwicklung von Werten im Zeitverlauf. Neben der Analyse von historischen Daten und deren Einflussfaktoren beinhaltet die Zeitreihenanalyse auch die Prognose des zukünftigen Verlaufs der Reihe auf Basis der vorliegenden Werte.

Abbildungsverzeichnis

Abbildung 1: Lastverlauf auf verschiedenen Aggregationsstufen [SR18].....	7
Abbildung 2: Schematischer Aufbau eines Containerterminals.....	8
Abbildung 3: Verlauf eines Lastgangs an einem Feiertag	12
Abbildung 4: Zusammensetzung des Gesamtlastgangs aus Teilverbräuchen (nach [GTMM14])	13
Abbildung 5: Darstellung des Prognosezeitpunkts für die Teilnahme an Ausschreibungen am Minutenreservemarkt.....	22
Abbildung 6: Klassifikation der Verfahren zur Lastgangprognose (in Anlehnung an [Hir15])	24
Abbildung 7: Schematischer Aufbau eines Multilayer-Perceptrons (MLP)	27
Abbildung 8: Parameter innerhalb eines neuronalen Netzes [Chri05].....	28
Abbildung 9: Das Ablaufmodell des Fallbasierten Schließens (in Anlehnung an [AP94]).....	32
Abbildung 10: Verteiltes Wissen in einem fallbasierten System (in Anlehnung an [Ric95])...	36
Abbildung 11: Verallgemeinerter Prozessablauf von Prognosesystemen.....	37
Abbildung 12: Verhältnis von monatlicher Durchschnittstemperatur zu Energieverbrauch pro Containerumschlag.....	53
Abbildung 13: Beispielhafte Lastverläufe.....	55
Abbildung 14: Beispielhafter Lastverlauf eines Feiertags mit Vor- und Folgetag.....	56
Abbildung 15: Verhältnis von Containerbewegungen zu Energieverbrauch.....	57
Abbildung 16: Wirtschaftswachstum und Containerumschlag 1998-2012 [Hhla12].....	59
Abbildung 17: Steigerung von Strombedarf und Containerumschlag relativ zum Jahr 2010.	59
Abbildung 18: Prognoseprozessschritte mit Integration von Betriebsdaten.....	61
Abbildung 19: Beispiele von Segellisten verschiedener Hafenbetreiber.....	62
Abbildung 20: Auszug aus einer einfachen Segelliste mit Beispieldaten.....	63
Abbildung 21: Beispiel eines tagesscharf aufgeteilten Segellisteneintrages ohne Containerzahlen.....	66
Abbildung 22: Beispiel der Be- und Entladerate eines Schiffes über die Liegedauer.....	67
Abbildung 23: Beispiel eines tagesscharf aufgeteilten Schiffsaufenthaltes mit Containerzahlen	67
Abbildung 24: Beispiel eines Containerumschlagprofils für einen Tag.....	69
Abbildung 25: Darstellung der Idee des prinzipiellen Aufbaus des Fallformats als Ableitung eines Falls als Problem und Lösung.....	72
Abbildung 26: Basis-Ähnlichkeitsmaße für numerische Attribute (nach [Ber02]).....	78
Abbildung 27: Parameter der exponentiellen und sigmoiden Ähnlichkeitsfunktion.....	78
Abbildung 28: Vergleich von Zahlen zum stündlichen Containerumschlag.....	89
Abbildung 29: Angepasster FBS-Zyklus für die Fallbasierte Lastgangprognose.....	91
Abbildung 30: Korrelogramme der ACF- und PACF-Werte eines beispielhaften AR[2]-	

Prozesses.....	95
Abbildung 31: Vorgehensmodell für die Konstruktion Künstlicher Neuronaler Netze.....	101
Abbildung 32: Schematische Darstellung des Konzepts für die Lastgangprognose mit Künstlichen Neuronalen Netzen.....	102
Abbildung 33: Generisches Beschreibungsschema eines Verbrauchers (in Anlehnung an [Gru16]).....	111
Abbildung 34: Beschreibung einer Zwei-Katz-Containerbrücke als Verbraucher (Auszug)..	113
Abbildung 35: Simulationsablauf für die Abfertigung eines Schiffes.....	115
Abbildung 36: Datenmodellierung für die Fallbasis.....	119
Abbildung 37: Verlauf des MAPE und des Average Similarity Error für Variante G01_2_2012	121
Abbildung 38: Anpassungsregeln und -werte für die Adaption auf Basis von Containerprofilen	122
Abbildung 39: Zerlegung der Zeitreihe in Saison-, Trend- und verbleibende Komponente. .	123
Abbildung 40: Entwicklung der ARIMA-Prognosegüte in Abhängigkeit der Anzahl vergangener Tage.....	124
Abbildung 41: Darstellung der Auswertung zu verschiedenen Parameterkombinationen des KNN.....	125
Abbildung 42: Ablaufschema eines Simulationslaufs für die Lastgangprognose.....	128
Abbildung 43: Durchschnittliche Prognoseabweichungen der Varianten des Vergleichstagverfahrens.....	129
Abbildung 44: MPE und MAPE der Fallbasierten Lastgangprognose mit und ohne Anpassungsfaktor.....	131
Abbildung 45: Prognosegüte verschiedener fallbasierter Varianten der Lastgangprognose für 2013 und 2014.....	132
Abbildung 46: Prognosegüte der ARIMA-Modelle mit verschiedenen externen Regressoren	133
Abbildung 47: Prognosegüte verschiedener KNN-Varianten für 2013 und 2014.....	134
Abbildung 48: Monatliche Prognoseergebnisse des Vergleichstagverfahrens.....	137
Abbildung 49: Monatliche Prognoseergebnisse der Fallbasierten Lastgangprognose.....	138
Abbildung 50: Monatliche Prognoseergebnisse der ARIMA-Modelle.....	139
Abbildung 51: Analyse der maximalen Abweichung der ARIMA-Prognose im Jahr 2013 ..	140
Abbildung 52: MPE-Verlauf für 14 Tage im Oktober 2014.....	140
Abbildung 53: Monatliche Prognoseergebnisse der Künstlichen Neuronalen Netze.....	141
Abbildung 54: Monatliche Prognoseergebnisse der Simulation.....	143
Abbildung 55: Vergleich der jährlichen durchschnittlichen MAPE-Werte aller Verfahren....	144
Abbildung 56: Strombedarf der batterie-elektrischen AGV im CTA [Bes16].....	144
Abbildung 57: Dauer der Prognoseerstellung mit ARIMA-Modellbestimmung	147

Tabellenverzeichnis

Tabelle 1: Klassifikation der Lastgangprognose nach Zeithorizont.....	20
Tabelle 2: Vergleich der verwandten Arbeiten aus dem Bereich der energetischen Prozesse in Containerterminals.....	46
Tabelle 3: Vergleich der verwandten Arbeiten aus dem Bereich Fallbasiertes Schließen in der Energiedomäne.....	50
Tabelle 4: Vergleich der Arbeiten aus dem Bereich Fallbasiertes Schließen für die Prognose von Zeitreihen.....	52
Tabelle 5: Beispielhafte Vergleiche von Tagen mit ähnlichen Containerumschlagzahlen und dem entsprechenden relativen Verbrauch über vier Jahre.....	54
Tabelle 6: Verschiedene Varianten des Vergleichstagsverfahrens.....	70
Tabelle 7: Attribute eines Falles zur Repräsentation der einzelnen Segellisteneinträge.....	73
Tabelle 8: Attribute für Tagesinformationen zu einem Fall.....	75
Tabelle 9: Relevanz der Attribute von FArrival für die Ähnlichkeitsbetrachtung.....	77
Tabelle 10: Konzept für Ähnlichkeitsmaße der einzelnen Attribute.....	82
Tabelle 11: Typisches Verhalten von ACF- und PACF-Werten nach Box-Jenkins.....	95
Tabelle 12: Beispielhafte Struktur eines Versuchsplans nach dem Prinzip der statistischen Versuchsplanung.....	105
Tabelle 13: Terminalbereiche und damit verbundene Planungsprobleme (Auszug).....	109
Tabelle 14: Zusammenfassung der genutzten Eingabedaten der verschiedenen Prognoseverfahren.....	117
Tabelle 15: Ähnlichkeitsmaße und deren Parameter für das Fallbeispiel CTA.....	120
Tabelle 16: Höchste und niedrigste Fehlerwerte der KNN mit einer und zwei verdeckten Schichten.....	126
Tabelle 17: Nachträglich eingefügte Anpassungsfaktoren.....	131
Tabelle 18: Übersicht zur Bewertung der Rechenzeit.....	146
Tabelle 19: Übersicht zur Bewertung des Modellierungsaufwandes.....	148
Tabelle 20: Übersicht zum Umfang der benötigten historischen Daten.....	149
Tabelle 21: Übersicht zur Bewertung der Anpassbarkeit.....	150
Tabelle 22: Übersicht zur Bewertung der Übertragbarkeit.....	151
Tabelle 23: Zusammenfassende Übersicht der Bewertung der Verfahren.....	154

Literaturverzeichnis

- [AB11]: Angeloudis, Panagiotis und Bell, Michael GH: *A review of container terminal simulation models*, in: *Maritime Policy & Management*, Vol. 38, Issue 5, S. 523-540, Taylor & Francis, 2011.
- [AEM97]: Al Fuhaid, A. S. und El-Sayed, M. A. und Mahmoud, M. S.: *Cascaded artificial neural networks for short-term load forecasting*, in: *IEEE Transactions on Power Systems*, Vol. 12, Issue 4, S. 1524-1529, 1997.
- [Amj01]: Amjady, Nima: *Short-term hourly load forecasting using time-series modeling with peak load estimation capability*, in: *IEEE Transactions on Power Systems*, Vol. 16, Issue 3, S. 798-805, IEEE, 2001.
- [AN02]: Alfares, Hesham K. und Nazeeruddin, Mohammad: *Electric load forecasting: literature survey and classification of methods*, in: *International Journal of System Science*, Vol.33, Issue 1, S. 23-34, Taylor & Francis, 2002.
- [AP94]: Aamodt, Agnar und Plaza, Enric: *Case-based reasoning: Foundational issues, methodological variations, and system approaches*, in: *AI communications*, Vol. 7, Issue 1, S. 39-59, IOS Press, 1994.
- [BAF+11]: Begum, Shahina; Ahmed, Mobyen Uddin; Funk, Peter; Xiong, Ning und Folke, Mia: *Case-based reasoning systems in the health sciences: A survey of recent trends and developments*, in: *IEEE Transactions on Systems, Man, and Cybernetics*, Vol. 41, Issue 4, S. 421-434, IEEE, 2011.
- [Bax92]: Baxt, William G: *Improving the accuracy of an artificial neural network using multiple differently trained networks*, in: *Neural Computation*, Vol. 4, Issue 5, S. 772-780, 1992.
- [BDE13]: BDEW: *BDEW-Roadmap: Realistische Schritte zur Umsetzung von Smart Grids in Deutschland*, BDEW, 2013.
- [Ber02]: Bergmann, Ralph: *Experience management: foundations, development methodology, and internet-based applications*, Springer, 2002.
- [Bes16]: BESIC Konsortium: *Batterie-Elektrische Schwerlastfahrzeuge im Intelligenten Containerterminalbetrieb (BESIC). Abschlussbericht im Rahmen des Förderprogramms IKT für Elektromobilität II.*, 2016.
- [BEW15]: Backhaus, Klaus; Erichson, Bernd und Weiber, Rolf: *Fortgeschrittene multivariate Analysemethoden: eine anwendungsorientierte Einführung*,

- Springer Gabler, 2015.
- [BJ76]: Box, George und Jenkins, Gwilym: *Time series analysis: forecasting and control*, Revised Edition, Holden-Day, 1976.
- [Bri05]: Brinkmann, Birgitt: *Seehäfen - Planung und Entwurf*, Springer, 2005.
- [BRS+01]: Bergmann, R.; Richter, M. M.; Schmitt, S.; Stahl, A. und Vollrath, I.: *Utility-oriented matching: A new research direction for case-based reasoning*, in: Professionelles Wissensmanagement: Erfahrungen und Visionen. Proceedings of the 1st Conference on Professional Knowledge Management, Shaker, 2001.
- [BVG11]: BDEW; VKU und GEODE: *BDEW/VKU/GEODE - Leitfaden: Abwicklung von Standardlastprofilen Gas*, Berlin, 2011.
- [CCMT90]: Cleveland, Robert; Cleveland, William; McRae, Jean und Terpenning, Irma: *STL: A Seasonal-Trend Decomposition Procedure Based on Loess*, in: Journal of Official Statistics, Vol. 6, Issue 1, S. 3-73, 1990.
- [Chri05]: Chrislb: *Schema eines künstlichen Neurons*, URL: https://de.wikipedia.org/wiki/Künstliches_neuronales_Netz#/media/File:ArtificialNeuronModel_deutsch.png, 2005, Verifizierungsdatum: 10.03.2018.
- [CL01]: Corchado, Juan und Lees, Brian: *A hybrid case-based model for forecasting*, in: Applied Artificial Intelligence, Vol. 15, Issue 2, S. 105-127, Taylor & Francis, 2001.
- [Cun09]: Cunningham, Pdraig: *A taxonomy of similarity mechanisms for case-based reasoning*, in: IEEE Transactions on Knowledge and Data Engineering, Vol. 21, Issue 11, S. 1041-4347, IEEE, 2009.
- [Dan15]: Dannecker, Lars: *Energy Time Series Forecasting: Efficient and Accurate Forecasting of Evolving Time Series from the Energy Domain*, Springer, 2015.
- [DEN10]: Deutsche Energie Agentur GmbH: *Dena-Netzstudie II*, DENA, 2010.
- [Dfki17]: DFKI GmbH: *myCBR*, URL: <http://www.mycbr-project.net>, 2017, Verifizierungsdatum: 01.02.2017.
- [DMD+09]: Davidson, Euan M; McArthur, Stephen DJ; Dolan, Michael J und McDonald, James R: *Exploiting intelligent systems techniques within an autonomous regional active network management system*, in: Power & Energy Society General Meeting 2009, IEEE, 2009.

- [Eis05]: Eisenbach, Dominik: *Künstliche Neuronale Netze zur Prognose von Zeitreihen*, Westfälische Wilhelms-Universität Münster, 2005.
- [Ele12]: Eley, Michael: *Simulation in der Logistik: Einführung in die Erstellung ereignisdiskreter Modelle unter Verwendung des Werkzeuges "Plant Simulation"*, Springer Science & Business Media, 2012.
- [Ent15]: ENTSO-E: *Harmonised Electricity Role Model*, URL: https://www.entsoe.eu/publications/electronic-data-interchange-ed-library/work%20products/harmonised_electricity_role_model/Pages/default.aspx, 2015, Verifizierungsdatum: 13.07.2016.
- [FG05]: Feinberg, Eugene A. und Genethliou, Dora: *Load forecasting*, in: Applied mathematics for restructured electric power systems, S. 269-285, Springer, 2005.
- [FK15]: Feindt, Michael und Kerzel, Ulrich: *Prognosen bewerten: Statistische Grundlagen und praktische Tipps*, Springer Gabler, 2015.
- [GC88]: Gellings, Clark W. und Chamberlin, John H.: *Demand-Side Management: Concepts and Methods*, The Fairmont Press, Inc., 1988.
- [GHI+14]: Grundmeier, Nico; Hahn, Axel; Ihle, Norman; Runge, Serge und Meyer-Barlag, Claas: *A simulation based approach to forecast a demand load curve for a container terminal using battery powered vehicles*, in: International Joint Conference on Neural Networks (IJCNN) 2014, IEEE, 2014.
- [Gru16]: Grundmeier, Nico: *Simulationsbasierte Energiebedarfsprognose in Seehafen Container-Terminals*, Dissertation, Universität Oldenburg, 2016.
- [GTMM14]: Guo, Hui; Tao, Liang; Moser, Jürgen und Müller, Holger: *Smart Grids für zukünftige Häfen - Herausforderungen und Potenziale*, in: VDE-Kongress 2014, VDE Verlag, 2014.
- [HA13]: Hyndman, Rob J. und Athanasopoulos, George: *Forecasting: principles and practice*, OTexts, 2013.
- [HBA+13]: Hernandez, L.; Baladrón, C.; Aguiar, J.; Carro, B.; Sanchez-Esguevillas, A. und Lloret, J.: *Short-Term Load Forecasting for Microgrids Based on Artificial Neural Networks*, in: Energies, Vol. 6, Issue 3, S. 1385-1408, MDPI, 2013.
- [HBA+14]: Hernandez, L.; Baladrón, C.; Aguiar, J. M.; Carro, B.; Sanchez-

- Esguevillas, A. J.; Lloret, J. und Massana, J.: *A survey on electric power demand forecasting: future trends in smart grids, microgrids and smart buildings*, in: IEEE Communications Surveys & Tutorials, Vol. 16, Issue 3, S. 1460-1495, IEEE, 2014.
- [HDB+14]: Hagan, Martin; Demuth, Howard; Beale, Mark und De Jesus, Orlando: *Neural Network Design*, Martin Hagan, 2014.
- [Hhla12]: Hamburger Hafen und Logistik AG: *Geschäftsbericht 2012*, URL: https://hhla.de/fileadmin/download/investor_relations/HHLA_GB_2012_D.pdf, 2012, Verifizierungsdatum: 14.01.2018.
- [Hhla16]: Hamburger Hafen und Logistik AG: *Technische Daten Altenwerder (CTA)*, URL: <http://hhla.de/de/container/altenwerder-cta/technische-daten.html>, 2016, Verifizierungsdatum: 27.11.2017.
- [Hir15]: Hirsch, Christian: *Fahrplanbasiertes Energiemanagement in Smart Grids*, Dissertation, Karlsruher Instituts für Technologie, 2015.
- [HK07]: Hyndman, Rob J. und Khandakar, Yeasmin: *Automatic time series for forecasting: the forecast package for R*, in: Monash University, Department for Econometrics and Business Statistics, Working Paper 06/07, 2007.
- [HK98]: Hufendiek, Kai und Kaltschmitt, Martin: *Einsatz künstlicher neuronaler Netze bei der kurzfristigen Lastprognose*, Universität Stuttgart, Institut für Energiewirtschaft und Rationelle Energieanwendung (IER), 1998.
- [Hon10]: Hong, Tao: *Short term electric load forecasting*, Dissertation, North Carolina State University, 2010.
- [HTK+11]: Herrmann, C.; Thiede, S.; Kara, S. und Hesselbach, J.: *Energy oriented simulation of manufacturing systems - Concept and application*, in: CIRP Annals - Manufacturing Technology, Vol. 60, Issue 1, S. 45-48, Elsevier, 2011.
- [Hynd14]: Hyndman, Rob: *Fitting models to long time series*, URL: <https://robjhyndman.com/hyndsight/long-time-series/>, 2014, Verifizierungsdatum: 14.01.2018.
- [IEA03]: International Energy Agency: *The Power to Choose: Demand Response in Liberalised Electricity Markets*, OECD Publishing, 2003.
- [Joh10]: Johanson, Fredrik: *Efficient use of energy in container cranes*, in: Port Technology International, Edition 48, S. 51-54, Henley Media Group,

- 2010.
- [JYGM99]: Juberias, G.; Yunta, R.; Garcia Moreno, J. und Mendivi, C.: *A new ARIMA model for hourly load forecasting*, in: IEEE Transmission and Distribution Conference, Vol. 1, S. 314-319, IEEE, 1999.
- [Kam09]: Kamper, Andreas: *Dezentrales Lastmanagement zum Ausgleich kurzfristiger Abweichungen im Stromnetz*, Dissertation, Karlsruher Institut für Technologie, 2009.
- [Kan92]: Kang, Suh Young: *An Investigation of the Use of Feedforward Neural Networks for Forecasting*, Dissertation, Kent State University, 1992.
- [Kau03]: Kauffmann, Andreas: *Prognosemethoden und Prognosequalität: Auswahl und Optimierung*, in: ew, Vol. 102, Issue 13, S. 18-21, Verlags- und Wirtschaftsgesellschaft der Elektrizitätswerke, 2003.
- [KB96]: Kaastra, Iebeling und Boyd, Milton: *Designing a neural network for forecasting financial and economic time series*, in: Neurocomputing, Vol. 10, Issue 3, S. 215-236, Elsevier, 1996.
- [KBK+11]: Kruse, Rudolf; Borgelt, Christian; Klawonn Frank; Moewes, Christian; Ruß, Georg und Steinbrecher, Matthias: *Computational Intelligence*, Vieweg + Teubner, 2011.
- [Kle14]: Klein, Bernd: *Statistische Versuchsplanung – DoE: Einführung in die Taguchi/Shainin-Methodik*, De Gruyter Oldenbourg, 2014.
- [Klo07]: Klobasa, Marian: *Dynamische Simulation eines Lastmanagements und Integration von Windenergie in ein Elektrizitätsnetz auf Landesebene unter regelungstechnischen und Kostengesichtspunkten*, Dissertation, ETH Zürich, 2007.
- [Kue12]: Küsters, Ulrich: *Evaluation, Kombination und Auswahl betriebswirtschaftlicher Prognoseverfahren*, in: Prognoserechnung, S. 367-404, Physica-Verlag, 2012.
- [Kur09]: Kurbalija, Vladimir: *Time Series Analysis and Prediction using Case Based Reasoning Technology*, Dissertation, Universität Novi Sad, 2009.
- [Le12]: Le, Kim: *Analysing electric yard cranes with simulation*, in: Port Technology International, Edition 53, S. 60-61, Henley Media Group, 2012.
- [Len99]: Lenz, Mario: *Case Retrieval Nets as a model for building flexible information systems*, Dissertation, Humboldt-Universität zu Berlin, 1999.

- [Lip87]: Lippmann, Richard: *An Introduction to Computing with Neural Nets*, in: IEEE ASSP Magazine, Vol. 4, Issue 2, S. 4-22, IEEE, 1987.
- [LQZ+14]: Liu, Nian; Tang, Qingfeng; Zhang, Jihanhua; Fan, Wei und Liu, Jie: *A hybrid forecasting model with parameter optimization for short-term load forecasting of micro-grids*, in: Applied Energy, Vol. 129, S. 336-345, Elsevier, 2014.
- [MAC13]: Monfet, Danielle; Arkhipova, E. und Choiniere, D: *Evaluation of a case-based reasoning energy prediction tool for commercial buildings*, in: International Conference for Enhanced Building Operations (ICEBO) 2013, Montreal, 2013.
- [MGCP03]: Moorthy, Rajeeva Lochana; Guan, Wee Hock; Cheong, Ng Wing und Piaw, Teo Chun: *Cyclic deadlock prediction and avoidance for zone-controlled AGV system*, in: International Journal of Production Economics, Vol. 83, Issue 3, S. 309-324, Elsevier, 2003.
- [MMB97]: Mentré, France; Mallet, Alain; Baccar, Doha: *Optimal design in random-effects regression models*, in: Biometrika, Vol. 84, Issue 2, S. 429-442, 1997.
- [MSW+01]: Martinssen, Dirk; Steenken, Dirk; Wölfer, Franz; Reiners, Torsten und Voss, Stefan: *Einsatz bioanaloger Verfahren bei der Optimierung des wasserseitigen Containerumschlags*, in: Logistik Management, S. 377-388, Springer, 2001.
- [Mul09]: Mulder, S.: *Energy Management Strategy for a Hybrid Container Crane*, TU Delft, 2009.
- [MWE97]: Momoh, J. A.; Wang, Y. und Elfayoumy, M.: *Artificial neural network based load forecasting*, in: IEEE International Conference on Computational Cybernetics and Simulation 1997, Vol. 4, S. 3443-3451, IEEE, 1997.
- [Nakh94]: Nakhaeizadeh, Gholamreza: *Learning prediction of time series. A theoretical and empirical comparison of CBR with some other approaches*, in: European Workshop on Case-Based Reasoning 1993, S. 65-76, Springer, 1994.
- [NUA12]: Nagahamulla, Harshani RK; Uditha R. Ratnayake und Asanga Ratnaweera: *An ensemble of artificial neural networks in rainfall forecasting*, in: International Conference on Advances in ICT for Emerging Regions (ICTer) 2012, S. 176-181, IEEE, 2012.

- [OHH+08]: O'Mahony, Eoin; Hebrard, Emmanuel; Holland, Alan; Nugent, Conor und O'Sullivan, Barry: *Using case-based reasoning in an algorithm portfolio for constraint solving*, in: Irish conference on artificial intelligence and cognitive science , S. 210-216, Springer, 2008.
- [PEM+91]: Park, D. C.; El-Sharkawi, M. A.; Marks, R. J.; Atlas, L. E. und Damborg, M. J: *Electric load forecasting using an artificial neural network*, in: IEEE Transactions on Power Systems, Vol. 6, Issue 2, S. 442-449, IEEE, 1991.
- [PMZ15]: Platon, Radu; Martel, Jaques and Zoghلامي, Kaiser: *CBR Model for Predicting a Building's Electricity Use: On-Line Implementation in the Absence of Historical Data*, in: International Conference on Case-Based Reasoning 2015, S. 306-319, Springer, 2015.
- [RB93]: Riedmiller, Martin und Braun, Heinrich: *A Direct Adaptive Method for Faster Backpropagation Learning: The RPRO Algorithm*, in: IEEE International Conference on Neural Networks 1993, S. 586-591, IEEE, 1993.
- [Res95]: Resnik, Philip: *Using Information Content to Evaluate Semantic Similarity in a Taxonomy*, in: Proceedings of the 14th International Joint Conference on Artificial Intelligence 1995, Morgan Kaufmann Publishers, 1995.
- [RG10]: Roon, Serafin von und Gobmaier, Thomas: *Demand Response in der Industrie - Status und Potenziale in Deutschland*, Forschungsstelle für Energiewirtschaft e. V., 2010.
- [Ric03]: Richter, Michael: *Fallbasiertes Schließen: Vergangenheit, Gegenwart, Zukunft*, in: Informatik Spektrum, Vol. 26, Issue 3, S. 18-190. Springer, 2003.
- [Ric95]: Richter, Michael: *The Knowledge Contained in Similarity Measures*, in: Invited Talk at the First International Conference on CBR (ICCBR-95), 1995.
- [Ric98]: Richter, Michael: *Introduction*, in: Case-Based Reasoning Technology - From Foundations to Applications, Springer, 1998
- [RIH+14]: Runge, Serge; Ihle, Norman; Hahn, Axel; Appelrath, Hans-Jürgen; Schmidt, Johannes und Kolbe, Lutz : *Simulation of power demand in a maritime container terminal using an event-driven data acquisition module*, in: International Conference on Logistics and Maritime Systems (LOGMS) 2014, Rotterdam, 2014.

- [RIMB+14]: Runge, Serge; Ihle, Norman; Meyer-Barlag, Claas; Grundmeier, Nico; Hahn, Axel und Appelrath, Hans-Jürgen: *Herausforderungen für Demand-Side-Integration mit Elektrofahrzeugen in geschlossenen Logistiksystemen („Battery-to-Market“)*, in: VDE-Kongress 2014, VDE Verlag GmbH, 2014.
- [RN95]: Russel, Stuart und Norvig, Peter: *Artificial Intelligence: a modern approach*, Prentice Hall, 1995.
- [Rot18]: Port of Rotterdam, *Container terminals and depots in the port of Rotterdam*, URL: <https://www.portofrotterdam.com/de/files/container-terminals-and-depots-in-the-port-of-rotterdam>, 2018, Verifizierungsdatum:02.04.2018.
- [S+13]: Sapina, Rafael and Green Cranes Consortium: *Report on Port Container Terminals Energy Profile*, Version 14, Brüssel, 2013.
- [Sch01]: Schlittgen, Rainer: *Angewandte Zeitreihenanalyse*, Oldenbourg Verlag, Wien, 2001.
- [Sch12]: Schröder, Michael: *Einführung in die kurzfristige Zeitreihenprognose und Vergleich der einzelnen Verfahren*, in: Prognoserechnung, S. 11-45, Physica Verlag, 2012.
- [Sch15]: Schlittgen, Rainer: *Angewandte Zeitreihenanalyse mit R*, de Gruyter Oldenbourg, 2015.
- [Sch83]: Schank, Roger C.: *Dynamic memory: A theory of reminding and learning in computers and people*, Cambridge University Press, 1983.
- [Sch96]: Schaaf, Jörg Walter: *Fish and Shrink. A next step towards efficient case retrieval in large scaled case bases*, in: European Workshop on Advances in Case-Based Reasoning 1996, S. 362-376, Springer, 1996.
- [SHK+14]: Srivastava, Nitish; Hinton, Geoffrey; Krizhevsky, Alex; Sutskever, Ilya und Salakhutdinov, Ruslan: *Dropout: A Simple Way to Prevent Neural Networks from Overfitting*, in: The Journal of Machine Learning Research, Vol. 15, Issue 1, S. 1929-1958, MIT Press, 2014.
- [SIM+13]: Singh, Arunesh Kumar; Ibraheem, S. Khatoon; Muazzam, Md. und Chaturvedi, D.K.: *An Overview of Electricity Demand Forecasting Techniques*, in: Network and Complex Systems, Vol. 3, Issue2, S. 38-48, IISTE, 2013.
- [SLCT12]: Sun, Zhuo; Lee, Loo Hay; Chew, Ek Peng und Tan, Kok Choon:

- MicroPort: A general simulation platform for seaport container terminals*, in: *Advanced Engineering Informatics*, Vol. 26, Issue 1, S. 80-89, Elsevier, 2012.
- [SLIK15]: Schmidt, Johannes; Lauven, Lars-Peter; Ihle, Norman und Kolbe, Lutz: *Demand side integration for electric transport vehicles*, in: *International Journal of Energy Sector Management*, Vol. 9, Issue 4, S. 471-495, Emerald, 2015.
- [SR18]: Sevlian, Raffi und Rajagopal, Ram: *Short Term Electricity Load Forecasting on Varying Levels of Aggregation*, in: *International Journal of Electrical Power & Energy Systems*, Vol. 98, S. 350-361, Elsevier, 2018.
- [SRB10]: Sonnenschein, Michael and Rapp, Barbara and Bremer, Jörg, *Demand Side Management und Demand Response*, in: *Handbuch Energiemanagement*, Band 3, EW, 2012.
- [SS01]: Schlittgen, Rainer und Streitberg, Bernd: *Zeitreihenanalyse*, Oldenbourg, 2001.
- [SS12]: Suganthi, L. und Samuel, Anand A.: *Energy models for demand forecasting - A review*, in: *Renewable and Sustainable Energy Reviews*, Vol. 16, Issue 2, S. 1223-1240, Elsevier, 2012.
- [Stahl03]: Stahl, Armin: *Learning of Knowledge-Intensive Similarity Measures in Case-Based Reasoning*, Dissertation, Universität Kaiserslautern, 2003.
- [SV08]: Stahlbock, Robert und Voss, Stefan: *Operations research at container terminals: a literature update*, in: *OR spectrum*, Vol. 30, Issue 1, S. 1-52, Springer, 2008.
- [SVH12]: Siebertz, Karl; van Bebber, David und Hochkirchen, Thomas: *Statistische Versuchsplanung - Design of Experiments (DoE)*, Springer, 2010.
- [Swi06]: Swider, Derk Jan: *Handel an Regelenenergie-und Spotmärkten: Methoden zur Entscheidungsunterstützung für Netz-und Kraftwerksbetreiber*, Dissertation, Universität Stuttgart, 2006.
- [Tra12]: Tran, Thanh Khanh: *Study of Electrical Usage and Demand at the Container Terminal*, Dissertation, Deakin University, 2012.
- [TXWP+10]: Taylor, P.C.; Xu, T.; Wade, S.; Prodanovic, M.; Silversides, R.; Green, T.; Davidson, M. und McArthur, S.: *Distributed voltage control in AuRA-NMS*, in: *IEEE Power and Energy Society General Meeting*, 2010, IEEE, 2010.

- [USR+10]: Urosevic, Ljubisa; Stokic, Dragan; Reimer, Philip; Sorli, Mikel und Armijo, Alberto.: *AmI based monitoring system for energy efficiency optimisation in manufacturing for the factories of the future*, in: XX. International GTE Conference on Manufacturing and related Technologies 2010.
- [VDE12]: VDE: *VDE-Studie: Demand Side Integration - Lastverschiebungspotenziale in Deutschland*, VDE Verlag, 2012.
- [VM04]: Vilcahuaman, R. und Melendez, J.: *Improvement of electric load forecasting reusing past instances and contextual based adaptation*, in: Transmission and Distribution Conference and Exposition: Latin America, S. 271-276, IEEE, 2004.
- [Vog15]: Vogel, Jürgen: *Prognose von Zeitreihen*, Springer Gabler, 2015.
- [WAD94]: Wess, Stefan; Althoff, Klaus-Dieter und Richter, Michael M.: *Using k-d trees to improve the retrieval step in case-based reasoning*, in: Topics in Case-Based Reasoning, S. 167-181, Springer, 1994.
- [Wan06]: Wang, Z. Y.: *Developed case-based reasoning system for short-term load forecasting*, in: IEEE Power Engineering Society, General Meeting, S. 6ff., IEEE, 2006.
- [WCBR08]: Wenzel, Sigrid; Collisi-Böhmer, Simone und Rose, Oliver: *Qualitätskriterien für die Simulation in Produktion und Logistik: Planung und Durchführung von Simulationsstudien*, Springer, 2008.
- [Wil04]: Wild, Yves: *Statistische Auswertung des E-Verbrauchs von Kühlcontainern auf fahrenden Schiffen*, in: Jahrbuch der Schiffbautechnischen Gesellschaft, Band 98, Springer, 2004.
- [WW11]: Wieschemann, Armin und Wulff, Boris: *Abschlussbericht zum Vorhaben Forschung und Entwicklung batteriebetriebener Schwerlastfahrzeuge (AGV) und deren Erprobung in einem Feldversuch im Container-Terminal Altenwerder in Hamburg*, BMU, 2011.
- [ZE11]: Zeilinger, Franz Xaver und Einfalt, Alfred: *Simulation der Auswirkung von Demand Side Management auf die Leistungsaufnahme von Haushalten*, in: Internationale Energiewirtschaftstagung der TU Wien 2011.
- [ZPH98]: Zhang, Guoqiang; Patuwo, B. Eddy und Hu, Michael Y.: *Forecasting with artificial neural networks: The state of the art*, in: International Journal of Forecasting, Vol. 14, Issue 1, S. 35-62, 1998.