

Ein datengetriebenes System  
auf Basis klinischer Pfade  
zur Entscheidungsunterstützung  
für Ressourcenplanung  
in Krankenhäusern:

*Prozess-Mining,  
Optimierung und Simulation*

Dissertation

zur Erlangung des Grades

Doktor der Wirtschaftswissenschaft (Dr. rer. pol.)

der Juristischen und Wirtschaftswissenschaftlichen Fakultät  
der Martin-Luther-Universität Halle-Wittenberg

vorgelegt von

Dipl.-Wirt.-Inf. Karsten Helbig

Halle (Saale),

August 2016

Erstgutachter:	Prof. Dr. Taïeb Mellouli
Zweitgutachter:	Prof. Dr. Rolf Rogge
Tag der Verteidigung:	13.12.2016

## Danksagung

Auf dem langwierigen und steinigen Weg zur Fertigstellung dieser Arbeit wurde mir große Unterstützung von einer Vielzahl von Personen zuteil. Ich freue mich außerordentlich, diesen Menschen hiermit meinen tiefen Dank ausdrücken zu können.

In erster Linie möchte ich mich bei Herrn Prof. Mellouli für die langjährige Unterstützung und die wertvollen Diskussionen rund um diese Arbeit bedanken. Die Ermutigungen, immer nach der optimalen Lösung zu suchen und auch vermeintliche unumstößliche Praxisgegebenheiten in Frage zu stellen haben meinen Blick auf die Praxiswelt nachhaltig verändert. Eine besondere Herzensangelegenheit ist es, mich für seine uneingeschränkte Unterstützung bei den vielen Begleitprojekten zu bedanken. Diese hat es mir ermöglicht, mein facettenreiches Tätigkeits- und Fähigkeitsprofil zu entwickeln, welches ich als unschätzbar wertvoll für meine weitere Zukunft empfinde.

Weiterhin möchte ich mich bei Herrn Prof. Rogge für die wertvollen methodischen Hinweise, für die Hilfestellungen zur zielgerichteten Gestaltung des Arbeitsprozesses sowie für die für mich wichtige Motivation in der Endphase des Schreibprozesses bedanken.

Großer Dank richtet sich an Herrn Dr. Michael Römer, welcher mir seit meiner Diplomarbeit mit fachlichem und persönlichem Rat zur Seite steht. Seine Expertise und sein Formulierungsgeschick haben die Qualität aller Veröffentlichungen maßgeblich positiv beeinflusst. Mehr noch als über unsere professionelle Beziehung freue ich mich über unsere freundschaftliche. Ich bin überzeugt, dass eine große wissenschaftliche Zukunft vor ihm liegt.

Für die Einführung in die komplexe Welt der Krankenhäuser sowie über die Möglichkeit, aus der Universität heraus Erfahrungen in der Welt der Praxis sammeln zu können, möchte ich mich bei Herrn Dr. Winfried Jänicke, Herrn Dr. Patrick Jahn und Herrn Björn Degenkolbe bedanken.

Weiterer Dank gebührt Herrn Thomas Stoeck und Herrn Markus Gragert für die Unterstützung in den Simulationsprojekten, ihre Geduld und ihr Kommunikationsgeschick bei meinen unzähligen Verbesserungseinfällen. Besonders für die Entwicklung von Studenten zu Kollegen hin zu Freunden bin ich sehr dankbar.

Besonderer Dank richtet sich an die Mitarbeiter der UKH, Frau Steffi Sinang und Herrn Matthias Gerlach. Ohne ihr Engagement bei der Datenerhebung hätte diese Arbeit nicht die angestrebte Praxisnähe erreichen können.

Ich danke Hendrik Nieß, Andrea Beckmann, Mathias Walter, Sebastian Köhler, Dr. Thomas Wöhner, Uwe Brettschneider, Hans Betke und allen anderen Kollegen für das ausnahmslos freundschaftliche Verhältnis, welches die optimale Arbeitsatmosphäre für mich darstellt. Ich danke Dr. Mathias Henze, Annika Henze, Dr. Thomas Kirschstein, Andreas End, Ulrike Treff und allen anderen Freunden für den Rückhalt, die Zerstreung und die Rückzugsmöglichkeiten vom Alltag eines wissenschaftlichen Mitarbeiters. Ich hoffe, alle aus Platzgründen nicht genannten verzeihen mir.

Mein persönlich größter Dank richtet sich an meine Freundin Andrea Schwarz. Ihre Geduld und Ungeduld, ihre Unterstützung bei den unzähligen neuen Projekten und Ideen, ihr Trost, wenn die Dinge sich nicht wie erwartet entwickelt haben und ihre Liebe haben den Abschluss diese Arbeit erst ermöglicht.

## Zusammenfassung

Krankenhäuser spielen eine entscheidende Rolle in der Gesundheitsversorgung Deutschlands. Trotz der Einführung des auf Fallpauschalen beruhenden G-DRG-Abrechnungssystems 2003 und ersten damit verbundenen Erfolgen steigen die durchschnittlichen Fallkosten stetig an. Obwohl neben den Fallkosten ebenfalls die Fallzahlen ansteigen, sind gegenwärtig 30 % aller Krankenhäuser defizitär. Durch den demographischen Wandel wird eine Steigerung der Fallzahlen um weitere 15 % in den nächsten Jahren prognostiziert. Ohne weitere Effizienzsteigerung sind die Krankenhäuser langfristig weder dem aktuellen finanziellen Druck noch den zukünftigen Herausforderungen des demographischen Wandels gewachsen.

Krankenhäuser sind hoch komplexe Systeme, in denen eine Effizienzsteigerung ohne IT-gestützte Entscheidungsunterstützung für Aufgaben der Ressourcenkapazitätsplanung kaum möglich ist. So setzt die operative Behandlung stationärer Patienten die Koordination einer Vielzahl von Ärzten und Pflegepersonal mit verschiedensten Qualifikationen voraus. Räumlichkeiten wie OP-Säle oder diagnostische Großgeräte müssen dem richtigen Personal zur richtigen Zeit zur Verfügung stehen. Auf taktischer Ebene sind Aufnahmen von elektiven Patienten zu planen, deren Behandlungszeitraum frei wählbar ist. Zufällig auftretende nicht verschiebbare Notfallpatienten konkurrieren dabei um dieselben Ressourcen und erschweren die Planung. Auf strategischer Ebene sind Betten- und Personalkapazitäten zu planen, welche taktische und operative Entscheidungen beeinflussen.

Aktuell werden Behandlungsverläufe und entscheidungsrelevanten Nebenbedingungen auf allen drei Ebenen nicht in einer adäquaten Detailstufe abgebildet. Dies führt oft zu Problemen: So müssen immer wieder kostenintensive Operationen verschoben werden, weil bei der operativen Planung nicht beachtet wurde, dass anschließend ein freies Bett in der Zielstation benötigt wird. Dabei erschweren Einschränkungen wie eine strikte Geschlechtertrennung in Stationszimmern oder Isolation bei infektiösen Krankheiten das Finden zulässiger Betten. Andererseits entstehen unnötig lange Verweildauern, weil zwar auf taktischer Ebene die Aufnahme zulässig geplant wurde, aber zeitnah keine Kapazitäten für eine Operation verfügbar sind. Weiterhin müssen für robuste Pläne Puffer für nicht planbare Notfallpatienten berücksichtigt werden. Dabei können Überdimensionierungen zu Ressourcenverschwendung und Unterdimensionierung zu Engpässen in der Versorgung führen. Eine Entscheidungsunterstützung sollte demnach auf Mikroebene unter Beachtung des gesamten Behandlungsprozesses mit allen relevanten Maßnahmen und interdisziplinären Stationsaufenthalten sowie praxisrelevanter Nebenbedingungen erfolgen.

Da klinische Pfade den strukturellen Behandlungsverlauf für definierte Krankheitsbilder beschreiben, eignen sie sich prinzipiell zur geforderten Entscheidungsunterstützung auf Mikroebene. Schon die Erstellung eines einzigen Pfades ist jedoch aufgrund der Vielzahl von beteiligten Akteuren, eingesetzten Ressourcen und individuellen Krankheitsbildern ein hochgradig aufwendiger Prozess. Zusätzlich sind Pfade nur sehr eingeschränkt übertragbar, da sie die verfügbaren personellen und materiellen Ressourcen eines Krankenhauses widerspiegeln. Bisherige Versuche, klinische Pfade automatisch aus Behandlungsdaten zu erzeugen, scheitern an stark heterogenen Krankheitsbildern und wenig standardisierten Behandlungsprozessen.

Zur Steigerung der Ressourceneffizienz eines Krankenhauses erscheint die taktische und operative Planung aller elektiven Patienten unter Verwendung klinischer Pfade sinnvoll.

Aktuelle Planungsansätze erfassen einerseits nur isolierte Aspekte wie Aufnahmeplanung, Planung der OP-Säle oder Planung der Behandlungen, was aufgrund starker Prozessinterdependenzen zu den eingangs beschriebenen Fehlentscheidungen führen kann. Andererseits existieren einige wenige Ansätze, die zwar den gesamten Behandlungsverlauf adressieren, aber wichtige praktische Nebenbedingungen wie z. B. die Geschlechtertrennung oder den Umgang mit Isolationspatienten auf Mikroebene der Ressourcen vernachlässigen.

Zusätzlich zur Planung elektiver Patienten können strategische Entscheidungen zum Ressourceneinsatz die Effizienz eines Krankenhauses positiv beeinflussen. So bietet z. B. die Flexibilisierung des Einsatzes von Krankenhausbetten, einer der wichtigsten Ressourcen im Krankenhaus ohne die keine stationären Behandlungen möglich sind, großes Potential zur Effizienzsteigerung. Auch hier müssen die verwendeten Entscheidungsmodelle in der Lage sein, krankenhaushausweite Konsequenzen zu evaluieren. Eine isolierte Betrachtung einzelner Aspekte wie die Steigerung der Bettenkapazität einer Station kann zu Fehlentscheidungen und negativen Konsequenzen wie neuen Engpässen im krankenhaushausweiten Kontext führen. Ebenso scheitert das Umsetzen von Veränderungsmaßnahmen nicht selten an der Vielzahl zu überzeugender Entscheidungsträger. Auch hier wirkt sich ein detailliertes Modell positiv auf das Vertrauen in die Ergebnisse aus. Die ereignisdiskrete Simulation hat sich als Methode zur Entscheidungsunterstützung etabliert. Damit können hinreichend komplexe Zusammenhänge modelliert und analysiert werden. Problematisch ist allerdings der hohe Erstellungsaufwand dieser Modelle. Weiterhin sind die entwickelten Modelle aufgrund krankenhausspezifischer Ressourcen- und Patientenprofile nur eingeschränkt auf andere Krankenhäuser übertragbar.

Zur Adressierung der skizzierten Problemstellungen und zur Verringerung der Schwachstellen bei der Modellierung und Verarbeitung wird ein Entscheidungsunterstützungssystem konzipiert, das taktische und strategische Entscheidungen unterstützen kann. Insbesondere eine adäquate Abbildungsgenauigkeit der Behandlungsprozesse sowie eine krankenhaushausunabhängige Nutzbarkeit sind dabei zu beachten. Diese Dissertation verfolgt den Anspruch, ein solches System zu konzipieren und umzusetzen.

Damit sind die Ziele:

- (1) ein generisches System zur Unterstützung von Ressourcenkapazitätsentscheidungen auf strategischer, taktischer und operativer Ebene für deutsche Krankenhäuser zu konzipieren,
- (2) im Rahmen des Konzepts integrierte, auf klinischen Pfaden basierende Werkzeuge zum
  - a. automatischen Gewinnen planbarer klinischer Pfade für elektive Behandlungen,
  - b. zum Planen vollständiger elektiver Behandlungen und
  - c. zur Evaluation von Veränderungen im Einsatz krankenhaushausinterner Ressourcen zu entwickeln und
- (3) diese Werkzeuge anhand praxisnaher Fallstudien zu evaluieren.

Dabei sollen alle Werkzeuge den übergeordneten Zielen einer

- (4) automatischen datengetriebenen Erstellung von Modell- und Prozessstrukturen sowie entsprechend der adressierten Entscheidungsebene einer
- (5) adäquaten Abbildungsgenauigkeit und einer
- (6) effizienten Lösbarkeit genügen.

Diese Dissertation besteht aus diesem Rahmenwerk sowie fünf wissenschaftlichen Publikationen. Das Rahmenwerk präsentiert das integrierte Gesamtkonzept des

Krankenhausentscheidungsunterstützungssystem (KH-EUS) und dessen Aufbau aus den Kernmodulen Prozess-Mining, Optimierung und Simulation, sowie die potentiellen Vorteile deren Interaktion für die Entscheidungsunterstützung. In den wissenschaftlichen Veröffentlichungen werden die Werkzeuge der einzelnen Module vorgestellt und anhand praxisnaher Fallstudien evaluiert.

Das konzipierte KH-EUS besteht aus drei Modulen. Deskriptive und prädiktive Analytics werden durch das Modul Daten- und Prozess-Mining unterstützt. Prädiktive und präskriptive Analytics ermöglichen das Optimierungs- und das Simulationsmodul. Durch eine Verbindung letzterer können darüber hinaus z. B. Optimierungsergebnisse bei stochastischen Umwelteinflüssen evaluiert und neue optimierte Ressourcenprofile simuliert werden. Durch die Verwendung interdisziplinärer klinischer Pfade als grundlegende Struktur wurden neue Ansätze zum Einsatz mathematischer Programmierung, ereignisdiskreter Simulation und im Prozess-Mining im Krankenhauskontext entwickelt. Alle Ansätze bilden die Prozesse auf Mikroebene ab und ermöglichen somit eine praktikable Entscheidungsunterstützung für potentielle Nutzer wie z. B. das Krankenhausmanagement, medizinischen- und kaufmännischen Controllern auf strategischer sowie Fallmanagern, Qualitätsmanagern und ärztlichem Personal auf taktischer und operativer Ebene. Der generische Charakter des Systems wird insbesondere durch die grundsätzliche Verwendung von standardisierten, im Rahmen des § 21 KHEntG jährlich erhobenen Daten bestimmt.

Für das Daten- und Prozess-Mining Modul wurde ein Werkzeug entwickelt, welches automatisch unter Verwendung standardisierter Routinedaten klinische Pfade gewinnen kann. Die mit Hilfe von Prozess-Mining gewonnen Pfade sind tageweise strukturiert und enthalten alle für eine spätere Verwendung in einem Planungsmodell notwendigen Informationen. Der entwickelte Ansatz wurde erfolgreich unter Verwendung von Realdaten der urologischen Station des Universitätsklinikums Halle evaluiert.

Für das Optimierungsmodul wurden zwei auf mathematischer Programmierung basierende Werkzeuge zur operativen (offline) Planung elektiver stationärer Behandlungen entwickelt. Im ersten Werkzeug wird ein gemischt-ganzzahliges lineares Optimierungsmodell zur stundengenauen Planung mit dem Ziel, die Verweildauer möglichst fair für alle Patienten zu minimieren, eingesetzt. Die Evaluation dieses Ansatzes bestätigt die Abbildbarkeit klinischer Pfade und praxisrelevanter Nebenbedingungen wie z. B. die Geschlechtertrennung in Stationszimmern durch ein lineares Modell. Im zweiten Werkzeug wird ein hierarchischer Planungsansatz verfolgt. Dieser besteht aus zwei ganzzahligen linearen multikriteriellen Modellen zur tagesgenauen Planung, welche ein breites Spektrum an Problemstellungen, wie z. B. hohe Ressourcenauslastung zu Beginn der Planungsperiode oder Gleichverteilung der Arbeitslast, abzubilden vermag. Dieser Ansatz wurde anhand von 286 zu planenden Fällen mit 1088 Behandlungen und 302 Stationsaufenthalten und einem Planungshorizont von 30 Tagen erfolgreich für praxisrelevante Modellinstanzen evaluiert.

Im Rahmen des Simulationsmoduls wurden zwei auf ereignisdiskreter Simulation basierende Werkzeuge für die Evaluation strategischer und taktischer Maßnahmen zur erhöhten Flexibilisierung des Einsatzes von Krankenhausbetten entwickelt. Beide Werkzeuge wurden unter Verwendung von Realdaten des Universitätsklinikums Halle evaluiert. Mit Hilfe des ersten Werkzeuges wurden drei flexible Bettenbelegungsszenarien evaluiert. Im Vergleich zum Status quo konnten die Wartezeiten auf stationäre Aufnahme von Notfallpatienten um 50 % und auf Verlegung in ITS- und IMC-Stationen nahezu vollständig auf null reduziert werden.

Aufbauend auf den Erkenntnissen des großen Potentials flexibilitätssteigernder Maßnahmen bei vergleichbar geringen Investitionskosten wurde das zweite Werkzeug zur Evaluation krankenhausweiter Belegungscluster entwickelt. Die Architektur dieses Werkzeugs erlaubt ein automatisches Erzeugen und Parametrisieren von krankenhausindividuellen ereignisdiskreten Simulationsmodellen. Unter Verwendung dieses Werkzeugs wurden drei verschiedene Clusterkonfigurationen evaluiert. Die Ergebnisse zeigen eine Reduzierung von Bettenengpässen für den simulierten Zeitraum von einem Jahr von bis zu 96 % gegenüber dem Ist-Zustand. Die besten Evaluationsergebnisse erreichte die Clusterkonfiguration mit einem großen interdisziplinären Chirurgie-Cluster.

Insgesamt zeigen die einzelnen Aufsätze, dass mit dem Konzept der Betrachtung der Mikroebene sowohl der klinischen Pfade als auch der Ressourcen genauere Analysen sowohl in der Optimierung als auch in der Simulation möglich sind. Durch die intensiven Evaluationen der Komponenten anhand von umfangreichen Praxisdaten sind verlässlichere und begründbare Entscheidungen möglich. Die Ergebnisse wurden in wissenschaftlichen Tagungen und bei Projektpräsentationen mit den Entscheidern auf fachlicher und Managementebene in einer Universitätsklinik vorgestellt. Sowohl aus wissenschaftlicher als auch Praxissicht wurde die These bestätigt, dass die adäquate Abbildung sowohl der Behandlungsverläufe als auch die Betrachtung der Ressourcen auf Mikroebene in Simulations- und Optimierungsstudien zu einer beträchtlichen Erhöhung der Qualität und Zuverlässigkeit der Entscheidungen im Krankenhaus führt. Bspw. führten die Ideen der Flexibilisierung von Ressourcen und deren Evaluation in Simulationsstudien zu strategisch wichtigen Entscheidungen bezüglich fachlicher Zusammenarbeit von Stationen im Krankenhaus. Die Berücksichtigung der Ressourcendetails auf Mikroebene zeigt am Beispiel der Geschlechtertrennung in Krankenzimmern große Unterschiede in Optimierungs- und Simulationsergebnissen. Somit ist sie ausschlaggebend für die Qualität der Entscheidungsunterstützung. Das Aufsetzen auf standardisierten Daten eines Krankenhauses für die automatische Gewinnung von klinischen Pfaden erhöht die Nutzbarkeit und Wiederverwendbarkeit aller Komponenten und damit des gesamten datengetriebenen Konzeptes eines Entscheidungsunterstützungssystems für Ressourcenplanung in Krankenhäusern.

## Inhaltsverzeichnis

Abbildungsverzeichnis .....	viii
Tabellenverzeichnis.....	ix
Abkürzungsverzeichnis .....	x
1. Einleitung .....	11
2. Forschungsbedarf und Zielstellung der Arbeit.....	15
3. KH-EUS Konzept.....	20
3.1. Routinedaten im G-DRG-System.....	20
3.2 Gesamtkonzept .....	23
3.3 Vorstellung der drei Kernmodule.....	24
4. Vorstellung der Publikationen.....	27
4.1 Überblick.....	27
4.2. Zeitplanung für Patientenpfade unter Berücksichtigung von Betten-, Behandlungskapazitäten und Fairnesskriterien .....	30
4.3. Simulation stationsübergreifender Patientenflüsse zur Evaluation flexibler Bettenbelegungsszenarien aufgrund der Jahresdatenanalyse eines Universitätsklinikums .	32
4.4. A Generic Simulation-based DSS for Evaluating Flexible Ward Clusters in Hospital Occupancy Management .....	33
4.5 A Clinical Pathway Mining Approach to Enable Scheduling of Hospital Relocations and Treatment Services .....	35
4.6. A Data-Driven Hierarchical ILP Approach for Scheduling Clinical Pathways: A Real- World Study from a German University Hospital .....	37
5. Schlussbetrachtung.....	39
Literatur .....	41
Anhang A: Zeitplanung für Patientenpfade unter Berücksichtigung von Betten-, Behandlungskapazitäten und Fairnesskriterien .....	46
Anhang B: Simulation stationsübergreifender Patientenflüsse zur Evaluation flexibler Bettenbelegungsszenarien aufgrund der Jahresdatenanalyse eines Universitätsklinikums .....	57
Anhang C: A Generic Simulation-based DSS for Evaluating Flexible Ward Clusters in Hospital Occupancy Management .....	70
Anhang D: A Clinical Pathway Mining Approach to Enable Scheduling of Hospital Relocations and Treatment Services .....	81
Anhang E: A Data-Driven Hierarchical ILP Approach for Scheduling Clinical Pathways: A Real-World Study from a German University Hospital.....	90
Anhang F: Überblick Definitionen klinischer Pfade.....	123

## Abbildungsverzeichnis

Abb. 1: Framework für Planung und Steuerung im Gesundheitswesen angewendet auf ein Krankenhaus (Hans et al. 2012, S. 11) .....	12
Abb. 2: Zusammenhang klinische Pfade, Problemstellungen und Lösungsmethoden (eigene Darstellung).....	16
Abb. 3: Überblick fallbezogene Routinedaten (eigene Darstellung in Anlehnung an (InEK 2015, 4f)).....	22
Abb. 4: Konzept Krankenhausentscheidungsunterstützungssystem (eigene Darstellung).....	23
Abb. 5: Konzept Daten- und Prozess-Mining-Modul (eigene Darstellung) .....	24
Abb. 6: Konzept des Optimierungsmoduls (eigene Darstellung) .....	25
Abb. 7: Konzept des Simulationsmoduls (eigene Darstellung) .....	26
Abb. 8: Einordnung der Publikationen in KH-EUS Konzept (eigene Darstellung).....	28
Abb. 9: Zuordnung der Publikationen zu Problemstellungen und verwendeten Lösungsmethoden (eigene Darstellung).....	30
Abb. 10: Struktur eines klinischen Pfades (eigene Darstellung).....	30
Abb. 11: Architektur des Entscheidungsunterstützungssystem (eigene Darstellung) .....	33
Abb. 12: Konzept planungsorientierter klinischer Pfade (eigene Darstellung) .....	35



## **Tabellenverzeichnis**

Tabelle 1: Überblick eingereicherter Publikationen (eigene Darstellung) .....	27
Tabelle 2: Definitionsübersicht „Klinischer Pfad“ (eigene Darstellung, in Anlehnung an Küttner und Roeder 2007, S. 20).....	124

## Abkürzungsverzeichnis

APMOD	Applied Mathematical Programming and Modelling
CCL	Komplikationen oder Komorbiditäten
DIMDI	Deutsches Institut für Medizinische Dokumentation und Information
DOWONO	Doktorandenworkshop Nord-Ost
DRG	Diagnosis Related Groups
DSS	Decision Support System
ETL	Extract, Transform, Load
G-DRG	German-Diagnosis Related Groups
GKV	Gesetzliche Krankenversicherung
KHEntgG	Krankenhausentgeltgesetz
KH-EUS	Krankenhausentscheidungsunterstützungssystem
KHG	Krankenhausfinanzierungsgesetz
ICD-10	International Statistical Classification of Diseases and Related Health Problems
ILP	Integer Linear Programming
IMC	Intermediate Care
InEK	Institut für das Entgeltsystem im Krankenhaus GmbH
ITS	Intensivstation
MDC	Major Diagnostic Category
MILP	Mixed Integer Linear Programming
OPS	Operationen und Prozeduren
PCCL	Patientenbezogener Gesamtschweregrad
UKH	Universitätsklinikum Halle
ZNA	Zentrale Notaufnahme

## 1. Einleitung

*„The hospital is altogether the most complex human organization ever devised [...]“  
- (Peter Drucker 2002)*

Eine flächendeckende Krankenhausversorgung gehört zu den wesentlichen Elementen der Daseinsvorsorge (Koalitionsvertrag 2013 S. 78). Krankenhäuser bilden dabei einen entscheidenden Pfeiler in der Versorgung von Patientinnen und Patienten, welcher darüber hinaus von über einer Million Beschäftigten getragen wird (Eckpunkte Bund-Länder AG zur Krankenhausreform 2015 S.1). Mit der GKV-Gesundheitsreform 2000 wurde der Grundstein zur Einführung eines „durchgängigen, leistungsorientierten und pauschalierten“ Vergütungssystems für die Vergütung allgemeiner Krankenhausleistungen (§ 17b Abs. 1 Satz 1 Krankenhausfinanzierungsgesetz, KHG) gelegt. Zweck des KHG ist es, „die wirtschaftliche Sicherung der Krankenhäuser, um eine bedarfsgerechte Versorgung der Bevölkerung mit leistungsfähigen, eigenverantwortlich wirtschaftenden Krankenhäusern zu gewährleisten [...]“ (§1 Abs. 1 Satz 1 KHG). Zur Schaffung von Anreizen zur Verbesserung der Wirtschaftlichkeit von Krankenhäusern wurde das G-DRG-System (German- Diagnosis Related Groups) eingeführt. In diesem System werden die allgemeinen voll- und teilstationären Krankenhausleistungen in Form von Fallpauschalen leistungsbezogen vergütet (§ 17b Abs. 1 Satz 2 KHG). Fallpauschalen werden für Fälle mit ähnlichem Kostenaufwand in Fallgruppen, sog. DRGs, zusammengefasst. Durch diese leistungsorientierte Vergütung und dem damit forcierten Wettbewerb zwischen den Krankenhäusern sollen u. a. Fehlanreize für längere Verweildauern beseitigt, sowie eine bedarfsgerechte, effizientere Nutzung krankenhauserinterner und –übergreifender Ressourcen motiviert werden (Braun et al. 2007). Übergeordnetes Ziel ist es, die Kosten für die Krankenhausversorgung durch Effizienzsteigerung und Abbau überflüssiger Kapazitäten zu senken. Bisher dokumentierte positive Effekte sind u. a. ein Sinken der durchschnittlichen Verweildauer von 9,7 Tagen (2000) auf 7,4 Tage (2014), ein Sinken der Bettenkapazität um ca. 10 % seit 2000 sowie ein Rückgang der Krankenhäuser insgesamt um ca. 12 % (Statistisches Bundesamt, 2015). „Festzuhalten bleibt jedoch: Im Kontext der DRG-Einführung ist bislang keine Verminderung des Ausgabenanstiegs der gesetzlichen Krankenversicherungen zu verzeichnen“ (Braun et al. 2007, S. 9). Unterstrichen wird diese These durch ein Ansteigen der durchschnittlichen Fallkosten von 2989 € (2000) auf 4298 € (2014) sowie ein Ansteigen der Fallzahlen von ca. 17 Mio. (2000) auf 19 Mio. (2014) (Statistisches Bundesamt, 2015). Damit belaufen sich die Kosten für die Finanzierung von Krankenhäusern auf ca. 86 Mrd. € (2014). Dies entspricht ca. 26 % der Gesamtkosten des deutschen Gesundheitssystems (Statistisches Bundesamt, 2016).

Die mit dem G-DRG-System erhofften Effekte einer Kostensenkung durch einen bedarfsgerechten und effizienteren Ressourceneinsatz sowie einer effizienteren Gestaltung krankenhauserinterner Prozesse haben sich demnach bisher nicht eingestellt. Dass Optimierungspotentiale im Ressourceneinsatz existieren, zeigt z. B. die seit 2008 nahezu unveränderte durchschnittliche Bettenauslastung von ca. 77 % (Augurzky 2013, S. 88). Trotz steigender Fallzahlen, gestiegener durchschnittlicher Fallpauschalen und sinkender Verweildauer erwirtschaften ca. 30 % aller Krankenhäuser ein Defizit (Augurzky 2015). Damit

ist die gegenwärtige Krankenhausversorgungsstruktur langfristig finanziell nicht tragbar (Augurzky 2013, S. 224). Mit Blick auf die demographische Entwicklung in Kombination mit den Trends der Krankheitshäufigkeiten werden bis 2020 um 15 % steigende Fallzahlen prognostiziert (Augurzky 2013, S. 34). Um den zukünftigen Herausforderungen in der medizinischen Versorgung qualitativ, quantitativ und finanziell gerecht werden zu können, sind weitere effizienzsteigernde Maßnahmen in Krankenhäusern unerlässlich (Augurzky 2015).

Das hierarchische Rahmenwerk zur Planung und Steuerung im Gesundheitswesen von Hans et al. (2012) (siehe Abb. 1) gibt einen Überblick über Entscheidungen im Krankenhaus. Kapazitäts- und Belegungsplanungsaufgaben, die auf die Steigerung der Ressourceneffizienz im Krankenhaus abzielen, sind demnach der Ressourcenkapazitätsplanung zuzuordnen. Zielstellung auf strategischer Ebene ist es, durch Planung der prinzipiell zu versorgenden Fälle, den dafür nötigen Ressourcenkapazitäten sowie des benötigten Personals langfristig das unternehmerische Ziel zu unterstützen. Die taktische Ebene adressiert mittelfristige Planungsaufgaben zur Personal- und zur Aufnahmeplanung elektiver Patienten. Die operative Ebene wird in offline und online unterteilt. Beide adressieren kurzfristige Planungsaufgaben, mit dem Unterschied, dass offline-Planungsaufgaben im Voraus getätigt werden können, wohingegen die online-Planung aufgrund von stochastischen Prozessen reaktiv erfolgt (Hans et al. 2012, S. 8ff).

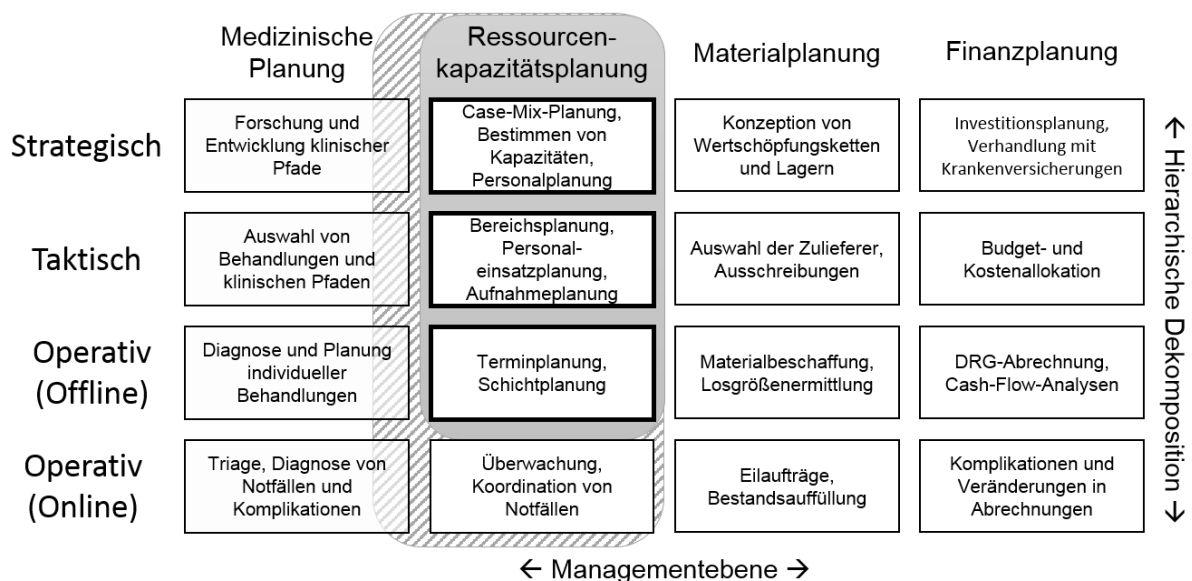


Abb. 1: Framework für Planung und Steuerung im Gesundheitswesen angewendet auf ein Krankenhaus (Hans et al. 2012, S. 11)

Ohne IT-basierte Entscheidungsunterstützung in der Ressourcenkapazitätsplanung ist das Finden und Evaluieren geeigneter effizienzsteigernder Maßnahmen nahezu unmöglich. Der Grund dafür ist die hohe Komplexität sowie der hohe Grad an Interdependenzen krankenhauserner Prozesse (McClellan und Millard 1995). Bereits ein mittelgroßes Krankenhaus hat ca. 400 Betten und durchschnittlich 500 Mitarbeiter unterschiedlichster Qualifikation und Spezialisierung. Patienten haben eine Vielzahl behandlungsrelevanter Merkmale sowie teilweise sehr individuelle Krankheitsbilder (Drucker 2002). Eine Vielzahl von Kommunikations- und Koordinationsaufgaben ist nötig, damit um die gleichen Ressourcen konkurrierenden Patienten versorgt werden können (Matthias Bartz 2006, S. 9ff). So muss

z. B. das Personal mit der richtigen Qualifikation zur richtigen Zeit im Raum mit der richtigen Ausstattung sein. Konsequenzen von Schwächen bei diesen Aufgaben reichen von Wartezeiten für Patienten, Überstunden des Personals, ungenutzten Kapazitäten teurer Ressourcen wie OP-Sälen bis hin zu Patientenabweisungen aufgrund fehlender Betten. Zum Abbau dieser Schwächen bietet sich eine Planung elektiver Patienten auf taktischer und operativer Ebene an.

Die dazu in der Industrie weit verbreiteten Systeme zur Produktionsplanung und Steuerung können nur bedingt für den Krankenhauskontext angepasst werden. Man könnte zwar Patienten prinzipiell mit Produkten vergleichbar, Behandlungen mit Fertigungsschritten und Ärzte und Räume mit Produktionskapazitäten, aber der Umgang mit Menschen im Krankenhauskontext ist grundsätzlich anders als die Produktion lebloser Gegenstände. Zum einen gibt es in der Industrie keine unaufschiebbaren Notfälle, welche gesamte Planungsergebnisse verzerren. Zum anderen sind im Umgang mit Menschen z. B. Aspekte der Fairness relevant. Die Verteilung von zwei Stunden durchschnittlicher Wartezeit oder von durchschnittlich zwei Überstunden auf eine von drei Personen kann bereits zur Nichtakzeptanz einer Lösung führen.

Weiterhin haben zwar Aufgaben zur Patientenplanung seit der ersten Pionierarbeit 1964 zur Identifikation guter Bestellstrategien (Welch 1964) eine lange Tradition, dennoch sind aktuelle Ansätze nur selten in der Lage, die skizzierte krankenhaushärente Komplexität adäquat abzubilden. Vorwiegend werden isolierte Problemstellungen wie die Planung von OP-Sälen oder anderen medizinischen Großgeräten thematisiert. Aufgrund der engen Verflechtung krankenhauser interner Prozesse müssen durch diese einseitige Planung immer wieder teure Operationen verschoben werden, weil im Anschluss kein freies Bett zur Verfügung steht, oder eine nötige Voruntersuchung nicht durchgeführt wurde. Die Nichtbeachtung von Behandlungskapazitäten bei taktischer Aufnahmeplanung kann ebenfalls zu einer unnötig langen Verweildauer führen, da z. B. auf freie OP-Kapazitäten gewartet werden muss. Weiterhin müssen Patienten abgewiesen werden, wenn bei der Planung praxisrelevante Nebenbedingungen wie die in Deutschland vorherrschende Geschlechtertrennung auf Normalstationen nicht beachtet wurde.

Alternativ zur taktischen und operativen Planung elektiver Patienten können strategische Maßnahmen zum Ressourceneinsatz die Effizienz eines Krankenhauses steigern. Aktuelle Ansätze fokussieren sich hier ebenfalls vorwiegend auf isolierte Aspekte. Dabei müssen gerade bei strategischen Veränderungsentscheidungen eine Vielzahl von krankenhauserweiterten Konsequenzen berücksichtigt werden. Eine isolierte Betrachtung kann die Realitätsnähe der verwendeten Modelle erheblich negativ beeinflussen und somit zu Fehlentscheidungen führen (Jacobson et al. 2006, S. 235).

Zur Unterstützung der Ressourcenkapazitätsplanung auf den genannten drei Ebenen ist eine Abbildung des gesamten stationären Behandlungsverlaufs auf Mikroebene nötig. Klinische Pfade stellen eine solche Abbildungsmöglichkeit dar und sind im Rahmen dieser Arbeit<sup>1</sup> definiert als:

---

<sup>1</sup> Siehe Anhang F für eine Übersicht weitere Begriffsdefinitionen.

*Eine vollständige interdisziplinäre Abbildung des stationären Behandlungsablaufs für homogene Patientengruppen. Dabei umfasst der Behandlungsablauf sämtliche planungsrelevanten Diagnose- und Behandlungsprozeduren, alle nötigen Stationsaufenthalte sowie mögliche Reihenfolgebeziehungen zwischen den einzelnen Elementen. Klinische Pfade sind darauf ausgerichtet, die Effizienz des Ressourceneinsatzes sowie der krankenhausinternen Prozesse zu steigern.*

Damit eignen sie sich prinzipiell zur Entwicklung neuer Ansätze zur Entscheidungsunterstützung. Aufgrund der Vielzahl am Behandlungsprozess beteiligter Akteure, eingesetzten Ressourcen und individueller Krankheitsbilder ist die Erstellung dieser Pfade ein sehr komplexer und zeitaufwendiger Prozess (Roeder et al. 2003b, S. 1150ff; Küttner und Roeder 2007, S. 10; Salfeld et al. 2009, S. 49). Dadurch ist der Einsatz dieser Pfade in der Praxis auf einige wenige stark standardisierte Behandlungsprozesse beschränkt. Auch eine Übertragbarkeit entwickelter Pfade von einem Krankenhaus zu einem anderen ist nur beschränkt möglich, da die Pfade immer an das individuelle Ressourcenprofil eines Krankenhauses gebunden sind. Ansätze, die Pfade automatisch zu generieren scheitern derzeit einerseits an der Heterogenität der Behandlungen, andererseits sind die Ergebnispfade aufgrund fehlender Informationen nicht zur Planung geeignet. Ein neuer Ansatz sollte so generisch sein, dass er ohne nennenswerte Änderungen für jedes Krankenhaus Deutschlands angewendet werden kann.

Anspruch dieser Arbeit ist es, ein generisches datengetriebenes Krankenhausentscheidungsunterstützungssystem (KH-EUS) für die skizzierten Ressourcenkapazitätsentscheidungen auf strategischer, taktischer und operativer Ebene zu konzipieren und umzusetzen. Dabei sollen insbesondere neue Ansätze für praxisnahe Problemstellungen im automatischen Erzeugen klinischer Pfade, im automatischen Planen elektiver Patienten sowie im Evaluieren von Ressourcenkapazitätsentscheidungen erforscht werden. Zur Steigerung der Praktikabilität fließen dabei Aspekte der medizinischen Planung sowie der online Ressourcenkapazitätsplanung (siehe Abb. 1) in die Ansätze ein. Beispiele für diese Aspekte sind u. a. die Entwicklung klinischer Pfade aus medizinischer Sicht, die Auswahl individueller Behandlungsabläufe nach verschiedenen Diagnosen sowie mögliche Komplikationen bei Behandlungsverläufen. Als Aspekt der online Ressourcenkapazitätsplanung werden prognostizierte Notfallpatienten berücksichtigt. Die Umsetzung einer operativen Steuerung der entwickelten Entscheidungsunterstützung ist nicht Bestandteil dieser Arbeit.

Um diesem Anspruch zu genügen, ist diese Dissertation wie folgt aufgebaut:

In Kapitel 2 wird der Forschungsbedarf und die Zielstellung der Arbeit vorgestellt. Das Konzept des Krankenhausentscheidungsunterstützungssystems (KH-EUS) wird in Kapitel 3 erläutert. Die Vorstellung der eingereichten Publikationen erfolgt im Kapitel 4. Die Schlussbetrachtung ist im Kapitel 5 enthalten. Die Anhänge A-E enthalten die einzelnen Publikationen.

## 2. Forschungsbedarf und Zielstellung der Arbeit

Verglichen mit der Industrie kommen Hans et al. (2012) zu dem Schluss, dass deutlich weniger Lösungsmethoden zur Planung und Steuerung im Krankenhaus eingesetzt werden und damit Potentiale für Effizienzsteigerungen ungenutzt bleiben. Als Gründe dafür werden neben dem prinzipiellen Problem, dass es sich bei einem Krankenhaus um eine Organisationsform handelt, in der eine Vielzahl von Akteuren (Ärzte, Pflegekräfte und Verwaltung) eng kooperieren müssen, diese aber eigene, teilweise gegenläufige Ziele (z. B. Vermeiden von Überstunden bei gleichzeitiger Minimierung der Verweildauer) verfolgen (Glouberman und Mintzberg 2001; Glouberman und Mintzberg 2001), Probleme bei den eingesetzten operativen Planungswerkzeugen und der Qualifikation des Planungspersonals angeführt. So setzt zwar die Abrechnung einer DRG eine vollständige und korrekte Kodierung aller Diagnosen und Maßnahmen voraus (Lauterbach et al. 2010, S. 238), allerdings wird die dadurch verbesserte Datengrundlage für die Entscheidungsunterstützung bisher nur selten in operative Systeme integriert (Khoumbati et al. 2006). Erschwerend kommt hinzu, dass die für die Steuerung des Patientenflusses beauftragten Fallmanager generell zwar beste Lösungen suchen, allerdings aufgrund von Qualifikationsdefiziten selten ressourcenoptimale Ergebnisse erzielen. Darüber hinaus werden Entwicklungen besserer administrativer Werkzeuge oft als Verschwendung wertvoller Zeit am Patienten empfunden (Carter 2002).

Die gegenwärtige Situation aus hohem Effizienz- und Kostendruck deutscher Krankenhäuser bedingt durch das G-DRG-System sowie steigende Patientenzahlen aufgrund des demographischen Wandels, erzwingt die Erforschung neuer Werkzeuge zum Identifizieren und Evaluieren weiterer Möglichkeiten für Effizienzsteigerungen. Ohne eine Steigerung der Effizienz ist die medizinische Versorgung mit Blick auf die zukünftigen Herausforderungen qualitativ, quantitativ und finanziell gefährdet (Augurzky 2015).

Grundsätzlich existieren zwei Arten von Patienten: zufällig auftretende, dringend zu behandelnde Notfälle sowie elektive Patienten, deren Behandlungszeitpunkt weitestgehend frei wählbar ist. Da beide Patientengruppen um dieselben krankenhausinternen Ressourcen konkurrieren, sind für einen effizienten Ressourceneinsatz eine Vielzahl von Kommunikations- und Koordinationsaufgaben nötig (Matthias Bartz 2006, S. 9ff). Erschwert werden diese durch den hohen Grad an Interdependenzen zwischen den Behandlungsprozessen sowie der Vielzahl beteiligter Akteure mit unterschiedlichsten Qualifikationen (McClellan und Millard 1995). Schwächen im Behandlungsmanagement führen u. a. zu Wartezeiten, ungenutzten Ressourcenkapazitäten und damit zu Kostensteigerungen, welche nicht durch die DRG-Fallpauschale kompensiert werden. Aufgrund der inhärenten Komplexität werden zur Verbesserung der Ressourcenverteilung integrierte krankenhausweite Ansätze benötigt (Villa et al. 2009). Zur Umsetzung dieser Ansätze wird eine zur Entscheidungsunterstützung geeignete Abbildung der stationären Behandlungsprozesse benötigt. Dabei verspricht die Etablierung patientenzentrierter Behandlungsabläufe die mit Abstand größte Hebelwirkung (Salfeld et al. 2009; Villa et al. 2009). Die damit einhergehende erhöhte Prozessstandardisierung und –transparenz ermöglichen eine bessere Planung und Steuerung medizinischer Behandlungsprozesse (Jacobs 2007).

Klinische Pfade eignen sich zur Beschreibung der Behandlungsverläufe zwischen Aufnahme und Entlassung (siehe Kapitel 1) und eignen sich damit prinzipiell als zentrale Struktur zur Entscheidungsunterstützung in Krankenhäusern. Dennoch werden trotz des großen Potentials klinische Pfade im Krankenhausalltag weder umfassend eingesetzt noch zur Entscheidungsunterstützung für Ressourcenkapazitätsentscheidungen verwendet. Abb. 2 zeigt entsprechende Problemstellungen, welche durch Verbindung von geeigneten Methoden und detaillierten Behandlungsstrukturen auf strategischer, taktischer und operativer Ebene durch neuartige Ansätze gelöst werden können.

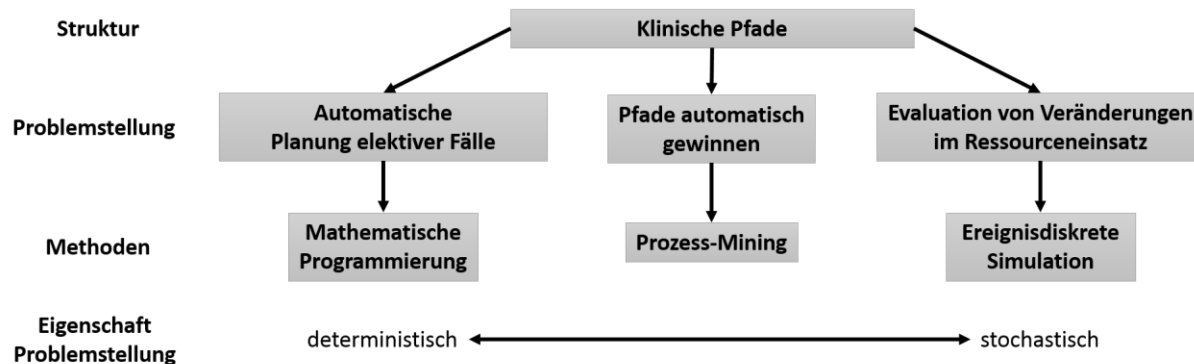


Abb. 2: Zusammenhang klinische Pfade, Problemstellungen und Lösungsmethoden (eigene Darstellung)

### Pfade automatisch Gewinnen

Zentrale Problemstellung ist das umfassende Bereitstellen klinischer Pfade. Durch heterogene Krankheitsbilder, krankenhausbedingter Behandlungsmöglichkeiten und die bereits angesprochene Vielzahl von Akteuren ist das Erstellen klinischer Pfade komplex und zeitaufwendig (Roeder et al. 2003b, S. 1150ff; Küttner und Roeder 2007, S. 10; Salfeld et al. 2009, S. 49). Um möglichst große Effizienzsteigerungen krankenhausinterner Ressourcen durch Planung oder Evaluation von Veränderungsmaßnahmen erzielen zu können, wird jedoch für jedes zu behandelnde Krankheitsbild ein klinischer Pfad benötigt. Die Analyse des aktuellen Forschungsstandes zum Einsatz von IT zur Gewinnung klinischer Pfade offenbart eine Vielzahl von Pfad-Mining-Ansätzen, welche sich in Prozess-Mining, Mining auf Basis klinischer Leitlinien sowie auf Datamining klassifizieren lassen. Dabei verfolgt Prozess-Mining den Ansatz, Prozessmodelle automatisch durch die Analyse von Log-Dateien in Unternehmen eingesetzter IT-Systeme zu erzeugen (Aalst 2011). Zur Umsetzung des G-DRG-Systems wird eine vollständige standardisierte Dokumentation aller Diagnosen sowie therapeutischer Maßnahmen benötigt. Diese Datengrundlage ist prinzipiell mit Log-Dateien vergleichbar. Damit besteht großes Potential für die Entwicklung neuer generischer Prozess-Mining-Werkzeuge zur automatischen Gewinnung klinischer Pfade. Aus diesem Grund beschränkt sich die Analyse des Forschungsstandes auf Prozess-Mining-Ansätze.

Im aktuellen Forschungsstand existieren Ansätze, welche Abweichungen in Behandlungsprozessen im Vergleich mit klinischen Leitlinien oder früheren Behandlungsverläufen aufzeigen (Peleg et al. 2007) sowie Studien, die versuchen besonders auffällige bzw. betrügerische Behandlungsverläufe automatisch zu finden (Yang und Hwang 2006; Rebuge und Ferreira 2012). Dennoch besteht großer Bedarf an neuen Ansätzen, da



bisherige Prozess-Mining-Verfahren kaum in der Lage sind, nutzbare Prozessmodelle selbst für gut strukturierte klinische Prozesse zu finden (Lang et al. 2008; Kaymak et al. 2012). Ein neuer von Huang et al. (2012) entwickelter, auf dynamischer Programmierung basierender Ansatz ist in der Lage, häufige Behandlungsmuster in bestimmten Zeitintervallen zu identifizieren. In weiteren Forschungsarbeiten konnten charakteristische Muster für Behandlungen identifiziert werden (Huang et al. 2013b). Aufbauend auf diesen Ergebnissen konnte die zeitliche Struktur des Behandlungsverlaufs durch Analyse der Behandlungszeiten bestimmt werden (Huang et al. 2013a). Zusammenfassend betrachtet, existieren zwar Ansätze, welche den Behandlungsverlauf beschreiben können, aber die daraus gewonnen Strukturen können nicht zur Planung von Behandlungsabläufen verwendet werden. Dies ist zum einen im Fehlen planungsrelevanter Informationen wie z. B. zeitliche Einschränkungen oder Reihenfolgebeziehungen begründet. Zum anderen begegnen die bekannten Verfahren dem Problem der hohen Prozessvariabilität klinischer Prozesse damit, ähnliche Fälle zu identifizieren, zu clustern und anschließend das Prozess-Mining durchzuführen. Durch das Vermischen ähnlicher Fälle ist es wahrscheinlich, dass im Ergebnis Strukturen enthalten sind, die in dieser Form nicht in der Realität auftreten. Damit ist ein Einsatz dieser Ergebnisse zur Planung nur stark eingeschränkt möglich.

### **Automatische Planung elektiver Patienten**

Durch die umfassende Verfügbarkeit planbarer klinischer Pfade können die geforderten neuen integrierten Ansätze der Planung elektiver Patienten entwickelt werden. Diese Ansätze ermöglichen eine verbesserte Ressourcenverteilung zwischen den einzelnen organisatorischen Einheiten eines Krankenhauses unter Beachtung struktureller Anforderungen an den Behandlungsprozess (Villa et al. 2009). Damit wird dem aktuellen Forschungstrend entsprochen. Modernere Ansätze<sup>2</sup> nutzen neben der häufig eingesetzten mathematischen Programmierung, Heuristiken wie z. B. genetische Algorithmen (Villa et al. 2009) oder agentenbasierte Verfahren (Paulussen et al.) zur Unterstützung der Patientenplanung und –steuerung. Dabei werden Zielstellungen wie: Verbesserung der medizinischen Versorgung, Kostenminimierung oder Verkürzung der Verweildauern verfolgt. Diese Arbeit fokussiert sich auf den Einsatz mathematischer Programmierung als Lösungsmethode, da diese im beschriebenen Kontext weit verbreitet ist und moderne Solver auch praxisnahe Instanzgrößen in akzeptabler Zeit lösen können. Weiterhin werden selbst wenn keine optimale Lösung gefunden wird, noch Schranken für die Lösungsgüte bereitgestellt. Darüber hinaus bietet die mathematische Programmierung die Möglichkeit, Modelle relativ einfach zu erweitern und anpassen zu können.

Die Analyse zum aktuellen Forschungsstand zur operativen Planung im Krankenhaus mit Hilfe mathematischer Programmierung ab 2005 zeigt eine Vielzahl von Arbeiten. Eine Einordnung dieser Arbeiten kann über die planungsrelevanten Ressourcen: OP-Saal, Bett, einzelne Behandlungen, OP-Saal und Bett simultan sowie gesamte klinische Pfade erfolgen. Da ein Planungsmodell des gesamten Pfades alle genannten Ressourcen tangiert, ist eine vollständige Analyse dieser Forschungsfelder sinnvoll. Verteilt auf die einzelnen genannten Planungsschwerpunkte konnten 14 Arbeiten zu OP-Sälen, 5 Arbeiten zu Krankenhausbetten, 3 zu Behandlungen, 10 Betten und OP-Sälen simultan sowie 5 Arbeiten zur Planung gesamter klinischer Pfade identifiziert werden.

---

<sup>2</sup> Überblick über klassische Lösungsmethoden zur Entscheidungsunterstützung im Krankenhaus liefern: von Shuman et al. (1974) Fries (1976), Köhler et al. (1977) und Page (1982)

In den Arbeiten zur Planung klinischer Pfade erstellt Vissers (2005) einen Gesamtplan für operative Eingriffe unter Berücksichtigung der aufeinanderfolgenden Schritte: Normalstation, Operation, Intensivstation und abschließende Normalstation. Mit Hilfe eines MILP-Modells konnte ein Planungshorizont von vier Wochen erfolgreich abgedeckt werden. Conforti et al. (2011) stellen einen MILP-Ansatz zum Planen von Diagnosen, Operationen und Stationsaufenthalten für ein Wochen-Krankenhaus<sup>3</sup> auf. In der Arbeit von Gartner und Kolisch (2013) wird das Ziel verfolgt, den DRG-basierten Erlös eines Krankenhauses zu maximieren. Dazu wird ein MILP-Modell mit fixem Planungshorizont sowie ein rollierendes Modell vorgestellt. Die Ergebnisse für einen Planungshorizont von 28 Tagen und 150 Patienten zeigen einen potentiell höheren Erlös und kürzere Zeitspannen zwischen Aufnahme und Operation. Einen Ansatz zur Planung multipler Behandlungen, welche verschiedene Ressourcen simultan benötigen, liefert Saadani et al. (2014). Mit dem Ziel, die Verweildauer zu reduzieren, konnten Instanzen mit einem Planungshorizont von 14 Tagen und 20 Patienten gelöst werden. Betten werden in diesem Ansatz vernachlässigt. Zusammengefasst existieren zwar einige Modelle zur Planung gesamter klinischer Pfade, aber in keinem Modell werden praktische Anforderungen wie Geschlechtertrennung in Räumen, eine möglichst gleichmäßige Verteilung der zu minimierenden Wartezeit unter den Patienten oder eine Änderung des Optimierungszieles (z. B. von Gleichverteilung der Arbeitslast hin zu hoher Arbeitslast zu Beginn des Planungshorizontes) berücksichtigt.

### **Evaluation von Veränderungen im Ressourceneinsatz**

Strategische Entscheidungen zu Veränderungen im Ressourceneinsatz können die Ressourceneffizienz steigern. Bei diesen langfristigen Entscheidungen müssen im Gegensatz zur Planung elektiver Patienten stochastische Elemente wie die Ankunft von Notfallpatienten, schwankende Behandlungsdauern oder Ressourcenausfälle berücksichtigt werden. Auch sind zur Umsetzung sinnvoller Prozessverbesserungen eine Vielzahl verschiedener Entscheidungs- und Funktionsträger von den Vorteilen der Veränderung zu überzeugen. Da das objektive Aufzeigen insbesondere krankenhauserweiter Konsequenzen dieser Veränderungen aufgrund der hohen Komplexität und der starken Interdependenzen krankenhauserinnerer Behandlungsprozesse sehr schwierig ist, werden Veränderungen häufig nicht durchgeführt. Der Einsatz von ereignisdiskreter Simulation zur Analyse und Verbesserung komplexer Systeme der Gesundheitsversorgung ist weit verbreitet und stellt laut Jacobson et al. (2006) das wahrscheinlich mächtigste und intuitivste Werkzeug dar. Diese Methode kann sowohl mit den stochastischen Elementen umgehen und besitzt die Mächtigkeit, alle Prozesse in adäquater Genauigkeit abzubilden. Die mögliche Visualisierung der Modelle erleichtert es Entscheidungsträgern, die Ergebnisse nachzuvollziehen und trägt somit zur Vertrauensbildung in die Ergebnisse bei. Aus diesen Gründen wird sich im Rahmen dieser Arbeit auf ereignisdiskrete Simulation zur Evaluation von Veränderungen im Ressourceneinsatz beschränkt.

Bei Analyse des Forschungsstandes fällt auf, dass der bisherige Fokus von Simulationsstudien im Krankenhauskontext auf einer isolierten Betrachtung einzelner Krankenhausbereiche und einer Problemlösung innerhalb dieser beruht (Eldabi et al. 2006; Jacobson et al. 2006; Günal und Pidd 2010). Aufgrund komplex verflochtener Krankenhausprozesse kann eine isolierte Betrachtung die Realitätsnähe der Modelle allerdings erheblich negativ beeinflussen (Jacobson et al. 2006, S. 235). Dies macht einen verallgemeinerbaren Erkenntnisgewinn unmöglich

---

<sup>3</sup> In einem Wochen-Krankenhaus ist die Verweildauer auf maximal eine Woche beschränkt.

(Günel und Pidd 2010, S. 48). Weiterhin tritt laut Günel (2012) die gesamte Forschung zur Simulation im Krankenhauskontext auf der Stelle, da sie neben der geringen praktischen Relevanz der Mehrzahl von Simulationsstudien auch keinen theoretischen Mehrwert für andere Forscher bereitstellt. Um diesen Stillstand in der Forschung zu beenden, sollten zukünftige Studien auf integrierten Modellen basieren, die versuchen die Komplexität eines Krankenhauses als Ganzes abzubilden (Eldabi et al. 2006; Günel und Pidd 2010). Ebenso sollten allgemeingültige Aussagen getroffen und ein praktischer Nutzen transparent dargestellt werden (Günel und Pidd 2010). Im aktuellen Forschungsstand existieren zwei Ansätze, die den Patientenfluss krankenhausesweit abbilden und allgemeingültige Aussagen zu treffen versuchen (Coughlan et al. 2011; Baboolal et al. 2012). Laut Jacobson et al. (2006) kann mit objektorientierten, einfach wiederverwendbaren Modellen und modernen Visualisierungstechniken die Akzeptanz von Simulationsergebnissen in der Praxis deutlich erhöht werden.

Neben der allgemeinen Nutzung der Simulationstechnik stellt die Flexibilisierung des Belegungsmanagements eine konkrete Verbesserungsmaßnahme dar, welche großes Potential zur Effizienzsteigerung einer der wichtigsten Ressourcen eines Krankenhauses, des Patientenbettes (Black und Pearson 2002), besitzt. Dabei ist das Belegungsmanagement in nahezu jeden Krankenhausprozess involviert (Proudlove et al. 2003) und bildet die Voraussetzung für eine effiziente Patientenversorgung (Kumar und Mo 2010). Die Analyse des aktuellen Forschungsstandes bezogen auf diese Problemstellung offenbart eine Vielzahl von Simulationsstudien zum Betten- und Belegungsmanagement. Aufgrund der skizzierten Notwendigkeit der simultanen Betrachtung mehrerer Stationen oder des gesamten Krankenhauses für realitätsnahe Aussagen in diesem Kontext (Roche et al. 2012) wird im Folgenden die Analyse des Forschungsstandes auf integrierte Studien eingegrenzt.

Basierend auf krankenhauseigenen Daten entwickelten Costa et al. (2003) ein Simulationsmodell zur Vorhersage der Anzahl benötigter Betten unter Berücksichtigung von Aufnahmekriterien, Prioritätsregeln und erwarteten Verweildauern. Kolker (2009) zeigt anhand einer Simulationsstudie, wie viele elektive Operationen pro Tag geplant werden sollten, um Engpässe auf den Intensivstationen zu vermeiden. Mit seinem Ansatz konnte er für ein Krankenhaus mit ca. 450 Betten zeigen, dass bis zu fünf Operationen pro Tag Engpässe vermeiden. Khare et al. (2009) zeigen in ihrer Studie, dass Veränderungen im Verlegungsintervall von Patienten aus der Notaufnahme auf Normalstation größere Effekte haben als die Verkürzung der Verweildauer. Barado et al. (2012) entwickelten unter Verwendung der Behandlungsdaten aus neun Jahren ein Simulationsmodell, welches die Belegungsdynamiken der Intensivstationen des Krankenhauses in Navarra abbildet. Basierend auf diesem Modell konnte ein Werkzeug entwickelt werden, welches die Anzahl von Betten in den Intensivstationen bei einer Vergrößerung der Patientenzahlen um 50 % prognostiziert. Zusammengefasst kann festgestellt werden, dass die Flexibilisierung des Belegungsmanagements im krankenhauseiten Kontext bisher nicht erforscht wurde. Weiterhin wurden bisher keine klinischen Pfade zur adäquaten Abbildung krankenhauseitiger Flüsse von elektiven und Notfallpatienten verwendet.

Neben der Lösung der beschriebenen Problemstellungen verfolgt diese Arbeit insbesondere den Anspruch, möglichst alle Facetten der Ressourcenkapazitätsplanung (siehe Kapitel 1) krankenhausesindividuell und praxistauglich abdecken zu können. Dazu werden die entwickelten Werkzeuge konzeptionell in ein generisches Entscheidungsunterstützungssystem integriert.

Damit wird eine einfache Wiederverwendung der entwickelten Werkzeuge durch die Verwendung einer einheitlichen standardisierten Datenbasis ermöglicht. Darüber hinaus werden Synergien durch eine Kombination der einzelnen Werkzeuge nutzbar. So könnten einerseits Optimierungsergebnisse durch ein Simulationsmodell evaluiert werden, andererseits können Ressourcenbedarfe sowie das Aufkommen von Notfallpatienten in einem Simulationsmodell geschätzt und anschließend als Grundlage zur Optimierung verwendet werden. Vor allem durch die angestrebte hohe Abbildungsgenauigkeit aller Behandlungsverläufe könnten somit die in der Planung für elektive Patienten verwendeten Puffer für Notfallbehandlungen auf ein statistisch begründetes Minimum reduziert werden.

Damit ergeben sich für diese Dissertation die folgenden Zielstellungen:

- (1) ein generisches System zur Unterstützung von Ressourcenkapazitätsentscheidungen auf strategischer, taktischer und operativer Ebene für deutsche Krankenhäuser zu konzipieren,
- (2) im Rahmen des Konzepts integrierte, auf klinischen Pfaden basierende Werkzeuge zum
  - a. automatischen Gewinnen planbarer klinischer Pfade für elektive Behandlungen,
  - b. zum Planen vollständiger elektiver Behandlungen und
  - c. zur Evaluation von Veränderungen im Einsatz krankenhauserinterner Ressourcen zu entwickeln und
- (3) diese Werkzeuge anhand praxisnaher Fallstudien zu evaluieren.

Dabei sollen alle Werkzeuge den übergeordneten Zielen einer

- (4) automatischen datengetriebenen Erstellung von Modell- und Prozessstrukturen sowie entsprechend der adressierten Entscheidungsebene einer
- (5) adäquaten Abbildungsgenauigkeit und einer
- (6) effizienten Lösbarkeit genügen.

### **3. KH-EUS Konzept**

In diesem Kapitel wird das Konzept des KH-EUS vorgestellt. Da ein Ziel des Systems die einfache Wiederverwendung aller datengetriebenen Werkzeuge ist, wird zu Beginn der nach laut § 21 KHEntgG jährlich von jedem Krankenhaus routinemäßig zu erhebende Datensatz vorgestellt. Anschließend wird das Gesamtkonzept des KH-EUS vorgestellt. Die Erläuterung der drei Kernmodule bildet den Abschluss dieses Kapitels.

#### **3.1. Routinedaten im G-DRG-System**

Das G-DRG-System stellt ein durchgängiges, leistungsorientiertes und pauschaliertes Vergütungssystem allgemeiner Krankenhausleistungen dar (§ 17b Abs. 1 Satz 1 KHG). Dieses System dient dem Zweck „die wirtschaftliche Sicherung der Krankenhäuser, um eine bedarfsgerechte Versorgung der Bevölkerung mit leistungsfähigen, eigenverantwortlich wirtschaftenden Krankenhäusern zu gewährleisten [...]“ (§1 Abs. 1 Satz 1 KHG).“ Grundsätzlich gilt es bundesweit für alle Krankenhäuser. Die Vergütung für alle Patienten eines Krankenhauses wird unabhängig von ihrer Krankenkassenzugehörigkeit in einheitlicher Höhe berechnet (§ 17b Abs. 1 Satz 1 KHG).

Schwerpunkt des leistungsbezogenen Vergütungssystems für Krankenhäuser ist die Gruppierung von Fällen mit ähnlichem Kostenaufwand in sog. DRGs. Dabei wird der Bezug zwischen Art und Anzahl der stationär behandelten Fälle und dem Ressourcenverbrauch eines Krankenhauses über die DRG hergestellt (Lauterbach et al. 2010, S. 237). Die mit jeder DRG verknüpfte *Bewertungsrelation* drückt die durchschnittliche Kostenintensität einer DRG im Verhältnis zu den anderen DRGs aus. Somit ist z. B. eine DRG mit einer Bewertungsrelation von 3,0 dreimal so kostenintensiv wie ein Fall mit 1,0 bewerteten DRG (Simon 2011, S. 306ff).

Formal besteht eine DRG aus vier alphanumerischen Zeichen (z. B. C08B für Extrakapsuläre Extraktion der Linse ohne angeborene Fehlbildung der Linse). Die erste Stelle gibt die Hauptgruppe (Major Diagnostic Category (MDC)) eines Falls an. Stelle zwei und drei geben an, ob es sich um eine *operative Partition* (01-39), eine *andere Partition* (40-59) oder eine *medizinische Partition* handelt (60-99). Die vierte Stelle dient zur Hierarchisierung des Ressourcenverbrauchs. Hier gilt: A = höchster Ressourcenverbrauch, B = zweithöchster Ressourcenverbrauch usw. (InEK GmbH 2014, S. 4f). Die Hierarchisierung des Ressourcenverbrauchs wird anhand der fallspezifischen Faktoren: patientenbezogener Gesamtschweregrad (PCCL), Alter, Verweildauer, Beatmung, Entlassungsgrund, Hauptdiagnose, Nebendiagnose und durchgeführten Prozeduren bestimmt (InEK GmbH 2014, S. 8). Zur Bestimmung des PCCL eines Falls, wird jeder Diagnose ein CCL-Wert (Komplikationen oder Komorbiditäten) zugeordnet, aus denen der PCCL-Wert berechnet<sup>4</sup> wird (InEK GmbH 2014, S. 8). Nach Ermittlung des PCCL-Wertes kann die endgültige DRG anhand der Faktoren: PCCL, Alter, Verweildauer, Beatmung, Entlassungsgrund, Hauptdiagnose, Nebendiagnose oder Prozeduren bestimmt werden (InEK GmbH 2014, S. 8).

Da die Krankenhausfinanzierung zum größten Teil über das G-DRG-System realisiert wird, müssen möglichst umfassend alle Besonderheiten der Behandlung von Patienten abgebildet werden. Vor diesem Hintergrund muss das Fallpauschalensystem von allen Beteiligten als *lernendes System* verstanden werden (Tuschen und Trefz 2004, S. 105). Um die zur Weiterentwicklung nötigen Daten zu gewinnen, ist laut § 21 KHentgG jedes Krankenhaus dazu verpflichtet, jährlich einen standardisierten Datensatz für das vorangegangene Kalenderjahr an das InEK zu übermitteln (§ 21 KHentgG). In diesem Routinedatensatz sind krankenhauses- und fallbezogene Daten enthalten. Krankenhausbezogen sind bspw. Name, Art, Anzahl Betten, Personalkosten je examinierte Vollkraft und Anzahl abgerechneter DRG-Fälle. Fallbezogene Daten enthalten einen Datensatz für jeden innerhalb eines Jahres behandelten stationären und teilstationären Fall (InEK GmbH 2015).

Die Grundlage zur Bestimmung klinischer Pfade bilden im Rahmen dieser Dissertation die fallbezogenen Daten, welche in Abb. 3 auszugsweise dargestellt sind. Prinzipiell handelt es sich dabei um die zur Bestimmung der jeweiligen DRG benötigten Daten. Aufgrund dessen müssen sie in allen Krankenhäusern routinemäßig vollständig und in guter Qualität erfasst werden. Zur detaillierten Dokumentation der Behandlungsverläufe werden Falldaten, Fachabteilungsangaben, Diagnoseangaben und Prozedurangaben erhoben<sup>5</sup>.

---

<sup>4</sup> Details zur Berechnung des PCCLs sich in InEK GmbH (2014) zu finden.

<sup>5</sup> Eine vollständige Übersicht sowie weitere Informationen zu Datentyp oder Länge der Zeichenketten sind in (InEK GmbH 2015) zu finden.

Die Falldaten werden einmalig für jeden Behandlungsfall erfasst. Identifiziert wird jeder Fall über das *KH-interne Kennzeichen*.<sup>6</sup> Neben patientenbezogenen Daten wie *Alter*, *Geschlecht* oder *Wohnort* wird z. B. über den *Aufnahmeanlass* ein Fall u. a. als Notfall oder Einweisung durch einen Arzt klassifiziert. Dies ermöglicht später eine Unterscheidung in elektive Fälle und Notfälle. Analog zur Aufnahme werden *Entlassungs-* bzw. *Verlegungsdatum* aus dem Krankenhaus sowie dessen Anlass (z. B. Behandlung regulär beendet oder Entlassung in eine Pflegeeinrichtung) dokumentiert. Zu jedem Behandlungsfall werden weiterhin in den Fachabteilungsangaben die einzelnen durchlaufenen Stationen des Krankenhauses chronologisch dokumentiert. Dies ermöglicht das Bestimmen der Reihenfolge der zu durchlaufenden Stationen sowie die Verweildauer auf den einzelnen Stationen. Weiterhin entspricht das früheste *Datum der Aufnahme in eine Fachabteilung* dem *Aufnahmedatum* des Falls. Das *späteste Datum der Verlegung-/Entlassung aus der Fachabteilung* entspricht dem *Entlassungsdatum* des Falls.

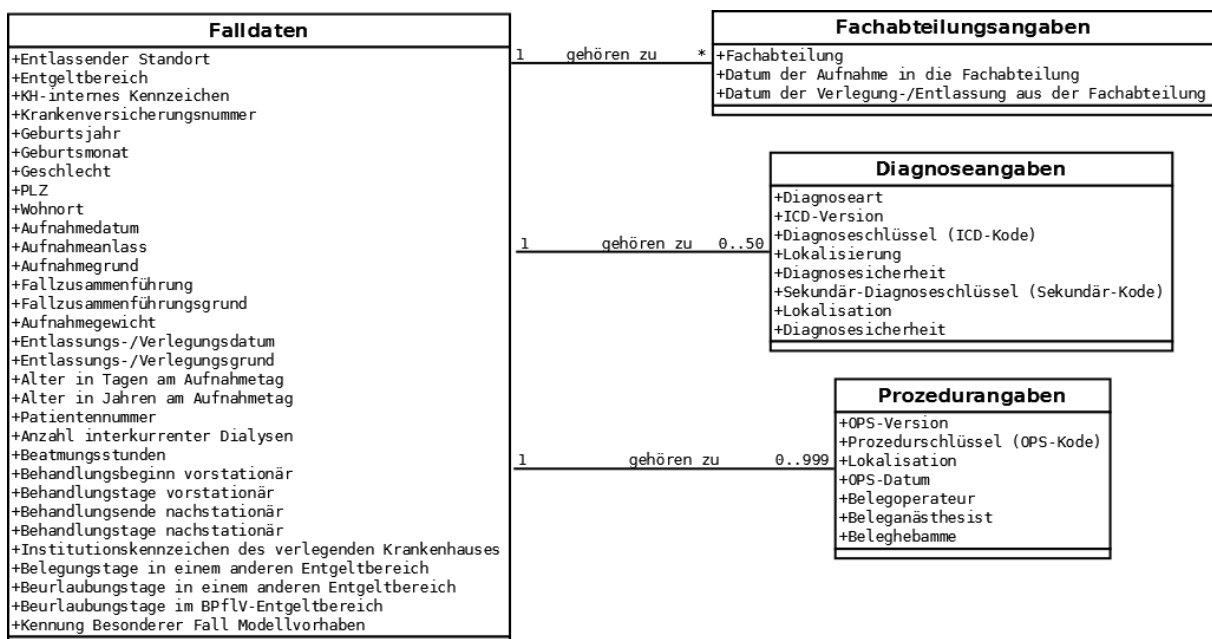


Abb. 3: Überblick fallbezogene Routinedaten  
(eigene Darstellung in Anlehnung an (InEK 2015, 4f))

In den Diagnoseangaben zu einem Fall können bis zu 50 verschiedene Diagnosen dokumentiert werden. Dabei muss bei Fällen, die im DRG-Entgeltbereich abgerechnet werden, genau ein *Diagnoseschlüssel* als *Diagnoseart* „Hauptdiagnose“ gekennzeichnet sein. Diese entspricht der medizinischen Indikation für die stationäre Behandlung des Patienten und bildet später ein wichtiges Kriterium zur Gruppierung von Behandlungspfaden. Alle anderen Diagnosen sind Nebendiagnosen. Alle Diagnosen werden standardisiert nach dem International Statistical Classification of Diseases and Related Health Problems (ICD-10) Klassifikationssystem dokumentiert.

Neben den Diagnosen können bis zu 999 Operationen und Prozeduren (OPS) für einen Fall angegeben werden. Die sog. OPS-Kodes dokumentieren die am Patienten vorgenommenen Maßnahmen und werden jährlich vom Deutschen Institut für Medizinische Dokumentation und Information (DIMDI) in standardisierter Form bereitgestellt. Dabei ist ein OPS-Kode eine bis

<sup>6</sup> Da die Datenlieferung ausschließlich als einzelne CSV-Dateien vorgenommen wird, werden keine Primärschlüssel im Sinne einer relationalen Datenbank vergeben.

zu 11 alphanumerische Zeichen lange hierarchische Kette, welche mit zunehmender Länge immer präziser wird. So lassen sich die verschiedenen Arten von Prozeduren (Diagnostische Maßnahmen, Bildgebende Diagnostik, Operationen, Medikamente, Nichtoperative therapeutische Maßnahmen sowie ergänzende Maßnahmen) anhand des ersten Zeichens des Codes unterscheiden. Das konkret eingesetzte Verfahren und verwendete Spezialtechniken können über den gesamten OPS-Code identifiziert werden. Bspw. handelt es sich bei dem OPS-Code: 3301.0 um das optische laserbasierte Verfahren: Konfokale Mikroskopie des Verdauungstraktes, endoskopisch inkl. Konfokale Mikroskopie der Papilla duodeni major. Zusätzlich zur eigentlichen Maßnahme wird deren Ausführungszeitpunkt im Feld *Datum* (bestehend auf Zeit und Datum) dokumentiert (InEK GmbH 2015). Damit ist es möglich, die Chronologie der Behandlungen nachzuvollziehen und auf Reihenfolgen zu untersuchen.

### 3.2 Gesamtkonzept

Aufbauend auf dem beschriebenen Forschungsbedarf (siehe Kapitel 2) sowie den dargestellten krankenhausinternen Planungsaufgaben zur Ressourcenkapazitätsplanung (siehe Kapitel 1) wird im Rahmen dieser Dissertation das in Abb. 4 dargestellte KH-EUS konzipiert. Bisher existiert kein generisches System, welches datengetriebene krankenhausindividuelle Entscheidungsunterstützung zur Verbesserung der Effizienz stationärer und teilstationärer Behandlungen unter Verwendung von klinischen Pfaden als strukturelle Grundlage für adäquate Abbildungsgenauigkeit ermöglicht. Als Nutzer des KH-EUS wird auf strategischer Ebene der Entscheidungsunterstützung das Krankenhausmanagement sowie medizinische- und kaufmännische Controller adressiert. Auf taktischer und operativer Ebene Fallmanager, Personaler, Qualitätsmanager und ärztliches Personal.

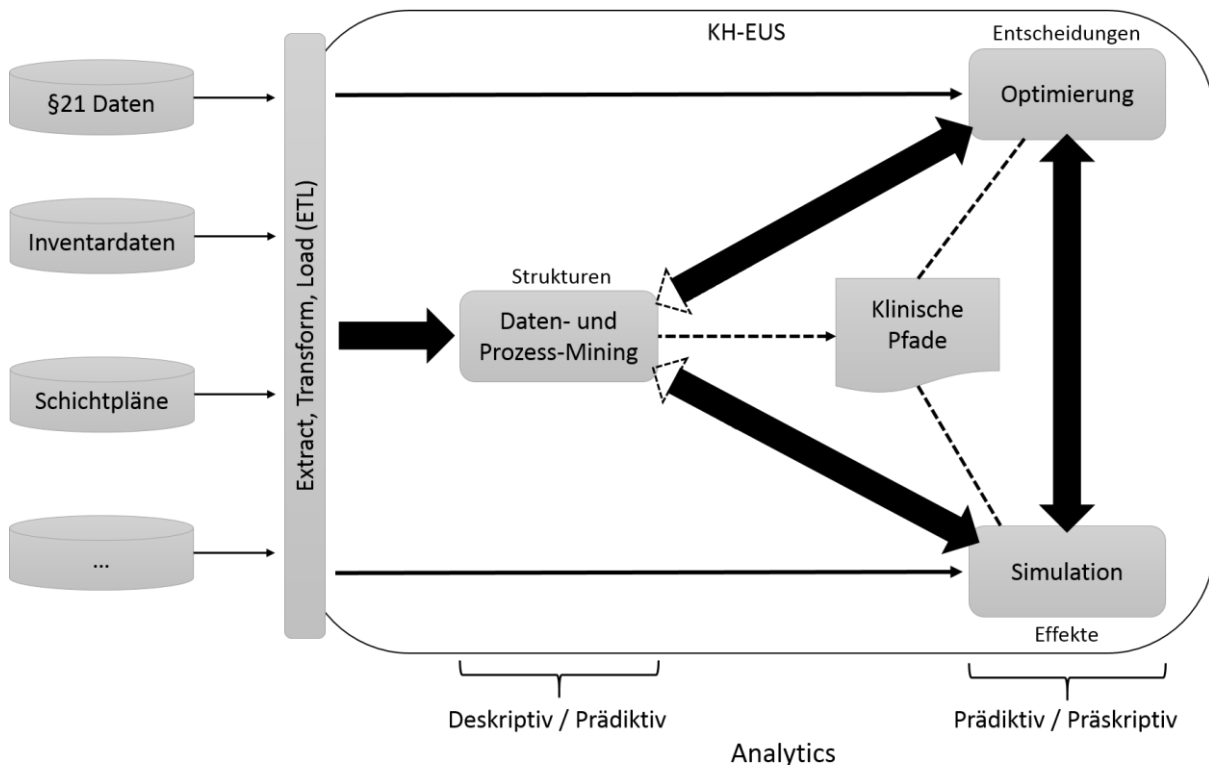


Abb. 4: Konzept Krankenhausentscheidungsunterstützungssystems (eigene Darstellung)

Das konzipierte KH-EUS besteht aus den drei Modulen: *Daten- und Prozess-Mining* für deskriptive und prädiktive Analytics sowie *Optimierung* und *Simulation* für prädiktive und präskriptive Analytics.

Als Daten für das KH-EUS werden zum einen Informationen über krankenhausspezifische stationäre Behandlungsverläufe und zum anderen über verfügbare Ressourcenprofile benötigt. Dabei wird der generische Charakter des KH-EUS insbesondere durch die Verwendung von standardisierten Routinedaten zur Abbildung der Behandlungsverläufe hervorgehoben. Zusammen mit den potentiell in Hinblick auf Struktur und Inhalt sehr heterogenen Daten verfügbarer Krankenhausressourcen werden die aufgrund §21 KHEntgG erhobenen Daten (siehe Kapitel 3.1) in einer *Extract, Transform, Load (ETL)*-Schicht in eine für das KH-EUS standardisierte Datenbasis überführt. Damit stehen die Daten für deskriptive und prädiktive Analysen im Rahmen des *Daten- und Process-Mining*-Moduls zur Verfügung und können zusätzlich direkt in Form von Ressourcenbudgets (z. B. für verfügbare OP-Zeiten pro Tag oder Bettenkapazität pro Zimmer) in den Modulen *Optimierung* und *Simulation* genutzt werden.

### 3.3 Vorstellung der drei Kernmodule

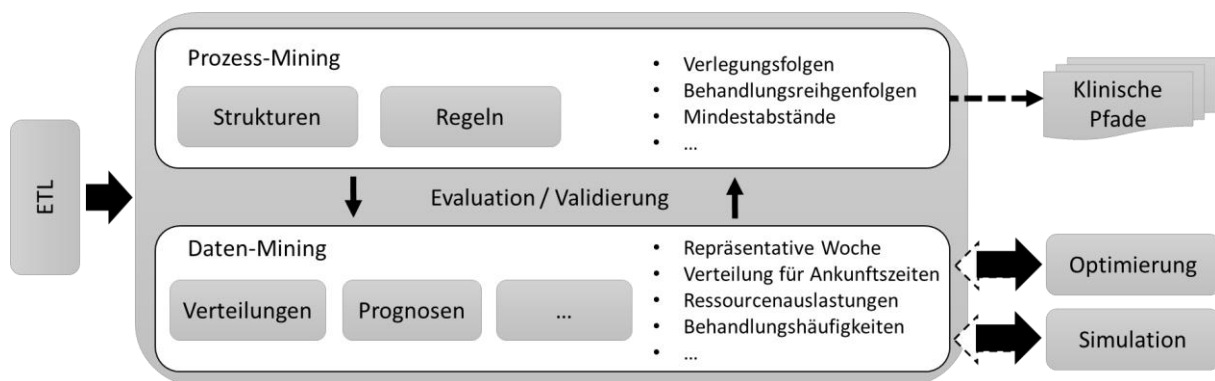


Abb. 5: Konzept Daten- und Prozess-Mining-Modul (eigene Darstellung)

In Abb. 5 ist das *Daten- und Prozess-Mining*-Modul skizziert. Zentrales Ergebnis dieses Moduls ist die **Struktur** krankenhausspezifischer klinischer Pfade, welche im Rahmen des Prozess-Mining aus den Daten stationärer Behandlungsverläufe gewonnen wird. Neben den klinischen Pfaden werden die für die Module *Optimierung* und *Simulation* benötigten Daten für Verteilungen (z. B.: von Ankunftszeiten bestimmter Patientengruppen oder die stationäre Verweildauer) und Prognosen (z. B. zukünftiger Patientenzahlen oder zukünftige Häufigkeit bestimmter Behandlungen) mit Hilfe der Data-Mining-Komponente bestimmt. Die (Teil-)Ergebnisse der beiden Komponenten können jeweils mit der anderen Komponente evaluiert bzw. validiert werden. Zusätzlich zur Analyse historischer Daten ist in diesem Modul die Analyse der Optimierungs- und Simulationsergebnisse angedacht.

Im Optimierungsmodul (siehe Abb. 6) werden mit Hilfe von mathematischer Programmierung **Entscheidungen** für Aufnahme und Behandlungstermine für elektive stationäre Patienten getroffen. Der Planung zugrundeliegend ist eine Menge zuvor bestimmter klinischer Pfade. Zur effizienten Lösbarkeit realistischer Probleminstanzen wird ein hierarchischer Planungsansatz verwendet. In diesem Ansatz wird das eigentliche Problem in ein Top-Modell und in ein entsprechendes Basismodell unterteilt. Lösungen des Top-Modells gehen dabei in das



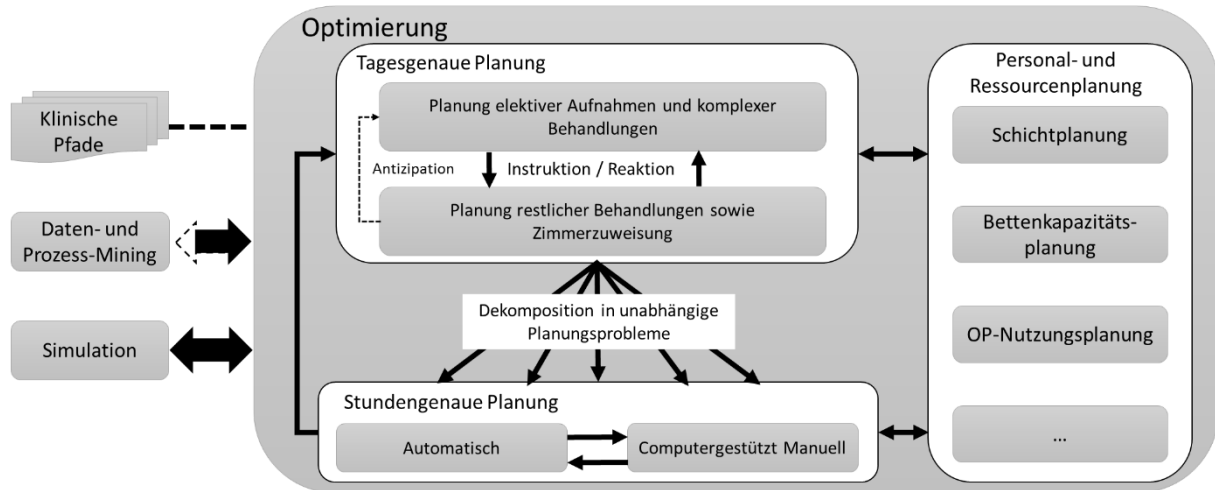


Abb. 6: Konzept des Optimierungsmoduls (eigene Darstellung)

Basismodell ein. Um dabei die Lösbarkeit nicht zu gefährden werden, Eigenschaften des Basismodells im Top-Modell antizipiert (Schneeweiß 1994). Diese werden mit Hilfe eines hierarchischen Planungsmodells auf der Top-Modell-Ebene tagesgenau und auf Ebene des Basismodells stundengenau geplant. Um die Dimension praxisrelevanter Modellgrößen handhaben zu können, ist das tagesgenaue Modell nochmals hierarchisch in ein Grob- und ein Feinmodell unterteilt. Im Grobmodell wird der Aufnahme- sowie der Behandlungstag komplexer Eingriffe (z. B. Operationen) bestimmt. Im Feinmodell werden aufbauend auf den Ergebnissen des ersten Modells allen Patienten konkrete Zimmer zugewiesen sowie die restlichen, im klinischen Pfad enthaltenen Behandlungen, unter Beachtung aller Nebenbedingungen eingeplant. Um für die Feinplanung möglichst gute Ausgangssituationen zu erhalten, werden in das Grobmodell einige Restriktionen des Feinmodells wie z. B. die Geschlechtertrennung in Stationszimmern übernommen. Nachdem für jeden Patienten bestimmt wurde, an welchem Tag die Aufnahme, die einzelnen Behandlungen sowie die weiteren krankenhausinternen Verlegungen stattfinden sollen, erfolgt eine stundengenaue Planung. Dazu können die bisherigen tagesgenauen Pläne in unabhängige, z. B. tageweise oder nach Patientengruppen differenzierte Planungsprobleme dekomponiert werden. Diese können dann, je nach bevorzugter Arbeitsweise im Krankenhaus automatisch über ein weiteres lineares Optimierungsmodell, computergestützt, manuell, oder über ein hybrides Verfahren eingeplant werden. Sollte aufgrund der Ergebnisse des tagesgenauen Planungsmodells keine zufriedenstellende stundengenaue Lösung möglich sein, kann die tagesgenaue Planung erneut mit zusätzlichen Nebenbedingungen oder zeitlichen Fixierungen angestoßen werden.

Personal- und Ressourcenplanung finden sowohl in tagesgenauer als auch in stundengenauer Planung Beachtung. So werden im tagesgenauen Modell z. B. verfügbare Zeitbudgets für die Nutzung von OP-Räumen pro Tag beachtet. Im stundengenauen Modell hingegen stündliche Verfügbarkeitsintervalle und Schichtpläne. Nicht planbare Notfälle werden in Form von Pufferkapazitäten antizipiert. Neben der Verwendung der Personal- und Ressourcenplanung als gegebene Größen verfügbarer Kapazitäten kann diese Planung selbst zu Teilen oder gänzlich unter Beachtung der Planungsergebnisse für klinische Pfade neu durchgeführt werden. Damit können unter Beachtung der geplanten elektiven Patienten Über- bzw. Unterkapazitäten von Personal- und Raumkapazitäten auf taktischer Ebene abgebaut werden. Bspw. sind nach der Planung reservierte aber ungenutzte OP-Zeiten sowie potentielle Engpässe im Bettenbelegungsmanagement transparent. Weiterhin können Zusammenhänge mit gegebener Schichtplanung und deren Auswirkungen auf den gesamten Behandlungsprozess einzelner

Stationen analysiert werden. Somit kann eine effiziente Anpassung der Ressourcenprofile an die geplanten Behandlungsstrukturen auf taktischer Ebene erfolgen.

Neben dem *Optimierungsmodul*, in welchem ausschließlich planbare elektive Patienten betrachtet werden, sind im Simulationsmodul zusätzlich nicht planbare Notfälle berücksichtigt. Weiterhin sind aufgrund der starken Interdependenzen krankenhauser Prozesse die krankenhauser Konsequenzen effizienzsteigernder Maßnahmen nur schwer abzuschätzen (McClellan und Millard 1995). In Abb. 7 ist das Konzept des Simulationsmoduls skizziert. Primäres Ziel dieses Moduls ist es, die krankenhauser **Effekte** operativer und strategischer Entscheidungen zu evaluieren. Als Grundlage dazu wird wie in Kapitel 2 diskutiert ein ereignisdiskretes Simulationsmodell verwendet. Dieses Modell bildet alle entscheidungsrelevanten Prozesse im krankenhauser Kontext auf operativer Ebene ab. Dadurch können mit Hilfe nur eines Modells durch Ausweitung bzw. Einschränkung des betrachteten Zeithorizonts sowohl strategische, taktische als auch operative Entscheidungen evaluiert werden.

Eine mögliche strategische Fragestellung stellt die Evaluation der Auswirkung einer vergrößerten Nutzungsflexibilität von Krankenhausbetten gegenüber einer Investition in

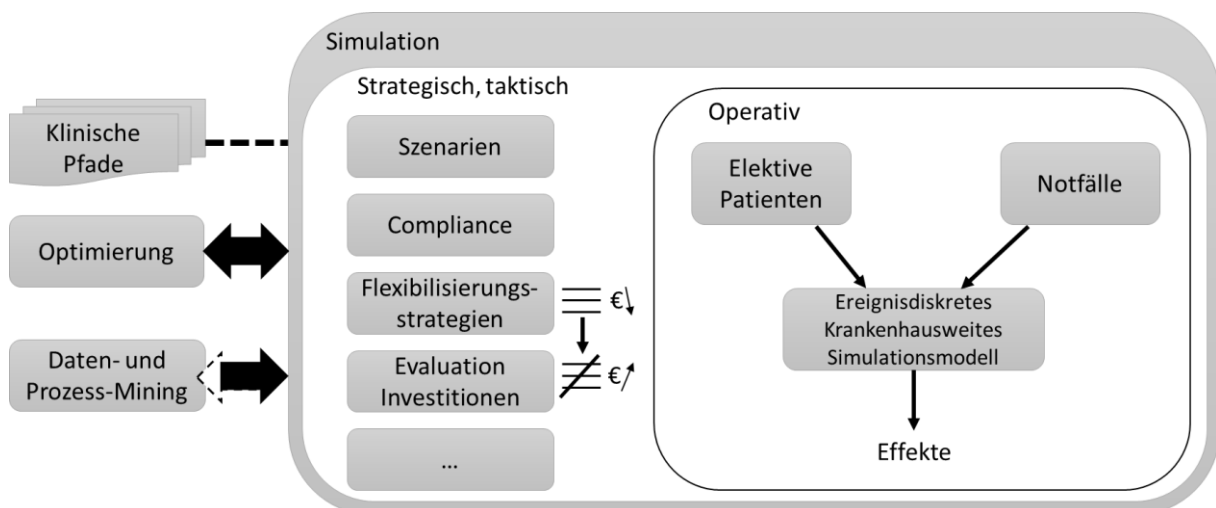


Abb. 7: Konzept des Simulationsmoduls (eigene Darstellung)

Ressourcen zur Senkung der durchschnittlichen Verweildauer um einen gegebenen Betrag dar. Im Ergebnisse könnte sich zeigen, dass eine Erhöhung der Ressourceneinsatzflexibilität z. B. durch kostenneutrale organisatorische Maßnahmen mindestens die gleichen Effekte erzielt wie eine größere Investition in neue Ressourcenkapazitäten. Taktisch können die Auswirkungen verschiedener Schichtmodelle auf die Verteilung der Arbeitslast unter den einzelnen Mitarbeitern evaluiert werden. Ein Beispiel für die Anwendung des Modells auf operativer Ebene ist die Evaluation der im Optimierungsmodul berechneten Pläne unter Berücksichtigung von Notfallpatienten und deren angenommener klinischer Pfade. Damit können Aussagen über die Robustheit der Pläne sowie die der Optimierung zugrundeliegenden Kapazitätspuffer getroffen werden. Neben der Evaluation der Entscheidungen des Optimierungsmodells können auch vielversprechende Simulationsszenarien strategischer oder taktischer Entscheidungen in die operative Planung eingehen. Somit können Pläne z. B. unter Berücksichtigung flexibler Ressourcenkapazitäten oder alternativer Schichtmodelle bestimmt und anschließend vom Krankenhausmanagement diskutiert werden.

## 4. Vorstellung der Publikationen

Im folgenden Kapitel wird ein Überblick über die im Rahmen dieser Dissertation entstandenen Publikationen gegeben. Anschließend werden Zielstellung, angewandter Methodik, Ergebnisse, Erkenntnisgewinn sowie die Einordnung in das Konzept des KH-EUS (siehe Kapitel 3) der einzelnen Publikationen vorgestellt.

### 4.1 Überblick

Bei der vorliegenden kumulativen Dissertation handelt es sich um das Ergebnis eines iterativen Forschungsprozesses, in dessen Rahmen vier Publikationen entstanden sind. Eine fünfte Veröffentlichung hat die erste Begutachtungsrunde passiert und befindet sich derzeit in Revision. Tabelle 1 zeigt alle Publikationen in chronologischer Reihenfolge

<b>Publikation</b>	<b>Kurzbezeichnung</b>
Helbig K (2011) <b>Zeitplanung für Patientenpfade unter Berücksichtigung von Betten-, Behandlungskapazitäten und Fairnesskriterien.</b> Tagungsband 15. Interuniversitäres Doktorandenseminar Wirtschaftsinformatik der Universitäten Chemnitz, Dresden, Freiberg, Halle-Wittenberg, Jena und Leipzig: 34–44.	(Helbig 2011) <i>Anhang A</i>
Helbig K, Mellouli T, Stoeck T, Gragert M, Jahn P. (2014) <b>Simulation stationsübergreifender Patientenflüsse zur Evaluation flexibler Bettenbelegungsszenarien aufgrund der Jahresdatenanalyse eines Universitätsklinikums.</b> In MKWI 2014 - Multikonferenz Wirtschaftsinformatik : 26. - 28. Februar 2014 in Paderborn ; Tagungsband, 749–762. Paderborn: Univ.	(Helbig et al. 2014) <i>Anhang B</i>
Helbig K, Stoeck T, Mellouli T (2015). <b>A Generic Simulation-Based DSS for Evaluating Flexible Ward Clusters in Hospital Occupancy Management.</b> In 48th Hawaii International Conference on System Sciences (HICSS), 2923–2932. IEEE. doi:10.1109/HICSS.2015.354.	(Helbig et al. 2015b) <i>Anhang C</i>
Helbig K, Römer M, Mellouli T (2015) <b>A Clinical Pathway Mining Approach to Enable Scheduling of Hospital Relocations and Treatment Services.</b> In Business Process Management, ed. Hamid Reza Motahari-Nezhad, Jan Recker, and Matthias Weidlich, 9253:242–250. Cham: Springer International Publishing.	(Helbig et al. 2015a) <i>Angang D</i>
Helbig K, Römer M, Mellouli T (2016) <b>A Data-Driven Hierarchical ILP Approach for Scheduling Clinical Pathways: A Real-World Study from a German University Hospital</b> Aktuell in Revision nach Einreichung und erster Begutachtungsrunde der Zeitschrift BUSINESS RESEARCH	(Helbig et al. 2016) <i>Anhang E</i>

Tabelle 1: Überblick eingereicherter Publikationen (eigene Darstellung)

Während der Arbeit am Lehrstuhl für Wirtschaftsinformatik und Operations Research wurde das in Kapitel 3 beschriebene Konzept eines generischen Entscheidungsunterstützungssystems

für Krankenhäuser entwickelt. In Abb. 8 sind die fünf wissenschaftlichen Publikationen den einzelnen Modulen des beschriebenen KH-EUS Konzept zugeordnet.

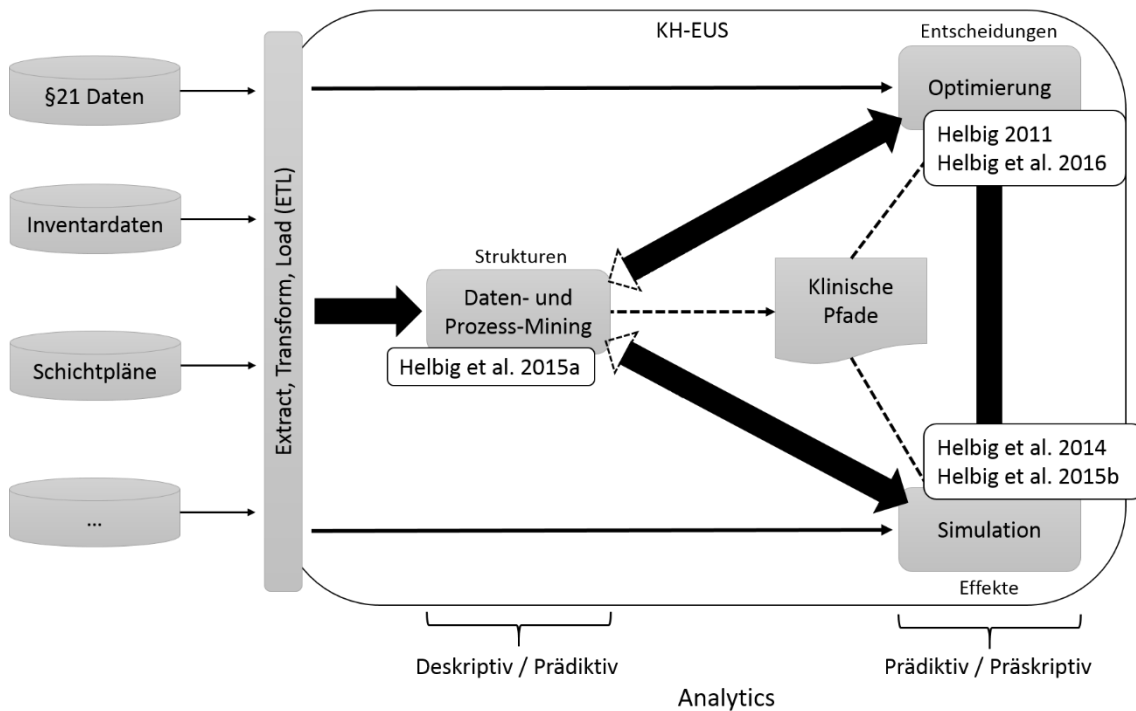


Abb. 8: Einordnung der Publikationen in KH-EUS Konzept (eigene Darstellung)

Im Rahmen einer Industriekooperation mit OR-Soft wurden die ersten konkreten Erfahrungen mit klinischen Pfaden sowie der auf Heuristiken beruhenden Planung erworben. Aufbauend darauf wurde mit dem damaligen Kenntnisstand klinischer Prozesse ein MILP-Modell zur stundengenauen Planung klinischer Pfade entwickelt und im Tagungsband des Doktorandenworkshops der Wirtschaftsinformatik veröffentlicht (Helbig 2011). Ziel der Modellierung war es, auf Basis modellhafter klinischer Pfade das operative (offline) Planungsproblem für elektive stationäre Patienten unter Beachtung praxisrelevanter Nebenbedingungen wie Geschlechtertrennung in Zimmern zu lösen.

Im Rahmen dieses Workshops ist eine weitere Kooperation mit der Gesundheitsforen Leipzig GmbH entstanden. Während dieser Kooperation wurden die nach § 21 KHEntgG jährlich zu erfassenden Routinedatensätze in Hinblick auf die Eignung als Datenbasis für die zu entwickelnden Methoden analysiert. Die Analyse ergab, dass die enthaltenen Informationen bezüglich Patientenaufkommen, Krankheitsbild sowie der Struktur stationären Behandlungsverläufe für die zu entwickelnden Methoden ausreichend sind. Aufgrund dessen, sowie der nahezu aufwandslosen Verfügbarkeit dieser Datensätze, verwenden alle im weiteren Verlauf dieses Dissertationsvorhabens entwickelten Methoden größtenteils Informationen aus diesen Datensätzen.

Um praxisnahe Methoden zu entwickeln und anhand realer Daten evaluieren zu können, wurde im Rahmen dieses Dissertationsvorhabens eine enge Zusammenarbeit mit dem Universitätsklinikum Halle (Saale) initiiert. Die Ergebnisse dieser Zusammenarbeit sind die Publikation (Helbig et al. 2014) und (Helbig et al. 2015b). Diese bilden den Kern des Simulationsmoduls des konzipierten KH-EUS. Konkret wurden in (Helbig et al. 2014) Szenarien zur Reduzierung der Wartezeiten in der zentralen Notaufnahme mit Hilfe eines

ereignisdiskreten Simulationsmodells evaluiert. Im Ergebnis konnte festgestellt werden, dass der flexible Einsatz von Krankenhausbetten verglichen mit den anderen untersuchten Szenarien, wie der im Allgemeinen geforderten Verkürzung der Verweildauer, das größte Potential für Effizienzsteigerungen besitzt.

Aufbauend auf dieser Erkenntnis entstand im Universitätsklinikum die Idee, die aktuell diskutierten stationsübergreifenden Belegungscluster zur flexiblen Nutzung vorhandener Bettenkapazitäten mit einem ähnlichen Modell zu evaluieren. Die Evaluation der Zuordnung der 47 Stationen des Klinikums zu sieben bis acht Clustern ist Gegenstand der Publikation (Helbig et al. 2015b). Neben der fachlichen Evaluation der Szenarien wurde ein generischer Ansatz entwickelt, welcher automatisch ein krankenhausweites Simulationsmodell zur Evaluation von Belegungsclustern für jedes deutsche Krankenhaus erstellen kann. Dabei werden erneut Daten verwendet, die prinzipiell im § 21 KHEntgG Datensatz enthalten sind. Neben der genannten Publikation wurden die Ergebnisse sowie der entwickelte Ansatz auf der Konferenz für Applied Mathematical Programming and Modelling (APMOD) 2014 vorgestellt und diskutiert. Mit der Möglichkeit, automatisch individuelle krankenhausweite Simulationsmodelle erstellen zu können, ist das Simulationsmodul für dieses Dissertationsvorhaben fertiggestellt.

Ein weiteres zentrales Konzept ist die Verwendung von klinischen Pfaden als strukturelle Modellierung von Behandlungsprozessen. Aktuell werden aufgrund des sehr komplexen manuellen Erstellungsprozesses nur wenige klinische Pfade im Krankenhausalltag eingesetzt. Aufgrund starker Interdependenzen klinischer Prozesse ist für eine sinnvolle Planung für jedes stationär behandelte Krankheitsbild eine zu planende Struktur notwendig. Aus diesem Grund wurde in (Helbig et al. 2015a) ein neuer Prozess-Mining-Ansatz zum automatischen Gewinnen planbarer tagesgenauer klinischer Pfade entwickelt. Mit Hilfe des entwickelten Ansatzes konnten für alle auf der Urologie des Universitätsklinikums behandelten elektiven Fälle klinische Pfade gewonnen werden. Die erfolgreiche Evaluation erfolgte stichprobenartig durch Experteninterviews mit der zuständigen Fallmanagerin. Durch den neuen Prozess-Mining-Ansatz und die zur Analyse der Daten verwendeten Methoden ist das Daten- und Prozess-Mining-Modul für dieses Dissertationsvorhaben umgesetzt.

Basierend auf den gewonnen realitätsnahen klinischen Pfaden wurde ein hierarchischer Ansatz zur tagesgenauen operativ (offline) Planung elektiver Patienten entwickelt. Dieser Ansatz basiert auf zwei ILP-Modellen und ist in der Lage, alle Patienten einer Station in einem Planungshorizont von einem Monat exakt zu planen. Getestet und evaluiert wurde der Ansatz mit Hilfe zuvor erhobener Realdaten zu Behandlungsdauern und verfügbarem Ressourcenprofil der urologischen Station. Die dazugehörige Publikation wurde 2016 bei der Zeitschrift *BUSINES RESEARCH* eingereicht, begutachtet und befindet sich derzeit in Revision (Helbig et al. 2016). Perspektivisch können die tagesgenauen Behandlungspläne z. B. tageweise, nach Patientengruppen oder nach Hauptdiagnosen differenzierte Planungsprobleme dekomponiert und anschließend mit dem stundengenauen Planungsansatz aus Helbig (2011) terminiert werden. Damit ist die Entwicklung des Optimierungsmoduls für das Dissertationsvorhaben abgeschlossen.

Abb. 9 zeigt die Zuordnung der einzelnen Publikationen zu den Problemstellungen und den verwendeten Lösungsmethoden.

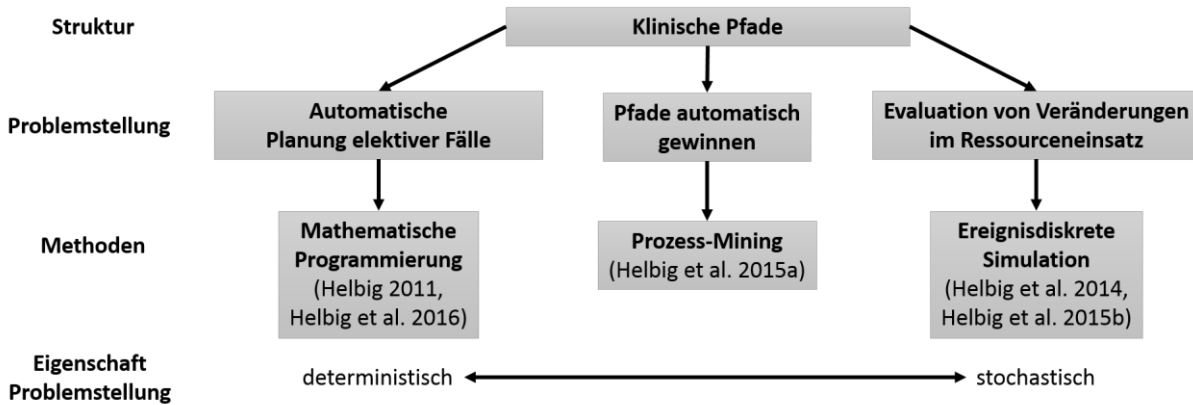


Abb. 9: Zuordnung der Publikationen zu Problemstellungen und verwendeten Lösungsmethoden (eigene Darstellung)

### 4.2. Zeitplanung für Patientenpfade unter Berücksichtigung von Betten-, Behandlungskapazitäten und Fairnesskriterien

Ziel dieser Publikation ist es, die Forschungslücke zum Einsatz klinischer Pfade zur Planung elektiver Patienten mit Hilfe mathematischer Programmierung zu schließen (siehe Kapitel 2 bzw. Anhang A). Konkret wird ein gemischt ganzzahliges lineares Modell vorgestellt und die Frage beantwortet, ob die Praxistauglichkeit linearer Programmierung in Hinblick auf die Lösungszeit bei realistischen Probleminstanzen gegeben ist.

Abb. 10 veranschaulicht beispielhaft die dem Modell zugrundeliegende Struktur eines klinischen Pfades. Deutlich wird die konzeptionelle Trennung von Betten- und Behandlungsebene. Die sog. Schritte entsprechen den eigentlichen klinischen Behandlungen und haben eine deterministische Dauer in Stunden. Alle Schritte sind einer Schrittgruppe zugeordnet. Zwischen diesen Gruppen existieren Reihenfolgenbeziehungen, welche mit Mindest- und Maximalabständen beschrieben werden können. Innerhalb der Gruppen kann die Reihenfolge der Schritte variieren. Weiterhin erfolgt über die Schrittgruppen die Zuordnung zu den einzelnen Stationsaufenthalten. Die Dauer dieser Aufenthalte kann zwischen gegebenen Mindest- und Maximalwerten variieren. Die Reihenfolge der Stationsaufenthalte ist im Pfad fest vorgegeben.

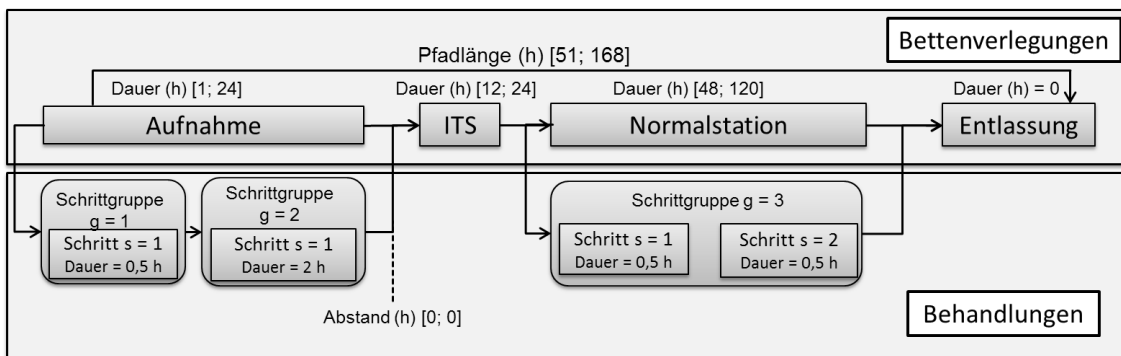


Abb. 10: Struktur eines klinischen Pfades (eigene Darstellung)

In Anlehnung an Schlüchtermann (1990, S. 170) werden im entwickelten Modell die Start- und Endzeitpunkte von Stationsaufenthalten und Behandlungsschritten als kontinuierliche Variablen modelliert. Damit wird im Ergebnis eine stundengenaue Aussage über die durchzuführenden Verlegungen und Behandlungen erzielt.

Zusammengefasst enthält das Modell zehn Gruppen von Nebenbedingungen für die Ebene der Bettenverlegung, die sicherstellen, dass pro Stationsaufenthalt genau ein Bett ausgewählt wird, zeitliche Mindest- und Maximaldauern nicht verletzt werden, dass die Geschlechtertrennung auf Normalstationen eingehalten wird und dass Verlegungen verschiedener Patienten überschneidungsfrei sind. Zur Modellierung der Behandlungsebene werden 19 Gruppen von Nebenbedingungen verwendet. Diese stellen u. a. sicher, dass für Behandlungen genau eine zulässige Ressource ausgewählt wird und die Behandlungen nur innerhalb der Öffnungszeiten dieser Ressource beginnen können. Ferner wird gefordert, dass unter Beachtung der Ressourcenkapazität die definierte Dauer des Schrittes eingehalten wird sowie eine Überschneidungsfreiheit von Behandlungen verschiedener Patienten gewährleistet ist. Weiterhin sind Nebenbedingungen formuliert, welche die vom Pfad vorgegebene Reihenfolge erzwingen und aus den möglichen Reihenfolgen von Schritten innerhalb einer Gruppe genau eine auswählen. In vier Gruppen von Nebenbedingungen wird sichergestellt, dass eine Schrittgruppe nur innerhalb des durch den Pfad definierten Stationsaufenthalts stattfinden darf. In der Zielfunktion wird die Minimierung der maximalen Verweildauer aller Patienten angestrebt. Da die Minimierung der Gesamtsumme oder der durchschnittlichen Verweildauer zu einer unfairen Verteilung von Wartezeit unter den Patienten führen kann, wird eine min-max-Zielfunktion (Suhl und Mellouli 2009, S. 104f) verwendet.

Das Modell wurde in AMPL implementiert und unter Verwendung von CLPEX 12.1 auf einem Intel Core 2 Duo CPU mit 2.39 GHz und 3 GB RAM getestet. Für die Experimente wurde der in Abb. 10 dargestellte Pfad als Struktur verwendet. Jede Behandlung besitzt vier mögliche Ressourcen. Die Normalstationen besitzen 23 mögliche Betten, die Intensivstation 2. Die erfolgreiche Validierung unter Verwendung kleiner Modelleinstanzen mit 2 – 4 Patienten bei einem Planungshorizont von 14 Tagen zeigt, dass das Modell die strukturellen Bedingungen des klinischen Pfades einhalten konnte. Aufgrund der Vielzahl binärer Variablen zur Sicherstellung von Überschneidungsfreiheit sowie zur Auswahl genau einer möglichen Behandlungsreihenfolge ist eine akzeptable Lösungszeit bei realistischen Modellinstanzen nicht gegeben.

In Hinblick auf das in Kapitel 3.2 konzipierte KH-EUS ist diese Publikation dem Optimierungsmodul zugeordnet. Die gewonnen Erkenntnisse zur Abbildung von Pfadstrukturen mit Hilfe eines linearen Modells sowie die Tatsache, dass ein stundengenaues Modellierungsansatz lediglich für kleine Instanzen exakt in akzeptabler Zeit gelöst werden kann, führen zur Entwicklung eines hierarchischen Optimierungsansatzes (siehe Kapitel 4.6 bzw. Anhang E). Von einem heuristischen Lösungsverfahren wird abgesehen, da die grundlegende Änderung der zeitlichen Modellierung von Stunden auf Tage und die damit stark reduzierte Dimension an binären Hilfsvariablen zur Gewährleistung der Überschneidungsfreiheit einzelner Behandlungen großes Potential zum Finden einer exakten Lösung in angemessener Zeit verspricht.

### **4.3. Simulation stationsübergreifender Patientenflüsse zur Evaluation flexibler Bettenbelegungsszenarien aufgrund der Jahresdatenanalyse eines Universitätsklinikums**

Die vorliegende Publikation zielt darauf ab, die fachliche Fragestellung zu beantworten, ob durch verschiedene Formen eines flexiblen Einsatzes von Krankenhausbetten die Wartezeiten in der ZNA reduziert werden können. Zusätzlich wird das Ziel verfolgt, den genannten Anforderungen an moderne Simulationsstudien (siehe Kapitel 2) gerecht zu werden. Dazu wird ein krankenhausweites Simulationsmodell entworfen, welches durch den Einsatz von Routinedaten einfach auf ähnliche Fragestellungen in anderen Krankenhäusern überführt werden kann und darüber hinaus die realitätsnahe Nebenbedingung einer nach Geschlechtern getrennten Zimmerbelegung beachtet. Dabei wird davon ausgegangen, dass die Ergebnisse dieser Studie allgemeingültig für ähnlich strukturierte Krankenhäuser sind. Die Praxisrelevanz ist durch die Kooperation mit dem UKH in einer derzeit relevanten Fragestellung gegeben.

Mit Hilfe der ereignisdiskreten Simulationssoftware ARENA wurde ein Modell erstellt, welches den Fluss von Notfall- und Elektivpatienten krankenhausweit abbildet. Für die Sicherstellung der Geschlechtertrennung wurde eine eigene Heuristik entwickelt, die bei Veränderungen in der Belegungssituation einer Station die maximal mögliche Anzahl an Patienten auf die jeweiligen Zimmer verteilt. Als Eingabedaten wurde ein Datensatz des Jahres 2011 mit der gesamten Aufnahme- und Verlegungshistorie aller Patienten verwendet.

Unter Verwendung dieser Daten konnte ein Modell erstellt werden, welches das Aufkommen der drei Patientenarten: elektiver stationärer Patient, ambulanter Notfall und stationärer Notfall im Verlauf einer repräsentativen Woche abbilden kann. Das Modell konnte erfolgreich durch Vergleich der für 1 Jahr simulierten Patientenzahlen, stationären Verweildauern sowie der Ankunftsverteilung stationärer Notfallpatienten mit den Ist-Daten validiert werden.

Nach erfolgreicher Validierung wurden gemeinsam mit dem UKH die folgenden drei Szenarien zur Flexibilisierung der Belegung entwickelt und anhand der Ergebnisse des validen Ist-Modells evaluiert:

- [S1] Flexible Belegung durch Zimmerverleih an räumlich angrenzende Stationen,
- [S2] Flexible Belegung durch Zusammenführung der ITS- und IMC-Stationen und
- [S3] Flexible Belegung durch Einführen einer Früh-Reha als Endphase stationärer Behandlung

Für [S1] konnte gezeigt werden, dass die Wartezeit auf eine Verlegung von der ZNA auf entsprechende Station um bis zu 50 % verringert werden konnte. Ebenfalls um bis zu 10 Stunden konnte die Wartezeit auf eine krankenhausinterne Verlegung verkürzt werden.

Durch ein Zusammenführen der Intensiv- und Intermediate Care Stationen (ITS- und IMC) [S2] konnte die Wartezeit des Ist-Modells von bis zu 20,7 Stunden und ca. 1.170 wartenden Patienten jährlich nahezu vollständig auf null reduziert werden.

Für [S3] konnte gezeigt werden, dass sich die für die Früh-Reha infrage kommenden Patientengruppen selten auf Stationen mit einem Engpass an Betten befinden. Aus diesem Grund konnte nur eine geringfügige Reduzierung der Wartezeiten beobachtet werden. Ob der



betroffene Patientenkreis erweitert werden kann, bedarf einer genaueren pflegerisch-therapeutischen Analyse.

Zusammenfassend konnte festgestellt werden, dass die vorgeschlagenen organisatorischen Maßnahmen zur Flexibilisierung des Einsatzes von Krankenhausbetten eine krankenhaushausweite Reduzierung der Wartezeiten auf Verlegungen und Aufnahmen verspricht. Diese allgemeingültige Erkenntnis konnte dem Vorstand des Klinikums überzeugend präsentiert werden. Dieser regte an, das Szenario des flexiblen Zimmerverleihs auf die aktuelle im UKH stattfindende Diskussion der Einführung bereichsübergreifender Belegungscluster anzuwenden.

In Hinblick auf das in Kapitel 3.2 vorgestellte Konzept eines KH-EUS stellt das entwickelte Modell ein Werkzeug für das Simulationsmodul dar. Dieses ist in der Lage, den gesamten krankenhaushausinternen Verlegungsablauf valide in einem Modell unter Verwendung von Routinedaten abzubilden. Darüber hinaus konnte die Grundidee des flexiblen Einsatzes Krankenhausbetten als kostengünstige Möglichkeit zur Effizienzsteigerung evaluiert werden.

#### 4.4. A Generic Simulation-based DSS for Evaluating Flexible Ward Clusters in Hospital Occupancy Management

Mit Blick auf den skizzierten Forschungsstand zum Einsatz von ereignisdiskreter Simulation im Krankenhauskontext (siehe Kapitel 2 bzw. Anhang C) und den Ergebnissen von Helbig et al. (2014) werden mit dieser Publikation die folgenden Forschungslücken adressiert: (1) Es wird ein integriertes krankenhaushausweites ereignisdiskretes Simulationsmodell zur Evaluation der Auswirkungen drei verschiedener Clusterszenarien auf den gesamten Patientenfluss modelliert. Um möglichst realitätsnahe Ergebnisse zu erzielen, werden weiterhin praxisrelevante Nebenbedingungen wie Geschlechtertrennung und Isolation bei ansteckenden Krankheiten berücksichtigt. (2) Zur einfachen Wiederverwendbarkeit bei ähnlichen Fragestellungen wird ein Entscheidungsunterstützungssystem entwickelt, welches unter Verwendung von Routine- und Ressourcendaten automatisch das Simulationsmodell für das jeweilige Krankenhaus erstellen kann.

In Abb. 11 ist die Architektur des entwickelten Entscheidungsunterstützungssystems abgebildet.

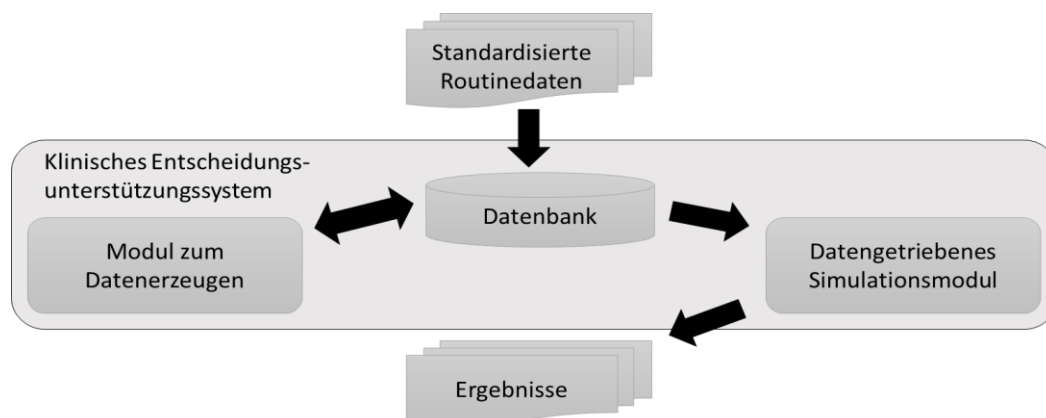


Abb. 11: Architektur des Entscheidungsunterstützungssystems (eigene Darstellung)

Standardisierte Routinedaten der Behandlungsfälle wie z. B. Geschlecht, Aufnahme- und Entlassungszeit, Chronologie der besuchten Stationen, Verweildauer und Infektionsstatus werden zusammen mit Infrastrukturdaten über die Bettenverteilung auf die Räume der einzelnen Stationen in eine MySQL-Datenbank aufgenommen. Dabei sind die Daten der Behandlungsfälle prinzipiell in den nach § 21 KHEntgG jährlich zu erhebenden Datensätzen enthalten. Die Infrastrukturdaten müssen gesondert erhoben werden. Aus der vollständigen Datenbank werden anschließend über Python-Skripte die benötigten Wahrscheinlichkeitsverteilungen für Ankunftszeiten, Art des Patienten sowie innerklinische Verlegungen berechnet und in die Datenbank integriert. Darauf aufbauend, wird automatisch ein auf den vorhandenen Daten basierendes Simulationsmodell in der Software Simio erstellt. Dabei ist das Modell so konzipiert, dass beliebige Clusterszenarien durch manuelle Parametrisierungen evaluiert werden können. Als Kennzahl für die Güte eines Szenarios wird die Anzahl der Bettenengpässe pro Jahr verwendet. Diese Zahl gibt an, wie oft eine Aufnahme bzw. eine Verlegung stattgefunden hat, ohne dass ein verfügbares Bett auf der jeweiligen Station zur Verfügung stand.

Nach erfolgreicher Validierung des Modells wurden drei vom UKH vorgegebene Clusterkonfigurationen anhand der folgenden drei Szenarien mit einer simulierten Dauer von einem Jahr evaluiert:

[S1] Vergleich mit dem Status quo

[S2] Erhöhen der durchschnittlichen Bettenauslastung auf 85 % durch Entfernen von Betten

[S3] Erhöhen der Anzahl elektiver Patienten um 50 %

Verglichen mit dem Status quo in [S1] konnten alle Clusterkonfigurationen die Anzahl der Engpässe über das Jahr um bis zu 96 % verringern. Basierend auf den Ergebnissen von [S1] wurden für [S2] ca. 30 % aller Betten entfernt um die gewünschte durchschnittliche Auslastung von 85 % zu erreichen. Auch nach dem Entfernen von 385 Betten liegt die Anzahl der gezählten Engpässe bei allen Clusterkonfigurationen auf einem Niveau von 65 % - 77 % gegenüber dem Status quo. Für [S3] wurden Niveaus von 35 % - 50 % gegenüber dem Status quo erreicht. Abschließend konnte festgestellt werden, dass die Bildung von Clustern in jedem Fall sinnvoll ist. Konkret wurden für das UKH für die Clusterkonfiguration mit einem großen interdisziplinären Chirurgie-Cluster die geringsten Engpässe beobachtet. Neben der Evaluation der Clusterkonfigurationen konnte in einem Experiment gezeigt werden, dass die Vernachlässigung praktischer Nebenbedingungen wie Geschlechtertrennung oder Isolation zu einer deutlichen Verringerung der Engpässe um bis zu 50 % und damit zu einer großen Verzerrung der gewonnenen Ergebnisse führt.

In Hinblick auf das in Kapitel 3.2 konzipierte KH-EUS ist im Rahmen dieser Publikation ein weiteres Werkzeug für das Simulationsmodul entstanden, welches anhand von Routine- und Ressourcendaten automatisch ein individuelles Simulationsmodell erstellen kann. Damit ist dieses Werkzeug prinzipiell für jedes deutsche Krankenhaus universell einsetzbar. Weiterhin konnte gezeigt werden, dass ressourceneinschränkende Nebenbedingungen wie Geschlechtertrennung oder Isolation bei der Ressourceneinsatzplanung nicht vernachlässigt werden dürfen.

### 4.5 A Clinical Pathway Mining Approach to Enable Scheduling of Hospital Relocations and Treatment Services

Ziel dieser Publikation ist es, basierend auf der beschriebenen Problemstellung und dem aktuellen Forschungsstand (siehe Kapitel 2 bzw. Anhang D), einen Prozess-Mining-Ansatz zu entwickeln, welcher automatisch homogene Fallgruppen identifizieren und daraus plausible, für tagesgenaue Planung geeignete klinische Pfade gewinnen kann. Zur problemlosen Wiederverwendbarkeit in allen deutschen Krankenhäusern werden dafür ausschließlich Routinedaten elektiver stationär behandelter Patienten gemäß § 21 KHentgG verwendet.

Abb. 12 zeigt das im Rahmen dieser Publikation entwickelte Konzept planungsorientierter klinischer Pfade. Im abgebildeten Konzept besteht ein Pfad aus Struktur und Nebenbedingungen. Die Struktur gibt die Reihenfolge der zu durchlaufenden Stationen, Alternativstationen sowie die durchzuführenden Behandlungen an. Darüber hinaus werden über die Struktur relativ zum Aufnahmetag zulässige Intervalle für Aufnahmen ( $a_w^i$ ), Entlassungen ( $d_w^i$ ) und Behandlungen ( $t_k$ ) tagesgenau abgebildet. Behandlungen, die zwingend am selben Tag stattfinden müssen, können über eine sog. Gruppierung definiert werden. Die Nebenbedingungen begrenzen die Verweildauern auf den einzelnen Stationen, legen die Reihenfolgen der einzelnen Schritte sowie die Grenzen für die Häufigkeit einer Behandlung fest.

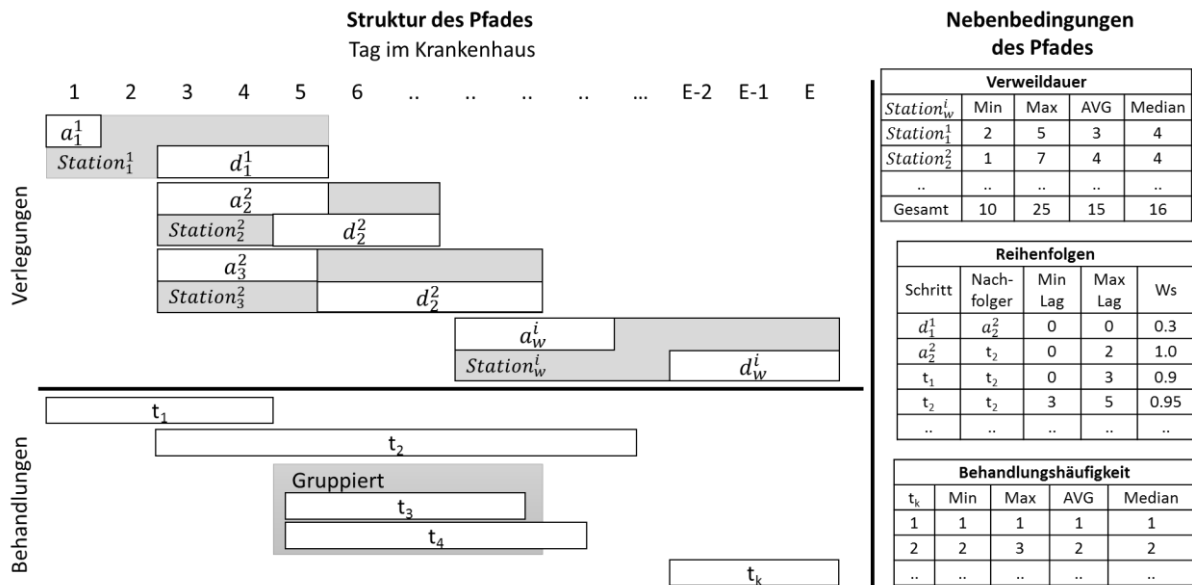


Abb. 12: Konzept planungsorientierter klinischer Pfade (eigene Darstellung)

Der im Rahmen dieser Publikation entwickelte Ansatz besteht aus zwei Phasen. In der ersten Phase werden alle elektiven Behandlungsfälle homogenen Behandlungsgruppen zugeordnet. In einer Gruppe sind alle Fälle mit derselber Hauptdiagnose, derselben aufnehmenden Station und dem gleichen Behandlungsprofil (gleiche Menge verschiedener Behandlungen, unabhängig von Anzahl und zeitlichem Auftreten) enthalten. In der zweiten Phase wird durch Analyse jeder homogenen Gruppe Struktur und Nebenbedingungen des Pfades bestimmt.

Die Datengrundlage des entwickelten Ansatzes bildet Routinedatensatz nach §21 KHentgG des UKH von 2011, welcher in eine MS-Access Datenbank importiert wurde. Der entwickelte

Prozess-Mining-Algorithmus ist in Virtual Basic implementiert. Zur Evaluation des Ansatzes wurden aus den ca. 40.000 im Jahr 2011 stationär behandelten Fällen verschiedene Hauptdiagnosen getestet.

In dieser Publikation wird mit 504 Fällen eine der häufigsten Hauptdiagnose C61 (Bösartige Neubildung der Prostata) untersucht. Zum Bestimmen der homogenen Fallgruppen wurden aus allen C61-Fällen 492 Fälle mit identischer Aufnahmestation ausgewählt. Zur einfachen Bestimmung identischer Behandlungsprofile wurde der hierarchische Clustering-Ansatz nach Ward mit dem Jaccard-Koeffizienten zur Bestimmung der Distanzmatrix verwendet. Um nur identische Behandlungsprofile zu gruppieren, wurden ausschließlich die Cluster auf Ebene Null verwendet. Auf dieser Ebene findet noch keine Cluster-Zusammenfassung statt und in den einzelnen Clustern sind ausschließlich identische Fälle enthalten. Insgesamt gab es drei große Cluster mit 87, 75 und 50 Fällen, vier mittelgroße mit 11 bis 27 Fälle sowie 131 Cluster mit jeweils einem Fall. Diskutiert werden Struktur und Nebenbedingungen des Ergebnispfades eines 13 Fälle enthaltenden Clusters. So konnte u. a. erkannt werden, dass die Operation am zweiten bis dritten Tag stattfindet, die Verweildauer zwischen acht und 19 Tagen schwankt und das am Tag der Operation Maßnahmen für den Blutkreislauf durchgeführt werden müssen. Durch die Planung dieses Pfades könnte u. a. sichergestellt werden, dass ein Patient nur aufgenommen wird, falls die Operation am zweiten Tag stattfinden kann. Nach Analyse der Daten würde dadurch die Verweildauer auf 11 Tage sinken. In einer Diskussion mit der verantwortlichen Fallmanagerin des UKH konnten sowohl der gewonnene Pfad als auch die identifizierten Verbesserungspotentiale erfolgreich validiert werden.

In Hinblick auf das in Kapitel 3.2 vorgestellte Konzept eines KH-EUS stellt der im Rahmen dieser Publikation entwickelte Ansatz ein wichtiges Werkzeug für das Daten- und Prozess-Mining-Modul dar. Erstmals existiert eine Methode zur automatischen Bestimmung plausibler klinischer Pfade für eine tageweise Planung. Damit sind die notwendigen behandlungsbeschreibenden Strukturen zur Entwicklung und Evaluation eines geeigneten exakten Planungsmodells für stationäre Behandlungen gegeben.

#### **4.6. A Data-Driven Hierarchical ILP Approach for Scheduling Clinical Pathways: A Real-World Study from a German University Hospital**

Aufbauend auf der Analyse des aktuellen Forschungsstandes (siehe Kapitel 2 bzw. Anhang E) wird in dieser Publikation ein auf ILP basierender Ansatz zur operativen Planung klinischer Pfade vorgestellt. Konkret werden dabei die folgenden Ziele verfolgt:

- (1) Das entwickelnde multikriterielle ILP-Modell soll flexibel mit verschiedenen Zielstellungen wie Gleichverteilung der Arbeitslast, Verkürzung der Verweildauern oder einer hohen Ressourcenauslastung zu Beginn des Planungshorizontes umgehen können.
- (2) Die entwickelte Methode soll auf standardisierten Routinedaten basieren und somit in allen Krankenhäusern Deutschlands einfach wiederverwendet werden können.
- (3) Durch das Beachten praxisrelevanter Nebenbedingungen wie z. B. Geschlechtertrennung und detaillierte Ressourcenallokation für knappe Ressourcen sollen die Ergebnisse einfach in die Realität übertragbar sein.
- (4) Trotz des detaillierten ILP-Modells soll die Methode auch für große Krankenhausstationen anwendbar sein.

Das im Rahmen dieser Publikation entwickelte hierarchische Modell dient zur tagesgenauen Planung klinischer Pfade. Dabei zielt die Hierarchisierung auf eine Lösbarkeit in angemessener Zeit auch für größere Instanzen ab. Dazu werden in einem ersten groben Modell die Aufnahme aller zu planender Patienten sowie komplexe Behandlungen geplant. Basierend auf diesen Ergebnissen werden in einem zweiten detaillierten Modell allen Patienten konkrete Räume zugeordnet sowie alle noch verbleibenden Behandlungen geplant. Um im zweiten Modell eine im Hinblick auf die Geschlechtertrennung zulässige Lösung zu gewährleisten, wird diese Nebenbedingung bereits im ersten Modell antizipiert. Da im ersten Modell lediglich komplexe Behandlungen planungsrelevant sind, besteht zusätzlich die Gefahr, dass im zweiten Modell im Hinblick auf Reihenfolgebeziehungen und Ressourcenkapazitäten keine zulässige Lösung existiert. Dies kommt dann vor, wenn eine komplexe Behandlung gegen Ende des Planungshorizontes terminiert wird und aufgrund von Reihenfolgebeziehungen weitere, im zweiten Modell enthaltene Behandlungen nach dem Ende des Planungshorizontes stattfinden müssten. Um dieser Gefahr vorzubeugen, werden im ersten Modell die Reihenfolgebeziehungen zwischen allen Behandlungen antizipiert. Eine zusätzliche Antizipation der Ressourcenkapazitäten erfolgt nicht, da davon ausgegangen wird, dass für die im zweiten Modell zu planenden einfachen Behandlungen notfalls durch Überstunden abgedeckt werden können. Durch die multikriterielle Modellierung, welche in beiden Modellen prinzipiell gleich ist, ist die Zielfunktion durch Veränderung von Gewichtungsfaktoren flexibel an verschiedene Zielstellungen anpassbar. Die Bestandteile der Zielfunktion sind in patientenbezogen (Wartezeit für alle Patienten, patientenindividuelle Wartezeit, Über- und Unterschreitung des Wunschaufnahmetag) und ressourcenbezogen (Überstunden und freie Kapazitäten der Ressourcen sowie zusätzliche Betten) eingeteilt.

Zur Evaluation des vorgestellten Ansatzes wurden mit Hilfe des von Helbig et al. (2015a) beschriebenen Verfahrens aus einem gemäß §21 KHEntgG standardisierten Routinedatensatz des UKH von 2011 alle zu planenden klinische Pfade gewonnen. Um Erkenntnisse über das Lösungsverhalten großer Instanzen gewinnen zu können, wurde mit der Urologie die Station mit der größten Fallzahl sowie der März als fallstärkster Monat verwendet. Insgesamt wurden

288 Fälle mit 90 verschiedenen Hauptdiagnosen und 69 verschiedenen DRGs für 31 Tage geplant. Die fehlenden Daten zum verfügbaren Ressourcenprofil sowie die Dauer der einzelnen Behandlungen wurden im Dialog mit der Fallmanagerin der Urologie ermittelt. Evaluiert wurden die Zielstellungen: (1) Gleichmäßige Verteilung der Arbeitslast unter Berücksichtigung des Wunschaufnahmetages und (2) Hohe Auslastung der verfügbaren Ressourcen zu Beginn des Planungshorizonts, ohne Berücksichtigung der Wunschaufnahmetage. Das Modell wurde in AMPL implementiert und auf einer i7-3770 CPU mit 3,4 GHz, 8 GB Ram und unter Nutzung von vier parallelen Kernen sowie 8 Threads gelöst. Geplant wurden alle 286 stationären elektiven Fälle (217 Männer und 69 Frauen) mit 1088 Behandlungen und 302 Stationsaufenthalten.

Nach Evaluation des Ansatzes durch den Vergleich eines integrierten mit dem vorgestellten hierarchischen Ansatz, durch Analyse der Auswirkungen einer Vernachlässigung von Geschlechtertrennung während der Planung auf die Überführung der Ergebnisse in die Realität sowie die Wirksamkeit der Geschlechterantizipation im ersten Modell zeigen die Ergebnisse die erfolgreiche Anwendung des entwickelten Ansatzes auf beide Zielstellungen. Für die Zielstellung (1) Gleichmäßige Verteilung der Arbeitslast unter Berücksichtigung der Wunschaufnahmetage konnte die angestrebte Glättung aller Ressourcenverbräuche erreicht werden. Der Wunschaufnahmetag wurde in 231 Fällen exakt eingehalten und schwankt zwischen -8 und +20 Tagen. Für die genannte Zielstellung und einen Planungszeitraum von 31 Tagen betrug die mögliche Abweichung +/- 30 Tage. Für diese maximal mögliche Abweichung wurde nach 51 Minuten das erste Modell mit einem MIP-Gap von 1 % gelöst. Das zweite Modell wurde in jedem Fall in wenigen Sekunden optimal gelöst.

Eine hohe Auslastung der verfügbaren Ressourcen zu Beginn des Planungshorizonts, ohne Berücksichtigung der Wunschaufnahmetage konnte im Rahmen der Zielsetzung (2) erreicht werden. Evaluiert wurden Modellinstanzen bis zu einer maximalen Abweichung zum Aufnahmetag von bis zu 30 Tagen. Alle Modelle waren in weniger als 75 Minuten lösbar. Auch hier zeigen die Ergebnisse den gewünschten Effekt einer Verschiebung der Ressourcenauslastung an den Beginn des Planungsintervalls. Das Ignorieren der Abweichung zum Wunschaufnahmetag in der Zielfunktion resultiert in einer breiten Streuung der Aufnahmetage von bis zu 28 Tagen früher bzw. später als erwünscht. Bedingt durch die Zielstellung werden 65 % (186 Patienten) eher aufgenommen. Zusammenfassend konnten die eingangs genannten vier Zielstellungen: Abbildbarkeit verschiedener Zielstellungen, einfache Wiederverwendbarkeit, Beachtung praxisrelevanter Nebenbedingungen und Lösbarkeit auch für große Instanzen, erreicht werden.

In Hinblick auf das in Kapitel 3.2 vorgestellte Konzept eines KH-EUS ist mit dem entwickelten hierarchischen Ansatz ein neues Werkzeug zur operativen (offline) Planung elektiver Patienten im Rahmen des Optimierungsmoduls entstanden. Durch Parametrisierung sowie die Verwendung von Routine- und mit überschaubarem Aufwand beschaffbarer Daten wird dem Anspruch der generischen Einsetzbarkeit des Systems entsprochen.

## 5. Schlussbetrachtung

Krankenhäuser in Deutschland sind einem hohen Kosten- und Effizienzdruck ausgesetzt. Aktuell sind ca. 30 % aller deutschen Krankenhäuser defizitär (Augurzky 2015). Diese Situation wird zusätzlich durch den demographischen Wandel und die damit zu erwartenden um 15 % steigenden Fallzahlen verschärft (Augurzky 2013, S. 34). Eine Steigerung der Effizienz deutscher Krankenhäuser wird somit dringend benötigt (Augurzky 2015). Herausfordernd ist die äußerst komplexe Natur krankenhauser Prozesse und krankenhauser Organisationsformen. Beide sind vielschichtig und eng miteinander verzahnt. Damit ist eine praktikable Entscheidungsunterstützung für Ressourcenkapazitätsplanungsprobleme nur durch eine Evaluation im krankenhauser Kontext möglich.

Zielstellung der Arbeit ist die Konzeption und Umsetzung eines generischen KH-EUS zur Ressourcenkapazitätsplanung basierend auf dynamisch erstellten klinischen Pfaden. Die Komponenten des KH-EUS unterstützen krankenhauser Entscheidungen auf strategischer, taktischer und operativer Ebene. Die klinischen Pfade dienen dabei zur strukturellen und adäquaten Beschreibung stationärer sowie teilstationärer Behandlungsabläufe. Die Routinedaten, welche im Rahmen des § 21 KHEntgG jährlich von jedem Krankenhaus erfasst werden müssen, ermöglichen eine generische Einsatzbarkeit des KH-EUS für alle deutschen Krankenhäuser. Das KH-EUS besteht aus den drei Modulen: Daten- und Prozess-Mining, Optimierung und Simulation. Die im Rahmen dieser Dissertation entstandene Publikation enthält die einzelnen Module konzeptionell zugeordnete, implementierte und anhand praxisnaher Fallbeispiele evaluierter Werkzeuge. Für diese Werkzeuge wurden die Methoden Prozess-Mining, mathematische Programmierung sowie ereignisdiskrete Simulation verwendet.

In der ersten wissenschaftlichen Publikation (Helbig 2011) wird für das Optimierungsmodul ein gemischt-ganzzahliges Optimierungsmodell für operative Planungsaufgaben thematisiert. Ziel ist die stundengenaue Planung elektiver Patienten unter Verwendung von klinischen Pfaden als strukturelle Planungsgrundlage. Das entwickelte Modell wird anhand eines beispielhaften klinischen Pfades evaluiert. Die Ergebnisse zeigen, dass mit Hilfe des vorgestellten Lösungsansatzes die gegebene Struktur sowie praxisrelevante Nebenbedingungen wie Geschlechtertrennung auf Zimmern erfolgreich modelliert werden können. Weiterhin zeigt die Evaluation des Ansatzes eine Lösbarkeit für kleine Instanzen in akzeptabler Zeit.

In der zweiten Publikation (Helbig et al. 2014) wird für das Simulationsmodul ein ereignisdiskretes Modell zur Analyse von strategischen und taktischen Maßnahmen zur Reduzierung der Wartezeit auf stationäre Aufnahme von Notfällen und krankenhauser Verlegungen entwickelt. Unter Verwendung von Daten, welche prinzipiell im Routinedatensatz nach § 21 KHEntgG vorhanden sind, konnte ein valides krankenhauser Simulationsmodell erstellt werden. Im Ergebnis konnte gezeigt werden, dass die durch organisatorische Maßnahmen zu erreichende Flexibilisierung des Einsatzes von Krankenhausbetten die Wartezeit auf freie ITS- und IMC-Betten vollständig auf null senkt und für Normalstationen um ca. 50 % reduziert.

Basierend auf den Erkenntnissen von (Helbig et al. 2014) wurde für das Simulationsmodul ein generischer Ansatz entwickelt, welcher automatisch ein valides Simulationsmodell zur

Evaluation interdisziplinärer Belegungscluster erstellen kann. Ziel des Ansatzes in (Helbig et al. 2015b) ist es, szenariobasiert die beste Clusterkonfiguration mit der höchsten Reduzierung auf Verlegung wartender Patienten zu finden. Die in einem Jahr Simulationszeit untersuchten Konfigurationen zeigten zum einen, dass bis zu 96 % der Verlegungsengpässe vermieden werden konnten. Zum anderen zeigte die Konfiguration mit einem großen interdisziplinären Chirurgie-Cluster die geringsten Engpässe an benötigten Betten.

Die vierte Publikation (Helbig et al. 2015) stellt eine Entwicklung für das Daten- und Prozess-Mining-Modul dar. Dabei wurde das Ziel verfolgt, eine Methode zur automatischen Erzeugung tagesgenauer klinischer Pfade für den Einsatz in Planungsmodellen zu entwickeln. Die entwickelte Methode konnte unter Verwendung eines Routinedatensatzes nach § 21 KHEntgG des Universitätsklinikum Halle aus dem Jahr 2011 erfolgreich evaluiert werden. Die Ergebnisse zeigen beispielhaft einen ermittelten Pfad für eine der häufigsten Hauptdiagnosen 2011: C61-Bösartige Neubildung der Prostata. Durch den generischen Charakter der Methode können erstmals klinische Pfade krankenhausintern und –übergreifend analysiert und verglichen werden. Diese neue Ebene der Transparenz ermöglicht den medizinischen und organisatorischen Akteuren im Krankenhaus u. a. ein einfacheres Identifizieren von Schwachstellen und Ineffizienzen stationärer Behandlungsverläufe.

In der fünften Publikation (Helbig et al. 2016) wird für das Optimierungsmodul ein Ansatz zur Planung stationärer elektiver Behandlungen entwickelt. Kern dieses Ansatzes sind zwei hierarchische ganzzahlige Optimierungsmodelle, welche mittels der Methode aus (Helbig et al. 2015a) gewonnene klinische Pfade tagesgenau planen. Dabei dient das erste Modell zur Planung der Aufnahme und komplexer Behandlungen. Im zweiten Modell werden unter Verwendung der Ergebnisse des ersten Modells alle noch ungeplanten Behandlungen terminiert und allen Patienten konkrete Stationszimmer zugewiesen. Die Evaluierung des Ansatzes erfolgt durch die Planung von 286 stationären elektiven urologischen Fällen, bestehend aus insgesamt 1088 Behandlungen und 302 Stationsaufenthalten. Durch den Vergleich der Ergebnisse mit den historischen Daten konnte der Ansatz erfolgreich evaluiert werden.

Mit den angeführten fünf Publikationen sind für jedes im KH-EUS-Konzept aufgeführte Modul Werkzeuge zur Unterstützung praxisnaher Ressourcenkapazitätsplanungsprobleme im Krankenhauskontext entstanden. Noch offene Komponenten für weitere Forschung sind Werkzeuge zur Personal- und Ressourcenplanung. Mit Entwicklung und Integration dieser Werkzeuge in die vorhandenen könnten iterativ optimale Personal- und Materialkapazitäten bestimmt werden. Ein weiterer offener Forschungspunkt ist die Verbindung des Optimierungs- und des Simulationsmoduls. Durch die Implementierung dieser konzipierten Verbindung können eine Evaluation der Planungsgüte sowie eine Gewinnung neuer Szenarien für krankenhausinterne Prozessverbesserungen erfolgen. Darüber hinaus könnten die derzeit bei der Planung verwendeten Puffer für Notfallbehandlungen basierend auf den Ergebnissen der Simulationsstudien zielgerichtet angepasst werden.

Mit den entwickelten Methoden auf den Gebieten der Simulation, lineare Programmierung und Prozess-Mining sowie der Einbettung dieser in ein integriertes KH-EUS Konzept wurden neue Werkzeuge zur Erreichung der dringend benötigten Effizienzsteigerung von Krankenhäusern geschaffen. Insbesondere der generische Charakter des KH-EUS ermöglicht krankenhausindividuelle Entscheidungsunterstützung auf strategischer, taktischer und operativer Ebene, ohne aufwendige Anpassungen der zugrundeliegenden Modelle. Weiterhin wird durch die zentrale Verwendung klinischer Pfade eine adäquate Abbildung von stationären



Behandlungsverläufen auf Mikroebene und somit eine praxistaugliche Entscheidungsunterstützung erreicht.

Neben den genannten noch offenen Entwicklungspunkten sind aus Sicht des Autors die größten Hürden allerdings weniger technischer Natur. IT-Innovationen in Krankenhäusern scheitern eher an Vertrauensproblemen sowie Ängsten vor Arbeits- und Machtverlust der Vielzahl von Nutzern und Entscheidungsträgern. Einen guten Weg zur Vertrauensbildung und zum Abbau der Ängste kann die Lösung einzelner überschaubarer Problemstellungen mit Hilfe von IT-Werkzeugen darstellen. Werden diese Werkzeuge, ähnlich wie in dieser Dissertation skizziert, von vornherein für ein integriertes System konzipiert, könnten diese Schritt für Schritt zusammengefügt werden, um letztendlich das Potential zur umfassenden IT-Unterstützung in Krankenhäusern zu heben.

## Literatur

- Aalst WMP van der: Process mining : discovery, conformance and enchancement of business processes. Springer, Heidelberg [etc.] 2011
- Augurzky B: Krankenhaus Rating Report 2013: Krankenhausversorgung zwischen Euro-Krise und Schuldenbremse. medhochzwei-Verl., Heidelberg 2013
- Augurzky B (Hrsg.) (2015): Bad Bank für Krankenhäuser: Krankenhausausstieg vor der Tür? ; [inklusive eBook]. Krankenhaus-Rating-Report : HCB, Institute for Health Care Business GmbH ; RWI
- Baboolal K, Griffiths JD, Knight VA, Nelson AV, Voake C, Williams JE (2012): How efficient can an emergency unit be? A perfect world model. *Emerg Med J*
- Barado J, Guergué JM, Esparza L, Azcárate C, Mallor F, Ochoa S (2012): A mathematical model for simulating daily bed occupancy in an intensive care unit\*: *Critical Care Medicine* 40, 1098–1104
- Black D, Pearson M (2002): Average length of stay, delayed discharge, and hospital congestion: A combination of medical and managerial skills is needed to solve the problem. *BMJ: British Medical Journal* 325, 610
- Braun T, Rau F, Tuschen KH (2007): Die DRG-Einführung aus gesundheitspolitischer Sicht. Eine Zwischenbilanz. *Krankenhaus-Report* 7, 3–22
- Carter M (2002): Diagnosis: mismanagement of resources. *OR MS TODAY* 29, 26–33
- Coffey RJ, Richards JS, Remmert CS, LeRoy SS, Schoville RR, Baldwin PJ (2005): An introduction to critical paths. *Quality Management in Healthcare* 14, 46–55
- Conforti D, Guerriero F, Guido R, Cerinic MM, Conforti ML (2011): An optimal decision making model for supporting week hospital management. *Health Care Management Science* 14, 74–88
- Costa AX, Ridley SA, Shahani AK, Harper PR, De Senna V, Nielsen MS (2003): Mathematical modelling and simulation for planning critical care capacity\*. *Anaesthesia* 58, 320–327

- Coughlan J, Eatock J, Patel N (2011): Simulating the use of re-prioritisation as a wait-reduction strategy in an emergency department. *Emerg Med J* 28, 1013–1018
- De Bleser L, Depreitere R, Waele KD, Vanhaecht K, Vlayen J, Sermeus W (2006): Defining pathways. *Journal of Nursing Management* 14, 553–563
- Drucker PF (2002): They're not employees, they're people. *Harvard Business Review* 80, 70–77
- Eckardt J, Sens B (2006): *Praxishandbuch Integrierte Behandlungspfade. Intersektorale und sektorale Prozesse professionell gestalten Heidelberg: Economica* 9–37
- Eldabi T, Paul RJ, Young T (2006): Simulation modelling in healthcare: reviewing legacies and investigating futures. *Journal of the Operational Research Society*
- Fries BE (1976): Bibliography of Operations Research in Health-Care Systems. *Operations Research* 24, 801–814
- Gartner D, Kolisch R (2013): Scheduling the hospital-wide flow of elective patients. *European Journal of Operational Research*
- Glouberman S, Mintzberg H (2001): Managing the care of health and the cure of disease—Part I: Differentiation. *Health care management review* 26, 56–69
- Greiling M, Mormann J, Westerfeld R: *Klinische Pfade steuern*. Baumann, Kulmbach 2003
- Günal MM (2012): A guide for building hospital simulation models. *Health Systems* 1, 17–25
- Günal MM, Pidd M (2010): Discrete event simulation for performance modelling in health care: a review of the literature. *Journal of Simulation* 4, 42–51
- Hans EW, van Houdenhoven M, Hulshof PJH: A Framework for Healthcare Planning and Control; in: *Handbook of Healthcare System Scheduling*, Band 168; hrsg. v. Hall R; Springer US, Boston, MA 2012, 303–320
- Helbig K (2011): Zeitplanung für Patientenpfade unter Berücksichtigung von Betten-, Behandlungskapazitäten und Fairnesskriterien. Tagungsband 15 Interuniversitäres Doktorandenseminar Wirtschaftsinformatik der Universitäten Chemnitz, Dresden, Freiberg, Halle-Wittenberg, Jena und Leipzig 34–44
- Helbig K, Mellouli T, Stoeck T, Gragert M, Jahn P: Simulation stationsübergreifender Patientenflüsse zur Evaluation flexibler Bettenbelegungsszenarien aufgrund der Jahresdatenanalyse eines Universitätsklinikums; in: *MKWI 2014 - Multikonferenz Wirtschaftsinformatik: 26. - 28. Februar 2014 in Paderborn; Tagungsband; Univ., Paderborn 2014*, 749–762
- Helbig K, Römer M, Mellouli T: A Clinical Pathway Mining Approach to Enable Scheduling of Hospital Relocations and Treatment Services; in: *Business Process Management*, Band 9253; hrsg. v. Motahari-Nezhad HR, Recker J, Weidlich M; Springer International Publishing, Cham 2015a, 242–250

- Helbig K, Stoeck T, Mellouli T: A Generic Simulation-Based DSS for Evaluating Flexible Ward Clusters in Hospital Occupancy Management; in: 48th Hawaii International Conference on System Sciences (HICSS); IEEE 2015b, 2923–2932
- Huang Z, Lu X, Duan H (2012): On mining clinical pathway patterns from medical behaviors. *Artificial Intelligence in Medicine* 56, 35–50
- Huang Z, Dong W, Ji L, Gan C, Lu X, Duan H (2013a): Discovery of clinical pathway patterns from event logs using probabilistic topic models. *Journal of Biomedical Informatics*
- Huang Z, Lu X, Duan H (2013b): Latent treatment topic discovery for clinical pathways. *Journal of Medical Systems* 37, 1–10
- InEK GmbH: G-DRG German Diagnosis Related Groups Version 2014/2015 Definitionsbandbuch. Band 1; Siegburg, 2014
- InEK GmbH (2015): Anlage zur Vereinbarung über die Übermittlung von Daten nach § 21 Abs. 4 und Abs. 5 KHEntgG: Daten nach § 21 KHEntgG - Version 2016 für das Datenjahr 2015.
- Jacobs B: Ableitung von klinischen Pfaden aus evidenzbasierten Leitlinien am Beispiel der Behandlung des Mammakarzinoms der Frau. 2007
- Jacobson SH, Hall SN, Swisher JR: Discrete-event simulation of health care systems; in: *Patient flow: reducing delay in healthcare delivery*; Springer 2006, 211–252
- Johnson S, Müller T (Hrsg.): *Interdisziplinäre Versorgungspfade: Pathways of care*. (Verlag Hans Huber, Programmbereich Pflege), 1. Aufl; Huber, Bern 2002
- Kahla-Witzsch HA, Geisinger T: *Clinical Pathways in der Krankenhauspraxis: ein Leitfaden*. (Kohlhammer Krankenhaus), 1. Aufl; Kohlhammer, Stuttgart 2004
- Kaymak U, Mans R, Steeg T van de, Dierks M: On process mining in health care; IEEE 2012, 1859–1864
- Khare RK, Powell ES, Reinhardt G, Lucenti M (2009): Adding More Beds to the Emergency Department or Reducing Admitted Patient Boarding Times: Which Has a More Significant Influence on Emergency Department Congestion? *Annals of Emergency Medicine* 53, 575–585.e2
- Khoubati K, Themistocleous M, Irani Z (2006): Evaluating the adoption of enterprise application integration in health-care organizations. *Journal of management information systems* 22, 69–108
- Köhler CO, Wagner G, Wolber U (1977): Patient scheduling-(Bibliography). *Methods of Information in Medicine* 112–115
- Kolker A (2009): Process Modeling of ICU Patient Flow: Effect of Daily Load Leveling of Elective Surgeries on ICU Diversion. *Journal of Medical Systems* 33, 27–40
- Kumar A, Mo J: Models for Bed Occupancy Management of a Hospital in Singapore; in: *Proceedings of the 2010 International Conference on Industrial Engineering and Operations Management*; 2010

- Küttner T, Roeder N (2007): Definition Klinischer Behandlungspfade. Klinische Behandlungspfade: mit Standards erfolgreich arbeiten/N Roeder/T Küttner (Hrsg)–Köln: Dr Ärzte-Verl, S 19–27
- Lang M, Bürkle T, Laumann S, Prokosch H-U (2008): Process mining for clinical workflows: challenges and current limitations. *Stud Health Technol Inform* 136, 229–234
- Lauterbach KW, Bollschweiler E, Lauterbach-Lüngen-Schrappé (Hrsg.): Gesundheitsökonomie, Management und Evidence-based Medicine: Handbuch für Praxis, Politik und Studium ; mit 71 Tabellen. 3., völlig neu bearb. und Aufl; Schattauer, Stuttgart 2010
- Matthias Bartz: Patientenpfade : ein Instrument zur Prozessoptimierung im Krankenhaus. Saarbrücken : VDM, Verl. Müller 2006
- McClellan S, Millard PH (1995): A decision support system for bed-occupancy management and planning hospitals. *Mathematical Medicine and Biology* 12, 249–257
- Page B: Methoden der Modellbildung in der Gesundheitssystemforschung. Springer, Berlin [u.a.] 1982
- Paulussen TO, Zöllner A, Rothlauf F, Heinzl A, Braubach L, Pokahr A, Lamersdorf W: Agent-Based Patient Scheduling in Hospitals; in: Multiagent Engineering; hrsg. v. Kirn S, Herzog O, Lockemann P, Spaniol O; Springer-Verlag, Berlin/Heidelberg, 255–275
- Peleg M, Soffer P, Ghattas J: Mining Process Execution and Outcomes – Position Paper; in: Business Process Management Workshops, Band 4928; hrsg. v. Hofstede A, Benatallah B, Paik H-Y; Springer Berlin Heidelberg, Berlin, Heidelberg 2007, 395–400
- Proudlove N, Gordon K, Boaden R (2003): Can good bed management solve the overcrowding in accident and emergency departments? *Emergency Medicine Journal* 20, 149–155
- Rebuge Á, Ferreira DR (2012): Business process analysis in healthcare environments: A methodology based on process mining. *Information Systems* 37, 99–116
- Roche KT, Rivera DE, Cochran JK (2012): A control engineering framework for managing whole hospital occupancy. *Mathematical and Computer Modelling* 55, 1401–1417
- Roeder N, Küttner T (2006): Behandlungspfade im Licht von Kosteneffekten im Rahmen des DRG-Systems. *Der Internist* 47, 684–689
- Roeder N, Hindle D, Loskamp N, Juhra C, Hensen P, Bunzemeier H, Rochell B (2003a): Frischer Wind mit klinischen Behandlungspfaden (I). *das Krankenhaus* 1, 21
- Roeder N, Hensen P, Hindle D, Loskamp N, Lakomek H-J (2003b): Instrumente zur Behandlungsoptimierung. *Der Chirurg* 74, 1149–1155
- Saadani NEH, Bahroun Z, Bouras A: A linear mathematical model for patients' activities scheduling on hospital resources; *IEEE* 2014, 074–080
- Salfeld R, Hehner S, Hehner S, Wichels R: Modernes Krankenhausmanagement: Konzepte und Lösungen. Springer 2009

- Schlüchtermann J: Patientensteuerung : am Beispiel der Radiologie eines Krankenhauses. Eul, Bergisch Gladbach u.a. 1990
- Schmidt U-A: Prozessoptimierung im Krankenhausbereich: logistische Abläufe mit Schwerpunkt Radiologie und deren Verbesserungspotenziale. (Gesundheitsmanagement und Medizinökonomie 21); Kovač, Hamburg 2011
- Schneeweiß C (1994): Elemente einer Theorie hierarchischer Planung. Operations-Research-Spektrum 16, 161–168
- Shuman LJ, Wolfe H, Jr RDS (1974): The Role of Operations Research in Regional Health Planning. Operations Research 22, 234–248
- Simon M: Das Gesundheitssystem in Deutschland: eine Einführung in Struktur und Funktionsweise. (Lehrbuch Gesundheitswissenschaften), 3., überarb. und aktualisierte Aufl., 1. Nachdr; Huber, Bern 2011
- Statistisches Bundesamt, Gesundheit - Kostennachweis der Krankenhäuser - Fachserie 12 Reihe 6.3 - 2014. Statistisches Bundesamt (Destatis), Wiesbaden 2015
- Statistisches Bundesamt, Gesundheit - Ausgaben - Fachserie 12 Reihe 7.1.1 - 2014. Statistisches Bundesamt (Destatis), Wiesbaden 2016
- Suhl L, Mellouli T: Optimierungssysteme Modelle, Verfahren, Software, Anwendungen. Springer, Berlin 2009
- Tuschen KH, Trefz U: Krankenhausentgeltgesetz: Kommentar mit einer umfassenden Einführung in die Vergütung stationärer Krankenhausleistungen. (Kohlhammer Krankenhaus), 1. Aufl; Kohlhammer, Stuttgart 2004
- Villa S, Barbieri M, Lega F (2009): Restructuring patient flow logistics around patient care needs: implications and practicalities from three critical cases. Health Care Management Science 12, 155–165
- Vissers JMH (2005): Patient mix optimization in tactical cardiothoracic surgery planning: a case study. IMA Journal of Management Mathematics 16, 281–304
- Welch JD (1964): Appointment Systems in Hospital Outpatient Departments. OR 15, 224–232
- Yang W-S, Hwang S-Y (2006): A process-mining framework for the detection of healthcare fraud and abuse. Expert Systems with Applications 31, 56–68
- Zander K: Critical pathways; in: Melumim & M. Sinions (Eds.), Total quality management; American Hospital Association Publishing, Chicago 1992

**Anhang A: Zeitplanung für Patientenpfade unter  
Berücksichtigung von Betten-, Behandlungskapazitäten und  
Fairnesskriterien**

Helbig K (2011)

In: Tagungsband 15 Interuniversitäres Doktorandenseminar  
Wirtschaftsinformatik der Universitäten Chemnitz, Dresden, Freiberg, Halle-  
Wittenberg, Jena und Leipzig 34–44

## Zeitplanung für Patientenpfade unter Berücksichtigung von Betten-, Behandlungskapazitäten und Fairnesskriterien

Karsten Helbig

Martin-Luther-Universität Halle-Wittenberg  
Lehrstuhl für Wirtschaftsinformatik und Operations Research,  
Universitätsring 3, 06108 Halle

Email: karsten.helbig@wiwi.uni-halle.de

**Abstract:** The costs of patient care reached a new height. Poor management of patient flows in hospitals lead to unnecessary waiting time, a low degree of capacity utilization and expensive needless treatments. In the beginning of this paper a shortly overview of health care optimization research is shown, which leads to the implementation of interdisciplinary clinical pathways to improve the patient flow. Based on this the structure of scheduling focused clinical pathways is described. After that, a mixed integer linear programming model is shown, which is able to schedule these pathways. In the end the model is verified by an instance of a clinical pathway.

### 1 Einleitung

Seit der Einführung des DRG (Diagnosis Related Groups) Abrechnungssystems 2003 konnte die durchschnittliche Verweildauer von Patienten in Krankenhäusern von 14 Tagen auf ca. 8 Tage reduziert werden. Gleichzeitig stiegen die Fallzahlen pro Jahr von ca. 14 Mio. 1991 auf 18 Mio. 2010 [Statistisches Bundesamt 2011, 10]. Trotz dieser Erfolge nehmen die Kosten pro Fall seit Jahren zu [Statistisches Bundesamt 2009, 6]. Ein Grund dafür ist die klassische auf Berufsgruppen ausgerichtete Organisationsform von Krankenhäusern. Damit ein Krankenhaus Behandlung- und Versorgungsleistungen erbringen kann, sind eine Vielzahl von Koordinations- und Kommunikationsdienstleistungen nötig. Diese werden durch die große Anzahl an Funktions- und Berufsgruppen deutlich erschwert [Bartz 2006, 9ff].

Schlechte Koordination der Behandlungen und mangelnde Kommunikation unter den Organisationseinheiten können weiterhin zu teuren Doppeluntersuchungen oder unnötigen Wartezeiten für die Patienten führen. Beides erhöht die Kosten und wirkt sich eher negativ auf die Genesung des Patienten aus. Um effizienter wirtschaften zu können und mehr Patienten Zugang zu modernen Behandlungsmethoden zu ermöglichen, muss das Krankenhaus die Koordination und Kommunikation bei Behandlungsabläufen verbessern.

Eine Möglichkeit dieses Ziel zu erreichen ist die Einführung einer interdisziplinären Planung von Patientenpfaden. Dadurch wird es möglich, unnötige Wartezeiten durch fehlende Kapazitäten für Behandlungen zu vermeiden. Weiterhin können die Kapazitäten der nötigen Ressourcen bedarfsgerecht verteilt werden. Die durch die Planung geschaffene Transparenz des Behandlungsablaufes macht es ebenfalls einfacher, auf unvorhergesehene Notfälle zu reagieren und dadurch erforderliche Umplanungen schneller durchführen zu können.

In dieser Arbeit wird ein gemischt-ganzzahliges lineares Planungsmodell für ideal verlaufende interdisziplinäre Patientenpfade vorgestellt. Ziel der Planung ist es, die Wartezeiten der einzelnen Patienten auf ein Minimum zu reduzieren und die nicht vermeidbaren Wartezeiten möglichst fair unter allen Patienten aufzuteilen. Weiterhin soll die

Auslastung der vorhandenen Ressourcen zu Beginn des Planungsintervalls möglichst hoch ausfallen, damit möglichst viele freie Kapazitäten in der noch unbekanntem Zukunft vorhanden sind.

Im Folgenden wird ein kurzer Überblick über den Stand der Forschung in der Prozessoptimierung im Krankenhaus gegeben. Anschließend wird auf die Struktur der Patientenpfade, wie sie dieser Arbeit zu Grunde liegen eingegangen. Darauf aufbauend wird das gemischt ganzzahlige Planungsmodell vorgestellt. Anschließend wird auf erste Experimente mit dem Modell eingegangen. Abgeschlossen wird diese Arbeit mit einem Fazit und dem Ausblick auf weitere Forschungen.

## 2 Stand der Forschung - Prozessoptimierung im Krankenhaus

Peter Drucker bezeichnete Krankenhäuser als: „*the most complex human organization ever devised*“ [Wartzman 2009]. Dieser Eindruck spiegelt sich an der großen Anzahl von Forschungsarbeiten zum Thema Prozessoptimierungen in Krankenhäusern wider. Die erste Pionierarbeit zum Finden von guten Bestellstrategien von Patienten in Arztpraxen und Kliniken wurde von [Welch 1964] veröffentlicht. Seitdem wurden nahezu alle Methoden des Operations Research zur Lösung von Problemstellungen rund um die Krankenhausplanung eingesetzt. Einen ersten Einblick über die beforschten Problemstellungen und die eingesetzten Methoden liefern [Fries 1976], [Page 1982], [Shuman et al. 1974] und [Köhler et al. 1977]. Vergleicht man die klassischen Problemstellungen wie die Suche nach der idealen Bestellstrategie [Welch 1964] oder die Planung von Personal [Trivedi 1981], [Rothstein 1973] mit modernen Ansätzen wie Patientenplanung mit Hilfe von genetischen Algorithmen [Villa et al. 2009], oder Patientensteuerung mit agentenbasierten Verfahren [Paulussen et al. 2006], wird deutlich, dass die primären Zielsetzungen von besserer medizinischer Versorgung, Kostenminimierung und kürzeren Verweildauern der Patienten [Sumer 1982, 115] zwar noch die gleichen sind, aber zunehmend an der Entwicklung integrierter Lösungen gearbeitet wird. Studien zeigen, dass schlechtes Management von Patientenflüssen zu längeren Verweildauern, Engpässen und geringen Ressourcenauslastungen führt. Die Planung wichtiger Ressourcen wie OPs und Betten muss zentralisiert werden. Dadurch kann eine Ressourcenverteilung zwischen den verschiedenen organisatorischen Einheiten eines Krankenhauses realisiert werden [Villa et al. 2009, 160f]. Nennenswerte Leistungsverbesserungen können nur durch eine vollständige Überarbeitung klinischer Kernprozesse geschehen. „Mit Abstand die größte Hebelwirkung verspricht die Etablierung patientenzentrierter Behandlungsabläufe.“ [Salfeld et al. 2009, 49]. Diese Behandlungsabläufe, oder klinische Patientenpfade haben sich als integriertes Managementkonzept für verschiedene Krankheitsbilder bewährt. Eine einheitliche Begriffsdefinition wurde bisher nicht gefunden. Je nach Problemschwerpunkt fallen die Definitionen unterschiedlich aus. Eine Übersicht dazu liefert [Bartz 2006, 37ff]. In dieser Arbeit werden Patientenpfade in Anlehnung an [Roeder/Küttner 2006, 684ff] als multidisziplinärer Plan, der festlegt, welche Behandlungsstationen ein Patient von Aufnahme bis Entlassung durchläuft, verstanden.

In dieser Arbeit dient das Konzept der Patientenpfade zur Formulierung eines gemischt-ganzzahligen linearen Optimierungsmodells zur Lösung des Patientensteuerungsproblems, also der Fragestellung welcher Patient wann welche Behandlung erhalten sollte. Als konzeptionelle Grundlage dient das Modell zur Patientensteuerung von [Schlüchtermann 1990, 171–174].



### 3 Strukturelle Eigenschaften von Patientenpfaden

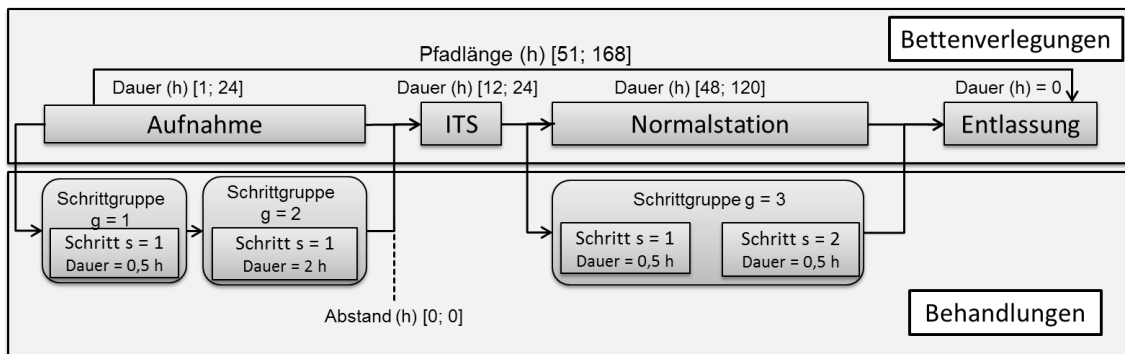


Abbildung 1 – Struktur eines Patientenpfades

Abbildung 1 zeigt exemplarisch die allgemeine Struktur eines auf die Planung ausgerichteten Patientenpfades. Die Struktur beschreibt einen idealen Behandlungsverlauf für eine Krankheit mit allen nötigen Untersuchungen, Operationen und therapeutischen Maßnahmen.

Ein Pfad besteht aus zwei inhaltlichen Ebenen, die miteinander koordiniert werden müssen. In der Ebene der Bettenverlegungen befindet sich eine definierte Folge von Verlegungen in Betten, die ein Patient während seiner Behandlung durchlaufen muss. Die erste Verlegung entspricht der Aufnahme in die Klinik, die letzte der Entlassung. Die Zeit, die der Patient in einem Bett verbringt, liegt zwischen gegebenen Grenzen. Während des gesamten Klinikaufenthalts muss dem Patienten zu jedem Zeitpunkt ein Bett zugewiesen sein. Die Entlassung wird als Punktereignis, ohne Dauer interpretiert. Ab diesem Zeitpunkt endet der Pfad und das belegte Bett steht wieder zur Verfügung.

Auf der Ebene der Behandlungen sind die einzelnen Behandlungsschritte zu finden. Diese werden in Schrittgruppen eingeteilt. Die Schrittgruppen besitzen eine feste vom Pfad vorgegebene Reihenfolge. Zeitliche Mindest- und Maximalabstände können zwischen Gruppen untereinander und Verlegungen und Gruppen gegeben sein. Im Beispiel in Abbildung 1 ist dargestellt, dass nach Schrittgruppe 2 unmittelbar die Verlegung auf die Intensivstation erfolgen muss.

Durch eine Zuordnung der Schrittgruppen zu den Verlegungen wird die Betten- mit der Behandlungsebene verbunden. Dadurch wird erreicht, dass Behandlungen nur dann durchgeführt werden können, wenn sich der Patient auf der entsprechenden Station bzw. an der entsprechenden Stelle im Behandlungspfad befindet. Im obigen Beispiel darf Schrittgruppe 3 nur während des Aufenthalts auf der Normalstation durchgeführt werden.

Da in der Praxis eine Vielzahl von Untersuchungen in beliebiger Reihenfolge durchgeführt können, muss auch diese Möglichkeit in die Struktur des Patientenpfades eingehen. Alle Schritte innerhalb einer Schrittgruppe besitzen die Eigenschaft in beliebiger Reihenfolge stattfinden zu können. Im obigen Beispiel trifft dies für alle Behandlungsschritte in der Schrittgruppe 3 zu. Zwischen Behandlungsschritten einer Schrittgruppe können ebenfalls zeitliche Mindest- und Maximalabstände auftreten.

Die Pfadlänge erstreckt sich von Beginn der Aufnahme, bis zum Ende der Entlassung. Die minimale und maximale Pfadlänge werden durch die der Krankheit zugeordneten DRG bestimmt.

## 4 Modell zur Zeitplanung für Patientenpfade

Im Folgenden wird ein gemischt ganzzahliges Modell zur Planung von Patientenpfaden mit einer wie in Kapitel 3 beschriebenen Struktur vorgestellt. In Anlehnung an [Schlüchtermann 1990, 170] werden die Start- und Endzeitpunkte der Verlegungs- und Behandlungsschritte als kontinuierliche Variablen modelliert.

Zur Modellierung der Zeitplanung von Patientenpfaden werden eine Vielzahl von Mengen, Parametern und Variablen benötigt. Um die Lesbarkeit zu erhöhen werden an dieser Stelle die allgemeinen für jede Problemstellung benötigten Mengen und Parameter definiert. Die für eine bestimmte Problemstellung benötigten Modellierungskonzepte werden in den einzelnen Unterkapiteln eingeführt.

Zur Modellierung benötigt wird die Menge aller Patienten  $P$ , sowie der Anfang  $T^S$  und das Ende des Planungshorizontes  $T^E$ . Die Menge aller Ressourcen  $R$  setzt sich zusammen aus der Menge aller Räume der Normalstationen  $R^N$ , der Menge aller Räume auf Intensivstationen  $R^{Int}$  und der Menge aller Behandlungszimmer  $R^B$ . Alle Variablen sind stets  $\geq 0$ .

### 4.1 Modellierung der Bettenverlegungen

Verlegungen sind die Schritte in einem Patientenpfad, bei denen der Patient ein neues Bett zugewiesen bekommt (siehe Kapitel 3). Um die Verlegungen abbilden zu können, wird die Menge aller Patienten  $P$  und die sortierte Menge aller Verlegungen  $V_p$  jedes Patienten benötigt. Weiterhin wird die Menge aller Räume  $R$ , die sich aus der Menge aller Räume auf Normalstationen  $R^N$  und der Menge aller Räume auf Intensivstationen  $R^{Int}$  zusammensetzt, benötigt. Die Menge aller für eine Verlegung  $v$  zulässigen Betten  $B_v$  entspricht allen Betten, die sich in einem für die Verlegung zulässigem Raum  $R_v$  befinden.

Die variable Dauer, die jeder Patient in einem Bett verbringt, ergibt sich aus der Differenz vom Verlassen und Beziehen des Bettes:

$$bed\_dur_{pvb} = bed\_out_{pvb} - bed\_in_{pvb} \quad \forall p \in P, v \in V_p, b \in B_v \quad (1)$$

Durch die binäre Variable  $yBed_{pvb}$  sowie die folgende Formel wird sichergestellt, dass nur genau ein Bett pro Verlegung ausgewählt wird:

$$\sum_{b \in B_v} yBed_{pvb} = 1 \quad \forall p \in P, v \in V_p \quad (2)$$

Zusammen mit Formel (1), der Forderung  $bed\_dur_{pvb} \geq 0$  und der Formel (3) wird erreicht, dass  $bed\_in_{pvb}$ ,  $bed\_out_{pvb}$  und  $bed\_dur_{pvb}$  nur für belegte Betten  $\geq 0$  werden können. Alle anderen sind gleich 0.

$$bed\_out_{pvb} \leq T^E * yBed_{pvb} \quad \forall p \in P, v \in V_p, b \in B_v \quad (3)$$

Um sicherzustellen, dass die Dauer, die ein Patient in einem Bett verbringt nicht die vom Pfad gegebenen Mindest- und Maximallänge verletzt, werden folgende Nebenbedingungen benötigt:

$$bed\_dur_{pvb} \leq bed\_dur\_max_{pv} * yBed_{pvb} \quad \forall p \in P, v \in V_p, b \in B_v \quad (4.1)$$

$$bed\_dur_{pvb} \geq bed\_dur\_min_{pv} * yBed_{pvb} \quad \forall p \in P, v \in V_p, b \in B_v \quad (4.2)$$

Da gemischte Zimmer auf Normalstationen für eine praktikable Lösung nicht in Frage kommen, muss die binäre Hilfsvariable  $yGender_{rpvp'v'}$  für jeden Raum und jede Patientenverlegungskombination ( $p$  und  $p'$ ) zwischen Patienten mit unterschiedlichem Geschlecht eingeführt werden. Mit Hilfe dieser Variable und der Aufteilung der Patienten in männliche ( $P^M$ ) und weiblichen ( $P^F$ ), können die folgenden Nebenbedingungen formuliert werden:

$$bed\_out_{pvb} \leq bed\_in_{p'v'} + T^E * (1 - yGender_{rpvp'v'}) \forall p \in P^M, p' \in P^F, v \in V_p, v' \in V_{p'}, r \in R^N, b \in B_{vr} \cup B_{v'r} \quad (5.1)$$

$$\sum_{p \in P^M} \sum_{p' \in P^F} \sum_{v \in V_p} \sum_{v' \in V_{p'}} yGender_{rpvp'v'} = 1 \forall r \in R_v^N \cup R_{v'}^N \quad (5.2)$$

Die folgende Nebenbedingung stellt sicher, dass jedem stationärem Patienten bis zur Entlassung (der letzten Verlegung  $v_n$ ) zu jedem Zeitpunkt ein Bett zugewiesen ist:

$$\sum_{b \in B} bed\_out_{pvb} = \sum_{b \in B_v} bed\_in_{pv+1b} \forall p \in P, v \in V_p \{v_n\} \quad (6)$$

Weiterhin muss sichergestellt werden, dass sich Verlegungen verschiedener Patienten nicht überschneiden. Dazu wird die binäre Variable  $yBedOrder_{pvp'v'b}$  eingeführt. Diese wird 1, wenn die Verlegung  $v$  eines Patient  $p$  vor der Verlegung  $v'$  eines anderen Patienten  $p'$  im Bett  $b$  stattfindet. Folgende beiden Nebenbedingungen gewährleisten Überschneidungsfreiheit der Verlegungen:

$$bed\_out_{pvb} \leq bed\_in_{p'v'b} + T^E * (1 - yBedOrder_{pvp'v'b})$$

$$\forall p, p' \in P: p \neq p', v \in V_p, v' \in V_{p'}, b \in B_v \quad (7.1)$$

$$yBedOrder_{pvp'v'b} + yBedOrder_{p'v'pvb} = 1$$

$$\forall p, p' \in P: p \neq p', v \in V_p, v' \in V_{p'}, b \in B_v \quad (7.2)$$

## 4.2 Modellierung der Behandlungsebene

In diesem Abschnitt wird die Modellierung der Schrittgruppen und Behandlungsschritte der Behandlungsebene (siehe Kapitel 3) beschrieben. Zuerst wird auf allgemeine Prinzipien der Modellierung eingegangen. Anschließend wird die Modellierung von Behandlungsschrittgruppen mit vom Patientenpfad festgelegter Reihenfolge beschrieben. Anschließend wird auf die Modellierung von Behandlungsschritten mit beliebiger Reihenfolge eingegangen.

Die Variable  $s\_begin_{pgsr}$  gibt an, wann der Behandlungsschritt  $s$  des Patienten  $p$  auf der Ressource  $r \in R_s^B$  beginnt. Der Index  $g$  stellt dabei ein künstliches Konstrukt zur Gruppierung der Behandlungsschritte in die Menge  $SG_p$  dar. Mit Hilfe dieses Indexes können Behandlungsschritte mit und ohne Reihenfolge voneinander unterschieden werden. Alle Schritte, deren Reihenfolge beliebig ist, sind demselben Gruppenindex  $g$  zugeordnet.

Die Ressourcen auf denen die einzelnen Behandlungen durchgeführt werden, haben im Gegensatz zu den Betten für die Verlegungen Öffnungszeiten, in denen diese zur Verfügung stehen. Es wird angenommen, dass alle für eine Behandlung nötigen Mittel während der Öffnungszeiten vorhanden sind. Da die einzelnen Ressourcen im Planungszeitraum mehr als ein Öffnungszeitenintervall besitzen können, bezeichnet  $I_R$  die Menge aller Öffnungszeitenintervalle der Ressource  $r$ . Die Intervalle sind chronologisch nummeriert. Mit Hilfe der binären Hilfsvariable  $yInterval_{pgsri}$  und der folgenden Formel wird sichergestellt, dass jeder Behandlungsschritt in genau einem Öffnungszeitenintervall liegt:

$$\sum_{i \in I_r} yInterval_{pgsri} = 1 \quad \forall p \in P, g \in SG_p, s \in S_g, r \in R_S^B \quad (8)$$

Da wie in der Praxis üblich einmal begonnene Behandlungen in den Überstunden beendet werden, genügt eine Nebenbedingung, die sicherstellt, dass alle Behandlungen innerhalb der Öffnungszeiten  $ot_{ri}$  beginnen.

$$s\_begin_{pgsr} \geq ot_{ri} * yInterval_{pgsri} \quad \forall p \in P, g \in SG_p, s \in S_g, r \in R_S^B, i \in I_r \quad (9)$$

Sind für einen Behandlungsschritt mehrere Ressourcen verfügbar, muss sichergestellt werden, dass genau eine dieser Ressourcen ausgewählt wird. Dies geschieht mit der binären Hilfsvariable  $yRes_{pgsr}$ , die angibt welcher Schritt  $s$  welches Patienten  $p$  auf welcher Ressource  $r$  ausgeführt wird und der folgenden Nebenbedingung:

$$\sum_{r \in R_S^B} yRes_{pgsr} = 1 \quad \forall p \in P, g \in SG_p, s \in S_g \quad (10)$$

Im Gegensatz zu den Verlegungen wird für die Behandlungsschritte eine feste vorgegebene Dauer  $s\_dur_{pgsr}$  angenommen. Dadurch muss der Abstand zwischen dem Anfang  $s\_begin_{pgsr}$  und dem Ende  $s\_end_{pgsr}$  eines Schrittes genau seiner Dauer entsprechen, wenn der Schritt auf dieser Ressource durchgeführt wird. Folgende Nebenbedingung stellt dies sicher:

$$s\_end_{pgsr} - s\_begin_{pgsr} = s\_dur_{pgsr} * yRes_{pgsr} \quad \forall p \in P, g \in SG_p, s \in S_g, r \in R_S^B \quad (11)$$

Die Gesamtkapazität einer Ressource in einem Öffnungszeiten-Intervall ( $kap_{ri}$ ) entspricht der Differenz zwischen Anfang  $ot_{ri}$  und Ende  $ct_{ri}$  der Öffnungszeiten. Die binäre Variable  $yKapUse_{ri}$  wird 1, wenn die Ressource  $r$  im Intervall  $i$  verwendet wird. Die folgende Nebenbedingung stellt sicher, dass die Dauer aller Behandlungsschritte in einem Intervall einer Ressource maximal so viel beträgt, wie Gesamtkapazität vorhanden ist.

$$kap_{ri} * yKapUse_{ri} \geq \sum_{p \in P} \sum_{g \in SG_p} \sum_{s \in S_g} s\_dur_{pgsr} * yInterval_{pgsri} \\ \forall r \in R_S^B, i \in I_{Rr} \quad (12)$$

Damit sich die Behandlungen der einzelnen Patienten nicht überschneiden, wird Binärvariable  $yOverlap_{pgsp'g'sr}$  eingeführt. Diese wird 1, wenn die Behandlung  $s$  der Schrittgruppe  $g$  eines Patienten  $p$  vor der Behandlung  $s'$  der Schrittgruppe  $g'$  eines anderen Patienten  $p'$  stattfindet. Die folgenden Nebenbedingungen stellen sicher, dass die Behandlung eines Patienten nur nach der Behandlung eines anderen Patienten stattfinden kann:

$$s\_end_{pgsr} \leq s\_begin_{pgs'r'} + T^E * (1 - yOverlap_{pgsp'g'sr})$$

$$\forall p, p' \in P: p \neq p', g \in SG_p, s \in S_g, g' \in SG_{p'}, s' \in S_{g'}, r \in R_S^B \quad (13.1)$$

$$yOverlap_{pgsp'g'sr} + yOverlap_{p'g'srpgs} = 1$$

$$\forall p, p' \in P: p \neq p', g \in SG_p, s \in S_g, g' \in SG_{p'}, s' \in S_{g'}, r \in R_S^B \quad (13.2)$$

#### 4.2.1 Nebenbedingungen für Schrittgruppen mit gegebene Reihenfolge

Um Schritte mit fester Reihenfolge abbilden zu können, wurden die Schrittgruppen  $SG_p$  eines Patienten  $p$  eingeführt. Diese symbolisieren die Reihenfolgen der Behandlungsschritte eines Patientenpfades (siehe Kapitel 3). Die Ordnung einer Schrittgruppe reicht von 1 bis  $u$ . Der Anfang einer Gruppe  $s\_group\_begin_{pg}$  wird durch den kleinsten Startzeitpunkt der Schritte in einer Gruppe  $s\_begin_{pgsr}$  bestimmt. In Anlehnung an die

Modellierungstechniken aus [Suhl/Mellouli 2006, 104f] ergeben sich dazu folgende Nebenbedingungen:

$$s\_begin_{pgsr} \geq s\_group\_begin_{pg} \forall p \in P, g \in SG_p, s \in S_g, r \in R_s^B \quad (14.1)$$

$$s\_begin_{pgsr} \leq s\_group\_begin_{pg} + T^E * (1 - ySBegin_{pgsr})$$

$$\forall p \in P, g \in SG_p, s \in S_g, r \in R_s^B \quad (14.2)$$

$$\sum_{s \in S_g} \sum_{r \in R_s^B} ySBegin_{pgsr} = 1 \forall p \in P, g \in SG_p \quad (14.3)$$

Für das Ende einer Gruppe  $s\_group\_end_{pg}$  von Behandlungsschritten ergibt sich mit derselben Modellierungstechnik analog:

$$s\_end_{pgsr} \leq s\_group\_end_{pg} \forall p \in P, g \in SG_p, s \in S_g, r \in R_s^B \quad (15.1)$$

$$s\_end_{pgsr} \geq s\_group\_end_{pg} + T^E * (1 - ySEND_{pgsr})$$

$$\forall p \in P, g \in SG_p, s \in S_g, r \in R_s^B \quad (15.2)$$

$$\sum_{s \in S_g} \sum_{r \in R_s^B} ySEND_{pgsr} = 1 \forall p \in P, g \in SG_p \quad (15.3)$$

Mit dem Wissen wann eine Schrittgruppe anfängt bzw. endet kann nun die Modellierung der Reihenfolgen in Anlehnung an [Schlüchtermann 1990, 171] erfolgen. Die folgende Nebenbedingung wurde um die Möglichkeit eines Mindestabstandes  $min\_dist_{pg}$  zwischen den Gruppen erweitert.

$$s\_group\_end_{pg} \leq s\_group\_begin_{pg+1} - min\_dist_{pg+1} \forall p \in P, g \in SG_p \setminus \{g_u\}, s \in S_g, r \in R_s^B \quad (16)$$

Falls ein Maximalabstand  $max\_dist_{pg}$  zwischen zwei Gruppen existiert, muss der Anfang der nachfolgenden Gruppe eingeschränkt werden:

$$s\_group\_begin_{pg+1} \leq s\_group\_end_{pg} + max\_dist_{pg+1} \forall p \in P, g \in SG_p \setminus \{g_u\}, s \in S_g, r \in R_s^B \quad (17)$$

#### 4.2.2 Nebenbedingungen für Behandlungsschritte mit variabler Reihenfolge

Behandlungsschritte mit beliebiger Reihenfolge sind alle derselben Schrittgruppe  $SG_p$  zugewiesen (siehe Kapitel 3). In der Lösung des Modells muss eine der möglichen Reihenfolgen ausgewählt werden. Dies wird durch die binäre Hilfsvariable  $yOrder_{pgss'}$  erreicht. Diese wird 1, wenn der Schritt  $s$  einer Gruppe  $g$  eines Patienten  $p$  vor einem andren Schritt  $s'$  derselben Gruppe durchgeführt wird. Folgende Nebenbedingung stellt sicher, dass genau eine mögliche Reihenfolge gewählt wird:

$$yOrder_{pgss'} + yOrder_{pgs's} = 1 \forall p \in P, g \in SG_p, s, s' \in S_g: s \neq s' \quad (18)$$

Ist eine Reihenfolge ausgewählt, so muss sichergestellt werden, dass sich die Schritte nicht überschneiden. Weiterhin müssen mögliche Mindest- ( $min\_dist_{pgss'}$ ) und Maximalabstände ( $max\_dist_{pgss'}$ ) zwischen den Schritten  $s$  und  $s'$  beachtet werden:

$$s\_end_{pgsr} + min\_dist_{pgss'} \leq s\_begin_{pgs'r'} + T^E * (1 - yOrder_{pgss'})$$

$$\forall p \in P, g \in SG_g, r \in R_s^B, r' \in R_{s'}^B, s, s' \in S_g: s \neq s' \quad (19.1)$$

$$s\_end_{pgsr} + max\_dist_{pgss'} \geq s\_begin_{pgs'r'} + T^E * (1 - yOrder_{pgss'})$$

$$\forall p \in P, g \in SG_g, r \in R_s^B, r' \in R_{s'}^B, s, s' \in S_g: s \neq s' \quad (19.2)$$

### 4.3 Verbindung zwischen Bettenverlegung- und Behandlungsebene

Um sicherzugehen, dass Behandlungen nur dann eingeplant werden, wenn sich der Patient auf der richtigen Station befindet, müssen die Behandlungsschritte mit den Verlegungen gekoppelt werden (siehe Kapitel 3). Der Parameter  $map_{pgv}$  wird 1, für einen Patienten  $p$  wenn die Behandlungsschrittgruppe  $g$  mit der Verlegung  $v$  gekoppelt ist. Inhaltlich bedeutet dies, dass alle Schritte dieser Gruppen zwischen dem Zeitpunkt des Beziehen und des Verlassens des Bettes der Verlegung stattfinden müssen. Für diese Fälle muss gelten:

$$s\_group\_begin_{pg} \geq bed\_in_{pvb} - T^E * (1 - yBed_{pvb}) \forall p \in P, g \in SG_g, s \in S_g, v \in V_p, b \in B_v: map_{pgv} = 1 \quad (20.1)$$

$$s\_group\_end_{pg} \leq bed\_out_{pvb} - T^E * (1 - yBed_{pvb}) \forall p \in P, g \in SG_g, s \in S_g, v \in V_p, b \in B_v \quad (20.2)$$

Sollte der Patientenpfad vorsehen, dass die Verlegung unmittelbar vor bzw. nach der Behandlungsschrittgruppe stattfindet muss, so sind für diese Fälle folgende Nebenbedingungen zu ergänzen.

$$s\_group\_begin_{pg} = bed\_out_{pvb} \forall p \in P, g \in SG_g, s \in S_g, v \in V_p, b \in B_v \quad (21.1)$$

$$s\_group\_end_{pg} = bed\_in_{pvb} \forall p \in P, g \in SG_g, s \in S_g, v \in V_p, b \in B_v \quad (21.2)$$

### 4.4 Modellierung der Zielfunktion

Wie u. a. in [Sumer 1982, 115] und [Paulussen et al. 2006, 255ff] gefordert, besteht das Ziel der Patientenplanung primär in der Minimierung der Verweildauer eines Patienten. Da eine Minimierung der durchschnittlichen Verweildauer zu einer unfairen Verteilung von Wartezeit führen kann, wird die Minimierung der maximalen Abweichung der Mindestverweildauer als ein Zielkriterium gewählt.

Um dies zu erreichen, muss die minimale Verweildauer für jeden Patientenpfad  $minStayTime_p$  bestimmt werden. Diese ergibt sich aus dem Maximum der Summe der Behandlungsdauern sowie der Mindestabstände der Behandlungen und der Summe der Minstdauern der Verlegungen.

Die tatsächliche Dauer der Behandlung ergibt sich aus der Differenz zwischen dem Endzeitpunkt des letzten ( $last_p$ ) und dem Anfangszeitpunkt des ersten Schrittes ( $first_p$ ) des Behandlungspfades. Um diese beiden Variablen mit den Verlegungen und den Behandlungsschritten zu verknüpfen sind folgende Nebenbedingungen nötig:

$$s\_group\_begin_{pg} \geq first_p \forall p \in P, g \in SG_p \quad (22.1)$$

$$bed\_in_{pvb} \geq first_p \forall p \in P, v \in V_p, b \in B_v \quad (22.2)$$

$$s\_group\_end_{pg} \leq last_p \forall p \in P, g \in SG_p \quad (22.3)$$

$$bed\_out_{pvb} \leq last_p \forall p \in P, v \in V_p, b \in B_v \quad (22.4)$$

Die Abweichung der Mindestverweildauer eines Patienten  $delay_p$  ergibt sich aus:

$$last_p - first_p = minStayTime_p + delay_p \forall p \in P \quad (23)$$

In Anlehnung an die Formulierung für eine min-max-Zielfunktion wie in [Suhl/Mellouli 2006, 104f] beschrieben, wird noch folgende Nebenbedingung benötigt:

$$delay_p \leq OverAllDelay \quad (24)$$

Das sekundäre Ziel der Patientenplanung ist eine möglichst hohe Auslastung der Kapazitäten. Um dieses Ziel zu erreichen, sollten Patienten und Ressourcenverwendungen so früh wie möglich im Planungsintervall eingeplant werden. Um dies zu erreichen wird die Zielfunktion um den Endzeitpunkt des letzten Behandlungsschrittes ( $last_p$ ) und die Nutzung der Ressource im Intervall  $i$  erweitert. Je nach Präferenz können die einzelnen Ziele mit den Faktoren  $d$ ,  $l$  und  $k_i$  gewichtet werden.

Abschließend ergibt sich die Zielfunktion:

$$z = \min(d * OverAllDelay + l * \sum_{p \in P} last_p + k_i * \sum_{r \in R^B} \sum_{i \in I_R} yKapUse_{ri}) \quad (25)$$

## 5 Experimente mit dem Modell

Das Basismodell konnte mit vereinfachten Annahmen für größere Probleminstanzen mit bis zu 64 Patienten und einem Planungszeitraum von 100 Tagen in weniger als zwei Minuten mit Hilfe des Standard-Solvers CLPEX 12.1 auf einem Intel Core 2 Duo CPU mit 2.39 GHz und 3 GB RAM gelöst werden. Erste Tests des Gesamtmodells wurden mit dem in Abbildung 1 dargestellten Patientenpfad durchgeführt. Jeder Behandlungsschritt besitzt in der Testinstanz vier mögliche Ressourcen. Für die normalen Verlegungen gibt es 23 mögliche Betten. Die Intensivstation besitzt 2 Betten. Die minimale Pfaddauer beträgt 51 h. Anhand kleiner Modelleinstanzen mit 2 – 4 Patienten und einem Planungshorizont von 14 Tagen konnte gezeigt werden, dass das Modell die strukturellen Bedingungen des Patientenpfades sowie die Anforderungen an eine umsetzbare Lösung im Krankenhausalltag einhalten konnte. Die Tests zeigten außerdem, dass die bisherige Formulierung ein stark symmetrisches Modell ergibt, was das Finden einer optimalen Lösung bei zunehmender Modellgröße erschwert. Bei einer starken Gewichtung des Kapazitätszieles (siehe Formel 25) konnte die Symmetrie etwas verringert werden. Dadurch konnten auch für größere Instanzen Lösungen in angemessener Zeit gefunden werden.

Ziel weiterer Forschung wird es sein, die Rechenzeit des Modells durch Vermeidung von Symmetrie, vereinfachten Modellannahmen und besseren Modellierungen auch für praxisrelevante Patientenzahlen auf ein akzeptables Maß zu reduzieren.

## 6 Fazit und Ausblick

In der Arbeit wurde gezeigt, dass eine Möglichkeit zur Erhöhung der Koordination von Patientenflüssen im Einsatz von interdisziplinären Patientenpfaden besteht. Weiterhin wurde ein Pfadkonzept vorgestellt, das sich für die Patientenplanung eignet. Darauf aufbauend wurde ein gemischt-ganzzahliges lineares Optimierungsmodell vorgestellt, das die Struktur von Patientenpfaden unter der Einhaltung praxisrelevanter Anforderungen abbilden kann. Mit Hilfe von kleinen Modellinstanzen konnte das Modell in ersten Experimenten verifiziert werden.

Schwerpunkt für zukünftige Forschung ist die Validierung des Modells mit Hilfe von Patientenpfaden, Ressourcenprofilen und Patientenzahlen aus der Praxis, sowie das Erforschen von Maßnahmen zur Verringerung der Lösungszeit. Ebenfalls interessant für weitere Untersuchungen sind Modellerweiterungen, durch die das Personal sowie externe Dienstleister in die Planung von Patientenflüssen einbezogen werden. Besonders letzteres hat großes Potential, Zeit und Kosten weiter zu senken, indem die Koordination und Kommunikation zwischen Klinik und Dienstleistern verbessert wird.

## Literatur

- Fries, Brant E. „Bibliography of Operations Research in Health-Care Systems“. *Operations Research* 24.5 (1976): pp. 801-814.
- Köhler, C. O., G. Wagner, und U. Wolber. „Patient scheduling-(Bibliography)“. *Methods of Information in Medicine* 16 (1977): 112-115.
- Matthias Bartz. *Patientenpfade : ein Instrument zur Prozessoptimierung im Krankenhaus*. Saarbrücken : VDM, Verl. Müller, 2006.
- Page, Bernd. *Methoden der Modellbildung in der Gesundheitssystemforschung*. Berlin [u.a.]: Springer, 1982.
- Paulussen, Torsten u. a. „Agent-based Patient Scheduling in Hospitals“. *Multiagent Engineering - Theory and Applications in Enterprises*. Hg von. Spaniol Kirn, Herzog, Lockemann. Springer, 2006. 255-275.
- Roeder, N., und T. Küttner. „Behandlungspfade im Licht von Kosteneffekten im Rahmen des DRG-Systems“. *Der Internist* 47 (2006): 684-689. 29 Sep. 2011.
- Rothstein, M. „Hospital manpower shift scheduling by mathematical programming.“ *Health Services Research* 8.1 (1973): 60-66.
- Salfeld, Rainer u. a. *Modernes Krankenhausmanagement: Konzepte und Lösungen*. Springer, 2009.
- Schlüchtermann, Jörg. *Patientensteuerung : am Beispiel der Radiologie eines Krankenhauses*. Bergisch Gladbach [u.a.], 1990.
- Shuman, Larry J., Harvey Wolfe, und R. Dixon Speas Jr. „The Role of Operations Research in Regional Health Planning“. *Operations Research* 22.2 (1974): pp. 234-248.
- Statistisches Bundesamt. „Grunddaten der Krankenhäuser - FS 12 R. 6.1.1 Fachserie 12 Reihe 6.1.1 - 2010“. 22 Nov. 2011.
- Statistisches Bundesamt. „Kostennachweis der Krankenhäuser - FS 12 R. 6.3 Fachserie 12 Reihe 6.3 - 2009“. 22 Feb. 2011.
- Suhl, Leena, und Taïeb Mellouli. *Optimierungssysteme: Modelle, Verfahren, Software, Anwendungen*. Springer, 2006.
- Sumer C., Aggarwal. „A focussed review of scheduling in services“. *European Journal of Operational Research* 9.2 (1982): 114-121.
- Trivedi, Vandankumar M. „A Mixed-Integer Goal Programming Model for Nursing Service Budgeting“. *Operations Research* 29.5 (1981): 1019-1034.
- Villa, Stefano, Marta Barbieri, und Federico Lega. „Restructuring patient flow logistics around patient care needs: implications and practicalities from three critical cases“. *Health Care Management Science* 12.2 (2009): 155-165.
- Wartzman, Rick. „Solving the Health-Care Conundrum“. *BusinessWeek: Managing* 15 Mai 2009. 4 Dez. 2011.
- Welch, J. D. „Appointment Systems in Hospital Outpatient Departments“. *OR* 15.3 (1964): pp. 224-232.



## **Anhang B: Simulation stationsübergreifender Patientenflüsse zur Evaluation flexibler Bettenbelegungsszenarien aufgrund der Jahresdatenanalyse eines Universitätsklinikums**

Helbig K, Mellouli T, Stoeck T, Gragert M, Jahn P (2014)

In: MKWI 2014 - Multikonferenz Wirtschaftsinformatik : 26. - 28. Februar 2014 in Paderborn ; Tagungsband; Univ., Paderborn 2014, 749–762

# **Simulation stationsübergreifender Patientenflüsse zur Evaluation flexibler Bettenbelegungsszenarien aufgrund der Jahresdatenanalyse eines Universitätsklinikums**

**Karsten Helbig, Prof. Dr. Taïeb Mellouli, Thomas Stoeck, Markus Gragert**

Martin-Luther-Universität Halle-Wittenberg, Lehrstuhl für Wirtschaftsinformatik und Operations Research, 06108 Halle (Saale), E-Mail: karsten.helbig@wiwi.uni-halle.de, mellouli@wiwi.uni-halle.de, thomas.stoeck@student.uni-halle.de, markus.gragert@student.uni-halle.de

**Dr. Patrick Jahn**

Universitätsklinikum Halle (Saale), Stabsstelle 7 des Klinikumsvorstands des UKH „Pflegeforschung und Entwicklung“, 06120 Halle (Saale), E-Mail: patrick.jahn@uk-halle.de

## **Abstract**

Im Zuge der Gesundheitsreform 2003 sind Krankenhäuser gezwungen, ihre Prozesse zu rationalisieren. Zur Evaluation von Verbesserungsmaßnahmen der komplexen Krankenhausprozesse ist die ereignisdiskrete Simulation ein effektives Werkzeug zur Unterstützung von Managemententscheidungen. Gemäß der Anforderungen an moderne Simulationsstudien im Krankenhauskontext (u.a. Praxisrelevanz und ganzheitliche Betrachtung) werden in diesem Aufsatz die Patientenflüsse im Universitätsklinikum Halle (Saale) stationsübergreifend modelliert. Zur stationären Aufnahme wird eine genaue Belegungsstrategie hinsichtlich Geschlecht und Isolationsstatus in die auf Jahresdaten basierende Simulation eingebettet. Flexible Bettenbelegungsszenarien wie Zimmerverleih an räumlich angrenzende Stationen sowie die Zusammenführung aller ITS- und IMC-Stationen zu zentralen Pools führten zu einer deutlichen Reduzierung der Wartezeit auf Verlegungen innerhalb des Klinikums.

## **1 Einleitung**

Krankenhäuser sind der wichtigste Leistungsbringer im deutschen Gesundheitssystem. Im Jahr 2011 verursachten diese ca. 76,8 Milliarden Euro an Kosten. Dies entspricht ca. 25% der Gesamtausgaben von 293,8 Milliarden Euro für Gesundheit im Jahre 2011 [13]. Aufgrund der Einführung des DRG-basierten Abrechnungssystems sind Krankenhäuser seit 2003 einem wettbewerbsbedingten Reformdruck ausgesetzt. Krankenhäuser, die es nicht schaffen, ihre Prozess- und Kostenstrukturen den Gegebenheiten anzupassen, sind in ihrer Existenz bedroht. Prozessverbesserungen sowie deren Auswirkungen sind aufgrund der hohen Komplexität und starken Interdependenzen der Krankenhausprozesse schwierig umzusetzen. Dies gilt insbesondere für große Krankenhäuser mit mehr als tausend Betten und einer Vielzahl fachspezifischer Stationen. Das Universitätsklinikum Halle (Saale) (UKH) gehört mit seinen ca. 1100 Betten zu dieser Gruppe. Im UKH werden jährlich ca. 40.000 voll- und teilstationäre Patienten behandelt. Davon sind ca. 10.000 stationäre Notfallpatienten,

die das Klinikum durch die zentrale Notaufnahme (ZNA) betreten. Deren stationäre Aufnahme kann erst erfolgen, sobald ein Bett auf der entsprechenden Station zur Verfügung steht. Zur Überbrückung dieser Zeit stehen der ZNA zehn Betten zur Verfügung. Diese sind primär für Patienten, die zur medizinischen Überwachung in der ZNA verweilen, ausgelegt. Nur im Falle von Ressourcenengpässen werden sie als Puffer verwendet. Sollte die Überwachungseinheit der ZNA ebenfalls voll ausgelastet sein, wird die gesamte ZNA handlungsunfähig und kann keine weiteren Patienten aufnehmen, bis wieder freie Kapazitäten zur Verfügung stehen.

In diesem Aufsatz wird gezeigt, wie Entscheidungsunterstützung zur Gestaltung des Bettenbelegungsmanagements des UKH mit Hilfe eines ereignisdiskreten Simulationsmodells des gesamten Patientenflusses erfolgen kann. Ziel ist es zu evaluieren, welchen Einfluss Verbesserungsmaßnahmen auf Wartezeiten in der Überwachungsstation der ZNA sowie bei klinikinternen Verlegungen haben. Dazu werden im folgenden Kapitel bisherige Arbeiten zum Einsatz von ereignisdiskreter Simulation im Krankenhaus vorgestellt und Anforderungen an moderne Simulationsstudien in diesem Kontext abgeleitet. Anschließend werden im dritten Kapitel die abgebildeten Patiententypen, das Simulationsmodell sowie die in der Simulation eingebettete Heuristik zur Bettenbelegung vorgestellt. Im vierten Kapitel wird die Analyse der für die Simulation verwendeten Patientenfalldaten beschrieben. Im fünften Kapitel werden die in einer Zusammenarbeit mit dem UKH erarbeiteten Lösungsszenarien vorgestellt. Das sechste Kapitel beinhaltet die Modellvalidierung sowie die Evaluation der Szenarien. Abschließend werden die Ergebnisse der Studie zusammengefasst und auf weiterführende Forschungsfragen eingegangen.

## 2 Einsatz ereignisdiskreter Simulation in Krankenhäusern

„Discrete-event simulation offers perhaps the most powerful and intuitive tool for the analysis and improvement of complex health care systems.“ [8] Zu diesem Schluss kommen *Jacobson et al.* nach der Sichtung einer Vielzahl von Studien zum Einsatz von ereignisdiskreter Simulation im Krankenhauskontext der letzten 40 Jahre [8]. Untermauert wird diese These durch die große Anzahl von Surveys, die die lange Tradition des Einsatzes von Simulationstechniken im Kontext des Gesundheitswesens sowie deren Anerkennung als geeignetes Mittel zur Entscheidungsunterstützung unterstreichen [3, 5, 7–11].

Ereignisdiskrete Simulation wird vorwiegend zur Unterstützung operativer Entscheidungen wie z.B. Personaleinsatz, Patientenplanung, Ressourcenausstattung, Bettenzuweisungen oder Layout von Gebäuden verwendet [5, 7, 10]. Auffallend ist der Fokus auf isolierte Krankenhausteilbereiche wie einzelne Stationen, die Notaufnahme oder Operationssäle und die versuchte Problemlösung innerhalb dieser, wie es der Großteil der Studien vor 2010 dokumentieren [5, 7, 8]. Da Krankenhausprozesse komplex miteinander verflochten sind, kann eine isolierte Betrachtung die Realitätsnähe der Modelle erheblich negativ beeinflussen [8]. Zusätzlich können dadurch keine verallgemeinerbaren Erkenntnissen für ähnliche Problemstellungen abgeleitet werden [7].

*Eldabi et al.* sowie *Gunal et al.* hinterfragen die Sinnhaftigkeit von Publikationen, die wenig praktischen Nutzen und überdies wenig theoretischen Mehrwert für andere Forscher bieten. Solange ähnliche Probleme mit ähnlichen Modellen gelöst werden, wird sich die Forschung zur Simulation im Krankenhauskontext nicht weiterentwickeln, so die Autoren [6, 7].

Anforderungen an zukünftige Studien sind demnach die Entwicklung integrierter Modelle, die die Komplexität der Krankenhausrealität möglichst umfassend darstellen können [5, 7], die Herleitung allgemeingültiger Aussagen sowie die transparente Darstellung des praktischen Nutzens [7].

Eine aktuelle Studie zur Effizienzsteigerung in der Notaufnahme eines Klinikums in Wales nimmt die genannte Kritik teilweise auf und ermittelt Schwachstellen im Patientenfluss der Notaufnahme. Verglichen werden Simulationsergebnisse einer perfekten Welt ohne Ressourcenbeschränkungen mit Ergebnissen der simulierten Ist-Situation. Die Differenz der beiden Modelle zeigt die Schwachstellen bei gleichem Patientenaufkommen. Es konnten ein effizienter Personal- und Ressourceneinsatz, sowie die nötigen Investitionen ermittelt werden, um die gegebenen Qualitätsziele zu erreichen [2].

*Coughlan et. al.* ist es gelungen, die dynamischen Re-Priorisierungsstrategien zur Reduzierung von wartenden Patienten in der Notaufnahme eines Londoner Krankenhauses valide nachzubilden. Ziel dieser Strategien ist es, Patienten spätestens nach vier Stunden Wartezeit in der Notaufnahme zu entlassen, oder aufgenommen zu haben. Aufgrund der Vielzahl von verschiedenen Diagnose- und Therapiemethoden wurden diese jeweils in einem Prozessschritt zusammengefasst. Differenziert werden die einzelnen Methoden durch ermittelte Verteilungen für Nutzungswahrscheinlichkeit und Dauer. Die Ergebnisse zeigen anhand der starken Korrelation ( $r = 0,98$ ) zwischen tatsächlicher und simulierter Wartezeit die Validität des Modells [4].

Eine Hilfestellung bei der Erstellung von Simulationsmodellen liefert die Arbeit von *Günal*. Basierend auf Literaturrecherchen und eigenen Erfahrungen werden die konzeptionelle, sowie die technische Sichtweise einer Simulationsstudie im Krankenhauskontext erläutert. Die Modellierung der komplexen Beziehungen zwischen Dienstleistungen und Aktivitäten am Patient stellt nach Meinung des Autors eine der größten Herausforderungen in der Krankenhausmodellierung dar. Dabei stellt die ereignisdiskrete Simulation u.a. aus Gründen der Modellflexibilität, Verfolgbarkeit einzelner Individuen, sowie der Möglichkeiten zur Abbildung stochastischer Komponenten eine häufig eingesetzte Methode zur Evaluierung von Verbesserungsmaßnahmen dar [6].

Die vorliegende Studie orientiert sich an den genannten Anforderungen und Hilfestellungen und bildet zur Evaluierung von Verbesserungsmaßnahmen des Belegungsmanagements den gesamten stationsübergreifenden Patientenfluss in einem ereignisdiskreten Simulationsmodell ab. Wie in [2, 4, 6] beschrieben, entsprechen die Entitäten den Patienten, die sich charakteristisch für beobachtete Patiententypen durch ein Prozessnetzwerk bewegen und Ressourcen für Behandlungen und stationäre Aufnahmen benötigen. Grundlegende Einflussfaktoren wie bspw. Ankunftsdaten, Prozessdauern und Übergangswahrscheinlichkeiten werden wie in [2, 4, 6] beschrieben verwendet. Dabei erhebt das entwickelte Modell den Anspruch, für ähnliche Strukturen in anderen Krankenhäusern angewendet werden zu können. Die Simulation berücksichtigt reale Belegungskapazitäten in der zentralen Notfallaufnahme und den einzelnen Stationen. Praxisrelevanz ist durch die Entscheidungsunterstützung aktueller Diskussionen zu Verbesserungsmaßnahmen im UKH gegeben.

### **3 Simulationsmodell für Patientenflüsse im Krankenhaus**

#### **3.1 Patiententypen zur Differenzierung der Patientenflüsse**

Im Universitätsklinikum konnten drei verschiedene Patiententypen im Hinblick auf deren Bewegung durch die Bereiche des UKH identifiziert werden:

**Ambulante Notfallpatienten** werden in der Zentralen Notfallaufnahme (ZNA) behandelt und im Anschluss wieder entlassen. In einzelnen Fällen (z.B. zum Ausschluss eines Myokardinfarktes) werden diese Patienten auf der Überwachungseinheit aufgenommen. In Jahr 2011 wurden von insgesamt 26.366 behandelten ambulanten Patienten ca. 1,35% auf der Überwachungseinheit untergebracht.

**Stationäre Notfallpatienten** müssen nach der Behandlung auf der ZNA von einer Station des Krankenhauses stationär aufgenommen und versorgt werden. Der Aufenthalt in der ZNA kann sich aufgrund einer medizinisch notwendigen Überwachungsphase in der Überwachungseinheit verzögern. Die darauf folgende Verlegung kann jedoch nicht in allen Fällen direkt im Anschluss durchgeführt werden: Zum einen erfolgen Verlegungen nur tagsüber, zum anderen muss die jeweils vorgesehene Nachfolgestation die benötigten Ressourcen zur Verfügung stellen können. Ist auch nur eine dieser Bedingungen nicht erfüllt, muss der Patient zur Überbrückung weiterhin auf der Überwachungseinheit untergebracht werden. In diesem Fall entsteht Wartezeit auf der ZNA. Von den insgesamt 9.718 stationären Notfallpatienten mussten 10,3% kurzzeitig auf der Überwachungsstation betreut werden.

**Elektive Patienten** mit anstehenden Behandlungen, deren Zeitpunkte verhältnismäßig frei wählbar sind, werden bei Ihrer Ankunft direkt auf der jeweiligen Station aufgenommen. Im Anschluss durchlaufen sie gegebenenfalls noch weitere Folgestationen bevor sie entlassen werden. Eine klinikinterne Verlegung kann nur erfolgen, wenn auf der Folgestation ein freies Bett zur Verfügung steht, andernfalls entsteht Wartezeit. Insgesamt wurden im Jahr 2011 23.936 elektive Patienten im Krankenhaus behandelt.

### 3.2 Simulationsmodell

Die vorgestellten Patiententypen dürfen aufgrund der Nutzung gleicher Ressourcen nicht losgelöst voneinander betrachtet werden. Daher wurde ein ereignisdiskretes Simulationsmodell in ARENA 10.0 (Rockwell Software) entwickelt, in dem die Entitäten den Patienten entsprechen. Die Bewegungen der Entitäten im Modell repräsentieren die für die beschriebenen Patiententypen charakteristischen Patientenflüsse. Da das Modell zu umfangreich und zu komplex für eine Abbildung ist, wird die umgesetzte Logik in einem vereinfachten Schema in Abbildung 1 veranschaulicht. Die Pfeile repräsentieren mögliche Bewegungen der Patienten zwischen verschiedenen Einheiten des Krankenhauses. Diese Einheiten stellen Ressourcen in Form von freien Betten zur Verfügung.

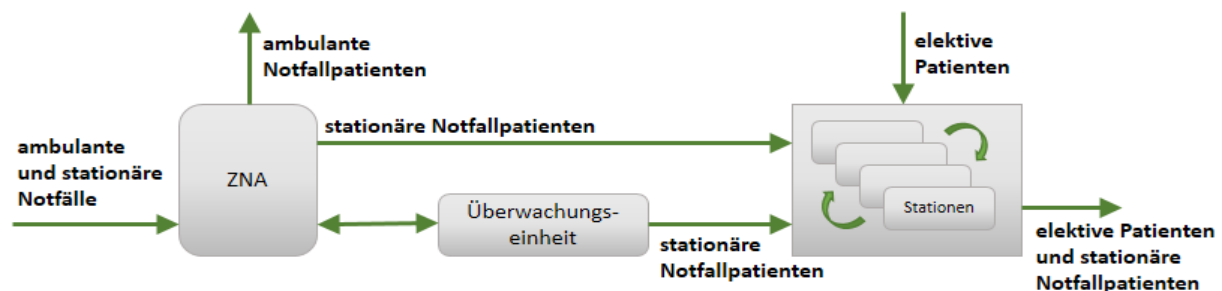


Abbildung 1: Schematische Darstellung der Simulationslogik

Die Bewegung einzelner Patienten im Modell wird durch empirische Verteilungsfunktionen, die sich aus den Ankunfts-, Aufenthalts- und Verlegungsdaten ergeben, bestimmt. Ausgewählte Charakteristika dieser Daten werden im vierten Kapitel beschrieben. Die Patientenflüsse werden ausschließlich mit Ankunfts- und Übergangsverteilungen und losgelöst von Diagnosen und Behandlungen abgebildet. Mit Hilfe dieser Übergangsverteilungen werden die zu durchlaufenden Stationen bei Ankunft der Patienten

in einem individuellen Stationsplan hinterlegt. Dieser Plan wird im Modell sukzessive durchlaufen. Da bei Erstellung ausschließlich Ausgangs- und Folgestationen betrachtet werden, könnten Stationspläne entstehen, die im verwendeten Datensatz nicht dokumentiert sind. Aus Sicht der Gesamtkapazitäten der Klinik wird das Ergebnis davon kaum beeinflusst werden, da mit sehr niedriger und abnehmender Wahrscheinlichkeit Patienten in eine zweite oder dritte Station verlegt werden.

Neben den patientenspezifischen Falldaten wurden für das Simulationsmodell Daten zu Anzahl und Verteilung vorhandener Krankenhausbetten, aufgeschlüsselt nach Stationen und verfügbaren Zimmer erhoben.

Mögliche Bettenengpässe können entstehen, wenn eine Vielzahl stationärer Patienten aus der ZNA zu einer bestimmten Station verlegt werden müssen. In diesem Fall verbringen die Patienten ihre Wartezeit auf der Überwachungseinheit. Diese wird im Modell als Kennzahl „Wartezeit von ZNA auf Folgestation“ gemessen. Wartezeiten bei innerklinischen Verlegungen entstehen ebenfalls durch Bettenengpässe auf der Folgestation. Diese Wartezeit wird durch einen verlängerten Aufenthalt auf der gegenwärtigen Station überbrückt und als „Wartezeit von Station auf Folgestation“ erfasst. Um stationäre Aufnahmen sowie innerklinische Verlegungen auf Stationen realistisch abbilden zu können, müssen wichtige Nebenbedingungen bei der Bettenbelegung in den Einzel- und Mehrbettzimmern berücksichtigt werden. Dies wird mit einer im Modell eingebetteten Heuristik erreicht.

### 3.3 Heuristik für die Bettenbelegung an den Stationen

Voraussetzung einer erfolgreichen Patientenverlegung ist es sicherzustellen, inwieweit die Nachfolgestation in der Lage ist, den Patienten in einem geeigneten Zimmer unterzubringen. Inwieweit ein freies Bett vergeben werden kann, wird vom Krankenhauspersonal koordiniert. Hierbei gilt, dass jedes Zimmer nur mit Patienten des gleichen Geschlechts belegt werden darf. Nur vereinzelt gibt es Stationen, darunter die Intensivstationen, bei denen diese Regelung nicht gilt. Weiterhin müssen Patienten, bei denen ein multiresistenter Keim diagnostiziert wurde, isoliert untergebracht werden. Isolation bedeutet in diesem Kontext die Unterbringung in einem Einzelzimmer oder die alleinige Unterbringung in einem Mehrbettzimmer.

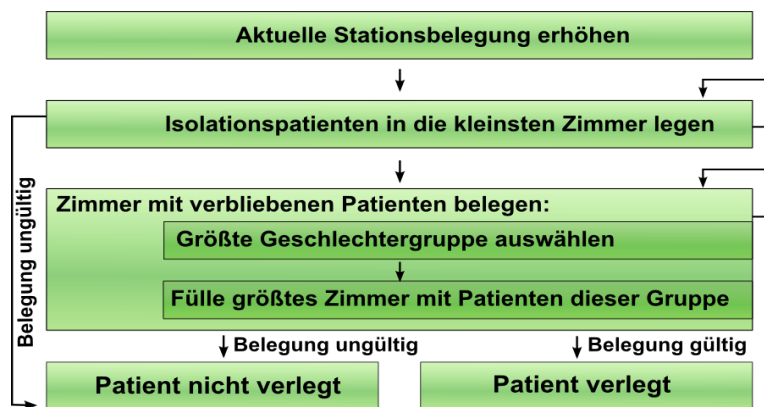


Abbildung 2: Heuristik zur Bettenbelegung

Da im Krankenhausalltag die Bettenbelegung durch Mitarbeiter der jeweiligen Stationen koordiniert wird, wurde eine Heuristik (siehe Abbildung 2) entwickelt, die diesen Entscheidungsprozess realistisch nachbildet. Die hierfür formulierte Heuristik prüft bei jeder Belegungsänderung einer Station, ob es für

die jeweilige Stationsbelegung und die zur Verfügung stehenden Zimmer eine Belegungsvariante gibt, bei der alle Nebenbedingungen erfüllt sind. Hierzu werden die verfügbaren Zimmer einer Station, die gewünschte Stationsbelegung, das Geschlecht sowie der Isolationsstatus des Patienten benötigt. Die Heuristik lässt sich in drei Teilschritte gliedern:

- (1) Alle an einem multiresistenten Keim erkrankten Patienten werden einzeln auf die kleinsten verfügbaren Zimmer verteilt.
- (2) Alle verbliebenen Patienten werden nun auf die übrigen Zimmer, beginnend bei dem größten verteilt. Dabei ist folgendes zu beachten: Sollte es unter den verbliebenen Patienten mehr Männer geben, so wird das größte verfügbare Zimmer mit Männern belegt. Wenn es hingegen mehr Frauen sind, so wird dieses Zimmer mit Frauen belegt.
- (3) Die Heuristik endet, sobald alle Patienten erfolgreich auf entsprechende Zimmer verteilt wurden (gültige Belegung) oder keine freien Zimmer mehr für verbliebene Patienten verfügbar sind (ungültige Belegung). Im Falle einer ungültigen Belegung werden verbliebene Patienten in der Simulation nicht verlegt und es entstehen Wartezeiten.

## 4 Analyse der Patientenfalldaten für die Simulation

Die Informationen bezüglich der Patientenankunft, Aufenthaltsdauer, sowie der Verlegungsprozesse wurden aus einem anonymisierten Falldatensatz des UKH gewonnen. Dieser Datensatz umfasst insgesamt 60.020 Falldaten aus dem Zeitraum vom 01.01.2011 bis zum 31.12.2011. Jede Patientenaufnahme sowie jeder Stationswechsel ist dokumentiert. Im Folgenden werden ausgewählte Charakteristika der Patientenankünfte, der Aufenthaltsdauern und der Verlegungsprozesse vorgestellt.

### 4.1 Patientenankunftsdaten je nach Patiententyp

Um die Anzahl der Patienten pro Tag und Station zu bestimmen, muss sowohl der Wochentag als auch das Geschlecht des Patienten berücksichtigt werden. Abbildung 3 zeigt die Verteilung der Patientenankünfte für elektive Patienten sowie ambulante und stationäre Notfallpatienten im Wochenverlauf. Erkennbar ist, dass elektive Patienten vor allem zu Beginn der Woche bestellt werden. Ambulante Notfallpatienten hingegen werden seltener an Werktagen, sondern meist am Freitagnachmittag sowie am Wochenende behandelt. Bei stationären Notfallpatienten ist eine konstante Ankunftsrate zu erkennen.

Neben dem Wochenverlauf ist eine getrennte Betrachtung der Verteilung männlicher und weiblicher Patienten durchzuführen. Während diese Verteilung für eine Entbindungsstation naturgemäß bekannt ist, sind nicht offensichtlich unterschiedliche Verteilungen in anderen Stationen aufgrund einer realistischen Abbildung der jeweiligen Ankunftsdaten nötig.




Abbildung 3: Wochenverlauf Patientenankünfte je Patiententyp [eigene Darstellung]

Neben den Ankunftsschwankungen innerhalb einer Woche kommt es auch zu Unregelmäßigkeiten innerhalb eines Tages. Abbildung 4 zeigt, dass elektive Patienten vermehrt vormittags bestellt werden. Beispielsweise erreichen 18% aller am Dienstag ankommenden Patienten das Krankenhaus zwischen 10.00 Uhr und 11.00 Uhr. Im Gegensatz dazu zeigt sich bei Notfallpatienten eine andere Tagesverteilung. Sowohl bei ambulanten als auch bei stationären Notfallpatienten kommt es, im Gegensatz zu elektiven Patienten, zu deutlich weniger Schwankungen im Tagesverlauf der Ankünfte. Vergleich man ambulante und stationäre Ankünfte, so fällt auf, dass ambulante Patienten vorwiegend am späten Nachmittag das Krankenhaus erreichen. Lediglich an den Wochenendtagen kommt es vermehrt zu Ankünften am Vormittag. Bei den stationären Patientenankünften lässt sich kein Unterschied zwischen den einzelnen Tagesverläufen feststellen. Die Ankünfte sind vom Vormittag bis zum Abend gleichbleibend.

Die Analyse der Jahresdaten im Wochen- und Tagesverlauf ermöglicht eine realistische stundengenaue Abbildung der Patientenströme in der Simulation. Dieser Detaillierungsgrad erlaubt es, krankenhausweite Verzögerungen im Stunden- bis Minutenbereich zu erfassen.

#### 4.2 Aufenthaltsdauer und Patientenentlassung im Wochenverlauf

Neben den Ankunftsdaten wurde die Aufenthaltsdauer der Patienten auf den Stationen analysiert. Vergleicht man die durchschnittliche Verweildauer verschiedener Stationen, so können hier starke Unterschiede beobachtet werden. Dies kann mit der medizinischen Ausrichtung einer Station und dem hiermit verbundenen Schweregrad der behandelten Krankheiten begründet werden. Konkret wurden Verweildauern von durchschnittlich 1,32 bis zu 10,4 Tagen festgestellt.

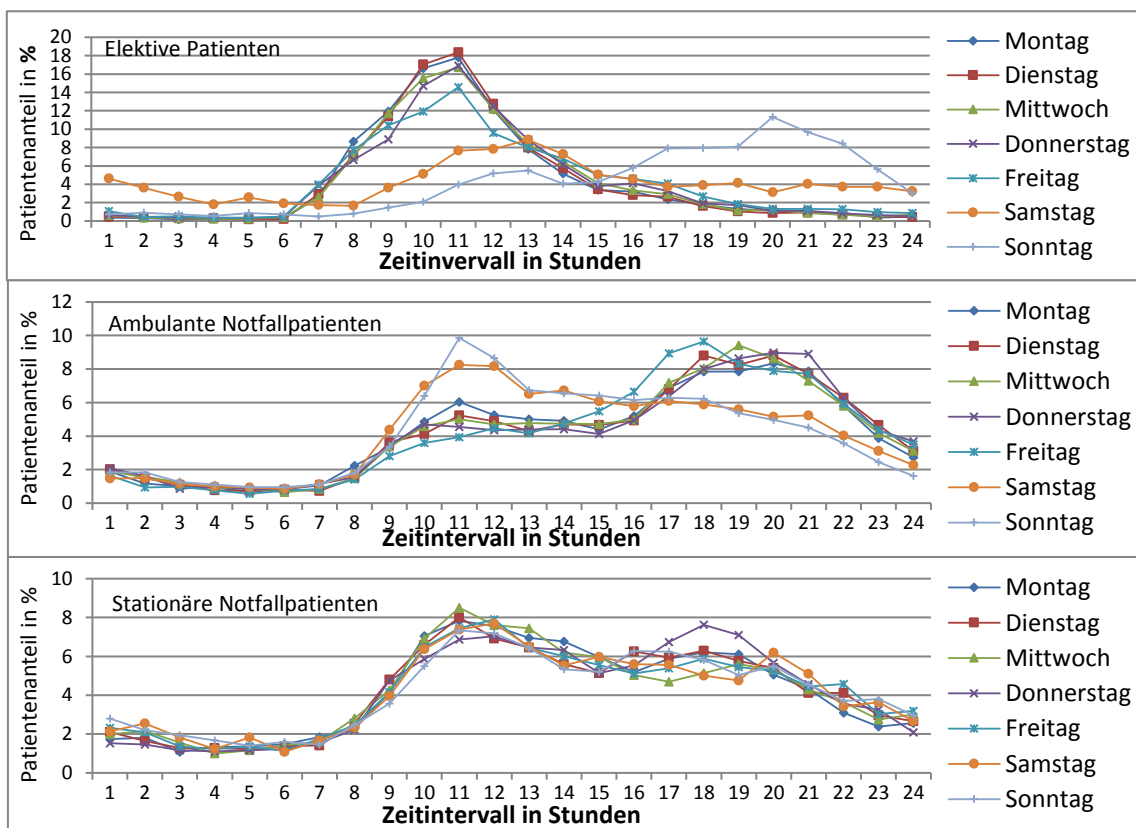


Abbildung 4: Tagesverlauf Patientenankünfte je Patiententyp [eigene Darstellung]



Das Ende eines Stationsaufenthaltes, bestimmt den Entlassungs- bzw. den Verlegungszeitpunkt eines Patienten. Hier ist zu beachten, dass, falls der Patient im Anschluss seines Stationsaufenthaltes entlassen werden soll, der Stationsaufenthalt tendenziell an einem Werktag und seltener an einem Wochenende endet. Dies wird in Abbildung 5 anhand von fünf gewählten Beispielstationen deutlich. Es ist zu erkennen, dass der Anteil der Entlassungen zum Freitag leicht steigt und anschließend deutlich abfällt, wodurch am Sonntag nur ca. 5% aller Entlassungen stattfinden.




Abbildung 5: Patientenentlassungen im Wochenverlauf [eigene Darstellung]

Die Verweildauer, wie sie im Krankenhausinformationssystem erfasst wird, setzt sich aus dem eigentlichen Stationsaufenthalt und einer eventuell entstandenen Wartezeit zusammen. Im Simulationsmodell soll die Wartezeit jedoch nicht als Eingabegröße einfließen, sondern später als Ergebnisgröße gemessen und zum Szenarienvergleich herangezogen werden. Bei der Berechnung einer Patientenverweildauer musste daher sowohl der Entlassungstermin, als auch die in der Verweildauer eingeschlossenen Wartezeit berücksichtigt werden.

### 4.3 Verlegungsprozesse

Um die Verlegungsprozesse eines Patienten korrekt abbilden zu können, wird für jeden Patienten ein individueller Stationsplan erzeugt. Dazu wurde ausgehend von der ersten Station eines Patientenfalls die Verteilung der insgesamt zu durchlaufenden Stationen bestimmt. Um die Art sowie die Reihenfolge der zu durchlaufenden Stationen zu bestimmen, wurden Übergangswahrscheinlichkeiten für alle Stationspaaren bestimmt. Dabei ergab die Datenanalyse, dass die Zielstation durch die aktuelle Station sowie durch das Geschlecht des Patienten beeinflusst wird. Beispielsweise werden ca. 41,7% aller männlichen Patienten von Station 2, sollte eine Verlegung stattfinden, im Anschluss auf Station 3 weiterbehandelt.

## 5 Szenarien flexibler Bettenbelegung zur Verringerung der Wartezeiten

Im Rahmen der Studie haben die Autoren zusammen mit Mitarbeitern der ZNA sowie der zentralen Pflegeforschung des UKH drei, teils bereits im Klinikum diskutierte und teils von den Autoren gestaltete Szenarien entwickelt. Zusätzlich zu der Forderung des UKH, eine ganzheitliche Betrachtung der Klinikumsprozesse zugrunde zu legen, wurden bei der Entwicklung der Szenarien neben der Reduktion von Wartezeiten folgende Ziele verfolgt:

- Freie Kapazitäten an den Stationen sollen besser genutzt werden können und somit eine bessere Auslastung unter Beachtung aller Patientenflüsse ermöglichen.
- Es sollen nur Strategien und Verbesserungsmaßnahmen in Erwägung gezogen werden, die geringe Anpassungen von Prozessen und Strukturen voraussetzen.
- Szenarien sollen nach Möglichkeit investitionsarm und mit wenig Aufwand umsetzbar sein.

Mit Blick auf die genannten Anforderungen konnte in Diskussionen mit dem UKH-Personal die Idee einer Flexibilisierung der Belegung entwickelt werden. Dabei wurden drei mögliche Formen flexibler Belegungen identifiziert, welche zu folgenden drei umsetzbaren Szenarien geführt haben:

[S1] Flexible Belegung durch Zimmerverleih an räumlich angrenzende Stationen,

[S2] Flexible Belegung durch Zusammenführung der ITS- und IMC-Stationen und

[S3] Flexible Belegung durch Einführen einer Früh-Reha als Endphase stationärer Behandlung

Unter Betrachtung der allgemeinen Struktur der Patientenflüsse, zielt Szenario [S3] auf die Schaffung freier Kapazitäten durch eine Entlassung bestimmter Patientengruppen in die Früh-Reha am Ende des Patientenflusses ab. Dadurch könnte die Verweildauer auf den entlassenden Stationen verkürzt werden. Dies ist aus Ressourcensicht des UKH sinnvoll, da die gewonnen Kapazitäten für weitere elektive und stationär übernommene Notfallpatienten verwendet werden können. Allerdings ist das Einführen einer solchen Station medizinisch aufgrund der Vielfalt von zu behandelnden Krankheitsbildern und den daraus resultierenden hohen Anforderungen an das eingesetzte Personal umstritten. Effektiv umsetzbar ist dies nur durch eine eigens dafür eingesetzte Station [12].

In Szenario [S1] können Engpässe durch den Verleih nicht genutzter Zimmer von räumlich angrenzenden Stationen vermieden werden. Insgesamt wurden vom Krankenhaus acht potentielle Tauschpartner identifiziert. Dies hat im Gegensatz zu [S3] Vorteile in allen Phasen des Patientenflusses, insbesondere zur Überwindung stochastisch verteilter zeitlich beschränkter Engpässe. Weiterhin wird dieser Pooling-Ansatz bereits in einigen Stationen des UKH umgesetzt. Aufgrund der Befürchtung, dass durch den Zimmerverleih für einen der Tauschpartner Ressourcenengpässe entstehen könnten, lehnen manche Stationen diesen Ansatz bisher jedoch ab.

Ziel des Szenarios [S2] ist das Pooling aller ITS- sowie aller IMC-Stationen (Intensivtherapie- und Intermediate-Care-Stationen). Dadurch werden bei Zimmern mit hohen Personal- und Ressourcenkosten Kapazitätsengpässe innerhalb wichtiger Phasen der Patientenflüsse, z.B. in postoperativen Phasen, abgebaut. Die Einführung zentraler ITS- und IMC-Stationenpools [S2] wird aktuell im UKH diskutiert und ist gängige Praxis in kleineren Kliniken [1]. Dies hätte den Vorteil, dass die verfügbaren Bettenkapazitäten gebündelt werden und dass bei Verlegungen aus der ZNA auf ein ITS- oder IMC-Bett direkt in den Pool verlegt werden kann. Als nachteilig werden die nötige interdisziplinäre Versorgung und die damit einhergehenden Anforderungen an Personal und Ausstattung angesehen.

## **6 Simulationsergebnisse und weiterer Forschungsbedarf**

Die folgenden Simulationsergebnisse stammen aus Simulationsläufen mit der Dauer eines Jahres. Die Modellvalidierung erfolgte durch den Vergleich der Messwerte des simulierten Ist-Zustandes mit den Vergleichswerten aus dem Falldatensatz des Jahres 2011. Zur Auswertung der Szenarien [S1], [S2] und [S3] wurden die zuvor ermittelten Messwerte des Ist-Modells mit den durch die Simulation ermittelten Messwerten der Szenariokonfigurationen verglichen.

### **6.1 Validierung des Simulationsmodells mit Jahresdaten des UKH**


Am Beispiel der Patientenzahl, der Verweildauern und der Ankunftsverteilung stationärer Notfallpatienten wird ersichtlich, dass das Modell die Realität mit hinreichender Genauigkeit widerspiegelt. Tabelle 1 zeigt, dass die Anzahl ambulanter und stationärer Patienten im Simulationsmodell nur geringe Abweichungen gegenüber den Vergleichswerten aufweisen. Lediglich elektive Patienten sind mit einer

Abweichung von -15,6% deutlich unterrepräsentiert. Da elektive Patienten im Simulationsmodell stochastisch erzeugt werden, im Realsystem jedoch geplant und vorhersehbar sind, wurde die Anzahl elektiver Patienten bewusst verringert um diesem Effekt entgegenzuwirken.

	Vergleichswerte Falldatensatz 2011	Messwerte Ist-Modell
Elektive Patienten	23.936	20.185,63
Ambulante Notfallpatienten	26.366	25.682,03
Stationäre Notfallpatienten	9.718	9.781,2

**Tabelle 1: Validierung der Patientenzahlen je nach Patiententyp [eigene Darstellung]**

Neben den Ankunftsdaten zeigt sich auch bei den Verweildauern eine Überstimmung mit den Messwerten des Ist-Modells. Da sich die Verweildauer, wie sie in Kapitel 4 beschrieben wurde, aus dem Stationsaufenthalt und einer eventuell entstandenen Wartezeit zusammensetzt, musste die Verweildauer im Simulationsmodell auf dieselbe Art erhoben werden. Das linke Diagramm in Abbildung 6 zeigt, dass die gemessenen Verweildauern mit den gegebenen Werten im Mittel übereinstimmen.



**Abbildung 6: Validierung der Stationsverweildauer [eigene Darstellung]**

Am Beispiel der stationären Notfallpatienten soll im letzten Schritt gezeigt werden, dass die Ankunftsverteilungen, wie sie in Kapitel 4 beschrieben wurden, korrekt umgesetzt werden konnten. Das rechte Diagramm in Abbildung 6 zeigt den durchschnittlichen Tagesverlauf stationärer Patientenaufnahmen in der ZNA. Es ist zu erkennen, dass die gemessenen Werte des Simulationsmodells den tatsächlichen Verlauf der Ankünfte sehr gut abbilden.

## 6.2 Simulation und Evaluation von Veränderungsszenarien für die UKH

Das validierte Simulationsmodell konnte anschließend für eine zuverlässige Evaluation der drei Szenarien angewendet werden. Dabei hatten [S1] und [S2] einen größeren Einfluss auf die Verringerung der Wartezeiten als [S3]. Bei den für die Früh-Reha in Frage kommenden Patientengruppen ergaben die Analysen, dass diese Gruppen selten in Engpassstationen auftraten, sodass die Wartezeiten auf der Bettenstation der ZNA sowie auf den Stationen vor klinikinternen Verlegungen nur geringfügig reduziert wurden.

### Zimmerverleih-Szenario [S1]

In Abbildung 7 sind die Tauschpaare räumlich angrenzender Stationen, die mittleren Wartezeiten eines Patienten bei Verlegung von einer Station auf eine andere sowie die Wartezeit bei stationärer Aufnahme von der ZNA dargestellt. Aus dem Vergleich dieser Wartezeiten zwischen Ist-Modell und [S1] wird

ersichtlich, dass die Wartezeit bei stationären Verlegungen um bis zu 10 Stunden verringert werden konnte. Die Wartezeit auf stationäre Übernahme von der ZNA konnten ebenfalls um bis zu 50% verringert werden. Die befürchtete Benachteiligung einzelner Tauschpartner trat nicht ein.




Abbildung 7: Wartezeiten im Szenario S1 [eigene Darstellung]

### Zusammenführung zentraler ITS- und IMC-Stationen [S2]

In Abbildung 8 sind die mittleren Wartezeiten eines Patienten bei einer Verlegung zwischen Stationen. Ohne Zusammenlegung der ITS- und IMC-Stationen bildeten sich Bettenengpässe, die dazu führten, dass in einem Jahr ca. 1.170 Patienten auf eine Nachfolgestation warten mussten. Die Wartezeit betrug hier bis zu 20,7 Stunden. Werden ITC- und IMC-Stationenpools gebildet, entstehen keine Wartezeiten mehr an den entsprechenden Stationen. Ein negativer Einfluss auf andere Stationen konnte nicht festgestellt werden. Für die Überwachungseinheit, die Notfallpatienten bei Engpässen nachfolgender Stationen aufnimmt, bedeutet dies ebenfalls eine Entlastung. Auch hier können, wie in Abbildung 8 dargestellt, die Wartezeiten vollständig abgebaut werden.




Abbildung 8: Wartezeiten im Szenario S2 [eigene Darstellung]

### 6.3 Fazit und weiterer Forschungsbedarf

Das in diesem Aufsatz entwickelte Simulationsmodell für stationsübergreifende Patientenflüsse wurde anhand der verfügbaren Jahresdaten des UKH erfolgreich validiert. Die Evaluation der in Zusammenarbeit mit dem UKH entwickelten Szenarien flexibler Bettenbelegung zeigte eine deutliche Verringerung der Wartezeiten und Verweildauern. Die Ergebnisse bei Einführung eines zentralen ITS- und eines IMC-Pools zeigen, dass das Pooling von ITS und IMC auch für größere Kliniken deutliches Potential besitzt. Die Vorurteile einseitiger Vorteilsnahme und möglicher entstehender Engpässe im Zimmerverleih-Szenario [S1] konnten ausgeräumt werden. Die Einführung einer zentralen Früh-Reha ist unter den analysierten Umständen in Hinblick auf den zu erwartenden hohen Einführungsaufwand und die geringen Auswirkungen auf die Wartezeit nicht zielführend.

Die gewählte Modellierung der Patientenflüsse auf Basis von Übergangsverteilungen ist ausreichend, um Verbesserungsmaßnahmen, die den krankenhausesweiten Patientenfluss betreffen, zu evaluieren.

Nicht im Datensatz dokumentierte Stationspläne beeinflussten die Validität des Modells nicht. Da bei der Modellierung ausschließlich routinemäßig erfasste Falldaten verwendet wurden sowie auf die Modellierungen krankenhausspezifischer Logik verzichtet wurde, kann das Modell mit wenigen Anpassungen für Kliniken mit ähnlicher Struktur und ähnlichen Fragestellungen angewendet werden.

Die genannten Ergebnisse wurden dem Klinikvorstand präsentiert, der einen Mehrwert für die Entscheidungsfindung im Klinikum durch unsere Simulationsanalysen anerkannte und anregte, die Simulation mit vorliegenden aktuellen Daten und der Berücksichtigung der fachlichen Kompatibilität bei den Szenarien flexibler Belegung durchzuführen. Vor einer Umsetzung in die Praxis sind genauere pflegerisch-therapeutischen Analysen durchzuführen, um potentielle kompatible ITS- und IMC-Stationen zu identifizieren. Des Weiteren soll das Szenario flexibler Belegung durch Zimmerverleih in aktuelle Gedanken zur Bildung fachlicher Cluster im UKH integriert werden. Wir haben angeregt, dass alle Paare fachlich kompatibler Partner vom UKH bestimmt werden. Die optimalen Cluster können dann durch unsere um Wiederverwendbarkeit und Objektorientierung verbesserten Simulationsmodelle verknüpft mit einer Optimierungskomponente (vgl. Kapitel 9.5 in [14]) bestimmt werden. Ob die Einführung einiger auf bestimmte Krankheitsbilder spezialisierter Früh-Reha-Stationen sinnvoll ist und welche Krankheitsbilder sich für diese Stationen am besten eignen, bleibt ebenfalls Gegenstand weiterer Forschung.

## 7 Literatur

- [1] Aken, H.K. van (2007): *Intensivmedizin*. G. Thieme.
- [2] Baboolal, K., Griffiths, J.D., Knight, V.A., Nelson, A.V., Voake, C. and Williams, J.E. (2012): How efficient can an emergency unit be? A perfect world model. *Emergency Medicine Journal*
- [3] Brailsford, S.C., Harper, P.R., Patel, B. and Pitt, M. (2009): An analysis of the academic literature on simulation and modelling in health care. *Journal of Simulation*. 3(3): 130–140.
- [4] Coughlan, J., Eatock, J. and Patel, N. (2011): Simulating the use of re-prioritisation as a wait-reduction strategy in an emergency department. *Emergency Medicine Journal*. 28(12): 1013–1018.
- [5] Eldabi, T., Paul, R.J. and Young, T. (2006): Simulation modelling in healthcare: reviewing legacies and investigating futures. *Journal of the Operational Research Society*.
- [6] Günal, M.M. (2012): A guide for building hospital simulation models. *Health Systems*. 1(1): 17–25.
- [7] Günal, M.M. and Pidd, M. (2010): Discrete event simulation for performance modelling in health care: a review of the literature. *Journal of Simulation*. 4(1): 42–51.
- [8] Jacobson, S.H., Hall, S.N. and Swisher, J.R. (2006): Discrete-event simulation of health care systems. *Patient flow: reducing delay in healthcare delivery*. Springer. 211–252.
- [9] Jun, J.B., Jacobson, S.H. and Swisher, J.R. (1999). Application of Discrete-Event Simulation in Health Care Clinics: A Survey. *The Journal of the Operational Research Society*. 50(2): 109–123.
- [10] Klein, R.W. and Dittus, M. (1993): Simulation Modeling and Health-care.
- [11] Mustafee, N., Katsaliaki, K. and Taylor, S.J.E. (2010): Profiling Literature in Healthcare Simulation. *SIMULATION*. 86(8-9): 543–558.
- [12] Reißhauer, A., Liebl, M. and Pögel, S. (2011): Fachübergreifende Frührehabilitation – Warum im Akutkrankenhaus? *Physikalische Medizin, Rehabilitationsmedizin, Kurortmedizin*. 21(06): 280–283.
- [13] Statistisches Bundesamt 2013. Pressemitteilung vom 4. April 2013 – 128/13 Gesundheitsausgaben im Jahr 2011 bei rund 294 Milliarden Euro.
- [14] Suhl, L. and Mellouli, T. (2013): *Optimierungssysteme: Modelle, Verfahren, Software, Anwendungen*. Springer.

## **Anhang C: A Generic Simulation-based DSS for Evaluating Flexible Ward Clusters in Hospital Occupancy Management**

Helbig K, Stoeck T, Mellouli T (2015b)

In: 48th Hawaii International Conference on System Sciences (HICSS); IEEE 2015b, 2923–2932

## Generic Simulation-based DSS for Evaluating Flexible Ward Clusters in Hospital Occupancy Management

Karsten Helbig<sup>1</sup>  
karsten.helbig@wiwi.uni-halle.de

Thomas Stoeck<sup>1</sup>  
thomas.stoeck@wiwi.uni-halle.de

Prof. Dr. Taïeb Mellouli<sup>1</sup>  
mellouli@wiwi.uni-halle.de

<sup>1</sup>Department of Management Information Systems and Operations Research, Martin-Luther-University Halle-Wittenberg

### Abstract

*Hospitals facing competitive pressure, a fortiori unprofitable ones, should improve their efficiency. We propose low-investment opportunities uprating patient treatment by tactically implementing hospital-wide occupancy clusters raising bed resource allocation flexibility. We develop a generic simulation-based DSS to evaluate cluster configurations for a 1000+ bed university hospital. Besides current state of bed resources and patient flow, prospective scenarios with less beds—raising their utilization rate—and with 50% more elective patients are evaluated.*

*Our data-driven DSS generates entire simulation models automatically from standard hospital data. Practical constraints like gender room separation and isolated infections treatment prevent underestimating bed requirements. Results show that clustering softens patient arrival peaks and induces dramatic reduction of bed bottleneck for all cluster configurations; yet more than 96% when including an internal medicine cluster. Doubling this cluster's size and introducing an interdisciplinary eleven wards surgery cluster induce the best-performing cluster configuration for bottleneck less-resource and more-patient scenarios.*

### 1. Introduction

Health is the most valuable asset for humans. Keeping people healthy, however can become a difficult and expensive task, especially when focussing on hospital costs. These costs have been rising in Germany since 1990. According to rating reports of 2013, at least one third of all hospitals make a loss [1,4]. In order to break this trend, the German government decided to change the way hospitals earn their money. Since 2003 the diagnostics related groups payment system (DRG) is established. Since then,

each German hospital earns an amount of money for each patient case which is computed by the treatment costs of benchmark hospitals. If the costs of treating patients are higher than in the benchmark hospitals, the hospital has to improve their efficiency or may become insolvent after some time [19].

One way to improve efficiency is managing the occupancy of *the most expensive resource*—inpatient beds [3], since most of medical and administrative resources is dependent on treatment (bed) capacity. Only with this, an effective patient flow management is possible [18]. Without this, hospitals have to face higher lengths of stay (LOS), idle expensive resources and bottlenecks within patient care [26].

In our previous simulation study on reducing waiting time of admission from the emergency department (ED) to an inner ward, we figured out that one very promising way of improving efficiency of occupancy management is to increase bed resource flexibility. For the University Hospital Halle (Saale) we achieved more flexibility by allowing patients to be admitted to a cluster containing all intensive care units (ICU) on the one hand and on the other hand allowing wards to borrow rooms from other wards nearby [11]. Encouraged by our findings, the hospital management decided to implement ward clusters to improve the flexibility of bed allocation and avoid bottlenecks in ICU and ED.

A cluster is defined as an amount of wards (hospital units or departments) which are able to nurse all kinds of patients of each single other ward of the cluster. Because of that, if the actual ward has no idle bed capacity, it is possible to admit a patient to another ward on the cluster. E.g. if a patient has an eye disease and the actual ward has no idle bed, each other ward of the corresponding head cluster is able to admit him. Without the cluster, the patient would have to wait or be rejected in the worst case.

Because of the complexity and the high amount of dependencies within hospital processes, changes are full of risk and uncertainty. That is why DSS (decision support systems) are needed to evaluate possible consequences of different occupancy policies [20].

With respect to existing literature on using simulation in the hospital context in general and supporting occupancy decisions in particular, this article pursues three main goals: **First** we will develop a simulation model which is able to simulate the whole patient flow of a hospital in order to evaluate three given cluster configurations. **Second** we will show, that practical constraints like gender separation in rooms and isolated nursing of patient with infectious illnesses have to be added to models for hospital occupancy decision support. **Third** we will show how our model can be integrated in a data driven decision support system for easy reuse within other hospitals.

In order to describe our current results, this paper is structured as follows: In the second section, we discuss the current state of the art of using discrete event simulation (DES) in hospitals generally, in occupancy management context in particular and derive the research gaps. Based on this, we show in the third section our concept of a simulation-based data driven decision support system. In the fourth section, we describe the three cluster scenarios which have to be evaluated. In fifth section, we show our results and discuss the consequences for the hospital. At the end we give a short summary and an outlook on further research opportunities.

## 2. Related Work

The use of discrete event simulation (DES) has a long tradition in the hospital context. Based on studies of scientific articles of the past 40 years *Jacobson et al.* conclude: “Discrete-event simulation offers perhaps the most powerful and intuitive tool for the analysis and improvement of complex health care systems” [12]. This statement is underlined with a big number of surveys [5,8,9,12,13,16,21,24] showing, that nearly every hospital related aspect has been investigated successfully. DES is mostly used for operational decision support like deployment, resource utilization or occupancy management [7,8,16].

Regarding to the large amount of literature, the low practical and theoretical benefits [7,8] question the sense of simulation studies in hospital context in general. “[...] there is no general sense of the literature moving forwards, because many papers tend to be reports of rather similar work on rather similar problems”[8]. Most of the studies are focusing isolated

hospital departments, but this could be misleading with regard to the strongly complex and interdependent processes in hospitals [7,8,12].

To end this stagnancy in simulation science in hospitals, future studies should contain models that encompass the hospital and the relevant processes at whole, should lead to universal findings and practical benefit and could be reused or easily adapted to similar problems [7,8,9].

Particularly occupancy management is involved in nearly every hospital process [22]. Furthermore, *Black and Pearson* call inpatient beds “the most expensive resource” [3]. Based on this it is not surprising that there are a lot of articles focusing on the inpatient bed resource.

Because of the strong interdependencies between the wards of a hospital, only an approach which models more than one department, or the hospital as a whole could lead to valid results on bed capacity [23]. For this purpose we focus on related work that fulfill that condition.

*Kim et al.* used a simulation model to analyze the admission and discharge process of an intensive care unit (ICU). The authors successfully developed a simulation model that supports hospital’s administration to evaluate different policies for improving the ICU performance, show that the current capacity of 14 beds is sufficient at the current patient arrival rates and found some initial inferences how ICU performance could be improved generally by pointing to the managerial aspects and showing that the ICU’s capacity is not as important as the management of the other wards and its admission procedures [15].

In 2002 *Harper und Shahani* have shown that employing simple deterministic spreadsheet calculations to plan and manage bed capacities leads to underestimate true bed requirements. A realistic approach has to consider various types of patient flows at individual patient level and resulting bed needs over time. They underline that capturing the inherent variability of different length of stay distributions are important to develop planning tools for hospital capacities [10]. This confirms that misleading planning models are based on average length of stay, homogenous movement of patients through the system and ignoring the inherent heterogeneity of patients [25].

*Costa et al.* use simulation to estimate the number of required beds. The developed model is able to consider different admission criteria, priorities and expected lengths of stay based on the hospital’s own data. The authors underline this as the main strength of their approach [6].

*Kolker* developed a simulation model to figure out how many elective surgeries should be scheduled per day in order to reduce diversion in the ICUs. He shows



that for his specific 450+ bed teaching hospital a tradeoff between five surgeries per day with no length of stay less than 24 h would be best. In order to solve these kind of problems in general, *Kolker* describes three basic components that should be accounted for: the number of patients entering the system, the number of patients leaving the system and the capacity which limits the flow of patients through the system [17].

*Khare et al.* used a simulation model to show that altering the interval of admitted patient departure from the ED has more effect on length of stay than increasing the capacity of the ED [14].

*Barado et al.* analyzed patient data of 9 years and build a mathematical simulation model that is able to show the bed occupancy dynamics of the ICU at the Hospital of Navarra. The authors successfully developed a tool which is able to predict the bed occupancy rate and evaluate changes in patient admission factors like number of admissions of other hospital wards. They used their model to predict the number of beds needed in the ICU considering up to 50% more patient arrivals [2].

As mentioned in Section 1, we have developed a simulation model of a whole hospital to evaluate the effects on waiting time for patient admission from ED to inpatient wards of a university hospital with approx. 1000 beds in 2014. We analyzed hospital own data to model gender specific patient flows. In our results we found out that increasing flexibility by implementing occupancy clusters of ICU or the possibility to borrow rooms from other wards strongly reduces waiting time. Like [2,14] we could show that one key of increasing hospital performance is a more flexible occupancy management [11].

Encouraged by our findings in [11], the hospital management decided to implement occupancy clusters in the whole hospital and asks advice and assistance of our institute concerning simulation and evaluation.

Regarding to the related work on using simulation for decision support in occupancy management in particular and the critique on simulation based approaches in general, we address the following gaps: pursue a holistic view of the process through the hospital influencing occupancy management. For this we model the whole hospital and all necessary processes to evaluate different occupancy policies and we add practical room occupancy constraints in order to not underestimate bed capacity requirements. No other study takes these kind of constraints into account and we believe that our study will prevent producing misleading results as using average length of stay or homogenous patient flows [10,25].

Finally, we show a decision support system which is able to generate the model including structure and required distributions automatically by using hospital

own data. Because of this data driven approach we reach a new level of generality which is beyond simple change of model parameters. We believe this kind of architecture is necessary to ensure easy reusability and adaptability of the simulation model to other hospitals.

### 3. Data Driven Decision Support System

#### 3.1. Architecture

In order to build a reusable and extendable information system we choose a modular approach. Basically the system consists of three modules which are independently interchangeable. The basic structure is shown in Figure 1. In this proposal we use a data processing component, a simulation component and a central database.




Figure 1. Structure of the information system

The central database stores the raw data provided by the hospital and the generated data needed by the simulation component. We implemented a MySQL database to ensure that the other components are able to access the stored data. For a more detailed view of the data needed, see Section 3.2.

Once the data is provided in a predefined format the data processing component is able to generate empirical distributions and other control data used by the simulation component. A short presentation of the distributions is given in Section 3.3. With the use of our data processing unit the only requirement to create all distributions is to load the hospital data into our database and push a button.

We decided to use the Simio simulation software to implement the simulation component because of it's strictly object oriented modelling approach. Every part of the created model is an object with its own logic. Furthermore, the basic simulation logic and the behavior of the simulation model is determined by the interaction of the objects. We use the standard interface to a MySQL database in order to pass empirical distributions and control data to the

simulation model. For a detailed look at the simulation model see Section 3.4.

The architecture of our proposed system provides various options for adaptation and reuse. First, the proposed decision support system provides customization options at the architecture level. Changes can be carried out with reasonable effort due to the modular structure of the system. If parts of the system are changed it does not affect the other components as long as the new components provide an interface to the database. If we want to change the simulation model, we have to ensure that the new model uses the same distributions and control data. Otherwise we have to alter the data processing unit and the database too.

Furthermore this implementation is independent from the observed hospital, because we can use generic objects to automatically build the simulation model with the help of the provided data. So if we want to use this system to evaluate another hospital we only have to load the new data and start the system.

In general, our system offers a simple process to evaluate different scenarios in different hospitals. This process consists of six steps that are independent from the hospital investigated (see Figure 2). First, the user has to store the raw data in the database. After that, he uses the data processing component in order to generate distributions and control data. With help of this data the simulation component automatically generates a model and the user is able to configure the scenarios he wants to evaluate. After running the model, he is able to evaluate the generated outputs.

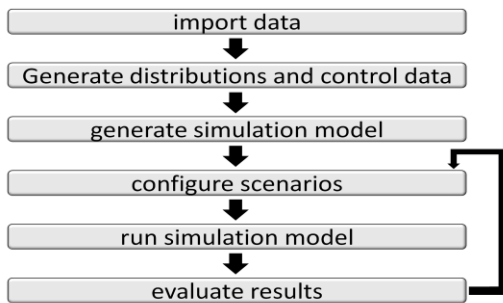


Figure 2. Process of DSS usage

### 3.2. Data

In order to generate the distributions and the simulation model, input data provided by the hospital is needed. To ensure an easy-to-use system, we focused on simple data every hospital should record or should have access to. Building the model is based on infrastructure data and patient data of a hospital. To generate a model, we only need a list of wards and a

list of available rooms according to the wards and the amount of beds in each room (see Table 1).

Infrastructural data		
wards	rooms	amount of beds

Table 1. Required infrastructural data

Patient data we need is a record about every patient case passing the considered wards. If a patient visits four wards during its treatment at the hospital we need four records of this particular patient. Once more we focus on data which should already be recorded at the hospital like gender, LOS or whether this patient has an infectious illness (e.g. multi-resistant germs). The structure of patient data needed is shown in Table 2.

Patient data			
ID	time of admission	ward	LOS
Gender	time of discharge	previous ward	infectious

Table 2. Required patient data

For German hospitals, all these data can be found in the billing data set every hospital is obliged to create once a year due to the §21-KHentgG.

### 3.3. Data processing and distributions

The data described in the previous section is needed to generate empirical input data distributions. These distributions are mainly used to control the patient flow in the simulation model. In order to generate the distributions we use the data processing unit. Hence we calculate the number of arrivals for each day of week and arrival times. Additionally, we generate several other distributions describing for example the length of stay or the next ward a patient has to be transferred to. An overview of the distributions used in the simulation is given in Table 3.

Each presented distribution is conditioned on certain attributes. For example the distribution of the next ward depends on the gender of the patient and on the current ward. Because of that we have to calculate a distribution for the next ward for every ward and every gender. Furthermore we did not notice any seasonal fluctuations in arrivals or other data. Thus, we decided to generate these distributions to fit a representative week. A more detailed presentation of the distributions and their relationships is given in our previous study [11].

distributions for arrival		
nr	name	conditioned on
1	number of arrivals	ward, day of week
2	number of arrivals ED	day of week
3	time of arrival	ward
4	time of arrival ED	day of week
distributions for patients		
nr	name	conditioned on
1	gender distribution	ward
2	gender distribution ED	
3	infectious	ward
4	infectious ED	
5	number of wards to visit	ward, gender
6	number of wards to visit ED	gender
distribution for wards		
nr	name	conditioned on
1	next ward	ward, gender
2	LOS	ward, day of week
3	LOS ED	gender

Table 3. Distributions needed by simulation

### 3.4. Simulation model

To achieve our main goal, to develop a hospital-wide simulation model for evaluating occupancy cluster configurations, we implemented a simulation model based on two inpatient flows. The flow of emergency patients and the flow of elective patients. The difference between these groups of patients is the starting point in the hospital. Emergency patients start their treatment unplanned in the ED, whereas elective patients can be scheduled and are directly admitted to a ward. At the ward, both patient groups compete for hospital beds. A schematic overview of the considered patient flows is given in Figure 3.




Figure 3. Patient flows

The presented patient flows were implemented in an object-oriented simulation model. Basically, this model consists of four custom objects we have developed using Simio. These objects represent the different departments of the hospital: hospital entrance, ED, ward and hospital exit, see Figure 4. The first object is the hospital entrance. Here the patients are generated and properties for each patient are set. Based on the computed distribution within the

database each patient has the following set of properties: gender, infectious germ status and whether he is an elective or an emergency patient. Second, there is an object which describes the ED. The other components include the wards and the hospital exit. In the ED or at the wards, patients are treated.<sup>7</sup> The hospital exit is used to collect several statistics. These objects altogether form the hospital which contains an additional allocation heuristic.

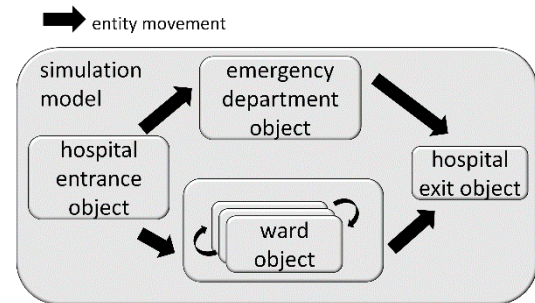


Figure 4. Model structure

A special feature of using an object oriented modelling approach is that the generated objects contain the processing logic. In our case the treatment process is encapsulated in the ward object. Basically, a patient is admitted to a ward, gets a treatment and is then discharged from the hospital or transferred to another ward. With these ward objects and the computed distributions we can easily create our model automatically. Furthermore the concept of object oriented programming offers additional concepts like inheritance or composition. For example, changing the behavior of some wards is easily be done by inheritance. In that case a new type of ward object will be created including some new logic without altering the original ward object. As stated before in Simio the simulation model itself is an object. Because of that we are able to build models of different hospitals and compose them to a model of a hospital infrastructure of a city for example. This can probably be done with reasonable effort.

To ensure a maximal possible number of patient allocations meeting all practical constraints on a ward after patient relocation, which is actually carried out by the hospital staff in practice, we implemented a separate patient room allocation heuristic. We consider two special constraints during the relocation, namely gender separation in rooms and isolation of infectious patients. The heuristic is triggered every time a patient should move to a new ward, to find a valid bed allocation on this ward. It consists of the following three steps:

<sup>7</sup> In detail, the ED object is an inherited ward object without any special characteristics so far. We created it as proof-of-concept.

1. All patients with an infectious disease are isolated distributed to the smallest rooms.
2. All remaining patients are distributed to the other rooms starting with the largest room: (case 2.a) if there are more men among the remaining patients, the largest available room is occupied by men. (case 2.b) If there are equal or more women, the next largest room will be occupied by women.
3. The heuristic ends if all patients were successfully distributed (valid assignment) or if no more rooms are available for the remaining patients (invalid assignment). In that case the heuristic fails.

If the heuristic fails, all patients that could not be assigned to a valid bed will be assigned to a **virtual bed** instead. We decided to use this concept because of the following reason: The provided data for the LOS on a ward consists of medically necessary stay time and a possible waiting time on relocation. Unfortunately, there is no possible way separate these times from the total LOS. If the patient in our model would have to wait for relocation, his LOS will be greater than in reality. In other words, the patient has to be relocated in the model after his LOS has been reached, because in reality this happened too. But where should the patient be located in reality when

In addition the model can be used for different scenarios. Through changing the control data and model settings several scenarios can be combined. The proposed model enables the user to combine a clustering of wards with other scenarios. Thus, opportunities for capacity reduction, for increasing the number of patients and the change of admitting rules are offered. These possibilities can be freely combined.

#### 4. Occupancy Cluster Configurations

The University Hospital Halle (Saale) consists of 47 wards and one ED. The hospital has a total number of approx. 1,000 beds and approx. 33,000 patients are treated every year. To increase the flexibility of bed allocation the management decided to implement ward occupancy clusters. Each cluster will contain a number of wards. Within a cluster all kinds of patients could be nursed by each containing ward. At first every ward basically tries to use its own beds. If there is no more capacity for another patient, this patient will be admitted to another ward of the cluster which has available capacities.

The management created the cluster configurations (CC) shown in Table 4 based on organizational and medical reasons. These configurations should be

cluster configuration 1 (CC-1)			cluster configuration 2 (CC-2)			cluster configuration 3 (CC-3)		
Nr	description	# wards	nr	description	# wards	nr	description	# wards
1	stomach cluster	10	1	stomach cluster	9	1	surgery cluster	11
2	chest cluster	8	2	chest cluster	7	2	head cluster	9
3	bone cluster	6	3	bone cluster	2	3	internal med. cluster	12
4	oncology cluster	3	4	oncology cluster	7	4	children/GEB/ZRA	5
5	children/GEB/ZRA	8	5	children/GEB/ZRA	5	5	oncology cluster	6
6	head cluster	9	6	head cluster	9	6	bone cluster	2
7	unassigned wards	3	7	internal med. cluster	6	7	unassigned wards	2
			8	unassigned wards	2			

Table 4. Cluster configurations

there is no valid bed available?

In practice, the hospital staff is quite creative in bridging the time until a valid bed is available. Thus we couldn't model all real world possibilities, but we could measure them in our model. We do this by using the concept of virtual beds. This concept is also the key to evaluate the occupancy policies later on. If a policy leads to a higher amount of virtual beds more cheating has to be done because of occurring occupancy problems.

Summarizing the design of our object-oriented model approach, the used concepts enable the user to automatically create the simulation model and change or modify existing objects easily. Thus, the model offers many ways to adapt it to changing conditions.

evaluated in order to find the most efficient usage of existing bed capacities. As mentioned in the introduction, our study in [11] shows benefits when considering flexible strategies for bed allocation to patients among nearby wards. The clustering concept should raise these benefits even more.

## 5. Results

### 5.1. Validating the Model

In order to get correct evaluation results for the different cluster configurations we compare the behavior of the initial model with the hospital data. This model represents the current situation at the

University Hospital Halle (Saale) without any clusters implemented. Because of comparing the different amount of needed virtual beds and the utilization rate of each ward later on, it suffices to make sure that all aspects of treatment capacity are correctly modeled. These aspects are: the total amount of elective and emergency patients treated within one year, the average LOS on each ward and the patient flows through the hospital.

According to the data of 2011, 24,598 patients were treated as elective patients and 9,087 patients entered the hospital as emergency cases. The following results based on 100 replications with a simulation time of one year. The average total number of patients generated in the simulation model were 24,707 elective and 9,064 non-elective Patients and matches the data.

As shown in Figure 5 the average LOS also shows only a slight difference to the sample data. The deviation varies between 2.1 % and -1.6 % and an average difference of 0.23 % could be achieved. Based on this the computed distributions for LOS are correctly.

reflects the patient flows of the hospital sufficiently correctly.

Based on the results the validation of our model is successful. The computed distributions and the adoption of the represented week are working correctly. In summary, the model has a sufficient level of detail for evaluation occupancy policies.

### 5.2. The Influence of Practical Constraints

In this section, we address our second goal: showing that practical constraints which are important in daily routine of hospital must not be ignored in studies focusing on occupancy management. As mentioned in Section 3.4 we implemented two kinds of constraints, gender separation and isolated treatment. On the one hand, gender separation makes sure that in each room of a normal ward, only male or female patients stay. On the other hand, isolated treatment ensures that a patient with an infectious germ will stay alone in a room. We assume that these constraints strongly restrict the allocation of free beds,

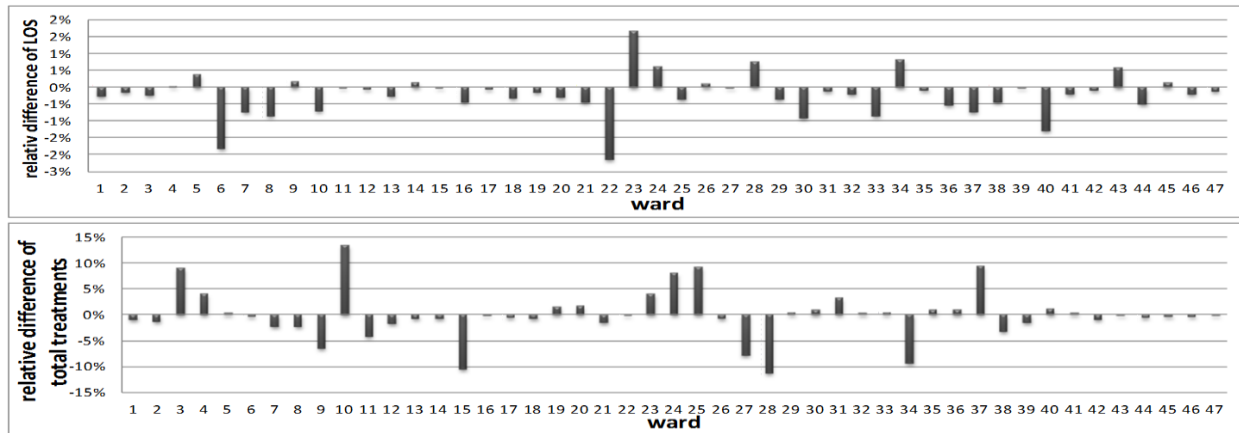


Figure 5. Results of model validation

To compare the patient flow of our model with the given data we take a closer look on the total amount of treated patients within each ward. In general a patient is treated by more than one ward. That’s why we measured the total amount of treated patients in the hospital and on every ward. If our patient flows based on the computed distributions are correct, each ward will treat as many patients as in the data. Our model generated 45,013 treatments in total, which approx. equals 45,172 total treatments given by the data. Figure 5 shows the difference in treated patients at each ward. It ranges from -11 % to 13 %. With respect to only three wards having a difference in treatments of more or less than 10 %, we assume that our model

ignoring them will lead to a misleading models.

We used our initial model as validated before and compared the amount of virtual beds needed with and without these constraints. As mentioned in Section 3.4 the usage of a virtual bed means that usually the patient could not be admitted and some kind of “cheating” has to be done. In the initial model, there was a usage of approximately 9,000 beds. By omitting these constraints less than the half (4,325) of virtual beds are needed. This difference confirms our assumption: Without these constraints the results of our study would be heavily biased.

### 5.3. Evaluation of Cluster Configurations

In order to evaluate the performance of the cluster configurations and to reach our third goal, we use two key performance indicators (KPI), the amount of needed virtual beds and the average utilization rate of the wards. As described in Section 3.4 represent each virtual bed needed an event of undersupply with available beds which have to be take care of. The utilization rate for each ward is computed by:

$$\frac{\sum \text{occupied beds} + \sum \text{blocked beds}}{\text{number of beds}}$$

*Occupied beds* are beds where a male or female patient is assigned. *Blocked beds* are beds within a room where an infectious patient is assigned. These beds can't be used by other patients. We compute the utilization rate at 00:00 o'clock simulation time each day like the hospital does in reality. To thoroughly evaluate all cluster configurations, the actual scenario with current state of bed resources and patient flow is evaluated together with two prospective scenarios, one with less bed resources allowing 85% utilization rate; the other with 50% more elective patients:

- [S1] compare each cluster configuration with the initial model
- [S2] raise the utilization rate of each ward to approx. 85% by removing beds
- [S3] increase the amount of elective patient cases treated in the hospital by 50%

To enable the usage of the cluster within our model, we simply modified the allocation heuristic (see Section 3.4.). Now, before assigning patients to virtual beds if a ward has no bed available, the heuristic tries to find a valid allocation within the whole cluster. If even this fails, virtual beds of the actual ward will be allocated.

Figure 6 shows the total number of used virtual beds in [S1]. The initial model uses 9,135 virtual beds. In CC-1 746 beds were used. A further reduction

occurred by using CC-2 (347 beds) and CC-3 (341 beds). The considerable reduction of virtual beds of




Figure 6. Usage of virtual beds

almost 92% for CC-1 and more than 96% for CC-2 and CC-3 underlines the great potential of increasing flexibility in using resources. Regarding our second KPI, the utilization rate (shown in Figure 7) there has been no change. Values between 55 % and 56 % have been measured. Furthermore, high utilization rates could be eliminated by clustering the capacities. Based on these results, clusters that obviously are able to handle load peaks which means almost all patients could be treated with regularly available capacities.

Based on the results of [S1], we computed how many beds should be removed from each ward in order to obtain an average utilization rate of 85 %. We computed the amount of approx. 354 beds that has to be removed from the hospital in total. To maximize flexibility within the wards, we removed beds to get as many small rooms as possible.

Figure 6 shows the amount of needed virtual beds and Figure 8 the average utilization rate for [S2]. The results show a distribution of work load between the wards and less unused capacities. However, this strategy aiming at an average utilization rate of 85 % has big disadvantage because of less possibilities to respond to peaks. As result, the usage of virtual beds in all cluster configurations nearly reach the same level as the initial model. However, removing approx.




Figure 7. Average occupancy rate of wards for scenario [S1]




Figure 8. Average occupancy rate of wards for scenario [S2]




Figure 9. Average occupancy rate of wards for scenario [S3]

one third of all beds and the use of occupancy clusters still needs up to 31 % less virtual beds than the initial model in the current state [S1].

To evaluate [S3], we increased the amount of treated elective patients by 50 % to a total number of approx. 38,000. We didn't change the amount of emergency patients, because the hospital can't influence this figure. As shown in Figure 6 and 9, the average utilization rate increase as desired. The average utilization rate is now at 81 % and the utilization of virtual beds ranges from 4,759 (CC-1) to 3,552 (CC-3).

Summarizing the evaluation results implementing occupancy clusters is better than the current state of the hospital in any case. Each cluster configuration is capable of handling peak loads in patient arrival. With regard to the number of needed virtual beds, CC-3 was best in all scenarios. However, the performance of a configuration is highly dependent on its composition because the improvement of efficiency is based on the more flexible usage of idle bed capacities within a cluster. If patient flows of wards belonging to a cluster are too similar, it is possible that no idle capacities are available when needed.

Furthermore our results indicate that the loss of flexibility by reducing capacity to increase the utilization rate leads to more problems in occupancy management than an increase of patient numbers.

## 6. Conclusion and Future Research

We successfully reached our main goal and developed a DES model of a whole hospital which is

able to evaluate different occupancy cluster configurations. Improving bed allocation flexibility by implementing occupancy cluster had reduced the usage of virtual beds up to more than 96 %. In all three scenarios (current state, reduce capacity and increase number of patients) the CC-3 had the best results.

From a medical point of view for the hospital, the introduction of an internal medical cluster in CC-2 and its extension in CC-3 seems to be crucial for an additional 50% reduction of virtual beds with regard to CC-1 already having 92% reduction. For prospective bottleneck less-resource and more-patient scenarios [S2] and [S3], CC-3 performed best, likely because of an additional big interdisciplinary surgery cluster. In contrast, omitting a big stomach cluster from CC-1 has no negative effects. This kind of results cannot be achieved without considering all patient data and their variations over the year, e.g. by simulation.

Model evaluations confirm our assumption that practical constraints like gender separated rooms and isolated patient treatment must not be ignored to avoid an underestimation of bed requirements.

To enable an easily reuse of our model, we finally embedded it in a data driven decision support system architecture. By doing this we could reach a new level of model generality. After entering hospital own data, we were able to automatically build the whole model including structure and distributions by pushing a button, instead of simply changing parameters.

In future research, we will try to find optimal cluster configurations by combining other operational research techniques like mathematical programming within our system.

## 7. References

- [1] Augurzky, B. *Krankenhaus Rating Report 2013: Krankenhausversorgung zwischen Euro-Krise und Schuldenbremse*. medhochzwei-Verl., Heidelberg, (2013).
- [2] Barado, J., Guergué, J.M., Esparza, L., Azcárate, C., Mallor, F., and Ochoa, S. A mathematical model for simulating daily bed occupancy in an intensive care unit\*. *Critical Care Medicine* 40, 4 (2012), 1098–1104.
- [3] Black, D. and Pearson, M. Average length of stay, delayed discharge, and hospital congestion: A combination of medical and managerial skills is needed to solve the problem. *BMJ: British Medical Journal* 325, 7365 (2002), 610.
- [4] Blum, K., Löffert, S., Offermanns, M., and Steffen, P. *Krankenhaus Barometer 2013*. Düsseldorf, (2013).
- [5] Brailsford, S.C., Harper, P.R., Patel, B., and Pitt, M. An analysis of the academic literature on simulation and modelling in health care. *Journal of Simulation* 3, 3 (2009), 130–140.
- [6] Costa, A.X., Ridley, S.A., Shahani, A.K., Harper, P.R., De Senna, V., and Nielsen, M.S. Mathematical modelling and simulation for planning critical care capacity\*. *Anaesthesia* 58, 4 (2003), 320–327.
- [7] Eldabi, T., Paul, R.J., and Young, T. Simulation modelling in healthcare: reviewing legacies and investigating futures. *Journal of the Operational Research Society*, (2006).
- [8] Günal, M.M. and Pidd, M. Discrete event simulation for performance modelling in health care: a review of the literature. *Journal of Simulation* 4, 1 (2010), 42–51.
- [9] Günal, M.M. A guide for building hospital simulation models. *Health Systems* 1, 1 (2012), 17–25.
- [10] Harper, P.R. and Shahani, A.K. Modelling for the Planning and Management of Bed Capacities in Hospitals. *The Journal of the Operational Research Society* 53, 1 (2002), 11–18.
- [11] K. Helbig, T. Stoeck, M. Gragert, and T. Mellouli, „Simulation stationsübergreifender Patientenflüsse zur Evaluation flexibler Bettenbelegungsszenarien aufgrund der Jahresdatenanalyse eines Universitätsklinikums“, in *MKWI 2014; Tagungsband*, Paderborn, 2014, S. 749–762.
- [12] Jacobson, S.H., Hall, S.N., and Swisher, J.R. Discrete-event simulation of health care systems. In *Patient flow: reducing delay in healthcare delivery*. Springer, (2006), 211–252.
- [13] Jun, J.B., Jacobson, S.H., and Swisher, J.R. Application of Discrete-Event Simulation in Health Care Clinics: A Survey. *The Journal of the Operational Research Society* 50, 2 (1999), 109–123.
- [14] Khare, R.K., Powell, E.S., Reinhardt, G., and Lucenti, M. Adding More Beds to the Emergency Department or Reducing Admitted Patient Boarding Times: Which Has a More Significant Influence on Emergency Department Congestion? *Annals of Emergency Medicine* 53, 5 (2009), 575–585.e2.
- [15] Kim, S.-C., Horowitz, I., Young, K.K., and Buckley, T.A. Analysis of capacity management of the intensive care unit in a hospital. *European Journal of Operational Research* 115, 1 (1999), 36–46.
- [16] Klein, R.W., Dittus, R.S., Roberts, S.D., and Wilson, J.R. Simulation Modeling and Health-care Decision Making. *Medical Decision Making* 13, 4 (1993), 347–354.
- [17] Kolker, A. Process Modeling of ICU Patient Flow: Effect of Daily Load Leveling of Elective Surgeries on ICU Diversion. *Journal of Medical Systems* 33, 1 (2009), 27–40.
- [18] Kumar, A. and Mo, J. Models for Bed Occupancy Management of a Hospital in Singapore. *Proceedings of the 2010 International Conference on Industrial Engineering and Operations Management*, (2010).
- [19] Marckmann, G. Zwischen Skylla und Charybdis: Reformoptionen im Gesundheitswesen aus ethischer Perspektive. *Gesundheitsökonomie & Qualitätsmanagement* 12, 2 (2007), 96–100.
- [20] McClean, S. and Millard, P.H. A decision support system for bed-occupancy management and planning hospitals. *Mathematical Medicine and Biology* 12, 3-4 (1995), 249–257.
- [21] Mustafee, N., Katsaliaki, K., and Taylor, S.J.E. Profiling Literature in Healthcare Simulation. *SIMULATION* 86, 8-9 (2010), 543–558.
- [22] Proudlove, N., Gordon, K., and Boaden, R. Can good bed management solve the overcrowding in accident and emergency departments? *Emergency Medicine Journal* 20, 2 (2003), 149–155.
- [23] Roche, K.T., Rivera, D.E., and Cochran, J.K. A control engineering framework for managing whole hospital occupancy. *Mathematical and Computer Modelling* 55, 3-4 (2012), 1401–1417.
- [24] Vanberkel, P.T., Boucherie, R.J., Hans, E.W., Hurink, J.L., and Litvak, N. A survey of health care models that encompass multiple departments. (2009). <http://eprints.eemcs.utwente.nl/15762/>.
- [25] Vere, D.W. Assessing and allocating beds in acute medicine in east London. *British medical journal (Clinical research ed.)* 287, 6395 (1983), 849.
- [26] Villa, S., Barbieri, M., and Lega, F. Restructuring patient flow logistics around patient care needs: implications and practicalities from three critical cases. *Health Care Management Science* 12, 2 (2009), 155–165.



## **Anhang D: A Clinical Pathway Mining Approach to Enable Scheduling of Hospital Relocations and Treatment Services**

Helbig K, Römer M, Mellouli T (2015a)

In: Business Process Management, Band 9253; hrsg. v. Motahari-Nezhad HR, Recker J, Weidlich M; Springer International Publishing, Cham 2015a, 242–250

## A Clinical Pathway Mining Approach to Enable Scheduling of Hospital Relocations and Treatment Services

Karsten Helbig<sup>1</sup>, Michael Römer<sup>1</sup> and Taïeb Mellouli<sup>1</sup>

<sup>1</sup> Department of Management Information Systems and Operations Research,  
Martin-Luther-University Halle-Wittenberg, Germany  
{karsten.helbig,michael.roemer,mellouli}@wiwi.uni-halle.de

**Abstract.** As discussed in numerous studies, clinical pathways of patients form an appropriate tool for describing hospital processes and thereby provide a basis for increasing the effectiveness of hospitals. Developing pathways led to a considerable research investigating IT-techniques to support pathway generation. However, previous research neglected finding pathways designed to support scheduling of hospital relocations and treatment services. To close this gap, we first introduce a clinical pathway concept consisting of both pathway structure and pathway constraints suitable for scheduling tasks. Second, we provide a pathway mining method for automatically extracting corresponding pathways from standard hospital billing data required for the German §21-KHentG. Applying our approach to a real world dataset of a university hospital, we illustrate the results using a pathway for malignant neoplasm of prostate containing feasible time windows and precedence relations of treatments, durations at attended wards as well as possible process improvements stimulated from the results.

**Keywords:** Clinical Pathway, Hospital, Process Mining, Scheduling

### 1 Introduction

Hospitals in Germany cause costs of 76bn Euro per year, which is approx. 25% of the total costs of the German health care system [1]. In order to reduce healthcare costs, the German Diagnosis Related Groups (DRG) system was established in 2003. Since then, hospitals are under considerable cost and quality strain by earning a case-based lump-sum. Today, every third hospital is still unprofitable [2]. Badly managed patient flows lead to an inefficient use of human and material resources, increasing costs and decreasing quality of medical care [3]. One of the most promising methods to achieve an efficient patient flow management is the use of clinical pathways (CP) [3].

A CP is a specific set of time-constrained treatment services and ward relocations to be performed to cure a disease between a patient's admission and discharge. The aim of using CP is to increase the transparency and the standardization of medical processes in order to enable scheduling and controlling [4]. However, developing CP is a complex and time-consuming task. As a result, only few CP are used in day-to-day hospital

operations. Due to heavily interdependent treatment services, using none or just a few CP within some kind of patient scheduling system becomes an obstacle to finding a best possible allocation of hospital resources. In order to obtain CP for nearly every disease treated by a hospital, IT support is indispensable.

Because of the great potential of employing CP, in recent years much effort has been taken to develop methods to automatically identify pathways. Existing methods for pathway mining focus on explicit descriptive characterizations of CP. Since they neglect implicit path feasibility information such as time windows of treatments or precedence constraints, they typically struggle with the heterogeneity and the variability of hospital-wide treatment processes and, cannot be used for scheduling.

Based on recent research in pathway mining and hospital-wide scheduling, this paper has two aims to improve business process management in hospitals: (1) Introduce a scheduling-focused CP concept composed of pathway structure and pathway constraints and (2) to develop a pathway mining method which is able to automatically extract CP corresponding to this CP concept from a standardized billing data each German hospital is obliged to create once a year according to the §21-KHentgG.

## 2 Related Work

Studies show significant improvements in medical care quality and economic factors like costs by employing CP in clinical operations management [5, 6]. In order to leverage this potential throughout the entire hospital, one pathway for every kind of treatment is needed. Unfortunately, due to the highly complex, ad hoc and multi-disciplinary nature of hospital processes, the development of a specific CP containing all necessary constraints of all treatments to cure an illness is a difficult and time-consuming task [7].

To support the development of CP, IT-based pathway mining methods have been designed in the recent years. These methods can be classified into process mining, mining from clinical guidelines and other techniques like data mining or machine learning.

In process mining, process models are extracted from execution logs [8]. Since the billing data used in this paper is similar to event logs, our novel path mining method can be classified as a process mining approach. For this reason, the following review focusses on this class of approaches for pathway mining.

Process mining methods have successfully been employed to identify changes in treatment processes and differences to given guidelines or clinical best practices [9]. Furthermore, they have been used to find particularly conspicuous and deceitful patient cases automatically [7, 10]. Notwithstanding, there is a great need of new process mining approaches. After analyzing several common process mining techniques, none of them was able to meet all requirements for using them in practice or to identify good models even for well-defined clinical processes [11, 12].

*Huang et al.* face these criticisms and develop a new approach based on a dynamic programming algorithm which splits the observed time periods into continuous and overlapping intervals. Their approach is able to find frequent medical behavior patterns

in each specific time interval in a given event log file. In a case study valid pathway summaries are found showing the global and time interval specific structure of current medical treatment processes [13].

Another approach developed by *Huang et al.* is based on an unsupervised probabilistic clustering technique called Latent Dirichlet Allocation. The patterns encompass a set of treatment activities forming the essential features of the CP [14]. In experiments with a real word data set, the temporal structure of discovered CP patterns could be extracted successfully by considering a treatment's timestamps [15].

To sum up, the mentioned approaches have a descriptive character and are able to show how current treatment processes are performed in hospitals. Nevertheless, none of these approaches is able to find CP that can be used for scheduling patient treatment services and relocations since they lack scheduling-relevant information like time or precedence constraints between single CP steps. Furthermore, the heterogeneity of patient case data from highly variable treatment processes is one of the most challenging problems in process mining approaches [7, 11, 12, 15, 16]. To find homogenous case groups, the use of clustering techniques is advised [16]. Unfortunately, using a clustering algorithm is likely to mix up heterogeneous patient cases resulting in CP that will never occur in reality, cannot be used for scheduling and could even decrease hospital process transparency.

To bridge this gap, we describe a process mining approach which is able to find homogenous cases and plausible CP for elective inpatients (pre-planned, non-emergency cases) that meet scheduling-relevant requirements, addressing the two main challenges of process mining techniques: (1) strongly heterogeneous patient cases with a great variability in treatment processes and (2) event data from various IT-systems with different structure and content [7, 11, 12, 15–17].

### 3 Concept of Scheduling-Focused Clinical Pathways

The CP scheduling problem aims at improving the patient flow and hospital resource allocation by finding a best possible hospital-wide schedule for each patient avoiding bottlenecks, waiting times etc. As a result, for each patient it is known where and when which kind of treatment will be performed and how long the patient will stay on certain wards during his hospitalization if no complications arise [18, 19].

Regarding the findings related to this scheduling problem, a time granularity of one day is considered to be sufficient [18, 19]. Thus, a clinical pathway comprises a set of day-based steps (ward relocations and medical treatments). Consequently, we propose that the result of CP mining should contain two separate interrelated components leading to an implicit pathway characterization: First, **the pathway structure** containing a set of daily pathway steps which are categorized into **relocations** and **treatments** together with their timely occurrence relative to the hospital admission. Second, a set of **pathway constraints** ensure feasible scheduling results while allowing some flexibility in scheduling which can be used for optimization (see Fig 1). Details of required resources are part of the scheduling process and beyond our scope.

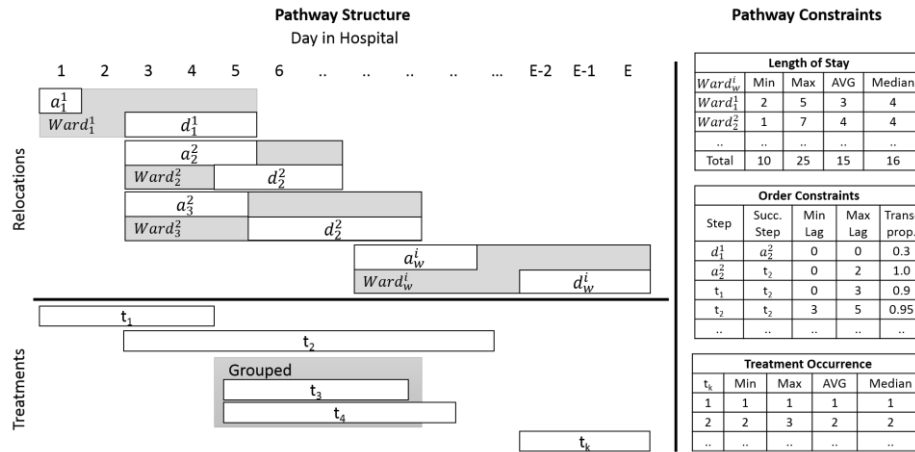


Fig. 1. - Concept of Scheduling Based Pathways

**Relocations** describe the sequence of wards a patient has to pass and the stay time on each ward. A relocation  $i$  consists of two events (admission  $a_w^i$  and discharge  $d_w^i$ ) corresponding to the start and end day of the stay on ward  $w$ . Possible values are integer values showing the day of this event during hospitalization corresponding to the hospital admission  $a_w^1 = 1$ . The time between two events corresponds to the length of stay in days on a ward using resource capacity (e.g. one bed). To provide more scheduling flexibility, it is possible to consider more than one ward as a relocation candidate. In Fig. 1, for example, either admission  $a_2^2$  or  $a_3^2$  could be selected after discharge  $d_1^1$ .

**Treatments**  $t_k$  are aggregated packages of activities required to cure an illness. Each treatment can be performed within one day if all relevant resources are available. If two or more have to take place at the same day, they can be “grouped”.

The timing of each relocation and treatment is constrained by the given feasible time frame relative to the admission day. The frame is bounded by the first and the last observed occurrence of a step within all cases. This supports a flexible treatment scheduling respecting patients and resource requirements later on.

**Pathway constraints** include the length of stay, precedence constraints and treatment occurrences. The length of stay specifies how much time a patient should at least (Min) and at most (Max) spend on a ward  $w$  at relocation  $i$ . In order to improve transparency, the average (AVG) and the median length of stay (Median) is considered for each individual ward as well as for the total stay time of the whole pathway.

The feasible time windows of all steps are computed on the basis of multiple cases. This can lead to overlapping permissible windows (see Fig. 1 treatment  $t_1$  and  $t_2$ ). Given this overlapping, precedence constraints are necessary to ensure a medically correct order of all steps after scheduling. These constraints consist of precedence relations as well as minimum (Min Lag), maximum (Max Lag) waiting time-lags and relative transition frequencies between successive steps. If the Min Lag equals zero, the two steps might occur at the same day. We use relative transition frequencies to ensure medically correct CP. To avoid CP biased by some exceptions in treatment processes, we use thresholds for the minimum relative transition frequency (e.g. occurrence of 90% in all cases) which have to be satisfied in order to consider a given transition. Transition frequencies between wards show valid relocation alternatives.

Finally, treatment occurrences ensure that each treatment  $t_k$  is at least ( $Min_{t_k}$ ) and at most ( $Max_{t_k}$ ) times contained in a CP. Average ( $AVG_{t_k}$ ) and median ( $Median_{t_k}$ ) occur is again computed for transparency purposes.

## 4 Pathway Mining Approach

```

1 caseGroupList = getHomogenousGroups(leadingDiagnosis, admissionWard)
2   for each group in caseGroupList:
3     while i <= max(countRelocationStates(group)):
4       wardList = getWardsAtRelocationState(i, group)
5       for each ward in wardList:
6         wardKeyFigDict[i, ward] = computeWardKF(i, ward, group)
7       i = i+1
8     totalLOSKeyFiguresDict = getTotalLOSKF(group)
9     treatmentList = getAllTreatments(group)
10    for each treat in treatmentList:
11      treatmentKeyFigures[treat] = getTreatKF(group)
12      listOfDays = getDaysOfOccurrence(treat, group)
13      treatDays[treat] = getFeasDays(listOfDays)
14    posGroups = getAllPossibleTreat-Groups(treatmentList)
15    for each (treat-A, treat-B) in posGroups:
16      if getGroupValue(treat-A, treat-B) >= groupThreshold:
17        listOfFoundGroups.add(treat-A, treat-B)
18    for each (pred, succ) in getAllPossibleStepOrders(group):
19      transFreq = getTransitionFrequency(pred, succ)
20      if transFreq >= precedenceThreshold then:
21        orderDict[pred, succ] = getOrderKF(pred, succ, group)

```

The above shown CP mining algorithm identifies pathway structures and constraints based on homogenous case groups received from a §21-KHentg<sup>8</sup> billing data set. A homogenous case group is a collection of patient cases sharing the same illness and a similar treatment. In line (L) 1 we extract all of these case groups, assuming that all possible treatments of a certain illness have to start at the same ward within a hospital and show a similar set of operations and procedures (OPS). Thus we first select all elective cases with the same leading diagnosis<sup>9</sup> and an admission on the same ward. After that we compute binary OPS profiles of all selected cases. All cases that now share the same OPS profile are considered as a homogenous case group.

To find all **relocations**, we first compute the maximum number of relocation steps of a group (L 3). Based on this, we extract the list of possible wards in chronological order (L 4). In L 5, we compute the key figures Min, Max, AVG and Median of length of stay (LOS) on each ward as well as the feasible day-based time windows for admission and discharge to/from these wards relative to the first admission. Similar key figures are computed in L 8 for the total LOS for the whole case group<sup>10</sup>.

In L 9 to 13, we extract all treatments within the case group, the key figures Min, Max, AVG and Median of the occurrence of each treatment as well as the list of feasible days (relative to the first admission) for each treatment. Start and end of the feasible time interval are computed in L 13 as min/max of all observed occurrences.

In order to obtain all groups of treatments to be scheduled at the same day, we first determine all pairs of steps which occurred at the same day (L 14). Based on these, we

<sup>8</sup> An overview of the entire §21-KHentg dataset, all case related data and an example data set can be found at: [http://www.g-drg.de/cms/Datenlieferung\\_gem.\\_21\\_KHentg](http://www.g-drg.de/cms/Datenlieferung_gem._21_KHentg)

<sup>9</sup> Each case can have plenty of diagnoses, but only one leading diagnosis. This diagnosis is the medical reason for hospitalization.

<sup>10</sup> In order to simplify accessing the figures later on, we store them in [key: value] dictionaries:

compute the relative group value by counting the number of real occurrences of both treatments at the same day divided by the amount of possible occurrences at the same day, which is the minimum of the occurrence of both treatments (L 16). To avoid groupings due to exceptional treatments, a given `groupThreshold` has to be met to create a hard-constrained grouping (L 17).

To identify precedence constraints, we compute the transition frequency of each possible pairing of case steps (L 18 to 19). We compute the transition frequency of two steps by counting how many times a certain daily-based pair occurred divided by the number of how many times the pair could have occurred within the group. The value of possible occurrences is the value of how many times both steps occur within all cases. To ensure valid relocation sequences after scheduling, we compute the transition frequency for two wards depending on the number of relocations in the case. Possible wards at stage  $i+1$  are feasible only if a relocation from the former ward at stage  $i$  has been observed. In order to avoid precedence constraints based on few individual patient treatments, a given `precedenceThreshold` has to be met within all cases to create significant constraints (L 20 to 21).

## 5 Results

The following results are based on a real-world billing dataset of a German university medical center from 2011 involving approx. 40.000 inpatient cases.

Since we pursue the goal of developing a general pathway mining method, we tested our approach on several leading diagnoses. In order to facilitate the discussion of the results, the following presentation focuses on the diagnosis C6111 (Malignant neoplasm of prostate) forming the leading diagnosis with the third largest amount of inpatients, admitted 504 times in 2011. We chose ward HA2200 for further path mining because 97 % of all patients were admitted there.

After extracting the OPS profiles of all 492 cases, we received the homogenous case groups by hierarchical Ward clustering using the Jaccard coefficient to compute the distance matrix and cutting the results at a height of zero such that only equal items are within a cluster. This ensures that different kinds of treatments are not mixed up within one cluster. Altogether, the Ward clustering resulted in 112 equal cases contained in three big clusters with 85, 75 and 50 cases and four medium-sized clusters with 11 to 27 cases. One third of all cases (131) are assigned to clusters with 2 to 10 cases and 71 clusters contain a single case. In the following, we discuss the results mining a 13-case cluster containing interesting results and exhibiting a complex treatment process. The parameters `groupThreshold` and `precedenceThreshold` were set to 0.95 and 0.9. Fig. 2 shows the path mining results. This CP contains 5 treatments including a surgery. The stay time is between 8 and 19 days, with an average of 11 and no further relocation. The DRG of the cases is M01B and has an average stay time of 9.9 days in Germany<sup>12</sup>.

---

<sup>11</sup> All diagnosis are stored as IDC-10 strings within the dataset.

<sup>12</sup> <http://medcode.ch/de/de/drgs/G-DRG-2012/M01B>

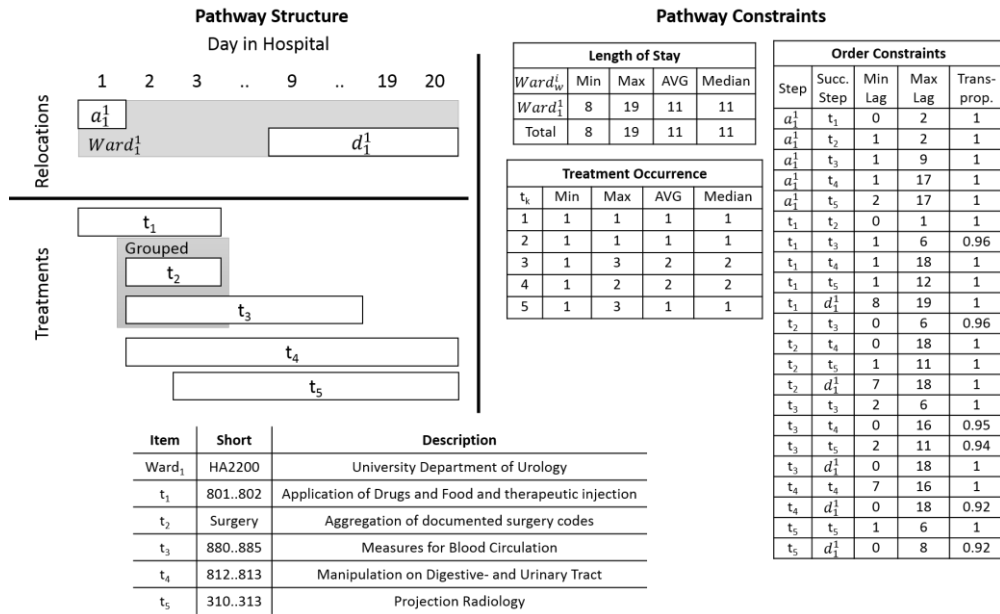


Fig. 2 – CP obtained with the presented method

It is notable that the surgery in our cases is done at day 2 or 3. If the surgery could be performed at the first day of hospitalization, the length of stay may be reduced. The found precedence constraint between  $t_2$  and  $d_1^1$  with a min lag of 7 days underlines this guess. A closer look at the data reveals that the average stay time of cases with surgery at the second day is approximately 11 days, instead of 14 days. Another interesting insight for managing patient flows is the insight of grouping the surgery ( $t_2$ ) and “measures of blood circulation” ( $t_3$ ). If it is known ahead that the resources required for  $t_3$  are unavailable at a certain time, the admission of patients should be shifted accordingly in order to avoid waiting time. The pathway mining results were discussed the case manager of the ward HA2200. She recognized the structure of our mined treatments processes and confirmed our scheduling-related interpretations like shifting the surgery on the first day and that a surgery could only be done if all preparing OPS have been done before.

## 6 Conclusion

In 2012, every third German hospital was unprofitable [2]. One of most promising ways to improve hospital efficiency is the implementation of CP [3]. In this paper, we propose a scheduling-focused CP concept and an algorithm to automatically extract CP from standardized billing data. Summarizing the results, our method is able to identify real-world treatment processes from standardized hospital billing data. Regarding the aims of this paper, the unique contributions of our approach are: First, our scheduling-based CP concept identifies structures and dependencies instead of merely computing key figures. This new level of transparency enables discussing reasons and solutions for inefficient treatment processes. Second, our CP ensure a valid patient scheduling by only considering homogenous case groups and scheduling-related information.

In future research, we will combine our CP components (structure and constraints) with resource information in order to develop a new kind of hospital-wide scheduling system for elective patient flows. This system will be validated in cooperation with the university hospital. With our results we hope to make an important step on the path to



realizing the vision of being “[...] able to derive (partial) treatment process models merely by pushing a button”[12].

## References

1. Publikation - Gesundheit - Statistisches Bundesamt (Destatis) - Gesundheit - Ausgaben - Fachserie 12 Reihe 7.1.1 - 2011 - Statistisches Bundesamt (Destatis) (2011)
2. Augurzky, B.: Krankenhaus Rating Report 2013: Krankenhausversorgung zwischen Euro-Krise und Schuldenbremse. medhochzwei-Verl., Heidelberg (2013).
3. Villa, S., Barbieri, M., Lega, F.: Restructuring patient flow logistics around patient care needs: implications and practicalities from three critical cases. *Health Care Manag. Sci.* 12, 155–165 (2009).
4. Jacobs, B.: Ableitung von klinischen Pfaden aus evidenzbasierten Leitlinien am Beispiel der Behandlung des Mammakarzinoms der Frau, (2007).
5. Cerrito, P.: Clinical Data Mining to Discover Optimal Treatment Patterns. In: Pardalos, P.M., Georgiev, P.G., Papajorgji, P., and Neugaard, B. (eds.) *Systems Analysis Tools for Better Health Care Delivery*. pp. 99–130. Springer New York, New York, NY (2013).
6. Huang, Z., Dong, W., Duan, H., Li, H.: Similarity Measure Between Patient Traces for Clinical Pathway Analysis: Problem, Method, and Applications. *IEEE J. Biomed. Health Inform.* 18, 4–14 (2014).
7. Rebuge, Á., Ferreira, D.R.: Business process analysis in healthcare environments: A methodology based on process mining. *Inf. Syst.* 37, 99–116 (2012).
8. Aalst, W.M.P. van der: *Process mining: discovery, conformance and enhancement of business processes*. Springer, Heidelberg [etc.] (2011).
9. Peleg, M., Soffer, P., Ghattas, J.: Mining Process Execution and Outcomes – Position Paper. In: Hofstede, A., Benatallah, B., and Paik, H.-Y. (eds.) *Business Process Management Workshops*. pp. 395–400. Springer Berlin Heidelberg, Berlin, Heidelberg (2007).
10. Yang, W.-S., Hwang, S.-Y.: A process-mining framework for the detection of healthcare fraud and abuse. *Expert Syst. Appl.* 31, 56–68 (2006).
11. Kaymak, U., Mans, R., Steeg, T. van de, Dierks, M.: On process mining in health care. Presented at the October (2012).
12. Lang, M., Bürkle, T., Laumann, S., Prokosch, H.-U.: Process mining for clinical workflows: challenges and current limitations. *Stud. Health Technol. Inform.* 136, 229–234 (2008).
13. Huang, Z., Lu, X., Duan, H.: On mining clinical pathway patterns from medical behaviors. *Artif. Intell. Med.* 56, 35–50 (2012).
14. Huang, Z., Lu, X., Duan, H.: Latent treatment topic discovery for clinical pathways. *J. Med. Syst.* 37, 1–10 (2013).
15. Huang, Z., Dong, W., Ji, L., Gan, C., Lu, X., Duan, H.: Discovery of clinical pathway patterns from event logs using probabilistic topic models. *J. Biomed. Inform.* (2013).
16. Song, M., Günther, C.W., Aalst, W.M.P. van der: Trace Clustering in Process Mining. In: Ardagna, D., Mecella, M., and Yang, J. (eds.) *Business Process Management Workshops*. pp. 109–120. Springer Berlin Heidelberg (2009).
17. Mans, R.S., van der Aalst, W.M., Vanwersch, R.J., Moleman, A.J.: Process mining in healthcare: Data challenges when answering frequently posed questions. *Process Support and Knowledge Representation in Health Care*. pp. 140–153. Springer (2013).
18. Gartner, D., Kolisch, R.: Scheduling the hospital-wide flow of elective patients. *Eur. J. Oper. Res.* (2013).
19. Helbig, K.: Zeitplanung für Patientenpfade unter Berücksichtigung von Betten-, Behandlungskapazitäten und Fairnesskriterien. Tagungsband 15 Interuniv. Doktorandenseminar Wirtsch. Univ. Chemnitz Dresd. Freib. Halle-Wittenb. Jena Leipz. 34–44 (2011).

**Anhang E: A Data-Driven Hierarchical ILP Approach for Scheduling Clinical Pathways: A Real-World Study from a German University Hospital**

Helbig K, Römer M, Mellouli T (2016)

Eingereicht für die Zeitschrift BUSINESS RESEARCH

-

Aktuell in Revision nach Absolvieren der erster Begutachtungsrunde

# A Data-Driven Hierarchical ILP Approach for Scheduling Clinical Pathways: A Real-World Study from a German University Hospital

Karsten Helbig, Michael Römer and Taïeb Mellouli

Department of Management Information Systems and Operations Research,  
Martin-Luther-University Halle-Wittenberg, Germany  
{karsten.helbig,michael.roemer,mellouli}@wiwi.uni-halle.de

## Abstract

Facing economic pressure and case-based compensation systems, hospitals strive for effectively planning patient hospitalization and making efficient use of their resources. In order to support this endeavor, this paper proposes a flexible hierarchical integer linear programming (ILP)-based approach for the tactical day-level scheduling of clinical pathways (CP). CP form sequences of ward stays and treatments to be performed during a patient's hospitalization under consideration of all relevant resources such as beds, operating rooms and clinical staff. Since in most hospitals, the CP-related information needed for planning is not readily available, we propose a data-driven approach allowing to automatically extract the structure of the CP to be scheduled including all CP-related constraints from standardized hospital billing data available in every German hospital. The approach uses a flexible multi-criteria objective function considering several patient- and hospital-related aspects and allowing to employ our approach in various scenarios. Furthermore, compared to other approaches, it considers several practically relevant aspects ensuring the implementability of the scheduling results such as multiple ward stays per hospitalization and gender-separated assignment of patients to rooms. Regarding the treatment resources such as operation rooms and clinical staff, it considers the eligibility of resources for treatments based on attributes such as special equipment or qualification and, in order to avoid disaggregation problems, represents complex resources individually. In order to be able to solve the resulting large-scale complex scheduling problem for realistically dimensioned problem instances, we propose a hierarchical two-stage ILP approach involving carefully-designed anticipation components in the first-level model. We evaluate our approach with real-world data from a German university hospital showing that our approach is able to solve instances with a planning horizon of one month exhibiting 1088 treatments and 302 ward stays of 286 patients. In addition to comparing our result to a monolithic ILP approach, we provide a detailed discussion of the scheduling results obtained with our approach for two practically motivated scenarios.

## Keywords

Clinical Pathways, Scheduling, ILP, Health Care Planning, Patient Flow, Data-Driven, Case Study

## 1 Introduction

In Germany, hospitals incur around 25 % of the total costs of the health care system (Destatis 2014). In order to reduce these costs of about 76bn Euro per year, in 2003, the German Diagnosis Related Groups (DRG) system was established. In contrast to the earlier length-of-stay-based approach, in the current system, hospitals receive a diagnose-dependent lump sum per patient case. As a consequence, hospitals have a strong incentive to reduce the patients' lengths of stay to effectively manage clinical processes and resources.

Nonetheless, at the time of this writing, every third hospital is still unprofitable (Augurzky 2015). Furthermore, there is a great need for increasing the efficiency of hospitals taking the demographic change into account (Augurzky 2015). According to Villa et al. (2009), the most promising method to achieve an efficient utilization of both human and physical hospital resources is to employ the concept of clinical pathways (CP). CP are specific sets of time-constrained treatments and ward stays to be performed between a patient's admission and discharge in order to cure a certain disease. Besides helping to increase the transparency and the standardization of medical processes, CP are instrumental in hospitalization scheduling and controlling (Jacobs 2007). Despite their great potential, however, neither a comprehensive use of CP nor a scheduling of the patient flow has found its way into day-to-day hospital practice.

Following (Roeder et al. 2003; Kirschner et al. 2007; Küttner and Roeder 2007; Salfeld et al. 2009), an important obstacle for a widespread utilization of CP is the fact that given the vast number of possible pathways, manually creating CP is a tedious endeavor. In addition, since CP are mostly used in a descriptive way, only few CP formalisms discussed in the literature which both enable the automatic extraction of CP structures from hospital data and can be employed for scheduling. Furthermore, many important parameters affecting pathway schedules such as emergency patient arrivals, (exact) treatment durations, resource availability or complications arising in surgeries are subject to uncertainty. Moreover, given that the pathway scheduling problem has to consider complex pathway constraints and to take into account all relevant resources, it gives rise to a complex large-scale optimization problem. As a consequence, many approaches rely on simplifications and operate on a high level of aggregation which makes putting the resulting schedules into practice difficult: The approach from Saadani et al. (2014), for example, completely ignores bed resources. The approach by Gartner and Kolisch (2013) for hospital-wide patient flow scheduling, to take another example, assumes that each patient stays in a single ward during hospitalization, operates on highly aggregated resources and ignores important practical aspects such as gender-separated rooms and resource eligibility based on specific skills or features such as operating room equipment. Finally, while hospital scheduling typically considers multiple objectives related to economics, patients and staff members, many approaches focus on one-dimensional performance indicators, typically based on cost minimization or cost maximization.

Motivated from a case study with a German university hospital, this paper addresses most of the issues discussed above and proposes a tactical pathway scheduling approach intended to support hospital case managers responsible for the coordination and scheduling of treatments and ward stays. The main contributions of this paper can be summarized as follows:

First, we propose a data-driven approach to pathway scheduling: Our approach is based on scheduling-relevant pathway information automatically extracted from standardized hospital billing data available for every hospital in Germany using the approach introduced by Helbig, Römer, et al. (2015). As a result, one of the most time-consuming data preparation steps

necessary for pathway scheduling – defining pathways and their constraints – is automated to a large extent.

Second, we propose a day-level pathway scheduling approach considering all pathway constraints and hospital resources on an adequate level of detail which is flexible enough to consider multiple scheduling criteria: It considers multiple ward stays during hospitalization and gender-separated assignment of patients to rooms. Moreover, it allows representing resource eligibility for treatment based on resource-specific feature and skill sets and considering important resources individually while aggregating identical resources if appropriate. Finally, in order to support scheduling pathways for a broad range of possible objective structures, the objective function in our approach involves a weighted combination of multiple hospital- and patient-related criteria including fairness and workload-balancing criteria.

Third, in order to tackle the resulting complex large-scale scheduling problem for realistic problem instances involving up to 300 patients with a planning horizon of a full month, we propose a two-stage integer linear programming (ILP) approach based on a hierarchical decomposition: The first-stage model determines the admission dates and schedules complex treatments with a high duration. Given instructions from the first model, the second model schedules the ward stays, assigns all patients to gender-separated individual rooms and schedules the remaining treatments. In order to align the first-stage instruction with the second-stage requirements, the first-stage model involves anticipation components to account for the gender separation requirement and to consider pathway constraints involving the full set of treatments.

Fourth, we evaluate the overall approach including the automatic CP extraction in a set of experiments using real-world data from a German university hospital involving 286 elective patients and 1088 treatments. On the one hand, we evaluate our hierarchical approach in comparison with a monolithic mixed integer linear programming (MILP) approach. On the other hand, we provide a detailed evaluation of two scheduling scenarios: In the first scenario, our approach is used to establish a balanced resource utilization throughout the planning horizon; in the second scenario, the main goal is to obtain a high resource utilization at the beginning of the planning horizon.

Note that in this paper, we do not explicitly address the stochastic character of the pathway scheduling problem: On the one hand, our approach only deals with scheduling elective patients for which most planning-relevant information is known ahead. Nonetheless, one of the goals of the planning approach is to establish balanced workloads and resource buffers in order to ensure that emergency cases can be handled adequately. On the other hand, our approach employs conservative point estimates for uncertain treatment times in order to obtain robust schedules. Finally note that, following the procedure proposed by Gartner and Kolisch (2013), our (deterministic) approach can be embedded into a rolling horizon planning approach in order to cope with uncertainty.

The remainder of this paper is structured as follows: Section 2 provides an overview of the rich literature dealing with offline operational scheduling in hospitals and identifies possible objectives, efficient modeling techniques and aspects to be considered in clinical pathway scheduling. Section 3 introduces the constraint-based CP concept according to which the scheduling is carried out and sketches the automated CP mining approach mentioned above. In

Section 4, we introduce our hierarchical ILP approach consisting of an aggregated model to schedule complex treatments and to determine the admission day and a detailed model to schedule the remaining treatment and assign patients to rooms. In Section 5 we explain the real-world dataset from a university hospital used in our computational experiments and show exemplary results of mining CP for its largest department, the department of urology. Section 6 presents the results from using our ILP approach to schedule all extracted CP for all elective patients of the department of urology. To demonstrate the effects of varying the weights in the multi-criteria objective function, we discuss two scenarios in which the resource allocation is A) balanced across the planning horizon and B) preferably allocated at the beginning of the planning horizon. Section 7 concludes the paper and points to further research opportunities.

## 2 Related Work

Hulshof et al. (2012) introduce a taxonomy of planning decisions in health care we employ to structure the following literature review. According to this taxonomy, the problem considered in this paper can be characterized as an offline operational planning problem: Complete CP for elective patients are scheduled within a planning horizon of about one month considering activities at the level of individual patients and resources. Since our approach takes all kinds of hospital resources into account, the following literature review does not only regard CP-related literature but also considers more general hospital resource scheduling approaches in order to identify aspects relevant for our research. Since the assignment of staff to shifts and inventory management issues are out of the scope of this paper, articles dealing with these topics are not included in the following review. Furthermore, the review is restricted to articles involving mathematical programming as solution technique published after 2005. Table 1 shows the related work classified by the combinations of considered resources and treatments.

Resources	Related Articles
Operating Room	Jebali et al. 2006; B. Denton et al. 2007; Lamiri et al. 2007; Chaabane et al. 2008; Lamiri, Xie, Dolgui, et al. 2008; Lamiri, Xie, and Zhang 2008; Cardoen et al. 2009; Fei et al. 2009; Testi and Tànfani 2009; B. T. Denton et al. 2010; Roland et al. 2010; Batun et al. 2011; Cardoen and Demeulemeester 2011; Marques et al. 2012,
Beds	Demeester et al. 2010; Ceschia and Schaerf 2011; Schmidt et al. 2013; Helm and Van Oyen 2014; Vancroonenburg et al. 2014
Treatments	Vlah Jerić and Rui Figueira 2010; Schimmelpfeng et al. 2012; Vlah Jerić and Figueira 2012
Operating Room and Beds	Pham and Klinkert 2008; Cardoen et al. 2009; Augusto et al. 2010; Fei et al. 2010; Chow et al. 2011; Banditori et al. 2013; Sun et al. 2013; Vancroonenburg et al. 2013; Ceschia and Schaerf 2014; Li et al. 2015
Clinical Pathways	Vissers 2005; Conforti et al. 2011; Helbig 2011; Gartner and Kolisch 2013; Saadani et al. 2014

Table 5: Overview of Related Work

Since surgeries form the greatest source of income for most hospitals (B. Denton et al. 2007) and at the same time operating rooms (OR) constitute the most expensive type of resource using more than 10 % of a typical hospital budget (Jebali et al. 2006; Chaabane et al. 2008), there is a rich body of literature dealing with surgery scheduling. The main goals of surgery scheduling are to reduce costs (overtime costs, penalties for idle time or fixed costs for opening an OR) and to increase the utilization of the available OR. This is achieved by either allocating surgeries

to a given set of OR (Lamiri et al. 2007; Lamiri, Xie, Dolgui, et al. 2008; Lamiri, Xie, and Zhang 2008; Fei et al. 2009; B. T. Denton et al. 2010; Riise and Burke 2011; Meskens et al. 2013), sequencing a set of given surgeries (B. Denton et al. 2007; Cardoen et al. 2009; Cardoen and Demeulemeester 2011) or both (Jebali et al. 2006; Testi and Tànfani 2009; Roland et al. 2010; Batun et al. 2011; Marques et al. 2012). In most cases, mathematical programming, heuristics, column generation or combinations of these methods are used to find a good or even optimal solution with respect to a typically multi-criteria objective function. With regard to the scope of the present article, the main insights from the surgery scheduling literature can be summarized as follows: Overtime should be avoided and the well-being of the medical staff should be considered (Roland et al. 2010; Meskens et al. 2013), using a flexible pooling strategy of OR has significant benefits (Batun et al. 2011), the eligibility of operating rooms for surgeries may depend special operating room equipment (B. Denton et al. 2007) and the patients' welfare should be taken into account (Testi and Tànfani 2009). Regarding the solution methods, carefully decomposing the problem into solving multiple small problems solved in sequence often yields a good performance in terms of solution time without having a significantly negative impact on solution quality (Jebali et al. 2006; Lamiri et al. 2007; Lamiri, Xie, and Zhang 2008; Lamiri, Xie, Dolgui, et al. 2008; Fei et al. 2009; B. T. Denton et al. 2010; Batun et al. 2011; Marques et al. 2012).

As stated by Helm and Van Oyen (2014), a proper bed management is necessary in order to avoid having to dismiss patients because of blocked beds, surgical cancellations and operational chaos. The literature discusses two kinds of bed management problems both of which typically consider medical needs as well as patient preferences: elective admission scheduling and the patient-to-room assignment. Elective admission scheduling problems are solved e.g. by local search heuristics (Ceschia and Schaerf 2011), MILP (Helm and Van Oyen 2014) or random forest models (Schmidt et al. 2013). (Demeester et al. 2010) solve the patient-to-room assignment problem using a tabu search heuristic. Vancroonenburg et al. (2014) develop an integrated model to solve both problems at once in order to increase both planning flexibility and operational efficiency. Gender separation in room assignment is typically considered as a crucial issue, see (Demeester et al. 2010; Ceschia and Schaerf 2011; Schmidt et al. 2013; Vancroonenburg et al. 2014).

According to Schimmelpfeng et al. (2012), manually scheduling treatments (encompassing not only surgeries but all types of medical activities) often leads to an inefficient resource allocation and can have negative effects on quality of care and patient satisfaction. In order to avoid this, Vlah Jerić and Rui Figueira (2010) develop a decision support system (DSS) to support the construction a daily schedule of medical treatments considering available resources and other criteria. They use a scatter search heuristic to construct a set of Pareto-optimal solutions among which the user can interactively choose. Another approach by the same authors presented in (Vlah Jerić and Figueira 2012) determines daily treatment schedules considering the availability of medical equipment and physicians. Their approach is based on a multi-objective binary programming formulation for which different solution approaches such as variable neighborhood search, scatter search and non-dominated sorting genetic algorithms are compared. Schimmelpfeng et al. (2012) outline a conceptual framework for a DSS to support the scheduling process of treatments in a rehabilitation hospital. In order to handle realistic problem dimensions, a hierarchical approach is developed using a daily model for aggregated long-term scheduling and an intra-day model (either time- or resource-oriented) for short-term scheduling.

As argued by Chow et al. (2011), trying to achieve a high OR utilization without considering further surgery-related resources often results in issues such as staff overtime, surgical cancellations and long surgical waiting times. In particular, scheduling surgeries without taking the availability of recovery beds into account often leads to problems. In order to avoid this issue, several authors propose to simultaneously schedule both the surgery and the following stay in a recovery bed or on a ward. For instance, Pham and Klinkert (2008) propose to allocate hospital resources to individual surgical cases divided into preoperative, perioperative (=surgery), postoperative intensive care unit (ICU) modes and formulate this problem as a MILP multi-mode blocking job shop model. Cardoen et al. (2009) solve a surgical case scheduling problem in a day-care facility. They formulate a multi-objective model to minimize peaks in recovery bed usage, the occurrence of recovery overtime and violations of staff and patients' preferences. Their approach is based on a combination of column generation and dynamic programming. To analyze the impact of recovery in OR when no recovery bed is available, Augusto et al. (2010) use a Lagrangian relaxation-based approach. Their results show a high benefit of this improved flexibility in resource usage, in particular in case of high demands for recovery beds. Fei et al. (2010) construct weekly surgery schedules for OR considering recovery beds in order to maximize resource utilization while minimizing overtime and idle time between surgeries. They use a hierarchical two-stage solution approach which first computes the date of the surgeries based on a set partitioning formulation solved by a column generation technique. In the second step, taking into account the availability of recovery beds the daily surgery scheduling problem in which the sequence of surgeries is determined is formulated as a flow-shop problem and solved by a hybrid genetic heuristic. The authors show that their overall approach allows reducing idle- and overtime increasing resource utilization. Chow et al. (2011) use Monte Carlo Simulation to predict bed requirements from historical data. Based on this, they formulate a MILP to reduce peaks in bed occupancy by scheduling surgeon blocks and patient types. Another simulation optimization approach for the surgery scheduling problem aiming at a maximal patient throughput is developed by Banditori et al. (2013). The authors first use a MILP model to determine the number of cases to be treated by surgery groups in each timeslot of a month. The model is then fine-tuned with a simulation approach to obtain both robust and easy-to-implement schedules. Sun et al. (2013) propose a weekly scheduling approach to achieve a balanced and high utilization of OR. The authors formulate a MILP taking into account limited key resources like ICU-beds and workload of surgeons. Vancroonenburg et al. (2013) incorporate OR and gender-separating room assignment constraints in their approach for the elective patient admission scheduling problem. Their goal is to determine how scheduling surgical and non-surgical admissions impacts room assignments at wards. Ceschia and Schaerf (2014) address a similar patient admission problem considering OR utilization constraints, gender separation in rooms, a flexible planning horizon and the notion of patient delay using a local search heuristic. Li et al. (2015) develop a MILP-based lexicographic goal programming approach of scheduling OR and beds considering competing resources like surgical and nursing staff, anesthesiologists and recovery beds. The most promising way to avoid bottlenecks, idle time and overtime during hospital patient flow is to schedule not only surgeries or surgeries with subsequent bed resources but the full CP of each patient. Vissers (2005) proposes a master surgery scheduling approach for CP involving cardiothoracic surgeries based on computing the patient mix with a MILP model. He divides the care process into for successive steps: medium care unit (MCU), surgery, ICU and medium care unit and computes the master schedule for a planning cycle of four weeks taking OR, MCU-beds, ICU-beds and nursing staff for ICU-beds into account. An approach to



schedule full CP of elective patients for a week hospital<sup>13</sup> is introduced by Conforti et al. (2011). The authors show their results from scheduling clinical services (diagnostics and surgeries) as well as patient admissions to maximize the patient flow using a MILP model in a case study with 20 patients. Helbig (2011) presents a MILP model for the operational hour-based scheduling of interdisciplinary CP containing treatments, surgeries, order constraints and ward stays. The aim of the model is to minimize waiting time and to finish each CP as early as possible within the planning horizon under consideration of practical constraints like gender separation in rooms and a fair distribution of waiting time among all patients. The paper reports results from experiments with artificial small-scale problem instances with up to four patients. A patient flow planning approach to maximize the length of stay (LOS)-based contribution margin for DRG-based reimbursement policies developed by Gartner and Kolisch (2013). The authors formulate two MILP models to schedule CP, one with fixed and one for variable patient admission dates. They experiment with these models in a static and in a dynamic setting in which the MILP is embedded in a rolling horizon approach. The results dealing with a planning horizon of 28 days and 150 patients show the potential to achieve a higher contribution margin and a significantly reduced time between admission and surgery compared to given manual solutions. Saadani et al. (2014) propose a MILP-based CP scheduling approach in which treatments using different resources are scheduled in order to minimize the patients' length of stay. Their CP contain multiple treatments but no bed requirements. The authors present results for an instance of 20 patients and a planning horizon of 14 days.

Summarizing the results of the literature review, the most promising way to improve the patient flow in hospitals is to consider the full CP of each patient. As shown above, scheduling CP involves various complex aspects to be considered by a CP scheduling approach in order to achieve practically useful and implementable schedules:

- Given the multitude of relevant objectives, the approach should allow to include multiple objective criteria related to both patients and resources:
  - Important patient-related objectives encompass the consideration of LOS (the main driver of schedule-related costs in a DRG system), admission day preferences and hospitalization without delays.
  - Among the resource-related objectives, the prominent are the minimization of overtime and idle time, establishing a balanced workload and achieving a high level of resource utilization
- In order to obtain implementable pathway schedules, patients should be assigned to concrete rooms taking gender separation into account
- For an adequate representation of resource requirements, the fact that in many cases the eligibility of resources for treatments depends on resource attributes such as special qualification or equipment should be considered. Furthermore, in order to avoid disaggregation problems as sketched in the introduction, important treatment resources such as OR should be considered individually instead of in an aggregated way
- It is unlikely to find an exact approach in order to solve a monolithic ILP formulation of the CP scheduling problem considering all these aspects. However, decomposing the problem into multiple stages, if carried out carefully, is a promising approach to achieve good results within acceptable solution times also for large-scale instances involving more than 200 patients, a 30 days planning horizon and 1000 treatments.

To the best of our knowledge, there is no CP scheduling approach taking into account all the aspects mentioned above. As a consequence, this paper proposes a novel hierarchical ILP

---

<sup>13</sup> A week hospital is a hospital where the duration of all hospitalizations is at most one week.

approach to schedule whole CP with hospital-wide ward stays able to handle the mentioned aspects for real-world problem instances. Another important feature of our approach is the fact that it is data-driven: Since it is based on the constraint-based representation of CP introduced by Helbig, Römer, et al. (2015), the structure of the CP to be scheduled can be automatically extracted from standardized data available in every German hospital.

### 3 Constraint-based CP Representation

While the general concept of CP is well known and widely accepted, there is no standard formalism for representing or developing CP (Vanhaecht et al. 2006). While the formal representation is of secondary importance if a CP serves merely descriptive purposes, when it comes to scheduling patient flow based on CP, the CP representation is crucial since it determines the set of feasible schedules for each CP. Conforti et al. (2011), for example, consider a CP as a set of treatments to be scheduled without imposing inter-treatment dependencies. Gartner and Kolisch (2013), on the other hand, represent the possible schedules for each CP on a directed graph in which the arcs form minimum time lags between the clinical activities. The CP scheduling approach presented in the next section relies on the constraint-based CP representation resulting from employing the clinical pathway mining approach introduced in (Helbig et al. 2015). As illustrated Fig. 1, the time granularity of this representation is days and a CP is considered on two levels: On the level of ward stays, a CP forms a chronological sequence of ordered ward stays  $\mathcal{S}$  in which a patient is assigned to one of the wards  $w$  from the set  $\mathcal{W}_s$  of possible wards for each ward stay  $s$ . A ward stay is characterized by an admission event  $v_s^{\text{ad}}$  and a discharge event  $v_s^{\text{dis}}$ . The admission event  $v_1^{\text{ad}}$  of the first stay corresponds to the hospital admission and always takes place at the first day of the CP. All other ward stay events have feasible time intervals indicating when they can be scheduled (e.g. discharge  $v_1^{\text{dis}}$  can be scheduled from day three to day six, see Fig. 1). The difference between admission and discharge on a ward forms the length of stay (LOS) on that ward. For every ward stay, the LOS is constrained by a minimum and a maximum number of

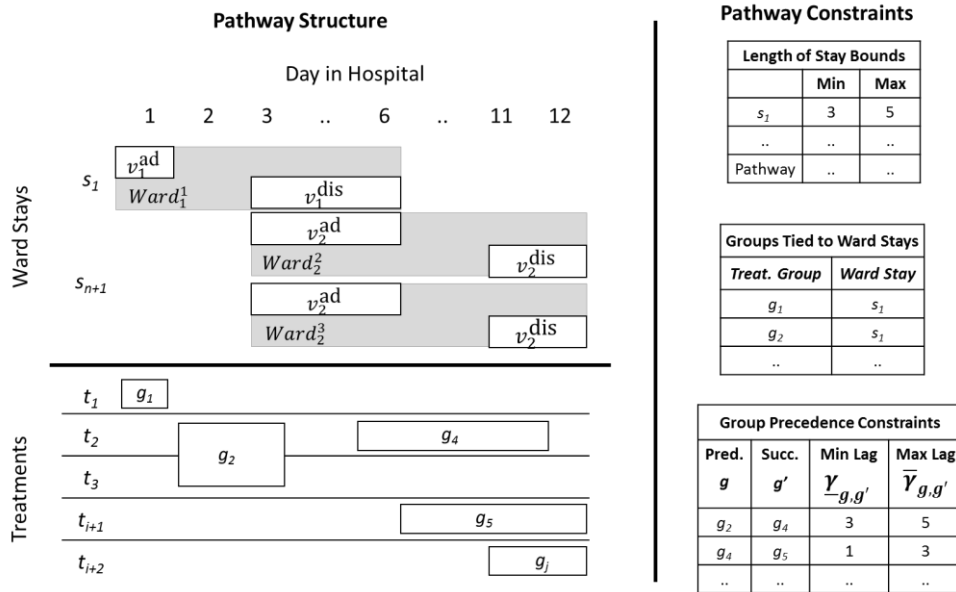


Fig. 1: Constraint-based CP Concept

days. During hospitalization, each ward stay requires a bed resource and all of them must be seamless, that is, there is no gap between two adjacent ward stays.

The other level on which a CP is described is the level of treatments. A treatment  $t$  corresponds to a surgery or any other clinical service to be performed in order to cure a disease. A CP contains a set  $\mathcal{T}$  of different treatments. Each of these treatments lasts at most one day and can only be performed if the required amount of all necessary resource types (e.g. surgeons, special rooms, theatre nurses or the patient) is available.

In order to facilitate scheduling, treatments are clustered into treatment groups; the treatments within the same group  $g$  have to be scheduled at the same day (see e.g.  $t_2$  and  $t_3$  in Fig. 1). Some treatment types may occur in multiple groups which means that they have to be performed once per group ( $t_2$ , for example, occurs in two groups). In order to ensure medically correct schedules, each treatment group  $g$  has a feasible time interval  $[\underline{\delta}_g; \overline{\delta}_g]$  relative to the first admission event. In Fig.1, this interval corresponds to the length of the bar associated with the treatment group (e.g.,  $g_2$  has the feasible interval [2;3]). In addition, a medically correct order can be enforced by precedence constraints imposing a minimum and a maximum time lag  $[\underline{\gamma}_{g,g'}; \overline{\gamma}_{g,g'}]$  between two related treatment groups  $g$  and  $g'$  (e.g., in Fig. 1,  $g_5$  needs to fall into the interval [1;3] relative to the scheduled day of  $g_4$ ). Moreover, a group can be tied to a certain ward stay which means that the group can only be performed during a certain ward stay (e.g.,  $g_1$  and  $g_2$  from Fig. 1 can only be scheduled during the first ward stay). Note that by grouping treatments as described, many CP-related constraints are aggregated and even considered implicitly. On the one hand, this contributes to a tractable size of the ILP models to be described in the next section, on the other hand, the modeling itself is facilitated by the grouping.

## 4 A Hierarchical ILP Approach for Scheduling Clinical Pathways

As observed in the literature review, while there are approaches for scheduling clinical pathways, these approaches typically consider both bed and treatment-related resources on a very high level of aggregation. As became clear in discussions with practitioners at our partner hospital and also in our computational results, however, while scheduling on the basis of days is a reasonable assumption, a high level of resource aggregation may lead to disaggregation problems and thus to clinical pathways which are not implementable in practice. Furthermore, they emphasized that it is important to consider that resource eligibility for treatments typically depends on special qualifications and equipment.

In this section, we introduce a flexible modeling and solution approach for scheduling clinical pathways which considers resources on a higher level of detail: On the one hand, bed resources are considered on the level of rooms located on wards, allowing to explicitly account for the gender separation requirement. On the other hand, resources are modeled under consideration of attributes such as special qualifications or equipment, allowing a realistic attribute-based representation of the resources eligible for a certain treatment. Furthermore, in order to avoid disaggregation problems, complex resources are considered individually. The flexibility of the model is also emphasized in the formulation of the objective function: It involves various patient and resource-related objectives; by adjusting the objective function cost coefficients, different preference structure of the decision makers can be represented.

While it is possible to formulate a single monolithic ILP model for this problem, as will be become clear in the experimental results in Section 6, for practically relevant problem sizes, the resulting model instances are not solvable by state-of-the art MIP solvers in a reasonable amount of time.

As a consequence, similar to Schimmelpfeng et al. (2012), we employ a two-stage approach which can be viewed as a constructional hierarchical decomposition in the terminology of hierarchical planning, see e.g. (Schneeweiss 1998): The first stage determines the “cornerstones” of the clinical pathway, that is, the patient admission and discharge days as well as the days of the complex key treatments of each clinical pathway. Taking these instructions from the first stage as fixed decisions, the second stage solves the full problem sketched above. In order to obtain a high-quality solution for the full problem, the first-stage model anticipates major aspects of the full planning problem using anticipation model components obtained by the means of aggregation and relaxation: While the first stage does not determine the ward stays, it anticipates ward stay scheduling under consideration of the gender separation requirement on the level of aggregated room types. Furthermore, while it only determines the dates of subset of complex treatments (under consideration of all required treatment resources), in order to make this scheduling consistent with the pathway constraints involving all treatments, the first-stage model also involves all remaining treatment groups (neglecting the respective resource requirements). Before presenting the ILP formulations for the first-stage and the second-stage model, we give a short overview of the notational conventions followed in the presentation.

#### 4.1 Notation Conventions and Variable Domains

We utilize calligraphic symbols for representing sets, in some cases refined with descriptive superscripts: As an example,  $\mathcal{P}$  denotes the set of patients,  $\mathcal{P}^m$  denotes the set of male patients. Descriptive superscripts also used for variables and parameters; subscripts are reserved for indices. Indices and parameters are written in lowercase (Greek letters are used for path-relative time information, see Section 3).

Decision variables are written as uppercase letters; we utilize the following conventions in order to enhance the readability of the models: The letter  $X$  is used for variables for which the value corresponds to day in the planning period, that is, the domain of these variables is the set  $\mathcal{D} = \{1, \dots, |\mathcal{D}|\}$ . Superscript are used to refer to specific groups of variables, e.g.,  $X_{p,s}^{ws}$  denotes the start day of ward stay  $s$  of patient  $p$ . Day-indexed variables are mostly denoted with  $Y$ , for example, the binary variable  $Y_{p,w,d}^{\text{ward}}$  indicates whether patient  $p$  stays at ward  $w$  at day  $d$  or not. Bookkeeping variables representing a duration, a slack or a violation of a soft constraint are denoted with  $U$ ; again specified with a descriptive superscript and possibly with an additional superscript signifying the direction of a violation. As an example, the variable  $U_p^{\text{ad}+}$  represents a positive violation from the desired admission date of patient  $p$ . If not specified otherwise, the bookkeeping variables are continuous non-negative variables. The letter  $Z$  is used for integer variables mostly representing assignment decisions; for example, the indicator variable  $Z_{p,s,q}^{\text{room}}$  takes the value of 1 if patient  $p$  stays in room  $q$  throughout her ward stay  $s$ .

#### 4.2 First-Stage Model

In the following exposition, we present the first-stage model used to determine the admission and discharge dates of the patients as well as dates of the (complex) key treatments in the clinical pathways. Note that all other decisions considered in the following model such as the start and end days of the ward stays, the aggregated gender-separated room assignments and the scheduled dates of the non-complex treatment groups are not transferred to the second-stage model as instructions but merely serve anticipation purposes.

*Scheduling Admission, Ward Stays and Discharge*

For each ward stay  $s$  from the ordered set  $\mathcal{S}_p = \{1..|\mathcal{S}_p|\}$  of ward stays of patient  $p$ , the decision variable  $X_{p,s}^{ws}$  represents the start day of the ward stay. The set of constraints (1) both computes the length  $U_{p,s}^{los}$  of the ward stay and establishes the correct sequencing of the ward stays of each patient. Note that in the constraint sets associated with the last ward stay  $|\mathcal{S}_p|$  of each patient, the index  $|\mathcal{S}_p| + 1$  arises as a subscript of the ward stay start variable; this variable can be interpreted as the first day after the end of hospitalization. The set of constraints (2) enforces the hard lower bound  $\underline{b}_{p,s}^{los}$  as well as the soft upper bound  $\bar{b}_{p,s}^{los}$  along with the upper bound violation variable  $U_{p,s}^{los+}$  for the length of stay of ward stay  $s$  of patient  $p$ .

$$X_{p,s+1}^{ws} - X_{p,s}^{ws} = U_{p,s}^{los} \quad \forall p \in \mathcal{P}, s \in \mathcal{S}_p \quad (1)$$

$$\underline{b}_{p,s}^{los} \leq U_{p,s}^{los} \leq \bar{b}_{p,s}^{los} + U_{p,s}^{los+} \quad \forall p \in \mathcal{P}, s \in \mathcal{S}_p \quad (2)$$

Every patient  $p$  has a desired admission day  $d_p^{desAd}$ . In the set of constraints (3), the deviation of the scheduled admission day  $X_{p,1}^{ws}$  from this day is registered by the variables  $U_p^{ad-}$  and  $U_p^{ad+}$  both of which are bound by the maximum allowed deviation  $\bar{b}^{devAd}$  enforced by the constraint set (4).

$$X_{p,1}^{ws} = d_p^{desAd} - U_p^{ad-} + U_p^{ad+} \quad \forall p \in \mathcal{P} \quad (3)$$

$$0 \leq U_p^{ad+} \leq \bar{b}^{devAd} ; 0 \leq U_p^{ad-} \leq \bar{b}^{devAd} \quad \forall p \in \mathcal{P} \quad (4)$$

*Aggregated Consideration of Bed Resources and Gender Separation*

For anticipation purposes, the first-level model considers bed resources as well as the gender separation requirement on the level of aggregated room types. In order to model these requirements, the day-indexed variables  $Y_{p,s,w,d}^{ward}$  indicate whether on day  $d$ , patient  $p$  occupies a bed on ward  $w$  during ward stay  $s$  on one of the eligible wards in set  $\mathcal{W}_{p,s}$ . The three sets of constraints (5)-(7) link the bed occupation variables  $Y_{p,s,w,d}^{ward}$  to the scheduling of the ward stays: Constraint (5) ensures that the number of bed occupation days equals the length of the ward stays; constraints (6) and (7) force the bed occupation days to fall into the scheduled period of the corresponding ward stay.

$$\sum_{w \in \mathcal{W}_{p,s}} \sum_{d \in \mathcal{D}} Y_{p,s,w,d}^{ward} = U_{p,s}^{los} \quad \forall p \in \mathcal{P}, s \in \mathcal{S}_p \quad (5)$$

$$X_{p,s}^{ws} \leq d + M \left( 1 - \sum_{w \in \mathcal{W}_{s,p}} Y_{p,s,w,d}^{ward} \right) \quad \forall p \in \mathcal{P}, s \in \mathcal{S}_p, d \in \mathcal{D} \quad (6)$$

$$X_{p,s+1}^{ws} - 1 \geq d - M \left( 1 - \sum_{w \in \mathcal{W}_{s,p}} Y_{p,s,w,d}^{ward} \right) \quad \forall p \in \mathcal{P}, s \in \mathcal{S}_p, d \in \mathcal{D} \quad (7)$$

In order to ensure that a patient is assigned to a single ward during the full ward stay, we introduce the binary ward assignment variable  $Z_{p,s,w}^{ward}$  indicating whether the ward stay  $s$  of patient  $p$  is assigned to ward  $w$ . The set of bundle constraints (8) ensures that this assignment

is unique; constraints (9) ensure that the bed occupation variables may only take a value of one on the assigned ward.

$$\sum_{w \in \mathcal{W}_{p,s}} Z_{p,s,w}^{\text{ward}} = 1 \quad \forall p \in \mathcal{P}, s \in \mathcal{S}_p \quad (8)$$

$$\sum_{d \in \mathcal{D}} Y_{p,s,w,d}^{\text{ward}} \leq Z_{p,s,w}^{\text{ward}} \quad \forall p \in \mathcal{P}, s \in \mathcal{S}_p, w \in \mathcal{W}_{p,s} \quad (9)$$

While the first-stage model does not involve an assignment of patients to a concrete room, it enforces on an aggregate level that on each day, there exists an assignment of patients to rooms respecting the gender separation requirement. In order to achieve this, the set of rooms  $\mathcal{Q}_w$  on ward  $w$  is partitioned into subsets  $\mathcal{Q}_{w,b}$  according to the number of beds  $b$  in the rooms; the set  $\mathcal{B}$  contains the possible number of beds in rooms. For each day  $d \in \mathcal{D}$ , the number of rooms on ward  $w$  with  $b$  beds used as female (male) room is decided by the integer decision variable  $Z_{w,b,d}^{\text{fRoom}}$  ( $Z_{w,b,d}^{\text{mRoom}}$ ). The constraints (10) ensure that on each day  $d$  on each ward  $w$  and for room capacity  $b$ , the total number of male and female rooms does not exceed the number  $|\mathcal{Q}_{w,b}|$  of rooms with the corresponding capacity. The constraints (11) and (12) ensure that for each ward  $w$  on each day  $d$ , the number of female (male) patients having a bed on a certain ward does not exceed the total number of beds available in the rooms assigned to female (male) patient plus the number of additional beds recorded in the variables  $U_{w,d}^{\text{fBed}^+}$  and  $U_{w,d}^{\text{mBed}^+}$ .

$$\sum_{p \in \mathcal{P}^f} \sum_{s \in \mathcal{S}_{p,w}} Z_{w,b,d}^{\text{fRoom}} + \sum_{p \in \mathcal{P}^m} \sum_{s \in \mathcal{S}_{p,w}} Z_{w,b,d}^{\text{mRoom}} \leq |\mathcal{Q}_{w,b}| \quad \forall w \in \mathcal{W}, b \in \mathcal{B}, d \in \mathcal{D} \quad (10)$$

$$\sum_{p \in \mathcal{P}^f} \sum_{s \in \mathcal{S}_{p,w}} Y_{p,s,w,d}^{\text{ward}} \leq \sum_{b \in \mathcal{B}} b Z_{w,b,d}^{\text{fRoom}} + U_{w,d}^{\text{fBed}^+} \quad \forall w \in \mathcal{W}, d \in \mathcal{D} \quad (11)$$

$$\sum_{p \in \mathcal{P}^m} \sum_{s \in \mathcal{S}_{p,w}} Y_{p,s,w,d}^{\text{ward}} \leq \sum_{b \in \mathcal{B}} b Z_{w,b,d}^{\text{mRoom}} + U_{w,d}^{\text{mBed}^+} \quad \forall w \in \mathcal{W}, d \in \mathcal{D} \quad (12)$$

### Scheduling Treatments Considering Pathway Constraints

As noted in Section 3, in our approach, treatments occurring on the same day are aggregated to form a treatment group. In the mathematical model, the integer decision variable  $X_{p,g}^{\text{treat}}$  represents the day on which the treatment group  $g$  from the set  $\mathcal{G}_p$  of all treatment groups of a patient  $p$  is scheduled. In order to anticipate the pathway constraints in the first-stage model, the set  $\mathcal{G}_p$  encompasses all treatment groups (not only those containing key treatments to be scheduled in the first stage).

The scheduling of treatments is linked to the scheduling of ward stays in two ways: First, as modelled in constraints (13), for each treatment group  $g$ , there is a time window  $[\underline{\delta}_{p,g}; \bar{\delta}_{p,g}]$  relative to the admission date of patient  $p$  associated with the variable  $X_{p,1}^{\text{ws}}$ ; violations of the time window are registered by the variables and  $U_{p,g}^{\text{tw}^+}$ . Second, as modelled by constraints (14), a subset  $\mathcal{G}_{p,s}$  of the treatment groups  $\mathcal{G}_p$  of a patient  $p$  may require to be performed during the ward stay  $s$  of  $p$ .

$$X_{p,1}^{\text{ws}} + \underline{\delta}_{p,g} \leq X_{p,g}^{\text{treat}} \leq X_{p,1}^{\text{ws}} + \bar{\delta}_{p,g} + U_{p,g}^{\text{tw}^+} \quad \forall p \in \mathcal{P}, g \in \mathcal{G}_p \quad (13)$$

$$X_{p,s}^{\text{ws}} \leq X_{p,g}^{\text{treat}} \leq X_{p,s+1}^{\text{ws}} - 1 \quad \forall p \in \mathcal{P}, s \in \mathcal{S}_p \quad (14)$$

In addition to the relations enforced by (13) and (14); the constraint-based pathway model described in Section 4 considers sequence constraints providing an interval  $[\underline{\gamma}_{g,g'}, \bar{\gamma}_{g,g'}]$  between a treatment group  $g$  and a successive treatment group  $g'$ . The set of successors of a treatment group  $g$  in the pathway of patient  $p$  subject to this type of constraint is denoted with  $\mathcal{G}_{p,g}^{\text{succ}}$ ; the respective constraints in the model can be formulated as follows:

$$X_{p,g}^{\text{treat}} + \underline{\gamma}_{p,g,g'} \leq X_{p,g'}^{\text{treat}} \leq X_{p,g}^{\text{treat}} + \bar{\gamma}_{p,g,g'} \quad \forall p \in \mathcal{P}, g \in \mathcal{G}_p, g' \in \mathcal{G}_{p,g}^{\text{succ}} \quad (15)$$

### Modelling Treatment Resource Requirements

In order to perform the treatments in the aggregated treatment groups, certain resources such as operating rooms, physicians and nurses are needed. As mentioned above, the first-stage model only considers the resource requirement for a subset of treatment groups denoted with  $\mathcal{G}_p^{\text{res}}$  in the following exposition.

When it comes to the representation of these resource requirements, most publications dealing with pathway scheduling rely on a simple representation of resources and requirements: Resources have a unique resource type (or a unique identifier) and the resource requirements are formulated in terms of time needed per resource type (or per specific resource). In reality, however, the eligibility of resources for treatment requirements depends on a vector of resource attributes such as qualifications (e.g., the capability of conducting a certain surgery) or features (e.g. special equipment only available in certain operating rooms). In this work, this more complex type of representing resource eligibility is referred to as attribute-based resource eligibility and modelled as follows:

We represent the resource requirements on the level of treatment groups; for each group, the requirements of all treatments in the group are aggregated. The set of resource requirements for a treatment group  $g$  of patient  $p$  is denoted with  $\mathcal{K}_{p,g}$ ; the amount of resource time needed for the requirement  $k \in \mathcal{K}_{p,g}$  is given by the parameter  $a_{p,g,k}$ . A resource requirement  $k$  is further associated with a set  $\mathcal{R}_k$  of eligible resources; the eligibility of a resource for a requirement depends on whether the resource exhibits all attributes (qualifications, equipment) specified in the requirement.

For each day  $d$  and for each eligible resource  $k \in \mathcal{K}_{p,g}$  for group  $g$  of patient  $p$ , there is a binary assignment variable  $Z_{p,g,k,r,d}^{\text{res}}$  indicating whether resource  $r$  is used to cover the resource requirement  $k$  of treatment group  $g$  of patient  $p$  scheduled at day  $d$ . The set of bundle constraints (16) ensures that exactly one resource is chosen for each requirement; constraints (17) link the resource assignment variables to the treatment group scheduling variables. For each resource  $r$ , the nominal capacity at day  $d$  is given by  $\bar{b}_{r,d}^{\text{res}}$ ; using the slack variables  $U_{r,d}^{\text{ot}}$  and  $U_{r,d}^{\text{it}}$  registering the overtime and the idle time, the corresponding resource capacity constraints are given in (18). Constraints (19) ensure that for both the amount of overtime and of idle time per resource and day is restricted by an upper bound ( $\bar{b}_r^{\text{ot}}$  and  $\bar{b}_r^{\text{it}}$ ).

$$\sum_{d \in \mathcal{D}} \sum_{r \in \mathcal{R}_k} Z_{p,g,k,r,d}^{\text{res}} = 1 \quad \forall p \in \mathcal{P}, g \in \mathcal{G}_p^{\text{res}}, k \in \mathcal{K}_{p,g} \quad (16)$$

$$X_{p,g}^{\text{treat}} = \sum_{d \in \mathcal{D}} \sum_{r \in \mathcal{R}_k} d Z_{p,g,k,r,d}^{\text{res}} \quad \forall p \in \mathcal{P}, g \in \mathcal{G}_p^{\text{res}}, k \in \mathcal{K}_{p,g} \quad (17)$$

$$\sum_{p \in \mathcal{P}} \sum_{g \in \mathcal{G}_p^{\text{res}}} \sum_{k \in \mathcal{K}_{p,g}} a_{p,g,k}^{\text{res}} z_{p,g,k,r,d}^{\text{res}} = \bar{b}_{r,d}^{\text{res}} + U_{r,d}^{\text{ot}} - U_{r,d}^{\text{it}} \quad \forall r \in \mathcal{R}, d \in \mathcal{D} \quad (18)$$

$$0 \leq U_{r,d}^{\text{ot}} \leq \bar{b}_r^{\text{ot}}; \quad 0 \leq U_{r,d}^{\text{it}} \leq \bar{b}_r^{\text{it}} \quad \forall r \in \mathcal{R}, d \in \mathcal{D} \quad (19)$$

Note that our formulation of resource requirements and capacities given by the constraints (16)-(19) is valid both for individual and aggregated resources. Resources can be aggregated if they have the same attribute values, e.g. the same qualifications or features. In our case study, for example, the OR nurses can be considered as an aggregated resource. In case of an aggregated resource  $r \in \mathcal{R}$ , the resource capacity  $\bar{b}_{r,d}^{\text{res}}$  per day corresponds to the sum of the capacity of all individual resources on that day.

Note, however, that in addition to adequately modelling resources with different attributes, there is another reason for individually considering (complex) resources: The requirements for these resources often comprise multiple hours and it is not possible to switch the assigned resource during a treatment. Aggregating these resources thus easily leads to a situation where there is no feasible disaggregated allocation to individual resources for an aggregated solution.

### Objective Function

The objective function of the first-stage model involves multiple patient- and resource-related objectives combined in a single function; depending of the preferences of the decision maker, the objective function coefficients can be chosen accordingly. An important part of the objective function deals with patient delays. The constraints sets (20) and (21) compute the total delay  $U_p^{\text{del}}$  of a patient: Constraint set (20) ensured that the total delay of a patient is at least as big as the number of days exceeding the medically required minimum length of stay  $\underline{b}_p^{\text{los}}$ . In addition to that, the constraints (21) force the total delay to be bigger than the sum of the ward stay delays  $U_{p,s}^{\text{los}+}$  and the treatment delays  $U_{p,t}^{\text{tw}+}$ . In order to establish fairness among the patients and to avoid huge delays of single patients, a min-max objective involving the maximum total delay  $U^{\text{maxDel}}$  of all patients is used;  $U^{\text{maxDel}}$  is forced to the maximum of all patient delays by constraints (22). Similarly, in order to be able to enforce a smooth resource allocation along the full planning horizon, for each resource  $r \in \mathcal{R}$ , the constraints (23) compute the maximum overtime  $U_r^{\text{maxOt}}$  and the maximum  $U_r^{\text{maxIt}}$  over all days of the planning horizon.

$$U_p^{\text{del}} \geq U_p^{\text{los}} - \underline{b}_p^{\text{los}} \quad \forall p \in \mathcal{P} \quad (20)$$

$$U_p^{\text{del}} \geq \sum_{s \in \mathcal{S}_p} U_{p,s}^{\text{los}+} + \sum_{t \in \mathcal{T}_p} U_{p,t}^{\text{tw}+} \quad \forall p \in \mathcal{P} \quad (21)$$

$$U^{\text{maxDel}} \geq U_p^{\text{del}} \quad \forall p \in \mathcal{P} \quad (22)$$

$$U_r^{\text{maxOt}} \geq U_{r,d}^{\text{ot}}; \quad U_r^{\text{maxIt}} \geq U_{r,d}^{\text{it}} \quad \forall r \in \mathcal{R}, d \in \mathcal{D} \quad (23)$$

The maximum total delay  $U^{\text{maxDel}}$  weighted with the penalty  $c^{\text{maxDel}}$  forms the first patient-related term in the first-stage minimization objective function (24). The other patient-related terms of the objective functions involve the individual delays  $U_p^{\text{del}}$  associated with the penalty  $c^{\text{del}}$  as well as the deviations from the desired admission days  $U_p^{\text{ad-}}$  and  $U_p^{\text{ad+}}$  of each patient  $p$  weighted with the coefficient  $c^{\text{ad}}$ . The remaining elements of the objective function deal with resource-related aspects: A penalty  $c^{\text{bed+}}$  is imposed for each female and male extra bed needed



per day. Regarding the treatment resources, overtime and idle time of each resource  $r \in \mathcal{R}$  are considered in the objective function two ways: First, for each resource the maximum overtime  $U_r^{\max\text{Ot}}$  and idle time  $U_r^{\max\text{It}}$  over the full planning period are considered using the penalties  $c^{\max\text{Ot}}$  and  $c^{\min\text{Ot}}$ . Second, for each day  $d \in \mathcal{D}$ , the overtime  $U_{r,d}^{\text{ot}}$  and idle time  $U_{r,d}^{\text{it}}$ , weighted with the penalties  $c_d^{\text{ot}}$  and  $c_d^{\text{it}}$ , contribute to the objective function.

$$\begin{aligned} \min \quad & c^{\max\text{Del}} U^{\max\text{Del}} + \sum_{p \in \mathcal{P}} \left( c^{\text{del}} U_p^{\text{del}} + c^{\text{ad}} (U_p^{\text{ad-}} + U_p^{\text{ad+}}) \right) + \sum_{w \in \mathcal{W}} \sum_{d \in \mathcal{D}} c^{\text{bed+}} (U_{w,d}^{\text{fBed+}} + U_{w,d}^{\text{mBed+}}) \\ & + \sum_{r \in \mathcal{R}} \left( c^{\max\text{Ot}} U_r^{\max\text{Ot}} + c^{\max\text{It}} U_r^{\max\text{It}} + \sum_{d \in \mathcal{D}} (c_d^{\text{ot}} U_{r,d}^{\text{ot}} + c_d^{\text{it}} U_{r,d}^{\text{it}}) \right) \end{aligned} \quad (24)$$

#### 4.1 Second-Stage Model

Considering the instructions from the first-stage model, that is, the patient admission and discharge dates as well as the scheduled days of the complex treatments, the second-stage model schedules the remaining treatments and performs the detailed allocation of patients to rooms on the wards respecting gender separation constraints.

Besides the fact that in the second-stage model, certain decisions are considered as fixed, the main differences between the first-stage and the second-stage model are the level of detail on which the bed resources are modeled and the fact that in the second-stage model, all treatment groups are scheduled under consideration of their resource requirements. As a result, assuming that in the second-stage model, the sets of treatment groups  $\mathcal{G}_p^{\text{res}}$  contains all relevant treatment groups instead of only the subset of complex key treatments, the constraint sets (1)-(4) dealing with scheduling ward stays (implying admission and discharge days) and (13)-(23) mainly dealing with treatment scheduling and the allocation treatment resources also appear in the second-stage model. In the following, we present the structurally different parts of the second-stage model, that is, the constraints for imposing the first-level decisions, the model component for representing bed resources on a high level of detail and the objective function in which the bed-related terms make use of the variables introduced in the second-stage model.

##### *Imposing the Instructions from the First-Stage Model*

In order to enforce the instructions from the first-stage model in the second-stage model, we impose the following constraints fixing the respective variables: Constraints set (25) fixes the admission day  $d_p^{\text{ad}}$  and the discharge day  $d_p^{\text{dis}}$  of each patient. Assuming that for each patient  $p$ , the set of treatment groups scheduled by the first-stage model is denoted with  $\mathcal{G}_p^{\text{fixed}}$  and that  $d_{p,g}^{\text{treat}}$  corresponds to the day on which treatment group  $g \in \mathcal{G}_p^{\text{fixed}}$  is scheduled, constraints (26) fix the respective scheduling decisions in the second-stage model.

$$X_{p,1}^{\text{ws}} = d_p^{\text{ad}} ; X_{p,|S|+1}^{\text{ws}} - 1 = d_p^{\text{dis}} \quad \forall p \in \mathcal{P} \quad (25)$$

$$X_{p,g}^{\text{treat}} = d_{p,g}^{\text{treat}} \quad \forall p \in \mathcal{P}, g \in \mathcal{G}_p^{\text{fixed}} \quad (26)$$

##### *Bed Resources, Room Assignment and Gender Separation Based on Individual Rooms*

In contrast to the first-stage model in which on each ward, the rooms with a common bed capacity are aggregated, the second-stage model considers each room individually. For each

day  $d$ , the binary day-indexed room stay variables  $Y_{p,s,q,d}^{\text{room}}$  determine whether a patient  $p$  stays in room  $q$  in ward stay  $s$ ;  $Q_{p,s}$  denotes the set of rooms which can be used by patient  $p$  for ward stay  $s$ . In analogy to the constraints (5)-(7) in the first-stage model, constraints (27)-(29) link the  $Y_{p,s,q,d}^{\text{room}}$  variables to the ward stay start variables  $X_{p,s}^{\text{ws}}$ ; enforcing the allocation of a bed in a room for each day of each ward stay.

$$\sum_{q \in Q_{p,s}} \sum_{d \in \mathcal{D}} Y_{p,s,q,d}^{\text{room}} = U_{p,s}^{\text{los}} \quad \forall p \in \mathcal{P}, s \in \mathcal{S}_p \quad (27)$$

$$X_{p,s}^{\text{ws}} \leq d + M \left( 1 - \sum_{q \in Q_s} Y_{p,s,q,d}^{\text{room}} \right) \quad \forall p \in \mathcal{P}, s \in \mathcal{S}_p, d \in \mathcal{D} \quad (28)$$

$$X_{p,s+1}^{\text{ws}} - 1 \geq d - M \left( 1 - \sum_{q \in Q_{p,s}} Y_{p,s,q,d}^{\text{room}} \right) \quad \forall p \in \mathcal{P}, s \in \mathcal{S}_p, d \in \mathcal{D} \quad (29)$$

In the second-stage model, it is assumed that a patient resides in the same room during the full ward stay. The assignment of a room  $q$  to a patient  $p$  at her ward stay  $s$  is represented in the binary decision variable  $Z_{p,s,q}^{\text{room}}$ ; the constraints set (30) ensures that each patient is assigned exactly one room during each ward stay. Constraints (31) enforce that the values of the day-indexed room assignment variables  $Y_{p,s,q,d}^{\text{room}}$  are in line with the same-room requirement.

$$\sum_{q \in Q_{p,s}} Z_{p,s,q}^{\text{room}} = 1 \quad \forall p \in \mathcal{P}, s \in \mathcal{S}_p \quad (30)$$

$$\sum_{d \in \mathcal{D}} Y_{p,s,q,d}^{\text{room}} \leq Z_{p,s,q}^{\text{room}} \quad \forall p \in \mathcal{P}, s \in \mathcal{S}_p, q \in Q_{p,s} \quad (31)$$

The gender separation requirement means that on each day in each room, all occupants share the same gender. In the model, the binary decision variable  $Y_{q,d}^{\text{mRoom}}$  is introduced;  $Y_{q,d}^{\text{mRoom}}$  equals 1 if room  $q$  is a “male room” and 0 if room  $q$  is a “female room” on day  $d$ . The constraints (32) and (33) enforce that for each day  $d$  and in each room  $q$ , the gender of the room occupants is consistent with the value of the variable  $Y_{q,d}^{\text{mRoom}}$  and at the same time ensure the room capacity is respected; it is assumed that the room capacity can be extended by extra beds registered by the variable  $U_{q,d}^{\text{mBed+}}$  for beds occupied by males and  $U_{q,d}^{\text{fBed+}}$  occupied by females. The set of constraints (34) ensures that for each room and for each day, the upper bound  $b_q^{\text{add}}$  for the number of extra beds is respected and that the gender of the extra bed occupants matches the gender assignment of the rooms on each day.

$$\sum_{p \in \mathcal{P}^{\text{m}}} \sum_{s \in \mathcal{S}_{p,q}} Y_{p,s,q,d}^{\text{room}} \leq b_q Y_{q,d}^{\text{mRoom}} + U_{q,d}^{\text{mBed+}} \quad \forall q \in Q, d \in \mathcal{D} \quad (32)$$

$$\sum_{p \in \mathcal{P}^{\text{f}}} \sum_{s \in \mathcal{S}_{p,q}} Y_{p,s,q,d}^{\text{room}} \leq b_q (1 - Y_{q,d}^{\text{mRoom}}) + U_{q,d}^{\text{fBed+}} \quad \forall q \in Q, d \in \mathcal{D} \quad (33)$$

$$U_{q,d}^{\text{mBed+}} \leq b_q^{\text{add}} Y_{q,d}^{\text{mRoom}} \quad ; \quad U_{q,d}^{\text{fBed+}} \leq b_q^{\text{add}} (1 - Y_{q,d}^{\text{mRoom}}) \quad \forall q \in Q, d \in \mathcal{D} \quad (34)$$

*Objective Function*

The objective function of the second-stage model is given by (35). While the scheduling objectives of both levels are basically identical, the objective function (35) reflects the main differences between the models on the two levels: First, since the admission decisions are fixed in the second stage, (35) does not consider admission day preferences. Second, since the level of detail of the bed allocation in the second-stage model is higher than in the first-stage model, the corresponding term is adapted.

$$\begin{aligned} \min \quad & c^{\max\text{Del}} U^{\max\text{Del}} + \sum_{p \in \mathcal{P}} c^{\text{del}} U_p^{\text{del}} + \sum_{q \in \mathcal{Q}} \sum_{d \in \mathcal{D}} c^{\text{bed}+} (U_{q,d}^{\text{fBed}+} + U_{q,d}^{\text{mBed}+}) \\ & + \sum_{r \in \mathcal{R}} \left( c^{\max\text{Ot}} U_r^{\max\text{Ot}} + c^{\max\text{It}} U_r^{\max\text{It}} + \sum_{d \in \mathcal{D}} (c_d^{\text{ot}} U_{r,d}^{\text{ot}} + c_d^{\text{it}} U_{r,d}^{\text{it}}) \right) \end{aligned} \quad (35)$$

## 5 Real-World Case Study from a German University Hospital

The research presented in this paper is based on a partnership with a German University Hospital providing us both with data and with an opportunity to discuss our assumptions with domain experts such as the case manager of the department of urology considered in our experiments. In this section, we describe the pathways and the case data to be scheduled, the resource capacities considered for scheduling and the scenarios used for our computational experiments.

### 5.1 Automated Pathway Extraction

One of the key features of our approach is that its underlying CP data can be automatically obtained by applying the CP mining approach proposed in (Helbig et al. 2015). Since this mining approach operates with standardized hospital billing data according to the §21KHEntG<sup>14</sup> which has to be reported by each hospital in Germany, it is readily applicable for each German hospital. The mining approach allows us to evaluate our CP scheduling approach for a real-world data set of a university hospital in Germany from 2011. This section describes the main characteristics of this data set and the resulting CP.

In 2011, the case study hospital had around 36.000 admissions divided into around 25.000 elective and 11.000 emergency inpatients. Figure 2 shows the amount of elective admissions on each ward in 2011. The department of urology (HA2200) has the highest number of cases; Figure 3 shows the distribution of these cases grouped by month of admission. In order to evaluate the performance of our model, we selected the peak month (March) of the department




Fig. 2: Distribution of Elective Patients on Wards




Fig. 3: Distribution of Cases on HA2200 in 2011

<sup>14</sup> More details about structure and containing data as well as an example dataset can be found at: [http://www.g-drg.de/cms/Datenveroeffentlichung\\_gem.\\_21\\_KHEntG](http://www.g-drg.de/cms/Datenveroeffentlichung_gem._21_KHEntG)

with the highest number of cases. In March, 286 cases with 90 different primary diagnoses and 69 different DRG were admitted. The percentage of female patients was approx. 17%. To receive CP according to the constraint-based concept discussed in Section 3 from the billing data, we applied the approach from (Helbig et al. 2015). This approach identifies similar treatment profiles for each primary diagnosis and creates corresponding homogenous case groups. Based on these groups, feasible intervals for treatments and ward stays as well as order constraints are determined. Note that if only a single case with a certain treatment profile occurs in the database, the mining approach returns treatment chains without scheduling flexibility for treatments and ward stays.

Applying the mining approach to the described data set resulted in 229 different CP among which 136 are based on unique treatment profiles and 93 represent profiles occurring more than once. Figure 4 to 6 show different CP for the primary diagnosis prostatic hyperplasia based on a single treatment profile (Fig. 4), a profile occurring three times (Fig. 5) and the most frequent profile (Fig. 6) for the primary diagnosis of malignant tumors of the prostate. As can be seen in Fig. 4 to 6, all CP only exhibit one ward stay consisting of admission and discharge on the department of urology. Each CP contains a specific set of treatments based on the OPS-Codes (operations and procedures) documented in the billing data according to §21KHentG. Fig. 4 shows a unique CP without scheduling flexibility for the treatment groups, Fig. 5 and 6 depict profiles occurring more than once exhibiting scheduling flexibility for the treatment groups.

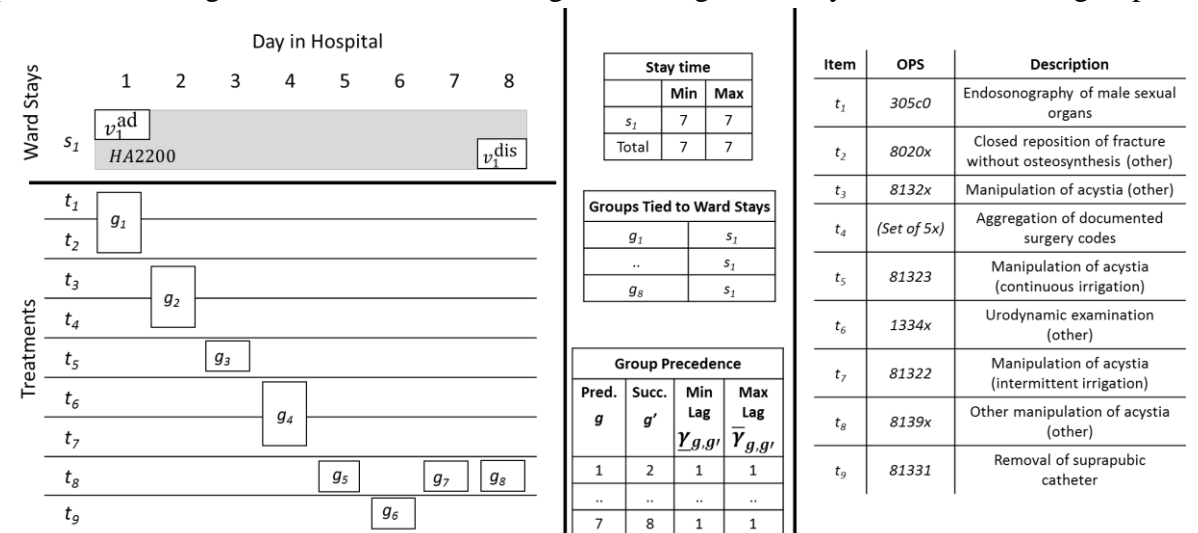


Fig. 4: Unique CP for Prostatic Hyperplasia

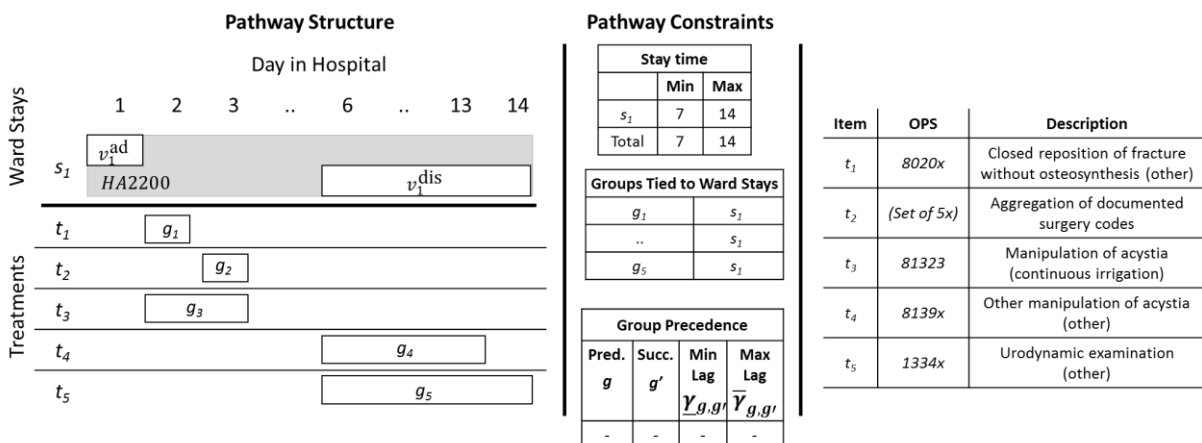


Fig. 5: CP for Prostatic Hyperplasia Occuring 3 Times




Fig. 6: CP for Malignant Tumors of the Prostate occurring 75 Times

## 5.2 Resource Requirements and Availability

In addition to the CP structure discussed so far, information regarding required and available resources is needed for our approach. In order to obtain a realistic set of parameters, we discussed all 259 different OPS-Codes that had occurred during our planning horizon (March 2011) with the case manager of the department for urology. Table 2 shows an excerpt of the required time on resource types needed by a treatment.

OPS-Code	Required Time on Resource Type (h)								
	Physician	Nurse	OR	OR-Nurse	Deputy	Urography <sup>15</sup>	MRT	Anesthetist	..
12750	0.5	0.5							..
13341	2	2				2			..
557840	2 x 0.75		0.75	0.75				0.75	..
560401	2 x 4		4	4	4			4	..
81372	0.5	1				0.5		0.5	..
..	..	..	..	..	..	..	..	..	..

Table 2: Excerpt of Required Resource Time of OPS

Since OPS-Codes are very detailed and surgeries involve multiple codes, considering each individual set of codes would typically result in a unique type of pathway for each surgery. In order to avoid this, all surgery codes (starting with a “5”) are aggregated to one artificial code. Furthermore, due the lack of duration data for these aggregated surgery code sets, the duration of a surgery is approximated by the maximum time a single resource type was used for the full set of codes associated with the surgery. This time is then used as the amount of time needed on each required resource. In order to obtain a robust schedule and in order to heuristically consider the time needed for preparation and follow-up tasks, it is assumed that all required resources are needed for the full surgery duration. Table 3 shows an excerpt of required resource types and their required time for some example surgeries; each surgery belongs to a primary diagnosis and a CP variant. For example, the surgery with the primary diagnosis C61 in variant 1 is based on the OPS-Codes 557840 and 560401. Using our assumptions, the required capacity for physicians and anesthetists of are 8 hours (4 hours times 2 physicians) and 4 hours. In general, the case manager of the department of urology considered this way of approximating resource requirements as valid. In some special cases, however, a more complex way of

<sup>15</sup> This is a special kind of operating room located in the department of urology.

computing resource requirements, e.g. a rule-based aggregation, would be more appropriate. Given that this paper focuses on scheduling, we consider this issue as future work.

Diagnosis (ICD-Code)	CP-Variant	Required Resource Time (h)					
		Physician	Deputy	OR-Nurse	OR	Anesthetist	..
N40	22	2	2	4	2		..
N40	24	0,75	0,75	0,75	0,75		..
C61	1	8	4	4	4	4	..
..	..	..	..	..	..	..	..

Table 3: Excerpt of Required Time on Resources for Surgeries

The case study department has a capacity of 88 patients during workdays and 73 at weekends spread on 7 single-, 5 double-, 9 three- and 11 four-bed rooms. We assume that small rooms are not used for scheduling elective patients because of their flexibility in handling emergencies. Based on this assumption, we reduced the amount of available beds to 53 by keeping all 11 four-bed rooms and 3 three-bed rooms. With regard to the CP to be scheduled, there are four additional departments in which beds are needed for ward stays. For these departments, we assume a bed capacity based on the observed number patient cases in the data and spread this amount to double bed rooms.

Regarding the treatment resources, we consider scarce and special resources such as operating rooms and the urography individually. On the one hand, this allows modeling resource eligibility for treatments in a detailed way, on the other hand, it avoids disaggregation issues such as scheduling three four-hour surgeries on a day while there are only two OR available for six hours at the same day. Other resources such as human resources with identical properties (e.g. OR nurses) are aggregated.

Based on the observation that in March 2011, approximately 60% of all patients were elective, for all treatment resources owned by the urology department, it is assumed that 60% of the total available time can be scheduled for elective patients. Furthermore, based on interviews with the department case manager, the per-day availability of shared hospital resources such as central OR, MRT or computer tomography for the urology department was determined.

Table 4 shows an excerpt of the capacity available for scheduling elective patients per resource type for each weekday.

Resource Type	Resource	Amount of Available Time (h)						
		Mon	Tue	Wed	Thu	Fri	Sat	Sun
Physician		58	58	58	58	58	15	10
OR	Central OR	10	10	10	6	10	0	0
	OR-HA2200	5	5	5	5	5	5	5
OR-Nurse		24	24	24	24	24	5	5
Deputy		20	20	20	20	20	0	0
Urography	Uro-1	5	5	5	5	5	5	5
	Uro-2	10	10	10	10	10	10	10
..	..	..	..	..	..	..	..	..

Table 4: Excerpt of Available Resource Capacity for Elective Patients

### 5.3 Experimental Scenarios

The data from March 2011 described above involving 286 cases (217 male and 69 female patients) with in total 1088 treatments and 302 ward stays forms the basis of the two main experimental scenarios based on different resource allocation objectives considered in the following sections. In the first scenario, the hospital aims at establishing a smooth resource allocation throughout the planning horizon. As noted by the case manager, a smooth resource allocation is favored by the staff members and establishes a similar level of flexibility to react to emergency cases on each day of the planning horizon. In order to achieve a smooth allocation, the objective function coefficients associated with the min-max objectives as well as the penalty associated with daily resource overtime are both 10 while the other objectives are smaller (see Table 5). Since extra beds on rooms are considered as worse than idle time or patient delays, we set extra bed penalty to 5 and the delay and idle time penalties to 2.

In the second scenario, the hospital aims at establishing a high resource utilization at the beginning of the planning horizon. On the one hand, shifting workload into the near future provides more scheduling flexibility for the more distant future to cope with uncertainties, e.g. due to complications and emergencies; on the other hand, this flexibility enables the hospital to seize opportunities for admitting a higher number of elective patients in the future. This may be useful in particular in a setting where our approach is embedded in a rolling horizon approach. Furthermore, since this scenario focuses on advantages for the whole hospital and the potential for admitting additional patients, individual admission day preferences are ignored. The resulting set of objective function coefficients is depicted in Table 5; note that in particular, this scenario involves a quadratic decreasing day-dependent penalty for the idle time of resources and zero penalties for the maximum idle time and for the deviation from admission day penalties.

Scenario	$c^{\max\text{Del}}$	$c^{\text{del}}$	$c^{\text{ad}}$	$c^{\text{bed+}}$	$c^{\max\text{Ot}}$	$c^{\max\text{It}}$	$c_d^{\text{Ot}}$	$c_d^{\text{it}}$
Smooth Allocation	10	2	1	5	10	10	10	2
Early Allocation	10	2	0	5	10	0	10	$5 + \frac{(31 - d)^2}{100}$

Table 5: Objective Function Weights in the Two experimental Scenarios

## 6 Experimental Results

The real-world case study data described in the previous section forms the basis of a series of computational experiments with our hierarchical approach. The first set of experiments, discussed in Section 6.1, aims at assessing the hierarchical approach proposed in this paper by comparing it to an integrated approach and by evaluating different ways of considering the gender separation requirement in pathway scheduling. The second sets of experiments aim at discussing the results of the two in detail.

For the experiments, the ILP models presented in Section 4 were implemented AMPL; all treatments exhibiting a duration of more than 30 minutes (about 50% of the treatments) were considered to form the set  $\mathcal{G}_p^{\text{res}}$  of treatment groups to be scheduled in the first-stage model. The model instances were solved with Gurobi 6.5 on an Intel i7-3770 CPU with 3.40 GHz and 8.00 GB RAM using 6 threads. For solving the aggregated first-stage model, the relative MIP gap tolerance was set to 1%, the time limit was set to two hours and the MIP search strategy was set to focus on improving bounds. The second-stage model was solved using default Gurobi parameter settings.

### 6.1 Evaluating the Proposed Hierarchical Approach

From a modeling perspective, compared to approaches presented in the literature, our approach involves a more detailed representation of resources: It considers both multiple ward stays and room-level bed assignment respecting gender separation; on the level of treatments, it allows representing attribute-based resource eligibility for treatments and handles complex resources individually. In this Section, we experimentally evaluate our approach for handling the resulting large-scale model instances and discuss the effects of ignoring the gender separation requirement in different stages of the planning approach.

#### *Integrated vs Hierarchical Approach*

The main reason for introducing a hierarchical approach comes from the fact that solving an integrated (monolithic) model with a standard solver is not possible in a reasonable amount of time for realistically sized problem instances. Table 6 depicts the results from experiments with both a monolithic model for directly the full pathway scheduling problem and the hierarchical approach proposed in Section 5. For the computation with the monolithic model, we allowed for a maximal solution time of 12 hours and varied the maximum allowed deviation  $\bar{b}^{\text{devAd}}$  of the desired admission from 3 up to 10 days. The monolithic model instances exhibit 19.500 rows, 112.000 columns and 700.000 nonzeros; the instances of the first-stage model in the hierarchical approach contain 19.000 rows, 29.000 columns and 530.000 non-zeros; the instances of the second-stage model contain 2.200 rows, 6.200 columns and 25.000 nonzeros.

Instance	$\bar{b}^{\text{devAd}}$	Monolithic				Hierarchical	
		Integer (h)	Total (h)	GAP (%)	Obj	Total (s)	Obj
Smooth Allocation	3	7.25	12	1.03	7856	311	8344
	5	11.6	12	4.14	8096	544	8299
	10	-	12	$\infty$		4353	8101
Early Allocation	3	3.5	3.9	1	25160	35	26030
	5	-	12	$\infty$		194	25549

Table 6: Integrated vs. Hierarchical Approach

The results show that within the targeted solution time of two hours, for none of the monolithic instances even a feasible solution is found. For instances allowing for a bigger deviation from the desired admission day, this even holds after twelve hours of solution time. Furthermore, for all but a single instance allowing only a three-day deviation from the desired admission date, a solution meeting the predefined 1% optimality gap is found within the time window of 12 hours considered for this set of experiments. To enable a comparison of the monolithic and hierarchical objective values we added the weighted penalty on missing the preferred admission day on the results of the second model. Comparing the results of the instances for which the monolithic approach found feasible solutions after 12 hours, the results from our hierarchical approach obtained in less than 10 minutes exhibit a gap of only 2.5 % to 6%.

#### *The Effect of Ignoring Gender Separation*

Compared to other pathway scheduling approaches, our model operates on a higher level of detail. With regard to treatments, our model considers the eligibility of resources based on the attributes (qualifications, available equipment) of the resources instead of characterizing resources using a single resource type (nurse, operating room) and stating requirements in terms of these resource types. While the advantage of this more realistic representation for matching



treatments and resources cannot be evaluated experimentally in a straightforward way, in the following, we discuss results from comparing different levels of detail of representing the allocation of bed resources. To evaluate the relevance of considering gender separation on rooms, we compare the solution obtained with our approach (a priori consideration of gender separation) to a solution obtained by first scheduling pathways ignoring the gender separation requirement and afterwards determining a gender-separated room assignment is performed based on these schedules (a posteriori consideration of gender separation).

Table 7 shows the results from using this comparison for two instances, both based on the “early bed allocation” scenario, with an increased penalty of 50 for extra beds: In the first instance, the number of beds and rooms in the department of urology is as described in Section 5 (11 four-bed rooms and 3 three-bed rooms) while in the second instance, only 10 four-bed rooms are considered. It turns out that in both instances, the overall solution quality is better and the number of needed extra beds is smaller when considering gender separation a priori. While the objective function differences are comparably small, note that a significant amount of extra beds typically represents solutions which are not implementable in practice.

Instance	Considering gender a priori		Considering gender a posteriori			
	A priori		A priori		A posteriori	
	Extra Beds	Objective	Extra Beds	Objective	Extra Beds	Objective
Given Capacity	0	24284	1	24194	3	24294
Reduced Capacity	19	25414	16	25181	28	25781

Table 7: Amount of additional Beds respecting and ignoring gender Restrictions

### *The Role of Anticipation in the Hierarchical Approach*

In our hierarchical approach, we carefully designed the anticipation of the second-stage problem in the first stage. As an example, it is important to consider all treatment groups (not only those to be scheduled) in the first-stage model in order to anticipate the full set of precedence constraints in the first-stage model. In our experiments, this anticipation turned out to be crucial: Without this anticipation, almost all the second-stage model instances were infeasible. As depicted in Table 8 showing results from based on the “early allocation” scenario with the reduced room capacity setting described above, it is also important to anticipate the gender separation requirement for patient rooms: If the gender separation anticipation is dropped in the first-stage model, the final solution obtained from the second-stage model involves considerably more extra beds.

$\bar{b}^{\text{devAd}}$	With Gender Anticipation		Without Gender Anticipation	
	Extra Beds	Obj. Value	Extra Beds	Obj. Value
10	26	26019	37	26577
30	19	25414	29	26053

Table 8: Comparing the amount of extra beds

## 6.2 Detailed Results of the Smooth Resource Allocation Scenario

In the first scenario to be discussed in detail, the objective structure favors a smooth allocation of resource utilization over the planning horizon. Table 9 shows the solution times and objective function values for different settings of the parameter  $\bar{b}^{\text{devAd}}$  limiting the deviation from the preferred admission day from 0 to 30. The results show that the solution time of the first-stage model is very sensitive to the amount of possible earlier or later admissions: The model with

five days admission tolerance is solved in less than 10 minutes whereas the model with 10 days needs an eight times higher solution time. The solution time of the last instance is surprisingly shortened. The reason for this could be the lag of shortages because of the great scheduling flexibility enabling a slightly better solution by shifting some patients by an amount of more than 10 days. The second-stage model could easily be solved in less than 20 seconds in all but the first case.

$\bar{b}^{\text{devAd}}$	Solution Time 1st Model (s)	Gap (%)	Objective	Solving Time 2nd Model (s)	Gap (%)	Objective
0	4	1	9228	20	0	9066
3	310	1	8493	1	0	8212
5	543	1	8435	1	0	8150
10	4352	1	8264	1	0	7919
30	3069	1	8253	1	0	7898

Table 9: Solving Time, Gaps and Objectives in the Smooth Resource Allocation Scenario

More details about the effects of more flexibility with regard to the admission day are shown in Table 10: Even a small amount of flexibility considerably improves resource and patient-related performance indicators. The total amount of overtime on OR, OR-nurses and urography is reduced by approx. 92 % in case of a three-day deviation and up to 96 % in the thirty-day case. Considering the OR values in detail (two central OR and one ward-owned OR) showed that the total overtime in the thirty-day case is associated to both central OR with a maximum overtime of 0.7 hours (the maximum overtime in the zero-days case was 6 hours). The ward-owned OR which cannot perform all kinds of surgeries needs no additional overtime at all in the thirty-day case anymore.

Indicator	$\bar{b}^{\text{devAd}}$			
	0	3	10	30
Maximum patient delay	3	5	0	0
Total patient delay	46	23	0	0
Maximum Overtime	OR	6	1.8	0.7
	OR-Nurse	2	0	0
	Uro	3.5	0.75	0.2
Maximum Idle Time	OR	12	7.8	4.2
	OR-Nurse	19.2	10.2	8.7
	Uro	11.5	10.3	10.5
Total Overtime	OR	36.8	2	0.85
	OR-Nurse	3.6	0	0
	Uro	4.2	1.25	0.23
Total Idle Time	OP	74.9	40.5	39
	OR-Nurse	135.7	132.8	132
	Uro	192.7	189.9	188.8
Extra Male Beds	1	0	0	0
Extra Female Beds	1	0	0	0

Table 10: Key Indicators in the Smooth Resource Allocation Scenario

With an increasing flexibility, the idle times of the OR are highly reduced. This contrasts with the comparably small change of idle time for OR-nurses and urography – we assume that these resources are not scarce. Taking a closer look, we could confirm our assumption for OR-nurses and for one of the urography resources. The other urography still forms scarce since it is eligible for a wider range of treatments. With regard to patient-related indicators, on the one hand the maximum delay has been reduced from three to zero days and the total amount of all delays

decrease from 46 to zero days as well. On the other hand, the distance to the preferred admission day increases from zero in the first up to 77 days in the last case. Fig. 7 depicts the frequencies of the deviations from the desired admission days for all patients for the last instance: From all 286 patients, 231 can be admitted at their preferred day; 7 % of all patients are admitted before and 11 % are admitted after their preferred admission day.




Fig. 7: Time Delta between Preferred and Scheduled Admission – Equal Allocation

Fig. 8 visualizes the effects on allocation profiles of the resource types physician, operating room and urography as given by empirical ex-post data (left hand side) and after the scheduling with an admission day flexibility of 30 days (right hand side). The blue background depicts the available capacity of treatment time and the visible area corresponds to the remaining capacity. The black line on top is the goal ratio of 80 % capacity allocation. The red and the green areas are the allocated resource times at each day.



For each resource, the allocation is very smooth compared to the empirical data. The resource allocation of the physicians shows an even workload distribution. Given the large blue area, physicians obviously do not form scarce resources considering only elective patients (as well as the OR-nurses mentioned above). The combined allocation profiles of all operating rooms show a better fit to the available capacity profile with less overtime occurring during the month. Since there is no idle time left for the central OR, the visible available capacity can be attributed exclusively to the ward-owned OR.

In order to quantify the smoothing effect obtained by our scheduling approach, let us consider the standard deviation of the daily allocation of each resource: For physicians, the standard deviation changed from 12.7 to 7.1, for operating rooms from 7 to 4, for OR-nurses from 8.4 to 5.2 and for the urography from 4.6 to 2.2. Given these values, it can be summarized that the resource allocation could successfully be equalized in this scenario. Furthermore, no extra beds would be required to hospitalize all 286 elective patients even under consideration of gender separation.



**Resource Allocation Given by Data**

**Resource Allocation after Scheduling**



**Resource Type: Physician**



**Resource Type: Operating Room**



**Resource Type: OR-Nurse**



**Resource Type: Urography**





Fig. 8: Results of Equal Resource Allocation with 10 Days Deviation

**6.3 Detailed Results of the Early Resource Allocation Scenario**

While the scenario presented in the previous section aimed at obtaining a smooth allocation of resources, the present section focuses on a scenario in which scheduling favors a high resource utilization at the beginning of the planning horizon. As in the first scenario, we vary the maximum allowed deviation from the preferred admission day by changing the parameter  $\bar{b}^{\text{devAd}}$  from zero to 30 days for the first-stage model. Table shows the objective function values, solving times and gaps for each considered value of  $\bar{b}^{\text{devAd}}$ . It turns out that even the largest possible instance with completely flexible patient admission days were solved in less than two

hours. We suspect that this considerable decrease in solving time compared to the first scenario results from the fact that in the objective function in the second scenario induces a less symmetric solution space. For all variants, the second model is solved to optimality in less than one minute.

$\bar{b}^{\text{devAd}}$	Solving Time 1st Model (s)	Gap (%)	Objective	Solving Time 2nd Model (s)	Gap (%)	Objective
0	1	1	27982	13	0	27384
3	34	1	26490	1	0	26030
5	190	1	26062	4	0	25549
10	870	1	25160	24	0	24679
30	4488	1	24726	506	0	24186

Table 11: Solving Time, Gaps and Objectives Aiming on Early High Resource Allocation

Table gives an overview how selected indicators change when increasing admission date flexibility from zero up to 30 days. The patient-related indicators (maximum and individual delay) can be reduced to zero. The resource-related indicators, however, show a more complex pattern: After reducing the total over- and idle time from the zero day to the 10 days case, these values increase in the 30-day case. The reason for this behavior are patients shifted from the end of the scheduling horizon to the beginning in order to avoid most expensive idle times on all resources.

Indicators		$\bar{b}^{\text{devAd}}$			
		0	3	10	30
Maximum patient delay		6	1	0	0
Total patient delay		45	2	0	0
Maximum Overtime	OP	7	3.8	2.4	4.7
	OR-Nurse	1.3	0.4	0.1	0.3
	Uro	3.5	0.2	0.4	0.7
Total Overtime	OP	39.1	13.1	8.6	14.8
	OR-Nurse	3.6	0.8	0.1	0.3
	Uro	4.5	0.3	0.2	0.3
Total Idle Time	OP	77.2	51.3	46.9	52.9
	OR-Nurse	135.7	132.8	132.2	132.4
	Uro	193.2	189	189.6	190
Extra Male Beds		1	0	4	2
Extra Female Beds		1	3	1	0

Table 6: Key Indicators in the High Early Allocation Scenario

Fig. 9 shows the absolute frequencies of the deviations between scheduled and the preferred admission days for the case of a fully flexible admission day. The scheduled admission days deviate up to 28 days from the preferred admission day. 65% (186) of the patients are admitted earlier than preferred; 30% (80 patients) are admitted more than 10 days earlier. On average, each patient is 4.5 days earlier admitted.




Fig. 9: Deviations of scheduled from preferred admission day – Early Allocation

The effect of the early resource allocation is visualized in Fig. 10 showing the time-dependent resource allocation profile of physicians, OR, OR-nurses and urography based on historical ex-post data (left hand side) as well as based on scheduling with full admission day flexibility (right hand side). The results show that the goal of establishing a high resource utilization at the beginning of the planning horizon could be achieved.



Since at the beginning of the planning horizon, the penalty for idle time substantially outweighs the penalties for overtime, the scarce OR resources tend to exhibit overtime while other resources are highly utilized. Note that an even higher utilization is prevented by the scarcity of bed resources at the admission ward, see Fig. 11 for a visualization of the bed allocation over time. At the first weekend starting at day 5 the OR exhibit a high amount of idle time: In this case, physicians and OR nurses form the scarce resources, and reducing OR idle time would induce overtime for several resources at once. Interestingly, the scheduling results on the first weekend also reflect the fact that in contrast to OR, the urography resources do not require the presence of OR-nurses: Their utilization does not decrease as heavily as the OR utilization; furthermore, given the reduced physician availability on Sundays, the urography utilization is lowest on Sunday.

Summarizing the results of this scenario, the desired maximization of the resource allocation at the beginning of the planning horizon can be achieved. However, putting the described results into practice may turn out to be risky since in case of a rate of arriving emergency patients higher than the expected ratio of 40 %, capacity bottlenecks will arise at least during the first week. Nevertheless, our scheduling approach can be used to identify such bottlenecks and to take measures to avoid them or to mitigate their consequences. In the current case, operating rooms and OR-nurses seem to be the scarcest resource types. This becomes particularly obvious after scheduling, showing noticeable available capacity only during the last days of the planning horizon.



**Resource Allocation Given by Data**

**Resource Allocation after Scheduling**



**Resource Type: Physician**



**Resource Type: Operating Room**



**Resource Type: OR-Nurse**



**Resource Type: Urography**





Fig. 10: Results of Early Resource Allocation with 30 Days Deviation




Fig. 11: Patient Assignment

## 7 Conclusion

This paper presents a hierarchical ILP approach for CP scheduling aiming at practical applicability in several ways: The CP information including the pathway constraints needed for our approach can be automatically extracted from standardized hospital billing data. This data-driven character of our approach substantially reduces the amount of work to be performed in order to obtain the CP information needed for scheduling. Moreover, the CP scheduling approach considers all relevant resources on an adequate level of detail; in particular, it models bed assignment on the level of rooms and allows considering treatment resources individually in order to avoid disaggregation problems of complex resources such as operating rooms. Furthermore, it considers several practically relevant aspects such as multiple ward stays per hospitalization, gender-separated rooms and attribute-based eligibility of resources for treatments (e.g., special equipment in operating rooms needed for a certain surgery or special qualifications). In order to support a broad range of application scenarios and hospital-specific objective structures, our approach employs a multi-criteria objective function allowing to account for both patient- and hospital-related objectives. Since the detailed representation of practically relevant aspects yields complex large-scale model instances, we propose a carefully designed hierarchical two-stage approach involving anticipation components aligning the first-stage solution with aspects relevant to the second-stage problem.

Our results from experiments with real-world data involving a planning horizon of 30 days, 1088 treatments and 302 ward stays of 286 patients show that our approach is capable of obtaining high-quality solutions within a reasonable amount of time for a tactical planning problem: Even the most complex instances in which the admission days of the patients can be freely chosen can be solved within less than 90 minutes. Furthermore, the detailed evaluation shows that our model is capable of considering different scenarios such as achieving a smooth allocation of resources over the planning horizon and establishing a high resource allocation in the beginning of the horizon.

The results presented in this paper offer multiple opportunities for future research: First, we will evaluate the robustness of our results in a simulation study considering stochastic elements such as emergency patients and short-term resource unavailability. Second, we will extend our model to allow selecting the optimal set of elective cases to be admitted in order to make effective use of the hospital resources. The ultimate goal, however, is to embed our model into the information systems of our partner university hospital to provide decision support for hospital-wide scheduling of elective patients in practice. While we are aware that this goal is presently out of reach mainly due to the present organizational structure in hospitals and due to a lack of integrated information systems, we believe that by being data-driven and by considering many practically relevant aspects, our approach forms a step in the right direction.

## 8. References

- Augurzky, Boris, ed. 2015. Bad Bank für Krankenhäuser: Krankenhausausstieg vor der Tür?; *Krankenhaus-Rating-Report : HCB, Institute for Health Care Business GmbH ; RWI*. Krankenhaus-Rating-Report.
- Augusto, Vincent, Xiaolan Xie, and Viviana Perdomo. 2010. Operating theatre scheduling with patient recovery in both operating rooms and recovery beds. *Computers & Industrial Engineering* 58: 231–238. doi:10.1016/j.cie.2009.04.019.
- Banditori, C., P. Cappanera, and F. Visintin. 2013. A combined optimization-simulation approach to the master surgical scheduling problem. *IMA Journal of Management Mathematics* 24: 155–187. doi:10.1093/imaman/dps033.
- Batun, Sakine, Brian T. Denton, Todd R. Huschka, and Andrew J. Schaefer. 2011. Operating Room Pooling and Parallel Surgery Processing Under Uncertainty. *INFORMS Journal on Computing* 23: 220–237. doi:10.1287/ijoc.1100.0396.



- Cardoen, Brecht, and Erik Demeulemeester. 2011. A DECISION SUPPORT SYSTEM FOR SURGERY SEQUENCING AT UZ LEUVEN'S DAY-CARE DEPARTMENT. *International Journal of Information Technology & Decision Making* 10: 435–450. doi:10.1142/S0219622011004397.
- Cardoen, Brecht, Erik Demeulemeester, and Jeroen Beliën. 2009. Optimizing a multiple objective surgical case sequencing problem. *International Journal of Production Economics* 119: 354–366.
- Ceschia, Sara, and Andrea Schaerf. 2011. Local search and lower bounds for the patient admission scheduling problem. *Computers & Operations Research* 38: 1452–1463. doi:10.1016/j.cor.2011.01.007.
- Ceschia, Sara, and Andrea Schaerf. 2014. Dynamic patient admission scheduling with operating room constraints, flexible horizons, and patient delays. *Journal of Scheduling*. doi:10.1007/s10951-014-0407-8.
- Chaabane, Sondes, Nadine Meskens, Alain Guinet, and Marius Laurent. 2008. Comparison of two methods of operating theatre planning: Application in Belgian Hospital. *Journal of Systems Science and Systems Engineering* 17: 171–186. doi:10.1007/s11518-008-5074-x.
- Chow, Vincent S., Martin L. Puterman, Neda Salehirad, Wenhai Huang, and Derek Atkins. 2011. Reducing Surgical Ward Congestion Through Improved Surgical Scheduling and Uncapacitated Simulation: Reducing Surgical Ward Congestion. *Production and Operations Management* 20: 418–430. doi:10.1111/j.1937-5956.2011.01226.x.
- Conforti, Domenico, Francesca Guerriero, Rosita Guido, Marco Matucci Cerinic, and Maria Letizia Conforti. 2011. An optimal decision making model for supporting week hospital management. *Health Care Management Science* 14: 74–88. doi:10.1007/s10729-010-9144-5.
- Demeester, Peter, Wouter Souffriau, Patrick De Causmaecker, and Greet Vanden Berghe. 2010. A hybrid tabu search algorithm for automatically assigning patients to beds. *Artificial Intelligence in Medicine* 48: 61–70. doi:10.1016/j.artmed.2009.09.001.
- Denton, Brian T., Andrew J. Miller, Hari J. Balasubramanian, and Todd R. Huschka. 2010. Optimal Allocation of Surgery Blocks to Operating Rooms Under Uncertainty. *Operations Research* 58: 802–816. doi:10.1287/opre.1090.0791.
- Denton, Brian, James Viapiano, and Andrea Vogl. 2007. Optimization of surgery sequencing and scheduling decisions under uncertainty. *Health Care Management Science* 10: 13–24. doi:10.1007/s10729-006-9005-4.
- Fei, H., C. Chu, and N. Meskens. 2009. Solving a tactical operating room planning problem by a column-generation-based heuristic procedure with four criteria. *Annals of Operations Research* 166: 91–108. doi:10.1007/s10479-008-0413-3.
- Fei, H., N. Meskens, and C. Chu. 2010. A planning and scheduling problem for an operating theatre using an open scheduling strategy. *Computers & Industrial Engineering* 58: 221–230. doi:10.1016/j.cie.2009.02.012.
- Gartner, Daniel, and Rainer Kolisch. 2013. Scheduling the hospital-wide flow of elective patients. *European Journal of Operational Research*. doi:10.1016/j.ejor.2013.08.026.
- Helbig, Karsten. 2011. Zeitplanung für Patientenpfade unter Berücksichtigung von Betten-, Behandlungskapazitäten und Fairnesskriterien. *Tagungsband 15. Interuniversitäres Doktorandenseminar Wirtschaftsinformatik der Universitäten Chemnitz, Dresden, Freiberg, Halle-Wittenberg, Jena und Leipzig*: 34–44.
- Helbig, Karsten, Michael Römer, and Taïeb Mellouli. 2015. A Clinical Pathway Mining Approach to Enable Scheduling of Hospital Relocations and Treatment Services. In *Business Process Management*, ed. Hamid Reza Motahari-Nezhad, Jan Recker, and Matthias Weidlich, 9253:242–250. Cham: Springer International Publishing.
- Helm, Jonathan E., and Mark P. Van Oyen. 2014. Design and Optimization Methods for Elective Hospital Admissions. *Operations Research* 62: 1265–1282. doi:10.1287/opre.2014.1317.
- Hulshof, Peter J H, Nikky Kortbeek, Richard J Boucherie, Erwin W Hans, and Piet J M Bakker. 2012. Taxonomic classification of planning decisions in health care: a structured review of the state of the art in OR/MS. *Health Systems* 1: 129–175. doi:10.1057/hs.2012.18.
- Jacobs, Birgit. 2007. Ableitung von klinischen Pfaden aus evidenzbasierten Leitlinien am Beispiel der Behandlung des Mammakarzinoms der Frau. Universität Duisburg-Essen, Medizinische Fakultät/Universitätsklinikum» Universitätsklinikum Essen» Institut für Medizinische Informatik, Biometrie und Epidemiologie.
- Jebali, Aïda, Atidel B. Hadj Alouane, and Pierre Ladet. 2006. Operating rooms scheduling. *International Journal of Production Economics* 99: 52–62. doi:10.1016/j.ijpe.2004.12.006.
- Kirschner, S., W.-C. Witzleb, M. Eberlein-Gonska, F. Krummenauer, and K.-P. Günther. 2007. Klinische Pfade. *Der Orthopäde* 36: 516–522. doi:10.1007/s00132-007-1098-z.
- Küttner, T., and N. Roeder. 2007. Definition Klinischer Behandlungspfade. *Klinische Behandlungspfade: mit Standards erfolgreich arbeiten/N. Roeder/T. Küttner (Hrsg.)–Köln: Dr. Ärzte-Verl., S: 19–27.*
- Lamiri, Mehdi, Johann Drezo, and Xiaolan Xie. 2007. Operating Room Planning with Random Surgery Times. In , 521–526. IEEE. doi:10.1109/COASE.2007.4341749.

- Lamiri, Mehdi, Xiaolan Xie, Alexandre Dolgui, and Frédéric Grimaud. 2008. A stochastic model for operating room planning with elective and emergency demand for surgery. *European Journal of Operational Research* 185: 1026–1037. doi:10.1016/j.ejor.2006.02.057.
- Lamiri, Mehdi, Xiaolan Xie, and Shuguang Zhang. 2008. Column generation approach to operating theater planning with elective and emergency patients. *IIE Transactions* 40: 838–852. doi:10.1080/07408170802165831.
- Li, Xiangyong, N. Rafaliya, M. Fazole Baki, and Ben A. Chaouch. 2015. Scheduling elective surgeries: the tradeoff among bed capacity, waiting patients and operating room utilization using goal programming. *Health Care Management Science*. doi:10.1007/s10729-015-9334-2.
- Marques, Inês, M. Eugénia Captivo, and Margarida Vaz Pato. 2012. An integer programming approach to elective surgery scheduling: Analysis and comparison based on a real case. *OR Spectrum* 34: 407–427. doi:10.1007/s00291-011-0279-7.
- Meskens, Nadine, David Duvivier, and Arnauld Hanset. 2013. Multi-objective operating room scheduling considering desiderata of the surgical team. *Decision Support Systems* 55: 650–659. doi:10.1016/j.dss.2012.10.019.
- Pham, Dinh-Nguyen, and Andreas Klinkert. 2008. Surgical case scheduling as a generalized job shop scheduling problem. *European Journal of Operational Research* 185: 1011–1025.
- Publikation - Gesundheit - Statistisches Bundesamt (Destatis) - Gesundheit - Ausgaben - Fachserie 12 Reihe 7.1.1 - 2011 - Statistisches Bundesamt (Destatis). 2014.
- Riise, Atle, and Edmund K. Burke. 2011. Local search for the surgery admission planning problem. *Journal of Heuristics* 17: 389–414. doi:10.1007/s10732-010-9139-x.
- Roeder, N., P. Hensen, D. Hindle, N. Loskamp, and H.-J. Lakomek. 2003. Instrumente zur Behandlungsoptimierung. *Der Chirurg* 74: 1149–1155. doi:10.1007/s00104-003-0754-z.
- Roland, B., C. Di Martinelly, F. Riane, and Y. Pochet. 2010. Scheduling an operating theatre under human resource constraints. *Computers & Industrial Engineering* 58: 212–220. doi:10.1016/j.cie.2009.01.005.
- Saadani, Nour El Houda, Zied Bahroun, and Asma Bouras. 2014. A linear mathematical model for patients' activities scheduling on hospital resources. In , 074–080. IEEE. doi:10.1109/CoDIT.2014.6996871.
- Salfeld, Rainer, S. Hehner, Steffen Hehner, and Reinhard Wichels. 2009. *Modernes Krankenhausmanagement: Konzepte und Lösungen*. Springer.
- Schimmelpfeng, Katja, Stefan Helber, and Steffen Kasper. 2012. Decision support for rehabilitation hospital scheduling. *OR Spectrum* 34: 461–489. doi:10.1007/s00291-011-0273-0.
- Schmidt, Robert, Sandra Geisler, and Cord Spreckelsen. 2013. Decision support for hospital bed management using adaptable individual length of stay estimations and shared resources. *BMC Medical Informatics and Decision Making* 13: 3.
- Schneeweiss, Ch. 1998. Hierarchical planning in organizations: Elements of a general theory. *International Journal of Production Economics* 56–57: 547–556. doi:10.1016/S0925-5273(96)00109-0.
- Sun, Bofei, Jie Song, and Leyuan Shi. 2013. Integrated operating room scheduling optimization under particularly workload constrain of surgeon. In , 972–977. IEEE. doi:10.1109/CoASE.2013.6653965.
- Testi, Angela, and Elena Tànfani. 2009. Tactical and operational decisions for operating room planning: Efficiency and welfare implications. *Health Care Management Science* 12: 363–373. doi:10.1007/s10729-008-9093-4.
- Vancroonenburg, Wim, Patrick De Causmaecker, Frits Spieksma, and Greet Vanden Berghe. 2013. Scheduling elective patient admissions considering room assignment and operating theatre capacity constraints. In *Proceedings of the 5th International Conference on Applied Operational Research, Lecture Notes in Management Science*, 5:153–158.
- Vancroonenburg, Wim, Patrick De Causmaecker, Frits Spieksma, and Greet Vanden Berghe. 2014. Integrating patient-to-room assignment planning with elective admission scheduling. In *Proceedings of the 28th Annual Conference of the Belgian Operations Research Society*.
- Vanhaecht, K., M. Bollmann, K. Bower, C. Gallagher, A. Gardini, J. Guezo, U. Jansen, et al. 2006. Prevalence and use of clinical pathways in 23 countries - an international survey by the European Pathway Association. *International Journal of Care Pathways* 10: 28–34. doi:10.1258/j.jicp.2006.124.
- Villa, Stefano, Marta Barbieri, and Federico Lega. 2009. Restructuring patient flow logistics around patient care needs: implications and practicalities from three critical cases. *Health Care Management Science* 12: 155–165.
- Visser, J. M. H. 2005. Patient mix optimization in tactical cardiothoracic surgery planning: a case study. *IMA Journal of Management Mathematics* 16: 281–304. doi:10.1093/imaman/dpi023.
- Vlah Jerić, Silvija, and José Rui Figueira. 2012. Multi-objective scheduling and a resource allocation problem in hospitals. *Journal of Scheduling* 15: 513–535. doi:10.1007/s10951-012-0278-9.
- Vlah Jerić, Silvija, and Jose Rui Figueira. 2010. An Interactive Approach for Multiple Criteria Scheduling in a Croatian Hospital. *Croatian Operational Research Review* 1: 93–103.

## Anhang F: Überblick Definitionen klinischer Pfade

Eine einheitliche Definition klinischer Pfade existiert bisher nicht. Je nach Verwendungskontext werden ökonomische, qualitative oder ablauforganisatorische Aspekte mehr oder weniger betont (Küttner und Roeder 2007, S. 19). Beispiele entsprechender Begrifflichkeiten im deutschsprachigen Raum sind Leitpfad, Patientenpfad, clinical pathway, integrierter Versorgungspfad oder critical pathway (Matthias Bartz 2006, S. 37). Zur Herleitung der verwendeten Definition sowie um einen Eindruck vom begrifflichen Spektrum zu vermitteln sind in Tabelle 1 einige häufig zitierte Definitionen dargestellt:

Begriff	Definition
<i>Integrierter Behandlungs- pfad</i>	Ein integrierter Behandlungspfad (IBP) ist ein Steuerungsinstrument. Der integrierte Pfad beschreibt den optimalen Weg eines speziellen Patiententyps mit seinen entscheidenden diagnostischen und therapeutischen Leistungen und seiner zeitlichen Abfolge. Interdisziplinäre und interprofessionelle Aspekte finden ebenso Berücksichtigung wie Elemente zur Umsetzung, Steuerung und ökonomischen Bewertung (Eckardt und Sens 2006, S. 25).
<i>Klinischer Pfad I</i>	Klinische Pfade sind abteilungs-, berufsgruppen- und professionsübergreifende, medizinisch und ökonomisch abgestimmte Handlungsleitlinien für den gesamten Behandlungsablauf einer Gruppe homogener Behandlungsfälle (Greiling et al. 2003, S. 26).
<i>Klinischer Pfad II</i>	Nach Vorliegen einer hinreichend sicheren Aufnahmediagnose legen klinische Pfade die optimale Schrittfolge und Terminierung der notwendigen Interventionen aus Diagnostik, Therapie und Pflege arbeitsteilig geordnet durch das Klinikpersonal (Ärzte, Pfleger, etc.) fest. Sie sind darauf ausgerichtet, Verspätungen und Verzögerungen zu minimieren und gleichzeitig die Ressourcenauslastung und Behandlungsqualität zu maximieren. Die Behandlung eines Patienten soll infolgedessen mit größtmöglicher Effizienz durchgeführt werden (Schmidt 2011, S. 18).
<i>Klinischer Behandlungs- pfad I</i>	Ein klinischer Behandlungspfad ist der im Behandlungsteam selbst gefundene berufsgruppen- und institutionsübergreifende Konsens bezüglich der besten Durchführung der Krankenhausgesamtbehandlung unter Wahrung festgelegter Behandlungsqualität und Berücksichtigung der notwendigen und verfügbaren Ressourcen sowie unter Festlegung der Aufgaben und der Durchführungs- und Ergebnisverantwortlichkeiten. Er steuert den Behandlungsprozess, ist gleichzeitig das behandlungsbegleitende Dokumentationsinstrument und erlaubt die Kommentierung von Abweichungen von der Norm zum Zwecke fortgesetzter Evaluation und Verbesserung (Roeder et al. 2003a, S. 21f).
<i>Klinischer Behandlungs- pfad II</i>	Klinische Behandlungspfade sind eine Art multisziplinärer Behandlungsfahrplan, der indikationsbezogen festlegt welche einzelnen Behandlungsstationen ein Patient von Aufnahme bis Entlassung durchläuft (Roeder und Küttner 2006, S. 684f).
<i>Inter- disziplinärer Versorgungs- pfad</i>	Interdisziplinäre Versorgungspfade verknüpfen alle antizipierten Elemente der Versorgung und Behandlung durch alle Mitglieder des interdisziplinären Teams für Patienten oder Klienten einer bestimmten Fallgruppe oder Auswahl innerhalb einer festgelegten Zeitspanne, um vereinbarte Ziele zu realisieren. Jede Abweichung vom Plan wird als Varianz dokumentiert: ihre Analyse liefert Informationen für die Überprüfung der gegenwärtigen Praxis (Johnson und Müller 2002, S. 41).
<i>Critical Pathway I</i>	A critical path is an optimal sequencing and timing of interventions by physicians, nurses, and other staff for a particular diagnosis or procedure, designed to better utilize resources, maximize quality of care, and minimize delays (Coffey et al. 2005, S. 45)
<i>Critical Pathway II</i>	Critical Pathways sind interdisziplinäre Behandlungspläne, die aufgrund optimaler Koordinierung eine ideale Patientenversorgung ermöglichen sollen. Sie orientieren sich dabei an der besten klinischen Praxis bei der Versorgung spezifischer Patientengruppen (Nese 1997 zitiert nach (Kahla-Witzsch und Geisinger 2004, S. 22))

<i>Clinical Pathway I</i>	A clinical pathway is defined as a clear outline of the usual pattern of care for a group of patients with a given diagnosis or procedure performed. For each patient in the group, the staff can quickly see the expected time frame for delivery of care (Zander 1992)
<i>Clinical Pathway II</i>	A clinical pathway is a method for the patient-care management of a well-defined group of patients during a well-defined period of time. A clinical pathway explicitly states the goals and key elements of care based on Evidence Based Medicine (EBM) guidelines, best practice and patient expectations by facilitating the communication, coordinating roles and sequencing the activities of the multi-disciplinary care team, patients and their relatives; by documenting, monitoring and evaluating variances; and by providing the necessary resources and outcomes. The aim of a clinical pathway is to improve the quality of care, reduce risks, increase patient satisfaction and increase the efficiency in the use of resources (De Bleser et al. 2006).
<i>Clinical Pathway III</i>	The clinical pathway defines the procedures (such as different types of diagnostic activities and surgery) as well as the sequence in which they have to be applied to the patient (Gartner und Kolisch 2013).

Tabelle 2: Definitionsübersicht „Klinischer Pfad“  
(eigene Darstellung, in Anlehnung an Küttner und Roeder 2007, S. 20)

Zusammenfassend handelt es sich bei klinischen Pfaden um ein interdisziplinäres Instrument zur umfassenden Darstellung von Behandlungsverläufen definierter Patientengruppen (Matthias Bartz 2006; Küttner und Roeder 2007). In Anlehnung an die genannten Definitionen wird im Rahmen dieser Arbeit ein klinischer Pfad definiert als:

*Ein klinischer Pfad ist eine vollständige interdisziplinäre Abbildung des stationären Behandlungsablaufs für homogene Patientengruppen. Dabei umfasst der Behandlungsablauf sämtliche planungsrelevanten Diagnose- und Behandlungsprozeduren, alle nötigen Stationsaufenthalte sowie mögliche Reihenfolgebeziehungen zwischen den einzelnen Elementen. Klinische Pfade sind darauf ausgerichtet, die Effizienz des Ressourceneinsatzes sowie der krankenhausinternen Prozesse zu steigern.*

## **Eidesstattliche Erklärung**

Ich erkläre an Eides statt, dass ich die vorliegende Promotion selbstständig und ohne fremde Hilfe verfasst, keine anderen als die von mir angegebenen Quellen und Hilfsmittel benutzt und die den benutzten Werken wörtlich oder inhaltlich entnommenen Stellen als solche kenntlich gemacht habe. Weiterhin wurde die vorliegende Arbeit bisher keiner anderen Prüfungsbehörde in gleicher oder ähnlicher Form vorgelegt.

Halle,

---

(Karsten Helbig)