

Datenbasierte Operationsplanung im Krankenhaus unter Entwicklung und Einbindung einer Machine Learning Plattform

Databased surgery planning in hospitals under development and integration of a machine learning platform

Jennifer Saß,
Nick Hartmann,
Michael Völker,
Thorsten Schmidt

Professur für Technische Logistik
Fakultät Maschinewesen, Institut für Technische Logistik und Arbeitssysteme
Technische Universität Dresden

Die vorliegende Arbeit gibt einen Überblick zur Ergänzung von Planungs- und Steuerungsprozessen im OP-Bereich von Krankenhäusern. Der Fokus liegt hier auf der automatisierten Vorhersage von Operationszeiten mittels maschineller Lernmethoden auf Basis von retrospektiven Daten. Der vorliegende Artikel befasst sich mit der Analyse der zu beziehenden Daten, der Aufbereitung und Vorverarbeitung dieser und der Empfehlung an geeigneten Algorithmen für das Maschinelle Lernen. Die beschriebene Arbeit ist im Rahmen des SAB geförderten Projektes; Platform for Operation Scheduling and Prediction using machine learning (PROSPER) entstanden.

[Schlüsselwörter: Maschinelles Lernen, Klassifikation, Regression, CRISP]

This paper gives an overview of the enhancement of planning and control processes in the operating theatre of hospitals. The focus here is on the automated prediction of operating times using machine learning methods based on retrospective data. This article deals with the analysis of the data to be obtained, the preparation and preprocessing of this data and the recommendation of suitable algorithms for machine learning. This work was carried out as part of the funded project Platform for Operation Scheduling and Prediction using machine learning (PROSPER).

[Keywords: Machine Learning, Classification, Regression, CRISP]

1 EINFÜHRUNG

Historisch bedingt wird die OP-Planung von besonders erfahrenen Ärzten durchgeführt. Diese planen blockweise in wöchentlichem oder monatlichem Rhythmus

[ZFY19]. Dabei wird versucht, die Auslastung der OP-Säle nach allen Vorgaben so hoch wie möglich zu planen. Ein besonderes Augenmerk liegt hierbei in der Schätzung der OP-Zeit. Somit ist die genaue Abschätzung der Falldauer auf Basis der chirurgischen Eingriffe für die Planung und Belegung der Säle, wie auch den effizienten Patientenfluss, [CM18] essentiell. Erfahrene Chirurgen schätzen die OP-Zeit auf Basis von grundlegenden Verfahrensdaten und die ihm zur Verfügung stehenden Patienteninformationen selbst [TYA17; BGS16]. Dabei kann die subjektive Vorhersage heute meist durch OP-Planungssysteme unterstützt werden, bei denen Zeiten, die auf Erfahrungswerten basieren, hinterlegt werden. Die jeweilige Fallkomplexität, wie auch die individuellen Patientenfaktoren und Variationen geben zusätzliche Hinweise auf OP-Zeitverzögerungen [DDM08; EHN10]. Welche Faktoren hier jedoch mit in die Planung einbezogen werden, obliegt dem erfahrungsbasierten Wissen und der subjektiven Sichtweise des Planenden. Diese Erfahrungswerte der Experten teilautomatisiert abbilden zu können und dies für die Planung nutzbar zu machen ist Herausforderung für das SAB geförderte Projekt (PROSPER).

Ziel dieser Forschungsarbeit ist die Unterstützung von Planungs- und Steuerungsprozessen im OP-Bereich mittels praxistauglicher ML-Anwendung. Auf Grundlage von OP-Zeitprognosen, die auf retrospektiven Daten basieren, soll die Planstabilität und Robustheit des OP-Plans erhöht werden. Dabei müssen folgende Forschungsfragen untersucht werden: Welche Parameter hinsichtlich Patientenzustand und Ressourcenverfügbarkeit müssen in die Planung einbezogen werden? Welche Faktoren können sich verzögernd auf die Operationsdauer auswirken? Wie ist der Umgang mit seltenen und / oder komplizierten Operationen in der Datenaufbereitung und der Einbezug in die Algorithmen?

2 STAND DER TECHNIK

Die Anzahl der weltweiten Operationen in den Jahren 2004 – 2012 steigt um 38% auf 313 Millionen [WHM16]. Mit steigender Lebenserwartung nimmt auch die Anzahl der Operationen weiter zu. Da der OP-Saal ein Hoherlös- und zugleich Hochkostenbereich [ZFY19] ist, nimmt auch die Bedeutung des Managements weiter zu. Es müssen Strategien und Konzepte entwickelt werden, um die steigende Nachfrage zu bedienen und gleichzeitig hochpreisige Ressourcen optimal zu nutzen.

Frühe wissenschaftliche Ansätze zur OP-Zeiten-Vorhersage gehen grundsätzlich in zwei Richtungen, die sich auf den Abgleich der Verteilungen der OP-Zeiten stützen. Vornehmlich werden die Zeiten auf bekannte Verteilungen, wie Normalverteilung [BAR68] und Lognormalverteilung [HWM88; RS93; SMV00; SMS03] angepasst, um die Varianz der OPs zu charakterisieren und so die Dauer vorherzusagen. Mit einer zweiten Methode wer-

den statistische Modelle zur Vorhersage erstellt, um kritische Einflussfaktoren, die die Varianz der OP-Dauer beeinflussen, zu detektieren. Unter den Studien, die sich auf Verteilungen beziehen, analysierten Sturm et. al. einen großen Datensatz klinischer Fälle und kamen zu dem Schluss, dass die Anpassung eines Lognormalmodells für jede Current Procedural Terminology (CPT), vergleichbar mit dem Operationen- und Prozedurencode (OPS), Anästhesiekombination genaue Vorhersagen für die Prozessdauer liefert [SMV00]. Die erwähnten Studien beziehen jedoch nicht generelle verzögernde oder patientenbezogene Faktoren ein. Da generelle verzögernde Faktoren, wie Personalmangel und Zusammenstellung des OP-Teams kaum bis gar nicht beeinflussbar sind und sich teilweise nicht mit dem Datenschutz vereinbaren lassen, beschäftigt sich die weitere Arbeit mit patientenbezogenen Faktoren. Es gibt mehrere Studien, die Einflussfaktoren der Verzögerung bei der OP-Dauer bei speziellen Diagnosen oder Prozeduren untersuchen, weshalb eine Verallgemeinerung der Methoden noch untersucht werden muss.

Tabelle 1: Gegenüberstellung der verzögernden Einflussfaktoren aus der Literatur

| | Fachgebiet | Alter | Geschlecht | Body Mass Index | ASA = American Society of Anesthesiologists Klassifikation | Vorherige OP | Diabetes Mellitus | Lungenerkrankungen | Herzkrankungen | Nierenerkrankungen | Lebererkrankungen | Raucher | Leukozytenanzahl |
|---------------------|------------|-------|------------|-----------------|--|--------------|-------------------|--------------------|----------------|--------------------|-------------------|---------|------------------|
| Gomes et al. 2012 | allgemein | x | x | | | x | x | | | x | | | |
| Eijkemans 2010 | allgemein | x | x | x | | x | x | x | x | x | | | |
| Thiels et al. 2017 | LC | x | x | x | x | | x | x | | | x | x | x |
| Lowndes et al. 2016 | LC | x | x | x | x | x | x | x | x | | x | x | |
| Zdichavsky 2012 | LC | x | x | x | x | x | | | | | | | |
| Lee et al. 2012 | LC | x | x | x | | x | x | | | | | | |
| Hussain 2011 | LC | x | x | x | | x | | | | | x | | |
| Rosen et al. 2002 | LC | x | | x | x | | x | | x | | | | x |
| Alponat et al. 1997 | LC | x | x | x | x | x | x | | x | | x | | x |
| Kaneko et al. 2013 | LRP | x | | x | | x | | | | | | | |
| Lindeborg 2020 | FLP | x | x | | x | | x | x | x | x | x | | |

LC = Laparoskopische Cholezystektomie (Entfernung der Gallenblase)

LRP = Laparoskopische radikale Prostatektomie (Entfernung der Prostata)

FLP = Freie Lappenplastik an Kopf und Hals

Tabelle 1 zeigt die Gegenüberstellung der in der Literatur untersuchten patientenbezogenen OP-Zeit verzögernden Faktoren. Dabei wurden in den Studien sowohl allgemeine als auch spezielle Diagnosen und Prozeduren untersucht. Es wird deutlich, dass die Faktoren: Alter, Geschlecht, BMI, ASA-Klassifikation und Voroperationen auch unabhängig vom Fachgebiet Auswirkungen auf die OP-Dauer haben. Darüber hinaus kann man erkennen, dass auch chronische Erkrankungen, wie Diabetes Mellitus und Erkrankungen von Herz, Lunge, Niere und Leber die OP-Dauern beeinflussen. Diese Erkenntnisse müssen bereits bei Bezug von Daten zur Prognose der OP-Dauern berücksichtigt werden.

3 METHODIK UND FALLBEISPIEL

Aus der zu Grunde liegenden Literaturarbeit geht hervor, dass die OP-Dauer von mehreren individuellen Faktoren abhängt, die zuvor detektiert werden müssen, um genaue Vorhersagen erzielen zu können. Die Daten zum Fallbeispiel der Polyklinik für Viszeral-, Thorax,- und Gefäßchirurgie des Uniklinikums Dresden beinhalten generelle und spezielle Daten zum Patienten. Alle Datenbestandteile wurden in einer mit Experten durchgeführten Analyse ausgewählt und dokumentiert. Patientenbezogene Daten unterliegen der ärztlichen Schweigepflicht und sind nicht ohne Zustimmung der Ethikkommission, des Datenschutzes und strenger Sicherheitsbestimmungen für die Forschung verfügbar. Somit wurde die ausgewählte Liste diesen Stellen zur Prüfung vorgelegt und nach Zustimmung die Daten bezogen.

Nach dem Bezug der Daten wird nach dem *Cross Industry Standard Process for Data Mining (CRISP)* Verfahren vorgegangen. Eine explorative Statistik des gesamten Datenbestandes gibt erste Anhaltspunkte über Korrelationen, Abhängigkeiten und Herausforderungen der Daten. Eine große Herausforderung ist der Umgang mit medizinischen Codes nach den Diagnose Related Groups (DRG). In dem bezogenen Datensatz befinden sich ca. 2000 verschiedene „Internationale Klassifikation der Krankheiten“ (ICD) und 3500 „Operationen und Prozeduren Schlüssel“ (OPS, vergleichbar mit CPT). Da es sich hier um kategorische Daten handelt, muss hier ein Encoding erfolgen, um die Daten für die ML Algorithmen lesbar zu machen. Hierfür müssen diese Codes statistisch verkleinert werden. Der Ansatz, der für diese Arbeit gewählt wurde, ist die Klassifizierung der Codes anhand der Länge der OP-Dauer nach [HSJ15]. Danach kann mit der Prognose der OP-Dauern fortgefahren werden. Das Vorgehen ist hierbei iterativ und vergleichend, um die besten Genauigkeiten in der Vorhersage zu erzielen. Die Ergebnisse werden mit den an der VTG hinterlegten Basiszeiten zur OP-Planung verglichen und zusätzlich von Experten geprüft. Abbildung 1 zeigt das grundsätzliche Ablaufschema zur Berechnung der OP-Zeiten-Vorhersage.

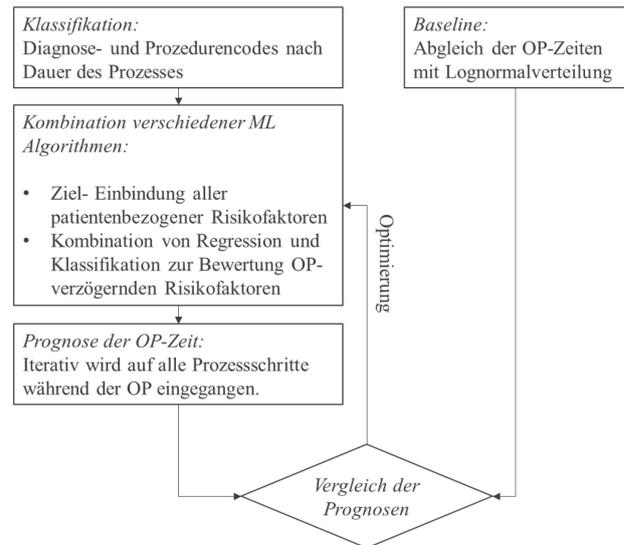


Abbildung 1 Vorgehensweise

Verglichen werden die Ergebnisse der Methoden mit der OP-Zeitermittlung aus der Lognormalverteilung. Im weiteren Verlauf des Artikels wird für die Prognose der OP-Zeitvorhersage ein Konzept aufgeführt und diskutiert. Eine Prüfung dieses Konzeptes mit dem erstellten Datensatz steht noch aus.

3.1 DATENSTRUKTUR

Die Daten bestehen aus 69 Attributen, die aus zwei verschiedenen Krankenhaus internen Datenbanken bezogen werden. Unter den Attributen sind sowohl Stammdaten wie Säle und Ausstattung dieser, wie auch patientenbezogene Daten zu finden. Weiterhin werden Dauern für Prozesse vor, während und nach der OP angegeben. Zu den jeweiligen Prozessen ist der Startzeitpunkt gegeben. Nach Absprache mit den Experten wurden für die Prozessschritte feste Ablaufschema erstellt, nach denen sich bei der weiteren Arbeit gerichtet werden soll. So startet jede Operation nach der „Einschleusen-OP-Freigabe“, die „Anästhesiezeit“ ist begleitend und parallel zu allen anderen Zeiten während der OP. Die Zeiten „Schnitt-Naht“, „Chir. Maßnahmen“ und „Patient im OP“ überlappen sich und finden parallel statt, siehe Abbildung 2. Die Daten des Datensatzes beziehen sich auf die Jahre 2012 bis 2020. Da ICD, wie auch OPS jährlich aktualisiert werden, müssen diese Codes auf eine Version transformiert werden. Hierfür wurden die Codes mittels Umsteiger, bereitgestellt vom Deutschen Institut für Medizinische Dokumentation und Information (DIMDI), auf die Versionen 2020 vereinheitlicht. Wichtig ist dies, da mit veränderten Therapien und Operationsmethoden sich die OP-Zeiten ändern können.

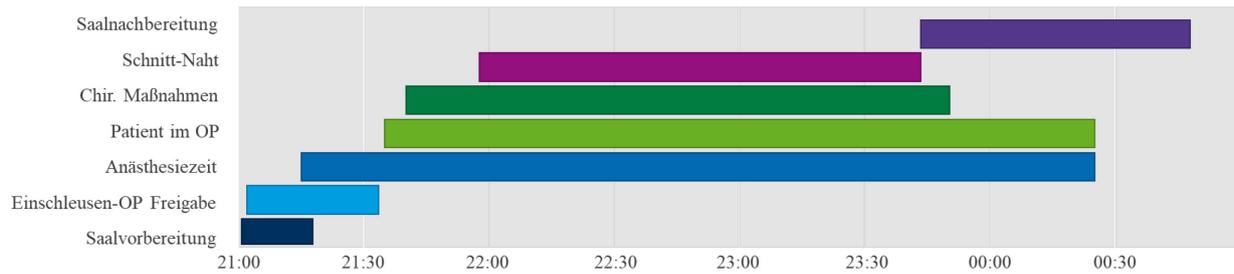


Abbildung 2: Ablaufschema der im OP durchgeführten Prozesse

Für die Bereinigung der Daten werden weitere Regeln und Festlegungen getroffen. So werden Körpergrößen auf 30cm bis 230cm, Körpergewicht von 3kg bis 200kg und Alter von 1 bis 100 Jahre festgelegt. Das Alter wird in kategorische Bereiche von 10 Jahresabschnitten eingeteilt. Alle weiteren Ausreißer oder Fehler werden entfernt. Des Weiteren gibt es unmögliche Kombinationen von zum Beispiel Größe und Gewicht, siehe Abbildung 3. Diese werden entfernt, da es sich hier um Tippfehler handelt und diese im Nachhinein nicht korrigiert werden können.

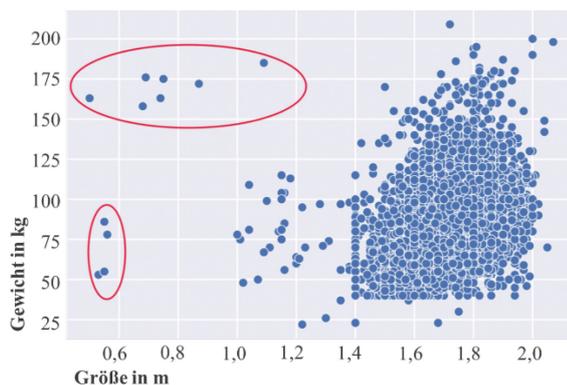


Abbildung 3: unmögliche Wertepaare.

Weiterhin gibt es bei der Zeitendokumentation Extremwerte über alle Prozessschritte (siehe Abbildung 2) hinweg, die nach Absprache mit Experten als falsch dokumentiert eingestuft werden. So finden sich Prozessdauern von bis zu 7600 min im Datensatz. Eine Überprüfung der Prozesszeiten wird mit folgender Logik abgeglichen. Prüfung nach erforderlichen Schritten; „Einschleusen-OP-Freigabe“, „Schnitt-Naht“, „Chir. Maßnahmen“, „Anästhesiezeit“, „Patient im OP“. Jeder Prozessschritt darf nicht länger als 800 Minuten dauern. Die gesamte OP-Zeit mit allen Prozessschritten darf nicht länger als 1300 Minuten dauern. Die Operation startet nach „Einschleusen-OP-Freigabe“. Die „Schnitt-Naht“ überlappt mit der „Anästhesiezeit“, „Chir. Maßnahmen“ und „Patient im OP“.

3.2 KLASSIFIKATION DER OPS-CODES

Um die statistische Verkleinerung der medizinischen Codes vorzunehmen, werden diese in Abhängigkeit zu der Dauer der jeweiligen Prozesse klassifiziert. Zur Validierung der Methodik werden hier anonyme Daten mit einem Umfang von ca. 2300 Datensätzen, die die Attribute ICD und OPS-Codes, Versionierung der Codes, Prozessschritt und Dauer der Prozessschritte beinhalten. Es werden zwei verschiedene Verfahren getestet. Vergleichend kommen die Methoden K-Means mit einem One Hot Encoding und das K-Prototyping zum Einsatz. Zuvor mussten alle medizinischen Codes auf die gleiche Jahresversion gebracht werden. Dies wurde mittels Umsteigertabellen des DIMDI erreicht. Zunächst muss die Anzahl der Klassen ermittelt werden, um so die Daten mit Labeln zu versehen. Dies wird mit der Ellenbogen-Methode erreicht. Hierfür wird die Clusteranzahl k auf der x-Achse und die Varianz auf der y-Achse aufgetragen. Da eine Verringerung der Varianz erreicht werden soll, zeichnet sich ein Knick ab, wenn sich diese nicht mehr wesentlich verändert. Es ergeben sich 9 Cluster. Im Anschluss werden die Methoden K-Means und K-Prototypes auf die Daten angewendet.

In Abbildung 4 a) sind zum besseren Verständnis die Prozessschritte über der Dauer in Minuten aufgetragen. Zusätzlich zeigen die Boxplots in welchen Minutenbereich sich die meisten Prozesse befinden. In Abbildung b) sind die OPS Codes als Punkt in der jeweiligen Labelfarbe dem Prozessschritt und der Dauer zugeordnet.

3.3 VORHERSAGE

Für die Vorhersage der OP-Dauer unter Berücksichtigung aller verzögernder Faktoren wird ein zweistufiges Verfahren vorgeschlagen, dass iterativ für jeden Prozess während der Operation durchgeführt werden muss. In der ersten Stufe wird eine Regressionsanalyse zur Bestimmung der Zeiten herangezogen. Zur Untersuchung werden hier die Lineare Regression, Random Forest Regression und die Support Vector Machine Regression vorgeschlagen.

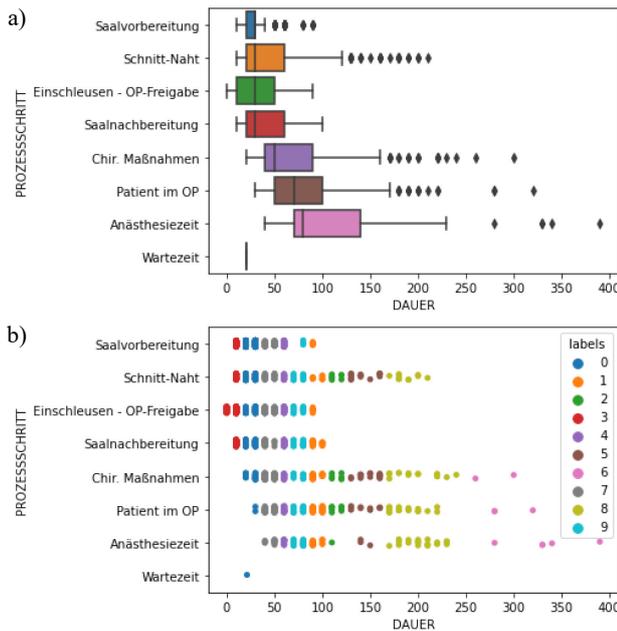


Abbildung 4: a) Boxplot der Dauern der einzelnen Prozessschritte; b) Einteilung der Label nach Prozess und Dauer

Die OP-Zeit Vorhersagen werden anschließend in drei Kategorien „kleiner als Durchschnitt“, „Durchschnitt“ und „größer als Durchschnitt“ eingeteilt. Innerhalb der jeweiligen Kategorien werden mittels *F-Test* Bewertung und *Mutual Information* diejenigen Features extrahiert, die signifikanten Einfluss auf die OP-Dauer haben. Mittels der Berechnung von *Square Error (MSE)*, *Mean Absolut Error (MAE)* und *Mean Absolute Percentage Error (MAPE)* werden die Algorithmen bewertet.

Für den zweiten Schritt wird mit Hilfe dieser Kategorien eine Multiklassen-Klassifizierung durchgeführt. Hier kann mit den vergleichenden Methoden *One-vs-Rest* oder dem *One-vs-One* gearbeitet werden. Zudem können die Algorithmen *Support Vector Machine Klassifikation (SVK)* oder eine *Random Forest Klassifikation (RFK)* zum Einsatz kommen. Bewertet werden diese Algorithmen mit einem *F1-Score*, der *Matthews Korrelationskoeffizienten (MKK)* oder der *Ausgewogenen Genauigkeit*. Nach dem Vergleich und der Bewertung der Klassifikationsverfahren wird eine *Feature Importance* durchgeführt. Die Features aus Schritt 1 und Schritt 2 werden nun verglichen und diejenigen ermittelt, die die OP-Zeiten am besten klassifizieren.

Anschließend wird der Datensatz auf diese Features und die Zielvariable „Einteilung nach Differenzdauer“ begrenzt. Die OP-Zeit verzögernden Features können so ermittelt werden. Mit einer Gegenüberstellung der Zeitverzögerung dieser Faktoren, kann die OP-Zeit Vorhersage mit Einbezug von Patientenzuständen bewertet werden und bietet so eine erhöhte Planschärfe und somit Planstabilität.

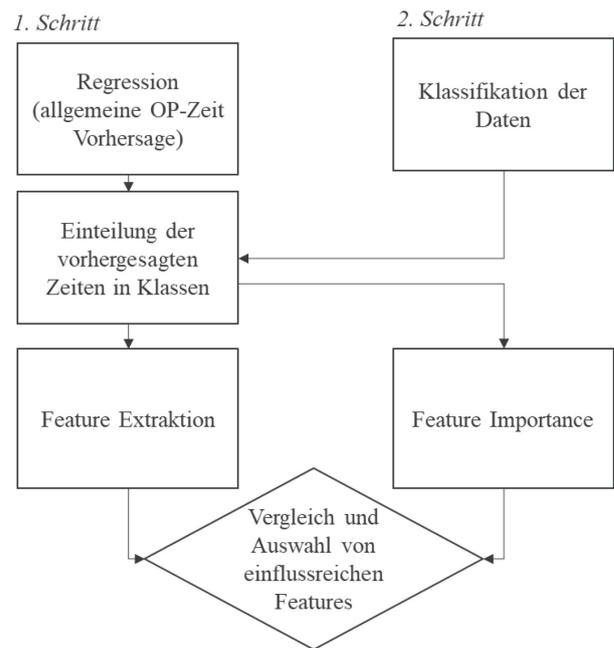


Abbildung 5: Schema zum Vorgehen der Prognose der Prozesszeiten

4 ERGEBNISSE

Die Untersuchungen, wie auch die Recherche, haben gezeigt, dass eine vorherige Auswahl an Faktoren, die auf die Operationsdauer Einfluss nehmen, sinnvoll ist. Basierend auf Erfahrungswerten der Experten und der vergleichenden Literaturrecherche konnten patientenrelevante Verzögerungsfaktoren bestimmt und für den Datenbezug geltend gemacht werden. Trotz Vorauswahl der Daten hat sich gezeigt, dass eine Bereinigung des Datensatzes unumgänglich ist, da die meisten Daten vor und während der OPs händisch eingepflegt werden und sich so Tippfehler und unmögliche Werte im Datensatz befinden. Eine vorherige Bearbeitung bedürfen auch medizinische Codes, da sie mit ihrer hohen Anzahl an Kategorien ein Encoding erschweren. Die hier durchgeführte Methode zur statistischen Reduktion hat gute Ergebnisse zur Klassifizierung im Bezug zur Dauer des Prozesses geliefert. So konnten mit einem anonymisierten Datensatz 9 Zeit-Klassen errechnet werden, für die die Varianz minimal ist. Der K-Prototype-Algorithmus hat hier deutlich bessere Ergebnisse geliefert. In Abbildung 6 a) sind für K-Means die Summen der Distanzen zu den Nachbarklassen über der Klassenanzahl aufgetragen, in Abbildung 6 b) sind für K-Prototype die Kostenwerte über der Anzahl der Klassen aufgetragen. Der K-Prototype Algorithmus berücksichtigt auch kategorische Werte, weshalb hier die Ellenbogen-Methode ein eindeutiges Ergebnis liefert, die K-Means Methode dagegen nicht, siehe Abbildung 6.

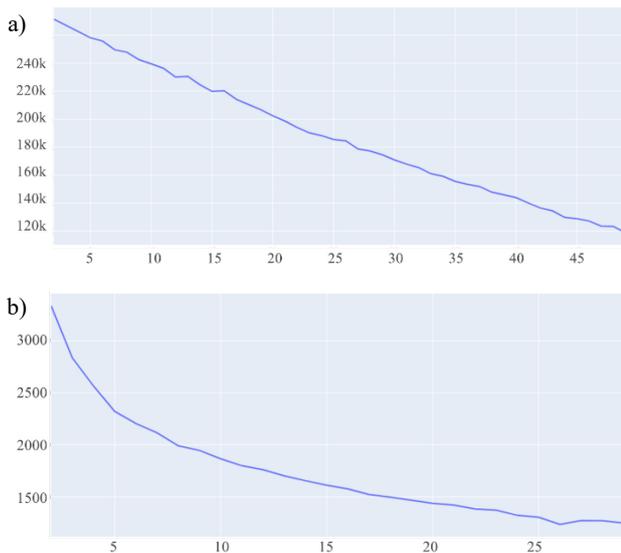


Abbildung 6: a) Distanz-Klassenanzahl-Graph für K-Means; b) Kosten-Klassenanzahl-Graph für K-Prototypes

Die Berechnung der K-Prototype-Methode dauert im Vergleich zu K-Means sehr lange. Dies ist bei der Integration in die Modelle der OP-Zeit-Vorhersage zu berücksichtigen

Für die OP-Zeit-Vorhersage wurde ein Konzept vorgestellt, dass sowohl Stammdaten als auch patientenrelevante und OP-Dauer verzögernde Faktoren berücksichtigt. Dies wird aus einer Kombination von Regressionsanalysen und Klassifikationen der patientenrelevanten Features erreicht. Mit dem vorgestellten Konzept zur OP-Zeit Prognose werden ebenfalls verzögernde Features herausgefiltert, so dass diese zur Bewertung von zum Beispiel seltenen oder komplexen Operationen herangezogen werden können. Hier wird sich in der weiteren Forschungsarbeit zeigen, ob der Datenumfang für die Ermittlung und Bewertung seltener Operationen ausreicht, oder ob hier in der Planung mit pauschalen Zeitvorgaben gearbeitet werden muss, da Verzögerungswerte nicht exakt genug berechnet werden können.

5 DISKUSSION UND AUSBLICK

Die nächsten Schritte dieser Arbeit sind die Umsetzung des Vorhersagemodells, der Vergleich und die Bewertung der Algorithmen, wie auch deren Optimierung. Hierbei ist eine iterative Umsetzung angedacht, da die Daten aus verschiedenen Datenbanken innerhalb des Fallbeispiels bezogen werden und diese mit unterschiedlichen Qualitäten behaftet sind. Die Anzahl der Attribute wird für die ersten Berechnungen auf wesentliche Merkmale reduziert. So werden typische Stammdaten und die grundlegenden Patientendaten einbezogen. Weitere Attribute werden nach einem Stufenplan in die Modelle eingepflegt. Nach dieser stufenweisen Integration aller Attribute werden auch die Vorhersagen für ausgewählte Prozesse im OP gestaltet. Die größte Unschärfe beinhaltet die Schnitt-Naht-Zeit,

weshalb dieser Prozessschritt als Zielvorgabe für die erste Iterationsstufe gewählt wird.

Ziel ist es, die Unschärfe der Operationszeiten zu minimieren und so den Operationsplan robust planen zu können. Mit dieser Herangehensweise können Über- und Unterauslastung im OP-Saal vermieden werden, was einen erheblichen Kostenvorteil mit sich bringt.

6 FÖRDERHINWEIS

Diese Maßnahme wird mitfinanziert mit Steuermitteln auf Grundlage des vom Sächsischen Landtag beschlossenen Haushaltes.



LITERATUR

- [AKK97] Alponat, A., Kum, C., Koh, B. et al. *Predictive Factors for Conversion of Laparoscopic Cholecystectomy*. World J. Surg. 21, 629–633 (1997). <https://doi.org/10.1007/PL00012288>
- [BW68] Baroon s, Wolfe H. *Scheduling a multiple operating room system: A simulation approach*. Health services research. 1968, 3 (4), 272
- [BGS16] Büren, C.; Gehrman, S. V.; Scholz, A. O.; Windolf, J.; Lögters, T. *Korrelation geschätzter und tatsächlicher Operationsdauer bei häufigen Eingriffen in der Traumatologie*. Zeitschrift für Orthopädie und Unfallchirurgie Ausgabe 03 · Volume 154 Juni 2016; DOI: 10.1055/s-00000099
- [CM18] Childers, C.P.; Maggard-Gibbons, M.; *Understanding Costs of Care in the Operating Room*. JAMA Surgery 2018 153(4): e176233. DOI: 10.1001/jamasurg.2017.6233. Epub 2018 Apr 18
- [DDM08] Dexter, F.; Dexter, Elisabeth U.; Masursky, Danielle; Nussmeier, Nancy A.; *Systematic Review of General Thoracic Surgery Articles to Identify Predictors of Operating Room Case Durations*. Anesthesia and Analgesia 2008 Apr;106(4):1232-41, table of contents. DOI: 10.1213/ane.0b013e318164f0d5
- [EHN10] Eijkemans, Marinus J.C.; Van Houdenhoven, Mark; Nguyen, Tien; Boersma, Eric; Steyerberg, Ewout W.; Kazemier, Geert.

- Predicting the Unpredictable: A New Prediction Model for Operating Room Times Using Individual Characteristics and the Surgeon's Estimate.* Anesthesiology 2010 Bd.112, Nr.1, S.41–49.
- [GAB12] Gomes C., Almada-Lobo B., Borges J., Soares C.; *Integrating Data Mining and Optimization Techniques on Surgery Scheduling.* In: Zhou S., Zhang S., Karypis G. (eds) Advanced Data Mining and Applications. ADMA 2012. Lecture Notes in Computer Science, vol 7713. Springer, Berlin, Heidelberg. https://doi.org/10.1007/978-3-642-35527-1_49
- [HSJ15] Hosseini, N; Sir, M.Y.; Jankowski, C.J; Pasupathy, K.S, *Surgical Duration Estimation via Data Mining and Predictive Modeling: A Case Study.* AMIA Annual Symposium Proceedings. 2015; 2015: 640–648
- [HA11] Hussain, Abdulzahra FRCS, FICMS, D.S *Difficult Laparoscopic Cholecystectomy*, Surgical Laparoscopy, Endoscopy & Percutaneous Techniques: August 2011 - Volume 21 - Issue 4 - p 211-217 doi: 10.1097/SLE.0b013e318220f1b1
- [HW88] Hancock WM, Walter PF, More RA, Glick ND. *Operating room scheduling data base analysis for scheduling.* Journal of medical systems. 1988;12(6):397–409.
- [KMY12] Kaneko, G.; Miyajima, A.; Yazawa, S.; et. al.; *What Is the Predictor of Prolonged Operative Timeduring Laparoscopic Radical Prostatectomy?* In: International Journal of Urology Bd.20, Nr.3, S.330–336. <https://doi.org/10.1111/j.1442-2042.2012.03185.x>
- [LCB12] Lee NW, Collins J, Britt R, Britt LD. *Evaluation of Preoperative Risk Factors for Converting Laparoscopic to Open Cholecystectomy.* The American Surgeon. 2012;78(8):831-833. doi:10.1177/000313481207800815
- [LPS20] Lindeborg, M.M; Puram, S.V.; Sethi, R.K.V.; et. al.; *Predictive factors for prolonged operative time in head and neck patients undergoing free flap reconstruction*, American Journal of Otolaryngology, Volume 41, Issue 2, 2020, 102392, ISSN 0196-0709, <https://doi.org/10.1016/j.amjoto.2020.102392>.
- [LTH16] Lowndes, Bethany; Thiels, Cornelius A.; Habermann, Elizabeth B., Bingener, Juliane; Hallbeck, Susan; Yu, Denny; *Impact of patient factors on operative duration during laparoscopic cholecystectomy: evaluation from the National Surgical Quality Improvement Program database.* The American Journal of Surgery (2016) 212, 289-296
- [RS93] Robb DJ, Silver EA. *Scheduling in a Management Context: Uncertain Processing Times and Non-Regular Performance Measures.* Decis Sci. 1993;24(6):1085–108
- [RBP02] Rosen, Michael. Brody, Fred. Ponsky, Jeffrey; *Predictive factors for conversion of laparoscopic cholecystectomy*, The American Journal of Surgery, Volume 184, Issue 3, 2002, Pages 254-258, ISSN0002-9610, [https://doi.org/10.1016/S0002-9610\(02\)00934-0](https://doi.org/10.1016/S0002-9610(02)00934-0).
- [SMV00] Strum DP, May JH, Vargas LG. *Modeling the uncertainty of surgical procedure times: comparison of log-normal and normal models.* Anesthesiology. 2000;92(4):1160–7.
- [SMS03] Strum DP, May JH, Sampson AR, Vargas LG, Spangler WE. *Estimating times of surgeries with two component procedures: comparison of the lognormal and normal models.* Anesthesiology. 2003;98(1):232–40.
- [TYA17] Thiels, Cornelius A.; Yu, Denny; Abdelrahman; Habermann, Elizabeth B.; Hallbeck, Susan; Pasupathy, Kalyan S.; Bingener, Juliane. *The Use of Patient Factors to Improve the Prediction of Operative Duration Using Laparoscopic Cholecystectomy.* Surgical Endoscopy (2017) 31:333–340, DOI 10.1007/s00464-016-4976-9.
- [WHM16] Weiser, Tomas G.; Haynes, Alex B.; Molina, George; Lipsitz, Stuart R.; Esquivel, Micaela M.; et. al. *Size and Distribution of the Global Volume of Surgery in 2012.* Bulletin of the World Health Organization 2016 Mar 1 Bd.94, Nr.3, 201–209F. DOI: 10.2471/BLT.15.159293
- [ZFY19] Zhu, Shuwan; Fan, Wenjuan; Yang, Shanlin; Pei, Jun; Pardalos, Panos M.; *Operating Room Planning and Surgical Case Scheduling: A Re- view of Literature*, Journal of Combinatorial Optimization, 2019, Bd.37, Nr.3, S.757–805 DOI <https://doi.org/10.1007/s10878-018-0322-6>

[ZBB12] Zdichavsky, Martya; Bashin, Yasser A.a; Blumenstock, Gunnarb; Zieker, Dereka; Meile, Tobiasa; Königsrainer, Alfreda *Impact of risk factors for prolonged operative time in laparoscopic cholecystectomy*, European Journal of Gastroenterology & Hepatology: September 2012 - Volume 24 - Issue 9 - p 1033-1038 doi: 10.1097/MEG.0b013e328354ad6e

Dipl.-Ing. Jennifer Saß, Research Assistant at the Chair of Material Handling, Technische Universität Dresden. Jennifer Saß received a Diploma in Mechanical Engineering in 2011. Her research areas are automated creation of process sequence rules for process planning using machine learning and determination of process sequence relationship based on multi-variant productions using machine learning to generate a better planning basis.

Address: Technische Universität Dresden, Faculty of Mechanical Science and Engineering, Institute of Material Handling and Industrial Engineering, Chair of Logistics Engineering, 01062 Dresden, Germany.
Germany, Phone: +49 351 463-32278;
Fax: +49 351 463-35499,
E-Mail: jennifer.sass@tu-dresden.de

Nick Hartmann, Student at the Chair of Material Handling, Technische Universität Dresden.

apl. Prof. Dr. Ing. Habil. Michael Völker, Research Assistant at the Chair of Material Handling and Head of the Factory Planning Working Group, Technische Universität Dresden.

Michael Völker is Head of the Factory Planning Working Group TU Dresden, Chair of Material Handling in the Mechanical Engineering faculty since 2009. He holds a diploma degree in mechanical engineering from the TU Dresden. He received his Ph.D. from the TU Dresden in 1988. His research areas are production system and factory planning, as well as production logistics, planning and control. He works on digital production (Industry 4.0) and simulation technology, industrial building design and construction and technical project management.

Address: Technische Universität Dresden, Faculty of Mechanical Science and Engineering, Institute of Material Handling and Industrial Engineering, Chair of Logistics Engineering, 01062 Dresden, Germany.

Phone: +49 351 463 34398
Fax: +49 351 463 35499
E-Mail: michael.völker@tu-dresden.de

Prof. Dr.-Ing. habil. Thorsten Schmidt, Head of the Chair of Material Handling, Technische Universität Dresden.

Thorsten Schmidt is full professor at the TU Dresden and heads the Chair of Material Handling in the Mechanical Engineering faculty since 2008. He holds a diploma degree in mechanical engineering from the TU Dortmund and a Master degree in industrial engineering from the Georgia Institute of Technology. He received his Ph.D. from the TU Dortmund in 2001. His research areas are the design and optimization of facility logistics and production systems including a focus on the machinery and components involved. He currently works on energy efficient control strategies in material flow, fast approximation in early planning stages by means of standard design modules, online data analysis, formal verification of control logic, performance analysis of decentral and self-controlled systems, lightweight structures in material handling and stress analysis on wire ropes and toothed belts, respectively.

Address: Technische Universität Dresden, Faculty of Mechanical Science and Engineering, Institute of Material Handling and Industrial Engineering, Chair of Logistics Engineering, 01062 Dresden, Germany.
Phone: +49 351 463 32538
Fax: +49 351 463 35499
E-Mail: thorsten.schmidt@tu-dresden.de