


Beiträge und Analysen

Gesundheitswesen

aktuell 2021

herausgegeben von Uwe Repschläger,
Claudia Schulte und Nicole Osterkamp



Beatrix Augustin, Katja Barnard, Matthias Becker, Erwan Bigan, Heike Dorninger, Milena Kauka,
Leonie Kulik, Uwe Repschläger, Michael Ruhl, Klaus Stein, Konstantin Storms
Der Einsatz von KI für eine personalisierte Patientenversorgung –
Identifikation von Risikofaktoren für Knie-TEP-Revisionen, Seite 290–307

doi: 10.30433/GWA2021-290

Beatrix Augustin, Katja Barnard, Matthias Becker, Erwan Bigan, Heike Doringner, Milena Kauka, Leonie Kulik, Uwe Repschläger, Michael Ruhl, Klaus Stein, Konstantin Storms

Der Einsatz von KI für eine personalisierte Patientenversorgung – Identifikation von Risikofaktoren für Knie-TEP-Revisionen

Der chirurgische Einsatz von Knie-Totalendoprothesen (Knie-TEP) gehört mit einem Anteil von elf Prozent zu den häufigsten vollstationär durchgeführten Operationen in Deutschland. Nach dem Einsatz einer Knie-TEP sind 18 Prozent der Patienten nicht zufrieden mit dem Ergebnis. In einigen Fällen kommt es zu Komplikationen oder Revisionsoperationen, bei denen die Prothese ausgetauscht wird. In einem gemeinsamen Projekt der Boston Consulting Group (BCG) und der BARMER wird eine Künstliche Intelligenz genutzt, um Risikofaktoren einer erneuten Knieoperation zu identifizieren. Grundlage für das Prädiktionsmodell sind die Routinedaten einer der größten gesetzlichen Krankenkassen. Durch die Nutzung dieser Daten ist es möglich, sowohl Eigenschaften der Behandlung als auch des Patienten abzubilden. Die Ergebnisse werden in die aktuelle medizinische Literatur eingeordnet und der Nutzen für eine zukünftige personalisierte Versorgung wird aufgezeigt.

Stand der Forschung und Ausgangslage

Die Implantation von Hüft- und Knie-Endoprothesen zählt zu den häufigsten vollstationär durchgeführten operativen Eingriffen in Deutschland: Im Jahr 2019 wurden über 240.000 Hüftgelenk- und über 190.000 Kniegelenk-Prothesen eingesetzt (Destatis 2019). Dabei ist die Anzahl der Endoprotheseneingriffe im Bereich des Knies von 2014 bis 2019 um 18 Prozent gestiegen (Bleß und Kip 2017: 36; Destatis 2019). Auch der Anteil der jüngeren Patienten steigt, rund zehn Prozent der Hüft-TEPs und rund acht Prozent der Knie-TEPs (Totalendoprothesen) werden bei Patienten unter 55 Jahren eingesetzt (Fath 2018). Im internationalen Vergleich zeigt sich, dass Deutschland relativ zu europäischen Ländern wie Frankreich, Großbritannien und den Niederlanden deutlich mehr Kniegelenkersatz-Operationen durchführt. Normiert auf die Einwohnerzahl werden in Deutschland im Vergleich zu den Niederlanden rund 75 Prozent mehr Kniegelenke ersetzt (Bleß und Kip 2017: 36).

Nach einer Operation kann es zu Unzufriedenheit, Schmerzen, aber auch zu Komplikationen bis hin zu Revisionsoperationen kommen. Insgesamt sind rund 18 Prozent der Patienten mit dem Ergebnis ihrer Knie-TEP nicht zufrieden (Reichel et al. 2019). Prädiktive Faktoren, die häufig mit einer Patientenunzufriedenheit einhergehen, sind die Patientenerwartung vor der Operation, die prä- und postoperativen Schmerzen und das Niveau der Kniefunktion (Reichel et al. 2019; Gunaratne et al. 2017).

Schmerzen werden häufig durch implantat- oder implantationsassoziierte Faktoren wie beispielsweise eine aseptische Lockerung oder eine Infektion verursacht und können oft durch Revisionen korrigiert werden (Reichel et al. 2019). Eine Studie zeigt auf, dass sozioökonomische und patientenabhängige Faktoren jedoch das Ergebnis und die Patientenzufriedenheit deutlich besser vorhersagen können als implantatabhängige Faktoren (Butler et al. 2019).

Zu den Faktoren, die mit Unzufriedenheit und Schmerz in Verbindung stehen, gehören niedrige Schulbildung, ein niedriges Einkommen und ein jüngeres Alter (geringer als 60 Jahre). Auch mangelnder sozialer Rückhalt oder psychische Vorerkrankungen wie beispielsweise Depressionen, Vermeidungsverhalten und Somatisierungsstörungen werden häufig mit einem negativen postoperativen Ergebnis assoziiert. Die prä- oder postoperative Opioidaufnahme kann sich ebenfalls negativ auf das Operationsergebnis auswirken (Reichel et al. 2019).

Bei näherer Betrachtung der implantat- oder implantationsassoziierten Faktoren und Revisionsoperationen zeigt der Jahresbericht des Endoprothesenregisters Deutschlands (EPRD) aus dem Jahr 2020, dass die häufigsten Gründe für einen Wechseleingriff am Kniegelenk Lockerungen (23,9 Prozent), Infektionen (14,5 Prozent) und Instabilitäten (8,5 Prozent) darstellen. Den größten Anteil der Knieprothesen machen zementierte Totalendoprothesen aus. Der Anteil der unicondylären Endoprothesen stieg allerdings über die vergangenen Jahre an und liegt bei 13,5 Prozent (Grimberg et al. 2020).

Die Analyse der EPRD-Daten zeigt, dass Männer insgesamt ein höheres Risiko für einen Prothesenausfall haben als Frauen. Wie von Reichel et al. (2019) gezeigt, haben auch

laut dieser Analyse jüngere Patienten eine höhere Ausfallwahrscheinlichkeit. Zusätzlich lässt sich sagen, dass bei Patienten mit mehr als fünf Begleiterkrankungen ein deutlich höheres Risiko vorliegt (Grimberg et al. 2020). Bekannte Vorerkrankungen mit dem erhöhten Risiko für einen Folgeeingriff stellen beispielsweise erhebliches Übergewicht ($\text{BMI} \geq 40$), Diabetes mellitus, Nikotinabusus, Alkoholabusus, Osteoporose, rheumatische Erkrankungen und Osteomalazie dar (Buecking et al. 2013; Lambertz et al. 2017).

Nicht nur individuelle Faktoren des Patienten, sondern auch der Behandler hat Einfluss auf das OP-Ergebnis. So zeigen Steinbrück et al. (2020), dass erfahrene Krankenhäuser mit häufig durchgeführten Knie-TEPs (mehr als 500 Implantationen im Jahr) eine signifikant niedrigere Revisionsrate aufweisen. In diesen Häusern liegt die Revisionsrate bei 2,7 Prozent im Vergleich zu 3,4 Prozent bei Häusern mit bis zu 250 Implantationen einer Knie-TEP. Zusätzlich führt ein Hersteller- beziehungsweise ein Implantatsystemwechsel innerhalb einer Klinik zu einem Anstieg der Revisionsrate auf 3,6 gegenüber 3,1 Prozent ohne Herstellerwechsel (Steinbrück et al. 2020).

Um das oben genannte Spektrum der Risikofaktoren abzubilden, eignet sich die Auswertung der Routinedaten einer gesetzlichen Krankenkasse, da sie viele der benannten Faktoren enthalten. Im Folgenden wird analysiert, inwieweit die wissenschaftlich belegten Risikofaktoren für eine Knie-TEP-Revision mithilfe einer Künstlichen Intelligenz aus Routinedaten der BARMER bestätigt werden können. Zusätzlich zeigt die Studie zukünftige Handlungsoptionen im Bereich des personalisierten Versorgungsmanagements auf und bewertet damit die Anwendbarkeit von Künstlicher Intelligenz auf Krankenkassendaten zum Zweck eines personalisierten Versorgungsmanagements am Beispiel der Knie-TEP-Revision. Der Begriff Künstliche Intelligenz bezieht sich hier auf Methoden aus dem Bereich des Maschinellen Lernens, welche in der Lage sind, auf Basis von Erfahrungen zu lernen und sich so eigenständig zu optimieren (Mitchell 1997).

Methodisches Vorgehen

In dieser Studie wird ein Modell aus dem Bereich des Maschinellen Lernens entwickelt mit dem Ziel, die individuelle Wahrscheinlichkeit einer Revision nach einer Knie-

Endoprothese zu präzisieren und so eine potenzielle Revision frühzeitig zu identifizieren. Aus dem trainierten Prädiktionsmodell können im Anschluss Risikofaktoren für eine Revision abgeleitet und diese hinsichtlich ihres Einflusses auf die Revisionswahrscheinlichkeit quantifiziert werden.

Beschreibung der Datenbasis

Die Datengrundlage für die Prädiktion bilden anonymisierte Versichertenstammdaten, Daten aus der ambulanten und stationären Versorgung sowie Arzneimitteldaten, die in den Routinedaten der BARMER vorliegen. Diese Routinedaten werden durch Informationen zu Größe und Qualitätsmerkmalen der operierenden Krankenhäuser ergänzt. Dieses Vorgehen hat mehrere Vorteile: Da die umfangreichen Routinedaten der BARMER genutzt werden, müssen Daten nicht gesondert erhoben werden. Dadurch entfällt in dieser Studie die zeitaufwändige Erhebung. Zusätzlich ist aufgrund der hohen Datenqualität und der standardisierten Struktur der Routinedaten wenig Aufwand für die Datenaufbereitung zu leisten.

Als Population (67.020 Patienten) für das Prädiktionsmodell dienen alle Patienten, denen in dem Zeitraum vom 1. Januar 2016 bis zum 31. Dezember 2018 eine Knie-Endoprothese implantiert wurde. Diese Patienten lassen sich anhand des Operationsschlüssels OPS 5-822 aus stationären Daten identifizieren. Um Notfälle und Frakturen auszuschließen, werden nur Patienten mit einer diagnostizierten Gonarthrose (ICD-10-Kode M17) berücksichtigt.

Aufbau des Prädiktionsmodells und Definition der Zielvariablen

Zur Prädiktion der Revision von Knie-Endoprothesen wird ein Klassifikationsmodell verwendet, welches die Patienten hinsichtlich des Eintretens einer Revision in zwei Gruppen segmentiert: (1) Patienten mit einer Revision innerhalb eines Jahres nach der Implantation und (2) Patienten ohne Revision (binäre Zielvariable). Genauer wird zur Bildung dieser binären Zielvariable geprüft, ob bei dem jeweiligen Patienten im ersten Jahr nach Implantation der Knie-Endoprothese eine Revision mit Lokalisation am gleichen Bein der Erstimplantation durchgeführt wird. Revisionen werden hierzu aus den stationären und ambulanten Daten evaluiert und als Operationen mit der

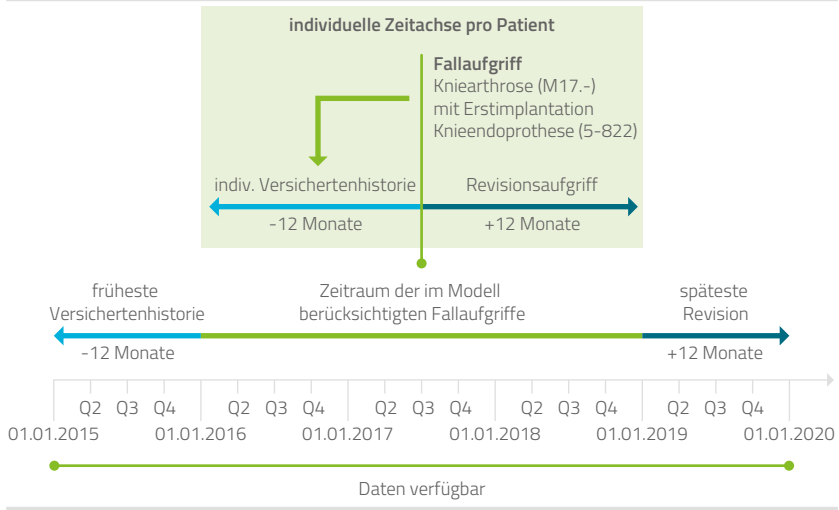
Kodierung OPS 5-823 (Revision, Wechsel und Entfernung einer Endoprothese am Kniegelenk) sowie einer erneuten Kodierung einer Implantation 5-822 (Implantation einer Endoprothese am selben Kniegelenk) verstanden. Die zeitliche Eingrenzung der Revisionen auf ein Jahr erfolgt aus zwei Gründen:

1. Das Prädiktionsergebnis des Modells kann verbessert werden, da Einflussfaktoren, die nach der Erst-Operation auftreten, vermieden werden. So erhöht sich der Bezug des Modells auf die zum Zeitpunkt der Operation vorliegenden Risikofaktoren.
2. Außerdem kann unter Voraussetzung des verfügbaren Datenzeitraums vom 1. Januar 2015 bis zum 31. Dezember 2019 der Aufgriffszeitraum für Patienten mit einer Knie-TEP maximiert werden, und mehr Patienten stehen für die Modellbildung zur Verfügung.

Abbildung 1 illustriert den zeitlichen Aufbau des Modells sowie die im Modell berücksichtigte individuelle Zeitachse der Patienten. Der individuelle Fallaufgriff der Patienten erfolgt jeweils zum Zeitpunkt der Erstimplantation der Knie-TEP. Zu diesem Zeitpunkt liegen Daten aus zwölf Monaten Patientenhistorie vor. Außerdem werden Revisionen innerhalb von zwölf Monaten nach dem Fallaufgriff berücksichtigt. Die Revisionsrate unter den berücksichtigten Patienten beträgt innerhalb des ersten Jahres 2,5 Prozent.

Das Prädiktionsmodell soll auf Basis der Patientenhistorie Patienten mit einer bevorstehenden Revision bereits zum Zeitpunkt unmittelbar vor der ersten Implantation der Endoprothese identifizieren.

Abbildung 1: Zeitliche Dimension, die durch das Modell betrachtet wird



Quelle: eigene Darstellung

Zur Prädiktion der Revisionen werden für jeden Patienten individuelle Features aus den anonymisierten Versichertenstammdaten, den individuellen ambulanten und stationären Diagnosen, den Verschreibungen, den Krankenhausdaten der BARMER sowie den zusätzlichen Informationen zu dem Krankenhaus, welches die Operation zur Implantation der Knie-Endoprothese durchführt, erstellt. Features sind in diesem Zusammenhang messbare Merkmale des Versicherten, die für die Nutzung durch einen Prädiktionsalgorithmus aufbereitet werden.

Es wird nicht nur analysiert, ob ein Patient eine Diagnose hat (ja/nein), sondern auch, wie oft die Diagnose gestellt wurde und wie oft die Diagnose im Verhältnis zu anderen Diagnosen gestellt wurde. Zusätzlich wird die vergangene Zeit seit der frühesten und spätesten Diagnosestellung als zeitabhängiges Feature berücksichtigt, um die zeitliche Dimension der individuellen Patientenreise im Modell abzubilden.

In Tabelle 1 werden die hieraus resultierenden 7.000 Features inhaltlich aufgliedert dargestellt. Aus den persönlichen Daten der Versicherten werden Informationen wie

Alter, Geschlecht, Daten zur Pflegebedürftigkeit sowie die Bevölkerungsdichte im Wohnort als Features genutzt. Informationen bezogen auf die Knie-TEP selbst werden herangezogen, um Differenzen zwischen operierenden Krankenhäusern und Operationsablauf aufzudecken.

Tabelle 1: Für alle Patienten erstellte Features mit ihrer jeweiligen Einordnung, Beschreibung und der Anzahl der entstandenen Datenpunkte pro Patient

	genutzte Datenpunkte	erzeugte Features	Anzahl erzeugter Feature-Spalten
Versicherte	Alter	Alter in Jahren (numerisch)	1
	Geschlecht	M/W/D	2
	Pflegebedürftigkeit	Pflegegrad (kategorisch) und Pfl egetyp (kategorisch)	14
	Wohnort	Bevölkerungsdichte	4
Knie-TEP	operierendes Krankenhaus	IK-Nummer (kategorisch)	986
	Prothesen-Typ	zweistellige Endung des OPS-Kodes der Implantation (kategorisch)	30
	Einweisungsgrund	voll-/teilstationär, Normalfall/Notfall etc. (kategorisch)	18
operierendes Krankenhaus	Anzahl Knie-TEP-OPs	Anzahl der Knie-TEP und Revisions-OPs (numerisch)	1
	Bettenzahl	Anzahl aller Betten des Hauses (numerisch)	1
	Servicestatus	Grund-/Regel-/Maximalversorger, Fach-Krankenhaus (kategorisch)	7
	Qualitätsindikatoren	Ergebnis (numerisch) und Ergebniseinordnung (kategorisch) für fünf Qualitätsindikatoren	44
Historie	Diagnosen (dreistellig)	Vorkommen (j/n) (kategorisch)	3.925
	Operationen (fünfstellig)	Anzahl der Vorkommen (numerisch)	1.305
	Medikamente (fünfstellig)	Zeit seit erster/letzter Diagnose/OP/Verschreibung (numerisch)	1.140

Quelle: eigene Darstellung

Auf das operierende Krankenhaus wird detaillierter eingegangen, indem die dort stattgefundenene Anzahl der Knie-TEP-Operationen, die Bettenzahl, der Servicestatus (Grund-/Regel-/Maximalversorger, Fachkrankenhaus) sowie verschiedene Qualitätsindikatoren als Features hinzugenommen werden. Diese Indikatoren stammen aus den Qualitätsberichten der Krankenhäuser beim Gemeinsamen Bundesausschuss (G-BA), welche die Raten der Reoperationen, postoperativen Wundinfektionen und Todesfälle

nach einer Knie-TEP abbilden (BCG German Hospital Database). Zusätzlich wird, wie zuvor beschrieben, ein Jahr aus der Patientenhistorie hinsichtlich aufgetretener Diagnosen (dreistellige ICD-Kodes), Operationen (fünfstellige OPS-Kodes) und verschriebene Medikamente (fünfstellige ATC-Kodes) ausgewertet, um den Verlauf der Erkrankung abzubilden und den Einfluss von Komorbiditäten auf das Revisionsrisiko zu bewerten.

In der technischen Umsetzung des Klassifikationsmodells wird eine Modellpipeline in zwei Schritten gebildet:

- (1) einem Feature Selection Algorithmus sowie
- (2) einem Gradient Boosted Tree Klassifikationsmodell (XGBoost).

Der Feature Selection Algorithmus dient dazu, unwichtige oder nur geringfügig wichtige Features auszuschließen, da diese einen negativen Effekt auf die Modellperformance haben können (John et al. 1994). Für das Klassifikationsmodell in dieser Studie werden 300 Features mit dem Algorithmus selektiert.

Auf Basis der selektierten Features wird im Anschluss ein XGBoost Klassifikationsmodell trainiert. XGBoost ist ein Algorithmus, welcher mithilfe eines Ensembles aus mehreren Entscheidungsbäumen lernt, die Zielvariable möglichst gut vorherzusagen. Dabei erkennt der Algorithmus auch komplexe, nicht lineare Zusammenhänge und ist sowohl für Regressions- als auch Klassifikationsprobleme anwendbar. XGBoost eignet sich aufgrund seiner Effizienz und seiner guten Eigenschaften im Umgang mit dünn besetzten Inputdaten für eine Vielzahl an Problemstellungen (Chen und Guestrin 2016). Der Datensatz, bestehend aus den aus Patientendaten generierten Features und der Zielvariable, wird in einen Trainingsdatensatz (70 Prozent) sowie einen Validierungsdatensatz (30 Prozent) unterteilt. Auf dem Trainingsdatensatz wird das Modell trainiert. Das heißt, es werden Muster erkannt, die den Zusammenhang zwischen Inputdaten und der Zielvariable (Revision) in den Trainingsdaten erklären.

Um die Güte des Modells zu evaluieren, werden Daten genutzt, die nicht für das Training genutzt werden – der Validierungsdatensatz. So wird verhindert, dass das Modell Muster erkennt, die nur zufällig im Trainingsdatensatz vorkommen.


Evaluation der Prädiktionsgüte

Nach dem Trainieren des Modells wird die Modellgüte mithilfe des Receiver Operating Characteristic (ROC) evaluiert. Die ROC-Kurve eines binären Klassifikationsmodells zeigt das Verhältnis zwischen der Rate der richtigerweise der positiven Klasse zugeordneten (True Positive Rate – TPR) und der Rate der fälschlicherweise der positiven Klasse zugeordneten Datenpunkte (False Positive Rate – FPR) (Fawcett 2001). Für den Anwendungsfall Knie-TEP bedeutet das: Die TPR umfasst den Anteil der Patienten, die tatsächlich eine Revision haben und durch das Modell korrekt vorhergesagt werden. Die FPR hingegen bezeichnet den Anteil derjenigen Patienten, welchen durch das Modell fälschlicherweise eine Revision vorhergesagt wird.

Schaut man sich das Verhältnis der TPR zu der FPR auf der ROC-Kurve an, kann das Klassifikationsmodell dieser Studie insbesondere hinsichtlich seiner Fähigkeit bewertet werden, Patienten mit Revision ein höheres Revisionsrisiko zuzuordnen. Die Fläche unter der ROC-Kurve (Area Under the Curve – AUC) liegt zwischen 0 und 1 und fasst diese Eigenschaft zusammen: Bei einem Wert von 0 ordnet das Modell alle Daten der jeweils falschen Klasse zu, bei einem Wert von 1 kann es alle Daten der richtigen Klasse zuordnen. Ein ROC-AUC von 0,5 entspricht der zufälligen Zuordnung (Fawcett 2001) und entspricht im ROC-Graph der Winkelhalbierenden (Abbildung 2). Um zehn Prozent der Patienten mit einer Revision zu selektieren, würde man ohne Modell ebenfalls zehn Prozent der Patienten ohne eine Revision selektieren müssen, da keine Information zur Differenzierung zwischen den Gruppen verfügbar wäre.

Das in dieser Studie erstellte Modell zur Prädiktion von Revisionen von Knie-Endoprothesen erreicht einen ROC-AUC-Wert von 0,7. Mit einem ROC-AUC von 0,7 und einer in Richtung der linken oberen Ecke verschobene Kurve erhöht das Modell in dieser Studie somit die Differenzierungsfähigkeit zwischen Patienten mit einem hohen und einem niedrigen Revisionsrisiko. Ein Wert von 0,7 lässt sich hierbei als ausreichend aussagekräftig interpretieren (Hosmer und Lemeshow 2000). Für den Anwendungsfall kann dies durch Auswertung auf dem Validierungsdatensatz veranschaulicht werden: Wenn wir für eine Intervention 2.000 Patienten berücksichtigen können, sind darunter ohne Modell nur 50 mit einer Revision. Mit dem Modell werden mit 179 Patienten mit Revision deutlich mehr richtig selektiert.

Abbildung 2: Modellgütevalidierung in Form einer ROC-Analyse



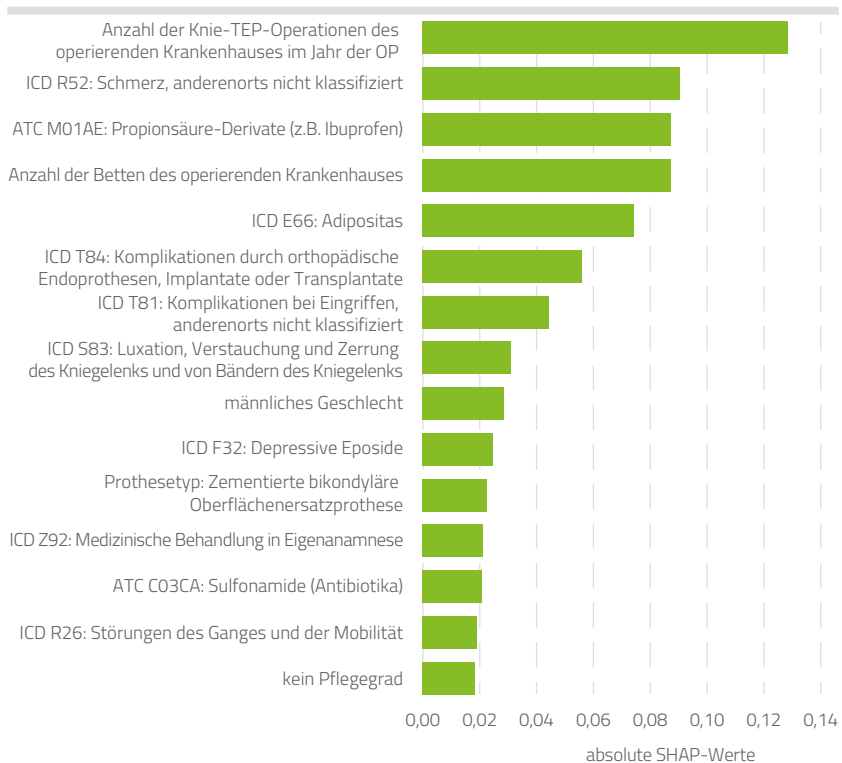
Anmerkung: Es wird ein ROC-AUC-Wert von 0,7 erreicht. Die blaue Linie stellt die zufällige Auswahl der Patienten dar. Die grüne Linie zeigt die Trefferquote, die durch das Modell erreicht werden kann.

Ableitung der Risikofaktoren für Knie-TEP-Revisionen

Der individuelle Einfluss der beteiligten Features auf das Modellergebnis kann mit einer SHAP-Analyse (SHapley Additive exPlanations) interpretiert werden (Lundberg und Lee 2017). Die SHAP-Analyse ermöglicht, die individuelle Wichtigkeit einzelner Features auf das Modellergebnis zu evaluieren, und wird oft genutzt, um Modelle im Bereich des Maschinellen Lernens erklärbar und interpretierbar zu machen (Ribeiro et al. 2016; Movahedi und Derrible 2020). In der Studie wird die SHAP-Analyse genutzt, um die vom Prädiktionsmodell genutzten Features hinsichtlich ihres individuellen Einflusses auf die Revisionswahrscheinlichkeit zu bewerten und die Haupt-Risikofaktoren für

Revisionsoperationen zu identifizieren. Mithilfe der SHAP-Analyse kann eine individuelle Vorhersage des Modells erklärt werden. Die SHAP-Werte zeigen für jedes Feature die Veränderung zwischen der Modellprädiktion und der Prädiktion, wenn dieses Feature nicht im Modell vorhanden wäre. Damit zeigt der SHAP-Wert für jeden Patienten auf, wie stark jedes Feature die Abweichung des tatsächlichen Prädiktionswertes vom durchschnittlichen Wert beeinflusst. Ob ein Feature wichtig ist oder nicht, hängt nicht direkt mit seinem Wert zusammen. In Abbildung 3 sind die aggregierten SHAP-Werte der 15 wichtigsten Features für den Anwendungsfall abgebildet.

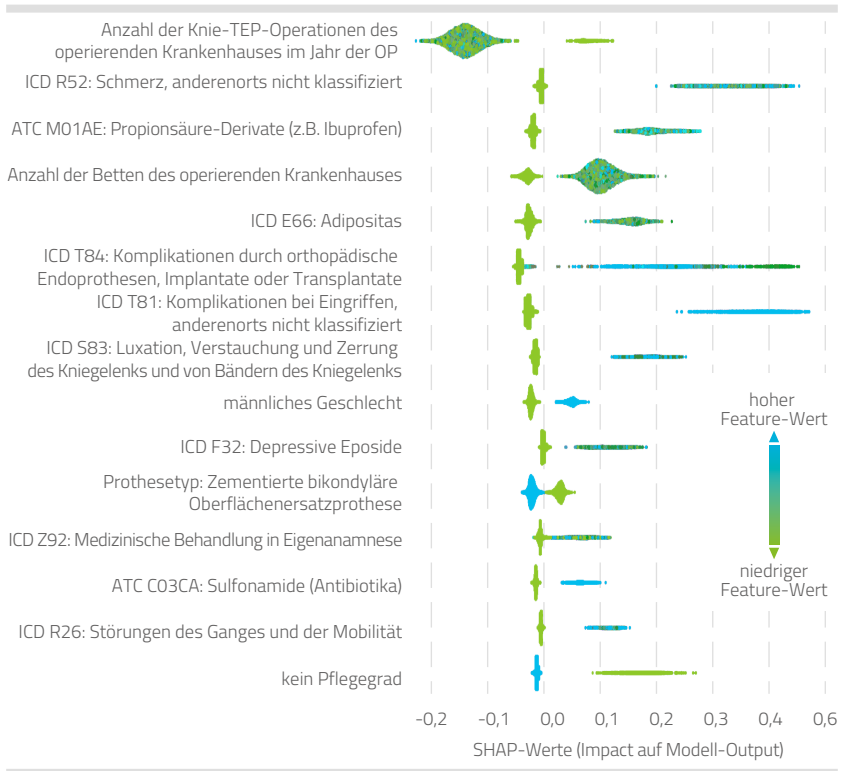
Abbildung 3: Die 15 wichtigsten Features nach SHAP-Werten aggregiert für alle Patienten



Quelle: eigene Daten, BARMER 2015 bis 2019

Durch das Feature „Anzahl der Betten des operierenden Krankenhauses“ wird das durchschnittliche prädizierte Revisionsrisiko um 0,09 verändert. Damit hat die Anzahl der Betten des Krankenhauses einen starken Einfluss auf das Revisionsrisiko und ist das viert einflussreichste Feature für die Prädiktion nach der SHAP-Analyse.

Abbildung 4: Die 15 wichtigsten Features nach SHAP-Werten mit ihrem patientenindividuellen Einfluss auf das Revisionsrisiko



Quelle: eigene Daten, BARMER 2015 bis 2019

Anmerkung: Jeder Punkt repräsentiert einen Patienten, die Farbskala repräsentiert einen hohen beziehungsweise niedrigen Feature-Wert.

Für jeden Patienten lässt sich mithilfe der SHAP-Analyse bewerten, welche Features für die Prädiktion der Revisionswahrscheinlichkeit wichtig sind. Diese können sich von Patient zu Patient unterscheiden. Abbildung 4 veranschaulicht, wie mithilfe der

SHAP-Werte der Einfluss der einzelnen Features auf die patientenindividuelle Prädiktion bewertet werden kann. Insbesondere kann die Richtung des Einflusses mit dem durchschnittlichen Prädiktionsergebnis verglichen werden. Am Beispiel des männlichen Geschlechts lässt sich entsprechend ableiten, dass bei männlichen Patienten dieses Feature zu einem vergleichsweise erhöhten prädiagnostizierten Revisionsrisiko beigetragen hat.

Darstellung der Hauptaussagen und Ergebnisse

Risikofaktoren für eine Revisionsoperation im Folgejahr nach einer Erstoperation

Mithilfe des in dieser Studie verwendeten Klassifikationsmodells können Risikofaktoren für eine Revision nach der Implantation einer Knie-Endoprothese mithilfe einer SHAP-Analyse identifiziert und quantifiziert werden. Diesen Risikofaktoren lassen sich drei Gruppen zuordnen:

1. Eigenschaften des operierenden Krankenhauses oder der Operation,
2. persönliche Eigenschaften der Patienten sowie
3. deren Diagnosehistorie.

Auf die 15 stärksten Risikofaktoren wird im Folgenden eingegangen.

Das in der Prädiktion wichtigste Feature des Modells ist die Anzahl der Operationen in dem jeweiligen Krankenhaus der Endoprothesen-Implantation. Das Modell zeigt, dass hierbei ein negativer Zusammenhang zwischen der Operationsanzahl und der Revisionsrate besteht, sodass Eingriffe in Krankenhäusern mit weniger Operationen im Durchschnitt zu einem erhöhten prädiagnostizierten Revisionsrisiko führen. Dabei ist der Zusammenhang komplexer. Vielen Krankenhäusern mit geringem Knie-TEP-Volumen ordnet das Modell kein erhöhtes Revisionsrisiko zu. Jedoch besitzen alle Krankenhäuser mit einem negativen Einfluss im Modell niedrige Fallzahlen.

Als weitere Eigenschaft des operierenden Krankenhauses zeigt sich, dass die Anzahl der Betten in positivem Zusammenhang mit dem Revisionsrisiko steht: Eine höhere

Bettenanzahl hat im Durchschnitt ein erhöhtes Risiko. Zusätzlich führt die Implantation einer zementierten bikondylären Oberflächenersatzprothese (OPS-Kode 5-822.g1) zu einem durchschnittlich verringerten Revisionsrisiko.

Insbesondere zwei Eigenschaften der Patienten werden als Risikofaktor erkannt: Das männliche Geschlecht steigert laut Modell bei allen Patienten das Revisionsrisiko im Vergleich zu den Patientinnen. Ebenfalls negativ wirkt sich ein Pflegegrad auf das Revisionsrisiko aus.

Zusätzlich haben einige Vordiagnosen und Medikationen aus der Patientenhistorie vor Implantation der Endoprothese Einfluss auf das prädizierte Revisionsrisiko: Häufige Schmerz-Diagnosen (ICD-10-Kode R52) sowie Verschreibungen von Propionsäure-Derivaten wie beispielsweise Ibuprofen (ATC-Kode M01AE) führen zu einem erhöhten prädizierten Risiko. Ebenso bedingen vorherige Komplikationen mit orthopädischen Endoprothesen (ICD-10-Kode T84) sowie Komplikationen bei Eingriffen (ICD-10-Kode T81) eine Erhöhung des Risikos einer erneuten Komplikation. Den gleichen Effekt zeigen Vordiagnosen, welche eine Verringerung der Mobilität bedingen: Luxation, Verstauchung oder Belastung von Gelenken (S83) sowie Störungen des Ganges und der Mobilität (ICD-10-Kode R26). Zuletzt können auch nicht-orthopädische Komorbiditäten ohne direkten Bezug auf den Bewegungsapparat das Revisionsrisiko beeinflussen: Vorherige Adipositas-Diagnosen (ICD-10-Kode E66), das Auftreten von depressiven Episoden (ICD-10-Kode F32), medizinische Behandlung in der Eigenanamnese, wie beispielsweise Dauertherapie mit Antikoagulanzen in der Eigenanamnese (ICD-10-Kode Z92), aber auch vergangene Verschreibungen von Sulfonamiden (ATC-Kode C03CA), einem Antibiotikum, dienen als Indikatoren für ein erhöhtes prädiziertes Revisionsrisiko nach einer Knie-TEP.

Bewertung und Ausblick

In der durchgeführten Studie wird gezeigt, dass eine gut trainierte Künstliche Intelligenz in der Lage ist, Risikofaktoren für eine Revisionsoperation zu identifizieren. Es zeigen sich große Überschneidungen zwischen der medizinischen Literatur und den Ergebnissen der Studie: Adipositas, das männliche Geschlecht und die Diagnose depressive Episode

sind Faktoren, welche sowohl durch das Prädiktionsmodell als auch in anderen Studien als Risikofaktoren für eine Revisionsoperation identifiziert werden. Ebenso zeigt das Modell auf, dass es in Krankenhäusern mit wenig Endoprothesen-Eingriffen zu einem erhöhten Revisionsrisiko kommt. Dies konnte ebenfalls in der Literatur gezeigt werden (Steinbrück et al. 2020). Zusätzlich weist das Modell Patienten ohne Pflegegrad eine geringere Wahrscheinlichkeit für eine Revisionsoperation zu. Dies lässt sich mit der Beobachtung aus der Literatur erklären, dass Patienten mit mehreren Begleiterkrankungen eine höhere Wahrscheinlichkeit für eine Revisionsoperation zeigen. Häufig erhalten Patienten aufgrund ihrer Begleiterkrankungen einen Pflegegrad (Bundesministerium für Gesundheit 2021). Wie in den Ergebnissen gezeigt werden konnte, hängt der Einsatz des am häufigsten genutzten Prothesentyps, der zementierten Totalendoprothese (Grimberg et al. 2020), mit einem verringerten Risiko für eine Revision zusammen.

Diese Erkenntnisse über Risikofaktoren könnten aktiv zur Verbesserung der Versorgung genutzt werden. Eine Möglichkeit stellt hier die Nutzung des oben beschriebenen KI-Modells zur Identifikation von Risikopatienten dar: Krankenkassen haben die Möglichkeit, Daten mithilfe von Maschinellem Lernen auszuwerten und ausgewählten Versicherten ein individuelles Leistungsangebot anzubieten, um so die Versorgungsqualität zu steigern. Dies kann in Form von Einsteuerung in Einrichtungen mit spezieller Expertise, aber auch durch risikoreduzierende Programme wie beispielsweise Ernährungcoachings oder Sportprogramme stattfinden. Zusätzlich können dem Versicherten Apps angeboten werden, die gefährdete Patienten auf ihrem Behandlungspfad begleiten und unterstützen (siehe auch den Beitrag zu „Auswirkungen von Mobile-Apps auf das postoperative pflegerische Schmerzmanagement von Patient:innen mit Hüft- oder Knie-Endoprothese von Klösch et al. in dieser Publikation). Patienten werden so vor OP-Einwilligung über ihr individuelles Risiko informiert und können auf dieser Basis eine Therapieentscheidung treffen. Auch nach der Operation werden Patienten mit Risiko für eine Revision eng beobachtet: Durch gezielte Aufklärung, gezielte Physiotherapie und enge Beobachtung werden eine Verschlechterung des Zustands und Revisionen verhindert beziehungsweise rechtzeitig erkannt.

Das Beispiel der Knie-TEP-Revisionen zeigt, dass Erkenntnisse aus Routinedaten der Krankenkassen sowohl für die Patientenversorgung als auch für die Beantwortung von Forschungsfragen hilfreich sind.

Gerade durch das Vorliegen von strukturierten Routinedaten lässt sich der hier beschriebene Ansatz leicht skalieren und auf weitere medizinische Anwendungsgebiete übertragen. So könnten ohne aufwändige Datenerhebung beispielsweise auch in den Bereichen Herz-Kreislauf psychiatrische oder neurologische Risikofaktoren entlang des Patientenpfades identifiziert und zur personalisierten Patientenversorgung und damit einer ziel- beziehungsweise qualitätsorientierten Versorgungssteuerung genutzt werden.

Literatur

- BCG German Hospital Database unter Nutzung der Qualitätsberichte der Krankenhäuser nach § 137 Abs. 3 Satz 1 Nr. 4 SGB V des Gemeinsamen Bundesausschusses.
- Bleß, H. H. und Kip, M. (2017). Weißbuch Gelenkersatz. Versorgungssituation endoprothetischer Hüft- und Knieoperationen in Deutschland. Berlin.
- Buecking, B., Bliemel, C. und Ruchholtz, S. (2013). Periprothetische Femurfrakturen – Inzidenz, Risikofaktoren, Klassifikation und Therapiestrategien. In: OUP 05/2013 2 (5). Online unter: <https://www.online-oup.de/article/periprothetische-femurfrakturen-inzidenz-risikofaktoren-klassifikation-und-therapiestrategien/uebersichtsarbeiten/y/m/249> (Download am 26. Mai 2021).
- Bundesministerium für Gesundheit (2021). Online-Ratgeber Pflege. Online unter: <https://www.bundesgesundheitsministerium.de/pflegegrade.html> (Download am 26. Mai 2021).
- Butler, A. R., Rosenzweig, S., Myers, L. und Barrack, R. L. (2011). The Frank Stinchfield Award: the impact of socioeconomic factors on outcome after THA: a prospective, randomized study. In: *Clinical orthopaedics and related research* 469 (2). S. 339–347. doi: 10.1007/s11999-010-1519-x (Download am 26. Mai 2021).
- Chen, T. und Guestrin, C. (2016). XGBoost: A scalable tree boosting system. In: *Proceedings of the 22nd ACM SIGKDD Conference on Knowledge Discovery and Data Mining*. S. 785–794.
- Destatis – Statistisches Bundesamt (2019). Die 20 häufigsten Operationen insgesamt (OPS5). Vollstationär behandelte Patientinnen und Patienten in Krankenhäusern 2019. Online unter: <https://www.destatis.de/DE/Themen/Gesellschaft-Umwelt/Gesundheit/Krankenhaeuser/Tabellen/drg-operationen-insgesamt.html> (Download am 26. Mai 2021).
- Fath, R. (2018). Ein anspruchsvoller Gelenkersatz. In: *Deutsches Ärzteblatt* 2018. 115 (8). A-332 / B-284 / C-284. Online unter: <https://www.aerzteblatt.de/archiv/196421/Knie-Totalendoprothesen-Ein-anspruchsvoller-Gelenkersatz> (Download am 26. Mai 2021).
- Fawcett, T. (2001). Using rule sets to maximize ROC performance. In: *Proceedings of the IEEE International Conference on Data Mining (ICDM-2001)*. S. 131–138.
- Grimberg, A., Jansson, V., Lützner, J., Melsheimer, O., Morlock, M. und Steinbrück, A. (2020). Jahresbericht 2020 Endoprothesenregister Deutschland (EPRD). doi: 10.36186/reportepd022020 (Download am 26. Mai 2021).

- Gunaratne, R., Pratt, D. N., Banda, J., Fick, D. P., Khan, R. J. K. und Robertson, B. W. (2017). Patient Dissatisfaction Following Total Knee Arthroplasty: A Systematic Review of the Literature. In: *The Journal of Arthroplasty*. 32 (12). S. 3854–3860. doi: 10.1016/j.arth.2017.07.021 (Download am 26. Mai 2021).
- Hosmer, D. W. und Lemeshow, S. (2000). *Applied Logistic Regression*, second edition, Chapter 5, New York. S. 160–164.
- John, G. H., Kohavi, R. und Pfleger K. (1994). Irrelevant features and the subset selection problem. In: *Proceedings of ICML-94, 11th International Conference on Machine Learning*. S. 121–129.
- Lambertz, O., Yagdiran, C., Wallscheid, A., Eysel, F. und Jung, N. (2017). Periprothetische Infektionen beim Gelenkersatz. In: *Deutsches Ärzteblatt* 114. S. 347–53. doi: 10.3238/arztebl.2017.0347 (Download am 10. Juni 2021).
- Lundberg, S. M. und Lee, S. (2017). A Unified Approach to Interpreting Model Predictions. In: *Advances in Neural Information Processing Systems*, 30. S. 4765–4774.
- Mitchell, T. W. (1997). *Machine Learning*. New York.
- Movahedi, A., und Derrible, S. (2020). Interrelated Patterns of Electricity, Gas, and Water Consumption in Large-Scale Buildings. doi: 10.31224/osf.io/ahn3e (Download am 26. Mai 2021).
- Reichel, F., Innmann, M., Gotterbarm, T., Schiltenwolf, M. und Merle, C. (2019). Prädiktoren für persistierende Schmerzen und Unzufriedenheit nach Kniegelenksendoprothese. In: *Schmerz* 33. S. 185–190. doi: 10.1007/s00482-019-0359-1 (Download am 26. Mai 2021).
- Ribeiro, M. T., Singh, S. und Guestrin, C. (2016). ‚Why Should I Trust You?‘: Explaining the Predictions of Any Classifier. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. S. 1135–1144. doi: 10.1145/2939672.2939778 (Download am 26. Mai 2021).
- Steinbrück, A., Grimberg, A., Melsheimer, O. und Jansson, V. (2020). Einfluss der institutionellen Erfahrung auf die Ergebnisse in Hüft- und Knie totalendoprothetik. In: *Orthopäde* 49. S. 808–814. doi: 10.1007/s00132-020-03963-z (Download am 26. Mai 2021).