

LeiVMed: Ein medizinisches Informationssystem für mehr Transparenz im Gesundheitswesen und zur Nutzung des Potenzials von Methoden des maschinellen Lernens

Julia Vetter, Bioinformatics Research Group, University of Applied Sciences Upper Austria, Hagenberg, Austria

Marina Strobl, Bioinformatics Research Group, University of Applied Sciences Upper Austria, Hagenberg, Austria

Teresa Hochstrasser, Process Management and Business Intelligence, University of Applied Sciences Upper Austria, Steyr, Austria

Judith Guttmann, Process Management and Business Intelligence, University of Applied Sciences Upper Austria, Steyr, Austria

Louise Buur, Bioinformatics Research Group, University of Applied Sciences Upper Austria, Hagenberg, Austria

Tilman Königswieser, Oberösterreichische Gesundheitsholding, Salzkammergut Klinikum, Gmunden, Austria

Gerhard Halmerbauer, Process Management and Business Intelligence, University of Applied Sciences Upper Austria, Steyr, Austria

Stephan Winkler, Bioinformatics Research Group, University of Applied Sciences Upper Austria, Hagenberg, Austria

Abstract: Fügen Sie hier Ihr Abstract ein (*max. 1000 Zeichen inkl. Leereichen*)

Die effiziente Nutzung klinischer Daten ist entscheidend für Prozessoptimierung und Qualitätssicherung im Gesundheitswesen. Seit 2015 entwickelt die FH Oberösterreich gemeinsam mit der Oberösterreichischen Gesundheitsholding (OÖG) die Plattform LeiVMed (Leistungsvergleich Medizin) zur strukturierten Erfassung, Überwachung und Analyse von Daten von Patient*innen. Der hier verwendete Datensatz enthält über 200.000 chirurgische Fälle, davon über 15.000 mit detaillierten Angaben zu Risikofaktoren und Komplikationen. Die Plattform ermöglicht Benchmarking, Transparenz und Ressourcenüberwachung. KI-basierte Modelle unterstützen u.a. Komplikationserkennung, Vorhersage der Verweildauer und patientenzentrierte Risikobewertung. Dabei wird der Multi-Model-Ensemble-Ansatz zur Unterstützung der Datenerhebung verwendet, um Fälle mit Komplikation(en) zu identifizieren, und eine Vorhersage der Aufenthaltsdauer erzielt eine Genauigkeit von 69 % mit hohem Potenzial für verbessertes Bettenmanagement.

Keywords: Gesundheitsdatenverarbeitung, Informationssystem, Data Science, Machine Learning

1. EINLEITUNG

Die effiziente Nutzung klinischer Daten zur Prozessoptimierung und Qualitätssicherung ist eine zentrale Herausforderung im Gesundheitswesen. Trotz großer Datenmengen fehlt oft eine strukturierte Analyse, die eine Vergleichbarkeit zwischen Krankenhäusern und Transparenz gewährleisten. Es besteht daher Bedarf an Systemen, die Daten nicht nur sammeln, sondern auch für Benchmarking und Entscheidungsunterstützung nutzbar machen.

Daher entwickeln seit 2015 die Fachhochschule Oberösterreich, Campus Hagenberg und Campus Steyr, gemeinsam mit der Oberösterreichischen Gesundheitsholding (OÖG) die Plattform Leistungsvergleich Medizin (LeiVMed) zur Erfassung, Überwachung und Analyse von Daten von Patient*innen. Derzeit werden Daten aus neun oberösterreichischen Krankenhäusern erhoben und systematisch strukturiert, um klinische Prozesse und die Qualitätssicherung zu unterstützen (Abbildung 1). Das LeiVMed-System liefert dadurch wertvolle Einblicke in Krankenhausprozesse und ermöglicht Fachkräften im Gesundheitswesen eine verbesserte Vergleichbarkeit, Kostenreduktion und Patientenversorgung.




Abbildung 1: Schematische Darstellung des LeiVMed-Systems und des Datenaufbereitungs- und Bereitstellungsprozess vom Beginn mit dem Erhalt der Daten der Krankenhäuser über die Strukturierung, Qualitätskontrolle und Mapping bis zur Bereitstellung der Daten für die Nutzer*innen und Data Science-Analysen.

2. MATERIAL UND METHODEN

Derzeit umfasst der monatlich aktualisierte Datensatz über 200.000 chirurgische Fälle. Davon stehen für über 15.000 Fälle zusätzliche detaillierte Informationen zu Risikofaktoren und Komplikationen zur Verfügung, welche zusätzlich erhoben werden. Für sieben medizinische Fallkategorien (Hernie, Cholezystektomie, Prostataktomie, Hüftendoprothetik, Thyreoidektomie, Kolektomie und Rektum-OP) mit stehen bereits umfassende Informationen zur Verfügung, welche in weiterer Folge auch als Datenbasis für KI-basierte Analysen dienen. KI-basierte Strategien zur Prozessoptimierung und Reduzierung des (Personal-) Aufwands umfassen derzeit unter anderem (1) die Erkennung von Komplikationen nach Operationen (Strobl, 2023), (2) die Vorhersage der Aufenthaltsdauer (Vetter, 2025) und (3) das Trainieren von Modellen für patient*innenspezifische Risikobewertung.

2.1. Datenaufbereitung und -bereitstellung

Monatlich werden Daten aus neun oberösterreichischen Krankenhäusern geliefert und in das LeiVMed-System eingespielt. Im Zuge der Datenübernahme erfolgt eine systematische Strukturierung, welche eine Abbildung auf ein einheitliches Zieldatenmodell sowie ein Mapping der Parameter und Konzepte der einzelnen beteiligten Institutionen beinhaltet. Zudem werden Qualitätsprüfungen (u.a. Vollständigkeits-, Plausibilitäts- und Konsistenzchecks) durchgeführt. Anschließend werden die Datensätze gemäß den geltenden Datenschutzerfordernungen pseudonymisiert und für nachgelagerte Verarbeitungsschritte vorbereitet: Bereitstellung für Benchmarking und Leistungsmonitoring, Data-Science-Analysen und weiterführende Auswertungen.

2.2. Multi-Model-Ensemble

Für die Modellierungen wird der Multi-Model-Ensemble-Ansatz (MME) verwendet, wobei verschiedene Algorithmen des maschinellen Lernens (ML) wie Random Forests (RF) (Breiman, 2001), genetische Programmierung (GP) (Koza, 1992) oder neuronale Netze (NN) (Goodfellow, 2016) kombiniert werden (Abbildung 2). Dieser Ansatz verfügt über das Potenzial robustere und genauere Vorhersagen zu erzielen. Als Datenbasis dienen hierbei die erhaltenen Daten der kooperierenden Krankenhäuser. Bei der *Komplikationserkennung* alle prä- und postoperativen Informationen der sieben genannten medizinischen Fallkategorien; bei der *Prädiktion der Verweildauer* werden verschiedene Feature-Sets (minimaler Basisdatensatz und prä-operative Informationen bis zum OP-Tag) für 21 verschiedene operative medizinische Fallkategorien verwendet; bei der *Risikobewertung* werden demographische Daten, ASA-Wert, Risikofaktoren (Rauchen, Alkohol, Diabetes, Dyspnoe) sowie OP-spezifische Risikofaktoren für drei medizinische Fallkategorien (Hernie, Cholezystektomie und Hüftendoprothetik). Die Risikobewertung wurde inspiriert vom National Surgical Quality Improvement Program (NSQIP) Risk Calculator, der vom American College of Surgeons (ACS) entwickelt wurde (Bilimoria et al., 2013).




Abbildung 2: Multi-Model-Ensemble (MME) mit Eingangsdaten, welche zur Modellierung mit unterschiedlichen Algorithmen des maschinellen Lernens verwendet werden. Jedes Modell liefert eine Klassenzuordnung, welche anschließend zur Berechnung der finalen Klassenzuordnung mittels Mehrheitsabstimmung oder anderen Methoden verwendet werden. (Strobl, 2023)

In allen bisherigen KI-basierten Ansätzen werden verschiedene ML-Algorithmen verwendet, um Modelle zu trainieren, welche in weiterer Folge ein Klassifikationsergebnis liefern und als Grundlage für das MME dienen. Es wird dabei eine 10- bzw. 5-fach Cross-Validation durchgeführt. Für die finale Klassenzuordnung wurden unterschiedliche Strategien entwickelt:

- *Komplikationserkennung*: es wird die minimale Anzahl an Modellen bestimmt, welche einen Fall als Komplikation klassifizieren müssen, sodass die Falsch-Negativ-Rate bei ~20 % liegt. Dadurch soll sichergestellt werden, dass ca. 80 % der komplikativen Fälle erkannt werden. Dies wurde aufgrund der hohen Relevanz der Komplikationserkennung und -übersicht für die Leiter*innen von klinischen Organisationseinheiten sowie das Krankenhausmanagement festgelegt.
- *Prädiktion der Verweildauer*: die durchschnittliche prädizierte Verweildauer der einzelnen Modelle wird für die Klassifikation verwendet, wobei acht Klassen definiert wurden: 1-6 Tage, 1 Woche bis 1 Monat und > 1 Monat.
- *Risikobewertung*: Anteil der Modelle, welche einen Fall als Komplikation einstufen wird zur Risikobewertung verwendet, wobei nur die leistungsstärksten Modelle mit einer hohen Genauigkeit und geringen Falsch-Negativ-Rate ins MME integriert werden.

3. ERGEBNISSE

Alle Daten und berechneten Kennzahlen werden auf der LeiVMed-Webplattform für die teilnehmenden Abteilungen bereitgestellt, um einen transparenten Überblick über Krankenhausprozesse zu bieten. Autorisierte Nutzer*innen können somit innerhalb ihrer jeweiligen Organisationseinheiten Leistungskennzahlen überwachen und einsehen. Zusätzlich werden regelmäßige Risikoadjustierungsanalysen durchgeführt, um die Vergleichbarkeit zu gewährleisten und Schlüsselparameter für kosteneffiziente(re) Krankenhausleistungen zu identifizieren.

3.1. Data-Science-Analysen

Die Verwendung des MME-Ansatzes ermöglicht es robustere und bessere Ergebnisse zu erzielen. Bei der retrospektiven *Komplikationserkennung* konnte dadurch die automatisierte Ermittlung der minimalen Anzahl an Modellen im MME, welche einen Fall als komplikativ einstufen, gewährleistet werden. Dies lieferte beim Vergleich des MME mit den einzelnen Modellen zudem bessere Ergebnisse. Somit konnte eine Genauigkeit von 83,79 % erreicht und gezeigt werden, dass die Anzahl der zu erhebenden Fälle deutlich reduziert werden kann, um ca. 80 % der Fälle mit Komplikationen zu identifizieren (FNR ~20 %).

Die *Vorhersagen zur Aufenthaltsdauer* (Abbildung 3) für Patient*innen aus 21 verschiedenen medizinischen Fallkategorien erreichen eine Genauigkeit von 69,34 % ($\pm$ ein Tag: 91,82 %). Hierbei wurden für jede medizinische Fallkategorie einzelne Modelle trainiert. Es konnte beobachtet werden, dass die Modellierung für manche OP-Arten (z.B. Blinddarm, Kaiserschnitt) komplexer ist als für andere (z.B. Augen-OP). Komplexere OP-Arten zeigen im neben einer größeren Variabilität der Verweildauer auch einen höheren Anteil an akuten Fällen, wodurch die Modellierung zusätzlich erschwert wird. Des Weiteren wurden für Entlassungen innerhalb der ersten fünf Tage

nach einer OP bessere ROC-AUC-Werte (1 Tag: 0,92) erreicht werden, als für Entlassungen nach dem fünften postoperativen Tag (Tag 6: 0,56).




Abbildung 3: (A) Vorhersage der Verweildauer; dafür wurden acht Klassen definiert (1-6 Tage, 1 Woche bis 1 Monat und > 1 Monat). (B) Ergebnisse der Vorhersage der Verweildauer anhand der prä-operativen Informationen mit korrekter Klassifikation (blau), +/- 1 Tag (hellblau) und falscher Klassifikation (rot). Genauigkeit: 69,34 % (+/- 1 Tag: 91,82 %).

Für die *Risikobewertung* wurden initial zehn verschiedene ML-Algorithmen verwendet und Modelle für drei medizinische Fallkategorien trainiert. Durch die Schiefe der Datensätze wurde besonderer Wert auf eine sensitive und zuverlässige Identifikation von Komplikationen gelegt. Die besten Klassifikationsmodelle für das MME wurden für die Cholezystektomie erzielt (Validierungsgenauigkeit: 0,67; FNR: 0,33), wobei die Ergebnisse folgender Modelle ins MME einbezogen wurden: logistische Regression, Random Forest, CatBoost, Light Gradient Boosting Machine, Ridge Regression, Quadratischer Diskriminanzanalyse, Support-Vector-Maschinen und neuronale Netze. Der ROC-AUC-Wert beträgt für die Cholezystektomie 0,67, für Hernien konnte ein ROC-AUC-Wert von 0,59 mit dem MME-Ansatz erzielt werden und ein Wert von 0,63 für Hüftendoprothetik.

4. DISKUSSION

Zusammenfassend bietet die LeiVMed-Plattform wertvolle Einblicke in Krankenhausprozesse und ermöglicht ein Benchmarking von oberösterreichischen Krankenhäusern. Diese Transparenz und Vergleichbarkeit birgt großes Potenzial für die Entwicklung von Strategien zur Verbesserung von Kernprozessen sowie der Patient*innenversorgung.

Durch die Entwicklung von KI-basierten Systemen können zusätzliche Kenntnisse gewonnen werden und das Potenzial dieses Datensatzes genutzt werden. Im Rahmen der Modellierung konnte gezeigt werden, dass eine sorgfältige Modell- und Merkmalsauswahl die Komplikationserkennung deutlich verbessern kann und so die Transparenz im Krankenhaus erhöht. Die MME-Methode reduziert die Anzahl übersehener Komplikationen bei der retrospektiven Komplikationserkennung auf 10–20 % und ermöglicht realistische Vorhersagen der Aufenthaltsdauer, wodurch potenziell das Operationsrisiko gesenkt, Managementkosten reduziert und eine bessere Patientenversorgung unterstützt werden kann. Eine akkurate Verweildauerprädiktion kann zudem zu verbessertem Bettenmanagement sowie besserer OP-Planung und Nachsorge (z.B. Physiotherapie) führen. Dies wird zudem durch die KI-basierte Risikobewertung adressiert.

Literaturverzeichnis

Bilimoria, K. Y., Liu, Y., Paruch, J. L., Zhou, L., Kmiecik, T. E., Ko, C. Y., & Cohen, M. E. (2013). Development and evaluation of the universal ACS NSQIP surgical risk calculator: a decision aid and informed consent tool for patients and surgeons. *Journal of the American College of Surgeons*, 217(5), 833-842.

Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5–32. <https://doi.org/10.1023/a:1010933404324>

Goodfellow, I., Bengio, Y., Courville, A., & Bengio, Y. (2016). *Deep learning* (Vol. 1, No. 2, pp. 1-800). Cambridge: MIT press.

Koza, J. R. (1992). Genetic Programming: On the Programming of Computers by Means of Natural Selection. In *Medical Entomology and Zoology*. <http://ci.nii.ac.jp/ncid/BA1926018X>

Strobl, M. T., Vetter, J., Halmerbauer, G., Königswieser, T., & Winkler, S. (2023). Using Explainable Artificial Intelligence for Data Based Detection of Complications in Records of Patient Treatments. In R. Moreno-Díaz, F. Pichler, & A. Quesada-Arencia (Eds.), *Computer Aided Systems Theory – EUROCAST 2022 - 18th International Conference, Revised Selected Papers: 18th International Conference, Las Palmas de Gran Canaria, Spain, February 20–25, 2022, Revised Selected Papers* (pp. 173-180). (Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics); Vol. 13789 LNCS). Springer. https://doi.org/10.1007/978-3-031-25312-6_20

Vetter, J., Strobl, M. T., Buur, L. M., Königswieser, T., Halmerbauer, G., & Winkler, S. (2025). Data-Based Prediction of the Duration of the Postoperative Stay of Patients. In A. Quesada-Arencia, M. Affenzeller, & R. Moreno-Díaz (Eds.), *Computer Aided Systems Theory – EUROCAST 2024 - 19th International Conference, 2024, Revised Selected Papers* (pp. 335-344). (Lecture Notes in Computer Science; Vol. 15173 LNCS). Springer. https://doi.org/10.1007/978-3-031-82957-4_28