



# KÜNSTLICHE INTELLIGENZ IN DER MEDIZIN

Sonderdruck: Digitale Assistenz zur Entscheidungsunterstützung  
in der Notaufnahme mit Hilfe von erklärbaren KI-Verfahren (ML)



<b>Editorial</b>	79
<b>Vorschau</b>	79
<b>Schwerpunkt</b>	
Künstliche Intelligenz in der Medizininformatik-Initiative _ Spreckelsen _Boeker _Schuppert _Semler	80
Ein wissensbasiertes, interoperables Entscheidungsunterstützungssystem für die pädiatrische Intensivmedizin _Wulff _Bode _Mast	85
Regulatorische Anforderungen an Verfahren des maschinellen Lernens bei Medizinprodukten _Johner _Prütting	88
Digitale Assistenzen zur Entscheidungsunterstützung in der Notaufnahme mit Hilfe von erklärbaren KI-Verfahren (ML) _Ritter _Rühlicke _Blaschke _et al.	92
Bedeutung von AI-Literacy bei medizinischen Anwender:innen _Mosch _Ritter	97
Künstliche Intelligenz zur Erkennung von Zustandsänderungen in hochdimensionalen Patientendaten _Kapsecker _Nissen _Weinhuber_Jonas	100
<b>Ausbildung</b>	
Sensorbasierte Klassifikation von Tanzfiguren mittels maschineller Lernverfahren _Gratius _Cissée _Stach von Goltzheim _et al.	102
<b>BVMI &amp; DVMD</b>	
Gedenksymposium zu Ehren von Dr. Carl Dujat	104
Preisverleihung des Berufsverbandes Medizinischer Informatiker e.V. (BVMI) zu Ehren von Dr. Carl Dujat	104
Köpfe im DVMD: Bärbel Wellmann	105
Der DVMD lädt zu seiner 53. Mitgliederversammlung ein	105
<b>Impressum</b>	106

## Liebe Leserinnen und Leser,

**K**eine Frage: Künstliche Intelligenz (KI) zieht in den letzten Jahren öffentliche Aufmerksamkeit fast magnetisch an. Sie gilt als strategisch wichtiges Zukunftsfeld und aktiviert damit hohe Fördermittel. An KI in der Medizin knüpfen sich besonders hohe, vielleicht überhöhte Erwartungen. Anders als in früheren Phasen der KI-Euphorie sind aber aktuelle KI-Ansätze im Gesundheitsbereich tatsächlich praxis-, routine- und konkurrenzfähig: Die amerikanische Zulassungsbehörde FDA lässt seit mehreren Jahren im Monatsrhythmus neue KI-gestützte Medizinprodukte zu.

KI in der Medizin steht vor besonderen Herausforderungen: Die Anpassung von KI-Verfahren an die spezifischen Erfordernisse und Anwendungsbedingungen der Medizin ist methodisch herausfordernd. Beispielsweise macht die Forderung nach nachvollziehbarer Datenverarbeitung innovative Ansätze zur erklärbaren KI (Explainable AI - XAI) nötig. Am Beispiel einer KI-Anwendung in der Notfallaufnahme zeigt der Heftbeitrag von Ritter et al. einen solchen Ansatz.

Gerade maschinelle Lernverfahren haben spektakuläre Erfolge der KI erzielt. Strenge regulatorische Vorgaben erschweren ihren Einsatz in der Medizin. Der Beitrag von Johner et al. gibt hier einen präzisen, orientierenden Überblick und macht auf akute Problemfelder einer überbordenden Regulierung insbesondere auf Ebene der EU aufmerksam.

Der Einsatz von KI gerade im klinischen Umfeld führt zu besonderen praktischen Herausforderungen: Hier stehen Fragen der Daten- und Funktionsintegration von KI-Anwendung, ihre Gebrauchstauglichkeit oder ihre Verfügbarkeit und Zuverlässigkeit im Vordergrund. Ein Beispiel dafür ist die oft unzureichende Datenqualität von Versorgungsdaten bei ihrer Nutzung im KI-Kontext. Mit einer Anwendung aus der pädiatrischen Intensivmedizin stellen Wolff et al. ein Entscheidungsunterstützungssystem mit Augenmerk auf dessen Interoperabilität vor.

Die Datenflut aus (mobilen) Sensoren überfordert zunehmend die menschliche Aufmerksamkeit und Aufnahmefähigkeit. KI kann hier bei der Datensammenfassung und -bewertung helfen. Besonders chancenreich ist das im Bereich mobiler Gesundheits-

anwendungen (mHealth), der Artikel von Kapsecker et al. zeigt ein Beispiel.

Die genannten Herausforderungen zeigen klar: Es ist notwendig, KI-Komponenten systematisch zu entwickeln. Erfolgreiche und sichere KI in der Medizin setzt voraus, dass entwickler-, nutzer- und betreiberseitig KI-spezifische Kenntnisse und Fertigkeiten vorhanden sind. Gerade auch Angehörige der Gesundheitsberufe benötigen Orientierung und gezielte methodisch-technische KI-Einführungen, damit der KI-Einsatz tatsächlich ein Nutzenpotenzial entfaltet und nicht im Gegenteil womöglich schadet. Der Artikel von Mosch & Ritter gibt einen beispielhaften Einblick in Angebote zur gezielten Entwicklung von KI-Kompetenzen.

In der Vergangenheit fehlten weitgehend fachliche, technische und organisatorische Voraussetzungen, um die Herausforderungen des KI-Einsatzes in der Medizin bewältigen zu können. Die Medizininformatik-Initiative (MII) stellt solche Voraussetzungen auf ganz verschiedenen Ebenen her. Der erste Artikel des Themenhefts beschreibt daher den wichtigen Beitrag, den die MII zur Etablierung von KI in der Medizin schon jetzt leistet und noch leisten wird.

Immer klarer zeichnet sich ab: Für den Erfolg von KI in der Medizin ist entscheidend, dass die Zusammenarbeit und Verständigung zwischen sehr unterschiedlichen Fachdisziplinen und Berufsgruppen funktioniert. Der gezielte Aufbau multiprofessioneller Teams ist eine Aufgabe, deren Bedeutung sowohl im Bereich der Entwicklung medizinischer KI-Anwendungen als auch für ihren sicheren und erfolgreichen Einsatz gar nicht zu überschätzen ist.

Medizinische Dokumentation, Medizininformatik und klinisches Informationsmanagement sammeln seit Jahren Erfahrung im Schnittbereich zwischen Gesundheitsberufen und Informationstechnik. Diese Erfahrung kann und sollte gerade für eine erfolgreiche Anwendung von KI im Gesundheitswesen fruchtbar gemacht werden. Wir hoffen, Ihnen, liebe Leserinnen und Lesern, mit diesem Heft Impulse für einen sinnvollen Einsatz von KI in der Medizin mitgeben zu können.

*Cord Spreckelsen und Oliver J. Bott*



*Prof. Dr.-Ing. Oliver J. Bott  
Hochschule Hannover  
oliver.bott@hs-hannover.de*



*Prof. Dr. Cord Spreckelsen  
Institut für Med Statistik,  
Informatik und Daten-  
wissenschaften, Universi-  
tätsklinikum Jena  
Cord.Spreckelsen@med.  
uni-jena.de*

### Die nächsten Themenhefte

mdi 4\_2022

**Tumordokumentation und klinische Register**  
Hartz, Stein

mdi 1\_2023

**Forschung und deren Folgenabschätzung**  
Goldschmidt, Händel

mdi 2\_2023

**Datenmanagement in Gesundheitsversorgung  
und medizinischer Forschung**

Ose, Katzensteiner, Händel

mdi 3\_2023

**KHZG, Corona und MII – Impulsgeber für die  
Digitalisierung im Gesundheitswesen?**

Bott, Schmücker



Vorschau

*Sie haben zu den genann-  
ten Themenheften eine  
Artikel-Idee? Bitte melden  
Sie sich bei Markus Stein:  
mstein@rzv.de*



**Dr. Zully Ritter<sup>1</sup>**  
zully.ritter@med.uni-  
goettingen.de

## Digitale Assistenz zur Entscheidungsunterstützung in der Notaufnahme mit Hilfe von erklärbaren KI-Verfahren (ML)

- In der Notfallversorgung ist die primäre Diagnosestellung von essentieller Bedeutung für das Patienten-Outcome und stellt aufgrund des Zeitdrucks insbesondere bei vital bedrohlichen Notfällen eine besondere Herausforderung für das ärztliche Personal dar.
- Es ist daher sinnvoll, effektive und effiziente klinische Entscheidungsunterstützungssysteme in diesem Setting zu implementieren.
- Für die Erstellung maschineller Lernmodelle als Teil eines klinischen Entscheidungsunterstützungssystems für die diagnostische Vorhersage in Notaufnahmen können die Notfallbehandlungsdaten des AKTIN-Notaufnahmeregisters genutzt werden.
- Der Aspekt der Erklärbarkeit von maschinellen Lernmodelle ist für die Anwendung, die Akzeptanz, Usability und Utility der Modelle im klinischen Umfeld wichtig.

In klinischen Versorgungsprozessen – zum Beispiel in der Notaufnahme – werden Entscheidungen getroffen, die den Genesungsprozess des Patienten maßgeblich beeinflussen. Im Rahmen dieser klinischen Entscheidungsunterstützung spielt die fortschreitende Digitalisierung im Gesundheitswesen eine immer wichtigere Rolle, da zunehmend relevante Informationen in Form von Behandlungsdaten zur Verfügung stehen. Während die Verfügbarkeit von Behandlungsinformationen für Ärzte und ihre Entscheidungsprozesse grundsätzlich positiv ist, stellt der Umgang mit der Datenmenge gerade in komplexen Behandlungsszenarien eine zunehmende Herausforderung dar [1]. Künstliche Intelligenz (KI) verspricht, mit dieser Vielzahl und Vielfalt an Daten und Informationen umgehen zu können. Während die Erwartungen an KI sehr hoch sind, zeigt sich im klinischen Kontext, dass diese Erwartungen aufgrund unzureichender oder unstrukturierter Daten, nicht verfügbarer Informationen oder mangelnder

Erklärbarkeit der vorgeschlagenen KI-Entscheidungen noch nicht ausreichend erfüllt werden. Dadurch fehlt es den Anwendern oft an Vertrauen in die Systeme.

Diese Herausforderungen wurden im Projekt ENSURE adressiert [2,3]. ENSURE: Entwicklung Smarter Notfall-Algorithmen durch Erklärbare KI-Verfahren wird vom Bundesministerium für Gesundheit gefördert (FKZ ZMVI1-2520DAT803) und hat zum Ziel, ein klinisches Entscheidungsunterstützungssystem (Clinical Decision Support System, CDSS) für die Notaufnahme zu entwickeln und zu evaluieren. Teil des Projekts ist die Integration erklärbarer KI-Ansätze in das Entscheidungssystem.

## Das Szenario der klinischen Notfallversorgung

Das Setting der Notfallversorgung in der Zentralen Notaufnahme der Krankenhäuser ist im Gegensatz zu anderen klinischen Versorgungsbereichen insbesondere dadurch charakterisiert, dass eine rasche, aber vor allem präzise Behandlung des Patienten insbesondere bei vital bedrohlichen Notfällen erfolgen muss. Grundvoraussetzung hierfür ist, dass der Diagnoseprozess möglichst akkurat und zeiteffizient durchlaufen wird. Insgesamt kann das Entscheidungsszenario im Setting der Notaufnahme als herausfordernd beschrieben werden. Hierbei spielen der Zeitdruck und die z.T. hohe Komplexität einzelner Notfälle eine große Rolle. Darüber hinaus werden in den Notaufnahmen häufig Rotationsassistent\*innen verschiedenster Fachdisziplinen zur Weiterbildung eingesetzt, die noch nicht über das erforderliche notfallmedizinische Fachwissen verfügen. Die Nutzung von nicht-evidenzbasierten Wissensquellen als Hilfsmittel stellt dabei ein potentielles Risiko dar [4], weshalb die Entwicklung von vertrauenswürdigen und digital verfügbaren Hilfsmitteln für die Notfallversorgung erstrebenswert ist. ENSURE wurde konzipiert, um eine strukturierte und evidenzbasierte Vorgehensweise in der Notfalldiagnostik zu implementieren und auf diese Weise die Qualität der Notfallversorgung zu verbessern.

## CDSS und ENSURE

Klinische Entscheidungsunterstützungssysteme (CDSS) sind komplexe IT-Systeme [5], welche Anwender, etwa Ärzte, Pflegekräfte oder Patienten, in ihrem Entscheidungsfindungsprozess im klinischen Kontext assistieren [6]. Die Vielfalt von klinischen Entscheidungen spiegelt sich in der Diversität der CDSS wider, sodass die Anwendungsfelder von einfachen Erinnerungs- und Alarmsystemen bis hin zu komplexen Diagnoseunterstützungssystemen (DDSS) reichen können. Die Komplexität von CDSS verlangt ein interdisziplinäres Team aus klinischen Domänenexpert\*innen, Data Scientist\*innen, Informatiker\*innen und vieler weiterer Professionen. Die

Beschaffenheit eines CDSS wird durch unterschiedliche Komponenten charakterisiert. Im Fokus dieses Artikels liegt die Anwendung von künstlicher Intelligenz, welche durch die Wissensbasis (Knowledge Base) und die Inferenz implementiert wird [7]. Im Projekt ENSURE kommt zum einen der KI-Ansatz »Expertensystem« (regelbasiertes System) und zum anderen »Machine Learning« zum Einsatz, um Notfallmediziner\*innen bei der Diagnosestellung zu unterstützen. Die dafür notwendigen Falldaten werden im Entscheidungsszenario in eine mobile Applikation per Tablet eingegeben, um daraus eine Empfehlung durch ENSURE berechnen zu lassen. Die Berechnung der Empfehlung erfolgt randomisiert entweder per Expertensystem oder durch Machine Learning. Mit dieser Arbeitsweise ist die Fragestellung verbunden, welcher der Ansätze die beste Performanz in der Versorgung leisten kann.

## Entwicklung einer diagnostischen Entscheidungsunterstützung (DDSS) für den Einsatz in der Notfallversorgung

Die Erprobung des DDSS ENSURE soll im Rahmen einer sonstigen klinischen Prüfung erfolgen. Für die prospektive Anwendung von ENSURE im klinischen Umfeld der Notaufnahme sind zwei Aspekte von übergeordneter Bedeutung: 1. Hochqualitative Daten und 2. die Erklärbarkeit der KI-Algorithmen. In den folgenden Abschnitten werden diese beiden Aspekte detailliert beschrieben.

## Auswahl der Wissensbasis für Expertensysteme und KI-Modelle

In ENSURE werden zwei unterschiedliche Ansätze für die Wissensbasis verwendet, um zum einen das »Expertensystem« (regelbasiertes System) und zum anderen das »Machine Learning« Modell mit entscheidungsrelevanten Informationen zu versorgen. Expertensysteme verwenden evidenzbasierte Wissensquellen, um eine Entscheidungslogik abzubilden. Bei maschinellen Lernmodellen werden Daten, im besten Fall Patientendaten, direkt aus den Produktivsystemen verwendet, um die Zielpopulation für die Entscheidungsfindung zu repräsentieren.

Die maßgebliche Wissensquelle für das Expertensystem von ENSURE ist das sog. SOP-Handbuch Interdisziplinäre Notaufnahme [8]: In diesem Handbuch sind für alle notfallmedizinischen Leitsymptome und Leitdiagnosen die standardisierten Vorgehensweisen in Notfalldiagnostik und -therapie auf der Basis der aktuell gültigen medizinischen Leitlinien und im Konsens mit den federführenden Fachgesellschaften dargestellt. Die Translation des SOP-Handbuchs in eine Regelrepräsentation für das Expertensystem erfolgt durch die enge Zusammenarbeit zwischen Notfallmediziner\*innen und IT-Experten.



*Stefan Rühlicke, M.Sc.<sup>1</sup>  
stefan.ruehlicke@med.uni-goettingen.de*



*Prof. Dr. Sabine Blaschke<sup>2</sup>  
sabine.blaschke@med.uni-goettingen.de*

*Prof. Dr. Tibor Kesztyüs<sup>1</sup>  
Kerstin Pischek-Koch<sup>1</sup>  
Stefanie Wache<sup>1</sup>  
Frank Schultze<sup>2</sup>  
Katrin Esslinger, B.A.<sup>2</sup>  
Michael Schmucker<sup>3</sup>  
Andreas Reiswich<sup>3</sup>  
Prof. Dr. Martin Haag<sup>3</sup>  
Wiebke Schirrmeyer<sup>4</sup>  
Prof. Dr. Dagmar Krefting<sup>1</sup>*

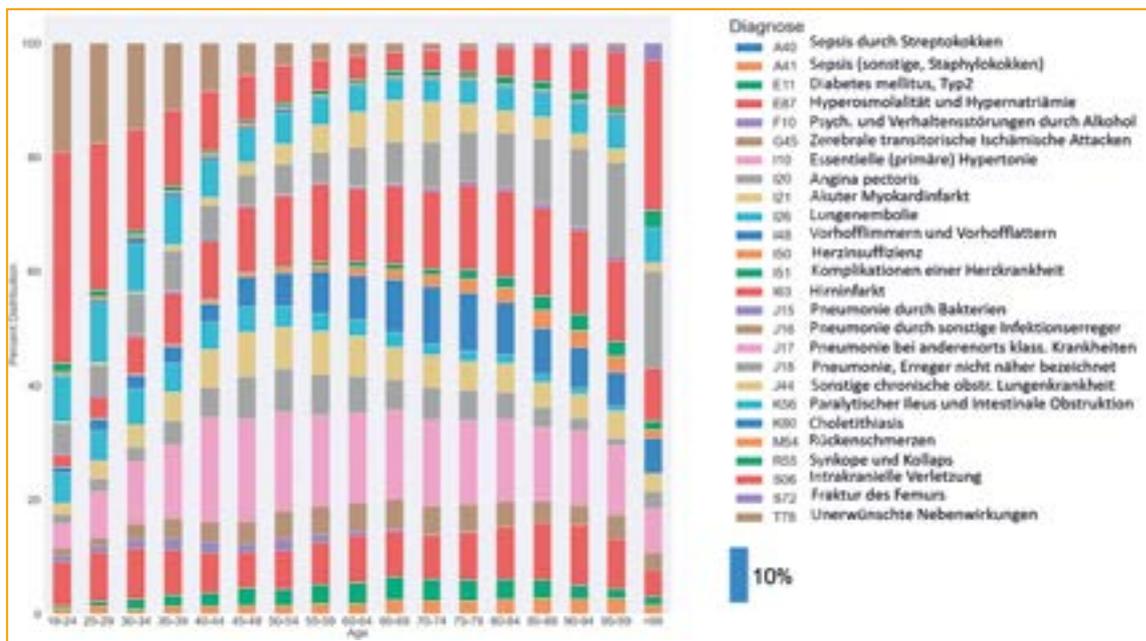
<sup>1</sup>) Institut für Medizinische Informatik, Universitätsmedizin Göttingen

<sup>2</sup>) Zentrale Notaufnahme, Universitätsmedizin Göttingen

<sup>3</sup>) GECKO-Institut, Hochschule Heilbronn

<sup>4</sup>) Klinik für Unfallchirurgie, AKTIN-Notaufnahmeregister Universitätsklinik Magdeburg

**Abb. 1**  
Analyse der häufigsten Notfall-Diagnosen in Prozent in Abhängigkeit vom Alter im AKTIN-Notaufnahmeregister-datensatz im Zeitraum 2017-2020 in n=13 teilnehmenden Kliniken



**Abb. 2**  
Normalisierte Mehrklassen-Konfusionsmatrix eines trainierten Random Forest Models zur Diagnoseklassifikation (ICD Codes in alphabetischer Reihenfolge sortiert).

Für das maschinelle Lernmodell von ENSURE werden zwei unterschiedliche Datenquellen einbezogen: Zum einen werden Falldaten von 2017 bis 2020 aus dem AKTIN-Notaufnahmeregister verwendet [9,10], welche von 13 angeschlossenen Notaufnahmen in Deutschland bereitgestellt wurden. Insgesamt liegen 51 Merkmale inklusive der abschließenden Fachabtei-

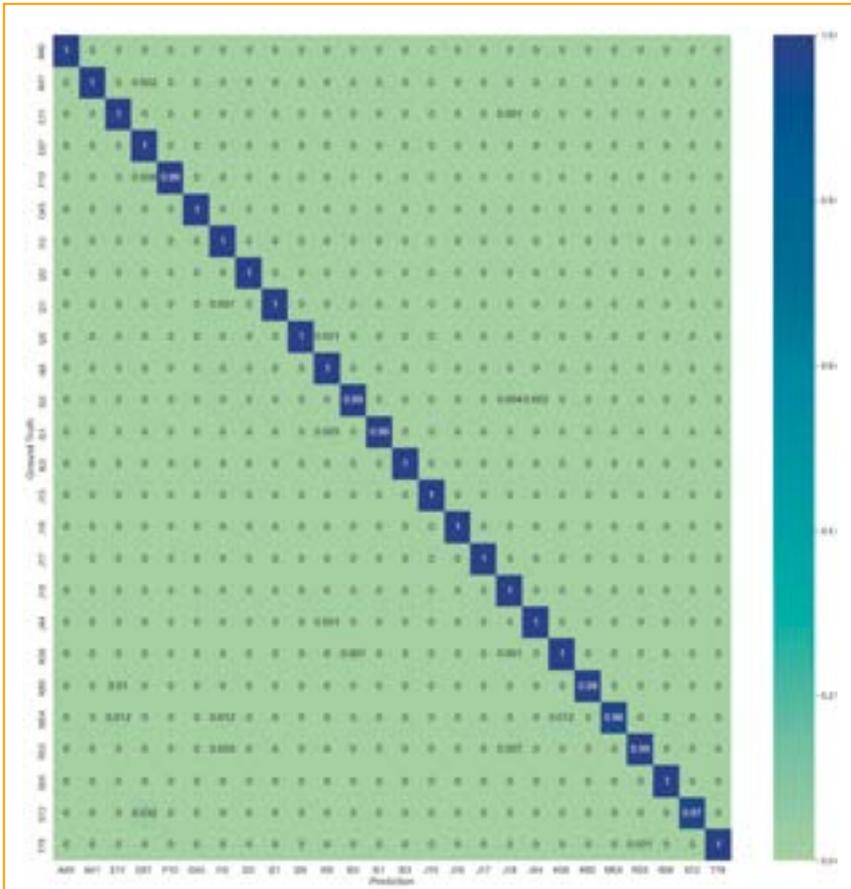
lungsd Diagnose von 137.152 Fällen als Zielvariablen in der Registerdatenbank vor. Abb. 1 zeigt beispielhaft die Verteilung der häufigsten Diagnosen (ICD Code) mit Bezug zum Alter der Patient\*innen. Aus der Grafik wird deutlich, dass bestimmte Diagnosen in Abhängigkeit vom Alter wahrscheinlicher werden, wohingegen andere Diagnosen relativ konstant bleiben. Beispielhaft ist der ICD-10 E87 (Hyperosmolarität und Hypermatriämie) nahezu konstant in allen Altersgruppen vertreten, wohingegen das Auftreten des ICD-10 I63 (Hirninfarkt) im Alter zunimmt und im Alter von 75-79 das Maximum von 15 % erreicht.

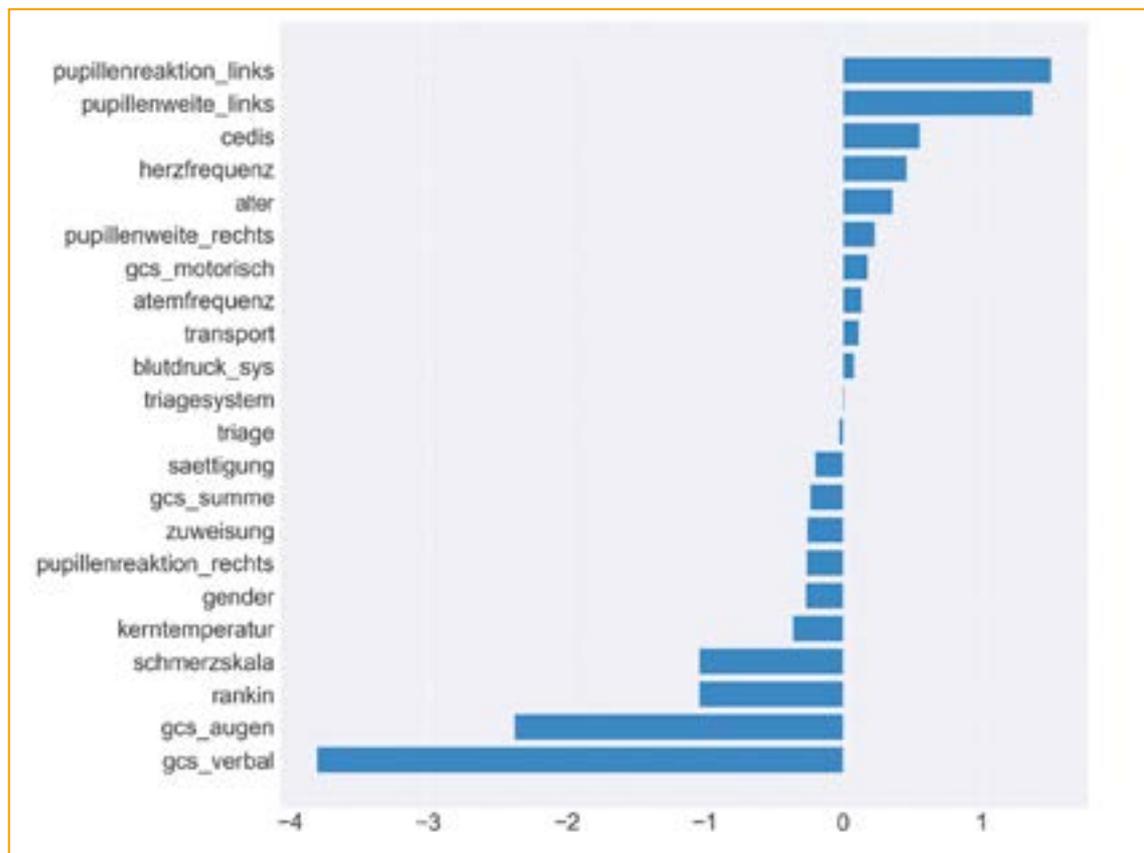
Als zweite Datenquelle werden Notfallbehandlungsdatensätze aus dem ZNA-Informationssystem der Universitätsmedizin Göttingen (UMG) in Verknüpfung mit den sog. §21-Daten verwendet, die im medizinischen Datenintegrationszentrum (MeDIC) der UMG zusammengeführt werden. Während das ZNA-Informationssystem die gesamten Notfallbehandlungsdaten liefert, wird der §21-Datensatz verwendet, um die abschließende Fachabteilungsdiagnose zu den jeweiligen Fällen einzubeziehen.

Mit der Nutzung der beiden beschriebenen Datenquellen sind die Ziele verbunden, einerseits das Risiko von möglichem Bias in den Trainingsdaten zu reduzieren und andererseits den Grad der Modellgeneralisierbarkeit zu erhöhen. Beide Aspekte limitieren häufig die Anwendbarkeit von KI-Modellen in der Praxis.

## Auswahl und Entwicklung der Machine Learning Modelle

Maschinelles Lernen (ML) als Verfahren eines ganzen Spektrums von unterschiedlichen Methoden der KI erlernt Muster in Datensätzen, um Klassifikations- und Prädiktionsprobleme zu lösen. Die im Projekt ENSURE





**Abb. 3**  
Diagnose-Klassifikationsergebnis eines Random Forest Models erklärt mit Shap [12] durch Darstellung der Merkmalsgewichtung

verwendeten Datensätze der Notfallbehandlung umfassen dabei unterschiedliche Parameter, so u.a. demographische Daten, Vitalparameter, Symptome sowie Diagnosen. Um diese Daten für das Training von ML-Modellen verwenden zu können, wurden zunächst die üblichen datenwissenschaftlichen Prozessschritte umgesetzt. Hierzu gehört, das Bereinigen der Daten, das Imputieren fehlender Daten und die Prüfung der Plausibilität etwa von physiologischen Werten auf Basis von Literatur und klinischer Erfahrung.

Während sich viele Studien mit Anwendung von ML-Modellen im Notaufnahmesetting auf die Unterscheidung von zwei Klassen beschränken, so etwa, ob eine Sepsis vorliegt (ja/nein), konzentriert sich ENSURE auf die Klassifizierung der 20 häufigsten Diagnosen in der klinischen Notfallmedizin. Teil des Entwicklungsprozesses ist die Erprobung mehrerer ML-Modelle und deren retrospektive Überprüfung anhand von Testdaten. Ziel dieser Labortesting ist es, das Modell mit der besten Performance zu identifizieren und dieses dann prospektiv neben dem Expertensystem (regelbasiertes System) in der sonstigen klinischen Prüfung nach MDR/MPDG (siehe hierzu den Artikel von Johner und Prütting in diesem Heft) zu erproben.

So wurden etwa Modelle der logistischen Regression, Random Forest Modelle, neuronale Netze sowie Support Vektor Maschinen auf Basis der Datenquellen trainiert. In Abb. 2 ist beispielhaft die normalisierte Mehrklassen-Konfusionsmatrix eines dieser trainierten

Modelle (Random Forest Modell) abgebildet, welches retrospektiv mit einem Testdatenset erprobt wurde. Die Grafik beschreibt die Performance des Modells für die 20 Diagnosen. So wird etwa S72 (Fraktur des Femurs) zu 97 % korrekt prädiziert. Im gleichen Beispiel besteht eine 3,2 %ige Wahrscheinlichkeit, dass das Ergebnis als E87 (Hyperosmolarität und Hypernaträmie) prädiziert wird.

### Erklärbarkeit

Während die Performance entlang der Parameter Spezifität, Sensitivität, AUC-Werte etc. die Bewertung einer Klassifikationsgüte zulassen, besteht dennoch das Problem, dass ML-Modelle und deren Entwicklung nicht hinreichend im Kontext der Erklärbarkeit für die Endnutzer sind [11]. So besteht für Endanwender nicht nur der Anspruch einer möglichst hohen Klassifikationspräzision des Modells, sondern auch die Anforderung zur Transparenz der Entstehung bzw. Berechnung des Modells. Diese Anforderung ist in der technischen Praxis eine Trade-off Entscheidung. So können beispielsweise Deep Learning Netze sehr präzise in ihrer Aufgabe sein, allerdings gelten sie allgemein hin als Blackboxes und können somit nur schwer zur Erklärung ihrer Ergebnisse genutzt werden. Das Gegenbeispiel sind etwa Regressionsmodelle, welche leichter eine Erklärung für das Rechenergebnis liefern können, aber in der Regel weniger präzise bei der Problemlösung sind.

**Quellen**

- [1] Schöpke, T. et al. Statusbericht aus deutschen Notaufnahmen, Notfall Rettungsmed. 17 (2014) 660–670.
- [2] <http://bmg-projekt-ensure.uni-goettingen.de/home/> (zuletzt zugegriffen am 31.08.2022)
- [3] <https://medizininformatik.umg.eu/en/research/projects/ensure/> (zuletzt zugegriffen am 31.08.2022)
- [4] Bernstein, S.L. et al. The Effect of Emergency Department Crowding on Clinically Oriented Outcomes, Academic Emergency Medicine. 16 (2009) 1–10.
- [5] Richter J., Vogel S. Illustration of Clinical Decision Support System Development Complexity. Stud Health Technol Inform. 2020;272:261-264. doi:10.3233/SHTI200544
- [6] Sutton, R.T., Pincock, D., Baumgart, D.C. et al. An overview of clinical decision support systems: benefits, risks, and strategies for success. npj Digit. Med. 3, 17 (2020). <https://doi.org/10.1038/s41746-020-0221-y>
- [7] Vogel S., Krefting D. Towards a Generic Description Schema for Clinical Decision Support Systems. Stud Health Technol Inform. 2022;294:119-120. doi:10.3233/SHTI220409
- [8] Blaschke S.; Walcher F.; Kulla M.; Wrede C. (Hrsg). SOP Handbuch Interdisziplinäre Notaufnahme. Medizinisch Wissenschaftliche Verlagsgesellschaft (MWV), Berlin, 2. Auflage 2022 (in press)
- [9] <https://www.aktin.org/de-de/> (zuletzt zugegriffen am 31.08.2022)
- [10] D. Brammen, et al. Das AKTIN-Notaufnahmeregister – kontinuierlich aktuelle Daten aus der Akutmedizin. 117 (2020) 24-33. <https://doi.org/10.1007/s00063-020-00764-2>
- [11] L.H. Gilpin, et al. Explaining Explanations: An Overview of Interpretability of Machine Learning, ArXiv:1806.00069 [Cs, Stat]. (2019).
- [12] L.S. Shapley, 17. A Value for n-Person Games, Volume II, Princeton Univ. Press, 1953: pp. 307–318.

Erklärbare KI-Verfahren für ML als Brückenschlag zwischen hoher Performance und Erklärbarkeit teilen sich in zwei Bereiche: zum einen modellabhängige Ansätze, zum anderen modellunabhängige Ansätze. Im Projekt ENSURE wurde der Fokus auf modellunabhängige Ansätze gelegt, um eine Vielzahl unterschiedlicher ML-Modelle parallel mit gleichartigen Erklärbarkeitsansätzen zu entwickeln. Eine der häufigsten Erklärbarkeitsansätze ist Shap (Shapley Additive exPlanations) [12]. So wurde im Projekt beispielsweise bei der Diagnoseklassifikation auf Basis unterschiedlicher Merkmalsparameter ein Random Forest Model mit Shap kombiniert (siehe Abb. 3).

Shap beschreibt entlang der Klassifikationsberechnung, welches Gewicht und somit welchen Einfluss die jeweiligen Merkmalsparameter auf das Ergebnis hatten. Für den Anwender ist dies eine zusätzliche Information, welche bei der Interpretation und kritischen Betrachtung der Modellempfehlung unterstützen kann.

**Ausblick des Projektes**

Klinische Entscheidungsunterstützungssysteme, so auch ENSURE, stehen großen Herausforderungen auf unterschiedlichen Ebenen gegenüber, um in die Routineversorgung gebracht zu werden. Ein Erfolgsfaktor ist es, CDSS schrittweise im Laborsetting zu testen und schließlich im prospektiven Feldversuch zu erproben. Auf diese Weise soll die Robustheit sowie Generalisierbarkeit, aber auch die Handhabbarkeit der Systeme evaluiert werden. Insbesondere die regulatorischen Anforderungen des MPDG stellen hierbei für die Entwickler und Hersteller eine hohe Hürde dar, um ihre Systeme in die klinische Routineversorgung zu bringen. Im Kontext einer sog. sonstigen klinischen Studie soll im Projekt ENSURE das gleichnamige Entscheidungsunterstützungssystem erprobt werden, um die erste Hürde einer prospektiven Pilotstudie zu nehmen. ■

## Impressum

### **Charakteristik:**

medizin://dokumentation/informatik/informationsmanagement/ (mdi) ist eine praxisorientierte Zeitschrift mit Fachartikeln zur Thematik der Medizinischen Dokumentation und des DV-Einsatzes im Gesundheitswesen und damit angrenzenden organisatorischen Fragen. Sie transportiert Erfahrungsberichte zu Top-Themen sowie aktuelle Entwicklungen direkt in die Praxis. Zielgruppe sind die ca. 2.600 tätigen Mitglieder der beteiligten Verbände, Entscheidungsträger im Management und DV-Management von Gesundheitsversorgungseinrichtungen und bei einschlägigen Industrie-Unternehmen wie Software-Häusern, Pharma-Firmen, CROs sowie leitende Mitarbeiter, Ärzte, Pflegekräfte und Therapeuten.

### **Verlag und Vertrieb:**

Eigenverlag und Eigenvertrieb  
**ISSN:** 1438-0900

**Auflage:** 1.400 Stück

### **Erscheinungsweise:**

4-mal jährlich, jeweils zum Quartalsende

### **Herausgeber:**

#### **mdi GbR**

**c/o BVMI** Berufsverband  
Medizinischer Informatiker e.V.  
Oberlinstr. 26  
41239 Mönchengladbach  
Fon: 02166 2171148  
Fax: 02166 134545  
info@bvmi.de | www.bvmi.de

**c/o DVMD** Der Fachverband für  
Dokumentation und Informations-  
management in der Medizin e.V.  
Lobdengaustraße 13  
69493 Hirschberg  
Fon: 06201 4891884  
Fax: 06201 4890459  
dvmd@dvmd.de  
www.dvmd.de

### **Nachdruck und Kopien:**

Nur mit Genehmigung der  
Redaktion und unter Angabe  
der genauen Quelle

### **Manuskripte:**

Zuschriften, die den Inhalt der Zeitschrift betreffen, sind direkt an die Redaktionsanschrift zu senden.

Für unverlangte Manuskripte wird keine Haftung und keine Verpflichtung zur Veröffentlichung übernommen. Beiträge, die anderweitig parallel eingereicht wurden, werden nicht angenommen. Die Redaktion behält sich vor, aus technischen Gründen Kürzungen vorzunehmen. Namentlich gekennzeichnete Beiträge geben die Meinung des Verfassers wieder.

### **Redaktionsteam:**

Prof. Dr.-Ing. Oliver J. Bott,  
Hannover | Prof. Dr. Andreas J. W.  
Goldschmidt, Frankfurt |  
Angelika Händel, Erlangen |  
Markus Stein, Berlin (Leitung) |  
Prof. Dr. Paul Schmücker,  
Mannheim

### **Redaktionsanschrift:**

Siehe Verbandsanschrift  
des BVMI

### **Autorenrichtlinien:**

unter <https://www.bvmi.de/mdi/mdi-kontakt/autorenrichtlinien>

### **Bestellungen:**

Über die Verbandsanschrift  
des BVMI. Abbestellungen sechs  
Wochen zum Jahresende.

### **Bezugspreis:**

Jährlich 49 Euro inkl. MwSt.,  
inkl. Versandkosten. Ausland plus  
Versandkosten, für BVMI- und  
DVMD-Mitglieder frei.

### **Anzeigenpreisliste:**

Nr. 22 vom Januar 2021

### **Anzeigenverwaltung:**

DVMD e.V.  
Katharina Mai  
Lobdengaustraße 13  
69493 Hirschberg  
Fon: 06201 489-1884, Fax: -0459  
dvmd@dvmd.de

### **Layout:**

Fleck · Zimmermann, Berlin

### **Titelfoto:**

shutterstock/HQuality

### **Druck:**

Kössinger AG, Schierling