Notfall Rettungsmed
<https://doi.org/10.1007/s10049-021-00874-0>

© Der/die Autor(en) 2021

S. Schacher¹ · M. Kuehl² · I. Gräff³

¹ Zentrale Notaufnahme, Evangelisches Krankenhaus Kalk, Köln, Deutschland

² Medizinische Fakultät, Universität Hamburg, Hamburg, Deutschland

³ Abteilung für Klinische Akut- und Notfallmedizin, Universitätsklinik Bonn, Bonn, Deutschland

Some machine's doin' that for you* – elektronische Triage-systeme in der Notaufnahme

Einführung

Vor etwa 25 Jahren begann, ausgehend von den angloamerikanischen Ländern, die Entwicklung und Etablierung von Triage- bzw. Ersteinschätzungssystemen für die Notaufnahmen, da sich durch die steigende Inanspruchnahme der Notaufnahmen die Notwendigkeit einer Priorisierung der unregelmäßig und ungeplant eintreffenden Patienten ergab. Ab 2004 setzten die ersten Notaufnahmen in Deutschland strukturierte Triage-systeme ein. 2010 wurde dem Thema ein Übersichtsartikel im *Deutschen Ärzteblatt* gewidmet [12] und spätestens mit dem G-BA-Beschluss zur strukturierten Notfallversorgung 2018, der den Einsatz eines strukturierten und validierten Systems zur Behandlungspriorisierung als Voraussetzung zur Teilnahme an der Notfallversorgung fordert [18], ist von einer flächendeckenden Verbreitung in Deutschland auszugehen.

Im deutschsprachigen Raum sind der Emergency Severity Index (ESI) und das Manchester Triage System (MTS) die verbreitetsten Triage-systeme zur Dringlichkeitseinschätzung der Notfallpatienten.

Die Validität beider Triage-systeme wird als moderat bis gut betrachtet, wobei beim ESI die Einstufung stark auf der klinischen Beurteilung durch die Pflegekraft beruht, was zu einer hohen Inter-rater-Variabilität und suboptima-

len Vorhersagekraft führt [34]. Beim MTS weisen dafür einige Präsentationsdiagramme, wie z. B. „abdomineller Schmerz beim Erwachsenen“, „Unwohlsein des Erwachsenen“, „Thoraxschmerz“ und „Extremitätenprobleme“ niedrige Sensitivitäten auf, die z. T. unter 0,5 liegen [43]. Dies kann dazu führen, dass je nach angewandtem Triage-system und in Abhängigkeit von der Erfahrung und der subjektiven Einschätzung des Anwenders ein Patient mit den gleichen Symptomen unterschiedlichen Dringlichkeitsstufen zugeordnet wird. Zudem greifen die etablierten Triage-systeme auf typische Symptome zurück, dabei hat z. B. der typische retrosternale Thoraxschmerz eine geringe Vorhersagekraft für Diagnose oder Prognose. Die mit steigendem Alter häufiger auftretenden atypischen Beschwerden, die mit einer höheren Morbidität und Mortalität assoziiert sind, werden dadurch nicht erfasst [4]. ESI und MTS sind nicht altersadaptiert und zeigen bei älteren Patienten geringere diagnostische Treffsicherheit und die Tendenz zur Untertriage [22, 25, 30, 43].

Die bisherigen Triage-systeme bauen auf medizinischem Wissen und Erfahrungen auf [16], die Eingaben beinhalten subjektive und objektive Informationen. Bisher wurden Triage-systeme vor allem auf prädiktive Validität und Reliabilität untersucht; allerdings sind die Triage-kategorien ungenau und überschneiden sich teilweise [22]. Bingisser empfiehlt

daher den Wechsel weg von der auf Expertenmeinung basierten Triage hin zur evidenzbasierten Triage. Er sieht eine Risikostratifizierung hoher Güte bei Eintreffen für das weitgehend unselektierte Patientengut einer Notaufnahme mit erheblichem kurzfristigem Morbiditäts- und Mortalitätsrisiko als elementar wichtig an [4].

Dies können elektronische Triage-systeme (ETS) leisten, die über die symptom-basierte Einschätzung einer Pflegekraft hinausgehen. Sie vergleichen Daten, die standardisiert im Rahmen der Triage erhoben werden, mit hinterlegten Algorithmen, die mit großen Datenmengen trainiert wurden. So können versteckte „Muster“, d. h. Risikokonstellationen, aus den Anamnesedaten erkannt werden [16] und die Dringlichkeitsstufe aus dem individuellen Risikoprofil des Patienten bestimmt werden. Neben der reinen Risikoeinschätzung bei der Triage erlauben ETS auch eine Vorhersage über klinisch-organisatorische Endpunkte, wie die Notwendigkeit der stationären Aufnahme, einer Intensivpflichtigkeit sowie der Mortalität oder der Verlegung in den Operationssaal bzw. das Herzkatheterlabor [14]. So kann schon sehr früh die Disposition des Patienten gesteuert und die Aufenthaltsdauer in der Notaufnahme verkürzt werden [23]. Dabei sollen solche Systeme nicht das medizinische Fachpersonal als Entscheider ersetzen, sondern ihnen relevantes Wissen und Unterstützung bei

*Aus: „In the Year 2525“, Zager & Evans

Tab. 1 Begriffserläuterung ETS und ML

ETS – elektronische Triage-Systeme	ML – Machine Learning/Modelllernen
Verwenden Algorithmen, die in der Lage sind, eine viel größere Anzahl von Prädiktorvariablen (z. B. Alter, Leitsymptom, Blutdruck etc.) zum Zeitpunkt der Triage zu berücksichtigen als etablierte Triage-Systeme	Teilbereich der KI, der verschiedene Methoden zur automatischen Erkennung von Mustern in Daten nutzt und diese Muster dann in Vorhersagen oder Entscheidungen umwandelt
Können zusätzliche Endpunkte zur Risikostratifizierung integrieren, wie z. B. Sterblichkeit oder Einweisung auf eine Intensivstation [4]	Modelle beginnen oft zufällig und verbessern sich dann mit der Zeit durch den Trainingsprozess
	Verwendet Klassifikationsverfahren (■ Tab. 2; [40])

ihrer Entscheidungsfindung zur Verfügung stellen [16].

Funktionsprinzip der elektronischen Triage (ETS)

Bereits 2007 taucht dieser Begriff erstmalig in der Fachliteratur auf, zunächst wurde damals, aber auch noch in aktuelleren Publikationen darunter die Bereitstellung der Ersteinschätzungsdiagramme bzw. -formulare in digitaler Form im Emergency-Department-Informationssystem (EDIS) oder Klinik-Informationssystem (KIS) verstanden [39]. In anderen Ländern, wie in Korea [10, 26], den USA [14, 17, 34], Spanien [44] oder dem Iran [33] wird dieser Begriff für spezielle Programme benutzt, die ein algorithmenbasiertes Clinical Decision Support System (CDSS) bilden. Dies entspricht auch der Definition von ETS in diesem Artikel als **computerbasierte Triage-Systeme mit Algorithmen, die eine größere Anzahl von Prädiktorvariablen zur Einstufung berücksichtigen** als traditionelle pflegebasierte Triage-Systeme.

Damit handelt es sich um eine Art des Machine Learning (ML) und eine Anwendungsform der künstlichen Intelligenz (KI) oder Artificial Intelligence (AI) (■ Tab. 1). Die zugrunde liegenden „intelligenten Systeme“ sind nicht einheitlich. Sie unterscheiden sich hinsichtlich Aussagekraft und Anwendungsgebiet.

Methoden – Grundlagen

Methode der Literaturrecherche

Selektive Literaturrecherche bei den Onlinedatenbanken PubMed® und Google

Scholar mit den Stichworten „electronic triage system“, „CDSS“, „emergency department triage“. Zusätzlich zu den ermittelten Publikationen wurde die dort zitierte Literatur gesichtet und von den Datenbanken als ähnlich klassifizierte Publikationen („related articles“) mit einbezogen. Die Datenbankabfragen erfolgten im Dezember 2020.

Machine Learning (ML) – häufig verwendete Modellierungsansätze

Machine-Learning-gestützte Vorhersagemodelle im medizinischen Bereich bedienen sich verschiedener Klassifikationsverfahren. In einem aktuellen systematischen Review der ETS waren die drei am häufigsten verwendeten Verfahren Logistic Regression (LR), baumdiagrammbasierte Modelle (Decision Trees [DT], Random Forests [RF], eXtreme Gradient Boost [XGBoost]) sowie Deep Neural Networks (DNN; [31]). Diese werden in ■ Tab. 2 vorgestellt. Dort wird auch das Natural Language Processing (NLP) kurz erläutert.

Die Darstellung der mathematischen und statistischen Grundlagen sowie weiterer Testmodelle ist nicht Teil dieses Artikels, hierzu sei auf detaillierte Ausführungen bei Fernandes [16] und Finkelstein [17] verwiesen.

Die Prädiktoren, die für das ML verwandt wurden, sind Parameter, die bereits bei der Ersteinschätzung bekannt sind bzw. im Rahmen der Triage erfasst werden (■ Infobox 1; [14, 17, 34]). Dies ist auch ein wichtiger Punkt für die Akzeptanz und Praktikabilität eines CDSS – es darf den Zeitbedarf nicht erhöhen und keine Zusatzdokumentation erfordern. Das Basismodul des

Infobox 1 Untersuchte Prädiktorvariablen. (Nach [14, 17, 34])

- Alter
- Geschlecht
- Art des Eintreffens (Rettungsdienst ja/nein)
- Vitalparameter:
 - Herzfrequenz
 - Temperatur
 - Blutdruck systolisch
 - Blutdruck diastolisch
 - Mittlerer Blutdruck
 - Sauerstoffsättigung pulsoxymetrisch
 - Atemfrequenz
- Schmerzsкала
- Bewusstsein
 - Glasgow Coma Scale (GCS)
- Hauptbeschwerden
- Blutzuckerspiegel
- Zugewiesene Triagekategorie Pflege
- Gehfähigkeit
- Zeit des Eintreffens
 - (Uhrzeit, Wochentag, Monat)
- Vorbehandlungen Notaufnahme
 - (Erstbesuch im System ja/nein)
- Angeordnete Untersuchungen bei Triage
 - (Zahl der Untersuchungen)
- Art der angeordneten Untersuchungen
 - (Augen-, HNO-, Orthopädiekonsil, EKG, Röntgen)

DIVI-Notaufnahmeprotokolls [37], das bereits Bestandteil vieler EDIS-Systeme ist und die im G-BA-Beschluss geforderten Standards der Dokumentation der Patientenversorgung erfüllt [18], erfasst viele dieser Parameter.

In diversen Arbeiten haben sich Alter, GCS, Herzfrequenz, Atemfrequenz und Körpertemperatur als jene Variablen erwiesen, welche über die höchste prädiktive Aussagekraft hinsichtlich der optimalen Weiterversorgung und der Prognose der Patienten verfügen [13, 14, 23, 25]. Darüber hinaus haben auch die Zuweisung mit dem Rettungsdienst und die Hauptbeschwerden (bspw. Bauchschmerzen oder Luftnot) einen gewissen Einfluss [14, 20]. Exemplarisch hierfür werden die prognoserelevanten Variablen mit ihren Odds Ratios aus der Arbeit von Dugas [14] in ■ Tab. 3 aufgeführt.

Keine relevante Vorhersagekraft wurde für Uhrzeit, Wochentag und Monat des Eintreffens gefunden [17]. In einzelnen Arbeiten wurden auch weitere Variablen wie Zahl der Voraufenthalte, Vorerkrankungen anhand ICD-Codes sowie

Notfall Rettungsmed <https://doi.org/10.1007/s10049-021-00874-0>
© Der/die Autor(en) 2021

S. Schacher · M. Kuehl · I. Gräff

Some machine's doin' that for you* – elektronische Triage-systeme in der Notaufnahme

Zusammenfassung

Hintergrund. In den letzten 25 Jahren haben sich Triage-systeme zur Dringlichkeitseinschätzung in den Notaufnahmen etabliert. Die bisherigen symptomorientierten Triage-systeme haben allerdings auch Schwächen. Inzwischen ermöglichen die Digitalisierung der Notaufnahmen und die Leistungsfähigkeit der aktuellen Computergeneration bereits zum Triagezeitpunkt einen algorithmenbasierten Datenvergleich und eine Risikostratifizierung für bestimmte klinische Endpunkte über die reine Triagestufe hinaus.

Ziel der Arbeit. Nach selektiver Literaturrecherche erfolgt eine Übersicht über elektronische Triage-systeme (ETS). Das Funktionsprinzip und die aktuellen Möglichkeiten der ETS werden dargestellt. Daneben

werden Chancen und Schwierigkeiten einer Etablierung von ETS in deutschen Notaufnahmen betrachtet.

Ergebnisse. Es wurden wesentliche Prädiktorvariablen wie Alter und bestimmte Vitalparameter identifiziert, die bisher nicht standardisiert in die Triage-stufen einfließen, aber mithilfe von Modelllernen (ML) in belastbare Vorhersagen für klinische Endpunkte wie stationäre Aufnahme oder Mortalität einfließen können. Die Güte der Ersteinschätzung durch ein ETS ist insgesamt hoch. Ein ETS kann das Triagepersonal evidenzbasiert bei der Disposition der Patienten unterstützen und Über- und Untertriage reduzieren. Es gibt einige Entwicklungen, die günstige Bedingungen für den Einsatz von ETS in deutschen ZNA schaffen. So erleichtern

z. B. repräsentative Notaufnahmeregister die Erstellung von Referenzdatensätzen, die zum Aufbau computerbasierter Klassifikationsmodelle benötigt werden. Außerdem müssen individuelle Patientendaten schnell verfügbar sein.

Schlussfolgerung. ETS können zur Erhöhung der Patientensicherheit und zur besseren Ressourcennutzung beitragen. Bislang fehlen allerdings noch objektive Referenzstandards und Leitlinien zum maschinellen Lernen.

Schlüsselwörter

Modelllernen (ML) · Künstliche Intelligenz (KI) · Klinische Entscheidungssysteme · Elektronische Patientenakte (ePA) · Evidenzbasierte Triage

Some machine's doin' that for you*—electronic triage systems in the emergency department

Abstract

Background. In the last 25 years, triage systems for urgency assessment have been established in emergency departments (ED). The existing symptom-based triage systems show some weaknesses. The present state of digitization of the EDs and the capacity of the current generation of computers allow, at the time of triage, algorithm-based data evaluation and risk stratification for specific clinical endpoints beyond the triage level.

Aim of the study. After selective literature review, we performed an analysis of electronic triage systems (ETS). The underlying principles and the current capabilities of ETS are explained. In addition, opportunities and

difficulties of establishing ETS in German EDs are considered.

Results. Age and other vital signs have been identified as important predictor variables, which have not yet been standardized in triage systems. Using these variables, machine learning (ML) can provide reliable predictions for clinical endpoints such as inpatient admission or mortality. The overall quality of initial assessment via ETS is high. ETS can offer evidence-based support to triage staff in patient disposition and reduce over- and undertriage. There are developments that create favorable conditions for the use of ETS in German EDs. For example, representative

ED registries facilitate the creation of reference data sets needed to build computer-based classification models. In addition, individual patient data must be available quickly.

Conclusion. ETS can help increase patient safety and improve resource utilization. However, to date, objective reference standards and guidelines for machine learning are still lacking.

Keywords

Machine learning (ML) · Artificial intelligence (AI) · Clinical decision support systems (CDSS) · Electronic health record (EHR) · Evidence-based triage

die Dauermedikation einbezogen, auch diese Variablen führen zu Modellen, welche bereits zum Zeitpunkt der Triage Vorhersagen bezüglich einer stationären Aufnahme treffen können [23].

Vorhersage klinischer Endpunkte (Clinical Outcome Prediction)

Bei der Beurteilung zum Stellenwert eines ETS muss beachtet werden, dass in den Anwenderstudien unterschiedliche Endpunkte verfolgt werden: In einigen Studien wurde das ETS lediglich eingesetzt, um

die Triagestufe und Behandlungspriorität zu ermitteln [10], während der Großteil der Studien darüber hinausgeht und klinische Endpunkte wie stationäre Aufnahme, Intensivpflichtigkeit, Mortalität [19, 25–27, 34], vereinzelt auch Inanspruchnahme von Herzkatheterlabor und Operationssaal einbezieht ([14]; **Abb. 1**).

Modelle, die die Wahrscheinlichkeit der stationären Aufnahme bereits zum Zeitpunkt der Triage vorhersagen, sind insofern von Interesse, als der Exit-Block, also das Abfließen der Patienten auf die Stationen, einer der wesentlichen Fakto-

ren des *Crowding* in der Notaufnahme ist [35, 36]. *Crowding* wiederum verschlechtert das Behandlungsergebnis der Patienten [2]. Wenn potenzielle Aufnahmen frühzeitig bekannt sind, können Bettenmanagement und Administration entsprechend informiert werden und darauf reagieren [20]. Daneben kann die Vorhersage einer stationären Aufnahme auch als Platzhalter für die Erkrankungsschwere, die Notwendigkeit von Notfallmaßnahmen und weiteren nachgelagerten Entscheidungen gewertet werden [14, 27].

Tab. 2 Die drei häufigsten Klassifikationsverfahren bei ETS und Erläuterung des NLP

<i>Logistic Regression (LR)</i>	<p>Extrem robustes und vielseitiges Klassifikationsverfahren</p> <p>Erklärt abhängige binäre Variablen</p> <p>Kann eine Vorhersage der Wahrscheinlichkeit treffen, mit der ein Ereignis eintritt oder nicht [41]</p>
<i>Baumbasierte Algorithmen: Random Forest (RF)</i>	<p>Besteht aus mehreren unkorrelierten Entscheidungsbäumen (Decision Trees [DT])</p> <p>Trifft Vorhersagen anhand einer Teilmenge aller Eigenschaften</p> <p>Für eine Klassifikation trifft jeder Baum in diesem Wald eine Entscheidung und die Klasse mit den meisten Stimmen entscheidet die endgültige Klassifikation</p> <p><i>RF hat viele Vorteile gegenüber anderen Klassifikationsmethoden:</i></p> <p>Der Klassifikator trainiert sehr schnell: kurze Trainings- bzw. Aufbauzeit eines einzelnen Entscheidungsbaums und linearer Anstieg der Trainingszeit bei einem RF mit der Anzahl der Bäume</p> <p>Sehr effizient für große Datenmengen (viele Klassen, viele Trainingsbeispiele, viele Merkmale)</p> <p>Wichtige Klassen können erkannt werden [42]</p>
<i>eXtreme Gradient Boost (XGBoost)</i>	<p>Überwachtes maschinelles Lernen mit dem Entscheidungsbaumalgorithmus Gradient Boosting</p> <p>Durch Kombination der Vorhersagen mehrerer einfacher Modelle können selbst komplexe Funktionen mit vielen Variablen genau und schnell erlernt werden</p> <p>Adressiert Problemstellungen des maschinellen Lernens in den Bereichen Regression, Rangfolge und Klassifizierung</p> <p>Arbeitet performant, parallel und verteilt [9]</p>
<i>Deep Neural Networks (DNN) – künstliche neuronale Netze</i>	<p>Sind aus Informationsverarbeitungsknoten, sog. „Neuronen“ aufgebaut, in Aspekten ähnlich dem menschlichen Gehirn</p> <p>Durch die Anordnung und Verknüpfung der Neuronen lassen sich Anwendungsprobleme computerbasiert lösen</p> <p>Neuronale Netze müssen, bevor sie Problemstellungen lösen können, trainiert werden – „lernen“</p> <p>Eingangsvariablen werden in Input-Neuronen eingespeist. Es folgt ein Netzwerk versteckter Neuronen. Anschließend erzeugen Output-Neuronen Ergebnisse. Zwischen den verschiedenen Neuronen des Netzwerks bestehen Verbindungen. Über diese kann die Ausgabe eines Neurons zum Input des nächsten Neurons werden. Je nach Gewichtung der Verbindung kann die Ausgabe hierbei Einfluss auf die Ausgabe eines anderen Neurons nehmen</p> <p>Während des Trainings/Lernens werden die Gewichtungen der Verbindungen so angepasst, dass die Eingangsvariablen des Trainingsdatensatzes möglichst genau zu den zugehörigen (bereits bekannten) Ausgaben führen</p> <p>Mit steigender Anzahl der Neuronen sowie der vorhandenen Schichten und Verbindungen steigt die benötigte Rechenleistung für das Trainieren und den Betrieb [28]</p>
<i>Natural Language Processing (NLP)</i>	<p>Versucht, natürliche Sprache zu erfassen und mithilfe von Regeln und Algorithmen computerbasiert zu verarbeiten</p> <p>Verwendet verschiedene Methoden und Ergebnisse aus den Sprachwissenschaften und kombiniert diese mit moderner Informatik und künstlicher Intelligenz [29]</p> <p>NLP-Methoden erlauben es, auch Freitexteingaben zu interpretieren</p> <p>Besondere Herausforderung im medizinischen Bereich ist, dass viel mit Abkürzungen und lateinischen bzw. griechischen Begriffen gearbeitet wird [10]</p>

Die Prädiktion einer „Aufnahme auf die Intensivstation“ ist zwar an sich ein interessanter Parameter in Hinsicht auf die begrenzte Intensivbettenkapazität, ist jedoch sehr vielen Einflüssen unterworfen und nicht gut vergleichbar: Die Auswirkungen der in der Notaufnahme erfolg-

ten Maßnahmen können nicht beurteilt werden, und wann ein Patient in der jeweiligen Klinik auf der Intensivstation aufgenommen wird, hängt von der Klinikstruktur und -politik ab sowie von den aktuell verfügbaren Ressourcen [25].

Ergebnisse der ETS

Natürlich ist die Einführung eines ETS nur sinnvoll, wenn das ETS die Zuverlässigkeit der Triageeinstufungen des medizinischen Fachpersonals übertrifft.

Die Leistungsfähigkeit der Triage-systeme und Modelle wird in Form von Genauigkeitsmetriken beschrieben. Dazu gehören Diskriminierung (C-Statistik) und Klassifikationsstatistiken (Sensitivität, Spezifität, Genauigkeit, positiver prädiktiver Wert [PPV], negativer prädiktiver Wert [NPV] sowie Likelihood Ratios [+/-]). Einige Studien verwenden Synonyme wie „Präzision“ statt PPV oder „Recall“ statt Sensitivität [31]. In den meisten Studien werden die Ergebnisse mittels C-Statistik (AUC/AUROC) dargestellt [13]. Werte oberhalb von 0,7 werden hierbei als gut betrachtet, über 0,8 als exzellent und größer 0,9 als herausragend [20, 31].

Es konnte sowohl im Vergleich ESI/MTS gegen ETS für die Punkte stationäre Aufnahme, Intensivpflichtigkeit, Mortalität und Notfallprozeduren [3, 17, 27, 34] als auch im Vergleich verschiedener ML-Modelle gegen Standardtriage eine höhere Leistungsfähigkeit der ETS gezeigt werden.

Dazu im Folgenden einige exemplarische Daten aus den Studien:

- Für den Parameter „Intensivpflichtigkeit“ bei den Triagestufen 1–3 lag das ESI-Referenzmodell bei 0,79 [17] bzw. 0,74 (95 %-CI 0,72–0,75; [34]) gegenüber einem DNN-basierten Modell mit 0,86 (95 %-CI 0,85–0,87) bzw. 0,92 mit gleichzeitig höherer Sensitivität und Spezifität. Die Präzision eines MTS-basierten Modells lag bei 0,74 und konnte unter Hinzunahme von klinischen Variablen wie Alter und Vitalwerten auf 0,84 bzw. mit Einbeziehung der Hauptbeschwerde auf 0,86 gesteigert werden [17].
- Für den Punkt „Krankenhausaufnahme“ ergab der Vergleich verschiedener Klassifikationsverfahren bei mit Triageinformationen trainierten Modellen eine Test-AUC von 0,87 für LR (95 %-CI 0,86–0,87), 0,87 für XGBoost (95 %-CI 0,87–0,88) und 0,87 für DNN (95 %-CI 0,87–0,88),

Tab. 3 ETS – Prädiktorvariablen mit hohen Odds Ratios (OR) für „critical outcomes“. (Nach [14])

ETS – Prädiktorvariablen		Odds Ratios (OR)
Alter:	61–70 Jahre	3,19
	71–80 Jahre	3,88
	>80 Jahre	4,11
Zuweisung mit Rettungsdienst		4,53
Schwere Tachykardie (≥ 130 bpm)		4,66
Systolischer Blutdruck: RR < 100 mm Hg		2,94
Atemfrequenz: Bradyponoe < 14/min		2,89
Atemfrequenz: Tachypnoe > 28/min		2,55
Fieber (Temp. > 38,0 Grad)		2,07
Führendes Symptom: Bauchschmerzen		2,62
Führendes Symptom: Atemnot		2,47

bei mit Patientenhistorie trainierten Modellen eine AUC von 0,86 für LR (95 %-CI 0,86 – 0,87), 0,87 für XGBoost (95 %-CI 0,87 – 0,87) und 0,87 für DNN (95 %-CI 0,87 – 0,88) und für Modelle, die auf dem vollständigen Satz von Variablen (Triage plus Anamnese) trainiert wurden, eine AUC von 0,91 für LR (95 %-CI 0,91 – 0,91), 0,92 für XGBoost (95 %-CI 0,92 – 0,93) und 0,92 für DNN (95 %-CI 0,92 – 0,92; [23]).

Interessanterweise war die Präzision eines ETS, das nur klinischen Variablen und die Hauptbeschwerden berücksichtigte, ohne Einbeziehung der MTS- oder ESI-Triage-Informationen gleichwertig der Kombination aus allen drei Teilen, bei gleicher Spezifität und Sensitivität [17]. Auch in einer weiteren Studie verbesserte das Hinzufügen von Anamneseinformationen die Vorhersagekraft signifikant im Vergleich zur alleinigen Verwendung von Triageinformationen – bei alleiniger Verwendung der Patientenhistorie wurde bereits eine AUC von 0,86 erreicht [23]. Diese Ergebnisse zeigen eine hohe Präzision der Triagevorhersagen der CDSS und auch, dass die subjektive Einschätzung und Erfahrung des Triagierenden darin keine Rolle mehr spielen. Dies führte

Tab. 4 Digitale Projekte in der Notfallmedizin in Deutschland

OPTINOFA	Assistenzdienst für die häufigsten notfallmedizinischen Leitsymptome und -diagnosen, stellt Notfallalgorithmen zur Verfügung, die über ein mobiles Endgerät oder direkt in der Klinik vor Ort abgerufen werden können
	Ziel ist eine bessere und bedarfsgerechte Verteilung der Patientenströme
	Teilnehmer: Uniklinik Göttingen und Magdeburg, Krankenkassen sowie Kliniken, kassenärztl. Vereinigungen und andere Partner
AKTIN	Notaufnahmeregister zur elektronischen Behandlungsdokumentation
	Daten können aufgrund datenschutzkonformer Infrastruktur ohne zusätzlichen Dokumentationsaufwand interoperabel einer sekundären Datennutzung zugeführt werden
	Aktuell Teilnahme von 15 Kliniken aller Stufen der Notfallversorgung

dazu, dass manche Untersucher in ihren endgültigen Modellen bereits auf die Triageinformationen verzichten [17].

Diskussion – Chancen und Herausforderungen der „e-Triage“

Ein ETS kann nur genutzt werden, wo ein EDIS mit computergestützter Triage und elektronischer Krankenakte etabliert ist [14]. Davon ist in Deutschland aber inzwischen überwiegend auszugehen.

Die Implementierung und Anwendung eines CDSS darf nicht zur Verlängerung der Triagezeit führen. Das bedeutet, dass neben den Daten, die bei der Aufnahme in der Notaufnahme im Computer erfasst werden, die ML-Modelle sich nur auf Variablen stützen sollten, die innerhalb von drei Minuten erfasst werden können (z.B. Vitalparameter und Hauptbeschwerden; [16]). Auch Daten aus der elektronischen Patientenakte oder der elektronischen Gesundheitskarte müssen daher rasch zur Verfügung stehen.

Die Einstufung mittels ETS soll Über- und Untertriage reduzieren. Die Untertriage birgt das Risiko einer Verschlechterung während der Wartezeit. Die Übertriage verbraucht knappe Ressourcen und schränkt die Verfügbarkeit freier Betten in der Notaufnahme für andere Patienten ein, die möglicherweise eine sofortige Behandlung benötigen [15]. Jordi hat 2015 gezeigt, dass eine korrekte Triagestufe bei ESI nur in 60 % gewählt wurde, 13,6 % waren über- und 26,8 % untertriiert [24], ähnliche Ergebnisse finden sich bei

Levin, hier legte das ETS bei 10 % der ESI-3-Patienten eine Höherstufung fest [27]. Untertriage ist eine gefährliche Situation bei Crowding und eine Quelle für Bias, da je nach initialer Triageklassifizierung angenommen wird, dass der Patient nicht relevant erkrankt ist [8].

Allerdings wird in verschiedenen Arbeiten übergreifend betont, dass ein ETS nicht die Triagekraft oder den Arzt ersetzen soll [14, 25, 27]. Diese können den Zustand des vor ihnen sitzenden Patienten oder Details der Anamnese beurteilen, die ein schnelles Handeln erfordern und ein ETS nicht erkennt. Daher muss das ETS vom Fachpersonal „überstimmt“ werden können [8]. Deshalb müssen auch eine Personifizierung der Algorithmen und die Annahme echter Intelligenz vermieden werden, genauso wie zu glauben, dass diese Systeme wirklich die Aufgabe verstehen, die sie durchführen [11].

Gerade bei DNN als Klassifikationsverfahren sind die Algorithmen bisher häufig nicht nachvollziehbar, diese „Undurchsichtigkeit“ und fehlende Datentransparenz kann ethische und juristische Auswirkungen haben. Dies ist auch eines der Schlüsselprobleme bzgl. der Einführung von KI [16, 40]. Mittlerweile rückt das Thema „AI interpretability“ jedoch immer weiter in den Fokus. So ist es bspw. möglich anhand der Gewichtungen eines DNN oder der Koeffizienten eines Regressionsmodells herauszufinden, welche Eigenschaften die Kategorisierung beeinflussen, und diese auf Plausibilität zu überprüfen [38]. Denn nur Transparenz der AI

Abb. 1 ▲ Machine-Learning-Algorithmen verarbeiten routinemäßig bei der Triage erhobene Daten, um stat. Aufnahmen vorherzusagen. Die Vorhersagen lassen sich für Bettenmanagement und Audits nutzen. (Nach [20])

schaft langfristige Akzeptanz bei den Anwendern.

Wie aus den oben gezeigten Daten ersichtlich, erreicht ein Vorhersagemodell für die Aufnahme, das auf der Vorgeschichte des Patienten aufbaut, eine hohe Präzision. Ein solches Modell enthält Funktionen, die aus Freitextdaten der elektronischen Krankenakte (Electronic Health Record [EHR]) abgeleitet werden können. Insbesondere die Analyse von Texten und medizinischen Notizen mittels NLP kann Informationen liefern, die in tabellarischen Daten fehlen. Dies haben Untersuchungen zu Vorhersagemodellen für Sepsis und Suizide gezeigt [23, 40]. Die Einbeziehung von Freitexteingaben führt zu signifikanten Verbesserungen sowohl der Sensitivität als auch der Spezifität neuronaler Netzwerkmodelle. Sie haben eine höhere Aussagekraft als codierte Beschwerden. Ein Beispiel dafür wäre, wenn die Triagekraft bei Hauptbeschwerde nur zwischen „Brustschmerzen“ und „Rückenschmerzen“ wählen kann, was nicht die Information erfasst, die „plötzlicher Brustschmerz mit Ausstrahlung in den Rücken“ bedeuten kann [25].

Bislang ist mit „elektronischer Gesundheitsakte“ nur die Krankengeschichte des Patienten im EDIS/KIS gemeint – eine Limitation, die durch eine elektronische Patientenakte (ePA), die sämtliche ambulanten wie stationären Behandlungen sowie ein Notfalldatenmanagement

enthält, wie sie in Deutschland nun sukzessiv eingeführt wird [21], überwunden werden kann. Natürlich ist die Vollständigkeit der Informationen eine wesentliche Bedingung für deren Verwertbarkeit.

Hier bietet die aktuelle Situation in Deutschland durch verschiedene Aspekte eine günstige Gelegenheit, solche Programme auf verschiedene verlässliche Datenquellen und eine Vielzahl von Kliniken auszudehnen, ggf. sogar als Startschuss einer nationalen ETS-Initiative.

Zum einen wird politisch durch den Digitalisierungsfonds für die Krankenhäuser die Implementierung klinischer Entscheidungssysteme gefördert [7]. Des Weiteren bietet die bereits oben erwähnte flächendeckende Einführung der ePA in Deutschland einen vielversprechenden Ansatz. Zusätzlich könnten Abrechnungsdaten der Krankenkassen einfließen, die über die Krankenhausverweildauer und Krankenhausmortalität Auskunft geben können.

Weitere interessante Elemente sind sowohl das OPTINOFA-Projekt [5], welches bereits jetzt, wenn auch unter der Zielsetzung der Zuordnung zur sektoralen Versorgung, über Strukturen verfügt, die für ein flächendeckendes ETS interessant sind, als auch die Daten des AKTIN-Notaufnahmeregisters ([6]; **Tab. 4**).

Daraus könnte ein ETS erstellt und validiert werden. Ein nationales ETS muss

auf der Vielzahl der auf dem Markt befindlichen Klinik-Informationssysteme (KIS) installierbar sein und mit diesen kommunizieren können. Dies stellt eine erhebliche Herausforderung bei dem sehr divergenten Stand der Digitalisierung der deutschen Krankenhäuser dar. Das AKTIN-Projekt zeigt, dass es grundsätzlich machbar ist, und mit fortschreitender Telematik-Infrastruktur einfacher wird [6].

Auch in Hinsicht auf die von der Politik gewünschten und andiskutierten integrierten Notfallzentren zur Steuerung von Akut- und Notfallpatienten wäre eine Unterstützung durch elektronische Triage-systeme auf der Basis belastbarer Daten zur Erhöhung der Patientensicherheit erstrebenswert. Dieser Ansatz ist besonders interessant, da sich bisherige Systeme als unzureichend zur Dringlichkeitseinstufung dieser Patientengruppe gezeigt haben [32]. Hierzu ist natürlich die Entwicklung und Implementierung einer datenschutzkonformen Infrastruktur zur Dokumentation in den Notaufnahmen erforderlich, damit eine interoperable, vom verwendeten IT-System unabhängige, sekundäre Datennutzung möglich ist [1].

Limitationen

Der Stand der digitalen Datenerfassung und die Rechenkraft der Computer in den Kliniken und Notaufnahmen ermöglichen die rasche Datenauswertung durch Prädiktionsmodelle und lassen ihren Einsatz verführerisch einfach aussehen [40]. Bei näherer Betrachtung vieler Studien fehlt aber eine Validierung [16] und insbesondere eine objektive Referenzgröße (Goldstandard), die den Vergleich und die Übertragbarkeit der Modellgenauigkeit bei Einsatz an anderer Stelle erlaubt [31].

Sowohl bei der Wahl der Triagestufe als auch des Endpunkts „Aufnahme auf die Intensivstation“ ist von starken subjektiven und lokalen Einflüssen auszugehen. Hier erscheinen objektiv messbare, nicht beeinflussbare Bezugsvariablen wie Mortalität oder Auftreten eines Herzstillstands in den ersten 72 h nach Aufnahme günstiger [31].

In den vorgelegten Studien wurde zwar zum Teil auf nationale Datenbanken zurückgegriffen (National Hospital and Ambulatory Medical Care Survey ED Data; [14, 34]), die meisten vorgestellten ETS sind aber lokale Lösungen, die mit lokalen Daten und Abfragealgorithmen programmiert wurden [16, 33].

Ebenso beziehen sich viele Studien auf eine retrospektive Datenanalyse, vor der Einbindung in den klinischen Alltag sind prospektive Studien zur Validierung sowie randomisierte Control-Studien erforderlich [40].

Es bleibt abzuwarten, ob elektronische Triage-Systeme durch ihre gute Prädiktion auch ohne die Informationen der klassischen Triage zu einem Paradigmenwechsel führen und Triage-Systeme wie ESI und MTS zukünftig ablösen.

Fazit für die Praxis

- ETS mit Implementierung von CDSS auf der Basis neuronaler Netzwerke und anderer komplexer ML-Verfahren können die Triage in der Notaufnahme auf verschiedene Weise sinnvoll unterstützen.
- Neben einer Assistenz des Triagepersonals bei der Wahl der Triagestufe können sie auch bereits zum Zeitpunkt der Triage für wichtige Eckpunkte der Patientenversorgung eine belastbare Vorhersage erstellen.
- Auf Basis der ETS-Empfehlung kann die Ressourcennutzung optimiert werden und eine frühzeitige Risikostratifizierung der Patienten erfolgen.
- In Deutschland gibt es bereits Projekte, auf deren Daten und Strukturen ETS sowie weitere für die Notfallmedizin interessante CDSS nicht nur lokal, sondern bundesweit aufgebaut werden könnten.
- Weitere Forschung zur Schaffung von Referenzstandards mit objektiv messbaren Parametern sowie von Leitlinien zur Transparenz der ML-Modelle ist erforderlich.

Korrespondenzadresse

I. Gräff

Abteilung für Klinische Akut- und Notfallmedizin, Universitätsklinik Bonn
Bonn, Deutschland
Ingo.graeff@ukbonn.de

Funding. Open Access funding enabled and organized by Projekt DEAL.

Einhaltung ethischer Richtlinien

Interessenkonflikt. S. Schacher, M. Kuehl und I. Gräff geben an, dass kein Interessenkonflikt besteht.

Für diesen Beitrag wurden von den Autoren keine Studien an Menschen oder Tieren durchgeführt. Für die aufgeführten Studien gelten die jeweils dort angegebenen ethischen Richtlinien.

Open Access. Dieser Artikel wird unter der Creative Commons Namensnennung 4.0 International Lizenz veröffentlicht, welche die Nutzung, Vervielfältigung, Bearbeitung, Verbreitung und Wiedergabe in jeglichem Medium und Format erlaubt, sofern Sie den/die ursprünglichen Autor(en) und die Quelle ordnungsgemäß nennen, einen Link zur Creative Commons Lizenz beifügen und angeben, ob Änderungen vorgenommen wurden.

Die in diesem Artikel enthaltenen Bilder und sonstiges Drittmaterial unterliegen ebenfalls der genannten Creative Commons Lizenz, sofern sich aus der Abbildungslegende nichts anderes ergibt. Sofern das betreffende Material nicht unter der genannten Creative Commons Lizenz steht und die betreffende Handlung nicht nach gesetzlichen Vorschriften erlaubt ist, ist für die oben aufgeführten Weiterverwendungen des Materials die Einwilligung des jeweiligen Rechteinhabers einzuholen.

Weitere Details zur Lizenz entnehmen Sie bitte der Lizenzinformation auf <http://creativecommons.org/licenses/by/4.0/deed.de>.

Literatur

1. Ahlbrandt J, Brammen D, Majeed RW et al (2014) Balancing the need for big data and patient data privacy—an IT infrastructure for a decentralized emergency care research database. *Stud Health Technol Inform* 205:750–754
2. Aronsky D, Jones I, Raines B et al (2008) An integrated computerized triage system in the emergency department. *AMIA . Annual Symposium proceedings AMIA Symposium*, S16–20
3. Barford C, Lauritzen MMP, Danker JK et al (2012) Abnormal vital signs are strong predictors for intensive care unit admission and in-hospital mortality in adults triaged in the emergency department—a prospective cohort study. *Scand J Trauma Resusc Emerg Med* 20:28. <https://doi.org/10.1186/1757-7241-20-28>
4. Bingisser R, Nickel CH (2019) The last decade of symptom-oriented research in emergency medicine: triage, work-up, and disposition. *Swiss Med Wkly* 149. <https://doi.org/10.4414/smww.2019.20141>
5. Blaschke S (2018) Projektstruktur und Methodik. <http://optinofaprojekt.uni-goettingen.de/startseite/projektstruktur-und-methodik/>. Zugegriffen: 25.12.2020
6. Brammen D, Greiner F, Kulla M et al (2020) Das AKTIN-Notaufnahmeregister – kontinuierlich aktuelle Daten aus der Akutmedizin. *Med Klin Intensivmed Notfmed*. <https://doi.org/10.1007/s00063-020-00764-2>
7. Bundesamt für Soziale Sicherung (2020) Richtlinie zur Förderung von Vorhaben zur Digitalisierung der Prozesse und Strukturen im Verlauf eines Krankenaufenthaltes von Patientinnen und Patienten nach § 21 Absatz 2 KHStFV
8. Chan W, Mason J, Grock A (2018) The long and winding triage road. *Ann Emerg Med* 71:575
9. Chen T, Guestrin C (2016) Xgboost: A scalable tree boosting system. S 785–794
10. Choi SW, Ko T, Hong KJ, Kim KH (2019) Machine learning-based prediction of Korean triage and acuity scale level in emergency department patients. *Healthc Inform Res* 25:305–312. <https://doi.org/10.4258/hir.2019.25.4.305>
11. Chollet F (2017) Deep learning with python Bd. 1. Manning Publications CO, Greenwich
12. Christ M, Grossmann F, Winter D et al (2010) Triage in der Notaufnahme. *Dtsch Arztebl Int* 107:892–898
13. Coslovsky M, Takala J, Exadaktylos AK et al (2015) A clinical prediction model to identify patients at high risk of death in the emergency department. *Intensive Care Med* 41:1029–1036. <https://doi.org/10.1007/s00134-015-3737-x>
14. Dugas AF, Kirsch TD, Toerper M et al (2016) An electronic emergency triage system to improve patient distribution by critical outcomes. *J Emerg Med* 50:910–918
15. Emergency Nurses Association Implementation Handbook Edition 2020 ESI Emergency Severity Index Version 4 2020.
16. Fernandes M, Vieira SM, Leite F et al (2020) Clinical decision support systems for triage in the emergency department using intelligent systems: a review. *Artif Intell Med* 102:101762. <https://doi.org/10.1016/j.artmed.2019.101762>
17. Finkelstein SN (2020) Predicting intensive care unit admission among patients presenting to the emergency department using machine learning and natural language processing
18. Gemeinsamer Bundesausschuss Regelungen zu einem gestuften System von Notfallstrukturen in Krankenhäusern. <https://www.g-ba.de/richtlinien/103/>. Zugegriffen: 20. Dez. 2020
19. Goto T, Camargo CA, Faridi MK et al (2019) Machine learning-based prediction of clinical outcomes for children during emergency department triage. *JAMA Netw Open* 2:e186937–e186937
20. Graham B, Bond R, Quinn M, Mulvenna M (2018) Using data mining to predict hospital admissions from the emergency department. *IEEE Access* 6:10458–10469
21. Haserück A (2020) Elektronische Patientenakte: Testphase startet. <https://www.aerzteblatt.de/archiv/217190/Elektronische-Patientenakte-Testphase-startet>. Zugegriffen: 10. Jan. 2021
22. Hinson JS, Martinez DA, Cabral S et al (2019) Triage performance in emergency medicine: a systematic review. *Ann Emerg Med* 74:140–152. <https://doi.org/10.1016/j.annemergmed.2018.09.022>
23. Hong WS, Haimovich AD, Taylor RA (2018) Predicting hospital admission at emergency

- department triage using machine learning. PLoS ONE 13:e201016
24. Jordi K, Grossmann F, Gaddis GM et al (2015) Nurses' accuracy and self-perceived ability using the Emergency Severity Index triage tool: a cross-sectional study in four Swiss hospitals. Scand J Trauma Resusc Emerg Med 23:62
25. Joseph JW, Leventhal EL, Grossestreuer AV et al (2020) Deep-learning approaches to identify critically ill patients at emergency department triage using limited information. J Am Coll Emerg Physicians Open 1:773–781. <https://doi.org/10.1002/emp2.12218>
26. Kwon J, Lee Y, Lee Y et al (2018) Validation of deep-learning-based triage and acuity score using a large national dataset. PLoS ONE 13:e205836
27. Levin S, Toerper M, Hamrock E et al (2018) Machine-learning-based electronic triage more accurately differentiates patients with respect to clinical outcomes compared with the emergency severity index. Ann Emerg Med 71:565–574
28. Luber S, Litzel N Was ist ein Neuronales Netz? <https://www.bigdata-insider.de/was-ist-ein-neuronales-netz-a-686185/>. Zugriffen: 10. Jan. 2021
29. Luber S, Litzel N Was ist Natural Language Processing? <https://www.bigdata-insider.de/was-ist-natural-language-processing-a-590102/>. Zugriffen: 10. Jan. 2021
30. Malinowska A, Pitasch L, Geigy N et al (2019) Modification of the emergency severity index improves mortality prediction in older patients. West J Emerg Med 20:633
31. Miles J, Turner J, Jacques R et al (2020) Using machine-learning risk prediction models to triage the acuity of undifferentiated patients entering the emergency care system: a systematic review. Diagn Progn Res 4:1–12
32. Möckel M, Reiter S, Lindner T. et al. (2020) „Triagierung“ – Ersteinschätzung von Patienten in der zentralen Notaufnahme. Med Klin Intensivmed Notfmed 115:668–681. <https://doi.org/10.1007/s00063-019-0589-0>
33. Pourasghar F, Tabrizi JS, Ala A, Daemi A (2016) Validity of the electronic triage system in predicting patient outcomes in Tabriz, Iran: a cross-sectional study. Bull Emerg Trauma 4:211
34. Raita Y, Goto T, Faridi MK et al (2019) Emergency department triage prediction of clinical outcomes using machine learning models. Crit Care 23:64
35. Richardson SK, Ardagh M, Gee P (2005) Emergency department overcrowding: the Emergency Department Cardiac Analogy Model (EDCAM). Accid Emerg Nurs 13:18–23. <https://doi.org/10.1016/j.aeen.2004.10.010>
36. Searle J, Muller R, Slagman A et al (2015) Überfüllung der Notaufnahmen. Notfall Rettungsmed 18:306–315. <https://doi.org/10.1007/s10049-015-0011-2>
37. Sektion Notaufnahmeprotokoll der DIVI DIVI-Notaufnahmeprotokoll Modul Basis (2015). <https://www.divi.de/joomlatools-files/docman-files/publikationen/notaufnahmeprotokoll/notaufnahmeprotokoll-version-2015-1/20150313-publikationen-1-basis-notaufnahmeprotokoll-v-2015-1.pdf>
38. Shen (2020) Interpretability in machine learning: an overview. <https://thegradient.pub/interpretability-in-ml-a-broad-overview/>. Zugriffen: 14. Jan. 2021
39. Spahn I, Sahmel K-H (2018) Mit Ersteinschätzungssystem zeitnah Dringlichkeiten priorisieren. Pflegezeitschrift 71:34–38. <https://doi.org/10.1007/s41906-018-0721-4>
40. Stewart J, Sprivilis P, Dwivedi G (2018) Artificial intelligence and machine learning in emergency medicine. Emerg Med Australas 30:870–874. <https://doi.org/10.1111/1742-6723.13145>
41. Wagner S Logistische Regression – Modell und Grundlagen. https://www.inwt-statistics.de/blog-artikel-lesen/Logistische_Regression.html. Zugriffen: 10. Jan. 2021
42. wikipedia (2020) Random Forest. Zugriffen: 25.11.2020
43. Zachariasse JM, Seiger N, Rood PPM et al (2017) Validity of the Manchester Triage System in emergency care: a prospective observational study. PLoS ONE 12:e170811. <https://doi.org/10.1371/journal.pone.0170811>
44. Zlotnik A, Alfaro MC, Pérez MCP et al (2016) Building a decision support system for inpatient admission prediction with the manchester triage system and administrative check-in variables. Comput Inform Nurs 34:224–230. <https://doi.org/10.1097/CIN.0000000000000230>