

Notfall Rettungsmed 2023 · 26:401–406
<https://doi.org/10.1007/s10049-021-00974-x>
 Angenommen: 7. Dezember 2021
 Online publiziert: 10. Januar 2022
 © Der/die Autor(en) 2022



Einsatz neuronaler Netze in der Notaufnahme

Eine Illustration anhand der Prognose der stationären Aufnahme

Carolin Weberskirch¹ · Uta Pigorsch¹ · Patric Tralls² · Sebastian Rachuba¹

¹ Schumpeter School for Business and Economics, Bergische Universität Wuppertal, Wuppertal, Deutschland

² Zentrale Notfallambulanz, Städtisches Klinikum Solingen gGmbH, Solingen, Deutschland

Zusammenfassung

Hintergrund: Krankenhäuser generieren einen Teil ihrer stationären Fälle aus ungeplanten Einweisungen über die zentrale Notfallambulanz (ZNA). Die Vorbereitung der Aufnahme benötigt üblicherweise eine ärztliche Entscheidung. Die resultierende Vorbereitungszeit für die Normalstation ist mitunter nicht ausreichend und es entstehen Verzögerungen.

Ziel der Arbeit/Fragestellung: Anhand der Prognose der Wahrscheinlichkeit einer stationären Aufnahme soll der potenzielle Nutzen des Einsatzes künstlicher neuronaler Netze (KNN) in der ZNA aufgezeigt werden. Dabei stellt sich die Frage, ob Routinedaten, welche in fast jeder ZNA bereits zum Zeitpunkt der Ersteinschätzung zur Verfügung stehen, einen Beitrag zur Reduktion von Verzögerungen bei der stationären Aufnahme leisten können.

Material und Methoden: Auf Grundlage von beschränkten und anonymisierten Routinedaten aus einem Krankenhausinformationssystem wird für eine ZNA ein KNN entwickelt, das die Vorhersage der stationären Aufnahme ermöglicht. Die Implementierung des KNN erfolgt über die Open-Source-Software R.

Ergebnisse: Unter Anwendung von Routinedaten erzielt das KNN eine Genauigkeit von 76,64 %. Die Sensitivität, d. h. der Anteil korrekt vorhergesagter Patientenaufnahmen, liegt bei 66,93 % und damit niedriger als die Spezifität (Anteil korrekt vorhergesagter Nichtaufnahmen), die 82,13 % beträgt.

Diskussion: Bereits unter Verwendung von Routinedaten können KNN einen wertvollen Beitrag für die Ablaufplanung in der ZNA leisten. Es ist zu erwarten, dass zusätzliche Variablen, wie z. B. das Patientenalter, die Prognosegüte steigern.

Schlüsselwörter

Zentrale Notfallambulanz · Stationäre Aufnahme · Neuronale Netze · Prognose · Routinedaten

Überfüllung von zentralen Notfallambulanzen (ZNA) ist ein zentrales Thema in der Diskussion um Notfallversorgung in Deutschland. Ursachen einer Überfüllung von ZNA sind Verzögerungen im Patientenfluss, konkret beim Übergang in den stationären Bereich. Frühzeitig verfügbare Informationen, ob ein Patient stationär aufgenommen werden muss, können helfen, diesen Patientenfluss zu optimieren. Bei der Triage erhobene Informationen können als Grundlage für

Prognosen der Wahrscheinlichkeit einer stationären Aufnahme genutzt werden.

Einleitung und Ziel der Untersuchung

In einer Studie der PricewaterhouseCoopers GmbH halten neun von zehn der Befragten die deutschen Notaufnahmen für überlastet [11]. Die Folgen überfüllter ZNA („overcrowding“) sind gravierend. Neben dem gesundheitlichen Risiko für die



QR-Code scannen & Beitrag online lesen

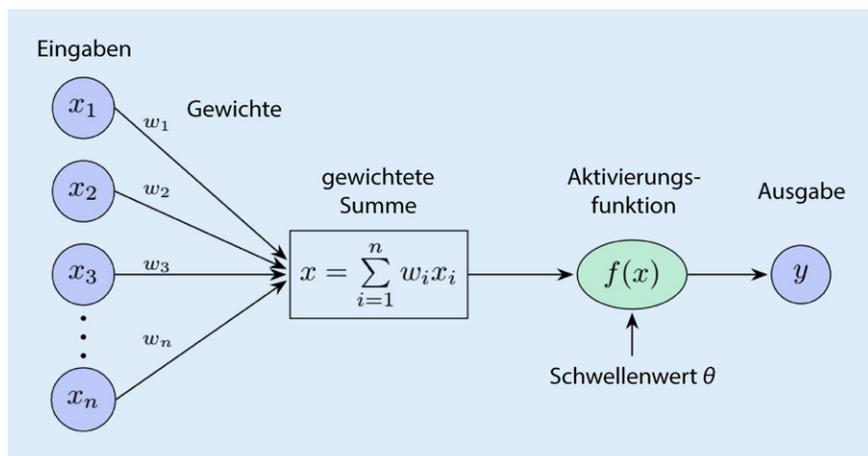


Abb. 1 ▲ Aufbau eines künstlichen Neurons

Patienten führt „overcrowding“ zu Überlastung des Personals, wodurch effiziente Arbeitsabläufe kaum möglich sind [5]. In vielen Studien werden Probleme im Patientenfluss (d. h. beim Übergang in den stationären Bereich, das sogenannte „boarding“) als zentrale Ursache genannt. Ein effizientes Betten- bzw. Aufnahmemanagement erfordert die Verfügbarkeit aktueller Informationen im Hinblick auf freie und benötigte Stationsbetten. Die Übermittlung dieser Informationen an das Management ist aufgrund der vielen Schnittstellen im Krankenhaus meist schwierig [4, 12]. Eine automatisierte Verarbeitung verfügbarer Informationen kann logistische Prozesse, wie bspw. Bettenanforderungen, vereinfachen. Eine Möglichkeit, aktuelle Informationen über die potenziell erforderlichen Bettenkapazitäten zu erhalten, bietet der Einsatz von künstlicher Intelligenz, konkret von maschinellen Lernmethoden, wie etwa künstlichen neuronalen Netzen (KNN). Diese können Muster in den Patientendaten erkennen und darauf basierend Prognosen über die Wahrscheinlichkeit der stationären Aufnahme eines Patienten liefern. Die automatisierte Bereitstellung solcher Prognosen kann komplementär zur Erfahrung des medizinischen Personals für eine Verbesserung des Patientenflusses genutzt werden, um die Wahrscheinlichkeit für eine Überfüllung der ZNA zu vermindern [7]. Die Verwendung von KNN zeigte bereits in anderen, vergleichbaren Studien, z. B. bei der Optimierung der Triage, sehr gute Ergebnisse [6, 13].

Künstliche Neuronale Netze

KNN stellen eine Modellklasse des maschinellen Lernens dar, welche durch das biologische Nervensystem inspiriert wurde. ■ Abb. 1 stellt den Aufbau eines künstlichen Neurons dar, welcher dem der Nervenzelle nachempfunden ist. So werden bei der Nervenzelle über die Dendriten eintreffende Signale (Erregungen) am Axonhügel summiert und ein Erregungspotenzial aufgebaut, wobei die einzelnen Signale abhängig von ihrem Typ (hemmend oder erregend) sowie der Entfernung der jeweiligen Synapsen vom Axonhügel unterschiedlichen Einfluss auf den Grad der Erregung haben können. Überschreitet das Erregungspotenzial das Schwellenpotenzial, wird ein Aktionspotenzial gebildet, welches über das Axon und die Synapsen an andere Nervenzellen weitergeleitet wird [1]. Beim künstlichen Neuron sind die Eingangssignale x_1, \dots, x_n durch die Inputvariablen gegeben. Diese werden mithilfe von Gewichten w_1, \dots, w_n , welche den verschiedenen Eingaben unterschiedliche Relevanz zuweisen, zu einer Netzeingabe x aggregiert. Eine Aktivierungsfunktion f übersetzt dann die eingehende Netzeingabe unter Berücksichtigung eines Schwellenwerts in ein bestimmtes Ausgangssignal y , den Output [3]. Ähnlich zum Schwellenpotenzial legt der Schwellenwert fest, ab welchem Wert der Aktivierungsfunktion eine Ausgabe erzeugt wird.

Die konkret verwendete Aktivierungsfunktion wird vom Anwender bei der Spezifikation des KNN a priori festgelegt. Die

Art der Aktivierungsfunktion hängt typischerweise vom Anwendungsfall ab.

Ähnlich zum biologischen Nervensystem bestehen KNN aus mehreren Neuronen, die in unterschiedlicher Weise miteinander verbunden sein können. Die Anzahl der Neuronen, die konkrete Spezifikation der Aktivierungsfunktion sowie die Struktur der Verbindungen bestimmen maßgeblich die sogenannte Netzwerkarchitektur (Topologie) eines KNN [3, 8]. Diese muss bei der Anwendung von KNN a priori bzw. durch „trial and error“ festgelegt werden. Einen wesentlichen Bestandteil der Struktur stellt die Anzahl der Schichten im KNN dar. Beim einschichtigen KNN ist die Eingabe direkt mit der Ausgabe verbunden. Mehrschichtige KNN bestehen hingegen aus mehreren, in Schichten angeordneten Neuronen, bei denen einige der Ausgaben die Eingaben anderer Neuronen darstellen. Somit setzen sich mehrschichtige KNN aus der Eingabe und Ausgabe sowie aus dazwischenliegenden, sogenannten versteckten Schichten zusammen. Sie sind besonders geeignet für das Erlernen komplexer (beispielsweise nichtlinearer) Zusammenhänge. Wie viele solche Schichten ein KNN beinhaltet, hängt von dem zu lösenden Problem ab und wird durch den Anwender festgelegt. Mit zunehmender Komplexität des zu lösenden Problems steigt typischerweise die Anzahl der Schichten in einem KNN [10, 16].

Der Einsatz von KNN erfolgt im Wesentlichen in zwei Schritten: erstens der Modellierung und zweitens der eigentlichen Anwendung und Evaluierung (■ Abb. 2).

Schritt 1: Modellierung

Im Rahmen der *Modellierung* wird zunächst der Datensatz aufbereitet (Vereinheitlichung von Texteingaben) und bereinigt (Plausibilitätsprüfung). Darauf aufbauend wird, wie in ■ Abb. 2 dargestellt, vor dem Hintergrund der Variablenauswahl die Netzwerkarchitektur konkretisiert. Die erforderlichen Netzeingaben (x_1, \dots, x_n) werden identifiziert und die Anzahl der Schichten und die jeweilige Anzahl an Neuronen sowie die Aktivierungsfunktionen werden festgelegt. Im Anschluss an die Auswahl der Architektur des Modells wird ein Teil der Daten verwendet, um das KNN zu trainieren.

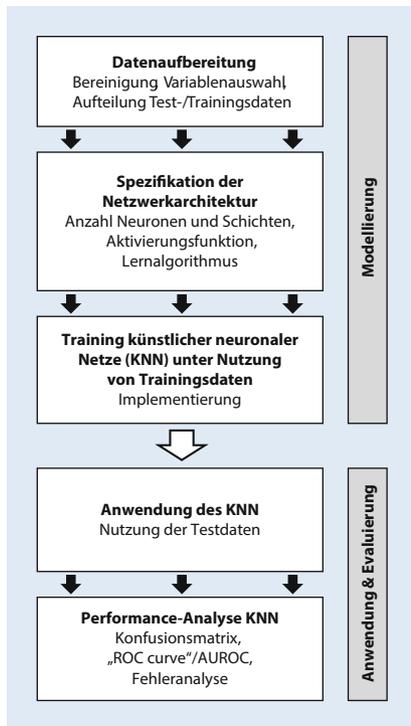


Abb. 2 ▲ Konzept zur Anwendung von KNN in der ZNA. ROC „receiver operating characteristics“, AUROC „area under the ROC“, ZNA Notfallambulanz, KNN künstlich neuronale Netze

Hierfür wird der bestehende Datensatz in einen Trainings- und einen Testdatensatz geteilt, wobei der Trainingsdatensatz üblicherweise größer ist. Durch das Training werden die Gewichte des KNN ermittelt. Die Festlegung der Gewichte erfolgt mithilfe eines Lernalgorithmus, welcher ausgehend von zufällig gewählten Initialgewichten anhand konkreter Prinzipien Anpassungen der Gewichte vornimmt [8]. Ziel der Anpassungen im Rahmen von überwachten Lernverfahren ist es, die Gewichte so festzulegen, dass ersichtlich wird, welche Merkmale (bzw. welche Kombination von Merkmalen) bedeutsam sind, um die bereits bekannte Entscheidung „Aufnahme ja/nein“ aus den Daten ableiten zu können.

Mittels der statistischen Programmiersprache R unter Version 3.6.2 [15] können die vorgestellten KNN unter Einsatz des Pakets ANN2 und der Funktion *neuralnet-work()* modelliert werden [2].

Schritt 2: Anwendung und Evaluierung

An die Modellbildung und das Trainieren des KNN schließt sich dessen *Anwendung* auf den Testdatensatz an. Eine Performance-Analyse ermöglicht es, die *Genauigkeit* der aus dem KNN gewonnenen Prognosen für diesen Testdatensatz zu *beurteilen*.

Fallstudie: Prognose der stationären Aufnahme

Im Folgenden wird demonstriert, dass KNN einen wertvollen Beitrag zur Prozessverbesserung in der ZNA leisten können, indem die Wahrscheinlichkeit einer stationären Aufnahme prognostiziert wird.

Schritt 1: Modellierung

Die Fallstudie basiert auf anonymisierten Realdaten aus der ZNA eines Krankenhauses der Maximalversorgung in Deutschland. In diesem Krankenhaus mit erweiterter Notfallversorgung wurden im Jahr 2018 rund 60.000 Fälle behandelt, davon ca. 38.000 in der ZNA. Prozentual war die ZNA an Montagen (16,3 %) und Dienstagen (14,8 %) stärker frequentiert (Wochenminimum am Sonntag mit 13,0 %). Die monatlichen Ankünfte schwanken zwischen rund 3300 im März und ca. 2900 im November. Im Tagesverlauf ist das Patientenaufkommen zwischen 4 und 6 Uhr am geringsten (rd. 1 % des Tagesvolumens je Stunde), das Maximum wird zwischen 10 und 13 Uhr erreicht (zwischen 6 und 7 % des Tagesvolumens je Stunde). Die Quote für stationäre Aufnahmen lag im betrachteten Zeitraum bei 35,12 %.

Datenaufbereitung. Zur Modellierung der KNN werden zunächst Inputvariablen ausgewählt und bereinigt, insbesondere unplausible bzw. unvollständige Datensätze wurden entfernt. Hierdurch hat sich der Datensatz auf 32.108 Fälle reduziert. In der so für die vorliegende Arbeit resultierenden Grundgesamtheit beträgt die Quote der aufzunehmenden Fälle 36,14 %. Verschiedene Studien zeigen, dass neben der Zuweisungsart und der Dringlichkeitsstufe ebenfalls die Merkmale Alter und frühere Krankenhausaufnahme rele-

vante Einflussfaktoren sind. Zudem sind die Hauptbeschwerde, das Geschlecht und die während der Ersteinschätzung erhobenen Vitalparameter des Patienten relevante Inputgrößen. Es werden auch zeitliche Variablen genannt, wie bspw. der Wochentag oder die Uhrzeit, zu der die ZNA aufgesucht wurde [7, 13, 14]. Häufig werden jedoch nicht alle diese Daten im Informationssystem des Krankenhauses gespeichert. Im Datensatz der hier betrachteten Fallstudie wurde z. B. das Patientenalter nicht erfasst. Die verfügbaren Inputvariablen werden in **Tab. 1** aufgeführt, wobei zwischen stetigen (Uhrzeit) und diskreten Merkmalen (Wochentag) zu unterscheiden ist. Stetige Variablen werden durch Transformation (Quartilsbildung) in diskrete Kategorien überführt. Die Quartilsbildung fasst den Tag in vier Zeitfenster von unterschiedlicher Länge zusammen, wobei in jedem Zeitfenster gleich viele Patienten (jeweils 25 %, vgl. **Tab. 1**) eintreffen. Die Informationen aus dem verwendeten Datensatz wurden in insgesamt 222 binäre Variablen umgewandelt. Ziel der Variablenumformung ist es, überschneidungsfreie Kategorien zu bilden, sodass schließlich für jedes Merkmal festgelegt werden kann, ob es zur Erklärung der Output-Entscheidung „Aufnahme: ja/nein“ beiträgt. Trifft beispielsweise die Zuweisungsart Rettungsdienst zu, wird der Variablenwert auf 1 gesetzt, andernfalls ist er 0. Die Output-Entscheidung wurde als binäre Variable „Aufnahme: ja/nein“ codiert. Das KNN hat zum Ziel, diejenigen Variablen (bzw. deren Kombination) zu identifizieren, die eine binäre Entscheidung „Aufnahme: ja/nein“ am besten prognostizieren. Das Trainieren des KNN erfolgt auf Basis von 75 % des gesamten Datensatzes, dem Trainingsdatensatz. Die restlichen 25 % werden als Testdaten zur Anwendung und Evaluierung der spezifizierten Netzwerke verwendet. Weil beide Datensätze durch zufälliges Sampling erzeugt werden, bleiben die Proportionen von aufzunehmenden und zu entlassenden Fällen nahezu gleich (beim Trainingsdatensatz beträgt die Quote 36,15 %, beim Testdatensatz 36,13 %).

Spezifikation der Netzwerkarchitektur. In dieser Fallstudie wurden verschiede-

Tab. 1 Verwendete Variablen		
Input	Anzahl	Kategorien
Zuweisungsart	8	Rettungsdienst, Notarzt, selbstständig, ...
Dringlichkeitsstufe	5	Blau, grün, gelb, orange, rot
Präsentationsdiagramm	46	Abdominelle Schmerzen bei Erwachsenen, ...
Leitsymptom	133	Kardialer Schmerz, ...
Vorstellung Fachbereich	6	ZNA, Unfallchirurgie, Urologie, ...
Ankunftszeit	4	Quartile (hier: 0–10, 10–14, 14–19, 19–24 Uhr)
Ankunftstag	7	Montag, Dienstag, Mittwoch, ...
Ankunftsmonat	12	Januar, Februar, März, ...
Output	Anzahl	Kategorien
Aufnahmeentscheidung	2	Stationäre Aufnahme, Entlassung

Tab. 2 Konfusionsmatrix – 1 versteckte Schicht mit 13 Neuronen, Schwellenwert 0,5				
		Output des KNN – Klassifizierung		
		Stat. Aufnahme	Entlassung	Summe
Tatsächliche Beobachtung	Stat. Aufnahme	1941	959	2900
	Entlassung	916	4211	5127
Summe		2857	5170	8027

KNN künstlich neuronale Netze

ne einschichtige Netzwerke mit maximal 30 Neuronen und zweischichtige Netzwerke mit jeweils maximal 10 Neuronen in den versteckten Schichten betrachtet. Für die Analyse im nächsten Schritt wurde aus den genannten Netzwerken eine Architektur mit einer versteckten Schicht und 13 Neuronen verwendet. Da die Wahrscheinlichkeit für eine stationäre Aufnahme eines Patienten prognostiziert werden soll, die Werte zwischen 0 und 1 annehmen kann, wurde hier zudem die sigmoidale Aktivierungsfunktion gewählt. Mit einem Entscheidungsschwellenwert wird festgelegt, ab welchem Output-Wert, der zwischen 0 und 1 liegt, das KNN die Entscheidung Aufnahme bzw. keine Aufnahme trifft. Überschreitet der Output den Schwellenwert, trifft das Modell die Prognose „Aufnahme“, ansonsten wird „Entlassung“ prognostiziert. Dieser Schwellenwert wird manuell festgelegt und hat Einfluss auf die Güte der Prognose.

Training des KNN. Mithilfe des Trainingsdatensatzes werden die Gewichte des KNN bestimmt. Hierbei werden durch einen Lernalgorithmus, die Backpropagation, im Programm R die Gewichte systematisch so angepasst, dass der Prognosefehler im Hinblick auf die tatsächlich erfolgte Aufnahme bzw. Entlassung minimiert wird. Das Netzwerk lernt also anhand

von Patientenmerkmalen bei gegebenem Ausgangssignal.

Schritt 2: Anwendung und Evaluierung der Prognosegüte

Die Anwendung der so trainierten Netzwerke auf den Testdatensatz ermöglicht die Beurteilung der jeweiligen Prognosegüte. In einem ersten Schritt wird zunächst verglichen, ob das Modell die Entscheidung korrekt oder nicht korrekt vorausgesagt hat. Liegt ein Prognosefehler vor, ist zwischen einem falsch-positiven und falsch-negativen Fehler zu unterscheiden. Für den vorliegenden Anwendungsfall bedeutet dies, dass das Modell entweder einen zu entlassenden Patienten als aufzunehmenden einstuft oder einen aufzunehmenden Patienten als zu entlassen klassifiziert. Diese Analysen können mithilfe einer Konfusionsmatrix durchgeführt werden, welche die Prognosen (Spalten der Tabelle) den tatsächlichen Beobachtungen (Zeilen) gegenüberstellt. **Tab. 2** zeigt die Konfusionsmatrix für ein Netzwerk mit einer versteckten Schicht und dreizehn Neuronen. Dieses Netzwerk erzielte im Vergleich mit anderen Architekturen die höchste Prognosegüte. Die Klassifizierung der präsentierten Konfusionsmatrix wurde anhand eines Schwellenwerts von 0,5 vorgenommen. Dies bedeutet, dass

alle Ausgangsprognosen mit einem Wert von mindestens 50 % der Klasse „stationäre Aufnahme“ und alle anderen der Klasse „Entlassung“ zugeordnet worden sind.

Die Gesamtzahl der Patienten im Testdatensatz ist 8027. Davon sind vom Netzwerk 1941 Patienten korrekt als stationär aufzunehmen und 4211 korrekt als zu entlassen klassifiziert worden. Im vorliegenden Fall wurden fälschlicherweise 959 Patienten als zu entlassen bzw. 916 als stationär aufzunehmen klassifiziert. Die Sensitivität des Modells, d. h. das Verhältnis korrekt prognostizierter positiver Fälle zu allen positiven Fällen, hier also den Aufnahmen, beträgt $1941/2900 = 66,93\%$. Die Spezifität, d. h. das Verhältnis korrekt prognostizierter negativer Fälle zu allen negativen Fällen, also keinen Aufnahmen, liegt bei $4211/5127 = 82,13\%$. Die Genauigkeit, welche definiert ist als das Verhältnis von korrekten Vorhersagen zur Anzahl der Beobachtungen im Testdatensatz, beträgt $(1941 + 4211)/8027 = 76,64\%$.

Im vorliegenden Datensatz ist das Verhältnis der stationär zu behandelnden und der zu entlassenden Patienten in etwa 3:5 und damit nicht gleich verteilt. Eine exklusive Fokussierung der Ergebnisevaluation auf die Kennzahl Genauigkeit kann bei unausgewogenen Datensätzen jedoch zu irreführenden Schlussfolgerungen führen, da eine hohe Genauigkeit auch nur dadurch zustande gekommen sein kann, dass das Modell fast ausschließlich die häufiger auftretende Klasse, hier die zu entlassenden Patienten, richtig klassifiziert, aber Probleme bei der Prognose der anderen Klasse, hier der stationär aufzunehmenden Patienten, hat. Neben Sensitivität und Spezifität berichten wir daher noch die Kennzahl Präzision, welche den Anteil der korrekt stationär Klassifizierten an allen stationär Klassifizierten angibt, sowie das harmonische Mittel aus Präzision und Sensitivität, den sogenannten F1-Score. Er liegt zwischen 0 und 1, wobei 1 perfekte Präzision und Sensitivität anzeigt. In unserer Fallstudie beträgt die Präzision $1941/2857 = 67,94\%$. Von allen stationär Klassifizierten sind somit ca. 68% korrekt als stationär klassifiziert worden, wohingegen 66,93% (= Sensitivität bzw. Recall) von allen stationär einzustufenden Patienten vom KNN auch als stationär eingestuft wurden. Präzision und Recall weisen

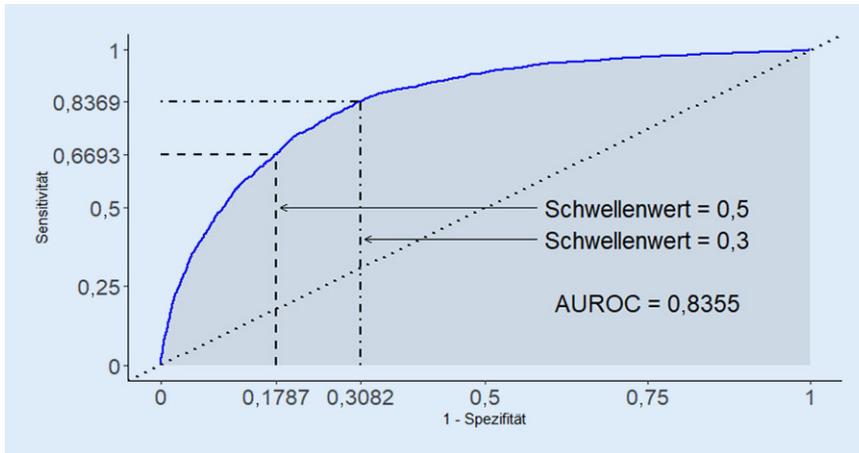


Abb. 3 ▲ „ROC curve“ – KNN mit einer versteckten Schicht und 13 Neuronen, Schwellenwerte 0,3 und 0,5. ROC „receiver operating characteristics“, AUROC „area under the ROC“, KNN künstliche neuronale Netze

somit eine ähnliche Größenordnung auf und der entsprechende F1-Score beträgt 0,67, was bedeutet, dass das KNN, obwohl es unter Nichtberücksichtigung der Unausgewogenheit des Datensatzes trainiert wurde, stationäre Fälle gut identifizieren kann und es nur beschränkt zu falsch-negativen und falsch-positiven Klassifizierungen kommt. Alternativ kann das Problem von unausgewogenen Datensätzen auch schon direkt beim Lernen des KNN berücksichtigt werden, indem ausgewogene Stichproben generiert werden, z. B. durch „over-“ oder „undersampling“ bzw. Generierung synthetischer Stichproben.

Die „receiver operating characteristics curve“ („ROC curve“) zeigt das Verhältnis zwischen Sensitivität und Spezifität für verschiedene Entscheidungsschwellenwerte zwischen 0 und 1. Je größer die Fläche unter der Kurve („area under the ROC curve“ [AUROC]) ist, umso höher ist die Genauigkeit des Modells [9], wobei die AUROC-Werte zwischen 0,5 und 1 liegen können. Ein Wert von 0,5 würde eine rein zufällige Klassifikation des KNN identifizieren, ein Wert von 1 bedeutet hingegen vollständige und fehlerfreie Erklärung durch das KNN. Die Kurve in **Abb. 3** verläuft deutlich oberhalb der Diagonalen und die AUROC beträgt 0,8355. Demnach handelt es sich bei der Prognose des vorliegenden Modells nicht um eine Zufallsentscheidung. In **Abb. 3** sind beispielhaft die Schwellenwerte 0,5 und 0,3 hervorgehoben. Die Vorteilhaftigkeit bestimmter Schwellenwerte ist von der Zielsetzung

bzw. der Bedeutung der jeweiligen Anteile in der Praxis abhängig, d. h., ob beispielsweise falsch-positive Fälle stärker wiegen als falsch-negative Vorhersagen. Wird der Schwellenwert von bislang 0,5 auf bspw. 0,3 geändert, erhöht sich die Sensitivität auf 83,69% bei gleichzeitiger Senkung der Spezifität auf 69,18%. Bei Veränderung des Schwellenwerts verändert sich auch die Modellgenauigkeit. Diese ist mit etwa 74,42% im Vergleich zum Entscheidungsschwellenwert von 0,5 leicht gesunken.

Diskussion der Ergebnisse

Eine niedrige Sensitivität bedeutet im vorliegenden Kontext, dass der Anteil richtiger Aufnahmeprognosen im Verhältnis zu allen Aufnahmen gering ist. Die Planung auf Basis falscher Aufnahmeprognosen führt zu einer ineffizienten Organisation der Aufnahmeprozesse. Für das Aufnahmemanagement bedeutet eine geringe Modellsensitivität, dass das Prognosemodell nur einen geringen Anteil der stationären Aufnahmen korrekt prognostizieren kann. Auf der anderen Seite bedeutet eine niedrige Spezifität, dass der Anteil richtiger Entlassungsprognosen an allen Entlassungen gering ist.

Falsch-positive Prognosen führen im vorliegenden Kontext zu unnötiger operativer Arbeit außerhalb der ZNA, wie bspw. zu erforderlichen Vorbereitungen auf den Stationen oder dem Anfordern von Transportdiensten. Falsch-negative Prognosen

verursachen hingegen keine zusätzlichen Ressourcenanforderungen in den aufnehmenden Bereichen, sodass aus Sicht des Krankenhauses vermutlich falsch-positive Prognosen schwerer gewichtet werden. Daher wäre im vorliegenden Kontext insbesondere eine hohe Sensitivität zu bevorzugen, was schließlich auch durch die Auswahl des Schwellenwerts gesteuert werden kann und in der Diskussion zu **Abb. 3** ausgeführt wurde.

Ziel dieser Fallstudie war es, den Patientenfluss zu den aufnehmenden Stationen zu verbessern. Dies kann in erster Linie geschehen, indem automatisiert eine möglichst verlässliche Information über eine Aufnahme frühzeitig aus der ZNA gemeldet wird. Eine vergleichbare Untersuchung aus einem Krankenhaus in Boston (USA) erzielte eine Genauigkeit von etwa 82%. Das dort vorgestellte Modell klassifiziert 87% korrekt als stationär aufzunehmende und 75% korrekt als zu entlassende Patienten. Die Autoren jener Studie identifizieren das Patientenalter und die Hauptbeschwerde als wesentlich für eine hohe Prognosegüte [6]. Die Hauptbeschwerde wird in der vorliegenden Fallstudie durch das Präsentationsdiagramm und das Leitsymptom des Manchester-Triage-Systems abgebildet. Das Patientenalter wird jedoch nicht im Krankenhausinformationssystem (KIS) erfasst. Trotz begrenzter Datenverfügbarkeit liefert das hier betrachtete KNN gute Ergebnisse. Es ist zu erwarten, dass die zusätzliche Berücksichtigung des Patientenalters die Prognosegüte des KNN noch steigern lässt. Eine Standardisierung der Dokumentation mit definierten Auswahlkategorien und Pflichtfeldern kann die Datenqualität erhöhen, sodass der Aufwand der Datenbereinigung gesenkt wird und eine umfassende Datenbasis zur Verfügung steht.

Modellbasierte Informationen, wie die durch ein KNN abgeleitete Prognose der stationären Aufnahme, können in Form von automatisierter Entscheidungsunterstützung den Patientenfluss verbessern. Die Modellprognose soll und kann keine medizinische Entscheidung ersetzen und dient lediglich als Entscheidungsunterstützung. Interessant wäre daher ein Vergleich der Ergebnisse des KNN mit einer ärztlichen Einschätzung zu Beginn der Behandlung in der ZNA.

Fazit für die Praxis

- KNN können selbst bei begrenzter Datenverfügbarkeit zum Zeitpunkt der Triage gute Prognosen liefern.
- Die Qualität der Prognose wird vom Entscheider durch die Modellarchitektur und speziell die Wahl des Schwellenwertes beeinflusst.
- Die Etablierung eines Ampelsystems (bspw. als Bildschirmnachricht im DIVI-Protokoll der ZNA mit Möglichkeit, eine Nachricht zu versenden) kann vorteilhaft sein, um den „Prognosestatus“ des jeweiligen Patienten frühzeitig zu erkennen.
- Die frühzeitige und automatisierte Weitergabe von Informationen an das Aufnahmemanagement kann das „Boarding“ beschleunigen.
- Durch Verwendung von vorhandenen Funktionen in der frei verfügbaren Programmiersprache R ist die Implementierung und Analyse des KNN verhältnismäßig einfach.

Korrespondenzadresse

Sebastian Rachuba
Schumpeter School for Business and Economics, Bergische Universität Wuppertal
Gaußstr. 20, 42119 Wuppertal, Deutschland
rachuba@uni-wuppertal.de

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

Einhaltung ethischer Richtlinien

Interessenkonflikt. C. Weberskirch, U. Pigorsch, P. Tralls und S. Rachuba geben an, dass kein Interessenkonflikt besteht.

Für diesen Beitrag wurden von den Autoren keine Studien an Menschen oder Tieren durchgeführt. Es wurden ausschließlich anonymisierte Daten verwendet, die keinerlei Rückschlüsse auf einzelne Patienten zulassen.

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 Ma-

Using neural networks in the emergency department. Illustration of how to predict the probability of inpatient admissions

Background: A portion of hospital admissions derive from unscheduled inpatients admitted through the emergency department (ED). Preparation for admission is routinely based on the decision by the physician in charge. The resulting time for the receiving ward to prepare for the admission is sometimes not sufficient and delays may occur.

Aim: The goal of this work is to demonstrate the benefits of using artificial neural networks (ANN) by illustrating its application within the context of predicting the probability that a patient in the ED will be admitted to the hospital. The question arises whether routinely collected patient data that are available in most EDs can already contribute to reducing the delay in the admission process.

Materials and methods: On the basis of limited and routinely collected data from a hospital information system, an ANN has been developed for an ED to predict whether admission to an inpatient ward is necessary. The ANN is implemented using the open source software R.

Results: Using routinely collected data, the ANN has an accuracy of 76.64%. The sensitivity, i.e., the share of correctly predicted admissions is 66.93%, which is lower than the specificity of 82.13% (share of correctly predicted discharges from ED).

Discussion: The results show that an ANN can make a valuable contribution to improve process management regarding admissions from the ED even if only routinely collected data are used. It is expected that additional variables, such as a patient's age, will increase the accuracy of the prediction.

Keywords

Emergency department · Admission · Neural networks · Prediction · Routinely collected data

terials 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. Brandes R, Lang F, Schmidt RF (2019) Physiologie des Menschen, 32. Aufl. Springer, Berlin, Heidelberg
2. CRAN (2020) Package ANN2. <https://CRAN.R-project.org/package=ANN2>. Zugegriffen: 15. März 2020
3. Dangeti P (2017) Statistics for machine learning: build supervised, unsupervised, and reinforcement learning models using both Python and R, 1. Aufl. Packt Publishing, Birmingham, Mumbai
4. Di Somma S, Paladino L, Vaughan L, Lalle I, Magrini L, Magnanti M (2015) Overcrowding in emergency department: an international issue. *Intern Emerg Med* 10(2):171–175
5. Fleischmann T, Amler N (2017) Patientenflusssteuerung und Wartezeitenmanagement – Medizinische und ökonomische Aspekte. In: Moecke H, Lackner CK, Dormann H, Gries A (Hrsg) Das ZNA-Buch. Medizinisch Wissenschaftliche Verlagsgesellschaft, Berlin, 576–80
6. Golmohammadi D (2016) Predicting hospital admissions to reduce emergency department boarding. *Int J Prod Econ* 182:535–544
7. Graham B, Bond R, Quinn M, Mulvenna M (2018) Using data mining to predict hospital admissions from the emergency department. *IEEE Access* 6(1):10458–10469
8. Hagan MT, Demuth HB, Hudson M, De Jesús O (2014) Neural network design, 2. Aufl.
9. Handelman GS, Kok HK, Chandra RV, Razavi AH, Huang S, Brooks M, Lee MJ, Asadi H (2019) Peering into the black box of artificial intelligence: evaluation metrics of machine learning methods. *AJR Am J Roentgenol* 212(1):38–43
10. Landau LJ, Taylor JG (1998) Concepts for neural networks: a survey, 1. Aufl. Springer, Berlin, New York
11. PricewaterhouseCoopers GmbH (2019) Notaufnahmen in der Not? <https://www.pwc.de/de/gesundheitswesen-und-pharma/berichtsband-notaufnahmen-in-not.pdf>. Zugegriffen: 8. März 2020
12. Proudlove N, Gordon K, Boaden R (2003) Can good bed management solve the overcrowding in accident and emergency departments? *Emerg Med J* 20(2):149–155
13. Raita Y, Goto T, Faridi MK, Brown DFM, Camargo CA, Hasegawa K (2019) Emergency department triage prediction of clinical outcomes using machine learning models. *Crit Care* 23(1):1–13
14. Rendell K, Koprinska I, Kyme A, Ebker-White A, Dinh MM (2019) The sydney triage to admission risk tool (START2) using machine learning techniques to support disposition decision-making. *Emerg Med Australas* 31(3):429–435
15. The R Foundation (2019) R-Project. <https://www.R-project.org/>. Zugegriffen: 15. März 2020
16. Thawakar O, Gajjewar P (2019) Training optimization of feedforward neural network for binary classification. 2019 International Conference on Computer Communication and Informatics (ICCCI), 51–9