

Positionspapier „Maschinelles Lernen und Künstliche Intelligenz in BOS-Leitstellen“

Positionspapier der AG „Maschinelles Lernen und
Künstliche Intelligenz in BOS-Leitstellen“
des Fachbeirats

Herausgeber:

Fachverband Leitstellen e.V.
Geschäftsstelle
Paulinenallee 28
24960 Glücksburg
E-Mail: info@fvlst.de
Website: www.fvlst.de

Erstellt von der AG „Maschinelles Lernen und Künstliche Intelligenz in BOS-Leitstellen“ des Fachbeirats des Fachverbands Leitstellen e.V.

Vertreter des Vorstands: Volkmar Lang

Leitung der AG: Dr.-Ing. Melanie Reuter-Oppermann, Felix Liebner, Volkmar Lang

Version 1.0
10. Mai 2020

Versionshistorie:

Versionsnummer	Datum	Änderungen
V1.0	10. Mai 2020	Veröffentlichung

Inhaltsverzeichnis

INHALTSVERZEICHNIS	3
KURZE ZUSAMMENFASSUNG	4
1 EINLEITUNG UND MOTIVATION	4
2 FORSCHUNG IM BEREICH DER KÜNSTLICHEN INTELLIGENZ	5
3 KURZE EINFÜHRUNG IN MASCHINELLES LERNEN	8
4 IST-ZUSTAND: GEFAHRENABWEHR IN DEUTSCHLAND	10
5 IST-ZUSTAND: GEFAHRENABWEHR INTERNATIONAL	11
6 EINSATZMÖGLICHKEITEN VON ML UND OR IN DER LEITSTELLE	11
7 WELCHEN (OPTIMIERUNGS-)BEDARF HABEN DIE LEITSTELLEN TATSÄCHLICH?	13
8 ANFORDERUNGEN AN DEN EINSATZ VON KÜNSTLICHER INTELLIGENZ IN LEITSTELLEN	17
9 ZUSAMMENFASSUNG UND FAZIT	18
10 REFERENZEN	20

Kurze Zusammenfassung

In den letzten Jahren haben Nachrichten, Forschung und Berichte zu Künstlicher Intelligenz stetig zugenommen. Vor allem Verfahren des maschinellen Lernens, als derzeit wichtigste Methode der künstlichen Intelligenz, werden bereits in vielen Bereichen des täglichen (Arbeits-) Lebens eingesetzt. Allerdings finden diese Methoden in BOS-Leitstellen innerhalb Deutschlands praktisch noch keine Anwendung. Daher werden in diesem Positionspapier die Potentiale und Möglichkeiten von Verfahren des maschinellen Lernens sowie des Operations Research für den Einsatz in BOS-Leitstellen aufgeführt und diskutiert.

1 Einleitung und Motivation

Polizeiliche und nicht-polizeiliche Leitstellen (BOS-Leitstellen) sind Einrichtungen mit umfangreicher, teils hochverfügbarer oder gar fehlertoleranter technischer Ausstattung. Sie nutzen die verschiedensten Datenbanken und stehen mit jedem Auskunfts- und Hilfeersuchen sowie jedem Einsatz vor der Aufgabe, bestmögliche Lösungswege für alle aufkommenden Probleme finden zu müssen. Dazu werden auch anhand der Vergangenheitsdaten soweit möglich Prozessverbesserungen vorgenommen. Sowohl in der Praxis als auch in der Forschung lassen sich erste Ansätze finden, um künstliche Intelligenz (KI), vor allem Methoden des maschinellen Lernens (ML), in Leitstellen einzusetzen. Genannt seien hier die Versuche in der Leitstelle Kopenhagen, die Einsatzsachbearbeiter*innen bei der Identifikation von Kreislaufstillständen und Schlaganfällen mit Hilfe einer verbesserten Spracherkennung durch sogenanntes „Deep-Learning“ zu unterstützen, und die Forschungsarbeiten von Dr. Reuter-Oppermann zur Optimierung der Krankentransportplanung und der strategischen und operativen Verbesserung der Rettungsdienstvorhaltung [1,2].

Vor diesem Hintergrund hat sich im Fachverband Leitstellen e. V. eine Arbeitsgruppe unter dem Titel „Maschinelles Lernen und künstliche Intelligenz in BOS-Leitstellen“ gebildet. Ziel der AG ist die Identifikation von möglichen Einsatzfeldern dieser Technologien in den BOS-Leitstellen, sowie die Diskussion der im Kontext der gesamten Entwicklung der künstlichen Intelligenz ebenfalls gesamtgesellschaftlich relevanten Fragestellungen in Bezug auf Gesetzgebung, Ethik und Moral, sowie Sicherheit der Daten und Anwendungen. Die AG hat vom Vorstand den Auftrag bekommen, konkrete Anwendungsfälle darzustellen, Zeithorizonte aufzuzeigen und Möglichkeiten zur Übertragung von Forschungsergebnissen in die Prozesse von Leitstellen zu erarbeiten.

In Deutschland sind polizeiliche und nicht-polizeiliche Gefahrenabwehr – je nach Kontext und Einschätzung der Vertraulichkeitsstufe – mehr oder weniger weit voneinander entfernt. Zweifelsohne sind jedoch bei der Entscheidungshoheit, sowie

bei Entscheidungs- und Ausführungsprozessen deutliche Unterschiede auszumachen, weshalb sich die Arbeitsgruppe auf den Bereich der nicht-polizeilichen Gefahrenabwehr fokussiert. Es erfolgt aber die Betrachtung und Einbindung der polizeilichen Gefahrenabwehr, wenn sinnvoll und notwendig.

Dieses Positionspapier gibt einen ersten Überblick über die derzeitigen Entwicklungen in Praxis und Forschung und stellt die Anforderungen der Leitstellen aus praktischer Sicht dar. Es werden verschiedene Methodenbereiche, wie das maschinelle Lernen oder Operations Research (mathematische Optimierung), als Ansätze innerhalb der künstlichen Intelligenz vorgestellt.

Juristische Aspekte werden in diesem Positionspapier nicht tiefgründig untersucht, da gegenwärtig kein konkretes Betätigungsfeld oder Projekt, folglich auch kein konkreter Kontext, vorliegt und zudem die Autor*innen auf ein Vorantreiben des Themas und das Aufzeigen von Möglichkeiten abzielen.

2 Forschung im Bereich der Künstlichen Intelligenz

Künstliche Intelligenz (engl. Artificial Intelligence oder kurz AI) erlebt seit einigen Jahren einen großen Aufschwung in Forschung und Praxis. Als Gründe für den Aufschwung („Rise of AI“) werden häufig drei Dinge angeführt [3]:

1. Es sind immer mehr Daten verfügbar, die für den Einsatz von KI eine wesentliche Grundlage darstellen.
2. Dank der technischen Entwicklungen sind in Forschung und Praxis Computersysteme mit ausreichend Rechenkapazitäten verfü- und bezahlbar, um die großen Datenmengen zu verarbeiten.
3. Aufgrund von Automatisierung und Skalierbarkeit, zum Beispiel von Prozessen, haben Unternehmen Interesse am Einsatz von KI in ihren Unternehmen.

Etwas uneinig ist sich die Forschung, was genau unter KI verstanden wird. In der Praxis passiert es häufig, dass bereits einfachste Software als KI bezeichnet wird. Oftmals wird künstliche Intelligenz synonym mit Verfahren des maschinellen Lernens verwendet. Tatsächlich sind ML-Verfahren aber nur eine mögliche Methode bei der Umsetzung von künstlicher Intelligenz und keinesfalls gleichzusetzen. ML-basierte Systeme analysieren oft lediglich die vorhandenen Daten und ermitteln zum Beispiel Vorhersagen für zukünftige Entwicklungen. Fortgeschrittene Implementierungen geben Vorschläge, zum Beispiel für Planungsprobleme wie die Zuweisung von Fahrzeugen zu Aufträgen. Auch bei diesen Systemen entscheidet der Mensch, bereitet in vielen Fällen die Daten vor, wählt die Verfahren und trainiert diese mit den Daten. Passiert dies für eine ausgewählte Aufgabe automatisch, so spricht man von einer „schwachen KI“. Im Vergleich dazu wäre eine „starke KI“ genauso intelligent wie ein Mensch, könnte also alle, auch übergreifende Entscheidungen abwägen, treffen und aus den Ergebnissen lernen [4].

Nachteil vieler Modelle des maschinellen Lernens ist der Bedarf nach einer großen Menge qualitativ hochwertiger Eingabedaten. Wenn es zum Beispiel um die Vorhersage von Notfällen geht, betrifft dies zum einen die Einsatzzahlen pro Jahr, zum anderen auch die Anzahl an Jahren mit gleicher Datenstruktur und –qualität. Diese Herangehensweise stellt eine große Herausforderung an die Leitstellen bzw. an die Entwicklung von in der Praxis verwendbaren Modellen dar. Aufgrund der geographischen, sozio- demographischen und insbesondere rechtlichen Strukturen und hieraus resultierenden Unterschiede können Daten von mehreren Leitstellen nicht einfach zusammengefügt und zum Trainieren von ML-Modellen verwendet werden. Der Austausch von Daten ist auch aus rechtlicher Sicht nicht immer einfach oder überhaupt möglich. Aktuelle Forschung beschäftigt sich daher mit der Übertragbarkeit von trainierten ML-Modellen. Die Frage aus dieser Sicht lautet: *„Ist es möglich, ML-Modelle mit den Daten einer Leitstelle zu trainieren, für die viele und qualitativ hochwertige Daten existieren, und die trainierten Modelle in anderen Leitstellen zu verwenden?“* Dabei ist wichtig zu verinnerlichen, dass tatsächlich nur die trainierten Modelle ohne Eingabedaten übertragen werden. Auf die Eingabedaten sind dann (in der Regel) keine Rückschlüsse mehr möglich. Eine derartige Verfahrensweise würde nicht nur dem Datenschutz gerecht werden, sondern auch den Aufwand drastisch reduzieren, da Modelle nur ein oder wenige Male trainiert werden müssten, statt einzeln und von Neuem für jede Leitstelle in Deutschland.

Ein aus unserer Sicht weiterer wichtiger und vielversprechender Forschungsbereich für Leitstellen, Feuerwehr und Rettungsdienst in Deutschland ist der Bereich des Operations Research (OR) bzw. der mathematischen Optimierung [5]. Mit Hilfe des OR lassen sich unter anderem logistische Fragestellungen wie die Standortplanung von Wachen und Fahrzeugen oder die Planung von Krankentransporten und Streifenbezirken/-routen beantworten [1,2]. In der Regel wird bei diesem Ansatz zuerst ein mathematisches Modell aufgestellt, das mit Hilfe von Software-Tools, sogenannten mathematischen Solvern, implementiert und gelöst werden kann. Ein Modell besteht dabei aus einer oder mehreren Zielfunktionen, die abbilden, mit welchem Ziel die Optimierung gelöst werden soll. Ziele können zum Beispiel die Reduktion der Kosten für Wachenstandorte oder den Einsatz von KTWs sein. Kann eine Lösung für ein Modell bestimmt werden, so ist dies die optimale, jeweils bestmögliche Lösung für das dem Modell zugrundeliegenden Problem. Bei der Modellierung von Praxisproblemen kommt es allerdings häufig vor, dass die Modelle zu komplex sind, um optimal gelöst werden zu können. Dann werden Näherungsverfahren, so genannte Heuristiken, verwendet, um in kurzer Zeit möglichst gute Lösungen zu bestimmen.

Ein weiterer relevanter Forschungsbereich beschäftigt sich mit den sogenannten Mensch-Maschine-Interaktionen. Dabei sind mit Maschinen nicht nur jegliche Art von (digitalen) Geräten oder Computern gemeint, sondern zum Beispiel auch ein hydraulisches Rettungsgerät. Es wird untersucht, wie Menschen mit diesen

Maschinen interagieren. Ein angrenzender Forschungsbereich beschäftigt sich mit den sogenannten Nutzerassistenzsystemen. Ziel dieser oft technischen bzw. computer-basierten Systeme ist es, den Menschen in seiner Handlung bestmöglich zu unterstützen. Ein Beispiel aus dem täglichen Leben sind die Fahrerassistenzsysteme in modernen Fahrzeugen. Nutzerassistenzsysteme zum Einsatz in Leitstellen können Methoden des ML oder des OR im Kern beinhalten, um Mitarbeiter*innen zum Beispiel bei der Disposition von Fahrzeugen zu unterstützen [6]. Wichtig bei der Entwicklung solcher Systeme ist nicht nur der Kern, der die eigentliche Funktion darstellt, sondern auch das Design des Systems um den Kern. Unabhängig von der Qualität der eigentlichen Funktion führt fehlendes Vertrauen in ein System häufig zu einer Ablehnung. Stehen Nutzer*innen für eine Fragestellung zwei oder mehr Alternativen zur Verfügung, so müssen Nutzer*innen durch entsprechende Transparenz des Systems in die Lage gebracht werden, eine fundierte Entscheidung zu treffen.

Es ist nicht zu erwarten, dass in absehbarer Zeit eine „starke KI“ entwickelt werden wird, die in der Praxis eingesetzt werden kann, vor allem nicht im öffentlichen Bereich. Die Forschung ist aktuell noch weit davon entfernt [3]. Daher werden wir uns im Folgenden nicht mehr mit künstlicher Intelligenz im Allgemeinen, sondern mit den Verfahren des maschinellen Lernens und des Operations Research als zwei wichtigen Säulen für zukünftige Entwicklungen beschäftigen, die aktuell schon in der Praxis der Gefahrenabwehr weltweit eingesetzt werden.

Eine Übersicht über die in der Rettungsdienstlogistik enthaltenen Planungsprobleme findet sich in [1]. Der Fokus lag und liegt dabei auf der Planung von Standorten für Rettungswagen und -wachen, dem wichtigsten strategischen Planungsproblem. Bis heute wurde eine Vielzahl von Modellen und Verfahren vorgeschlagen, für Regionen weltweit getestet und verwendet. Diese Modelle unterscheiden sich in den getroffenen Annahmen und bieten verschiedene Möglichkeiten. Manche nehmen zum Beispiel explizit die Nichtverfügbarkeit von RTW an, andere betrachten verschiedene Zeitperioden (zum Beispiel Jahreszeiten, Tageszeiten oder die nächsten 3-5 Jahre) und ermitteln ggf. abweichende Standortlösungen für diese Perioden. In den letzten Jahren beschäftigen sich die Wissenschaftler*innen im Bereich der nicht-polizeilichen Gefahrenabwehr vor allem mit der dynamischen Positionierung von Rettungsmitteln bzw. mit der Umpositionierung in Echtzeit, sowie mit der unmittelbaren Disposition. Neueste Forschung untersucht, inwieweit Verfahren des maschinellen Lernens für die Vorhersage von Notfällen verwendet werden können [7]. Für den Bereich des Krankentransports gibt es bereits einige Veröffentlichungen, die Verfahren vorschlagen, mit denen Touren im Vorhinein sowie in Echtzeit geplant werden können [1].

Ein weiterer wichtiger Forschungszweig sind Untersuchungen zur Akzeptanz und Transparenz von KI-Verfahren mit folgenden primären Fragestellungen:

1. Wie können Verfahren so erstellt werden, dass ihr Ablauf und ihre Ergebnisse von Anwender*innen nachvollzogen werden können?
2. Wie können die Ergebnisse aufbereitet und erklärt werden, damit Anwender*innen den Ergebnissen vertrauen?
3. Welche zusätzlichen Möglichkeiten bestehen, um die Akzeptanz von KI-Verfahren in der Praxis zu erhöhen?

Forschungsgruppen wie das Fachgebiet für Wirtschaftsinformatik | Software & Digital Business der Technischen Universität Darmstadt, geleitet von Prof. Dr. Peter Buxmann, führen in verschiedenen Domänen Forschungsprojekte und Studien zu diesen Fragestellungen durch und sammeln dabei wichtige Erkenntnisse, die unter anderem für Leitstellen und den Rettungsdienst relevant sind [8].

3 Kurze Einführung in maschinelles Lernen

In diesem Abschnitt soll eine kurze Zusammenfassung der wesentlichen Bestandteile von ML-Verfahren gegeben werden. Eine ausführlichere Darstellung finden interessierte Leser*innen zum Beispiel in [4].

Verfahren des maschinellen Lernens lassen sich grundsätzlich in drei Bereiche unterscheiden:

1. Überwachtes Lernen (engl. supervised learning)
2. Unüberwachtes Lernen (engl. unsupervised learning)
3. Verstärkendes Lernen (engl. reinforcement learning).

Überwachtes Lernen bedeutet, dass Algorithmen mit „beschrifteten“ Daten trainiert werden. Dem Algorithmus wird die Unterscheidung zwischen den Trainingsdaten mitgegeben und er lernt ähnlich wie wir Menschen. Soll zum Beispiel eine Bilderkennung von Unfallbildern erstellt werden, so würde man dem Algorithmus mitgeben, was auf den Trainingsbildern zu sehen ist, zum Beispiel Fahrzeuge oder Personen. Verfahren des überwachten Lernens werden derzeit am häufigsten verwendet und es stehen dem Nutzer einige, zum Teil kostenlose Tools, wie zum Beispiel Weka [9] oder scikit-learn [10], zur Verfügung.

Algorithmen des unüberwachten Lernens sollen Muster selbst bestimmen und bekommen daher keine „beschrifteten“ Daten vorgegeben. Bei dem Beispiel der Bilderkennung würde der Algorithmus also nur die reine Sammlung an Bildern erhalten. Hinweise darauf, was sich auf den Bildern befindet, fehlen. Der Algorithmus erstellt selbst Kategorien der Bilder. Eine mögliche Kategorisierung wäre nach dem Inhalt der Bilder. Es kann auch nach ganz anderen Mustern sortiert werden, beispielsweise nach der Helligkeit der Bilder. Dass der Algorithmus Muster selbst erkennt, kann ein Vorteil sein, wenn z. B. ihm bis dahin unbekannte Bilder gezeigt werden. Es stellt allerdings vor allem mit Hinblick auf die praktische Verwertung auch

ein Risiko dar, wenn die Muster unbekannt sind und dann Entscheidungen nicht nachvollzogen werden können.

Algorithmen des verstärkenden Lernens sollen eine optimale Strategie für ein gegebenes Problem erlernen. Dazu wird eine zu maximierende Belohnungsfunktion verwendet. Über diese Funktion bekommt der Algorithmus eine Rückmeldung auf die zuvor gewählte Aktion, ohne dass ihm direkt gezeigt wird, welche Aktion die beste ist. Der Algorithmus muss selbst herausfinden, welche Aktionen die Belohnungsfunktion maximieren und zum Erreichen des Ziels führen.

Verfahren des maschinellen Lernens können für viele Anwendungsfälle hilfreich sein und werden heute bereits vielfach erfolgreich eingesetzt. Dennoch sind sie keine Allheilmittel und können oftmals, wenn man ihre Funktionsweise kennt, leicht ausgetrickst werden. Dies gilt es bei sicherheitsrelevanten bzw. -kritischen Anwendungen auszuschließen bzw. zu verhindern. Daher müssen Verfahren vor ihrer Anwendung genauestens geprüft werden. Dazu gehört, die Qualität der Verfahren unter Verwendung vordefinierter Maße zu bestimmen. Ein häufiger Ansatz, vor allem bei Klassifizierungsproblemen, ist die Erstellung einer sogenannten Konfusionsmatrix (Abb. 1). Bei einem binären Klassifizierungsproblem kann eine Variable die Werte 1 (ja) oder 0 (nein) erhalten. Ziel des Algorithmus ist es, diese Variable richtig vorherzusagen. Dafür wird mit einer Trainingsmenge trainiert und die Vorhersage dann für eine Testmenge durchgeführt, für welches man die tatsächlich zu bestimmenden Werte kennt. So kann man die Vorhersage mit den tatsächlichen Werten vergleichen. Es gibt für jeden Vergleich vier mögliche Fälle:

1. Richtig positiv (RP): Die Vorhersage ist „ja“ und auch der tatsächliche Wert ist „ja“.
2. Falsch positiv (FP): Die Vorhersage ist „ja“ und der tatsächliche Wert ist „nein“.
3. Falsch negativ (FN): Die Vorhersage ist „nein“ und der tatsächliche Wert ist „ja“.
4. Richtig negativ (RN): Die Vorhersage ist „nein“ und auch der tatsächliche Wert ist „nein“.

		Tatsächlich	
		Ja	Nein
Vorhersage	Ja	RP	FP
	Nein	FN	RN

Abbildung 1: Konfusionsmatrix

Der Vergleich wird für alle Werte in der Testmenge durchgeführt und die summierte Anzahl der vier Fälle in die jeweilige Zelle eingetragen. Es ergeben sich verschiedene Maße, die einige oder alle der vier Parameter RP, FP, FN und RN in Beziehung setzen. Wichtig ist, dass man die Maße passend zur Anwendung auswählt. Geht es zum Beispiel um die Vorhersage von Herzinfarkten, so sind falsch positive Vorhersagen weniger gravierend als falsch negative. Es kann auftreten, dass zur Minimierung der falsch negativen Vorhersagen mehr falsch positive in Kauf genommen werden müssen. Es ist für den Einsatz entsprechender Verfahren in der Praxis sehr wichtig, diese Anpassungen transparent anzugeben, da zu viele falsch positive Vorhersagen die Akzeptanz der Nutzer*innen senken und/oder den Aufwand zu stark erhöhen könnten. Tritt ein solcher Fall auf, sollten Gegenmaßnahmen überlegt und gegebenenfalls der tatsächliche Nutzen des Systems diskutiert werden.

4 Ist-Zustand: Gefahrenabwehr in Deutschland

Im Rahmen der polizeilichen und nicht-polizeilichen Gefahrenabwehr kommen in Deutschland künstliche Intelligenz und Verfahren des maschinellen Lernens bei den Kernprozessen nur in wenigen, vereinzelt Projekten zum Einsatz. Ähnliche Ansätze zur Unterstützung der Einsatzsachbearbeiter*innen, wie sie zum Beispiel aus Dänemark (siehe Einleitung) bekannt sind, gibt es in Deutschland nicht oder zumindest nicht ausschließlich für den BOS-Markt entwickelt. Im Bereich der Peripherie der Leitstellen hält künstliche Intelligenz bereits Einzug, zum Beispiel nutzen Anwendungen zum Schutz vor Angriffen aus dem Internet (Virens Scanner) heute schon maschinelles Lernen zur Verbesserung der Erkennensrate von unerlaubten Zugriffen oder Schadsoftware. Softwaretools zur Social-Media-Analyse nutzen ebenso Mechanismen der künstlichen Intelligenz in Form von Suchbots.

Im Bereich der polizeilichen Gefahrenabwehr in Deutschland finden seit einigen Jahren Systeme des maschinellen Lernens Anwendung, wobei diese – trotz des Einflusses (positiv wie negativ) auf die Arbeit der Leitstellen – bislang die systemische Hürde in die Leitstelle noch zu nehmen haben. Derzeit erfolgt der Datenaustausch eher unregelmäßig und manuell. Dies betrifft sowohl den Einfluss der Ergebnisse des sogenannten Predictive Policing wie auch der maschinellen Verarbeitung und insbesondere Weitergabe der ausgewerteten Information aus Videomaterialien an die Leitstellen, respektive das Einsatzleitsystem zur Signalisierung und Weiterverarbeitung durch den Menschen. Die technische Machbarkeit wurde auf der PMRExpo 2019 und der GPEC 2020 eindrucksvoll bewiesen – die Hürden zur Umsetzung sind hier eher juristischer Natur, wobei der finale Beweis in Sachen tatsächlicher juristischer Hürden noch aussteht.

5 Ist-Zustand: Gefahrenabwehr international

Einen international vielbeachteten Ansatz zur Nutzung von maschinellem Lernen im Prozess der Notrufabfrage verfolgt die dänische Firma “Corti”, die ihre Verfahren in den vergangenen Jahren verfeinert und in Dänemark, Frankreich und Italien mit Unterstützung durch die EENA in einem Pilotprojekt getestet hat. Die EENA hat die Ergebnisse gemeinsam mit Corti publiziert [11]. Anliegen der Entwickler*innen von Corti ist es, die Einsatzsachbearbeiter*innen beim Erkennen von Herz-Kreislaufstillständen unabhängig von der Muttersprache der Anrufer*innen zu unterstützen. Zu diesem Zweck wurde die Anwendung mit historischen Daten aus den teilnehmenden Leitstellen trainiert, um dann im Einsatz den Disponent*innen signalisieren zu können, dass ein Herz-Kreislaufstillstand vorliegen könnte. Abhängig von Umfang und Qualität der historischen Daten konnte durchaus gezeigt werden, dass künstliche Intelligenz dabei helfen kann, lebensbedrohliche Zustände schneller und sicherer zu erkennen. Ein nutzbares System ist daraus bisher nicht entstanden. Weitere ähnliche Versuche die Notrufabfrage zu verbessern, gibt es in den USA unter Nutzung von IBM Watson Speech-to-Text und Watson Analytics oder durch Huawei u. a. im asiatischen Raum [12].

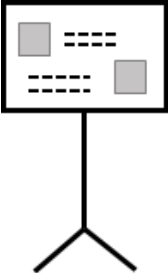
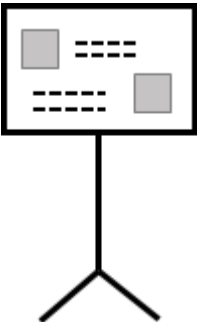

6 Einsatzmöglichkeiten von ML und OR in der Leitstelle

Bevor die konkreten Einsatzmöglichkeiten aufgeführt und beschrieben werden, wird zunächst eine Taxonomie für die Einordnung von technischen Systemen und KI-Anwendungen eingeführt. Diese ist in Tabelle 1 dargestellt.

Art der Leitstelle	Rettungsdienst		Feuerwehr	
Einsatzbereich	Medizinisch		Logistisch	
Methodik	Operations Research		Maschinelles Lernen	
Planungsebene	Strategisch		Taktisch	Operativ
Anwendungsfälle	Unterstützende und logistische Prozesse	Einsatzplanung	Einsatzannahme	Einsatzbearbeitung
Einsatzfall	Notfallrettung	Brand / Feuer / THL	Krankentransport	Sonstige Einsätze

Tabelle 1: Taxonomie für KI-Anwendungen in Leitstellen

Die möglichen Anwendungsfälle lassen sich nach den Kategorien „Unterstützende und logistische Prozesse“, „Einsatzplanung“, „Einsatzannahme“ und „Einsatzbearbeitung“ systematisieren. In Abbildung 2 sind eine Reihe von Anwendungsfällen und ihre Zuordnung zu den genannten Kategorien dargestellt.

<u>LEITSTELLE</u>			
<p>Unterstützende und logistische Prozesse</p> 	<p><u>Verfahren des Operations Research:</u></p> <ul style="list-style-type: none"> - Personalbedarfsplanung mit Prognosen für Tages- und Jahreszeit - Dienstplanung mit Berücksichtigung von Präferenzen/Wünschen der Arbeitnehmer*innen, sowie Vorgaben der Arbeitgeber*innen <p><u>Verfahren des Maschinellen Lernens</u></p> <ul style="list-style-type: none"> - Vorausschauende Wartung der Systeme (Predictive Maintenance) - Lageangepasste Überwachung und Steuerung von Licht und Klima im Leitstellenraum 		
<p>Einsatzplanung</p> 	<p><u>Verfahren des Operations Research:</u></p> <ul style="list-style-type: none"> - Planung von Standorten für Rettungs- und Feuerwachen und von Fahrzeugen - Dynamische Umpositionierung anhand von Positionsdaten der Fahrzeuge, sowie von beobachteten und vorhergesagten Einsätzen - Dienstplanung mit Berücksichtigung von Präferenzen/Wünschen und Vorgaben des Arbeitsgebers <p><u>Verfahren des maschinellen Lernens bzw. der Statistik</u></p> <ul style="list-style-type: none"> - Vorhersage von Notfällen (zeitlich und örtlich) unter Nutzung von externen Parametern (z. B. Wetter) - Erkennen von Häufungen akuter Erkrankungen (z. B. Infektionen) - Dynamische Lagedarstellung und –bewertung auf den verschiedenen Führungsebenen - Prognose weiterer unterstützender Prozesse z. B. bei Vermissten in Fließgewässern 		
<p>Einsatzannahme</p> 	<p><u>Verfahren des maschinellen Lernens:</u></p> <table border="0"> <tr> <td style="vertical-align: top;"> <ul style="list-style-type: none"> - Texterkennung / Spracherkennung <ul style="list-style-type: none"> o Automatische Übersetzungen o Priorisierung von Anrufen bei Überlaufsituationen o Erkennen von Krankheitsbildern o Vorannahme/Zuweisung von Notrufen </td> <td style="vertical-align: top;"> <ul style="list-style-type: none"> - Bilderkennung / Kamerabilder <ul style="list-style-type: none"> o Erkrankungen o Feuer, Unfälle, Schadenslagen etc. - Notruf-App mit Chatbots – dynamische Notrufabfrage </td> </tr> </table>	<ul style="list-style-type: none"> - Texterkennung / Spracherkennung <ul style="list-style-type: none"> o Automatische Übersetzungen o Priorisierung von Anrufen bei Überlaufsituationen o Erkennen von Krankheitsbildern o Vorannahme/Zuweisung von Notrufen 	<ul style="list-style-type: none"> - Bilderkennung / Kamerabilder <ul style="list-style-type: none"> o Erkrankungen o Feuer, Unfälle, Schadenslagen etc. - Notruf-App mit Chatbots – dynamische Notrufabfrage
<ul style="list-style-type: none"> - Texterkennung / Spracherkennung <ul style="list-style-type: none"> o Automatische Übersetzungen o Priorisierung von Anrufen bei Überlaufsituationen o Erkennen von Krankheitsbildern o Vorannahme/Zuweisung von Notrufen 	<ul style="list-style-type: none"> - Bilderkennung / Kamerabilder <ul style="list-style-type: none"> o Erkrankungen o Feuer, Unfälle, Schadenslagen etc. - Notruf-App mit Chatbots – dynamische Notrufabfrage 		
<p>Einsatzbearbeitung</p>	<p><u>Verfahren des Operations Research:</u></p> <ul style="list-style-type: none"> - Krankentransportplanung und -disposition - Dynamische Fahrzeugzuweisung unter Einbindung von Verkehrsdaten/ Meteorologie/ Straßenzustandsdaten (z. B. Glätte) und Einsatzwert 		


	<ul style="list-style-type: none"> - „intelligente“ Alarmierung von Ersthelfer*innen anhand Qualifikation, Verfügbarkeit, Standort und Bedarf im Einsatz (optimierter Einsatz von Ressourcen/Wirtschaftlichkeit/adäquater Einsatz des Ehrenamtes) - automatische Krankenhauszuweisung aufgrund der Verfügbarkeit von Betten/Schockraum unter Berücksichtigung von Warte- und Anfahrtszeiten <p><u>Verfahren des maschinellen Lernens und Nutzerassistenzsysteme:</u></p> <ul style="list-style-type: none"> - Schaffung von „intelligenten“ Leitsystemen: Erkennen der Einsatzsituation und dynamische Anpassung der graphischen Benutzeroberfläche – „zur richtigen Zeit die richtige Information“ - Informationen automatisch zusammenstellen und visualisieren: Aus Gesprächen und Eingaben Informationen zu Notfallort und –art - Alarmierungsszenarien, Auswertung Social Media oder automatisches Generieren von Unterstützungstexten bei medizinischen Notfällen - Medienübergreifende Informationssuche für Disponenten mittels Chatbots - Erkennen des Zustandes des Leitstellendisponenten (Zwangspause) - Automatisierte / teilautomatisierte Warnung der Bevölkerung - Hintergrundüberwachung der Dispositionsentscheidungen mit proaktiver Information der Disponenten bei schnellerem / besserem EM aufgrund neuer Erkenntnisse oder geänderter Fahrzeugverfügbarkeiten
---	--

Abbildung 2: Einordnung der Anwendungsfälle in einer Leitstelle

7 Welchen (Optimierungs-)Bedarf haben die Leitstellen tatsächlich?

Bei dem tatsächlichen Optimierungsbedarf und dem Bedarf an technischer Unterstützung basierend auf Methoden der mathematischen Optimierung und des maschinellen Lernens kann zwischen kurzfristigen, mittelfristigen und langfristigen Maßnahmen unterschieden werden. Diese Zeiträume sind zum einen bedingt durch die gegebenenfalls benötigten Entwicklungs- und Implementierungszeiten eines Systems, zum anderen durch eventuell notwendige Anpassungen der rechtlichen und organisatorischen Rahmenbedingungen.

Kurzfristig (Zeitraum < 2 Jahre)

In dem kurzen Zeithorizont für die kommenden zwei Jahre können Bedarfe der Leitstellen gedeckt werden, für welche bereits Lösungen bereitstehen oder kurzfristig fertig entwickelt werden können. Entscheidend ist, dass die Leitstellen die zur Verfügung stehenden Werkzeuge und deren Vorteile gegenüber herkömmlichen

Methoden kennen, ihren Einsatz fordern und der Zugang zu ihnen unkompliziert möglich ist.

Insbesondere stehen heute bereits Verfahren, zum Teil erste Systeme, für nachfolgend dargestellte Anwendungsfälle zur Verfügung und können in maximal zwei Jahren zu einem funktionsfähigen System erweitert werden.

Überwachen und Auswerten von Social-Media-Kanälen:

Das Erkennen und Auswerten einsatzrelevanter Informationen aus den verschiedensten Kanälen im Internet (Twitter, Instagram, Facebook, andere soziale Netzwerke) kann mit verfügbaren Analysetools einfach, schnell und zielgenau durchgeführt werden [13]. Beispielhaft ist die Arbeit des „Virtual Operation Support Teams“ (VOST) des THW zu nennen, welches diese Dienstleistung den BOS lage- oder einsatzbezogen und zeitlich befristet zur Verfügung stellt. Besteht ständiger Bedarf an den Ergebnissen solcher Analysen, kann entsprechende Software gekauft oder gemietet und durch geschulte Mitarbeiter*innen in den Leitstellen bedient werden.

Berechnung der notwendigen Einsatzmittelvorhaltung für Rettungsdienst und Krankentransport:

Bereits fertig entwickelte und getestete Algorithmen können anhand des vergangenen und laufenden Einsatzgeschehens Vorhersagen für zukünftige Einsatzzahlen an bestimmten Orten erstellen [7] und die Leitstellen mittels Virtualisierung auf einer Benutzeroberfläche auf die sich verändernden Bedingungen hinweisen [14]. Aufgrund der erwarteten Einsatzzahlen lassen sich resultierende Einsatzmittelvorhaltungen (Anzahlen und Standorte) für Rettungsdienst und Krankentransport bestimmen. Diese Berechnungsmethoden funktionieren sowohl bei der operativen, der taktischen, als auch bei der strategischen Planung.

Berechnung und Optimierung von Fahrtrouten im Krankentransport:

Mit Methoden des OR können Patiententransporte durch Krankentransportwagen wirtschaftlicher organisiert werden [1]. Anhand bekannter Voranmeldungen für bestimmte Tage und geografische Bereiche, deren Ergänzung mit ad-hoc-Anmeldungen und Änderungen für den laufenden Tag, können die Fahrtrouten und Fahrzeiten vorhandener Krankentransportwagen wirtschaftlicher und patientenfreundlicher gestaltet werden.

Unterstützung bei der Alarmierung von Einsatzkräften und –mitteln:

Am Markt erwerbbar Systeme können Einsatzkräfte unter Berücksichtigung des tatsächlichen Einsatzkräftebedarfs anhand vorgegebener Qualifikationen, Sollstärken und verschiedener Einsatzszenarien, Verfügbarkeit und Gruppenzugehörigkeit gezielt und bedarfsgerecht über verschiedene Wege alarmieren. Zwei bedeutende Nachteile derartiger Systeme sind die Einschränkung hinsichtlich der zur Verfügung stehenden Alarmierungswege (POCSAG, Analogfunk, Apps, Tetra), deren systemimmanente Limitationen (z. B. fehlende Rückmelde-

/Quittierungsfunktionen, Netzabdeckung, Dynamik des verarbeitenden Einsatzleitsystems) sowie die Tatsache, dass gegenwärtig einmalig getroffene Entscheidungen nicht nachvalidiert werden (können).

Schutz der IT-Infrastruktur mit selbstlernenden Systemen:

In aktueller IT-Sicherheitssoftware kommen bereits Tools zum Monitoring und zur Analyse von Datenströmen zum Einsatz, die maschinelles Lernen zum schnelleren und teilautomatisierten Erkennen von bekannten und neuen Gefährdungen nutzen.

Dynamische Personalbedarfs- und Dienstplanung:

Zukünftige Anwendungen können durch die fortlaufende systematische Auswertung der Einsatz- und Telefondaten den zu jeder Tages- und Nachtzeit optimalen Personalbedarf berechnen. Anhand tariflicher und betrieblicher Vorgaben, der Qualifikationsanforderungen und der persönlichen Wünsche der Mitarbeiter*innen generiert ein OR-Verfahren die erforderlichen bedarfsgerechten Dienstpläne.

Mittelfristig (Zeitraum 2 - 5 Jahre)

Schon deutlich schwieriger wird es, die Einführung von Technologien zeitlich einzuordnen, für die es heute noch keine bzw. noch keine vollständigen Lösungen gibt. Die folgende Einteilung soll hier versuchsweise anhand der Dringlichkeit der Bedarfe der Leitstellen vorgenommen werden.

Verbesserung der Informationssuche und Bereitstellung:

Die Nutzung „intelligenter“ Suchmaschinen wird dazu führen, dass Informationen nicht nur gesucht, sondern automatisch geordnet und interpretiert werden können, um komplexe Fragestellungen in kurzer Zeit beantworten zu können. Zwar sind diese enorm leistungsfähigen, unter anderem für Sprachauswertung tauglichen Systeme, in anderen Bereichen bereits im Einsatz, jedoch fehlen im Bereich der BOS-Leitstellen ausreichend große Datenmengen aus den relevanten Bereichen. Dafür sind Sprachaufzeichnungen, konsequente digitale Erfassungen aller Prozesse, Anweisungen, Checklisten und Feuerwehreinsatzpläne, die Einbindung von Gefahrstoffdatenbanken oder Internetportalen wie „Leitstellen-Wissen“ [15] unerlässlich. Eine alle BOS-Leitstellen übergreifende Bereitstellung von relevanten Daten ist anzustreben.

Verknüpfung von Dispositionsvorgängen mit externen Anforderungen:

Als Weiterentwicklung der Krankentransportplanung sollten die Anforderungen aus Krankenhäusern, Arztpraxen oder anderer möglicher Beteiligter über geschützte Internetportale direkt mit den in der Leitstelle bereits gestarteten Dispositionsprozessen synchronisiert und eine Anmeldung über ein Webinterface ermöglicht werden. Die Systeme können zukünftig mögliche Abholzeiten vorschlagen, oder das richtige Rettungsmittel, zum Beispiel für Intensivtransporte, finden und zur Disposition vorsehen.

Erkennen und Sortieren von Notfällen:

Mit Hilfe von Spracherkennungssystemen für gesprochenes Wort und geschriebenen Text sollen z. B. in Fällen des Notrufüberlaufs wegen Unwetter oder einer anderen großen Schadenslage die Notrufe für die zügige Bearbeitung durch die zuständigen Mitarbeiter*innen nach der Zugehörigkeit zu einem bereits erfassten Notfall, nach Notfallort oder nach Art und Intensität der Gefährdung sortiert werden. Solche Systeme müssen übergreifend die verschiedensten Medien überwachen und verstehen können. Dazu werden die Notrufleitungen, die Verbindung zur bundeseinheitlichen Notruf-App, aber auch Schnittstellen zum „Internet of Things“ gehören. Das Auswerten und Erkennen von Bild- oder Videoinhalten („umgestürzter Baum“ oder „blasse Haut“) wird Bestandteil einer solchen Anwendung werden und die Einsatzmittelentscheidung unterstützen.

Dynamische Lagedarstellung und -verarbeitung:

Unter Nutzung aller möglichen eingehenden Kanäle (Social Media, Statusmeldungen von Einsatzmitteln, Lageberichte durch Einsatzkräfte, Gefahrgutdatenbanken, Wettervorhersagen, Hochwasserpegel, Waldbrandgefahrenstufen etc.) wird ein sich automatisch an veränderte Verhältnisse angepasstes Lagebild erzeugt, aus dem wiederum Vorhersagen für die weitere Entwicklung der Situation getroffen werden können. Diverse Schnittstellen zu anderen Systemen ermöglichen schnelle Reaktionen, wie z. B. die adäquate Warnung der Bevölkerung, Alarmierung/Gruppierung von Einsatzmitteln und -kräften oder weitergehende Führungsentscheidungen.

Langfristig (Zeitraum > 5 Jahre)

Es scheint bei der Geschwindigkeit, mit der neue Technologien derzeit in der Arbeitswelt einziehen, kaum möglich, den Betrachtungszeitraum größer als fünf Jahre anzulegen. Orientiert an den Bedürfnissen der Leitstellen können vier Anforderungen/Themenfelder grob formuliert werden.

Unterstützung in Kernprozessen: Notrufabfrage, Alarmierung, Einsatzbegleitung

An erster Stelle wird die Unterstützung aller Mitarbeiter*innen in den Leitstellen durch den Einsatz von künstlicher Intelligenz in den Prozessschritten der Notrufabfrage, der Alarmierung, sowie der Steuerung von Einsatzmitteln und -kräften zunehmend gefordert sein. Die Übertragung von Bild, Schrift und Ton, sowie erweiterter Ortsdaten, zum Beispiel mit Höhenangaben, während der Notrufabfrage ermöglichen unter der Überschrift „NG112“ (Next-Generation-112) den Einsatz von Unterstützungsprogrammen zur richtigen Einordnung der Symptomatik. Anhand von Bild- und Spracherkennung mit Einbindung von Dolmetscherdiensten können Verfahren zu schnellerer, zielgerichteter und bedarfsgerechter Alarmierung implementiert werden.

Lastverteilung zur Aufrechterhaltung der Leistungsfähigkeit der Mitarbeiter*innen

Weitere Tools können die Lastverteilung an den Arbeitsplätzen der Leitstellen steuern und erkennen anhand der Sprache, Mimik und Gestik der Mitarbeiter*innen, wie das Leitstellenpersonal individuell physisch und psychisch belastet ist und ggf. eine Arbeitspause oder aktive Erholung benötigt. Entsprechend können Licht, Ton und Luftfeuchtigkeit im Leitstellenbetriebsraum automatisch angepasst oder Anrufe automatisiert zugeordnet werden.

Dynamische, kontextbezogene Nutzer-Oberfläche

Ein dritter großer Bedarfszweig ist die dynamische Anpassung der Einsatzleit- und Kommunikationssysteme an den tatsächlichen Bedarf der Mitarbeiter*innen. Die heute auf bis zu sechs Monitoren zur Anzeige kommenden Informationen können durch die Calltaker*innen und Einsatzsachbearbeiter*innen gar nicht mehr vollständig wahrgenommen und verarbeitet werden. Diese mangelhafte Verarbeitung von Informationen kann zu Fehlern führen. Ziel einer solchen Entwicklung muss es sein, alle für den gerade zu bearbeitenden Einsatzfall notwendigen Informationen und Bedienelemente übersichtlich und priorisiert zu visualisieren. Informationen werden übergreifend dargestellt, alles andere wird auf das für die jeweils auszuübende Tätigkeit Sinnvolle und Notwendigste beschränkt. Hierzu sind erfreulicherweise erste Ansätze bei einigen Herstellern erkennbar.

Einbindung weiterer Datenquellen

Ein weiterer Punkt bedingt die tiefergehende Implementierung und Optimierung der in den anderen Betrachtungszeiträumen bereits beschriebenen Lösungsansätze. Die weitere Digitalisierung, insbesondere die Ausweitung des Internet of Things (IoT), wird eine heute nur in Ansätzen zu überschaubare Datenflut in die Leitstellen bringen. Ein Blick auf das Vorhandensein von sogenannten Wearables und Smart Devices in der Bevölkerung zeigt, dass hier Vitaldaten in erheblichem Umfang automatisiert in die Leitstellen gelangen können, was völlig andere Ansätze der Einsatzbearbeitung erfordern würde. Ist es denkbar, Rettungskräfte präventiv bei einer sich abzeichnenden Blutdruckerhöhung zu entsenden und nicht erst, wenn der Schlaganfall oder der Herzinfarkt bereits geschehen sind?

8 Anforderungen an den Einsatz von künstlicher Intelligenz in Leitstellen

Neben den Anforderungen der Endnutzer*innen, zum Beispiel der Disponent*innen, sind weitere Rahmenbedingungen zu berücksichtigen. Zu diesen gehören unter anderem rechtliche Limitierungen, ausreichende Rechenkapazitäten, sowie etwaige finanzielle Aufwendungen, die über die reine Beschaffung und Wartung hinausgehen. Das können zum Beispiel Aufwendungen für Schulungen, Evaluierungen, Nachsteuerungen oder Anpassungen sein, welchen einen Großteil der anfallenden Gesamtkosten ausmachen können. Darüber hinaus ist eine

Abstimmung bzw. Einordnung von Einführungs- oder Forschungsprojekten in die bereits bestehenden Vorhaben und Interessen anderer repräsentativer Gruppen (zum Beispiel AGBF Bund, DFV, DIVI, Deutscher Städte- und Landkreistag, KVB) zu beachten.

Wesentliche Anforderungen werden an den Datenschutz gestellt. Die Einhaltung sämtlicher rechtlicher Vorgaben hat oberste Priorität. Eine Untersuchung der Anforderungen und Risiken einer Speicherung von großen Datenmengen in Einrichtungen der polizeilichen und nicht-polizeilichen Gefahrenabwehr sollte vor Einführung eines KI-Systems durchgeführt werden. Aus dem Untersuchungsergebnis werden notwendige Maßnahmen und Absicherungen zur Vermeidung von Problemen und Risiken definiert.

Für den erfolgreichen Einsatz von Methoden des maschinellen Lernens und des Operations Research ist ein bewusster Umgang mit den Limitationen eine wichtige Voraussetzung. Wie bereits erwähnt sind ausreichend viele und qualitativ hochwertige Eingabedaten eine Hauptvoraussetzung für effiziente Systeme. Liegen diese für eine Leitstelle nicht vor, muss untersucht werden, inwiefern ein für eine andere Leitstelle trainiertes Modell des maschinellen Lernens übertragen werden kann. Dies würde zudem den ansonsten sehr großen Aufwand reduzieren, wenn für jede Leitstelle individuelle Modelle trainiert werden müssten.

Neben den methodischen Grenzen sind technische Systemgrenzen bzw. Anforderungen an eine technische Mindestausstattung zu beachten. Es sollten ausreichend personelle, finanzielle und zeitliche Ressourcen für die Einführung und den Betrieb von KI-Systemen zur Verfügung stehen. Bei allen Beteiligten sind anhaltende Motivation und Bereitschaft wichtige Voraussetzungen während der gesamten Nutzungsdauer.

9 Zusammenfassung und Fazit

Die oben aufgeführte Liste der Maßnahmen, die bereits zeitnah oder in den nächsten zwei bis fünf Jahren umgesetzt werden können, zeigt das Potential, welches die Verfahren des maschinellen Lernens und des Operations Research für den Einsatz in deutschen Leitstellen bietet. Um dieses Potential zu nutzen, müssen **jetzt** die Anforderungen, Erwartungen und Rahmenbedingungen geklärt werden. Entscheidend für die Leistungsfähigkeit und den Nutzen der ML- und OR-Verfahren ist die Verfügbarkeit und Qualität der Eingabedaten. Vereinfacht gesagt wird erwartet, dass je größer, strukturierter und standardisierter die Datenmenge ist, desto schneller (und kommerziell günstiger) und vor allem genauer wird das darauf aufbauende System sein. Nutzer*innen von KI-Systemen müssen sich über mögliche Grenzen der Systeme und der zur Vereinfachung getroffenen Annahmen im Klaren sein.

Die in der Gefahrenabwehr Agierenden werden häufig in ihrem Berufsalltag mit seltenen, teils noch nie dagewesenen Herausforderungen konfrontiert. Eine daraus resultierende Motivation und Bereitschaft wird essentiell sein, um den Einzug von KI-basierten Systemen in den Leitstellen nicht nur mitzugestalten, sondern proaktiv voranzutreiben.

Die Arbeitsgruppe hat sich darauf geeinigt, nächste Schritte in einer Mischung aus „bottom-up-“ und „top-down-Ansatz“ zu definieren und hat dazu folgendes weiteres Vorgehen beschlossen: Als erster Impuls wird das Positionspapier verteilt und auf verschiedenen Kanälen beworben. Mit wissenschaftlicher Unterstützung sind eine Online-Umfrage und Interviews mit Expert*innen geplant, um Einstellungen zu künstlicher Intelligenz sowie Erwartungen, Wünsche, Anforderungen und Bedenken an die Umsetzung von konkreten Maßnahmen zu sammeln und zu untersuchen. Die Ergebnisse sollen neben einer wissenschaftlichen Verwertung dazu genutzt werden, konkrete Pilotprojekte abzuleiten. Idealerweise wird die zunehmende Einführung von künstlicher Intelligenz in den BOS-Leitstellen unter Fortschreibung dieses Positionspapieres dokumentiert.

Die – zum Zeitpunkt der Fertigstellung dieses Papieres im Mai 2020 – noch hochaktuelle, gerade abklingende Lockdown-Situation in Folge der Corona-Pandemie zeigt zum einen, welche Wichtigkeit und Dringlichkeit die Digitalisierung in Deutschland hat, zum anderen aber auch, wie viel auf einmal doch möglich ist, was jahrelang als nicht möglich galt – wie zum Beispiel die konsequente Nutzung des Homeoffice in weit mehr Bereichen als es zuvor für realisierbar gehalten wurde.

Die Zukunft hat schon begonnen – gestalten wir sie mit!

10 Referenzen

- [1] M. Reuter-Oppermann (2017): On the Optimisation of EMS Logistics. Dissertation, Karlsruher Institut für Technologie, Karlsruhe.
- [2] M. Reuter-Oppermann, P. van den Berg, J. Vile (2017): Logistics for Emergency Medical Service systems; Health Systems, 6(3), 187-208.
- [3] N. Kühl, M. Goutier, R. Hirt, G. Satzger (2019): Machine Learning in Artificial Intelligence: Towards a Common Understanding. Proceedings der 52. HICSS Konferenz, Hawaii, USA.
- [4] P. Buxmann, H. Schmidt (2018): Künstliche Intelligenz: Mit Algorithmen zum wirtschaftlichen Erfolg. Springer-Verlag.
- [5] M. Reuter-Oppermann (2019): Rettungsdienstlogistik für die Leitstelle: Mathematische Optimierung in der Praxis. BOS-LEITSTELLE AKTUELL (9).
- [6] M. Reuter-Oppermann, S. Morana, P. Hottum (2017): Towards Designing an Assistant for Semi-Automatic EMS Dispatching. Proceedings der 50th HICSS Konferenz, Hawaii, USA.
- [7] M. Reuter-Oppermann, C. Wolff (2020): Towards a Unified Understanding of Data-Driven Support for Emergency Medical Service Logistics. Proceedings der 53. HICSS Konferenz, Hawaii, USA.
- [8] N. Mesbah, C. Tauchert, C.M. Olt, P. Buxmann (2019): Promoting Trust in AI-based Expert Systems. Proceedings der AMCIS 2019 Konferenz, Cancun, Mexico.
- [9] Weka. <https://www.cs.waikato.ac.nz/ml/weka/>
- [10] Scikit-learn. <https://scikit-learn.org/stable/>
- [11] A. Cleve, D. Devillers, M. Palladini, J. Pâris, R. Michael (2020): Project report: Detecting out-of-hospital cardiac arrest using artificial intelligence, EENA, Brüssel.
- [12] I. Gomez (2019): Artificial Intelligence & Machine Learning in Public Safety, EENA, Brüssel.
- [13] K. Eismann, M. Reuter-Oppermann, K. Fischbach (2019): Towards Social Media Decision Support for Joined EMS and Crisis Logistics. Proceedings der 16. ISCRAM Konferenz in Valencia, Spain.
- [14] M. Reuter-Oppermann, D. Richards (2019): Decision Support for EMS Policy Making Using Data Analytics and Real-Time Alerts. Proceedings des IEEE SERVICES 2019 Workshop on Big Data for Public Health Policy Making, Milano, Italy.
- [15] Leitstellen-Wissen. www.leitstellen-wissen.de