

Association for Information Systems

AIS Electronic Library (AISeL)

Wirtschaftsinformatik 2021 Proceedings

Track 10: Design, management and impact of
AI-based systems

Gestaltung künstlicher neuronaler Netze zur Prognose des Verkehrsaufkommens im Kontext von Smart-Mobility-Lösungen

Christian Anschütz
FernUniversität in Hagen

Jan Henrik Ibisch
FernUniversität in Hagen

Katharina Ebner
FernUniversität in Hagen

Stefan Smonik
FernUniversität in Hagen

Follow this and additional works at: <https://aisel.aisnet.org/wi2021>

Anschütz, Christian; Ibisch, Jan Henrik; Ebner, Katharina; and Smonik, Stefan, "Gestaltung künstlicher neuronaler Netze zur Prognose des Verkehrsaufkommens im Kontext von Smart-Mobility-Lösungen" (2021). *Wirtschaftsinformatik 2021 Proceedings*. 2.
<https://aisel.aisnet.org/wi2021/QDesign/Track10/2>

This material is brought to you by the Wirtschaftsinformatik at AIS Electronic Library (AISeL). It has been accepted for inclusion in Wirtschaftsinformatik 2021 Proceedings by an authorized administrator of AIS Electronic Library (AISeL). For more information, please contact elibrary@aisnet.org.

Gestaltung künstlicher neuronaler Netze zur Prognose des Verkehrsaufkommens im Kontext von Smart-Mobility-Lösungen

Christian Anschütz¹, Jan Ibisch¹, Katharina Ebner¹ und Stefan Smolnik¹

¹FernUniversität in Hagen, Lehrstuhl für Betriebswirtschaftslehre, insbesondere Betriebliche Anwendungssysteme, Hagen, Deutschland
christian.anschuetz@fernuni-hagen.de

Abstract. Im Rahmen dieses Beitrags werden als Grundlage für eine spätere Smart-Mobility-Lösungen mit Verkehrssensordaten der Stadt Darmstadt künstliche neuronale Netze (KNN) zur Prognose des Verkehrsaufkommens entwickelt. Nach Aufbereitung der gewonnenen Sensordaten lassen sich Informationen über die aktuelle Verkehrssituation ableiten und Ereignisse wie Stoßzeiten im Berufsverkehr, Wochenenden oder Feiertage erkennen. Aufbauend auf aktuellen Forschungserkenntnissen auf dem Gebiet der Verkehrsprognose mittels neuronaler Netze zeigt unsere Arbeit erste bewährte Verfahren für die Modellierung des Verkehrsaufkommens und einer damit einhergehenden Verkehrsprognose auf. Bei der Prognose der Verkehrssituation zeigt sich ein Long Short-Term Memory (LSTM)-Netz einem Deep Neural Network (DNN) überlegen, bezogen auf die Prognosegüte und den Vorhersagehorizont. Weiter wird erörtert, ob die Anreicherung der Trainingsdaten mit zusätzlichen Zeit- und Wetterdaten eine Steigerung der Prognosegenauigkeit ermöglicht. Im Sinne eines designtheoretischen Vorgehens werden Gestaltungsanforderungen und Designprinzipien für die Entwicklung eines KNN im verkehrsspezifischen Kontext abgeleitet.

Keywords: Künstliche neuronale Netze, Long Short-Term Memory, Deep Neural Network, Verkehrsprognose, Smart Mobility

1 Einleitung

Die Bevölkerung in urbanen Regionen in Deutschland wird in den kommenden Jahren weiter zunehmen [1]. Besonders Großstädte wie Berlin oder München werden aufgrund der dort vorhandenen Ausbildungs- und Arbeitsplätze in den nächsten Jahren ein starkes Bevölkerungswachstum verzeichnen [1]. Damit geht eine zunehmende Belastung des Straßennetzes durch Staus, Verkehrslärm und Emissionen einher [2]. Konzepte zur Begegnung der Herausforderungen im Bereich Verkehr werden unter dem Begriff Smart Mobility (SM) zusammengefasst [3]. SM bezeichnet dabei allgemein eine „*intelligente, vorausschauende und nachhaltige Steuerung des städtischen Verkehrs mithilfe moderner Informationstechnologien und verfolgt das Ziel, die Emissions-, Lautstärke- und Stressbelastung von Pendlern und Anwohnern zu reduzieren*“ [4]. Städte

wie Duisburg, Essen, München, Bad Hersfeld oder Darmstadt setzen bereits Verkehrstelematik zum Verkehrsmanagement ein, um den Verkehr über stationäre Verkehrssensoren zu beobachten, zu leiten und beispielsweise Pendlern Verkehrsinformationen bereitzustellen. Verkehrstelematik kann SM-Lösungen unterstützen, indem sie Daten für Verkehrsprognosen bereitstellt und so den Pendlern und Verkehrsbehörden die Möglichkeit gibt, vorab auf Verkehrsbehinderungen zu reagieren [5]. Die Verkehrsprognose als Teil einer SM-Lösung kann helfen, den Verkehr gleichmäßig über verschiedene Routen, Zeiträume und Transportmittel zu verteilen [6], [7]. Auch möglichen Staus kann präventiv entgegengewirkt werden, was sich in einer Reduzierung der Umweltbelastungen (z.B. den CO₂-Ausstoß) bemerkbar macht [6], [8].

Für den Erfolg von SM-Lösungen ist es entscheidend, dass diese nicht nur die aktuelle Verkehrssituation zeigen, sondern auch eine Prognose liefern, nach der sich der Nutzer richten kann [9]. Im Rahmen eines Forschungsprojekts beabsichtigen wir die Entwicklung einer dynamischen Verkehrsprognose, die zur Erreichung eines optimalen Verkehrsflusses (z.B. die Vermeidung von Staus oder eine optimierte Ampelschaltung) beitragen kann. Dazu werden im Rahmen dieses Beitrags mit Verkehrsdaten der Stadt Darmstadt künstliche neuronale Netze (KNN) zur Verkehrsprognose entwickelt [10]. KNN eignen sich für die Behandlung nicht-linearer Probleme und können daher im Verkehrsbereich, der durch Schwankungen geprägt ist, zur Prognose eingesetzt werden [11]. Die Entwicklung erfolgt mit historischen Sensordaten und anschließender Evaluation mit Testdaten [10]. Der Mehrwert der KNN soll durch den Vergleich mit Prognosemodellen ermittelt werden [12]. Im Zuge der Entwicklung des KNN stellen sich daher folgende Forschungsfragen:

1. *Welche Designanforderungen und -prinzipien können für die Gestaltung von KNN zur Prognose des Verkehrsaufkommens im Kontext von SM-Lösungen herangezogen werden?*
2. *Welches Prognosemodell ist für die Verkehrsprognose am geeignetsten?*

Um diese Forschungsfragen zu beantworten, leiten wir im Rahmen dieses Beitrags aus der Literatur zunächst vier relevante Gestaltungsanforderungen ab. Weiterhin leiten wir unter Berücksichtigung der einschlägigen Literatur zu (Smart) Mobility und KNN sowie aufbauend aus der konkreten Entwicklung eines KNN sieben Designprinzipien ab. Weiterhin analysieren wir, welches Prognosemodell am genauesten zurückliegende Sensorerfassungen in die Prognose miteinbezieht und wie sich die Prognosegenauigkeit bei zunehmendem Vorhersagehorizont entwickelt. Des Weiteren wird geprüft, ob sich die Prognosegenauigkeit verbessern lässt, wenn die vorhandenen Verkehrsdaten mit weiteren Zeit- oder Wettermerkmalen angereicht werden. Mit unserer Forschung können wir einen Beitrag zur Entwicklung, Gestaltung und Implementierung von KNN, insbesondere in städtischen und verkehrsbezogenen Kontexten leisten. Weiterhin demonstrieren wir den praktischen Einsatz von KNN in einem konkreten Anwendungsfeld (Verkehr), wobei wir überzeugt sind, dass die Erkenntnisse zur Aufbereitung und Verwendung von Sensordaten im Kontext von KNN für sehr viele Anwendungsfelder z.B. im Umfeld von Smart Citys oder intelligenten Fabriken relevant sind.

2 Stand der Forschung

Für den wissenschaftlichen Diskurs in diesem Beitrag sind zwei Aspekte maßgeblich: SM und die Methodik des maschinellen Lernens eines KNN. Zunächst werden der aktuelle Stand der Forschung dieser beiden Aspekte aufgearbeitet sowie relevante Forschungslücken und Herausforderungen aufgezeigt.

2.1 Smart Mobility

SM ist in der wissenschaftlichen Literatur definiert als „*intelligente, vorausschauende und nachhaltige Steuerung des städtischen Verkehrs mithilfe moderner Informationstechnologien und verfolgt das Ziel, die Emissions-, Lautstärke- und Stressbelastung von Pendlern und Anwohnern zu reduzieren*“ [4] und ist dabei „*anwendbar und nutzbar für jedermann unabhängig von Standort und Region, unabhängig von Nutzungszeitraum und -dauer, unabhängig von individuellen Fähigkeiten und Budget*“ [13]. Die Definition kann, insbesondere für den innerstädtischen Kontext, erweitert werden um die „*proaktive und nachhaltige Steuerung des städtischen Verkehrs durch eine Einbindung von Pendlern*“ zur Erreichung eines optimalen Verkehrsflusses in Städten [9]. Um mit SM-Lösungen eine „smarte“ Mobilität zu ermöglichen, werden bereits vorhandene Lösungen durch den Einsatz von Informations- und Kommunikationstechnologien optimiert [2, 13, 14]. Ein Beispiel für eine solche Technologie ist die Verkehrstelematik [15] mit der Fähigkeit zur Sammlung, Verarbeitung und Analyse von Verkehrsdaten über Sensoren [16]. Damit lassen sich in Städten u.a. Verkehrsabläufe effizienter gestalten [17], die Verkehrssicherheit erhöhen [18] und verkehrsbedingte Umweltbelastungen verringern [19]. Einige praktische Umsetzungen in Deutschland finden sich z.B. in Duisburg (ÖPNV-Vorrangschaltung), Essen (digitale Verkehrsschilder), Bad Hersfeld (sensorgesteuerte Parkraumüberwachung), München (intelligente Mobilitätsstationen) oder Darmstadt (Optimierung der Verkehrssteuerung) [16].

In der Literatur werden weitere praktische Einsatzszenarien diskutiert, Verkehrstelematiksysteme mit Daten anzureichern und den Verkehr zu optimieren [20–22]. Ein aktuell vieldiskutierter Ansatz ist die Verkehrsoptimierung mittels eines neuronalen Netzwerks, das mit Daten aus der Verkehrstelematik (z. B. stationäre Sensoren) und weiteren Datenquellen (z. B. mobile Sensoren) versorgt wird [23], [6]. Mit Hilfe dieser Daten lassen sich für den städtischen Verkehr genaue Verkehrsprognosen treffen [16], [24]. Ein daraus gewonnenes Verkehrsprognosemodell ermöglicht vorausschauendes Verkehrsmanagement, kann als Teilaspekt einer SM-Lösung betrachtet werden und damit zur Erreichung eines optimalen Verkehrsflusses beitragen [5], [6].

2.2 Verkehrsprognose mittels künstlicher neuronaler Netze

In den letzten Jahren hat gemessen an den steigenden Veröffentlichungen zum Thema Verkehrsflussprognose mittels KNN eine dynamische Entwicklung in diesem Bereich stattgefunden, die durch die Verfügbarkeit umfangreicher Trainingsdaten und der Entwicklung leistungsstarker Hardware und Algorithmen ermöglicht wurde [25]. Das Problem der Verkehrsflussprognose ist im Kern ein Zeitreihenvorhersageproblem, bei

dem der Verkehr zu einem zukünftigen Zeitpunkt mit Daten, die in der Vergangenheit an Messstellen gesammelt wurden, geschätzt werden soll [24]. Der Verkehrsfluss wird durch Zeit (Tageszeit, Wochentag, Ferien, Feiertage, Veranstaltungen [26], [27]), Wetter (Niederschlag, Temperatur [24], [28]) und teils zufällige Verkehrsbehinderungen (Unfälle, Sperrungen, Baustellen [29]) beeinflusst. Parametrische Modelle aus der Statistik und analytische Ansätze konnten aufgrund der stochastischen und nicht-linearen Charakteristiken des Verkehrsflusses bislang keine überzeugenden Prognosen liefern [24], [27], [30]. KNN hingegen zeigen sich als aussichtsreiche Werkzeuge, da sie in der Lage sind, eine Vielzahl an unterschiedlichen Datenquellen zu integrieren [27], [28], Zustände zu bewahren [24], hohe Prognosegenauigkeit zu erreichen sowie Robustheit gegenüber verrauschten Daten zu zeigen [30]. Eine vertiefte Einführung zu KNN bieten [25], [31] und [32].

Ein Nachteil bei der Anwendung von Feedforward-Netzen (Netze mit einer Inputschicht, einem oder mehreren Hidden Layers sowie einer Outputschicht) für die Prognose von Zeitreihen oder sonstigen sequenziellen Daten ist ihre fehlende Merkfähigkeit [31]. Jede Eingabe fließt unabhängig von der vorherigen Eingabeschicht *vorwärts* zur Ausgabeschicht, dabei wird kein Zustand weitergegeben [25], [31]. Dieses Vorgehen ist jedoch gerade für die komplexen Muster im Verkehrskontext nicht geeignet, da es nicht ausreicht nur die Erkenntnisse von Schicht zu Schicht weiterzureichen, sondern die vielschichtigen Abhängigkeiten berücksichtigt werden müssen [7], [33]. Um diesen Umstand zu beheben, wurde durch Erweiterung der KNN mit Feedback-Schleifen die Klasse Recurrent Neural Networks (RNN) geschaffen [25]. Beim Iterieren durch die Eingabesequenzen speichern diese einen Zustand, der sich aus den bisher verarbeiteten Daten zusammensetzt [34]. Dies ist mit einer Rückkopplungsschleife vergleichbar, durch welche die aktuelle Ausgabe des Neurons („Recheneinheit“) mit der Eingabe der nächsten Sequenz verknüpft wird. Ein Nachteil dieses einfachen Aufbaus ist, dass er nicht in der Lage ist, längerfristige Abhängigkeiten zwischen den Sequenzen zu erlernen [34]. Im Rahmen der Verkehrsflussprognose kommt es jedoch häufig zu Verzögerungseffekten, d. h. zwischen Ursprung des Ereignisses und Wahrnehmung der Konsequenzen kann ein größerer Zeitraum liegen [24], [28]. Um diese Schwachstellen zu adressieren, entwickelten Hochreiter und Schmidhuber [34] die Long Short-Term Memory (LSTM)-Netzwerke. Im Gegensatz zu RNN verfügen diese über interne Gatter, die den Fluss der Information steuern [25]. Ein Schlüsselement der LSTM-Zelle ist ihr Zellenzustand, der über mehrere Sequenzen hinweg weitergegeben werden kann, ohne zu verblasen [34]. Daher eignen sich LSTM-Architekturen besonders zur Zeitreihenprognose [35], sind dadurch jedoch rechenintensiver.

2.3 Anforderungsanalyse

Das zu entwickelnde KNN zur Verkehrsprognose soll in der späteren Bereitstellungsphase dazu dienen, Verkehrsprognosen zur Verfügung zu stellen und diese an eine SM-Lösung (z. B. eine Smartphone-App) weiterzuleiten, damit der Nutzer eine individuelle Entscheidung bzgl. seiner Abfahrtszeit, Route und/oder Verkehrsmittel treffen kann [10], [6]. Aus diesem Aspekt und aus dem aktuellen Stand der Forschung in den Bereichen SM und KNN [16], [23], [28] ergeben sich im Sinne eines designtheoretischen

Vorgehens für die Entwicklung eines KNN für die Verkehrsprognose verschiedene und nachfolgend in Tabelle 1 dargestellte Anforderungen (Design Requirement, DR) [36].

Tabelle 1. Anforderungen an die Entwicklung eines KNN für die Verkehrsprognose

<i>Anforderung</i>		<i>Beschreibung</i>	<i>Quellen</i>
DR1	Nützlichkeit	Das KNN soll den Verkehr für eine bestimmte Wegstrecke und ein geeignetes Reisezeitfenster prognostizieren.	[6], [7], [37]
DR2	Merkfähigkeit	Das KNN muss komplexe Verkehrsmuster und Abhängigkeiten der Vergangenheit erkennen können, um daraus Gesetzmäßigkeiten für zukünftige Vorhersagen abzuleiten.	[3], [5], [8], [21], [27], [38]
DR3	Prognosegüte	Das KNN muss den zu erwartenden Verkehr mit hinreichender Prognosegüte (Genauigkeit mind. 85%) vorhersagen.	[11], [28], [39], [40]
DR4	Verwendbarkeit	Die vom KNN übermittelten Daten müssen in einer Form vorliegen, die für den Nutzer interpretierbar ist.	[6], [29], [41]

3 Entwicklung und Training eines KNN zur Verkehrsprognose

Als Vorgehensschema für die Entwicklung des neuronalen Netzes wurde auf den Cross-Industry Standard Process for Data Mining (CRISP-DM) zurückgegriffen [10]. Dieser bildet eine Standardvorgehensweise für die Erstellung von KNN und gliedert sich in die Phasen Geschäftsverständnis (beinhaltet die wichtigsten Anforderungen aus den Bereichen der SM sowie KNN und ist in Abschnitt 2.3 dargestellt), Datenverständnis, Datenvorbereitung, Modellierung, Evaluation und Bereitstellung der Anwendung und bildet daher auch die Grundlage für unseren Beitrag [42], [43].

In der Phase des Datenverständnisses und der Datenvorbereitung haben wir uns insbesondere mit Fragestellungen betreffend der Prognosegüte (DR3) auseinandergesetzt, die maßgeblich von der Datenbasis abhängt. Die Basis für unsere Entwicklung der KNN zur Verkehrsprognose bilden die Verkehrsdaten der Stadt Darmstadt¹. Diese umfassen die Daten von über 2.300 verschiedenen Sensoren unterschiedlicher Bauart. Hierunter fallen auch Induktionsschleifensensoren, die über zahlreiche Kreuzungen und Ampelanlagen in der Stadt verteilt sind und die auch im Rahmen des Datenverständnis analysiert wurden. Diese Sensoren erkennen durch eine elektromagnetische Spule unter dem Fahrbahnbelag ein Fahrzeug bzw. Metall, das sich über sie hinwegbewegt. Es wird die Anzahl der Fahrzeuge pro Minute Z und die prozentuale Sensorbelegung pro Minute B gemessen. Die Geschwindigkeit des Objekts wird dabei nicht ermittelt. Für die Trainingsdaten des neuronalen Netzes wurde aufgrund der großen Datenmengen nur jede fünfte Minute automatisiert mittels eines Skripts heruntergeladen. Damit besteht eine jede Stunde aus insgesamt zwölf Messpunkten. Als Ausschnitt der Daten wurde ein Zeitraum von 23 Wochen aus dem Jahr 2019 verwendet, da hier die wenigsten Komplettausfälle des Sensornetzes vorlagen. Da zu Beginn weder aus dem Belegungsgrad B noch der Anzahl Z allein eine belastbare Aussage über die Auslastung des Verkehrsnetzes getroffen werden konnte, wurde die Anzahl und der Belegungsgrad

¹ Verfügbar unter <https://ui-traffic-da.azurewebsites.net/>

ins Verhältnis zueinander gesetzt. Dieses Verhältnis kann als Verweildauer D eines Fahrzeugs auf dem Induktionssensor der Kreuzung oder Ampelanlage interpretiert werden. Die Berechnung ist in den Formeln (1) und (2) nachfolgend dargestellt:

$$D [\text{sec}] = (B \times 0.6) / c, Z > 0 \quad (1); \quad D [\text{sec}] = B \times 0.6, Z = 0 \quad (2)$$

Abbildung 1 zeigt beispielhaft die durchschnittliche Verweildauer eines Fahrzeugs an einem Sensor. Der innerstädtische Berufsverkehr von Montag bis Freitag lässt sich deutlich an den Früh- und Abendspitzen identifizieren. Bis auf den früheren Heimreiseverkehr freitags, lässt sich für die Werktage ein wiederkehrendes Muster der Verkehrsbelastung erkennen [26]. Samstags und sonntags entfällt der Berufsverkehr und die Verkehrsbelastung bleibt selbst mittags unter dem Wochentagsdurchschnitt. Eine ausreichende Abdeckung derartiger wiederholender Muster in den Daten ist für das Training (und die spätere Prognosegüte) des KNN wichtig, damit die entstehenden Neuronenverknüpfungen diese zentralen Muster mit entsprechender Stärke abbilden.




Abbildung 1: Durchschnittliche Verweildauer eines Fahrzeugs pro Wochentag und Tageszeit über die gesamten Daten

Ein häufiger Fehlertyp der Daten aus Darmstadt im Rahmen der Datenvorbereitung waren fehlende Werte oder mehrere Tage mit Sensorwerten von dauerhaft 0 oder 100 für die Sensorbelegung (in % von einer Minute). Zur Korrektur wurden die Daten eines Sensors nach Berechnung der Verweildauer (in Sekunden auf Basis der Sensorbelegung und Zählwert) komplett verworfen, sobald über 90% aller Zeitpunkte den Wert 0 Sekunden oder 20% aller Zeitpunkte den Wert 60 Sekunden für die Verweildauer hatten. Einzelne fehlende Datenpunkte in der Zeitachse wurden linear interpoliert, weil ein fehlender Messwert von einem KNN als das Fehlen eines Fahrzeugs interpretiert werden würde (Abbildung 2).

Die Sensordaten wurden mit der Medianfilterung geglättet, um Sprünge durch die Ampelphasen zu vermeiden [27]. Der gesamte Prozess innerhalb der Datenaufbereitung dient der Sicherstellung einer hinreichenden Prognosegüte. Die für das Training verwendeten Daten sollten möglichst lückenlos vorliegen und möglichst wenig durch Störungen unterbrochen sein und die zu erwartenden Muster in der Verkehrsentwicklung abbilden (z.B. tägliche Verkehrsspitzen).




Abbildung 2: Die Verweildauer (blau) am Sensor A008/D44 nach Medianfilterung und Interpolation der Messwerte (rot)

Darauf aufbauend haben wir die folgenden Designprinzipien (Design Principle, DP) abgeleitet, die insbesondere DR3 adressieren:

DP1: Einzelne fehlende Sensordatenpunkte sollten mittels eines Workflows ersetzt werden (z. B. Interpolation). Wenn fehlende Sensordatenpunkte nicht ersetzt werden können, müssen diese aus den Datensätzen entfernt werden.

DP2: Einige Sensordaten (z.B. beim Übergang von Ampelphasen) sollten geglättet werden, um eine sinnvolle Prognose zu ermöglichen.

DP3: Die für das Training verwendeten Daten müssen für einen ausreichend langen Zeitraum vorliegen, um die zu erwartenden Muster in der Verkehrsentwicklung wiederkehrend abzubilden.

Für jeden Datenpunkt wurde aus dem Zeitstempel der Wochentag abgeleitet und als kategorisches Datum kodiert [16]. Daneben wurde das zyklische Merkmal Uhrzeit durch eine Sinus- sowie Kosinusspalte kodiert. Auf Basis der Erkenntnis verschiedener Forscher [8], [24], [27], dass sich die Integration von Wetterdaten positiv auf die Prognosegenauigkeiten von KNN auswirkt, wurden die mittlere Tagestemperatur sowie Minimal- und Maximaltagtemperatur und Niederschlagsmenge in die Trainingsdaten integriert, wie sie z.B. vom Wetterkontor² zur Verfügung gestellt werden.

Die verwendeten Gesamtdaten haben einen zeitlichen Umfang T von 32.000 Zeilen. Dies entspricht rund 111 Tagen. Davon wurden 80% zum Training verwendet und jeweils 10% für einen Validierungs- und Testdatensatz genutzt. Jede Spalte stellt einen Sensor oder ein zusätzliches Merkmal wie Wochentag oder Niederschlag dar. Die Anzahl der verwendeten Spalten beträgt 531. Die Anzahl der zusätzlichen Zeit- und Wetterspalten beträgt 13. Der Wertebereich der Einträge ist zwischen $[0; 1]$ skaliert. Um im Sinne der DR1 zu nützlichen Prognosen zu kommen, wurden Prognosemodelle für die Zeiträume von 15, 30 und 60 Minuten entwickelt. Diese Prognosen können einerseits den Verkehrsteilnehmern dienen, stressfrei und schnell an ihr Ziel zu gelangen und andererseits wichtige Erkenntnisse für die zukünftige Verkehrsplanung in Städten liefern. Als Eingabemuster für die Prognose stehen dem KNN 36 Zeilen (drei Stunden)

² Verfügbar unter <https://www.wetterkontor.de/wetter-vorhersage/deutschland/darmstadt>

eines im Training zufällig ausgewählten Abschnitts der Trainingsmatrix zur Verfügung. Für den Beitrag wurde eine Teilmenge von zehn Sensoren als zu prognostizierende Ausgabe verwendet. Dies führt uns zu folgenden Designprinzipien (vgl. DR1 und DR3):

DP4: Die für das Training verwendeten Verkehrsdaten sollten um weitere Daten angereichert werden, die Einfluss auf das zu prognostizierende System haben (bei Verkehr z.B. Wetter, Ferien).

DP5: Der angestrebte Prognosehorizont muss weit genug sein, damit Akteure des zu prognostizierenden Systems sinnvoll auf die Prognose reagieren können.

Als Vergleichsgrundlage für die Ergebnisse der KNN werden zwei Basismodelle genutzt: (1) das Modell des „Historischen Durchschnitts“ (HD) [44], bei dem für den zu prognostizierenden Wert die durchschnittliche Verweildauer zur gleichen Tageszeit und am gleichen Wochentag nachgeschlagen wird (Abbildung 1); (2) der „Naive Random Walk“ (NRW) [45] genutzt. Hierbei wird der Verkehrsfluss in der Zukunft mit dem aktuellen Wert prognostiziert. Im Rahmen der Modellierung verfügt das erste KNN über eine Plättungsschicht (engl. flatten layer), welche die 36x544-Matrix zu einem Vektor mit 19.584 Einträgen transformiert. Als verborgene Schichten werden 600, 300 und 100 Neuronen in drei Schichten mit der Rectified-Linear-Unit-(ReLU)-Aktivierungsfunktion verwendet [46]. Die Ausgabeschicht verfügt über zehn Neuronen mit ReLU-Aktivierungsfunktion. Aufgrund der multiplen verborgenen Schichten bezeichnen wir das Modell in der Auswertung als DNN. Zur Adressierung der Merkfähigkeit (DR2), verfügt das zweite entwickelte KNN über LSTM-Zellen, im Weiteren als LSTM bezeichnet. Die LSTM-Schicht besteht aus 600 Zellen und Ausgabeschicht enthält zehn Neuronen mit ReLU-Aktivierungsfunktion. Bei beiden KNN führten Versuche mit zusätzlichen Schichten nicht zu einer steigenden Prognosegüte auf den Validierungsdaten, sondern teils sogar zu Overfitting [31]. Um die Vorhersagegüte der Prognosemodelle bewerten zu können, betrachten wir den durchschnittlichen absoluten Fehler in Sekunden (engl. Mean Absolute Error, MAE) [33] und die Wurzel der mittleren quadratischen Abweichung (engl. Root Mean Squared Error, RMSE) [7]. Zudem leiten wir aus obigen Ausführungen noch folgendes Designprinzip hinsichtlich der DR2 ab:

DP6: Das KNN-Design muss längerfristige Abhängigkeiten zwischen zwei relevanten Messpunkten in dem zu prognostizierenden System berücksichtigen (z.B. Verzögerungseffekte im Verkehr).

Die kompletten Projektdateien sind online auf der Plattform GitHub³ abrufbar.

4 Ergebnisse

Nach dem Training des DNN werden die Fehlermaße der Validierungsdaten für die verschiedenen Architekturen und Vorhersagehorizonte in Abbildung 3 verglichen und evaluiert. Der NRW kann die anderen Modelle nur bei einem Vorhersagehorizont von

3 Verfügbar unter <https://github.com/jaib0001/TrafficFlowPrediction>

15 Minuten übertreffen. Die Fehlerwerte des NRW steigen erwartungsgemäß mit größerem Vorhersagehorizont stark an. Der historische Durchschnitt zeigt sich als robustes Basismodell, das unabhängig vom Vorhersagehorizont nur vom LSTM-Netz im Fehlermaß konstant unterboten werden kann. Dem DNN gelingt es, für alle Vorhersagehorizonte konstante Fehlerwerte zu erreichen. Es liegt auf dem Niveau des historischen Durchschnitts. Das LSTM-Netz weist für die Vorhersagehorizonte von 30 und 60 Minuten ein deutlich geringeres Fehlermaß als alle anderen Modelle auf. Für das LSTM-Netz lässt sich eine im Vergleich höhere und über weite Vorhersagehorizonte konstante Prognosegenauigkeit für die Daten feststellen.

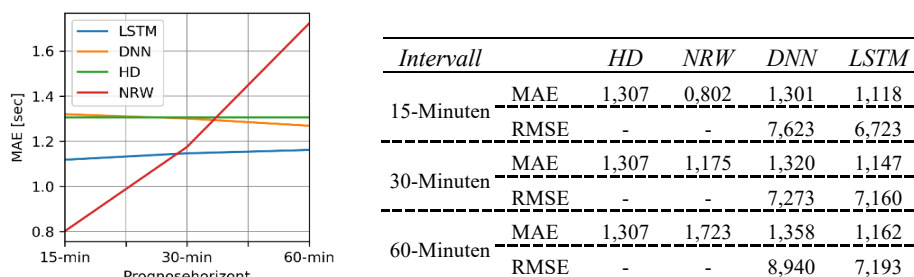


Abbildung 3: Ein Vergleich des MAE für alle Modelle und Vorhersagehorizonte

Zur weiteren Veranschaulichung zeigt Abbildung 4 einen Vergleich der Prognose zwischen dem LSTM-Netz und dem DNN für einen Vorhersagehorizont von 60 Minuten. Dazu wurde für jeden Tageszeitpunkt eine Prognose der Verweildauer am Sensor A008_10 erstellt. Die auftretenden Abweichungen zwischen allen zehn Sensoren und den Realwerten wurden mittels des MAE berechnet.

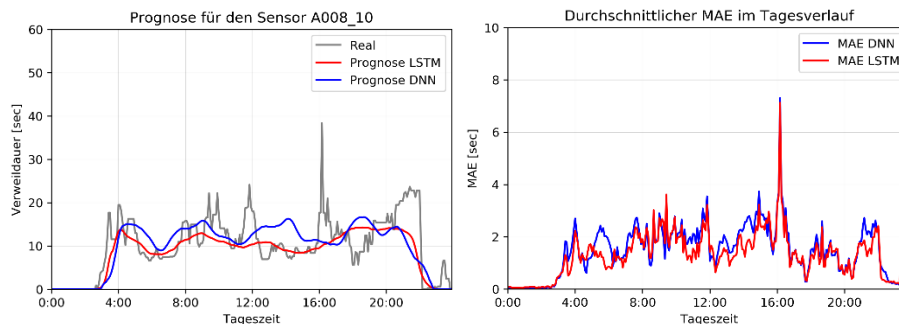


Abbildung 4: Prognose und MAE des LSTM und des DNN für den Sensor A008_10 am 17.06.2019

Ein Vergleich der beiden Abbildungen zeigt, dass das LSTM-Netz den morgendlichen Berufsverkehr besser als das DNN in der Prognose abbildet. Im gewählten Beispiel wird gegen 16:00 Uhr eine starke Spitze in der Verweildauer an der Kreuzung sichtbar.

Beiden Netzen gelingt es nicht, diese zu prognostizieren, was sich in einer stark ausschlagenden Fehlerkurve bemerkbar macht. Diese zufälligen Spitzen durch unvorhergesehene Ereignisse (Unfälle, Veranstaltungen, Unwetter) werden ebenfalls durch Polson et al. [27] beschrieben und können nicht durch die Modelle prognostiziert werden. Im Weiteren wird der Einfluss der zusätzlichen Zeit- und Wettermerkmale auf die Prognosegenauigkeit des DNN und LSTM-Netzes untersucht (Tabelle 2). Dazu wurden die Netze unter verschiedenen Konfigurationen trainiert und die Fehlermaße der Validierungsdaten verglichen.

Tabelle 2: Einfluss zusätzlicher Merkmale bei einem Vorhersagehorizont von 60 Minuten

		<i>Mit zus. Merkmalen</i>	<i>Ohne zus. Merkmale</i>	<i>Nur mit Zeit- Merkmalen</i>	<i>Nur mit Wetter- Merkmalen</i>
LSTM	MAE	1,162	1,155	1,164	1,173
	RMSE	7,193	7,171	7,543	7,267
DNN	MAE	1,358	1,226	1,226	1,314
	RMSE	8,941	7,599	7,676	7,442

Die Ergebnisse für Konfigurationen mit und ohne zusätzliche Daten sind indifferent. Für das LSTM-Netz lässt sich unter Auslassung der zusätzlichen Merkmale keine wesentliche Veränderung des Fehlermaßes erkennen. Das DNN zeigt sogar teilweise eine Verbesserung der Fehlermaße unter Auslassung der Zeit- und Wettermerkmale.

5 Diskussion

Im Rahmen der Entwicklung eines KNN zur Verkehrsprognose konnte unter Rückgriff auf bewährte Architekturen und Verfahren aus dem Bereich der Verkehrsprognose mittels der Verkehrssensordaten der Stadt Darmstadt ein Prognosemodell erstellt werden. Die Daten des KNN können dazu verwendet werden, dem Nutzer einer SM-Lösung situationsbezogen und individuell zugeschnittene Verkehrsprognosen bereitzustellen. Der Modellierung ging eine umfangreiche Aufbereitung der Sensordaten voraus. Das LSTM-Netz konnte die höchste Prognosegenauigkeit aller entwickelten Modelle erzielen. Da die Einflüsse der einzelnen Merkmale zwischen DNN und LSTM-Netz überwiegend vergleichbar sind, lassen sich die Prognosevorteile des LSTM-Netzes nicht allein damit erklären. Eine Untersuchung der Zeitachse der Netzeingabe für die beiden Modelle mittels des Ansatzes der „permutation importance“ [47] zeigt in Abbildung 5, dass das LSTM-Netz auch weiter zurückliegende Sensorerfassungen in der Prognose berücksichtigt. Das DNN konzentriert sich hingegen eher auf die jüngere Vergangenheit. Damit bestätigt sich die von Polson et al. [27] geäußerte These, dass ein LSTM-Netz in der Lage ist, die längerfristigen zeitlichen Abhängigkeiten des Verkehrsflusses in die Prognose miteinzubeziehen. Ihre Beobachtungen, dass jüngere Erfassungen einen stärkeren Einfluss als ältere haben, kann für beide Architekturen bestätigt werden [27].




Abbildung 5: Vergleich des Einflusses einzelner Zeitpunkte in der Netzeingabe. Je niedriger der Index T, desto älter die Sensorerfassung

Die Analyse des Einflusses zusätzlicher Merkmale mittels „permutation importance“ zeigte, dass besonders die als Sinus- und Kosinusspalten kodierte Tageszeit bedeutsam für das neuronale Netz ist. Daneben scheint die Information über den Wochentag Freitag einen deutlichen Mehrwert zu bieten (Abbildung 6). Ein Vergleich mit Abbildung 1 zeigt für Freitag einen zu den anderen Wochentagen fast identischen Verlauf der Verweildauer. Gegen Nachmittag wird dieser jedoch durch den früheren Heimreiseverkehr gestört. Hier kann spekuliert werden, dass das Merkmal für das KNN deshalb so bedeutsam ist, da es als einziges einen Hinweis zur Unterscheidung der sonst gleichförmig verlaufenden Wochentage liefert. Dadurch kann das Netz eine starke Fehlprognose für Freitagnachmittag vermeiden. Die Wochentage Samstag und Sonntag bieten weniger Mehrwert, da ihr Verlauf sich grundsätzlich stark von den anderen Wochentagen unterscheidet. Die Fehlermaße der neuronalen Netze wurden durch Auslassung der zusätzlichen Zeit- und Wettermerkmale (Abbildung 6) beim Training kaum beeinflusst.

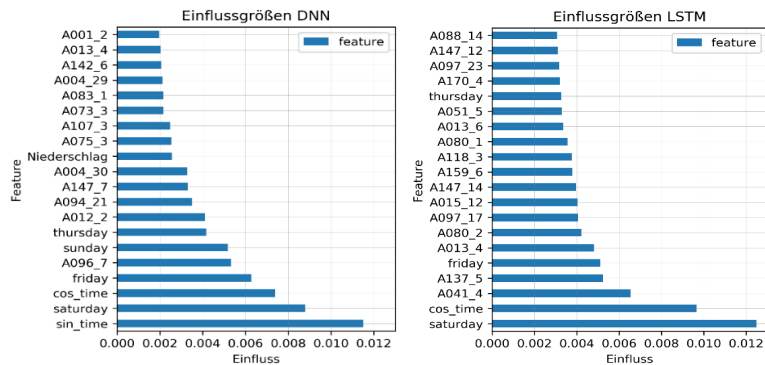


Abbildung 6: Vergleich des Einflusses einzelner Merkmale in der Netzeingabe

Eine Analyse konnte jedoch zeigen, dass die Zeit- und Wettermerkmale, sofern sie in das Training des Netzes miteinbezogen wurden, die Prognose stark beeinflussen. Dies erscheint zunächst widersprüchlich. Jedoch kann die kaum messbare Auswirkung einer Auslassung dieser Merkmale durch Substitutionseffekte erklärt werden. Wird das Netz ohne die zusätzlichen Merkmale trainiert, greift es stattdessen auf alternative Merkmale

(also Sensoren) mit ähnlicher Aussagekraft zurück. Somit kommt es zu keinen messbaren Unterschieden der Prognosegenauigkeit. Unsere Analysen ergaben, dass die beiden KNN sich umso stärker auf die zusätzlichen Merkmale stützen, desto weniger Sensorstandorte miteinbezogen wurden. Das heißt, dass für die im Vergleich umfangreichen Sensordaten aus Darmstadt eine zusätzliche Anreicherung nicht erforderlich ist. Bei nur wenigen Sensorstandorten, wie beispielsweise in einigen der untersuchten Beiträge (z.B. [23] oder [27]), erreicht die Miteinbeziehung zusätzlicher Merkmale eine Verbesserung der Prognosegenauigkeit. Aus dem umfangreichen Datenbestand der Stadt Darmstadt wurden in einem ersten Schritt nur ausgewählte Daten zum Training verwendet. Damit enthalten die Daten noch Potenzial zur Steigerung der Prognosegenauigkeit und Generalisierungsfähigkeit der Modelle durch ein Training mit Daten über mehrere Monate und Jahre. Die Festlegung auf die Architekturen und ihre Hyperparameter erfolgte aufgrund der untersuchten Literatur (u.a. [44–46]). Die Verkehrsprognosen des KNN sind jedoch nicht ohne weiteres für eine nachfolgende SM-Lösung verwendbar. Hierfür müssen die Daten nach der Bereitstellung durch das KNN entsprechend aufbereitet und per Schnittstelle für eine SM-Lösung zur Verfügung gestellt werden (vgl. DR4), was uns zu folgendem Designprinzip führt:

DP7: Die Verkehrsprognosen müssen für nachfolgende Anwendungen aufbereitet werden.

Die erläuterten Erkenntnisse auf Grundlage der DRs und DPs sind noch weitergehenden Untersuchungen zu unterziehen und sollten abschließend in eine umfassende Designtheorie inklusive zugehöriger Designfeatures überführt werden [36], [48].

6 Zusammenfassung und Ausblick

Im vorliegenden Beitrag wurden KNN auf ihre Eignung zur Entwicklung eines Prognosemodells für die Verkehrsauslastung basierend auf Daten der Stadt Darmstadt überprüft. Aus den dazu aufbereiteten Sensordaten ließen sich Informationen über die aktuelle Verkehrssituation ableiten und Ereignisse wie Stoßzeiten im Berufsverkehr oder Feiertage erkennen. Durch Analyse des aktuellen Forschungsstands konnten Verfahren ermittelt werden, die auf die Problemstellung angewendet wurden. Nach Auswertung der Modelle zeigte sich das LSTM-Netz im Prognostizieren der in naher Zukunft zu erwartenden Verkehrssituation dem DNN sowie den Basismodellen überlegen. Durch weitere Analyse konnte gezeigt werden, dass das LSTM-Netz auch weiter zurückliegende Sensorerfassungen in die Prognose miteinbezieht, durch die sich der Vorsprung gegenüber dem DNN erklären lässt. Erwartungsgemäß lag bei allen Modellen eine abnehmende Prognosegenauigkeit bei zunehmendem Vorhersagehorizont vor. Ein Vergleich der Fehlermaße für das Anreichern der Verkehrsdaten mit weiteren Zeit- oder Wettermerkmalen konnte entgegen den Erwartungen keine weiteren Verbesserungen der Prognosegenauigkeit erzielen. Im Rahmen weiterer Forschung bietet sich aber die Evaluation weiterer Architekturen und Hyperparameter für den Verkehrskontext an. Die Optimierung der Modelle sowie ihre abschließende Integration in eine umfassende SM-Lösung ergeben ebenfalls konkrete Möglichkeiten für weitere Forschung.

Literaturverzeichnis

1. Deschermeier, P.: Die Großstädte im Wachstumsmodus. Stochastische Bevölkerungsprognosen für Berlin, München und Frankfurt am Main bis 2035. IW (2016)
2. Benevolo, C., Dameri, R.P., D'Auria, B.: Smart Mobility in Smart City. In: Empowering Organizations. Enabling Platforms and Artefacts, 11, S. 13–28. Springer, Cham (2016)
3. Schmidt, W., Borgert, S., Fleischmann, A., Heuser, L., Müller, C., Schweizer, I.: Smart Traffic Flow. HMD 52, S. 585–596 (2015)
4. Wolter, S.: Smart Mobility- Intelligente Vernetzung der Verkehrsangebote in Großstädten. In: Zukünftige Entwicklungen in der Mobilität, S. 527–548. Verlag, Wiesbaden (2012)
5. Mohammed, O., Kianfar, J.: A Machine Learning Approach to Short-Term Traffic Flow Prediction: A Case Study of Interstate 64 in Missouri. In: 2018 IEEE International Smart Cities Conference (ISC2), S. 1–7. IEEE (2018)
6. Ebner, K., Anschütz, C., Smolnik, S.: STREAM – Ein Smart-Mobility-System zur langfristigen Einbindung von Pendlern. In: Proff (Hg.) 2020 – Neue Dimensionen in der Mobilität, S. 545–558
7. Lv, Y., Duan, Y., Kang, W., Li, Z., Wang, F.-Y.: Traffic Flow Prediction With Big Data: A Deep Learning Approach. IEEE Trans. Intell. Transport. Syst., S. 865–873 (2014)
8. Zhang, D., Kabuka, M.R.: Combining Weather Condition Data to Predict Traffic Flow: A GRU Based Deep Learning Approach. In: 2017 IEEE 15th Intl Conf on Dependable, Automatic and Secure Computing, 15th Intl Conf on Pervasive Intelligence and Computing, 3rd Intl Conf on Big Data Intelligence and Computing and Cyber Science and Technology Congress(DASC/PiCom/DataCom/CyberSciTech), S. 1216–1219. IEEE (2017)
9. Ebner, K., Mattes, P., Smolnik, S.: Are You Responsible for Traffic Congestion? A Systematic Review of the Socio-technical Perspective of Smart Mobility Services. In: Proceedings of the 52nd Hawaii International Conference on System Sciences. Hawaii International Conference on System Sciences (2019)
10. Wirth, R., Hipp, J.: CRISP-DM: Towards a standard process model for data mining (2000)
11. Bogenberger, K., Belzner, H., Kates, R.: Ein hybrides Modell basierend auf einem Neuronalen Netz und einem ARIMA-Zeitreihenmodell zur Prognose lokaler Verkehrskenngrößen. In: Ágnes, V.T. (ed.) Egy megkésett vallomás. Z-Press, [Miskolc] (2009)
12. Altendeitering, M., Pflügler, C., Schreieck, M., Fröhlich, S., Wiesche, M., Kremer, H.: Prognose von Parkplatzdaten. In: Management digitaler Plattformen, S. 193–206. Springer Fachmedien, Wiesbaden (2018)
13. Anschütz, C., Ebner, K., Smolnik, S.: Spielerisch zum Ziel: Initiale Designprinzipien für die nachhaltige Gestaltung von Smart-Mobility-Apps auf Basis einer Marktanalyse. In: WI2020 Zentrale Tracks, S. 538–553. GITO Verlag (2010)
14. Kagermann, H.: Die Mobilitätswende: Die Zukunft der Mobilität ist elektrisch, vernetzt und automatisiert. In: CSR und Digitalisierung. Der digitale Wandel als Chance und Herausforderung für Wirtschaft und Gesellschaft, S. 357–371. Springer Gabler, Berlin, Heidelberg (2017)
15. Tcheumadjeu, L.C.T., Suske, D., Sohr, A., Bei, X.: Traffic Information Systems for Smart Mobility as part of Smart Cities. International Symposium on Smart Mobility for Smarter Cities (SmartCity 2016) 2016

16. Jiber, M., Lamouik, I., Ali, Y., Sabri, M.A.: Traffic flow prediction using neural network. In: 2018 International Conference on Intelligent Systems and Computer Vision (ISCV), S. 1–4. IEEE (2018)
17. Rathore, M.M., Son, H., Ahmad, A., Paul, A.: Real-time video processing for traffic control in smart city using Hadoop ecosystem with GPUs. *SoftCom*. 22, S. 1533–1544 (2018)
18. Astarita, V., Festa, D.C., Giofrè, V.P.: Mobile Systems applied to Traffic Management and Safety: a state of the art. *Procedia Computer Science* 134, S. 407–414 (2018)
19. Meroux, D., Telenko, C., Jiang, Z., Fu, Y.: Towards Design of Sustainable Smart Mobility Services through a Cloud Platform. In: SAE Technical Paper Series. SAE International 400 Commonwealth Drive, Warrendale, PA, United States (2020)
20. Chao, Q., Bi, H., Li, W., Mao, T., Wang, Z., Lin, M.C., Deng, Z.: A Survey on Visual Traffic Simulation: Models, Evaluations, and Applications in Autonomous Driving. *Computer Graphics Forum* 39, S. 287–308 (2020)
21. Wilkie, D., Sewall, J., Lin, M.C.: Transforming GIS data into functional road models for large-scale traffic simulation. *IEEE transactions on visualization and computer graphics* 18, S. 890–901 (2012)
22. Ameli, M., Lebacque, J.-P., Leclercq, L.: Improving traffic network performance with road banning strategy: A simulation approach comparing user equilibrium and system optimum. *Simulation Modelling Practice and Theory* 99, S. 101995 (2020)
23. Bojarski, M., Yeres, P., Choromanska, A., Choromanski, K., Firner, B., Jackel, L., Muller, U.: Explaining How a Deep Neural Network Trained with End-to-End Learning Steers a Car (2017)
24. Jia, Y., Wu, J., Xu, M.: Traffic Flow Prediction with Rainfall Impact Using a Deep Learning Method. *Journal of Advanced Transportation* 2017 (2017)
25. Goodfellow, I., Bengio, Y., Courville, A.: *Deep learning*. MIT Press, Cambridge, Massachusetts, London, England (2016)
26. Schneider, W., Toplak, W.: Verkehrsprognosen mit Visuellem Data Mining und Künstlicher Intelligenz. *Elektrotech. Inftech.* 125, S. 232–237 (2008)
27. Polson, N., Sokolov, V.: Deep Learning for Short-Term Traffic Flow Prediction. *Transportation Research Part C: Emerging Technologies* 79, S. 1–17 (2017)
28. Essien, A., Petrounias, I., Sampaio, P., Sampaio, S.: Improving Urban Traffic Speed Prediction Using Data Source Fusion and Deep Learning. In: 2019 IEEE International Conference on Big Data and Smart Computing (BigComp), S. 1–8. IEEE (2019)
29. Guo, J., Wang, Z., Chen, H.: On-line Multi-step Prediction of Short Term Traffic Flow Based on GRU Neural Network. In: Proceedings of the 2nd International Conference on Intelligent Information Processing - IIP'17, S. 1–6. ACM Press, New York, USA (2017)
30. Liu, Y., Zheng, H., Feng, X., Chen, Z.: Short-term traffic flow prediction with ConvLSTM. In: 2017 9th International Conference on Wireless Communications and Signal Processing (WCSP), 1–6. IEEE (2017)
31. Chollet, F.: *Deep learning with Python*. Manning, Shelter Island, NY (2018)
32. Duda, R.O., Hart, P.E., Stork, D.G.: *Pattern Classification*. Wiley-Interscience (2012)
33. Wang, W., Bai, Y., Yu, C., Gu, Y., Feng, P., Wang, X., Wang, R.: A network traffic flow prediction with deep learning approach for large-scale metropolitan area network. In: NOMS 2018 - 2018 IEEE/IFIP Symposium, 1–9. IEEE (2018)

34. Hochreiter, S., Schmidhuber, J.: Long Short-Term Memory. *Neural Computation* 9, S. 1735–1780 (1997)
35. Graves, A., Liwicki, M., Fernández, S., Bertolami, R., Bunke, H., Schmidhuber, J.: A novel connectionist system for unconstrained handwriting recognition. *IEEE transactions on pattern analysis and machine intelligence* 31, Seiten 855–868 (2009)
36. Jones, D., Gregor, S.: The Anatomy of a Design Theory. *JAIS* 8, S. 312–335 (2007)
37. Pessa, E.: Neural Network Models. In: Management Association, I.R. (ed.) *Nature-inspired computing. Concepts, methodologies tools, and applications*, S. 368–395 (2017)
38. Fajtl, J., Argyriou, V., Monekosso, D., Remagnino, P.: AMNet: Memorability Estimation with Attention (2018)
39. Schimbinschi, F., Nguyen, X.V., Bailey, J., Leckie, C., Vu, H., Kotagiri, R.: Traffic forecasting in complex urban networks: Leveraging big data and machine learning. In: 2015 IEEE International Conference on Big Data (Big Data), S. 1019–1024. IEEE (2015)
40. Biancofiore, F., Busilacchio, M., Verdecchia, M., Tomassetti, B., Aruffo, E., Bianco, S., Di Tommaso, S., Colangeli, C., Rosatelli, G., Di Carlo, P.: Recursive neural network model for analysis and forecast of PM10 and PM2.5. *Atmospheric Pollution Research* 8, S. 652–659 (2017)
41. Kim, Y., Soo Choi, E., Seo, J., Choi, W.-S., Lee, J., Lee, K.: A novel approach to predicting human ingress motion using an artificial neural network. *Journal of biomechanics* 84, S. 27–35 (2019)
42. Marban, O., Mariscal, G., Segovia, J.: A Data Mining & Knowledge Discovery Process Model. 1. In: *Data Mining and Knowledge Discovery in Real Life Applications*. IntechOpen, Rijeka (2009)
43. Nodeh, M.J., Calp, M.H., Şahin, İ.: Analyzing and Processing of Supplier Database Based on the Cross-Industry Standard Process for Data Mining (CRISP-DM) Algorithm. In: Hemanth, D.J., Kose, U. (eds.) *Proceedings of the International Conference on Artificial Intelligence and Applied Mathematics in Engineering '19*, 43, S. 544–558. Springer (2020)
44. Oh, S.-d., Kim, Y.-j., Hong, J.-s.: Urban Traffic Flow Prediction System Using a Multifactor Pattern Recognition Model. *IEEE Intell. Transport. Syst. (IEEE Transactions on Intelligent Transportation Systems)* 16, Seiten 2744–2755 (2015)
45. Kang, D., Lv, Y., Chen, Y.-y.: Short-term traffic flow prediction with LSTM recurrent neural network. In: 2017 IEEE 20th International Conference on Intelligent Transportation Systems (ITSC), S. 1–6. IEEE (2017)
46. Zhang, Y.-D., Pan, C., Chen, X., Wang, F.: Abnormal breast identification by nine-layer convolutional neural network with parametric rectified linear unit and rank-based stochastic pooling. *Journal of Computational Science* 27, S. 57–68 (2018)
47. Ramachandran, R.: Using neural networks to predict icephobic performance (2020)
48. Anshütz, C., Ebner, K., Smolnik, S.: Spielerisch zum Ziel: Initiale Designprinzipien für die nachhaltige Gestaltung von Smart-Mobility-Apps auf Basis einer Marktanalyse. In: Gronau, N., Heine, M., Poustechi, K., Krasnova, H. (eds.) *WI2020 Zentrale Tracks*, S. 538–553. GITO Verlag (2020)