

Anwendung von künstlichen neuronalen Netzen (KNN) zur Erfassung von Verkehrsdaten und Achslasten mithilfe von Schwingungsmessungen

Application of Artificial Neural Networks for Recording Traffic Data and Axle Loads with the Help of Vibration Measurements

Boris Resnik, Jörg Patzak, Wolf Uhlig

Eine sehr wesentliche Eingangsgröße in der Dimensionierung des Oberbaus von Straßen und tragenden Konstruktionen der erforderlichen Ingenieurbauwerke, wie z.B. Brücken, stellt die prognostizierte Verkehrsbelastung innerhalb der vorgesehenen Nutzungsdauer dar. Die modernen rechnerischen Verfahren benötigen dafür zwingend praxisnahe Eingangsgrößen der aktuellen örtlichen Verkehrsbelastung und die Erhebung der lokal auftretenden Achslasten. Wird der reale Verkehr, d.h. alle auftretenden Fahrzeugtypen, lückenlos erfasst und je nach den entsprechenden Achslasten zuverlässig klassifiziert, können sogenannte objektspezifische Achslastkollektive ermittelt werden, auf deren Basis genauere Aussagen zur prognostizierten Lebensdauer getroffen werden können. Besonders effizient ist eine solche Erfassung, wenn dafür ohnehin verwendete Sensoren des Monitoringsystems, wie z.B. typische Low-Cost-Beschleunigungssensoren, eingesetzt und die erfassten Daten mit einem computergestützten Beurteilungssystem vollautomatisch verarbeitet werden. Es liegt auch nahe, zu diesem Zweck moderne Methoden der künstlichen Intelligenz einzusetzen, welche die Vorteile des menschlichen Lernens mit der enormen Rechenkapazität heutiger Prozessoren kombinieren. Anhand von umfangreichen Messdaten eines aktuellen Überwachungsprojekts in Berlin wurde von den Autoren beispielhaft untersucht, inwieweit KNN bei der Auswertung von Schwingungsmessungen dienlich sind, um eine Verkehrszählung sowie Schätzung von Achslasten nach bestimmten Fahrzeugklassen erfolgreich zu ermöglichen.

Schlüsselwörter: Verkehrsbelastung, Achslasten, Mustererkennung, künstliche Intelligenz, künstliches neuronales Netz

A very important input variable in the dimensioning of roads and their load-bearing structures such as bridges is the predicted traffic load within the intended service life. The modern mathematical methods for such calculations required reliable information for current local traffic and occurring axle loads. If all vehicle types are recorded and classified according to the corresponding axle loads, so-called object-specific axle load collectives can be determined. This information can be used also to make precise statements about the expected service life of structures. Such a data acquisition is particularly efficient if existing sensors of the monitoring system, such as typical low-cost acceleration sensors, are used and the acquired data are processed fully automatically with a computer-aided evaluation system with the modern methods of artificial intelligence. The effectiveness of the classification was evaluated by experiments on

a bridge in Berlin, Germany. Model training was applied using the CNN method for vehicle classification, resulting in good overall classification accuracy.

Keywords: *Traffic load, axle loads, pattern recognition, artificial intelligence, artificial neural network*

1 ERFASSUNG VON VERKEHRSDATEN UND ACHSLASTEN

Das Verkehrsaufkommen auf deutschen Straßen steigt ständig. Zum Erhalt des Verkehrsflusses, zur Erhöhung der Verkehrssicherheit und Anwendung von modernen dynamischen Navigationssystemen ist die Gesellschaft in zunehmenden Maße auf aktuelle und genaue Informationen über die Verkehrslage angewiesen. Die zuverlässigen Verkehrsdaten bilden unter anderem die Grundlage für eine langfristige und beanspruchungsgerechte Dimensionierung von Straßenoberbauten und die Bemessung von Brückenbauwerken. Insbesondere die rechnerischen Verfahren nach RDO Asphalt /RDO Asphalt 2009/ und RDO Beton /RDO Beton 2009/ benötigen zwingend praxisnahe Eingangsgrößen der örtlichen Verkehrsbelastung. Die Erfassung von Verkehrsdaten wird in diesem Beitrag ausschließlich in diesem Zusammenhang näher behandelt.

Die Verkehrsdaten, wie Anzahl, Fahrtrichtung, Geschwindigkeit, Fahrzeuglänge usw., können heutzutage mit unterschiedlichen Verfahren und entsprechenden speziellen Messsystemen erfasst werden. Dazu gehören u.A.: Induktionsschleifen-, Video-, Radar-, Ultraschall-, Infrarot- und Magnetdetektoren sowie unterschiedliche Kombinationen aus ihnen (Abb. 1). In diesem Beitrag werden nur einige von diesen Verfahren näher betrachtet, um einen Vergleich mit der entwickelten Methodik zu ermöglichen. So werden bei den oftmals verwendeten Induktionsschleifendetektoren die Drahtschleifen mit vordefinierter Abmessung in der Fahrbahn verlegt und dann versiegelt. In diesen Drähten wird dann ein Magnetfeld erzeugt, welches bei Überfahrt eines metallischen Fahrzeugs gestört wird. Je nach Fahrzeug kommt es zu einer charakteristischen Induktivitätsänderung, anhand derer jedes Fahrzeug kategorisiert werden kann /Höfler 2006/. Die Installation von Videodetektion erfolgt dagegen durch Anbringung von Detektoren (Kameras) über der Fahrbahn. Das Messprinzip von Videodetektoren basiert entweder auf der Erkennung von Veränderungen in bestimmten Bereichen gegenüber einem Referenzbild oder auf der Erkennung und Verfolgung von Fahrzeugen (Tracking-Verfahren). Für die Fahrzeugdetektion im Straßenverkehr können außerdem aktive Radarsysteme im Mikrowellenbereich eingesetzt werden. Die Erfassung von Fahrzeugen mithilfe dieser Detektoren erfolgt dann unter Nutzung des Dopplereffekts, d.h. der Frequenzänderung einer elektromagnetischen

Welle durch die Relativbewegung von Sender und reflektierendem Fahrzeug zueinander.

Eine wesentliche Eingangsgröße bei der Dimensionierung des Oberbaus von Straßen und tragenden Konstruktionen der erforderlichen Ingenieurbauwerke, wie z.B. Brücken, stellt die prognostizierte Verkehrsbelastung innerhalb der vorgesehenen Nutzungsdauer dar. Sie ist allerdings nicht nur von der Anzahl der Fahrzeuge, sondern auch von den entsprechenden Achslasten abhängig. Dabei ist insbesondere der Schwerverkehr von Bedeutung, da sich mit steigenden Achslasten auch die Beanspruchung von tragenden Konstruktionen sehr schnell erhöht. Rechnerische Dimensionierungsverfahren im Straßenbau setzen die sog. Achslastkollektive zwingend als eine Eingangsgröße des Verfahrens voraus, um die erforderliche Schichtdicken festlegen zu können. Anzustreben sind dabei die Achslastmessungen, auf deren Grundlage die objektspezifische Achslastverteilung ermittelt werden kann. Das Arbeitspapier „Eingangsgrößen für die Dimensionierung und Bewertung der strukturellen Substanz“ /AP EDS-1 2022/ stellt die Möglichkeiten der Ermittlung relevanter Verkehrsbelastungsdaten zusammen und erläutert die theoretischen Hintergründe.

Grundsätzlich ist bei der Erfassung von Achslasten zwischen statischen und dynamischen Wiegesystemen zu unterscheiden. Statische Wiegesysteme wie Plattformwaagen und Radlastwaagen stellen das Gewicht stillstehender Fahrzeuge fest. Beim hier behandelten Thema sind jedoch insbesondere die sog. dynamischen Wiegesysteme (Platten- und Streifensensoren) von Interesse. Die Gewichtsmessung bei solchen Systemen erfolgt während der Fahrt, wobei zurzeit ebenfalls verschiedene physikalische Messtechnologien, wie z.B. Dehnungsmessstreifen (DMS), Piezosensoren, kapazitive Sensoren usw., eingesetzt werden können (Abb. 2).

Eine Erfassung der Achslasten während der Fahrt (Weight In Motion – WIM) kann mit den speziellen stationären Messeinrichtungen durchgeführt werden. Die Ausstattung der Messquerschnitte umfasst dabei meistens neben der eigentlichen Achslasterfassung auch die Induktivschleifen (Abb. 1) zur Registrierung von Fahrzeugen und ihrer Geschwindigkeit. Solche Messstellen zur statistisch relevanten Erfassung von Achshäufigkeiten und Achslasten des Schwerverkehrs bedürfen eines sehr hohen Investitionsaufwands und sind in Deutschland gegenwärtig nur auf einzelnen Bundesautobahnen verfügbar. So betreibt die Bundesanstalt für Straßenwesen (BASt) ein spezielles Achslastmessstellennetz dieser Art, welches



Abb. 1 | Messeinrichtungen für eine Verkehrserfassung (exemplarisch)




Abb. 2 | Messeinrichtungen für eine Achslasterfassung (exemplarisch)

aktuell 41 Richtungsmessstellen an 21 Querschnitten umfasst /BAST 2022/. Daten dieser Achslastmessstellen (AMS) auf den Bundesautobahnen werden in einem einheitlichen Datenformat zur Verfügung gestellt und können für mehrere Jahre bei den jeweiligen Messstellenquerschnitten heruntergeladen werden. Auch in anderen Ländern wurden inzwischen erfolgreich ähnliche Projekte auf ausgewählten Autobahnabschnitten realisiert. Auf allen anderen Strecken der Autobahnen sowie im gesamten nachgeordneten Straßennetz liegen jedoch praktisch keine verlässlichen Informationen zur Höhe der Achslasten des Schwerverkehrs vor.

Die hier vorgeschlagene Methodik der Datenerfassung ermöglicht es generell, sowohl die Fahrzeugtypen zu erkennen und zu klassifizieren als auch die entsprechenden Achslasten zu ermitteln. Da dabei Low-Cost-Sensoren verwendet werden und keine spezielle Eingriffe in den vorhandenen Ingenieurkonstruktionen erforderlich sind, kann diese Methodik auf der Basis von künstlicher Intelligenz (KI) als eine sinnvolle, preiswerte Alternative bzw. eine effektive Ergänzung zu allen oben genannten Verfahren betrachtet werden.

2 DATENERFASSUNG

Die Datenerfassung sowie Datenanalyse bzw. -interpretation werden in diesem Beitrag exemplarisch am Beispiel der Freybrücke (Havelquerung) veranschaulicht. Dieses Bauwerk gehört zur etwa 10 km langen Heerstraße, die eine wichtige Verbindung zwischen den westlichen Stadtteilen und dem Zentrum Berlins darstellt und täglich

von rund 60 000 Fahrzeugen passiert wird. Darunter befindet sich ein nicht unbeträchtlicher Anteil an Schwerverlastverkehr in Form von Lkw und Bussen. Aufgrund der schnurgeraden Streckenführung sowie der Tatsache, dass keine nennenswerten Hindernisse den Verkehrsfluss vor der Brücke beeinträchtigen, konnte bei der Datenerfassung von einer relativ konstanten Geschwindigkeit der Fahrzeuge (50 km/h) während der Überfahrt ausgegangen werden.

Es ist bekannt, dass u. A. schlanke Bauwerke mit niedrigen Eigenfrequenzen bei geringer Dämpfung unter Umständen aufgrund natürlicher Anregungsquellen, wie z. B. Wind oder Verkehr, in Schwingungen mit großer Amplitude versetzt werden. Deshalb wird heutzutage oftmals zusätzlich zu den üblichen statischen Untersuchungen der Baukonstruktionen auch eine intensive Betrachtung der Dynamik und speziell der auftretenden Schwingungen gefordert. Im behandelten Beispiel wurden deswegen, ergänzend zu anderen Messverfahren der Bauwerksüberwachung, Schwingungsmessungen mit einem typischen Beschleunigungsaufnehmer mit einer Abtastrate von 153 Hz durchgeführt /Resnik & Sargsyan 2019/. In Bezug auf das Hauptziel der Untersuchung musste bei der folgenden Datenanalyse festgestellt werden, ob die dynamischen Schwingungsparameter bei laufendem Verkehr (Eigenfrequenzen und -formen, Dämpfungskoeffizienten usw.) den Erwartungswerten entsprechen. In diesem Beitrag werden gezielt die Messungen an der Dehnungsfuge des Bauwerks analysiert (Abb. 3). Es wurde davon ausgegangen, dass jeder Achsübergang eines Fahrzeugs über diese Dehnungsfuge einen „Schlag“ bzw. Schwingungen verursacht würde, die in ihrer unmittelbaren Nähe besonders gut messbar sein

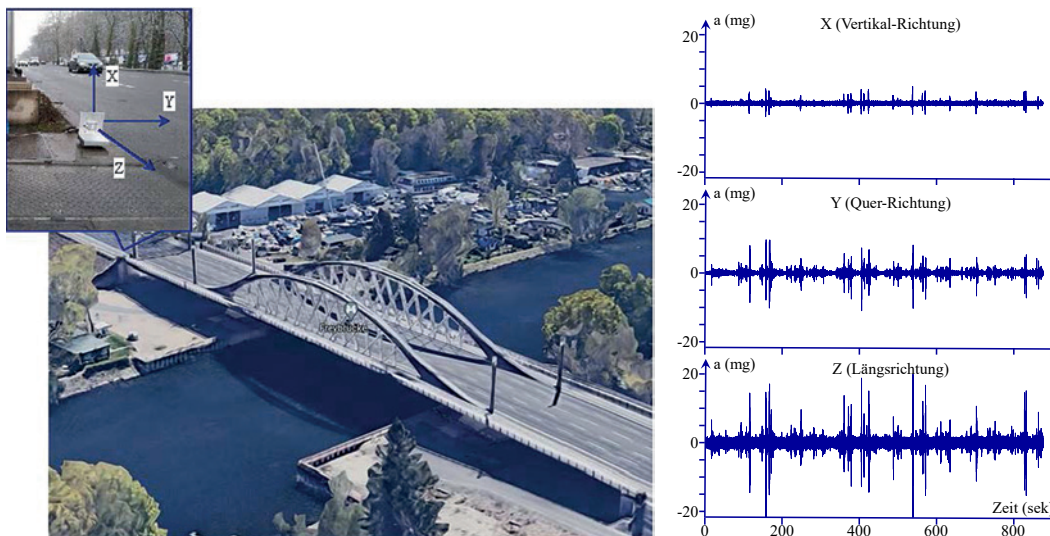


Abb. 3 | Datenerfassung mit einem Beschleunigungssensor

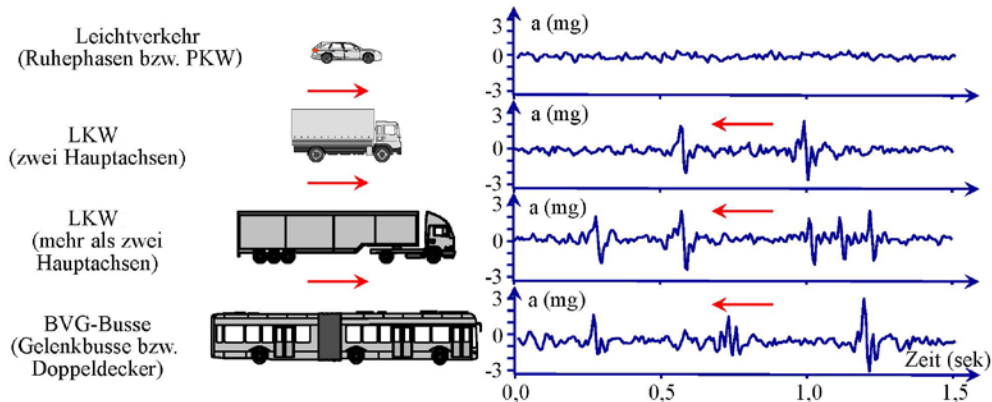


Abb. 4 | Ergebnisse je nach Fahrzeugart (X-Achse)

sollten. Außerdem waren der Sensor sowie der daneben platzierte Computer aufgrund ihrer „versteckten“ Lage hinter dem Pfeiler einer benachbarten Verkehrszeichenbrücke für Fahrzeugführer schwer einsehbar, sodass das Risiko von ungewollten Bremsmanövern (aus Neugier, Furcht vor einem „Blitzer“ etc.) minimiert werden konnte. Um die vorbeifahrenden Fahrzeuge einzelnen Ausschnitten der Messung zuordnen zu können, wurde eine parallele Videoaufzeichnung durchgeführt. Während der mehrstündigen Datenerfassung konnte ein normales, gut frequentiertes Verkehrsaufkommen von leichten und schweren Fahrzeugen dokumentiert werden.

In *Abb. 3* sind exemplarisch die Messergebnisse eines etwa 15-minütigen Intervalls für alle drei Messachsen dargestellt. Bei einem Blick auf die gewonnenen Daten, insbesondere auf die Größe der Ausschläge bei der Durchfahrt einzelner schwerer Fahrzeuge, sind erwähnenswerte Unterschiede zwischen den Achsen festzustellen. In vertikaler Richtung (X) weisen die Beschleunigungswerte eine Spannweite kleiner als 10 mg auf, während in den beiden horizontalen Achsen (Y und Z) wesentlich höhere Ausschläge mit Spannweiten von etwa 20 mg bzw. 40 mg festzustellen sind. Der wesentliche Grund dafür ist, dass die Messungen im behandelten Beispiel nicht auf den freihängenden Brückenteilen (z. B. in der Mitte), sondern direkt auf einem Widerlager und in der Nähe zur Dehnungsfuge (mit der Bewegungsfreiheit gerade in Längs- und Querrichtung) durchgeführt wurden.

Neben den absoluten Größen der Ausschläge ist das Verhältnis zwischen der Spannweite und der Größe des „normalen“ Schwingungsbereichs von besonderem Interesse. Was sich visuell schon an der „Dicke des Streifens“ erahnen lässt, kann durch eine numerische Betrachtung untermauert werden. Bei der Vertikalrichtung (X) ist dieses Verhältnis am kleinsten, d. h. die Spannweite ist hier nur ca. 8-mal so groß wie das Fenster des normalen Schwingungsverhaltens. Im Kontrast dazu ist das Verhältnis bei der Querrichtung (Y) wesentlich höher, die Spannweite ist über 20-mal größer als die normale Schwingungsspanne.

Die Analyse der vorliegenden Daten hat auch gezeigt, dass die schweren Fahrzeuge auf den nahegelegenen Fahrspuren deutlich sichtbare Unterschiede in den erfassten Schwingungen aufweisen (*Abb. 4*), während sich die Schwingungsmuster in den kompletten Ruhephasen, bei der Durchfahrt von leichten Fahrzeugen (Pkw) und reinem Gegenverkehr nur sehr geringfügig unterscheiden. Diese Erkenntnisse zeigen, dass auch mit einfachen Beschleunigungsmessungen eine Reihe von unterschiedlichen Klassifizierungen

möglich ist. Um den Gegenstand der vorliegenden Untersuchung auf ein überschaubares Maß einzugrenzen, beschränkten sich die Autoren im Folgenden auf die Detektion und Klassifikation des schweren Kraftverkehrs, da dessen Häufigkeit zur Einschätzung der Brückenstabilität deutlich relevanter ist als die Menge des leichteren Pkw-Verkehrs.

3 FAHRZEUGKLASSIFIZIERUNG MIT KNN

Die KNN-Technologie ist bereits seit mehr als 60 Jahren bekannt. Früher fehlten jedoch die Rechenleistungen für ihre effektive Anwendung bei der Lösung von praktischen Aufgaben. Die hier nur sehr kurz erläuterte KNN-Vorgehensweise ist inzwischen inhaltlich und mathematisch in einer enorm großen Anzahl von Publikationen beschrieben, die auch über eine schnelle Recherche gefunden werden können. Hier wird passend für die behandelten Anwendungen nur auf das entsprechende Kapitel der Publikation von /Heunecke et al. 2013/ verwiesen. Durch die Fortschritte im Bereich der Hardware und die Entwicklung neuer, wesentlich effizienterer Algorithmen erlebt diese Technologie inzwischen eine neue Blütezeit in vielen Anwendungsbereichen. Eine solche Lösungen verbirgt sich unter dem Begriff Convolutional Neural Network (CNN), auf Deutsch etwa „faltendes neuronales Netzwerk“. Grundsätzlich wird bei diesem Verfahren der Versuch unternommen, die Funktionsweise von menschlichen visuellen Systemen nachzubilden. Während die meisten Neuronen dabei nur auf einen kleinen Bereich des Wahrnehmungsfelds reagieren, verarbeiten die anderen die komplexeren Reize, die sie von den erstgenannten Neuronen übertragen bekommen. Eine typische Architektur eines CNN setzt sich deswegen aus zwei Abschnitten zusammen (*Abb. 5*): dem Detektions- und dem Identifikationsteil. Die Neuronen des ersten Teils werden dabei schichtweise angeordnet und jede nachfolgende Schicht reagiert nur auf einen lokalen Bereich der Vorgängerschicht. Die Schichten dienen der Extraktion von komplexen Eigenschaften eines Bilds bzw. einer Zeitreihe und können deswegen als eine spezielle Art der Komprimierung bzw. Filterung betrachtet werden. Anschließend folgt der Identifikationsteil, der typischerweise aus einem herkömmlichen KNN besteht und die eigentliche Klassifizierung vornehmen muss. Das Training von CNN-Modellen wird durch mehrere Vorwärts- und Rückwärtsberechnungen durchgeführt, wobei die Gewichte in den beiden oben genannten Teilen so angepasst werden, dass der

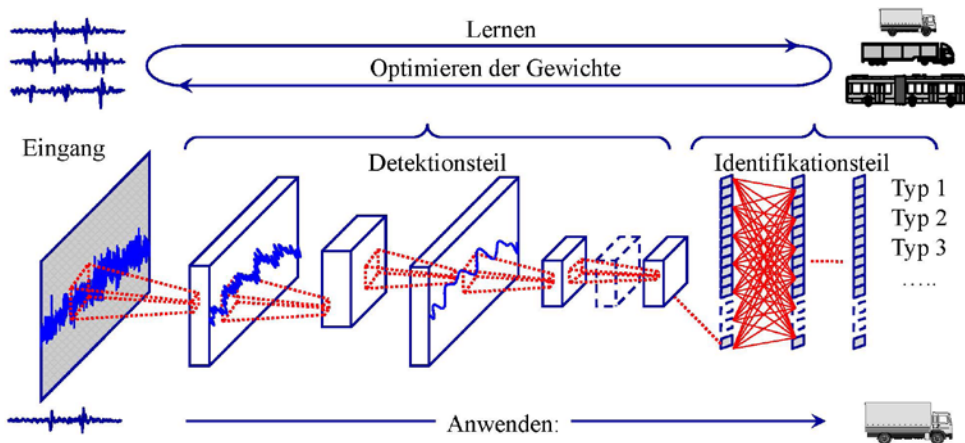


Abb. 5 | Anwendung eines CNN-Modells für die Lösung der gestellten Aufgabe

Abschlussfehler anhand zahlreicher Lernbeispiele minimiert wird. Bei der späteren Anwendung des gespeicherten Modells wird nur die Vorwärtsberechnung eingesetzt, die somit die unbekannt Antworten für weitere Beispiele liefern kann /vgl. Resnik 2021/.

Auch wenn es möglich ist, die erforderlichen CNN-Programme von Grund auf neu zu schreiben, ist es inzwischen viel einfacher, vorhandene sehr umfangreiche Bibliotheken zu verwenden. Die Auswertung von hier behandelten Beispielen wurde von den Autoren deswegen mit der multifunktionalen Open-Source-Bibliothek Keras (<https://keras.io>) in der Python-Umgebung vorgenommen, die sich bei der Entwicklung und der folgenden Analyse von Ergebnissen als ein sehr flexibles und schnelles Werkzeug erwiesen hat. Die sog. Hyperparameter von verwendeten KNN- bzw. CNN-Modellen zur Steuerung des Trainingsalgorithmus mithilfe der genannten Bibliothek müssen immer vor dem eigentlichen Training festgelegt werden. Bei der hier präsentierten Machbarkeitsstudie wurde deswegen zunächst die Suche nach den optimalen Hyperparametern anhand der vorliegenden Daten durchgeführt, auf die hier aber nicht eingegangen werden soll.

Anhand umfangreicher Tests zur Anwendung dieser Technologie auf die gestellte Klassifizierungsaufgabe, die von den Verfassern zwar realisiert wurden, aber hier wegen des begrenzten Umfangs des Beitrags nicht ausführlich beschrieben werden können, wurde festgestellt, dass eine binäre, d. h. ausschließlich auf zwei mögliche Varianten begrenzte Klassifizierung von Fahrzeugen anhand der Schwingungsmessungen für ein neuronales Netz bereits jetzt vielversprechend ist. Unterschiedliche multinomiale Klassifikationen sind dagegen noch zu komplex, um wegen unvermeidlicher „Ver-

schmierungen“ von Antworten auf unterschiedliche Fahrzeugtypen erfolgreich zu reagieren.

Für eine erfolgreiche Klassifizierung (hier „Leicht- vs. Schwerverkehr“) bedarf es bei der Anwendung von künstlichen neuronalen Netzen keiner mathematischen Beschreibung von gesuchten Mustern, sondern zahlreicher Lernbeispiele eines bestimmten Typs, die anhand der Videoaufnahmen gesucht und aus der Zeitreihe ausgeschnitten werden. Ein besonderes Augenmerk bei der Anwendung dieses Verfahrens sollte, wie immer, auf die optimale Größe des Fensters gelegt werden. Ausgehend von der mittleren Fahrgeschwindigkeit wurden Zeitintervalle von 230 Messwerten gewählt, die bei der genannten Abtastrate jeweils etwa 1,5-Sekunden-Abschnitte repräsentieren. In den dargestellten Datensätzen (Abb. 6) handelt es sich um solche Intervalle der erfassten Zeitreihen (vgl. Abb. 3 und Abb. 4) mit einer Durchfahrt eines schweren Fahrzeugs (rechts) und ohne solche Ereignisse (links). Um die Anwendbarkeit des gelernten Modells bei unterschiedlichen Daten (Maßstab der Änderungen, Vorzeichen usw.) zu ermöglichen, wurden bei der Auswertung sowohl die Trainings- als auch die Testdaten in den Bereich zwischen 0 und 1 transformiert, d. h. die kleinsten Werte erscheinen dabei als 0 und die größten Werte als 1 in jedem einzelnen Datensatz. Die Lernbeispiele selbst sind bekanntermaßen für eine Kontrolle der Sinnhaftigkeit eines Modells nicht geeignet. Um die Qualität der erstellten und gespeicherten Modelle zu beurteilen, wurden deswegen unabhängige Testbeispiele der gleichen Art verwendet. Bei genauer Betrachtung dieser Auswahl kann ihre Zugehörigkeit zu einer bestimmten Klasse auch visuell festgestellt werden. Trotz einer relativ geringen Anzahl von verwendeten Lernbeispielen




Abb. 6 | Anwendung eines CNN-Modells (Leicht- vs. Schwerverkehr) für die Testdaten




Abb. 7 | Anwendung des vorbereiteten CNN-Modells beim laufenden Betrieb

und eines recht großen Rauschens weisen die Ergebnisse eine gute Übereinstimmung mit den Soll-Werten auf (1,00 bzw. 100 % in Abb. 6).

Die getesteten CNN-Modelle für unterschiedliche Muster können später bei beliebigen Messreihen eingesetzt werden (Abb. 7). Bei der Analyse der Ergebnisse ist zu berücksichtigen, dass der Zeitpunkt von festgestellten Ereignissen in die Mitte des betrachteten Intervalls verschoben und somit mit einer bestimmten Verzögerung erkannt wird. Im Rahmen dieses Projekts wurde bislang nur eine nachträgliche Bearbeitung von weiteren noch nicht benutzten Zeitreihen („Postprocessing“) durchgeführt. Die Ergebnisse des Modells „Leichtverkehr vs. Schwerverkehr“ weisen auch hier eine sehr gute Übereinstimmung (100 %) mit den visuellen Aufnahmen auf. Eine Erweiterung dieses Konzepts auf ein echtzeitfähiges Detektionssystem sowie eventuell die weitere Vertiefung der Klassifizierung (vgl. Abb. 4) sind als zukünftige Ausbaustufen des Projekts denkbar.

4 ERFASSUNG VON EINZELNEN FAHRZEUGACHSEN UND ACHSLASTEN

Obwohl die beschriebene Differenzierung zwischen Leicht- und Schwerverkehr mit einem CNN-Modell bereits jetzt sehr gute Aussichten auf Erfolg hat, ist eine Klassifizierung der zahlreichen Typen des Schwerverkehrs (vgl. /Wolf 2010/ bzw. /Uhlig 2019/) in den weiteren binären Schritten mit der sehr zeitintensiven Vorbereitung von Lernbeispielen je nach Art des Fahrzeugs (vgl. Abb. 6) verbunden und deswegen nach der Meinung der Autoren zurzeit wenig sinnvoll. Stattdessen ist es zielführend, im Laufe der weiteren Auswertung die einzelnen Achsen in den Intervallen mit einer detektierten Durchfahrt eines schweren Fahrzeugs (Modell 2) zu erkennen und dann die entsprechende Gesamtzahl von Achsen eines Fahrzeugs zu ermitteln (Abb. 8).

Diese Aufgabe stellt prinzipiell ebenfalls eine Mustererkennung dar, d.h. die Fähigkeit, in einer Menge von Daten bestimmte Regelmäßigkeiten oder Gesetzmäßigkeiten zu erkennen. Die Zielsetzung ist dabei, die gewonnenen Messwerte eines ausgewählten Zeitintervalls in die noch kleineren Intervalle zu teilen und dann einer Klasse „Achse“ bzw. „gedämpfter Impuls“ der gelernten Form mit bestimmten charakteristischen Merkmalen zuzuordnen. Die Vorgehensweise bei der Analyse von Deformationsmessungen mit typischen Ereignissen dieser Art sowie die KNN-Algorithmen für ihre Erkennung bzw. Trennung voneinander wurden im Beitrag /Resnik 2021/ ausführlich beschrieben. Genauso wie bei der bereits behandelten Fahrzeugklassifizierung können auch hier durch Verschieben eines entsprechenden Rechteckfensters die signifikanten Abweichungen vom „Normalverhalten“ (Muster „einfaches Rauschen“) aufgespürt werden, die dann ggf. in mehreren weiteren Stufen (Kaskaden) genauer untersucht werden können. Auch bei diesem Schritt der Datenauswertung sollte ein besonderes Augenmerk der optimalen

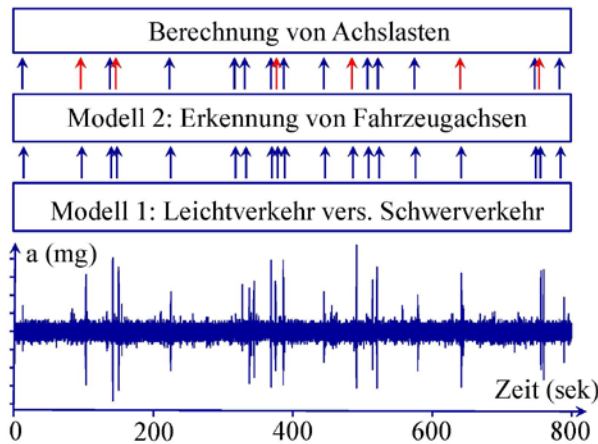


Abb. 8 | Mehrstufige Klassifizierung




Abb. 9 | Anwendung eines CNN-Modells (Fahrzeugachsen) für die Testdaten




Abb. 10 | Erfassung von Achslasten

Größe des Fensters gewidmet werden. Ein schmaleres Analysefenster hat eine bessere Zeitauflösung, aber wegen der kleinen Anzahl von Messungen ein schlechteres Signal-Rausch-Verhältnis. Ein breites Analysefenster erlaubt eine bessere Erfassung der vorhandenen Ereignisse nach der Durchfahrt eines Fahrzeugs, kann jedoch durch eine Überlappung von mehreren nahliegenden Achsen in einem Intervall zur Verfälschung von Ergebnissen führen. Im behandelten Beispiel wurde – ausgehend von der mittleren Fahrgeschwindigkeit – die Fenstergröße von 24 Messwerten gewählt, die bei der verwendeten Abtastrate jeweils einen etwa 0,16-Sekunden-Zeitreihenabschnitt repräsentiert.

Bei der Datenauswertung müssen im ersten Schritt die entsprechenden Zeitreihen analysiert werden, um typische Erscheinungsbilder für das gesuchte Muster „Achse“ zu generieren. Als ein Gegenstück beim Trainieren eines CNN-Netzes (Abb. 3) dienen die Abschnitte der vorliegenden Intervalle ohne schweren Verkehr. Wie bereits in Abschnitt 3 erläutert wurde, bedarf es dabei keiner mathematischen Beschreibung von gesuchten Erscheinungen, sondern der zahlreichen Lernbeispiele eines bestimmten Typs. Die Darstellungen von diesen gesuchten Mustern in den typischen Intervallen sind exemplarisch in Abb. 9 am Beispiel von Testdaten präsentiert (vgl. Abb. 6). Trotz einer relativ kleinen Anzahl der verwendeten Trainingsdatensätze und einem relativ großen Rauschen weisen die Ergebnisse für diese zusätzlichen Testdatensätze auch hier eine gute Übereinstimmung mit den Soll-Werten auf.

Die hier vorgeschlagene Methodik der Datenerfassung ermöglicht generell sowohl die Verkehr- als auch Achslasterfassung, die auf einen Vergleich von entstanden Schwingungen mit den Amplituden bei Durchfahrt eines Referenzfahrzeugs basiert. Es ist bekannt, dass

die maximale Auslenkung einer gedämpften Schwingung nach dem Anbringen eines einmaligen Impulses bei Durchfahrt eines Fahrzeugs (Abb. 10) von den Bauwerkeigenschaften (wie Masse, Steifigkeit, Dämpfung von einzelnen Konstruktionselementen) abhängig ist (vgl. /Petersen & Werkle 2018/). Das Verhältnis von entstandenen Beschleunigungsamplituden von tragenden Konstruktionen kann dagegen weitgehend als unabhängig von der physikalischen Beschaffung des Bauwerks angesehen werden, da die Messungen am gleichen Ort und ohne Änderung von den o.g. Parametern stattfinden. Außerdem kann dabei näherungsweise von der gleichen Geschwindigkeit von Fahrzeugen bei den gleichen Bedienungen und Begrenzungen ausgegangen werden.

Obwohl es sich dabei um eine erhebliche Vereinfachung von beschriebenen Zusammenhängen handelt, können die hier behandelten Zusammenhänge mithilfe eines einfachen Federschwingers (Abb. 10) veranschaulicht werden, der sich geradlinig längs einer Richtung bewegen kann. Zur Erzeugung einer harmonischen Schwingung muss das System aus der Gleichgewichtslage ausgelenkt werden, d.h. dem Schwinger muss einmalig Energie zugeführt werden. So kann dieses System z.B. durch einen kurzfristigen Stoß entlang seiner Achse (etwa Kugel mit der Masse m und Geschwindigkeit v) in Bewegung gebracht werden, wobei die angebrachte kinematische Energie ($0,5 \cdot m \cdot v^2$) der Kugel vereinfacht komplett in kinetische und potentielle Energie des Pendels umgewandelt wird. Während die maximale kinetische Energie der entstandenen Schwingung in der Null-Lage des Pendels erreicht wird, ergibt sich die maximale potentielle Energie bei der maximalen Auslenkung des Pendels S und kann vereinfacht nach der Formel ($0,5 \cdot D \cdot S^2$) berechnet werden, wobei es sich beim Parameter D um die materialabhängige mechanische Federkonstante handelt. Unter Berücksichtigung der Tatsache, dass die kinetische Energie der Schwinger dabei gleich 0 ist, entsteht Gl. (1):

$$0,5 \cdot m \cdot v^2 = 0,5 \cdot D \cdot S^2 \quad (1)$$

Bei den gleichen Geschwindigkeiten v von unterschiedlichen Kugeln und gleichen Federparametern D entspricht das Verhältnis von ermittelten Schwingungsamplituden der Wurzel aus den entsprechenden Massen m . Vorausgesetzt, dass die maximale Auslenkung S_R bei einer Referenzmasse m_R bekannt ist, können aus den weiteren maximalen Auslenkungen von gegebenen Versuchen S_i auch die entsprechenden Massen m_i geschätzt werden, Gl. (2):




Abb. 11 | Erfassung von Achslasten bei laufendem Betrieb

$$m_i = m_R \cdot \left(\frac{S_i}{S_R} \right)^2 \quad (2)$$

Die realen Geschwindigkeiten von Fahrzeugen können sich selbstverständlich etwas unterscheiden und somit die festgestellten Achslasten im Verhältnis zum Referenzfahrzeug erheblich verfälschen, da das Verhältnis von ermittelten Schwingungsamplituden auch dem Verhältnis von den Fahrzeuggeschwindigkeiten (v_i/v_R) proportional ist. Generell können diese realen Geschwindigkeiten z.B. aus den Klassifizierungen mit zwei Sensoren in einer bekannten Entfernung ziemlich genau ermittelt und dann nach Gl. (1) bei der Berechnung von Achslasten berücksichtigt werden. Diese Vorgehensweise wurde von den Autoren jedoch noch nicht getestet.

Die Anwendung dieser Vorgehensweise wird in diesem Beitrag anhand der bereits beschriebenen Messungen veranschaulicht. Als Referenzwerte wird eine dokumentierte Durchfahrt eines dreiachsigen Busses des Typs Citaro G festgelegt. Dabei basierten das berechnete Gesamtgewicht und die entsprechenden Achslasten (7,6 t, 5,6 t und 4,4 t) sowohl auf den Daten des Fahrzeugherstellers als auch auf der geschätzten Fahrzeugauslastung (im Beispiel von 10 %) gemäß der Auslastungsinformation der Berliner Verkehrsbetriebe (BVG). Bei der Berechnung der Achslasten von anderen detektierten Fahrzeugen nach der Anwendung der vorbereiteten KNN-Modelle 1 und 2 (Abb. 8) wurde das mittlere Verhältnis zu allen drei genannten Referenzwerten verwendet. Die in Abb. 11 präsentierten Ergebnisse für den früher behandelten Testabschnitt der Messungen (Abb. 7) weisen eine gute Übereinstimmung mit den Erfahrungswerten auf und sollten an dieser Stelle nur den Ablauf der Auswertung exemplarisch veranschaulichen. An dieser Stelle wird explizit darauf verwiesen, dass keine Justierung der Messungen/des Messsystems an tatsächlich bekannten Achslasten und Fahrzeuggeschwindigkeiten erfolgte.

FAZIT UND AUSBLICK

In der Forschung gibt es derzeit sehr umfangreiche Investitionen im Bereich der KI und folglich viele neue Ansätze und Lösungen, um diese Technologie konkurrenzfähiger zu machen. Obwohl es sich bei den besonders erfolgreichen KNN-Anwendungen um die Erkennung von Mustern bzw. Gesetzmäßigkeiten innerhalb der Daten handelt, können theoretisch alle Aufgaben der Datenanalyse in den Ingenieurwissenschaften von KNN übernommen werden, sofern sie auch mit einem gesunden Menschenverstand gelöst werden können. Allerdings sind solche Lösungen auch heute oftmals im Vergleich zu den klassischen Algorithmen, die eigentlich für die beliebigen Rechenaufgaben prädestiniert sind, nicht ausreichend effizient. Einem Menschen erscheint es nämlich viel schwerer, schnell große Summen zu bilden, doch ist hierzu auch kaum Intelligenz erforderlich. Eine menschliche Intelligenz kann dagegen ganz schnell die recht großen Informationsmengen der Bilder, Texte oder Sounds verarbeiten, um die Inhalte zu interpretieren. Gerade solche Aufgaben sind für einen Computer ohne KI jedoch schwer bzw. kaum lösbar. Deswegen werden sich auch in der Zukunft die beiden genannten Lösungen bei den vielfältigen Ingenieuraufgaben optimal ergänzen. Ein typisches Beispiel dieser Art stellt die hier präsentierte

Machbarkeitsstudie dar, bei der die Klassifizierung von Fahrzeugen mit den KNN und die folgende Berechnung der entsprechenden Achslasten mithilfe von üblichen Algorithmen durchgeführt wird.

Die hier vorgestellten Verfahren der Datenauswertung weisen sowohl in der Zuverlässigkeit als auch hinsichtlich der möglichen Automatisierbarkeit ohne Zweifel ein sehr großes Potenzial auf. Der größte Vorteil dieser Vorgehensweise besteht darin, dass die erfassten Informationen im Laufe mehrerer Jahre ohne große Investitionen systematisch erfasst und dann je nach Bedarf gemeinsam analysiert werden können. Die Entwicklung solcher Technologien erfordert daher eine weitere intensive interdisziplinäre Forschungsarbeit, wobei die Erfahrungen mit der Messtechnik und Zeitreihenanalyse mit dem Expertenwissen im Bereich des Bauwesens und der Verkehrsplanung verknüpft werden müssen.

LITERATUR

- AP EDS-1 (2022): Arbeitspapier „Eingangsgrößen für die Dimensionierung und Bewertung der strukturellen Substanz“ Teil 1 – Verkehrsbelastung. FGSV, Köln.
- BAST (2022): Automatische Dauerzählstellen auf Autobahnen und Bundesstraßen. https://www.bast.de/DE/Verkehrstechnik/Fachthemen/v2-verkehrszaehlung/zaehl_node.html (26.05.2023).
- Heunecke, O.; Kuhlmann, H.; Welsch, W., Eichhorn, A., Neuner, H. (2013): Handbuch Ingenieurgeodäsie – Auswertung geodätischer Überwachungsmessungen. Wichmann, Berlin/Offenbach.
- Höfler, F. (2006): Verkehrswesen-Praxis: Band II: Verkehrstechnik. Bauwerk, Berlin.
- Petersen, C.; Werkle, H. (2018): Dynamik der Baukonstruktionen. Vieweg, Braunschweig.
- RDO Asphalt 09 (2009): Richtlinien für die Dimensionierung des Oberbaus von Verkehrsflächen mit Asphaltdeckschicht (RDO Asphalt). FGSV, Köln.
- RDO Beton 09 (2009): Richtlinien für die rechnerische Dimensionierung von Betondecken im Oberbau von Verkehrsflächen (RDO Beton). FGSV, Köln.
- Resnik, B. (2021): Anwendung von künstlichen neuronalen Netzen bei der Auswertung von Deformationsmessungen. In: allgemeine vermessungsnachrichten 128(2021)2, 94–103.
- Resnik, B.; Neupert, F.; Schiefelbein, N.; Widczisk, J. (2023): Anwendung von künstlichen neuronalen Netzen (KNN) zur Fahrzeugklassifizierung im Rahmen der geodätischen Bauwerksüberwachung. In: Weinold, T. (Hrsg.): 22. Internationale Geodätische Woche Obergurgl 2023. Wichmann, Berlin/Offenbach, 150–162.
- Resnik, B.; Sargsyan, A. (2019): Anwendung von MEMS-Beschleunigungssensoren im Rahmen von Bauwerksüberwachungen anhand eines typischen Beispiels. In: allgemeine vermessungsnachrichten (avn) 126(2019)6-7, 163–172.
- Uhlig, W. (2019): Grundlagen für Lastannahmen zur Dimensionierung von Straßenbefestigungen. Dissertation, Technische Universität Dresden.
- Wolf, A. (2010): Modell zur straßenbautechnischen Analyse der durch den Schwerverkehr induzierten Beanspruchung des BAB-Netzes. Berichte der Bundesanstalt für Straßenwesen. Straßenbau, 61. Wirtschaftsverlag NW, Bremen.

AUTOREN



Prof. Dr.-Ing. Boris Resnik

BERLINER HOCHSCHULE FÜR TECHNIK
FACHBEREICH BAUINGENIEUR- UND
GEOINFORMATIONSWESEN

Luxemburger Straße 10 | 13353 Berlin | Deutschland
resnik@bht-berlin.de | OCID: 0009-0005-1171-4855



Prof. Dr.-Ing. Jörg Patzak

BERLINER HOCHSCHULE FÜR TECHNIK
FACHBEREICH BAUINGENIEUR- UND
GEOINFORMATIONSWESEN

Luxemburger Str. 10 | 13353 Berlin | Deutschland
joerg.patzak@bht-berlin.de



Dr.-Ing. Wolf Uhlig

UHLIG & WEHLING GMBH
INGENIEURGESELLSCHAFT

Leipziger Straße 27 | 09648 Mittweida | Deutschland
W.Uhlig@uhlig-wehling.de