

DER NAHVERKEHR

Öffentlicher Personenverkehr in Stadt und Region



Betrieb & Infrastruktur

Ja, nein, vielleicht? – Wie verlässlich ist die Fahrgastinfo in Frankfurt a. M.?

Verkehrsplanung & Organisation

Transit-Oriented Development:
Bestandsorientierte Perspektiven

Technik & Umwelt

KI: Automatisierte Empfehlung
für die Instandsetzung von Radsätzen

Finanzen & Recht

ÖPNV-Direktvergaben in Form von
Inhouse-Vergaben (EuGH-Entscheidung)

Kunden & Marketing

Digitale Alleskönner-App: Wie „moin
mobil“ den ländlichen Raum anbindet

Fahrweg

Optimierte Isolierstoßsysteme

Fahrgastinformation – ein Schlüssel zu umweltsensitiver Mobilität mit AIAMO

Dr. rer. nat. Christine Langhanns, Dr. rer. nat. Kolja Thormann

Wie können Städte und Regionen Mobilität effizient organisieren, Umweltbelastungen reduzieren und gleichzeitig die Attraktivität des öffentlichen Verkehrs stärken? Mit diesen Fragestellungen beschäftigt sich das Forschungsprojekt AIAMO – Artificial Intelligence And MObility. Ziel ist es, Mobilitäts-, Umwelt- und Infrastrukturdaten intelligent zu verknüpfen, um fundiertere Entscheidungen in einem datenbasierten und KI-gestützten Mobilitätsmanagement zu ermöglichen. Eine zentrale Rolle spielt dabei die Qualität des öffentlichen Verkehrs. Echtzeit-Prognosen für verlässliche Fahrgastinformationen können wesentlich dazu beitragen, Bus und Bahn attraktiver zu machen und die Nutzung nachhaltiger Mobilitätsangebote zu stärken.

Angebote des öffentlichen Personennahverkehrs (ÖV) ermöglichen nicht nur die Verknüpfung verfügbarer Mobilitätsformen wie Gehen, Radfahren, E-Scooter-Nutzung und motorisierter Individualverkehr, sondern leisten einen wichtigen Beitrag zur Verbesserung der Kohlendioxidbilanz, insbesondere bei ausreichender Auslastung der Fahrzeuge. Das entscheidende Potenzial dieses Personenverkehrs liegt dabei in der hohen Transportkapazität, die eine bessere Emissionsbilanz je Fahrgast erzielen kann. Damit wird der ÖV zu einem wesentlichen Akteur im umweltsensitiven Mobilitätsmanagement, das unter anderem die Einhaltung der neuen Luftqualitätsgrenzwerte ab 2030 unterstützen soll.

Vor allem im städtischen Raum werden Busse und Bahnen bereits intensiv genutzt. Hier empfiehlt sich im Regelbetrieb der Einsatz von Fahrzeugen mit geringem CO₂-Ausstoß, um lokale Emissionen möglichst niedrig zu halten. Die Neuanschaffung von Elektrobussen in einem mit Lastsäulen ausgestatteten Umfeld kann die ÖV-Attraktivität erhöhen.

Außerstädtisch ist die Auslastung der Busse geringer bis hin zu Leerfahrten. Hauptgründe für die Nichtnutzung des ÖV-Angebots

sind meist eine geringe Versorgungsqualität durch schwer erreichbare Haltestellen und zu seltene Abfahrtszeiten sowie eine mangelnde Verlässlichkeit durch Fahrtausfälle und Verspätungen.

Das Verkehrsnetz ist permanenten Veränderungen unterworfen, die in Wechselwirkung alle Akteure betreffen und herausfordern. Ist eine Strecke wegen Straßen- oder Gleisbatterneuerung gesperrt, hat das Auswirkungen auf den Betrieb von Bus und Bahn sowie auf die Bereitschaft der Menschen, diese weiterhin zu nutzen oder auf sie umzusteigen. Die zentrale Forderung der Verkehrsunternehmen lautet daher, dass Maßnahmen der Verkehrslenkung nicht zu Lasten der Betreiber und letztlich auch der Nutzenden gehen dürfen. Beeinträchtigungen wie verlängerte Reisezeiten werden von Fahrgästen schlecht toleriert – es droht der Umstieg in den motorisierten Individualverkehr und damit eine weitere Verschlechterung des Verkehrsflusses sowie der Luftqualität in den betroffenen Gebieten.

Eine Maßnahme kann eine gezielte Bevorzugung der ÖV-Verkehrsmittel sein, um wirksam die Attraktivität dieses gemeinschaftlichen Verkehrssystems zu erhöhen. Spezifische Anreizsysteme können zur Nutzung umweltfreundlicher Mobilitätsmodelle motivieren. Schließlich kann auch der ÖV selbst einen Beitrag zur Akzeptanz und regelmäßigen Inanspruchnahme leisten, die in hohem Maße von der wahrgenommenen Qualität des Angebots abhängen. Diese Qualität wird aus Nutzersicht maßgeblich durch verlässliche, verständliche und zeitnahe Fahrgastinformation bestimmt.

Für die Einbindung des ÖV in die Maßnahmenplanung, in die umweltsensitive Verkehrslenkung und für die Fahrgastinformation sind hochwertige, valide Daten nötig. Die Bereitstellung dieser Daten befindet sich nach § 3a Bereitstellung von Mobilitätsdaten im Personenbeförderungsgesetz (PBefG) bereits seit Juli 2022 in Umsetzung.

Mobilitätsplanung mit ÖV-Daten

Die Fahrgastinformation im ÖV ist heute nahezu vollständig digitalisiert. Informationen zu Fahrten und Verbindungsmöglichkeiten stehen über Apps sowie browserbasierte Auskunftssysteme zur Verfügung – unabhängig davon, ob diese von Verkehrsverbünden, Aufgabenträgern oder einzelnen Verkehrsunternehmen betrieben werden.

Die große Anzahl unterschiedlicher Akteure erfordert eine strukturelle Vereinheitlichung der zugrunde liegenden Daten, um sie über kommunale und Landesgrenzen hinweg für die Reiseplanung zu nutzen und eine durchgängige Mobilität mit öffentlichen Verkehrsmitteln zu gewährleisten. Unter dem Dach der Organisation DELFI (Durchgängige Elektronische Fahrgastinformation e.V.) engagieren sich Fachleute der Bundesländer für die Entwicklung, Umsetzung und Einhaltung entsprechender Konventionen in der Fahrplanung und der Echtzeitinformation.

Eine dieser Konventionen in der Fahrplanung ist die eindeutige Verknüpfung einer Haltestellennummer mit einer klar definierten geografischen Referenz. Dadurch können Fahrten und Haltepunkte räumlich korrekt abgebildet werden. Diese Informationen ermöglichen eine automatisierte Routenberechnung mit effizienter Wegeführung und sinnvoll ausgewiesenen Umsteigevorgängen.


Ein weiterer Auskunftsstandard ist die Darstellung der aktuellen Verkehrslage mittels Echtzeit-Prognosemeldungen, die bundesweit ebenfalls von DELFI über die sogenannten RegioCluster bereitgestellt werden. Sobald eine Fahrt vom Betriebspersonal gemeldet wird, wird die entsprechende Abfahrts- beziehungsweise Pünktlichkeitsprognose in den Auskunftssystemen angezeigt und dient damit der Fahrgastinformation.

Für die individuelle Routenplanung ist es essenziell, möglichst frühzeitig verlässli-

che Informationen zu einer Fahrt zu erhalten. Die Informationskette reicht von der Bestätigung des Stattfindens einer Fahrt mindestens zwei Stunden vor der planmäßigen Abfahrt in Form einer Prognose bis zur frühzeitigen Kommunikation von Verspätungen, Fahrt- und Haltausfällen, um rechtzeitig alternative Reisemöglichkeiten planen zu können.


Divergenz von Abfahrtsprognose und Realzeit

Während der Fahrt werden die Prognosen kontinuierlich durch die Bordrechner in Bussen und Bahnen aktualisiert. Diese erfassen die aktuelle Uhrzeit und Position des Fahrzeugs und gleichen sie mit dem hinterlegten Fahrplan ab. Abweichungen von mehr als einer Minute gegenüber dem Fahrplansoll sind in den Auskunftssystemen als Verspätungen auszuweisen.



Zur Autorin

Dr. rer. nat. Christine Langhanns ist promovierte Bewegungswissenschaftlerin und seit 2023 bei der rms GmbH. Zunächst als Data Scientist tätig, leitet sie seit 2024 das Team Data Analytics. Sie begleitet das Forschungsprojekt AIAMO ÖV-seitig und koordiniert die heterogenen Anforderungen an das Data Analytics Team.



Zum Autor

Dr. rer. nat. Kolja Thormann ist Informatiker und wechselte nach seiner Promotion im Bereich Datenfusion und stochastische Zustandsschätzung als Specialist Data Analyst zur rms GmbH. Er analysiert Daten aus dem öffentlichen Personenverkehr (zum Beispiel Fahrplan-, Echtzeit-Prognose- und Realdaten) und entwickelt KI-basierte Analyseverfahren.




Abb. 1: Analyse der Fahrplanabweichungen und Prognosefehler der Haltestellen. Je Haltestelle wurde der Median der Fahrplanabweichung und der Prognosefehler bestimmt. Liegt der Median der Fahrplanabweichung und des Prognosefehlers im Bereich einer Minute, ist die Haltestelle als kleiner weißer Kreis mit schmalen schwarzem Rand dargestellt. Mit größerem Radius dargestellt sind Haltestellen mit einer Fahrplanabweichung >1 Minute: Je dunkler die Füllung des Kreises, desto höher die typische Abweichung an diesem Halt. Der Rand des Kreises gibt Auskunft über die Genauigkeit der Prognosemeldung im Vergleich zur Realität: Die Stärke der Lilafärbung indiziert den typischen Prognosefehler an diesem Haltepunkt. Ein positiver Wert bedeutet, dass die Abfahrt in der kommunizierten Abfahrtsprognose stattfand.

Grafiken: rms GmbH, Kartendaten © OpenStreetMap – Community (ODbL), <https://openstreetmap.de/nutzen/namensnennung>

Zur Bewertung der Genauigkeit der Echtzeit-Prognosen werden systeminterne Realdaten derselben Bordrechner verwendet. Im Rahmen des Forschungsprojekts AIAMO stellen die Leipziger Verkehrsbetriebe (LVB) ihre Daten der AIAMO Pilotregion Leipzig zur Verfügung.

Die Genauigkeit der Prognosen, die anhand der Realdaten der LVB im Nachgang bestimmt wurde, lag meist bei ± 1 Minute. Meldungen mit dieser Genauigkeit können als korrekte, das heißt als plausible, Information interpretiert werden. Die verbleibenden circa 36 Prozent der Meldungen wiesen deutlich größere Abweichungen (bis zu 169 Minuten) von den Realdaten auf und wurden als unplausibel interpretiert. In Abbildung 1 lässt sich die Heterogenität der Pünktlichkeit und der Auskunftsgenauigkeit erkennen. Die Grafik verdeutlicht, dass eine typische Fahrplanabweichung nicht zwangsläufig in einer ungenauen Prognosemeldung mündet und umgekehrt. Obwohl der Median eine gute Einschätzung der haltebezogenen Prognosedaten gibt und robust gegen statistische Ausreißer ist, können auch an als unauffällig deklarierten Halten stärkere Abweichungen enthalten sein.

Die Menge an Echtzeit-Prognosemeldungen, die von den Fahrzeugen der LVB täglich bereitgestellt wird, beträgt etwa eine Million an Wochenenden und 1,8 Millionen an Werktagen. Diese Informationsmenge übersteigt die Kapazitäten eines Menschen zur Kontrolle der angepassten Pünktlichkeiten der Fahrten und deren Kommunikation. Entsprechend soll im Forschungsprojekt geprüft werden, inwieweit KI-basierte Klassifikationsmodelle aus dem Bereich des Maschinellen Lernens (ML) dabei helfen können, die Plausibilität der Echtzeit-Prognose automatisiert einzuschätzen.

KI-basierte Bewertung der Echtzeit-Prognosen in AIAMO

Ein Lösungsansatz war die KI-basierte Klassifikation der gesamten LVB-Prognosemeldungen in „plausible“ und „unplausible“ Meldungen, die dazu beitragen soll, den Datensatz je nach Anwendungsfall auf relevante Meldungen reduzieren zu können. Die Betrachtung des LVB-Netzes stellte folgende Anforderungen an den ML-Algorithmus:

- Der Algorithmus muss in der Lage sein, binäre Klassifikation zu lösen.
- Die Verwendung strukturierter, das heißt tabellarischer Daten, muss möglich sein.
- Eine Funktionalität muss existieren, die Nachvollziehbarkeit des Modells darzustellen und die Wirksamkeit der Faktoren zu visualisieren.
- Die Prognosemodellierung erfordert einen leistungsstarken Algorithmus und robuste Modellierungseigenschaften.

Schließlich wurde der XGBoost-Classifizierer als geeignet bewertet. Im Minutentakt werden die zu dem Zeitpunkt verfügbaren Meldungen gelistet und ab zehn Minuten vor dem geplanten Halt einer Fahrt systematisch betrachtet. Der Schwellenwert von zehn Minuten wurde vorab bereits als für den Fahrgast relevanter Informationszeitraum angenommen. In die KI-Modellierung gehen unter anderem folgende Informationen ein:

- Daten aus der aktuellen Meldung des Halts (zum Beispiel Soll-Abfahrtszeit, prognostizierte Abfahrtszeit, erwartete Fahrzeit vom letzten Halt, Haltestellenkoordinaten),
- Daten aus vergangenen Meldungen der Fahrten (beispielsweise Mittelwert und

- Varianz der Prognosen der Fahrt beziehungsweise des Haltepunkts),
- ergänzende Zeitinformationen (Wochentag, Tageszeit),
 - mittlerer Prognosefehler einer Linie beziehungsweise Haltestelle sowie
 - Anzahl der Meldungen.

Die Datensätze aus dem Zeitraum Oktober 2025 (Abb. 2) wurden im Verhältnis 80 Prozent Trainingsdaten und 20 Prozent Testdaten gesplittet. Da KI-Algorithmen dazu neigen, sich zu stark an die Trainingsdaten anzupassen (Overfitting), wird ein Teil der Trainingsdaten als separater Validierungsdatsatz abgetrennt. Der Algorithmus trainiert nun auf den Trainingsdaten iterativ neue Klassifikationsmodelle, sogenannte „Entscheidungsbäume“. Schrittweise wird das Modell auf den Validierungsdatsatz angewandt. Tritt keine Verbesserung mehr für die Validierungsdaten auf, wird der Trainingsprozess gestoppt. Dadurch soll das Modell verallgemeinerbar bleiben.

Im Ergebnis zeigt sich, dass das Modell eine mittlere Genauigkeit von 71 Prozent der korrekten Zuordnung von „plausiblen“ und „unplausiblen“ Meldungen erreicht. Die restlichen Meldungen wurden fälschlicherweise der jeweils anderen Klasse zugeordnet. Insgesamt ist das KI-Modell bereits in der Lage, Prognosen zuverlässiger einzuschätzen als auf Basis einer Zufallswahrscheinlichkeit von 50 Prozent. Zur Überprüfung der Robustheit des Modells wurden mehrere weitere Zeiträume des Jahres 2026 getestet, wobei wiederholt eine Genauigkeit von 69 Prozent erzielt wurde und somit Ergebnisse nahe am ursprünglichen Modell erreicht wurden. Der Testdatensatz mit der geringsten Genauigkeit von 67 Prozent und geringerem Erfolg in der Klassifikation „unplausibler“ Meldungen enthält drei

Zeitraum	Kategorie	Genauigkeit	„plausibel“		„unplausibel“	
			korrekt klassifiziert	falsch klassifiziert	korrekt klassifiziert	falsch klassifiziert
03.10.-24.10.2025	Modellierung	71 %	41,8 %	15,8 %	29,6 %	12,8 %
05.01.-25.01.2026	Testung	69 %	35,3 %	16,4 %	33,9 %	14,4 %
09.02.-01.03.2026	Testung	67 %	38,5 %	16,2 %	29,2 %	16,1 %
18.03.-30.03.2026	Testung	69 %	38,0 %	17,2 %	30,8 %	14,0 %

Abb. 2: Ergebnisse der Modellierung und Re-Testungen des Modells für verschiedene Testzeiträume von Daten der LVB. Als Kennwerte sind die Genauigkeit (Accuracy) und die Fehlermatrix (Confusion Matrix) präsentiert, die neben den korrekten Klassifikationen auch den Anteil der falsch klassifizierten Meldungen aufzeigt.

Grafik: rms GmbH

ÖPNV-Streiktag, die die Klassifikation der Prognosen typischer Verkehrstage erschwerten.

Fazit

Die aktuelle Prognosequalität in der Fahrgastinformation des öffentlichen Personennahverkehrs muss substanziell besser werden, um Fahrgäste gut informiert zu transportieren und Reise- sowie Anschlussplanung zu ermöglichen. Die automatisiert erstellten Abfahrtsprognosen der Bordrechner weisen dafür eine nur teilweise geeignete Genauigkeit auf. Unsystematisch erscheinende Eigenschaften dieser Echtzeit-Prognosedaten sollen durch KI-Methoden auf mögliche Zusammenhänge und damit auf Klassifizierbarkeit geprüft werden. Die Ergebnisse des skizzierten KI-Ansatzes zeigen, dass die Prognosedaten Informationen zur korrekten Klassifikation von „plausiblen“ und „unplausiblen“ Meldungen beinhalten. Das trainierte Modell kann damit beispielsweise zum Filtern unplausibler Meldungen beitragen, um diese entweder zu entfernen, den Leitstellen zu melden oder in einem nächsten Schritt die Abfahrtszeiten KI-basiert bestimmen zu können.

Trotz des stabilen Klassifikationsergebnisses ist die Genauigkeit mit circa 70 Prozent möglicherweise noch nicht ausreichend. In der Integrationszone des AIAMOnexus sind ergänzende Datenquellen verfügbar (zum Beispiel Informationen zur Straßenverkehrslage), um das Modell und damit die Fahrgastinformation kontinuierlich und datenbasiert weiter zu verbessern. Damit stellt AIAMO eine wichtige Basis zur Verbesserung von Prognosequalität, Fahrgastinformation und wirksamer Intermodalität dar. Das erhöht nicht nur die Attraktivität des ÖV insgesamt, sondern bindet ihn als wichtigen Akteur auch wirksam in ein ganzheitliches, umweltsensitives Mobilitätsmanagement mit ein.

Zusammenfassung/Summary

Fahrgastinformation – ein Schlüssel zu umweltsensitiver Mobilität mit AIAMO

Der öffentliche Personennahverkehr steht vor der Herausforderung, seine Attraktivität im Sinne eines umweltsensitiven Mobilitätsmanagements zu steigern und Fahrgastabwanderung zu vermeiden. Entscheidend ist dabei die Qualität der Fahrgastinformation, die unter ungenauen Echtzeit-Prognosen leidet. KI-basierte Verfahren ermöglichen die automatisierte Analyse großer Datenmengen und die systematische Bewertung der Prognoseplausibilität. Durch die Identifikation fehlerhafter Meldungen und nachgelagerte Korrektur verbessern sie die Datenqualität und stärken das Vertrauen der Fahrgäste.

Passenger Information – a Key to Eco-friendly Mobility with AIAMO

Public transport faces the challenge of increasing its attractiveness in the context of environmentally sensitive mobility management while preventing passenger loss. A key factor is the quality of passenger information, which is impaired by inaccurate real-time predictions. AI-based methods enable the automated analysis of large datasets and the systematic evaluation of forecast plausibility. By identifying inaccurate data and correcting them in downstream processing steps, they can improve data quality and strengthen passenger trust.

ANZEIGE

Der neue Standard

903 Duisburg Hbf.
über Hamborn + Dulsborn

901 Zoo/Uni 4 min
903 Meiderich Bf. 13:27

903 25'

Linie	Nach	Abfahrtszeit	Ankunftszeit
6N	nach Berlin	10 min	10:10
72	nach München	16 min	10:16
310	nach Hamburg	25 min	10:25
240	nach Stuttgart	42 min	10:42
6N	nach Berlin	1,3 min	10:13
72	nach München	1,10 min	10:11
310	nach Hamburg	1,16 min	10:16

Fahrgastinformation für alle Ansprüche

lumino®
Dynamische Fahrgastinformation
www.lumino.de

Individuelle Sonderdrucke

Schaffen Sie Aufmerksamkeit!

Für mehr Informationen besuchen Sie
www.nana-online.de/sonderdrucke-dnv



Wir finden mit Ihnen die beste Ergänzung zu Ihrem Marketingmix, sodass Sie Ihre Reichweite optimal ausnutzen können.

- ▀ Sowohl als Print-Sonderdrucke als auch in digitaler Form
- ▀ Individuelle Erweiterung durch zusätzliche Inhalte
- ▀ Profitieren Sie von der hohen Markenpräsenz von DER NAHVERKEHR
- ▀ Zielgruppenspezifisches Werben durch einen nachhaltigen Kommunikationsverstärker
- ▀ Unterstützung Ihrer Kanäle durch hochwertige Fachbeiträge
- ▀ Für Online-Kongresse, Messen oder Symposien
- ▀ Kostengünstige und individuelle Content Marketing Inhalte

Ihre Vorteile:



Interesse? Ihre Ansprechpartnerin: Martina Seemann
lizenzen@dvvmedia.com | 040 237 14 139

DVV Media Group GmbH, Heidenkampsweg 73-79, 20097 Hamburg