

Integriertes Verkehrs- und Mobilitätsmanagement mit AIAMO

Im Forschungsprojekt AIAMO werden modulare Systeme für ein KI-gestütztes, integriertes Verkehrs- und Mobilitätsmanagement entwickelt. Kern ist der AIAMOnexus, der heterogene Datenquellen – z. B. aus den Digitalen Zwillingen Verkehr, Umwelt und Infrastruktur – zusammenführt und aufbereitet. Auf dieser Basis werden adaptive Steuerungsverfahren, etwa für Lichtsignalanlagen, strategisches Baustellenmanagement und umweltsensitive Maßnahmen umgesetzt. Das Strategiemangement basiert auf u. a. auf Reinforcement Learning und nutzt einen Digitalen Zwilling zur simulationsgestützten Entscheidungsunterstützung. Eine datenschutzkonforme Mobilitätsverhaltenserkennung sowie KI-gestützte Routing- und Anreizsysteme ermöglichen eine Integration nutzerseitiger Aspekte. Der Ansatz kombiniert klassische Verfahren mit neuronalen Netzen, Graphenmodellen und Simulationen, um komplexe, intermodale und umweltorientierte Mobilitätsstrategien dynamisch zu steuern.

In the AIAMO research project, modular systems are being developed for AI-supported, integrated traffic and mobility management. The core is the AIAMOnexus, which combines and processes heterogeneous data sources – e. g. from the digital twins traffic, environment and infrastructure. On this basis, adaptive control procedures are implemented, for example for traffic lights, strategic roadworks management and environmentally sensitive measures. Strategy management is based on reinforcement learning, among other things, and uses a digital twin for simulation-based decision support. Data protection-compliant mobility behaviour recognition as well as AI-supported routing and incentive systems enable the integration of user-side aspects. The approach combines classic methods with neural networks, graph models and simulations to dynamically control complex, intermodal and environmentally-oriented mobility strategies.

doi.org/10.53184/SVT11-2025-2

1 Motivation

Laut Umweltbundesamt reichen die bisherigen Klimaschutzmaßnahmen im Verkehrssektor nicht aus, um die Emissionsziele zu erreichen. Eine schnellere Reduktion ist notwendig, unterstützt durch zusätzliche Instrumente [1]. Trotz differenzierter Verkehrsmittelwahl steigt die Pkw-Verfügbarkeit bei gleichzeitig sinkender Kilometerleistung, während neue Mobilitätsangebote wie Sharing kaum verbreitet sind [10]. Zugleich führen Sanierungsbedarf, wachsende Komplexität und Zielkonflikte – etwa zwischen Umweltauflagen und Erreichbarkeit – zu neuen Herausforderungen. Stadt und Umland weisen dabei zunehmend unterschiedliche Mobilitätsbedarfe auf. Der Ausbau von ÖPNV, Sharing-Angeboten und digitalen Anwendungen eröffnet neue Handlungsspielräume. Die EU-TEN-T-Verordnung [21] und die Sustainable Urban Mobility Plans (SUMP) [20] fordern integrierten Stadt-, Netz- und Ortsbezug mit regionalen Strategien zur Sicherung der Erreichbarkeit urbaner Knotenpunkte. Diese müssen zunehmend sektorübergreifend agieren und etwa auch Energiesysteme einbeziehen.

Neue Instrumente spielen in diesem Kontext eine entscheidende Rolle. Incentivierung – also gezielte Anreize für gewünschtes Mo-

bilitätsverhalten – und Gamification können als wichtige Vorstufe für eine stärkere Nutzung alternativer Infrastrukturen und Mobilitätsdienste dienen. Dabei ist es entscheidend, dass diese Instrumente den zuvor beschriebenen räumlichen und sektoralen Rahmen berücksichtigen. Nur so lassen sich innovative Mobilitätslösungen entwickeln und erproben – beispielsweise durch die Kombination von bidirektionalem Laden, intelligentem Parkraummanagement und öffentlichem Nahverkehr.

Die Entwicklung von Strategien des Verkehrs- und Mobilitätsmanagements, die unterschiedliche Situationen mit Maßnahmen bzw. Maßnahmenbündeln verbinden, wird somit deutlich komplexer. Gleiches gilt für den Betrieb eines solchen integrierten Systems [14]. In dem System stehen jedoch auch zunehmend Daten zur Verfügung, die Umwelt- und Verkehrssituationen zu erkennen helfen und Aufschluss über die aktuellen Mobilitätsanforderungen der Bevölkerung geben. Verfahren der künstlichen Intelligenz ermöglichen es, diese Daten umfassend auszuwerten und sie in neuen, ebenfalls KI-basierten Ansätzen des Strategiemagements zu nutzen. Im Projekt AIAMO werden hierzu geeignete Systemarchitekturen und auf die Anforderungen des Verkehrs- und Mobilitätsmanagements abgestimmte Verfahren der künstlichen Inte-

lligenz entwickelt, die zukünftig einen Beitrag zur Optimierung des gesamten Systems leisten können.

2 Voraussetzungen für den erfolgreichen Einsatz von KI

Digitale Lösungen sind seit Langem Teil moderner Verkehrskonzepte – mit teils gemischtem Erfolg. Ihr Nutzen entfaltet sich vor allem dann, wenn sie nicht isoliert, sondern strategisch eingebettet in ein Gesamtsystem umgesetzt werden [11]. Dies gilt

■ Verfasser

Alexander Sohr
alexander.sohr@dlr.de

Michael Ortgiese
michael.ortgiese@dlr.de

Deutsches Zentrum für Luft- und Raumfahrt e. V. (DLR)
Institut für Verkehrssystemtechnik
Rutherfordstraße 2
D-12489 Berlin

Dr. Katharina Peine
k.peine@highq.de

Thomas Hornig
t.hornig@highq.de

highQ Computerlösungen GmbH
Schwimmbadstraße 26
D-79100 Freiburg

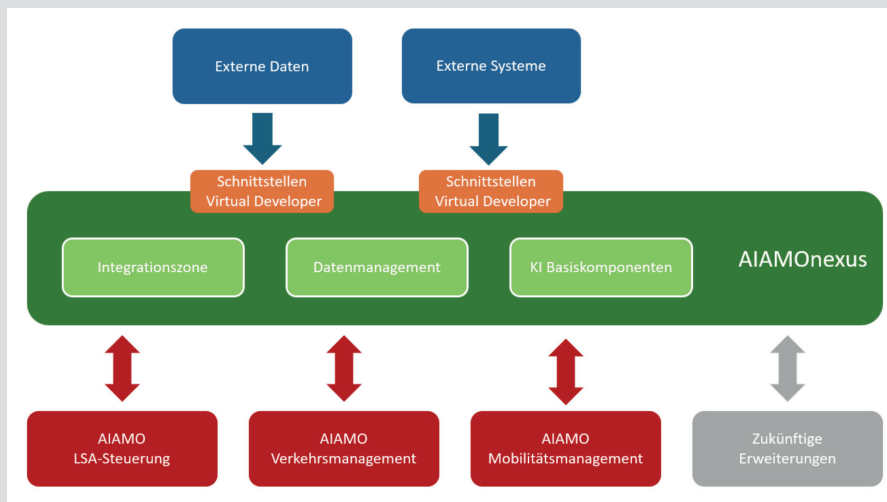


Bild 1: AIAMO Systemkomponenten – Quelle: Deutsches Zentrum für Luft- und Raumfahrt (DLR)

umso mehr bei der Integration von künstlicher Intelligenz (KI), die erhebliche Potenziale bietet, aber eine gezielte, strategische Planung und Einbettung in bestehende Mobilitätsstrukturen erfordert.

Ein KI-System umfasst nicht nur Technik, sondern auch organisatorische und strategische Elemente. Es muss Teil der übergeordneten Verkehrsplanung sein und auf klar definierte Ziele und Einsatzszenarien abgestimmt werden. KI sollte als Steuerungsinstrument verstanden und eng mit der langfristigen Mobilitätsstrategie verknüpft sein. Der Betrieb verteilter KI-Systeme verlangt klare Zuständigkeiten, Transparenz, menschliche Aufsicht und ethische Standards. Regionale Kompetenzzentren sollten den lokalen Betrieb übernehmen und als Schnittstelle zur Verwaltung, Politik und Öffentlichkeit fungieren.

Während die technische Infrastruktur oft nur begrenzt anpassbar ist, können Steuerungsstrategien flexibel weiterentwickelt werden. Ein kontinuierliches Monitoring – wie in den SUMP-Leitlinien gefordert – ist essenziell, um Wirksamkeit und Auswirkungen von KI-Maßnahmen auf Verkehr, Umwelt und Gesellschaft zu bewerten und laufend zu optimieren.

3 AIAMO Systemübersicht

Die im Forschungsprojekt AIAMO entwickelte Gesamtarchitektur zur Implementierung innovativer KI-gestützter Verfahren im Verkehrs- und Mobilitätsmanagement basiert auf einem modularen Systemdesign, das ein zentrales Datenmanagement mit applikationsspezifischen Komponenten verbindet.

Im Zentrum der Infrastruktur steht der AIAMOnexus [19] (Bild 1). Er übernimmt die im Verkehrsmanagement übliche Zusammenführung, Aufbereitung und Qualitätssicherung heterogener Datenquellen – darunter Verkehrsdaten, Umweltdaten, Infrastrukturdaten und Nutzerinformationen [12]. Für diese Prozesse kommen in AIAMO intelligente Verfahren der künstlichen Intelligenz zum Einsatz, etwa zur Datenbereinigung, Merkmalsextraktion und Fusionierung verteilter Informationsquellen.

Darüber hinaus stellt der AIAMOnexus perspektivisch eine Bibliothek von KI-Bausteinen bereit, die flexibel in verschiedenen Anwendungsbereichen genutzt werden können. Diese wiederverwendbaren Komponenten ermöglichen es, KI-Funktionalitäten effizient in unterschiedliche domänenspezifische Applikationen zu integrieren – etwa für die Verkehrssteuerung, Umweltüberwachung oder das Baustellenmanagement.

Aktuell werden im Rahmen von AIAMO auf der Applikationsebene drei KI-basierte Schwerpunkte entwickelt:

1. Adaptive Lichtsignalsteuerung, bei der auf Basis von Verkehrsdaten intelligente Regelalgorithmen für Ampelanlagen generiert werden, um Stau zu reduzieren und Emissionen zu senken [15].
2. Datengetriebenes Mobilitätsmanagement, das Nutzerverhalten und Echtzeitbedingungen berücksichtigt, um flexible, effiziente Mobilitätsangebote zu gestalten [6].
3. Die Koordination und übergreifende Steuerung der Maßnahmen erfolgt durch ein zentrales Strategiemangement, das derzeit insbesondere auf die Verbesserung der urbanen Umweltsituation und die intelli-

gente Steuerung von Baustellen fokussiert ist. Ziel ist eine dynamische, datenbasierte Entscheidungsunterstützung, die sich flexibel an sich ändernde Rahmenbedingungen anpassen kann [17].

Über den AIAMOnexus können sowohl externe Datenquellen (z. B. Wetterdienste, ÖPNV-Systeme, Crowd-Daten, Digitale Zwillinge) als auch externe IT-Systeme an die AIAMO Umgebung angebunden werden. Damit wird eine interoperable, erweiterbare Infrastruktur geschaffen, die zukünftige Anforderungen und neue Anwendungsszenarien integrieren kann.

In kommenden Ausbaustufen wird die Architektur durch weitere Systemkomponenten ergänzt, die – wie bereits in der Zielvision des Projekts vorgesehen – auch eine strategisch optimierte Planung des gesamten Mobilitätsangebots auf Stadt- und Regionalebene ermöglichen. Dazu gehören u. a. Komponenten für langfristige Verkehrsprognosen, kapazitive Angebotsplanung oder dynamische Anreizsysteme für nachhaltiges Mobilitätsverhalten.

4 Datenbereitstellung und Management

Effektive und leistungsfähige KI-Anwendungen leben von hochwertigen, aktuellen und gut strukturierten Daten. Diese Daten müssen auf die Zielsetzungen des Verkehrs- und Mobilitätssystems der funktionalen Stadt, d. h. der zentralen Stadt mit ihrem Umland, abgestimmt sein. Daraus ergibt sich die Notwendigkeit, eine städtische bzw. regionale Datenstrategie zu etablieren, die nicht nur den internen Datenaustausch regelt, sondern auch die Zusammenarbeit mit externen Dienstleistern bzw. Partnern umfasst. Ausbau innerstädtischer Sensorik und Datenflüsse ist ein zentraler Hebel zur Qualitätssteigerung KI-basierter Entscheidungen. Datenquellen können sowohl innerhalb des Systems (z. B. auch durch C-ITS-Infrastruktur oder Echtzeitdaten zur Fahrzeugauslastung) als auch außerhalb generiert werden (z. B. Veranstaltungskalender, Ankündigungsseiten von Großveranstaltungen).

Die notwendigen regionalen Daten werden über das AIAMO Gesamtsystem, konkret über den AIAMOnexus, gesammelt, integriert und bereitgestellt. Dabei handelt es sich um eine leistungsfähige Dateninfrastruktur, die vielfältige Quellen integriert:

- Daten aus dem Verkehrsmanagementsystem der Stadt
- Fahrplan- und Betriebsdaten des öffent-

| Begriff Reinforcement Learning | Begriff Verkehrs- und Mobilitätsmanagement | Beschreibung |
|--------------------------------|--|---|
| Zustand (State) | Situation | Beschreibt die aktuelle Verkehrs- und Umweltsituation, z. B. Level of Service der Streckenabschnitte, Emissionen oder Auslastung im ÖPNV. |
| Aktion (Action) | Strategie in Form eines Maßnahmenbündels | Eine oder mehrere Maßnahmen der Strategie, die geschaltet werden – z. B. Information über eine Umleitung oder Aktivierung von Anreizen (Incentivierung). |
| Belohnung (Reward) | Direkter Nutzen bzw. Schaden bei einem Wechsel des Zustands | Eine Rückmeldung, wie „gut“ die gewählte Maßnahme war – z. B. Verbesserung des Verkehrsflusses oder Reduktion der Emissionen. Diese Belohnung basiert auf Key Performance Indicators (KPIs). |
| Q-Werte (Quality) | Erwarteter Nutzen der Strategieschaltung und Berücksichtigung von Folgezuständen | Der geschätzte Nutzen einer Aktion (der Summe der Maßnahmen) in einem bestimmten Zustand. Sie helfen dem System, aus mehreren potenziell möglichen Aktionen/Strategien die beste auszuwählen. |
| Entscheidungsregel (Policy) | Empfehlung für die Strategieaktivierungen über eine Sequenz von Situationen | Eine Entscheidungsregel, die angibt, welche Aktionen in einer Abfolge bestimmter Zustände gewählt werden soll. Diese wird im Lernprozess fortlaufend optimiert. Hierbei können auch langfristig wirkende Effekte berücksichtigt werden. |

Tabelle 1:
Anwendung des Reinforcement Learnings im AIAMO Strategiemangement
Quelle: Deutsches Zentrum für Luft- und Raumfahrt (DLR)

lichen Personennahverkehrs

- Informationen zum Mobilitätsverhalten der Nutzenden, bereitgestellt durch Mobilitätsplattformen
- öffentlich verfügbare netzbasierte Daten (z. B. Wetter, Events, sozioökonomische Parameter).

Der AIAMOnexus übernimmt dabei die im Verkehrsmanagement zentralen Aufgaben der Datenintegration: Datenaufnahme, -harmonisierung, -fusionierung, Erkennung und Ergänzung fehlender Werte sowie die semantische Zusammenführung. Diese Prozesse basieren auf KI-Verfahren und ermöglichen eine qualitativ hochwertige, konsolidierte Datenbasis. Ein wesentliches Alleinstellungsmerkmal gegenüber heutigen Systemzentralen besteht darin, dass AIAMO systematisch auf eine Vielzahl heterogener Datenquellen zugreift und nicht auf proprietäre Redaktionssysteme beschränkt ist.

Mit fortschreitender Digitalisierung wird sich die Datenverfügbarkeit in Zukunft nochmals deutlich erweitern – etwa durch die zunehmende Fahrzeugvernetzung (V2X), neue Sensorik in der Verkehrsinfrastruktur und die Umsetzung der ITS-Direktive (insbesondere vorrangiger Bereich Individualverkehr (IV): IVS-Dienste für kooperative, vernetzte und automatisierte Mobilität), die eine vernetzte, perspektivisch auch automatisierte Mobilität als strategisches Ziel formuliert.

Die über die AIAMO Integrationszone bereitgestellten Mobilitätsverhaltensmuster bilden die Grundlage für den Aufbau sowie die effiziente und nutzerzentrierte Gestaltung multimodaler Mobilitätslösungen. Die dabei generierten, neuen Daten – etwa zum Mobilitätsverhalten – können nach ihrer Anonymi-

sierung und Aggregation erneut über die Integrationszone für weitere Anwendungen bereitgestellt und weiterverwendet werden, insbesondere für die Gestaltung nachhaltiger, multimodaler Mobilitätslösungen.

Umfassende betriebliche Datenquellen erfordern eine effiziente Bereitstellung von Schnittstellen, die nur teilweise standardisiert sind. Das AIAMO Tool „Virtual Developer“ interpretiert Schnittstellendefinitionen und setzt sie dokumentiert automatisiert in Programmcode um. Dadurch werden sowohl die Bereitstellung von Daten über Schnittstellen als auch die Entwicklung von Software zum Zugriff auf diese Daten beschleunigt. Mithilfe dieser Erweiterungen können KI-Anwendungen die über die Schnittstellen abrufbaren Daten direkt nutzen. Zusätzlich können auf Basis der erweiterten Schnittstellendefinitionen MCP-Server (Model Context Protocol) generiert werden, die von KI-Anwendungen genutzt werden.

5 KI-basiertes Strategiemangement

5.1 Grundlagen des KI-basierten Strategiemangements

AIAMO steuert die Auswahl geeigneter intermodaler Strategien für ein regionales Verkehrs- und Mobilitätssystem unter Berücksichtigung eines umfassenden Datenbestands sowie zahlreicher Optimierungskriterien durch ein KI-gestütztes Strategiemangement. Grundlage ist ein Deep Reinforcement Learning-Ansatz, der die optimale Strategie über ein neuronales Netz auf Basis regionaler Daten sowie innerhalb einer simulationsgestützten Umgebung erlernt. Die hierüber gelernte Policy berücksichtigt

nicht nur die Maßnahmenbündel, die für den Übergang von Situation n in eine angestrebte Situation n+1 geschaltet werden müssen, sondern auch weitere potenziell mögliche Situationen. So können auch langfristig relevante Effekte berücksichtigt werden, wie beispielsweise der Verlauf der Emissionen im Jahresmittel oder die Anzahl der Grenzwertüberschreitungen. Der KI-Agent des Reinforcement Learning-Ansatzes lernt so durch Versuch und Irrtum eine optimale Entscheidung, um ein definiertes Ziel zu erreichen. Die Übersicht in Tabelle 1 zeigt die zentralen Elemente und führt die Instrumente des Reinforcement Learning mit denen des Verkehrs- und Mobilitätsmanagements zusammen.

Für das Training und den Betrieb des Strategiemangements fließen die durch den AIAMOnexus bereitgestellten Daten in den Simulationskern des Digitalen Zwillings ein. Hierbei handelt es sich um ein mikroskopisches Modell des regionalen Verkehrsnetzes, das zur Steigerung der Genauigkeit mit Echtzeitdaten zur aktuellen Verkehrslage angereichert wird. Durch diese Verschneidung konnten bereits signifikante Verbesserungen bei der Repräsentation der Ist-Situation sowie bei kurzfristigen Prognosen erreicht werden [11]. Neben verkehrlichen Parametern werden auch Umweltfaktoren wie Emissionen, Lärm oder Energieverbrauch modelliert und bewertet.

5.2 Hybride Datennutzung und Simulation im KI-basierten Strategiemangement von AIAMO

Das Reinforcement Learning des AIAMO Strategiemangements zielt auf die Schal-

tung des günstigsten Maßnahmenbündels für hochkomplexe Situationen, in denen mehrere Teilaspekte gleichzeitig berücksichtigt werden müssen: von der aktuellen Verkehrslage über die Umweltsituation bis hin zu zeitlich dynamischen Entwicklungen, etwa bei sich abzeichnenden Grenzwertüberschreitungen oder Stauverlagerungen.

Das AIAMO System kombiniert hierzu reale und simulierte Daten. Diese hybride Datennutzung ist aktuell noch unerlässlich, da die heutige Datenlage insbesondere für großräumige, intermodale und langfristig wirkende Strategien noch keine ausreichende Tiefe, Qualität oder flächendeckende Verfügbarkeit aufweist. Anlagenspezifische Echtzeitdaten bilden zwar eine solide Grundlage für die Steuerung, stoßen jedoch an ihre Grenzen, wenn es um Prognosen oder Szenarienplanung geht, etwa bei seltenen Ereignissen oder neuen, bisher nicht erfassten Mobilitätsmustern.

Der Digitale Zwilling bildet somit nicht nur den aktuellen Systemzustand ab und dient als vorausschauendes Analysewerkzeug. Er erweitert auch die reale Datenbasis um simulierte Zustände, Prognosen und Szenarien für die Trainingsphase des Reinforcement Learnings. Die KI lernt aus diesen Daten, welche Maßnahmen unter bestimmten Bedingungen langfristig den größten Nutzen bringen – gemessen an vordefinierten Key Performance Indicators (KPIs) wie Verkehrsfluss, Emissionsreduktion oder Einhaltung von Umweltgrenzwerten. Ein wichtiger Anwendungsfall ist dabei die Abbildung zukünftiger Ereignisse, etwa geplante, aber noch nicht begonnene Infrastrukturmaßnahmen. Für Leipzig bedeutet dies beispielsweise die Berücksichtigung umfangreicher Bauarbeiten an Brückenbauwerken, deren verkehrliche Auswirkungen frühzeitig simulativ erfasst und strategisch gemanagt werden können.

5.3 Architektur des neuronalen Netzes

Der AIAMO Reinforcement-Learning-Ansatz basiert auf einem neuronalen Netz. Ziel ist es, Maßnahmen oder Maßnahmenbündel so zu bewerten und auszuwählen, dass definierte Key Performance Indicators (KPIs) – etwa Verkehrsfluss, Emissionen oder Reisezeiten – systematisch verbessert werden. Das eingesetzte Modell ist ein klassisches Feedforward-Netz, implementiert in Java unter Nutzung der DeepLearning-Bibliothek DeepLearning4J. Es besteht aus mehreren Schichten, die jeweils spezifische Funktionen erfüllen:

Die Eingabeschicht (Input Layer) hat eine Dimension der Anzahl der KPIs, die zur Bewertung herangezogen werden. Jeder KPI beschreibt dabei einen Teilaspekt des aktuellen Verkehrs- oder Systemzustands. Diese Schicht dient als Schnittstelle, über die die Daten in das neuronale Netz eingespeist werden.

Die Ausgabeschicht (Output Layer) besteht aus so vielen Neuronen, wie Maßnahmen zur Auswahl stehen. Jedes Neuron liefert einen kontinuierlichen Q-Wert für eine potenzielle Maßnahme. Die Verwendung der IDENTITY-Aktivierung ermöglicht eine direkte Repräsentation dieser Werte ohne nachgeschaltete Transformation. Diese Q-Werte dienen als Grundlage für die Auswahl der Maßnahmen, die zur Optimierung der KPIs beitragen sollen.

Zwischen Input und Output Layer liegen versteckte Schichten (Dense Layer). Diese vollständig verbundenen Zwischenschichten verwenden eine RELU-Aktivierungsfunktion, die es ermöglicht, nichtlineare Zusammenhänge zwischen den Eingaben und den Q-Werten zu lernen. Die Anzahl der Neuronen in dieser Schicht wird heuristisch über das Quadratprodukt von Eingabe- und Ausgabedimensionen bestimmt, also $(\text{Anzahl KPIs} \times \text{Anzahl möglicher Maßnahmen})$. Dadurch wird sichergestellt, dass das Modell eine hinreichende Kapazität besitzt, ohne unnötig überdimensioniert zu sein.

5.4 Trainingsmethodik und Lernprozess

Als Optimierungsverfahren wird Stochastic Gradient Descent (SGD) mit einstellbarer Lernrate verwendet. Dieser Ansatz bietet eine gute Kontrolle über die Lernfortschritte und ist besonders für kleine bis mittelgroße Modelle effizient und robust. Das Netz wird mittels Mean Squared Error (MSE) als Verlustfunktion trainiert. Da es sich um ein Regressionsproblem handelt, lernt das Modell, den erwarteten zukünftigen Nutzen (Q-Wert) einer Maßnahme in einem gegebenen Zustand korrekt zu prognostizieren.

Die Trainingsdaten stammen aus einem episodischen Lernprozess: Nach jeder ausgewählten Maßnahme wird eine Verkehrssimulation über den Digitalen Zwilling mit SUMO (Simulation of Urban Mobility) durchgeführt, um den resultierenden Systemzustand sowie den erzielten Reward zu bestimmen. Die Simulation ermittelt somit den Nutzen der ausgewählten Maßnahmen. Auf Basis dieser Ergebnisse wird das neuronale Netz aktualisiert. Die Berechnung des Ziel-Q-Werts er-

folgt dabei unter Anwendung der Bellman-Gleichung, einem fundamentalen Baustein des Q-Learning-Algorithmus. Die hiermit verbundene Heuristik ist notwendig, da der Q-Wert auch den Reward und somit den Nutzen, der sich aus zukünftigen Zustandswechseln ergibt, darstellt.

Im Betrieb des Verkehrsmanagementsystems ermöglichen Q-Werte so den Aufbau einer lernenden Policy, die in einer Abfolge von Situationen die bestmögliche Entscheidung trifft. Auf Basis von Echtzeitdaten und Simulationen werden Q-Werte kontinuierlich angepasst, sodass das System aus Erfahrung lernt und sich dynamisch weiterentwickelt. Eine Herausforderung ist die Definition der Bewertungsfunktionen für die Rewards, nach denen die Q-Werte bestimmt werden. Diese müssen die Komplexität der multikriteriellen Entscheidung abbilden. Ähnlich wie bei formalisierten Entscheidungsverfahren findet hier eine Aggregation von Teilbewertungen statt, die eine Nachvollziehbarkeit des Ergebnisses erschwert und somit nicht immer den Anforderungen einer transparenten Abwägung genügt. Unter dem Stichwort Explainable AI werden Forschungsansätze gebündelt, die einen Beitrag zur Nachvollziehbarkeit der KI-basierten Entscheidungen leisten [23]. Diese Nachvollziehbarkeit wird nicht zuletzt von der Gesetzgebung der Europäischen Kommission (AI-Act) gefordert.

6 KI-basiertes Mobilitätsmanagement

Verkehrsteilnehmende streben zunehmend nach einer intermodalen, benutzerfreundlichen Mobilitätslösung, die ihnen eine einfache, nahtlose Fortbewegung von A nach B ermöglicht [13]. Zentrale Anforderungen an solche Systeme sind eine intuitive Bedienbarkeit und eine durchgehende, digitale Unterstützung für unterschiedliche Mobilitätsbedürfnisse – idealerweise über eine zentrale App. Die Integration verschiedener Verkehrsmittel in einer Anwendung soll nicht nur Effizienz und Komfort steigern, sondern auch den Nutzungsprozess vereinfachen und mit einem positiven Nutzererlebnis verknüpft werden. Der Mobilitätsprozess soll dabei nicht nur funktional, sondern auch motivierend und im Idealfall sogar mit Freude verbunden sein, um zu einer Veränderung des Mobilitätsverhaltens zu motivieren. Hier kommt der Ansatz des Decision Driven Data Making zum Tragen – angelehnt an die beschriebenen Bedürf-

nisse der Verkehrsteilnehmenden bietet die mytraQ App editionAIAMO mit der zugehörigen Mobilitätsplattform highQ Mobility-Suite eine flexible Lösung und Möglichkeit der Integration der Maßnahmen aus der Verkehrsplanung (siehe Abschnitt 5).

6.1 KI-basierte, intermodale Mobilitäts-verhaltenserkennung durch die mytraQ editionAIAMO

Sind Verkehrsteilnehmende mit der Mobilitätsapp mytraQ editionAIAMO unterwegs, bietet diese eine patentgestützte, DSGVO-konforme Mobilitätsverhaltenserkennung direkt auf dem Smartphone, d. h., es erfolgt keine Weiterleitung ausführlicher Trackingdaten an Hintergrundserver. Das Verfahren lehnt sich an das Zeus-Patent [2] an, um die Mobilitätsverhaltenserkennung datenschutzkonform auf dem Smartphone durchzuführen. Die Berechnung wird mit Methoden der KI und unter Verwendung von Hidden Markov Algorithmen [7] in der App des Verkehrsteilnehmenden implementiert. Die Analyse dieser abstrahierten Wegabschnitte ermöglicht eine Klassifikation der genutzten Verkehrsmittel (Transportmodi) unter Wahrung der informationellen Selbstbestimmung der Verkehrsteilnehmenden. Dafür werden Messdaten der Smartphones (GPS, Beschleunigung, Geschwindigkeit) kombiniert mit öffentlich verfügbaren Haltestellen- und Linieneinformationen. So wird es möglich, auch bei unscharfen GPS-Messungen den wahrscheinlichsten Weg zu ermitteln und einem Verkehrsmittel zuzuordnen. Damit mytraQ editionAIAMO die Mobilitätsmuster erfassen und Verkehrsmitteln zuordnen kann, müssen weder Standorte noch Bewegungsprofile mit Personen verknüpft werden. Ziel ist, über die Erfassung der Mobilitätsmuster nachhaltiges Mobilitätsverhalten zu fördern und gleichzeitig abrechnungsrelevante Daten für ÖPNV- und Sharing-Dienste automatisch zu erfassen und zur Verfügung stellen zu können.

6.2 Integration der Verkehrsplanung durch Ausgabe von maßnahmenbasierten, KI-unterstützten Routingalternativen für Verkehrsteilnehmende

Die Maßnahmen, die das Strategiemangement situativ auswählt, werden als Routingalternativen an die Verkehrsteilnehmenden über die mytraQ editionAIAMO ausgegeben. Die Route, hier als „AIAMO Route“ bezeichnet, die durch den Optimizer des Workflow-Managers während der Simulationszyklen als diejenige Maßnahme mit dem größten

positiven Effekt auf das jeweilige Verkehrssystem identifiziert wurde, wird besonders hervorgehoben und gekennzeichnet (Bild 2). So erfolgt die Verzahnung der Verkehrs- und Mobilitätsplanung, deren Ergebnisse über die App für die Verkehrsteilnehmenden zugänglich gemacht werden.

6.3 Unterstützung der Umlenkung in den Umweltverbund und Stärkung der Schiene durch Bereitstellung von Push- und Pullfaktoren

Gemäß den Leitlinien für eine krisensichere und klimafreundliche Verkehrspolitik (siehe AGORA-Verkehrswende [4]) sind sowohl Push- als auch Pullfaktoren notwendig, um eine Veränderung des Mobilitätsverhaltens zu bewirken. Die mytraQ editionAIAMO bietet hierfür eine flexible Lösung, anpassbar an die unterschiedlichsten Verkehrs- und/oder Umweltprobleme verschiedener Städte und Kommunen.

6.3.1 Pullfaktoren: Incentivierung und Gamification – Anpassung der Verkehrsströme an Mobilitätsstrategien einer Region

Incentivierung und Gamification motivieren Verkehrsteilnehmende zu Verhaltensänderungen, Bonusleistungen führen zu nachweisbaren Verkehrsentlastungen [5, 8].¹ Die Anwendungen aus AIAMO werten unterschiedlichste Verkehrsszenarien aus. Die Mobilitätsstrategien der Städte und Kommunen werden über die KI-basierten Routenvorschläge, die aus den Auswertungen der Verkehrsplanung entstehen (siehe Abschnitt 6.2), über die mytraQ editionAIAMO



Bild 2: mytraQ editionAIAMO: Maßnahmenbasierte Routenvorschläge als Alternative für Verkehrsteilnehmende – Quelle: highQ Computerlösungen GmbH

an die Verkehrsteilnehmenden weitergegeben. Durch ein Bonussystem wird umweltfreundliches Verhalten belohnt: Die in der App angezeigten Routenvorschläge sind mit Bonuspunkten (Zeitmeilen) versehen, die die Verkehrsteilnehmenden für die Verfolgung eines Vorschlags verdienen können. Die Bonuspunkte können so konfiguriert werden, dass die Strategien der Städte und Kommunen widerspiegelt werden – je strategiekonformer (z. B. nachhaltiger, zu einer gewissen Uhrzeit, einer bestimmten Route folgend oder basierend auf einem bestimmten Mobilitätsangebot, etc.) eine Route ist, desto mehr Bonuspunkte können die Verkehrsteilnehmenden sammeln. Hierbei zielt AIAMO nicht auf individuelle, sondern gemeinwohlkonforme Mobilitätsverbesserung (Social Mobility, siehe [6]) ab und somit auf das Schwarmverhalten: Die von AIAMO identifizierte Route, die der Mobilitätsstrategie der Stadt/Kommune folgt und gleichzeitig für die Gesellschaft insgesamt am besten zu verfolgen wäre, wird besonders incentiviert durch extra viele Bonuspunkte als „AIAMO Route“ (Bild 3).

Neben dieser Incentivierung bietet die mytraQ editionAIAMO zudem die Möglichkeit, Verkehrsteilnehmende durch Gamification zur Veränderung ihres Mobilitätsverhaltens zu motivieren, z. B. durch Auswer-

¹ Hamari et al. führen eine umfassende Literaturübersicht durch, die sich auf die Auswirkungen von Gamification konzentriert. Diese Studie analysiert systematisch frühere Studien zu den Auswirkungen von Gamification und identifiziert deren Ergebnisse und Herausforderungen. Die Ergebnisse der Überprüfung deuten darauf hin, dass Gamification im Allgemeinen die Benutzerbindung erhöht und einen positiven Einfluss auf Lernen und Verhaltensänderung hat.

Bild 3: mytraQ editionAIAMO: Motivation zur Verkehrsverhaltensänderung mit Incentivierung und Gamification – Quelle: highQ Computerlösungen GmbH

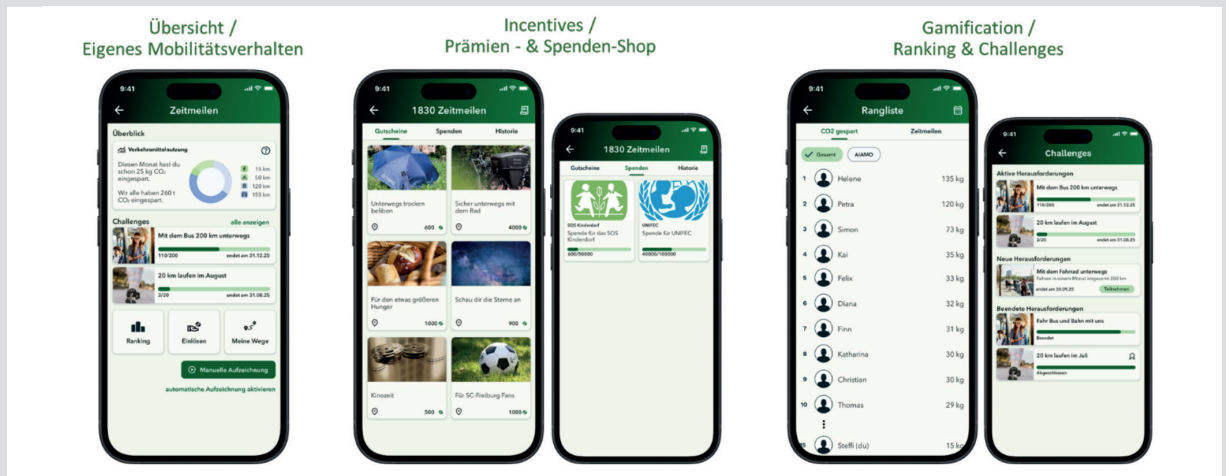



Bild 4: Öffentliches highQ-Dashboard für AIAMO Nutzergruppen – Quelle: highQ Computerlösungen GmbH



tungen zum Mobilitätsverhalten: mit welchem Verkehrsmittel war ein Verkehrsteilnehmer wie viele km unterwegs und wie viel CO₂ hat er eingespart (Bild 3). So wird für Verkehrsteilnehmende ihr eigener Beitrag zu nachhaltiger Mobilität sichtbar und nachvollziehbar. Diese Auswertungen sind nicht nur für einzelne Verkehrsteilnehmende, sondern auch kommunen-/städteübergreifend möglich: Durch ein Management-Cockpit können Daten zur Ermittlung der Verkehrsdichte, Nutzung und Frequenz der Transportmittel sowie ökologische Auswertungen bereitgestellt werden. Das highQ-Dashboard, an zentraler, öffentlicher Stelle platziert, visualisiert unterschiedliche Reports, wie z. B. Anzahl/Anstieg der Bahn-/Busfahrer, Wechsel von Verkehrsmitteln, CO₂-Einsparung, gesammelte Zeitmeilen, u. v. m. (Bild 4).

Neben diesen Auswertungen sorgt das in die

App integrierte Bonusprogramm für die Incentivierung: Hierbei sind unterschiedliche Mobilitätskontexte denkbar – die Städte und Kommunen stellen selbst oder über Partner (lokale Einrichtungen wie Einzelhandel, Parkhausbetreiber, öffentliche Einrichtungen) Prämien im Prämienshop bereit, gegen die die gesammelten Bonuspunkte durch die Verkehrsteilnehmenden eingetauscht werden können. Durch diese Maßnahme kann zum einen der eigene Verkehrsverbund, z. B. durch vergünstigte Tickets, zum anderen die jeweilige Region eingebunden und gestärkt werden, z. B. durch vergünstigte Schwimmbadtickets oder den „Kaffee um die Ecke“.

Weiterhin gibt es auch die Möglichkeit, die gesammelten Punkte zu spenden, z. B. für ein regionales, gemeinnütziges Projekt. Gamification-Elemente, wie Wettbewerbe (Challenges) oder Ranglisten, befördern

zudem die Verhaltensänderung: Städte und Kommunen können ihre vielfältigen Ziele durch Challenges unterstützen, z. B. „Wir alle wollen gemeinsam 100.000 Fahrradkilometer erradeln“ oder „200 Mitfahrergemeinschaften bilden“ oder „50 Tonnen CO₂ einsparen“ – so können die Verkehrsteilnehmenden als Gruppe immer wieder durch neue Aufgaben motiviert werden, gemeinschaftlich Klimaziele zu erreichen (Bild 3).

6.3.2 Pushfaktoren: Perspektivische Möglichkeit für dynamisches Pricing und verursachergerechte Bepreisung (EAV) durch Verkehrsmittelerkennung und -zuweisung

Die datenschutzkonforme Erkennung von Verkehrsmitteln mittels mytraQ edition-AIAMO basiert auf einer „unscharfen“ Lokalisierung, bei der Positionsdaten anonymisiert und aggregiert wahrscheinlichsba-

siert erfasst werden. Die Mustererkennung nutzt Wahrscheinlichkeitsmodelle und einen loQate-Algorithmus nach dem ZEUS-Ansatz (siehe Abschnitt 6.1), um Sensordaten dem richtigen Verkehrsmittel zuzuordnen. GTFS-Daten helfen, zwischen privaten Fahrzeugen und öffentlichen Verkehrsmitteln zu unterscheiden. So wird die multimodale Route eines Verkehrsteilnehmers präzise – und dennoch anonymisiert und wahrscheinkeitsbasiert – rekonstruiert. Dies bildet die Grundlage für eine angestrebte verursachergerechte Bepreisung, welche in Zukunft von politischer Bedeutung sein wird [3], insbesondere für die Einnahmeverteilung (EAV) unter Mobilitätsdienstleistern. Zukünftig sollen dynamische Preise dabei unterstützen können, Verkehrs- und Umweltspitzen (z. B. Stau am Morgen oder Feinstaubbelastung am Nachmittag oder auch durch ein großes Event, wie ein Fußballspiel) zu reduzieren, indem durch höhere Preise für die Mobilitätsdienstleistungen die Nachfrage der Verkehrsteilnehmer gesenkt bzw. durch niedrigere Preise erhöht wird. Durch diesen Mechanismus strebt die mytraQ edition-AIAMO an, die Verkehrsteilnehmer in

unterschiedliche Zeiten (z. B. außerhalb von Stoßzeiten), auf unterschiedlichen Routen und in unterschiedliche Mobilitätsangebote zu verteilen, um eine nachhaltige, gemeinwohlkonforme Mobilität zu fördern (Bild 5).

7 Zukunftsperspektiven KI-gestützter Verkehrsprognosen: Von Simulation zu lernenden Modellen

Die Beispiele aus AIAMO zeigen, dass KI neue Impulse bei der Systementwicklung setzen kann, insbesondere dann, wenn sie mit „klassischen“ Verfahren kombiniert werden. So setzt auch AIAMO für die Vorhersage zukünftiger Verkehrssituationen weiterhin auf Simulationsmodelle. Diese sind notwendig, wenn keine ausreichende Datenbasis für das Training von KI-Systemen zur Verfügung steht, z. B. bei der Modellierung neuer Infrastruktursituationen oder außergewöhnlicher Ereignisse. Simulationen erzeugen dann synthetische Daten für ein realitätsnahes Training von KI-Modellen. Die Ergebnisse von AIAMO zeigen aber auch, dass die KI-

Forschung im Verkehrs- und Mobilitätsmanagement rasch voranschreitet. So ist beispielsweise kontinuierlich zu prüfen, ob KI-basierte Verfahren zumindest Teilprozesse klassischer Simulationen ersetzen können.

Transformer-Modelle eignen sich beispielsweise für dynamische Prognosen von Zeitreihen, bei denen mehrere Einflussgrößen über längere Zeiträume hinweg interagieren. Erkannten Ähnlichkeiten zwischen Werten über einen Zeitraum fehlen jedoch die räumliche Bezüge, die für Verkehrs- und Mobilitätssysteme unerlässlich sind. Für die räumliche Dimension ist daher die Kombination der Transformer mit graphenbasierten neuronalen Netzen (GNNs) vielversprechend. GNNs modellieren die räumlichen Strukturen als Knoten-Kanten-Netzwerke, z. B. Straßenabschnitte, Haltestellen oder Netzverknüpfungspunkte, und ermöglichen eine realitätsnahe Repräsentation räumlicher Interaktionen.

Ein weiterer zukunftsorientierter Ansatz ist der Einsatz von Generative Adversarial Networks (GANs). Diese bestehen aus zwei

RTB DIALOG-DISPLAY

VOLL ANSPRECHEND

FREI PROGRAMMIERBARE VOLLMATRIX-ANZEIGE

INNOVATIVES DESIGN - MEHR PLATZ FÜRS MOTIV

NACHHALTIGE LÄRM- UND GESCHWINDIGKEITSREDUZIERUNG

RTB

www.rtb-bl.de | Tel. +49 5252 9706-0

Icons: Carpooling, Electric Vehicle, Parking

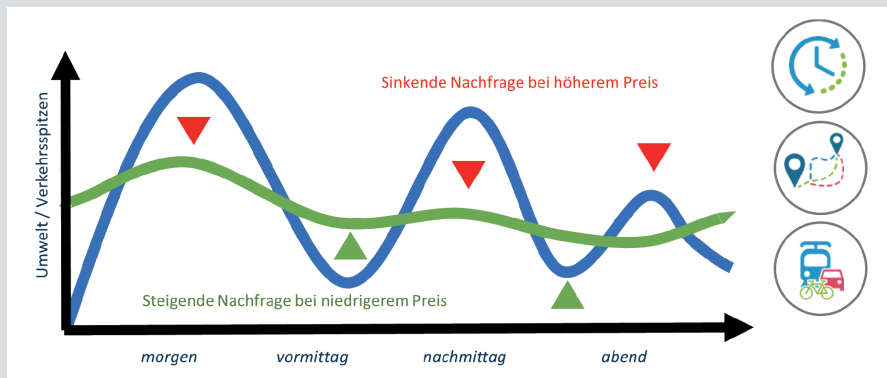


Bild 5: Verringerung von Verkehrs- und Umweltpitzen durch dynamische Preisgestaltung –
Quelle: highQ Computerlösungen GmbH

konkurrierenden Netzwerken: ein Generator versucht, realistische Daten zu erzeugen und ein Diskriminator entscheidet, ob es sich um reale oder, ggf. falsche, synthetische Daten handelt. In der Verkehrsprognose könnten GANs zur Erzeugung realitätsnaher Verkehrsszenarien eingesetzt werden, die in der Praxis bisher nicht beobachtet wurden. Diese Halluzinationen müssen gerade bei sicherheitskritischem Einsatz im Verkehrsmanagement kontrollierbar und nachvollziehbar bleiben [22].

Insgesamt zeigt sich eine klare Entwicklungsperspektive. AIAMO verfolgt daher einen hybriden Ansatz, bei dem reale Daten, Simulationsergebnisse und zunehmend lernbasierte KI-Verfahren systematisch miteinander verbunden werden, um die Mobilität von morgen intelligent, robust und nachhaltig zu gestalten. In der Zukunft werden jedoch in Gesamtsystemen – sei es in Simulationsverfahren, Digitalen Zwillingen oder Mobilitäts-services – einzelne Verfahren schrittweise durch KI-basierte Verfahren ersetzt. Dies soll aber nicht heißen, dass auf nicht KI-basierte Verfahren in der Zukunft verzichtet werden kann und sollte. Alle Ansätze haben ihre Stärken und Schwächen und es gilt, den besten Verfahrensmix zu finden.

Literaturverzeichnis

- [1] Umweltbundesamt (2025): Klimaschutz im Verkehr, auf den Seiten des Umwelt Bundesamts, URL: <https://www.umweltbundesamt.de/themen/verkehr/klimaschutz-im-verkehr#undefined>, abgerufen am 10.7.2025
- [2] ZEUS-Patent (2025): auf den Seiten des Deutschen Patentamts, URL: <https://register.dpma.de/DPMAregister/pat/register?AKZ=1020070145286>, abgerufen am 23.7.2025
- [3] o. V. (2024): Neues Gremium verteilt Einnahmen des Deutschlandtickets, auf den Seiten des Zukunftsnetzwerks ÖPNV, URL: <https://www.zukunftsnetzwerk-oepnv.de/aktuelles/news/neues-gremium-verteilt-einnahmen-des-deutschlandtickets>, abgerufen am 23.7.2025

- [4] Agora Verkehrswende und Ellery Studio (2021): Abgefahren! Eine infografische Novelle zur Verkehrswende Agora Verkehrswende (2020), auf den Seiten der Agora Verkehrswende, URL: <https://www.agora-verkehrswende.de/fileadmin/Projekte/2020/Abgefahren-Comic/Ellery-Studio-AGORAVerkehrswende-Abgefahren-OnlineVersion.pdf>, abgerufen am 23.7.2025
- [5] Khademi, E.; Timmermans, H. (2014): The Long-term Effectiveness of a Reward Scheme in Changing Daily Travel Choices, in: Proceedings of the Social and Behavioral Sciences, 2014, 111, 380–389
- [6] Peine, K.; Hornig, T. (2025): Social Mobility als Erfolgsfaktor des Mobilitätswandels, in: Sonderdruck AIAMO KI-Serie in Straßenverkehrstechnik, auf den Seiten der Straßenverkehrstechnik, URL: https://aiamo.de/download/pdfs/Sonderdruck_AIAMO_SVT.pdf, abgerufen am 23.7.2025
- [7] Zimmermann, K.-H. (2022): Das Hidden-Markov-Modell, Zufallsprozesse mit verborgenen Zuständen und ihre wahrscheinlichkeitstheoretischen Grundlagen, Springer, Heidelberg 2022
- [8] Hamari, J.; Koivisto, J.; Sarsa, H.: Does Gamification Work? – A Literature Review of Empirical Studies on Gamification. The 47th Hawaii International Conference on System Sciences, pp. 3025–3034. Waikoloa, HI, USA (2014). <https://doi.org/10.1109/HICSS.2014.377>
- [10] BMV (2025): Mobilität in Deutschland – MiD, Kurzbericht, URL: www.mobilitaet-in-deutschland.de/pdf/MiD2023_Kurzbericht.pdf, abgerufen am 28.7.2025
- [11] FGSV (2003): Hinweise zur Strategieentwicklung im dynamischen Verkehrsmanagement, FGSV Verlag, Köln
- [12] FGSV (2009): Arbeitspapier zur Gestaltung von Verkehrsmanagementstrukturen, FGSV Verlag, Köln
- [13] FGSV (2018): Empfehlungen zur Anwendung von Mobilitätsmanagement, FGSV Verlag, Köln
- [14] FGSV (2011): Hinweise zur Strategieanwendung im dynamischen Verkehrsmanagement, FGSV Verlag, Köln
- [15] Trabert, T.; Schmid, A.: Künstliche Intelligenz im Mobilitätsmanagement: Revolution oder Risiko? Straßenverkehrstechnik, auf den Seiten der Straßenverkehrstechnik, URL: https://aiamo.de/download/pdfs/Sonderdruck_AIAMO_SVT.pdf, abgerufen am 23.7.2025
- [17] Dalauff, C.; Sohr, A. (2025): Digitale Zwi-

linge ermöglichen ein umweltsensitives Verkehrsmanagement, Straßenverkehrstechnik, auf den Seiten der Straßenverkehrstechnik, URL: https://aiamo.de/download/pdfs/Sonderdruck_AIAMO_SVT.pdf, abgerufen am 23.7.2025

- [19] Wiens, N. (2025): Daten vernetzen, Mobilität neu denken, Straßenverkehrstechnik, auf den Seiten der Straßenverkehrstechnik, URL: https://aiamo.de/download/pdfs/Sonderdruck_AIAMO_SVT.pdf, abgerufen am 23.7.2025
- [20] Europäische Union (EU) (2023): Empfehlungen der Kommission vom 8.3.2023 zu den nationalen Unterstützungsprogrammen der nachhaltigen städtischen Mobilität, Brüssel
- [21] Europäische Union, 2024: VERORDNUNG (EU) 2024/1679 DES EUROPÄISCHEN PARLAMENTS UND DES RATES vom 13. Juni 2024 über Leitlinien der Union für den Aufbau des Transseuropäischen Verkehrsnetzes, zur Änderung der Verordnungen (EU) 2021/1153 und (EU) Nr. 913/2010 und zur Aufhebung der Verordnung (EU) Nr. 1315/2013
- [22] Hüb, N.; Mauerer, W. (2025): Generative KI: Vom technologischen Paradigmenwechsel zur Vision einer neuen Ära im Straßenverkehr, THEMENHEFT KI, Fachzeitschrift Straßenverkehrstechnik Ausgabe April 2025
- [23] Hiller, J. Chevalier, E.; Fazekas, A. (2025): Machine Learning, Deep Learning, KI? Grundlagen und Chancen im Straßenverkehrsbereich, THEMENHEFT KI, Fachzeitschrift Straßenverkehrstechnik Ausgabe April 2025

Über AIAMO

Das Forschungsprojekt AIAMO verbindet die neuesten Entwicklungen der Künstlichen Intelligenz (KI) mit konkreten, praktischen Anwendungen im Bereich der inter- und multimodalen Mobilität. Es zielt darauf ab, Mobilitätsdaten effizient zu nutzen, um die Verkehrssteuerung in Städten und ländlichen Regionen zu optimieren, den CO₂-Ausstoß zu minimieren und gleichzeitig die Lebensqualität der Bürgerinnen und Bürger zu erhöhen. AIAMO entwickelt und nutzt KI-Modelle zur Analyse und Optimierung von Mobilitätsdaten. Durch die Einbindung bisher ungenutzter Daten, deren intelligenter Vernetzung und Analyse, werden neue Möglichkeiten für die nachhaltige Mobilität eröffnet.

Das Projekt wird gefördert vom ehemaligen Bundesministerium für Digitales und Staatsmodernisierung in Höhe von 16,7 Millionen Euro. Das durch ITS Germany e.V. geführte Konsortium von 13 Partnern aus Wissenschaft, Forschung und Industrie – T-Systems, Theis Consult, Fraunhofer IML, Bosch, Deutsches Zentrum für Luft- und Raumfahrt, Helmholtz Zentrum für Umweltforschung, highQ, FKFS, TEQYARD, Swarco sowie Schlothauer & Wauer – entwickelt innovative Lösungen, die urbane und ländlich geprägte Mobilitätsbedürfnisse gleichermaßen abdecken. ■