

Straßen- verkehrstechnik

Sonderdruck AIAMO KI-Serie in *Straßenverkehrstechnik*

Sonderdruck

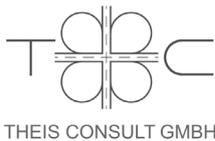
MOBILITÄT MIT KI.

NACHHALTIGER. EFFIZIENTER. SICHERER.

AIAMO
Artificial Intelligence And MObility

ITS
GERMANY

AIAMO Konsortialpartner





Inhalt

Grußworte

Digitale Möglichkeiten nutzen – Mobilität der Zukunft gestalten

Patrick Schnieder,

Bundesminister für Verkehr 4

AIAMO macht Fortschritt greifbar – Datenintelligenz für den Mobilitätsalltag

Markus Wartha,

Präsident ITS Germany e.V. und Konsortialführer AIAMO 5

AIAMO KI-Serie – Fachbeiträge

Das AIAMO-Prinzip – den Mobilitätswandel mit künstlicher Intelligenz neu gestalten

Markus Wartha, Präsident ITS Germany e.V. und

Christian Roszak, Vizepräsident ITS Germany e.V.

(Straßenverkehrstechnik 2-2025, ab Seite 158) 6

Social Mobility als Erfolgsfaktor des Mobilitätswandels

Dr. Katharina Peine und Thomas Hornig

highQ Computerlösungen, Freiburg

(Straßenverkehrstechnik 3-2025, ab Seite 224) 10

Daten vernetzen, Mobilität neu denken

Nicol Wiens

TEQYARD, Braunschweig

(Straßenverkehrstechnik 4-2025, ab Seite 287) 12

Generative KI: Vom technologischen Paradigmenwechsel zur Vision einer neuen Ära im Straßenverkehr

Nicole HöB und Prof. Dr. Wolfgang Mauerer

Ostbayerische Technische Hochschule Regensburg,

Fakultät Informatik und Mathematik

(Straßenverkehrstechnik 4-2025, ab Seite 247) 15

Künstliche Intelligenz im Mobilitätsmanagement: Revolution oder Risiko?

Dr. Thomas Trabert und Andreas Schmid

Helmholtz Zentrum für Umweltforschung (UFZ), Leipzig;

SWARCO, Gaggenau

(Straßenverkehrstechnik 5-2025, ab Seite 352) 20

Digitale Zwillinge ermöglichen ein umweltsensitives Mobilitätsmanagement

Carsten Dalaff und Alexander Sohr

DLR Deutsches Zentrum für Luft- und Raumfahrt e.V.,

Institut für Verkehrssystemtechnik, Braunschweig

(Straßenverkehrstechnik 6-2025, ab Seite 396) 23

Grußwort von Patrick Schnieder, Bundesminister für Verkehr

Digitale Möglichkeiten nutzen – Mobilität der Zukunft gestalten

Klimafreundlich und leistungsfähig, verfügbar und vernetzt, bürger-nah und bezahlbar: So soll die Mobilität von morgen aussehen. Diese Zukunft zu gestalten, ist eine vielfältige, anspruchsvolle Aufgabe – eine Aufgabe, an der wir entschlossen arbeiten und bei der uns digitale Lösungen helfen. Zum Beispiel das Projekt AIAMO, das die Bundesregierung fördert.

Bei diesem Projekt werden mithilfe von Künstlicher Intelligenz Verkehrsdaten nicht nur erfasst, sondern kontextbezogen ausgewertet und strategisch nutzbar gemacht. Damit kann Mobilität modern und klug gemanagt werden. So lassen sich zum Beispiel Baustellen vorausschauend koordinieren, Emissionen reduzieren oder multimodale Mobilität intelligent planen. Das heißt, Verkehrsflüsse können dynamisch, ressourcenschonend und umweltfreundlich gesteuert werden.

Statt auf Insellösungen zu setzen, denkt AIAMO Mobilität dabei als vernetzten Raum – über Zuständigkeitsgrenzen hinweg, flexibel integrierbar in kommunale Systeme und offen für vielfältige Partner. Ein solcher übergreifender Ansatz ist entscheidend, um Verkehr und Mobilität nachhaltig und attraktiv zu gestalten.

Kommunen erhalten dank AIAMO fundierte Entscheidungsgrundlagen, um Infrastrukturen und verkehrliche Maßnahmen bedarfsgerecht zu planen, Verkehrsangebote besser zu vernetzen und den öffentlichen Raum lebenswerter zu gestalten. Für Unternehmen bietet das Projekt ein Innovationsfeld, um neue datenbasierte Services und Anwendungen zu entwickeln – von einer Tür-zu-Tür-Routenplanung bis zu intelligenter Verkehrslogistik. Und die Menschen in Städten und ländlichen Regionen bekommen verlässliche, auf ihre Situation zugeschnittene Mobilitätsangebote.



AIAMO zeichnet sich nicht nur durch technologische Exzellenz aus, sondern auch durch einen konsequenten Praxisbezug. So werden Anwendungen und Verfahren unter realen Bedingungen in mehreren Pilotregionen erprobt – orientiert an den jeweils unterschiedlichen Bedürfnissen. Dabei entstehen übertragbare Lösungen, die als Blaupause für Kommunen deutschlandweit und auf europäischer Ebene dienen können.

Mobilität und Digitalisierung: Das Projekt AIAMO zeigt eindrucksvoll, wie beides zusammen gedacht, umgesetzt und gelingen kann – mit Gewinn und Mehrwert für ganz viele.

Berlin, Juni 2025

*Ihr Patrick Schnieder
Bundesminister für Verkehr*

Grußwort von Markus Wartha, Präsident ITS Germany e.V. und Konsortialführer AIAMO

AIAMO macht Fortschritt greifbar – Datenintelligenz für den Mobilitätsalltag

Die Anforderungen an modernes Mobilitätsmanagement wachsen rasant: Klimaziele müssen erreicht, Ressourcen zielgerichtet eingesetzt und Mobilitätsangebote effizienter, inklusiver, flexibler und sicherer gestaltet werden. Für all das braucht es eines: die Fähigkeit, komplexe Datenstrukturen in nutzbare Informationen zu übersetzen – präzise, aktuell und verlässlich.

AIAMO schafft eine robuste KI-Datenbasis für konkrete Anwendungen.

Mit dem AIAMOnexus stellen wir erstmals eine Infrastruktur zur Verfügung, die fragmentierte Mobilitätsdaten nicht nur technisch zusammenführt, sondern kuratiert, strukturiert, qualitätsgesichert und mit KI-Modellen aufbereitet, zur Verfügung stellt. Damit stehen die Daten für Prognosen, Steuerung und innovative operative Mobilitätslösungen bereit. Das eröffnet eine neue Qualität datenbasierter Entscheidungsunterstützung – für Städte, Verkehrsunternehmen, Technologieanbieter und die öffentliche Hand.

Was AIAMO auszeichnet, ist der konsequent praxisorientierte Ansatz:

Wir entwickeln nicht nur theoretische Konzepte, sondern erproben diese unter realen Bedingungen – ausgerichtet an den konkreten Anforderungen und Herausforderungen von Städten und Kommunen. In den ersten AIAMO-Pilotregionen Leipzig und Landau in der Pfalz werden die entwickelten Lösungen bereits in der Praxis getestet, weiterentwickelt und auf ihre Übertragbarkeit geprüft. Und: Wir machen diese Anwendungen anschlussfähig für die ITS-Industrie. edition AIAMO bietet dafür ein klar strukturiertes Entwickler-Framework – technisch fundiert, marktnah gedacht.

Ein großer Vorteil für Kommunen ist die direkte Umsetzbarkeit.

Viele Städte haben keine Kapazitäten für eigene KI-Entwicklung oder Datenharmonisierung. Mit AIAMO können sie bestehende Systeme integrieren – ohne neue Speicherinfrastruktur, ohne proprietäre In-sellösungen und ohne umfassendes Spezialisten-Know-How. Der Zugang zu qualitativ hochwertigen, nutzungsbereiten KI-Daten wird deutlich vereinfacht. Das reduziert Aufwände – und erhöht Wirkung.

Zugleich leisten wir mit AIAMO einen aktiven Beitrag zur europäischen Vernetzung:

Mit AIAMOitip starten wir den Innovationstransfer und unterstützen gezielt den Weg in den Wirkbetrieb. Gemeinsam mit ERTICO – ITS Europe etablieren wir Kooperationsstrukturen, die technologische



Markus Wartha

Präsident
des ITS Germany e.V.

Exzellenz mit strategischer Skalierbarkeit verbinden. Hier entstehen nicht nur Lösungen – hier entstehen Standards und Referenzmodelle für den europäischen Raum.

Dieser Sonderdruck der AIAMO KI-Serie dokumentiert, was möglich ist.

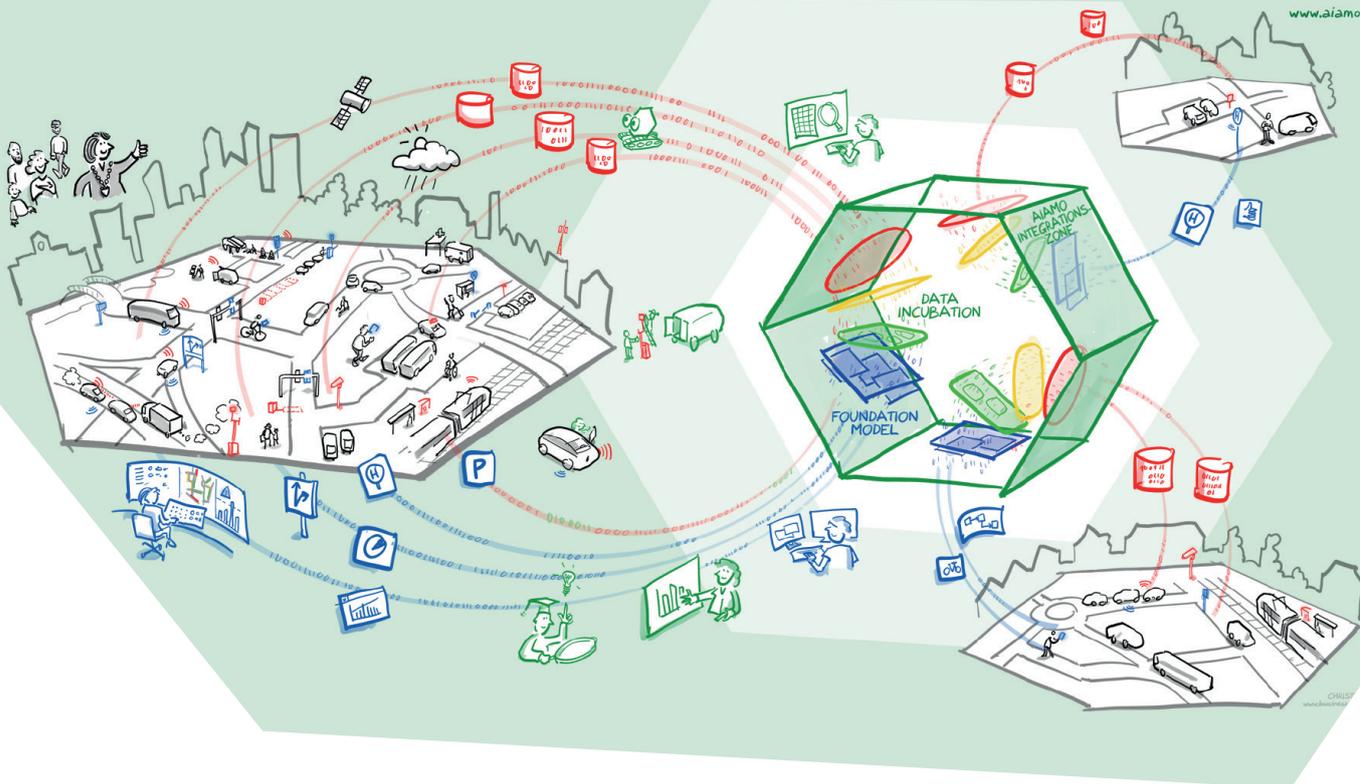
Er versammelt Fachbeiträge, die tief in die Praxis und Architektur des Projekts blicken – verfasst von Expertinnen und Experten unserer Partner. Er steht für den Anspruch von AIAMO, Innovation nicht nur zu erforschen, sondern in den Mobilitätsalltag zu bringen – nachvollziehbar, anschlussfähig, wirksam.

Ich danke allen Beteiligten für ihre Zusammenarbeit und ihr Vertrauen in unsere gemeinsame Vision – und wünsche eine erkenntnisreiche Lektüre.

AIAMO steht für KI in Bewegung – und für den Beginn einer neuen Ära des Mobilitätsmanagements in Deutschland und Europa.

Markus Wartha

*Präsident ITS Germany e.V.
Konsortialführer AIAMO*



Das AIAMO-Prinzip – Den Mobilitätswandel mit künstlicher Intelligenz neugestalten

Im Rahmen globaler Herausforderungen urbaner Mobilität und der Klimaagenda rückt das Thema „Intelligente Mobilität“ immer stärker in den Fokus. AIAMO (Artificial Intelligence And MObility) – ein vom Bundesministerium für Digitales und Verkehr (BMDV) gefördertes Forschungsprojekt – hebt sich mit einem ganzheitlichen, KI-gestützten Mobilitätsansatz hervor. Die Vision: Mit modernster KI-Technologie neue Standards in Verkehrsmanagement, Umweltentlastung und Lebensqualität setzen.

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 Bürger zu erhöhen. AIAMO entwickelt und nutzt KI-Modelle zur Analyse und Optimierung von Mobilitätsdaten. Durch die Einbindung bisher ungenutzter Daten, deren intelligente Vernetzung und Analyse, werden neue Möglichkeiten für die nachhaltige Mobilität eröffnet.

Das durch ITS Germany e.V. geführte Konsortium von 13 Partnern aus Wissenschaft, Forschung und Industrie entwickelt innovative Lösungen, die urbane und ländlich geprägte Mobilitätsbedürfnisse gleichermaßen abdecken. Mit einer Reihe fundierter

Fachbeiträge beleuchten wir in den nächsten Ausgaben von **Straßenverkehrstechnik** aus unterschiedlichen Perspektiven, wie der ganzheitliche Ansatz, KI-basierte Anwendungen und spezialisierte KI-Software von AIAMO ein neues Mobilitätsdenken ermöglichen und nachhaltige, niedrigschwellige Lösungen für Städte und Kommunen schaffen. Im Auftaktgespräch zur neuen Serie erklären Markus Wartha, Präsident von ITS Germany e.V., und Dipl.-Ing. Christian Roszak, Vizepräsident des Verbands, wie AIAMO diesen Wandel vorantreibt.

Gefördert durch:



Die Bundesregierung



aufgrund eines Beschlusses des Deutschen Bundestages

„Mit AIAMO schaffen wir erstmals die technische Grundlage, um Mobilitätsdaten in hochentwickelten KI-Modellen zu nutzen.“

Herr Wartha, wie trägt der Einsatz von künstlicher Intelligenz konkret dazu bei, die von AIAMO angestrebte Zukunft der Mobilität zu verwirklichen, und welche Innovationen heben Ihr Projekt von anderen Mobilitätsansätzen ab?

Markus Wartha: Unsere Überzeugung ist, dass die Mobilität der Zukunft inter- und multimodal, klimafreundlich sowie bedarfsorientiert sein muss – und zwar für alle Akteure und zum Wohl der nutzenden Bürger: von kleinen und mittleren Städten und Kommunen bis hin zu großen Ballungszentren sowie von kleinen und mittelständischen Unternehmen (KMU) und Mobilitätsdienstleistern bis hin zu großen Verkehrsbetrieben.

Die entscheidende Schlüsselinnovation ist dabei die Nutzung künstlicher Intelligenz (KI) im Rahmen eines ganzheitlichen Ansatzes für die Mobilitätsanwendungen der nächsten Generation. KI ermöglicht es uns, die vorhandenen Daten aus verschiedensten Quellen – von Umweltmessungen, Fahrzeug- und Nutzungsdaten bis zu Verkehrsdaten – intelligent zu verknüpfen, umfassend zu analysieren und für Prognosen sowie die Steuerung der Mobilität anzubieten. Dies eröffnet völlig neue Möglichkeiten, etwa bei der Vernetzung von Individualverkehr (IV), öffentlichem Personennahverkehr (ÖPNV) sowie Rad- und Fußverkehren oder im Bereich der umweltsensitiven Verkehrssteuerung.



Markus Wartha,
Präsident ITS Germany e.V.



Christian Roszak,
Vizepräsident ITS Germany e.V.

Mit AIAMO schaffen wir erstmals die technische Grundlage, um Mobilitätsdaten in hochentwickelten KI-Modellen zu nutzen. Dies steht im Zentrum von AIAMO. Damit legen wir den Grundstein für zukunftsweisende Anwendungen im Mobilitätsmanagement, die nicht nur bestehende Herausforderungen lösen, sondern ein Umdenken in der Art, wie wir Mobilität morgen und übermorgen organisieren und erleben, ermöglichen.



Das AIAMO Team mit Projektpartnern beim zweiten AIAMOCamp in Frankfurt

Herr Roszak, welche technologischen und methodischen Ansätze stecken hinter AIAMO, und wie ermöglichen diese die Umsetzung Ihrer Vision?

Christian Roszak: Eine effektive Verkehrssteuerung wird heute oft durch eine fragmentierte, häufig lückenhafte und nicht interoperable Datenbasis erschwert, da viele Akteure und Systeme ihre Daten getrennt voneinander verwalten. AIAMO löst dieses Problem mit einer leistungsfähigen Integrationszone, die es ermöglicht, Daten aus verschiedensten Quellen intelligent zugänglich zu machen, zu analysieren und zu verknüpfen.

Die Mesh-Architektur der Lösung erlaubt die Integration dezentraler Datenquellen, ohne eine zentrale Speicherung zu benötigen. Das stellt die Datenhoheit der Akteure sicher und schafft eine Grundlage für Interoperabilität und Skalierbarkeit. Der Verarbeitungsprozess der Daten beginnt mit der Qualitätsverbesserung der Rohdaten, gefolgt von einer Veredelung durch Feature Engineering und Aggregation. So entsteht eine konsistente und strukturierte Datengrundlage für das Foundation Modelling Framework, das ein effektives Training der KI-Modelle sicherstellt.

Durch Technologien wie Natural Language Processing und maschinelles Lernen können enorme Datenmengen analysiert und für Anwendungen wie digitale Zwillinge oder umweltsensitive Verkehrssteuerungen nutzbar gemacht werden. So können Verkehrsflüsse präzise modelliert, Engpässe prognostiziert und umweltfreundliche Routen identifiziert werden.

Eine weitere Besonderheit sind die neutralen Schnittstellen von AIAMO, die eine flexible und standardisierte Integration von Datenquellen wie Individualverkehr, ÖPNV und Umweltmessstationen ermöglichen. Dies bildet die Grundlage für zukunftssichere Mobilitätslösungen, die vernetzt, nachhaltig und skalierbar sind.

Wie können vor allem Städte und Kommunen von künstlicher Intelligenz in der Mobilitätssteuerung profitieren, und warum ist ihr Einsatz in diesem Bereich heute so wichtig?

Markus Wartha: Der Einsatz von KI ermöglicht es, die im Verkehrsumfeld entstehende Komplexität, die durch die exponentielle Zunahme erhobener Daten entsteht, so zu verarbeiten, dass daraus umsetzbare Erkenntnisse gewonnen werden können. Dies ist entscheidend, um Lösungen für die Fragestellungen der Verkehrsplanung, Fahrzeugentwicklung sowie des integrierten Verkehrs-, Flotten- und Energiemanagements zu finden – sowohl für große räumliche Einheiten wie ganze Bundesländer oder europäische Regionen als auch für kleinere Kommunen.

Durch den Einsatz von KI können Städte und Kommunen den Verkehr effizienter gestalten. Die dringend notwendigen innovativen Mobilitätsanwendungen der nächsten Generation können entwickelt werden. Insbesondere für kleinere Städte bietet KI eine Chance, moderne, ressourcenschonende und nachhaltige Mobilitätslösungen zu implementieren, die auf ihre spezifischen Bedürfnisse abgestimmt sind. Der Einsatz von KI in der Mobilitätssteuerung wird somit zur Schlüsseltechnologie, wie wir die Herausforderungen der Mobilität von morgen und übermorgen bewältigen.

Christian Roszak: Die Vorteile von KI für die Mobilitätssteuerung in Städten und Kommunen sind weitreichend und von entscheidender Bedeutung für den Mobilitätswandel:

- **Echtzeit-Optimierung der Verkehrssteuerung:** KI kann Verkehrsströme in Echtzeit analysieren und optimieren. Das reduziert Staus, sorgt für flüssigeren Verkehr und verkürzt Wartezeiten an



Ampeln – alles wesentliche Faktoren für eine spürbare Verbesserung des Verkehrsflusses und eine höhere Lebensqualität.

- **Multimodale Mobilitätslösungen:** Durch die intelligente Vernetzung von Daten aus dem Individualverkehr, dem öffentlichen Nahverkehr sowie dem Fahrrad- und Fußgängerverkehr entstehen integrierte Mobilitätslösungen, die den Bedürfnissen unterschiedlicher Nutzergruppen gerecht werden. Dies führt zu einer nahtlosen und optimierten Mobilitätserfahrung für alle Verkehrsteilnehmer.
- **Nachhaltigkeit und Umweltschutz:** KI ermöglicht es, Emissionsdaten, Umweltbelastungen und Wetterverhältnisse zu analysieren und darauf basierend umweltsensitive Verkehrssteuerungen vorzunehmen. Dies ist ein entscheidender Schritt hin zu nachhaltigeren, klimafreundlichen Verkehrsstrategien, die aktiv zum Klimaschutz beitragen.
- **Prognose und vorausschauende Planung:** Mit Hilfe von KI können präzise Prognosen zu zukünftigen Verkehrsaufkommen, Mobilitätsbedarfen und Engpässen erstellt werden. Städte und Kommunen können damit ihre Mobilitätsplanung proaktiv anpassen und mögliche Verkehrsstörungen vermeiden, bevor sie entstehen.
- **Kosten- und Ressourceneffizienz:** Automatisierte Datenanalysen sparen nicht nur Zeit, sondern auch personelle Ressourcen. Das ermöglicht einen niedrighwelligen Zugang zu bedarfsgerechten Lösungen ohne eigenen Entwicklungsaufwand, die effizientere Nutzung von Finanzmitteln und eine präzisere Planung und Umsetzung von Mobilitätsmaßnahmen.

Angesichts der Herausforderungen durch wachsende Städte, zunehmende Mobilitätsanforderungen und den Klimawandel ist der Einsatz von KI in der Mobilitätssteuerung nicht nur sinnvoll, sondern unerlässlich. KI bietet die notwendigen Werkzeuge, um eine zukunftsfähige, ressourcenschonende und nachhaltige Mobilität in Städten und Kommunen zu realisieren.

AIAMO arbeitet mit den Pilotregionen Leipzig und Landau in der Pfalz. Welche Ziele verfolgt das Projekt dort, und wie weit ist der Fortschritt?

Christian Roszak: Die Pilotregionen Leipzig und Landau in der Pfalz sind entscheidend, um die theoretischen und technologischen Ansätze von AIAMO in der Praxis zu erproben und weiterzuentwickeln. In Leipzig liegt der Fokus auf einem urbanen, multimodalen und umweltsensitiven Mobilitätsmanagement. Unser Ziel ist es, Mobili-



tätsdaten aus verschiedenen Quellen – Individualverkehr, ÖPNV und Umweltmessstationen – intelligent zu verknüpfen. Im Zentrum steht der Aufbau eines digitalen Zwillings, der Verkehrs- und Umweltbedingungen in Echtzeit abbildet und dynamische Verkehrsprognosen ermöglicht. Außerdem setzen wir KI-gestützte Steuerungsmodelle ein, um den Verkehr effizienter zu lenken und die Emissionen zu reduzieren.

Landau in der Pfalz hingegen bietet uns die Möglichkeit, die Entwicklungen auf die spezifischen Bedürfnisse von Mittelstädten in Verbindung mit weniger dicht besiedelten Regionen anzupassen. Hier geht es darum, flexible Mobilitätsangebote zu schaffen, die das Umland besser mit städtischen Zentren vernetzen. Gleichzeitig liegt ein Schwerpunkt auf der Entwicklung umweltsensitiver Verkehrssteuerungen und der Integration multimodaler Mobilitätslösungen. Ziel ist es, gerade kleinere Kommunen dabei zu unterstützen, Mobilitätsdaten effizient zu nutzen, eine zukunftsorientierte Verkehrsplanung zu etablieren und Lösungen nicht jedes Mal von Grund auf neu entwickeln zu müssen.

Was den Projektfortschritt betrifft, sind wir in beiden Regionen gut vorangekommen. Die technische Infrastruktur der AIAMO-Integrationszone, inklusive der Mesh-Architektur und der KI-Module, wurde erfolgreich implementiert. Erste Datenerhebungen und -analysen haben uns wertvolle Einblicke in die lokalen Mobilitätsbedarfe gegeben. Prototypische Anwendungen wie der digitale Zwilling und KI-basierte Verkehrssteuerungen befinden sich bereits in einer ersten Testphase. Für die nächsten Schritte liegt der Schwerpunkt auf der Feinabstimmung der KI-Modelle und der Erprobung der Lösungen im realen Betrieb. Unsere Vision ist es, die Ergebnisse aus Leipzig und Landau so zu skalieren, dass sie als Blaupause für Städte und Kommunen jeder Größe dienen können. So leisten wir einen Beitrag zu einem nachhaltigen und intelligenten Mobilitätsmanagement in ganz Deutschland.

Welche innovativen Anwendungsfälle bietet AIAMO und welchen konkreten Nutzen können die Anwender daraus ziehen?

Markus Wartha: AIAMO bietet für Kommunen, kleinere Städte, Verkehrsbetriebe, Innovatoren sowie kleine und mittelständische Unternehmen (KMU) maßgeschneiderte Ansätze, die durch den Einsatz von künstlicher Intelligenz völlig neue Möglichkeiten eröffnen. Lassen Sie mich einige konkrete Anwendungsfälle für bestimmte Akteure nennen, um das Spektrum deutlich zu machen:

Für *Kommunen und kleinere Städte* sehen wir zentrale Anwendun-

gen für die dynamische Verkehrsflusssteuerung. KI-gestützte Analysen und Prognosen ermöglichen es, Staus zu reduzieren, Luftqualität zu verbessern und den Verkehrsfluss durch intelligente Ampelschaltungen zu optimieren. Zusätzlich bietet AIAMO Lösungen für die umweltsensitive Verkehrssteuerung, indem Umwelt- und Wetterdaten integriert werden. So können Städte Emissionshotspots erkennen und gezielt Maßnahmen wie Zufahrtsbeschränkungen oder umweltfreundliche Routenführung einleiten. Durch die Niederschwelligkeit und Bezahlbarkeit der Lösungen ist es auch für kleinere Städte mit begrenztem Budget möglich, diese Technologien ohne hohe Einstiegskosten und komplexe Implementierung zu nutzen. AIAMO bietet skalierbare, kostengünstige Anwendungen, die einfach an die spezifischen Bedürfnisse und Ressourcen der Kommunen angepasst werden können. Anbieter von Mikromobilitätsdiensten wie E-Scooter oder E-Bikes profitieren zudem von einer besseren Sichtbarkeit ihrer Angebote im vernetzten Mobilitätsökosystem.

Die *Verkehrsbetriebe* profitieren von einer Optimierung des ÖPNV, bei der Fahrpläne und Ressourcen dynamisch an den tatsächlichen Bedarf angepasst werden. Dies führt zu einer höheren Auslastung und effizienteren Betriebsabläufen. Die Plattform ermöglicht zudem die intermodale Verknüpfung verschiedener Verkehrsmittel – etwa die Integration von Carsharing- oder Fahrradverleihsystemen – und schafft so attraktive und nahtlose Mobilitätsangebote. Zusätzlich unterstützt AIAMO Incentive-Programme für eine höhere Nutzerbindung und hilft, die Servicequalität und Disposition durch ausreichende, vernetzte und verfügbare Mobilitätsangebote zu optimieren, sodass Nutzer stets passende Optionen vorfinden.

Kleinen und mittelständischen Unternehmen (KMU) bietet AIAMO trainierte Daten aus den Foundation Models, die sie für die Simulation von Verkehrsflüssen, die Entwicklung eigener Analyseapplikationen sowie von Next-Generation-Anwendungen oder neuen Geschäftsmodellen nutzen können.

Christian Roszak: Besonders innovativ ist dabei die technische Grundlage von AIAMO. Durch die offene Mesh-Architektur können Daten dezentral integriert werden, ohne dass die Akteure ihre Datenhoheit aufgeben müssen. Dies schafft eine einzigartige Flexibilität und Skalierbarkeit, um die Anforderungen der unterschiedlichen Zielgruppen zu erfüllen.

KI ist dabei ein zentraler und integrierter Bestandteil von AIAMO: Sie ermöglicht die Echtzeit-Analyse von Verkehrsströmen und Mobilitätsdaten, was zu präziseren Prognosen und einer optimierten Verkehrssteuerung führt. Diese KI-gestützten Lösungen tragen nicht nur zur Effizienzsteigerung bei, sondern auch zur Resilienz der Mobilität, indem sie schnelle Anpassungen an dynamische, sich verändernde Bedingungen ermöglichen.

Letztendlich profitieren alle Mobilitätsnutzer von einer verbesserten Datenqualität, präziseren Analysen und der Möglichkeit, Mobilität effizienter, effektiver, nachhaltiger und nutzerzentrierter zu gestalten. Als Schlüsselwerkzeug ermöglicht AIAMO die Entwicklung ganzheitlicher Mobilitätslösungen der nächsten Generation und macht Städte und Kommunen fit für die Mobilitätsanforderungen der Zukunft.

→ Weitere Informationen

ITS Germany e.V.
 Projektbüro AIAMO
 D-52064 Aachen
 E-Mail: info@aiamo.de
 Telefon: 0241 96072870
www.aiamo.de

Social Mobility als Erfolgsfaktor des Mobilitätswandels

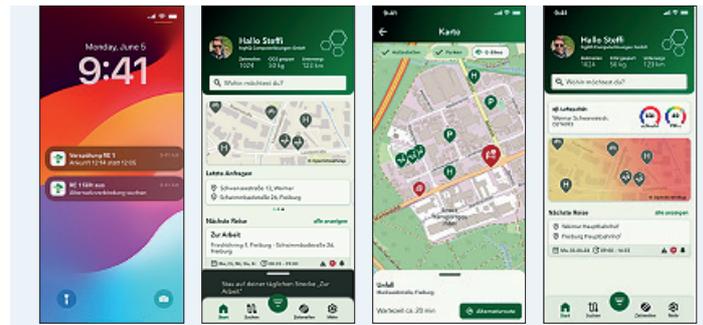
Das Freiburger Software-Unternehmen highQ gestaltet im Forschungsprojekt AIAMO KI-gestützte Mobilitätslösungen, die attraktive, gemeinwohlorientierte und umweltfreundliche Fortbewegungsmöglichkeiten für Verkehrsteilnehmer anreizen.

Der Mobilitätswandel erfordert innovative Ansätze, um städtische Herausforderungen wie Umweltbelastungen, Verkehrsstaus und soziale Ungleichheiten anzugehen. Künstliche Intelligenz (KI) spielt eine Schlüsselrolle, um Mobilitätsdaten zu integrieren und Entscheidungsprozesse zu optimieren. Das Forschungsprojekt AIAMO, unter der Leitung von ITS Germany e.V., entwickelt gemeinsam mit Partnern aus Wissenschaft und Praxis innovative Lösungen, die Verkehrsangebote effizient vernetzen und das Mobilitätsmanagement effektiver, sicherer und nachhaltiger machen. highQ trägt mit seiner Mobilitätsplattform highQ MobilitySuite und der zugehörigen mytraQ-App editionAIAMO mit der Umsetzung der Social Mobility in AIAMO entscheidend dazu bei, gemeinwohlorientierte und multimodale Mobilitätsangebote zu schaffen.

Social Mobility ermöglicht gemeinwohlorientierte Mobilität für alle

Social Mobility steht für die Entwicklung zukunftsfähiger Mobilitätslösungen, die Sicherheit, Nachhaltigkeit und das Gemeinwohl in den Fokus rücken. Zentral ist dabei die Förderung von Partizipation und Interaktion, um sozialen Austausch, Vernetzung und Kommunikation zwischen Verkehrsteilnehmern über die mytraQ-App editionAIAMO aktiv zu unterstützen. Eine durchgängige, intuitive End-to-End-Routenplanung über sämtlich zur Verfügung stehende Verkehrsmittel hinweg ermöglicht nahtlose und umweltfreundliche Mobilität von der ersten bis zur letzten Etappe – im Sinne eines ganzheitlichen Caring-Ansatzes. Der Caring-Gedanke geht dabei über das Sharing – also über die reine Mitnutzung – von Fahrzeugen oder Verkehrsmitteln hinaus: Er umfasst auch die Bereitstellung transparenter Echtzeitinformationen zu Verkehrslage, Wetterbedingungen, Verzögerungen oder alternativen Routen.

Die Mobilitätsplattform integriert Mobilitätsdaten unterschiedlicher Verkehrsträger wie ÖPNV, Sharing-Dienste und Fahrradverkehr nahtlos in verschiedene Anwendungen und ermöglicht so, attraktive Alternativen zum Auto bereitzustellen, die den Verkehrsteilnehmern einen echten Mehrwert bieten.



Verschiedene Darstellungsmodi der mytraQ-App editionAIAMO: (v. l. n. r.) Pushnachrichten, Anzeige Verkehrsstörung auf einer favorisierten Route, Anzeige Verkehrsunfall und Anzeige Luftqualität

Eine wesentliche Basis dabei ist die Nutzung von KI, um Verkehrsströme zu analysieren, vorherzusagen und zu steuern. Damit können Kapazitäten bedarfsgerecht angepasst, Verkehrsstaus vermieden und umweltfreundliche Optionen gezielt gefördert werden. Gleichzeitig hilft die MobilitySuite dabei, besonders schutzbedürftige Verkehrsteilnehmer wie Fußgänger oder Radfahrer durch sicherheitsrelevante Daten und personalisierte Routen besser zu leiten. KI-gesteuerte Routenvorschläge haben das Potenzial, die Mobilität zu revolutionieren. Die multimodale Mobilitätsplattform unterstützt KI-basiert dabei, die Schwarmmobilität einer Region zu optimieren: Sie motiviert durch ihr integriertes Anreizsystem „Zeitmeilen“, dass sich Menschen für nachhaltige Routenvorschläge entscheiden und und hilft so dabei, die Umweltziele von Städten und Kommunen zu erreichen.

Innovative Technologien für zukunftsweisende Mobilität

Darüber hinaus bildet AIAMO mit den involvierten Forschungs- und Entwicklungspartnern eine Plattform, um neue Technologien zu diskutieren und zu erforschen. Während des Projekts konnten Zukunftsszenarien entwickelt werden, wie die KI und insbesondere die Lösungen von highQ dabei unterstützen können, die Mobilitätsangebote weiter zu professionalisieren und zu optimieren.

So soll die Mobilitätsplattform zukünftig um neue Funktionalitäten, die auf den im AIAMONexus bereitgestellten KI-Daten aufsetzen, erweitert werden. Dazu gehören z. B. Dienste für die dynamische Anpassung von Fahrplänen, Ressourcen und auch Tarifmodelle, die die Auslastung von Verkehrsangeboten optimieren, indem sie Preise an Nachfrage und Umweltbedingungen anpassen. Managementlösungen für die intermodale Verknüpfung verschiedener Verkehrsmittel, wie die Integration von Carsharing- oder Fahrradverleihstationen, tragen dazu bei, die Attraktivität des Umweltverbunds zu steigern und individuelle Mobilitätsentscheidungen positiv zu beeinflussen.

Die Integration der patentierten Codegenerierungstechnologie der Generative Software GmbH (Entwicklungspartner von highQ) ermöglicht eine schnelle Anpassung an neue Standards wie „((etiCORE“. Dadurch werden Entwicklungszeiten verkürzt und die

Verfasser



Dr. Katharina Peine



Thomas Hornig

highQ Computerlösungen GmbH
D-79100 Freiburg
www.highq.de

Skalierbarkeit der Mobilitätsplattform deutlich erhöht. Diese Flexibilität macht es möglich, Mobilitätsdienste effizienter bereitzustellen und ihre Reichweite zu erweitern.

Katalysator des Mobilitätswandels

Der AIAMOnexus stellt eine leistungsstarke KI-Basis bereit, die aus einer hochperformanten Integrationszone für Mobilitäts- und Umweltdaten und spezialisierten Foundation Models besteht, die für innovative Anwendungen wie digitale Zwillinge und vorausschauende Mobilitätssteuerung genutzt werden. Die Integrationszone verknüpft die Mobilitäts- und Umweltdaten verschiedener Anbieter miteinander und ermöglicht eine sichere flexible und effiziente Nutzung, ohne dass zentrale Systeme zur Speicherung benötigt werden. KI-Tools werten die über die AIAMO Integrationszone in hoher Qualität aufbereiteten und bereitgestellten Daten aus und stellen diese Ergebnisse für mobilitätsspezifische Anwendungen wie die Vernetzung von Fahrzeugen und Infrastruktur, das Verkehrsmanagement sowie den Aufbau digitaler Zwillinge bereit. Solche virtuellen Abbilder von Verkehrssystemen in Städten oder Regionen helfen, Verkehrsflüsse zu simulieren und Optimierungsmaßnahmen in Echtzeit abzuleiten.

Die über die Integrationszone bereitgestellten Echtzeitdaten ermöglichen auch den Aufbau und die effiziente, benutzerfreundliche Gestaltung multimodaler Mobilitätslösungen, aus denen wiederum neu gewonnene Daten – z. B. zum Mobilitätsverhalten – anonymisiert und aggregiert wiederum über die Integrationszone anderen Anwendungen zur Verfügung gestellt werden können. Verfahren, wie sie der MDS oder Gaia-X, die rechtssichere Cloud-Infrastrukturen für den Datenverkehr innerhalb der EU gemäß Datenschutz-Grundverordnung (DSGVO) anstreben, anbieten, sorgen dabei für die Datensicherheit und unterstützen die Entwicklung neuer Dienste. Gleichzeitig erleichtert die standardisierte Infrastruktur den Zugang für kleine und mittlere Städte und Unternehmen, was die Innovationskraft des Mobilitätsmarkts stärkt.

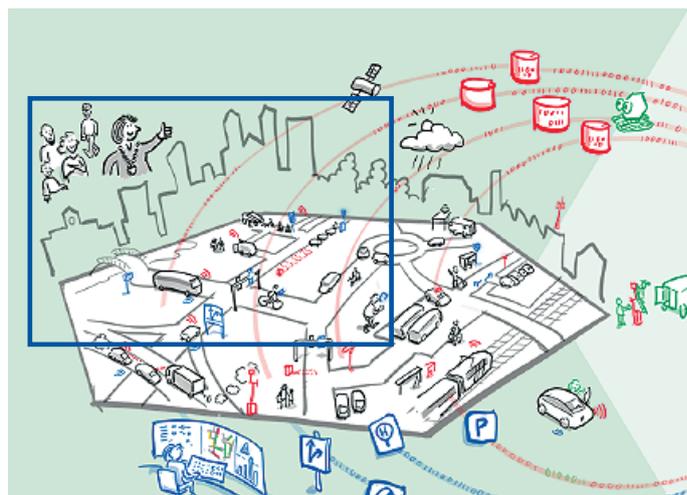
Fokus auf den Menschen: Inter- und multimodale, sichere Mobilität

Social Mobility stellt den Menschen in den Mittelpunkt. Die mytraQ-App editionAIAMO nutzt den AIAMOnexus und bietet Funktionen wie multimodale Routenplanung, Ticketing und Echtzeitfahrplan oder Umweltinformationen auf Basis der in AIAMO entstehenden digitalen Verkehrs- und Umweltzwillinge. Mithilfe von KI können diese Dienste personalisiert und an individuelle Bedürfnisse angepasst werden.

Die KI-basierte Erkennung des Mobilitätsverhaltens bildet die Grundlage für multimodale Routenempfehlungen. Datenschutzkonforme Verkehrsmittelerkennung erfolgt durch „unscharfe“ – also anonymisierte und aggregierte – Ortung und Analyse von Wegabschnitten zur Klassifikation nach Transportmodi.

Ziel ist, nachhaltiges Mobilitätsverhalten zu fördern und abrechnungsrelevante Daten für ÖPNV- und Sharing-Dienste automatisch zu erfassen. Dafür werden Messdaten der Smartphones (GPS, Beschleunigung, Geschwindigkeit) kombiniert mit öffentlich verfügbaren Haltestellen- und Linieninformationen. Die Mustererkennung nutzt Wahrscheinlichkeitsmodelle und einen loQate-Algorithmus nach dem ZEUS-Ansatz, um Sensordaten dem richtigen Verkehrsmittel zuzuordnen. GTFS-Daten helfen, zwischen privaten Fahrzeugen und öffentlichen Verkehrsmitteln zu unterscheiden. So wird die multimodale Route eines Nutzers präzise – und dennoch anonymisiert – rekonstruiert.

Die App ist als White-Label-Lösung adaptiv für Verkehrsbetriebe



Die mytraQ-App editionAIAMO fördert nachhaltiges Mobilitätsverhalten durch Incentivierung, erfasst abrechnungsrelevante Messdaten der Smartphones und kombiniert diese mit verfügbaren Haltestellen- und Linieninformationen

oder Städte personalisierbar, sodass die Verkehrsteilnehmer durch ein zum Kontext passendes Design abgeholt werden können.

Ein besonderes Augenmerk der Lösung liegt auf der Inklusion. Die App soll auf Grundlage KI-basierter Routen etwa barrierefreie Wege für Menschen mit besonderen Bedürfnissen, spezifische Informationen für ältere Verkehrsteilnehmer oder optimierte Optionen für Familien mit Kinderwagen bieten. Ziel ist es, Mobilitätsbarrieren abzubauen und allen Verkehrsteilnehmern einen einfachen Zugang zu nachhaltigen Alternativen zu ermöglichen.

Incentivierung als Anreiz nachhaltiger Mobilität

Ein wichtiger Bestandteil von Social Mobility ist zudem die Incentivierung nachhaltigen Mobilitätsverhaltens. Mit einem Bonus-system wird umweltfreundliches Verhalten belohnt: Mithilfe der App sammeln Verkehrsteilnehmer Punkte, wenn sie nachhaltige Verkehrsmittel nutzen oder alternative Routen bzw. Reisezeiten wählen, die die App ihnen vorschlägt. Gamification-Elemente wie Wettbewerbe oder Ranglisten, bei denen erworbene Punkte z. B. in neugepflanzte Bäume eingelöst werden können, motivieren die Nutzer, ihr Mobilitätsverhalten langfristig zu ändern. KI-Algorithmen analysieren dann das Verhalten, um personalisierte Anreize zu schaffen und die Effizienz der Maßnahmen zu steigern.

Ein Erfolgsmodell für die Zukunft

Der Mobilitätswandel ist eine zentrale Herausforderung für moderne Gesellschaften. Mit technologischen Innovationen, sozialer Verantwortung und einem klaren Fokus auf Nachhaltigkeit bietet AIAMO zusammen mit highQ und weiteren Partnern ein ganzheitliches Modell für die Mobilität der Zukunft. Die Weiterentwicklung und entstehende Vision der highQ MobilitySuite im Rahmen von AIAMO zeigt, wie Digitalisierung, KI und Gemeinwohl für einen erfolgreichen Mobilitätswandel kombiniert werden können, der allen Akteuren und der Umwelt zugutekommt und eine lebenswerte Zukunft für kommende Generationen sichert.

Gefördert durch:



aufgrund eines Beschlusses
des Deutschen Bundestages



Daten vernetzen, Mobilität neu denken

Die Mobilität der Zukunft erfordert nahtlose, ressourcenschonende und intelligente Verkehrs- und Mobilitätskonzepte. Trotz rasanter technologischer Entwicklungen ist die Realität hinter diesen Erwartungen zurück: Fragmentierte Datenlandschaften, fehlende Interoperabilität und technische Barrieren verhindern eine effiziente Nutzung der vorhandenen Mobilitätsdaten. Städte, Kommunen und Unternehmen stehen vor der Herausforderung, heterogene Datenquellen sinnvoll zu verknüpfen, um den Verkehr smarter zu steuern und nachhaltiger zu gestalten.

Der Einsatz Künstlicher Intelligenz (KI) ist entscheidend für die Weiterentwicklung und Optimierung urbaner Mobilität. Neue KI-gestützte Systeme können ihr volles Potenzial nur entfalten, wenn sie auf einer diversifizierten, umfassenden und qualitätsgesicherten Datenbasis operieren. Eine ausreichende Menge an validen Datensätzen ist essenziell, um präzise Muster zu identifizieren, zuverlässige Vorhersagen zu treffen und datenbasierte Entscheidungen zu ermöglichen.

Genau hier setzt das Forschungsprojekt AIAMO (Artificial Intelligence And Mobility) an, das vom Bundesministerium für Digitales und Verkehr (BMDV) mit rund 16,7 Mio. € gefördert wird. Das Ziel des Forschungsprojekts ist die Entwicklung eines KI-gestützten, inter- und multimodalen Mobilitäts- und Umweltmanagements, das Mobilität effizienter, nachhaltiger, sicherer und bedarfsgerechter gestaltet.

Alle Daten vereint in einem System

Um die Herausforderungen fragmentierter Mobilitätsdaten zu überwinden, bedarf es eines übergeordneten, skalierbaren und neutralen Systems: der Integrationszone. Diese fungiert als Schnittstelle, die unterschiedliche Systeme nahtlos miteinander verbindet und einen niederschweligen Zugang zu standardisierten Datenformaten sowie eine Anbindung vielfältiger Datenquellen und Datenräume ermöglicht. Durch die konsequente Nutzung standardisierter API-Schnittstellen werden Datenräume wie der Mobility Data Space (MDS) und die Mobilithek mit regionalen Quellen verknüpft – von Umweltdaten-Messstationen über Fahrzeugsensoren bis hin zu Wetterinformationen.

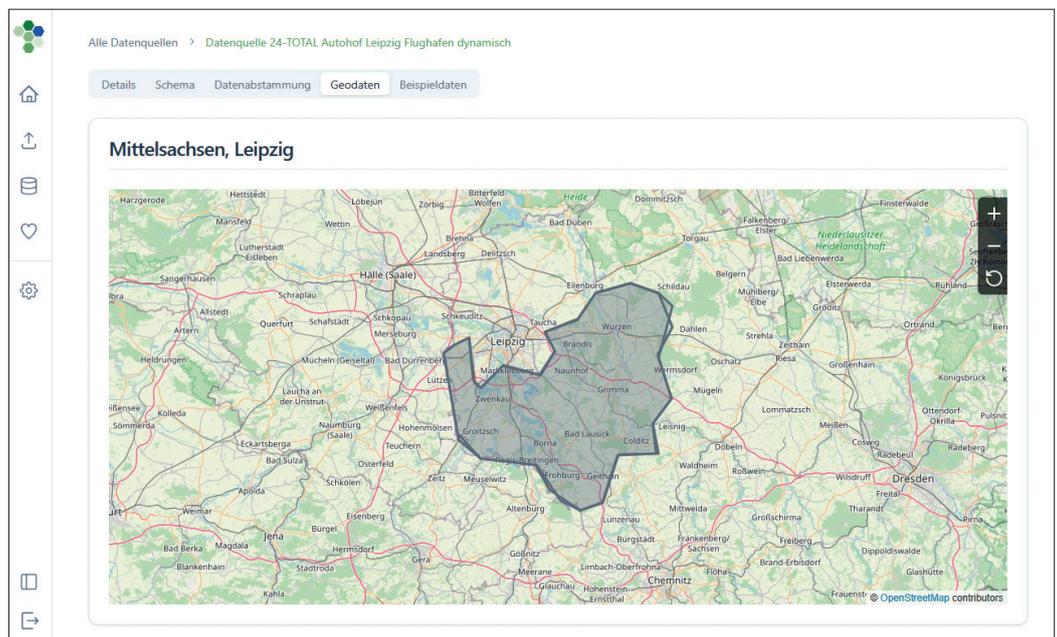
Dabei ist die Aktualität und Einhaltung von Qualitätsstandards essenziell für die zuverlässige Nutzung von Daten. Eine strukturierte Daten-Dokumentation mit Referenzcode und standardisierten Visualisierungen ermöglicht eine effiziente Datenverarbeitung und -analyse. Durch einheitliche Metadaten und Versionierung wird Transparenz und Konsistenz gewährleistet, wodurch eine präzise Nachverfolgbarkeit von Datenänderungen sichergestellt wird. Ergänzend dazu sorgen automatisierte Updates durch Push-/Pull-Mechanismen und



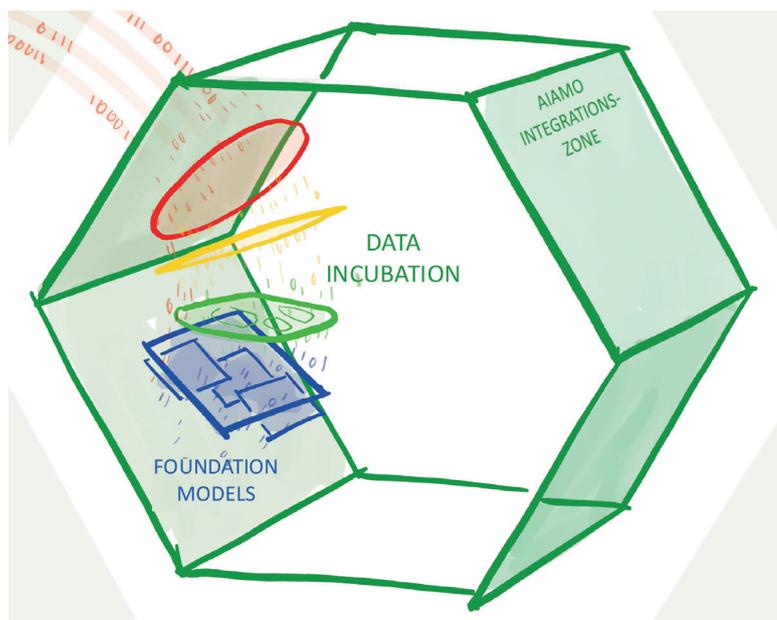
■ Verfasserin
Nicol Wiens
TEQYARD GmbH
D-38126 Braunschweig
www.teqyard.de

kontinuierliches Monitoring für stets aktuelle Datensätze.

Durch hochautomatisierte Aktualisierungen und standardisierte Versionierungen bleiben Daten dauerhaft konsistent und verlässlich – eine entscheidende Grundlage für den Einsatz in KI-Modellen und analytischen Prozessen. So werden reproduzierbare, transparente Ergebnisse gemäß höchster Qualitätsstandards sichergestellt. Diese umfassende Datenintegration schafft die Grundlage für den Einsatz leistungsfähiger KI-Modelle, die Verkehrs- und Umweltmanagement



Webbasierte Oberfläche der Integrationszone: Detailsansicht einer Geodatenquelle (Quelle: TEQYARD)



Die Integrationszone fungiert als Schnittstelle, die Daten, Technologien und Anwendungen nahtlos verknüpft und somit eine einheitliche, interoperable Umgebung schafft

in bisher unerreichter Qualität optimieren können.

Dafür wird der AIAMOnexus entwickelt, der das zentrale Element dieser datengetriebenen Mobilitätslösung bildet. Er setzt sich aus zwei Hauptkomponenten zusammen: der Integrationszone und den AI Foundation Models.

Die Integrationszone fungiert als Schnittstelle, die Daten, Technologien und Anwendungen nahtlos verknüpft und somit eine einheitliche, interoperable Umgebung schafft. Ergänzt wird sie durch leistungsfähige Foundation Models, die als leistungsstarke KI-Basis allgemeine und spezialisierte Modelle für die Verkehrs- und Umweltsteuerung bereitstellen. Durch die Kombination dieser beiden Komponenten entsteht eine intelligente und skalierbare Infrastruktur, die Mobilitätsnutzern eine nahtlose, effiziente und personalisierte Mobilität ermöglicht.

KI-gesteuerte Suche nach Mobilitätsdaten

Ein konkretes Anwendungsbeispiel für die AIAMO Integrationszone ist die Optimierung des städtischen Verkehrsflusses. Über eine webbasierte Oberfläche können kommunale Mobilitätsverantwortliche einfach auf die Integrationszone zugreifen. Dort unterstützt sie eine KI-basierte Suchfunktion, die speziell darauf ausgelegt ist, sie effizient durch das umfangreiche Netzwerk von Datenquellen zu navigieren. Eine beispielhafte Anfrage könnte lauten: „Welche Spitzenzeiten des Fahrradverkehrs in der Innenstadt gab es im letzten Quartal?“ Der KI-gestützte Suchalgorithmus verarbeitet die Anfrage und nutzt fortschrittliche Methoden der natürlichen Sprachverarbeitung, um die verteilten Daten im System schnell und präzise zu durchsuchen. Innerhalb von Sekunden erhält der Nutzer eine Liste relevanter Datenquellen, darunter Informationen von lokalen Fahrradverleihunternehmen, Sensordaten zu Fahrradwegen oder aggregierte Ergebnisse aus Nutzerbefragungen.

Strukturierte Datenverwaltung für hohe Effizienz

Die leichte Auffindbarkeit geeigneter Daten spielt eine entscheidende Rolle für eine effiziente Datenakquise. Ein umfassender Metadatenkatalog indexiert sämtliche Datenquellen und erleichtert so die strukturierte Verwaltung und den schnellen Zugriff. Ergänzend

dazu sorgt eine intelligente Suche mit Tags, Filtern und Kategorien für eine gezielte und präzise Datenrecherche. Durch diese optimierten Identifikations- und Zugriffsmechanismen wird eine hohe funktionale Exzellenz erreicht, die es ermöglicht, kontextrelevante Informationsressourcen schneller zu finden und effektiv zu nutzen. Zusätzlich hilft eine farbkodierte Darstellung der Verarbeitungsstufen dabei, die Qualität und den Reifegrad der Daten auf einen Blick zu erfassen:

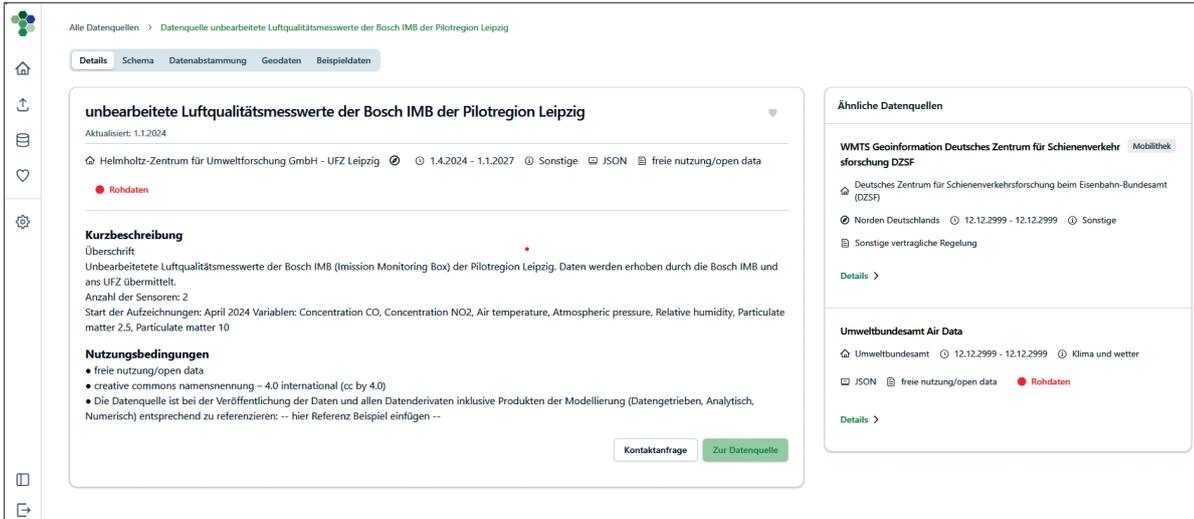
- Rot markierte Daten sind Rohdaten, die noch unbearbeitet vorliegen.
- Gelb kennzeichnet bereits bereinigte und qualitätsgeprüfte Datensätze.
- Grün steht für veredelte Daten, die sich besonders für KI-Trainingszwecke eignen.
- Blau weist Ergebnisdaten aus, die bereits durch ein KI-Modell verarbeitet wurden und direkt für Anwendungen genutzt werden können.

Ein konkreter Anwendungsfall im Mobilitätsalltag verdeutlicht den Nutzen dieses Systems:

Ein städtischer Verkehrsbetrieb möchte den Verkehrsfluss optimieren und Stauprognosen verbessern. Dafür werden verschiedene Sensordaten von Straßen, Ampelanlagen und Fahrzeugen erfasst. Die erhobenen Rohdaten (rot) enthalten bspw. ungenaue GPS-Positionen, fehlerhafte Sensorwerte oder unvollständige Datensätze. Durch eine erste Bereinigung und Qualitätsprüfung entstehen gelb markierte Daten, bei denen bspw. doppelte oder unplausible Werte entfernt wurden. Anschließend werden die bereinigten Daten durch spezielle Algorithmen weiterverarbeitet, um aussagekräftige Muster zu extrahieren – etwa wiederkehrende Stauzeiten oder Engstellen. Diese veredelten Daten (grün) sind besonders wertvoll für das Training eines KI-gestützten Verkehrsprognosemodells. Sobald das KI-Modell trainiert ist und in Echtzeit Prognosen erstellt, werden die aus den KI-Daten generierten Stauvorhersagen als blaue Ergebnisdaten gekennzeichnet. Diese können dann direkt in Navigationssysteme, Anwendungen in Verkehrsleitzentralen oder Mobilitäts-Apps integriert werden, um Autofahrer und Verkehrsplaner frühzeitig über Engpässe zu informieren und Alternativrouten vorzuschlagen.

Dank der strukturierten Verwaltung und farbkodierten Klassifizierung der Daten profitieren Nutzer von einer schnelleren und gezielteren Informationssuche, da relevante Datensätze leicht auffindbar sind. Die klare Unterscheidung zwischen Rohdaten sowie bereinigten, veredelten und KI-generierten Daten sorgt für höhere Transparenz und Verlässlichkeit, da sofort erkennbar ist, welche Daten geprüft und einsetzbar sind. Dies ermöglicht fundiertere Entscheidungen, insbesondere in Echtzeit-Anwendungen wie Navigation oder Verkehrssteuerung, wo präzise Prognosen helfen, Staus zu vermeiden. Behörden und Unternehmen sparen zudem Zeit und Ressourcen, da sie direkt auf qualitativ hochwertige Daten zugreifen können, ohne diese erst aufwendig aufbereiten zu müssen. So führt die optimierte Datenverwaltung insgesamt zu effizienteren Prozessen, leistungsfähigeren KI-gestützten Systemen und einer verbesserten Nutzererfahrung in datenintensiven Bereichen wie Mobilität und Stadtplanung.

Für eine sichere und effiziente Nutzung der Daten sind eine einfache Lizenzierung und Abrechenbarkeit zentrale Faktoren. Unternehmen und Entwickler benötigen klare Rahmenbedingungen, um Daten rechtssicher zu nutzen und gleichzeitig faire, flexible Kostenmodelle zu gewährleisten. Eine eindeutige Lizenzierung – von Open Data



Detailsansicht einer Datenquelle zu Luftqualitätsmesswerten (Quelle: TEQYARD)

Lizenzen bis hin zu kommerziellen Modellen – würde sicherstellen, dass Daten entsprechend rechtlicher und wirtschaftlicher Anforderungen genutzt werden können. Ergänzend ermöglicht eine transparente Abrechenbarkeit flexible Kostenstrukturen – etwa durch Pay-per-Use, Abonnements oder transaktionsbasierte Modelle. Automatisierte Monitoring- und Abrechnungssysteme können dann gewährleisten, dass Nutzer nur für die tatsächlich verwendeten Daten zahlen, während Anbieter eine nachhaltige Monetarisierung realisieren. So entsteht eine verlässliche Grundlage für datengetriebene Innovationen und wirtschaftliche Skalierbarkeit.

Navigieren in der Datenflut

Während klare Lizenzierungs- und Abrechnungsmodelle die Grundlage für eine rechtssichere und wirtschaftliche Datennutzung schaffen, stellt sich die Frage, wie Daten in einer zunehmend komplexen digitalen Welt effizient verwaltet werden können. Das Konzept des Data Mesh bietet eine innovative Lösung: Es organisiert die Verantwortung für Daten und stellt deren Qualität direkt an ihrem Ursprung sicher. Dieser Ansatz ermöglicht eine flexible, effiziente und sichere Nutzung von Daten in Echtzeit, ohne zentrale Systeme zu benötigen.

Die dezentrale Speicherung der Daten bringt zahlreiche Vorteile:

- Agilität & Innovation: Unternehmen können schneller auf Veränderungen reagieren und Daten gezielt für spezifische Anwendungen optimieren.
- Skalierbarkeit und Leistung: Die Infrastruktur wächst flexibel mit den steigenden Datenmengen und optimiert gleichzeitig die Performance.
- Resilienz & Sicherheit: Die verteilte Datenhaltung erhöht die Ausfallsicherheit und minimiert zentrale Abhängigkeitsrisiken.
- Datenschutz & Compliance: Daten verbleiben an ihrem Ursprungsort, was das Risiko von Datenschutzverstößen reduziert und die Einhaltung regulatorischer Vorgaben erleichtert.

Ein entscheidender Faktor für die erfolgreiche Nutzung dieser Daten ist der Einsatz von KI. Externe KI-Tools können die über die Integrationszone verfügbaren Daten analysieren und stellen die Ergebnisse für mobilitätsspezifische Anwendungen und Dienste bereit, darunter die Vernetzung von Fahrzeugen und Infrastruktur sowie das Verkehrsmanagement.

Gleichzeitig werden durch KI die Datenqualität gesichert, Muster erkannt und Trends analysiert. Neutrale Schnittstellen stellen die

Anschlussfähigkeit an weitere Dienste sicher, wodurch sich Innovationen schneller umsetzen lassen. So wird eine datenbasierte Entscheidungsgrundlage geschaffen, die Mobilitätslösungen auf ein neues Niveau hebt.

Die Integrationszone setzt diesen Ansatz konsequent um, indem sie Mobilitätsdaten verschiedener Akteure in einem sicheren und interoperablen Rahmen orchestriert. Sie integriert dezentrale Datenquellen, wahrt die Kontrolle der Datenbesitzer und fördert den nahtlosen Austausch von Informationen. So entsteht ein konsistentes und skalierbares Datenökosystem, das Innovationen vorantreibt und Datenschutz sowie Compliance sicherstellt. Durch standardisierte Schnittstellen und Prozesse können Mobilitätsdaten effizient genutzt werden, um nachhaltige und zukunftsfähige Mobilitätslösungen im urbanen Raum zu gestalten.

Ist die intelligente Mobilitätssteuerung eher Vision oder Fiktion?

Die Diskrepanz zwischen der Vision intelligenter Verkehrssysteme und der fragmentierten Realität der Mobilitätsdaten ist nach wie vor groß. Doch durch die Kombination des Data-Mesh-Ansatzes mit KI-gestützten Such- und Analysemethoden eröffnet sich ein vielversprechender Weg, diese Lücke zu schließen.

Der AIAMONexus schafft mit der Integrationszone und den AI Foundation Models die Grundlage für ein vernetztes, effizientes und nutzerzentriertes Mobilitätsökosystem. Er ermöglicht einen sicheren und dezentralen Datenaustausch, gewährleistet Datenschutzkonformität und vereinfacht den Zugriff auf relevante Mobilitätsdaten. Städte und Kommunen profitieren von einer intelligenten Verkehrssteuerung, die nicht nur den Verkehrsfluss optimiert, sondern auch nachhaltige, datenbasierte Mobilitätslösungen fördert und das urbane Leben nachhaltig verbessert.

Die Zukunft der Mobilität liegt in der intelligenten Vernetzung und Nutzung von Daten – und mit AIAMO rückt die Vision einer smarten, nachhaltigen und nahtlos integrierten Mobilitätslandschaft ein großes Stück näher.

Gefördert durch:



aufgrund eines Beschlusses des Deutschen Bundestages

Generative KI: Vom technologischen Paradigmenwechsel zur Vision einer neuen Ära im Straßenverkehr

Generative Künstliche Intelligenz (KI) geht bereits mit enormen Effizienzsteigerungen für Domänen einher, die von Kreativität profitieren. Die Fähigkeit, beliebig viele realitätsnahe Daten zu synthetisieren, bietet jedoch auch neue Potenziale für Anwendungen, die bisher aufgrund fehlender Datenmengen noch nicht den Sprung in die Praxis überwunden haben. Im Straßenverkehr betrifft dies z. B. das autonome Fahren in herausfordernden Situationen. Um neue Anwendungspotenziale zu erschließen, ist es allerdings erforderlich, die grundlegende Funktionsweise der Technologie gepaart mit ihren Chancen und Herausforderungen zu verstehen. Dieser Fachbeitrag dient deshalb als erste Einführung in die generative KI, indem er einen Überblick über zentrale Modelle, ihre grundlegenden Ideen und Funktionsweisen gibt. Darauf basierend werden typische Problemarten aufgezeigt, die mit generativer KI neu betrachtet und besser gelöst werden können – allgemein und spezifisch für den Straßenverkehr. Unter gleichzeitiger Betrachtung derzeitiger Limitierungen dient der Beitrag als Entscheidungshilfe für die Selektion passender generativer oder klassischer KI-Verfahren.

Generative artificial intelligence (AI) is associated with enormous increases in efficiency for domains that benefit from creativity. However, the ability to synthesize any amount of realistic data also offers new potential for applications that have not yet made the leap into practice due to a lack of data. In road traffic, for example, this applies to autonomous driving in challenging situations. However, in order to unlock new application potential, it is necessary to understand the basic functioning of the technology coupled with its opportunities and challenges. This article therefore serves as a gentle introduction to generative AI by providing an overview of central models, their fundamental ideas and function. Based on this, we present typical problem types that can be revisited and profit from generative AI – in general and specifically for road traffic. While at the same time considering current limitations, the article serves as a decision support for the selection of suitable generative or classic AI methods.

doi.org/10.53184/SVT4-2025-2

1 Einleitung

Generative Künstliche Intelligenz (Generative AI, Gen AI) ist ein transformatives Paradigma des maschinellen Lernens, das mit seinen Fähigkeiten zur Synthetisierung realistischer [16] neuer Daten viele Branchen revolutioniert. Im Gegensatz zu traditionellen maschinellen Lernverfahren, die versuchen, bekannte Ausgaben bestmöglich auf Basis der Eingaben zu erklären und diese Erklärungen zu generalisieren, um für neue Eingabedaten Vorhersagen mit möglichst geringem Fehler zu tätigen [35], zielen generative Verfahren darauf ab, bewusst Varianz in den Ausgabedaten zu erzeugen, um Kreativität zu imitieren. Die zentrale konzeptuelle Idee hinter generativen Modellen ist es dabei, aus latenten Datenrepräsentationen Datenpunkte zu erzeugen [16], die in ihrer Verteilung der Verteilung der Eingangsdatenpunkte, mit denen ein Modell trainiert wurde, entsprechen [3].

Besonders prominente Erfolge von generativen Modellen zeigen sich derzeit vor allem in der Text-zu-Text-, Bild-zu-Bild-, Audio- und Videosynthese [1, 3]. Schlüsselmodelle wie der

Generative Pre-trained Transformer (GPT), DALL-E und Sora sowie diverse Open-Weight-Alternativen wie Llama und DeepSeek führen gerade in Bereichen wie Kommunikation und Marketing zu enormen Effizienzsteigerungen [15]. Die Generierung neuer chemischer Verbindungen zeigt zudem große Erfolge bei der Beschleunigung und gleichzeitigen Optimierung von Stoffeigenschaften im Material- [20] und Arzneimitteldesign [10].

Um die vielen darüber hinausgehenden, oft noch verborgenen Anwendungspotenziale aufzudecken, gibt dieser Fachbeitrag Einblicke in die grundlegenden Konzepte, das Training und die Evaluation generativer Modelle. Dazu wird die Evolution von Generativer KI von den ersten Anfängen mit Variational Autoencoders [17] und Generative Adversarial Networks [12] bis zu aktuellen State-of-the-Art-Modellen überblickend dargestellt, um eine Einschätzung der aktuellen Fähigkeiten generativer KI und ihrer Bedeutung für maschinelles Lernen zu ermöglichen.

Anschließend werden Potenziale und Herausforderungen erläutert, die bei der Adaption der Technologie und der Konzeption zukünftiger Lösungen berücksichtigt werden sollten.

Ein besonderer Fokus liegt dabei auf international erforschten Anwendungen, welche die Straßenverkehrstechnik fundamental verändern und verbessern können. Insbesondere die Möglichkeit zur Erzeugung großer und diverser Mengen synthetischer Daten für seltene Ereignisse wie Unfälle können den entscheidenden Impuls liefern, um Anwendungen des klassischen maschinellen Lernens voranzutreiben, die bisher aufgrund zu geringer Datenmengen scheitern. Die abschließende Diskussion betrachtet zusammenfassend die Vorzüge generativer und klassischer KI nach Anwendungsfällen.

■ Verfasser

Nicole Höß

nicole.hoess@oth-regensburg.de

Prof. Dr. Wolfgang Mauerer

wolfgang.mauerer@oth-regensburg.de

Regensburg Center for Artificial Intelligence
Fakultät Informatik und Mathematik
Ostbayerische Technische Hochschule
Regensburg
Galgenbergstraße 32
93053 Regensburg

2 Generative Künstliche Intelligenz

2.1 Variational Autoencoder

Einen wichtigen Durchbruch bei der Generierung neuartiger Datenpunkte erreichte 2013 der *Variational Autoencoder (VAE)* von Kingma et al. [17]. Traditionelle Autoencoder lernen anhand von gegebenen Input-Daten, wichtige Eigenschaften bestmöglich zu extrahieren und kompakt als latente Repräsentationen zu codieren. Dazu nutzen Autoencoder zwei Teilnetze, einen Encoder und einen Decoder. Der Encoder ist dafür zuständig, die beobachteten Datenpunkte in sinnvolle latente Variablen zu überführen, indem er über ein Bottleneck die Eingabedaten komprimiert. Der Decoder versucht dann, aus diesen latenten Repräsentationen die originalen Daten zu rekonstruieren [37]. Bei der Optimierung des Netzes wird der Fehler dieser Rekonstruktion minimiert, um möglichst effiziente Repräsentationen der Daten zu lernen [26].

Der latente Raum ist bei klassischen Autoencodern allerdings nicht unbedingt strukturiert, sodass die Ähnlichkeit latenter Repräsentation nicht zwangsläufig auch eine Ähnlichkeit der echten Datenpunkte impliziert. Der VAE codiert die latenten Variablen hingegen nicht als einzelne diskrete Werte, von denen jeweils nur eine bestimmte Ausgabe abgeleitet werden kann, sondern als kontinuierliche Reihe an Wahrscheinlichkeiten einer Wahrscheinlichkeitsverteilung, von der viele weitere Variationen als neue Datenpunkte gesampelt werden können [26].

2.2 Generative Adversarial Network

Das wegweisende Konzept des *Generative Adversarial Network (GAN)* wurde 2014 von Goodfellow et al. vorgestellt. Dabei nehmen zwei verschiedene neuronale Netze die Rolle von Gegenspielern ein und werden parallel trainiert. Während das erste Modell die Verteilung der Trainingsdaten bestmöglich lernt, um gefälschte Datenpunkte zu generieren (*Generator*), lernt das zweite Modell, den Betrug zu erkennen, indem es die Wahrscheinlichkeit schätzt, dass ein bestimmter Datenpunkt aus der echten Verteilung stammt (*Diskriminator*). Im Laufe des Trainingsprozesses verbessert der Diskriminator seine Fähigkeiten zur Klassifikation, während der Generator seine Strategie zur Anpassung an die echten Daten verbessert, um den Diskriminator von der Echtheit der generierten Datenpunkte zu überzeugen. Ziel dieser Mi-

nimax-Optimierung ist es, ein Nash-Gleichgewicht herzustellen, bei dem beide Netze ihre jeweils optimale Strategie erlernt haben, die es sich nicht mehr anzupassen lohnt [12].

Die beschriebenen Architekturen sind allerdings noch nicht in der Lage, Datenpunkte mit bestimmten gesuchten Eigenschaften zu generieren. Dazu müssten wiederholt neue Datenpunkte gesampelt werden, bis einer davon das gewünschte Kriterium erfüllt. Die Erweiterungen von VAEs und GANs zu *Conditional VAEs (C-VAEs)* bzw. *GANs (C-GANs)* lösen dieses Problem, indem sie die zu erfüllende Bedingung als zusätzlichen Eingabeparameter für die neuronalen Netze aufnehmen [12, 26]. VAEs und GANs können außerdem zu neuen Architekturen kombiniert werden, indem z. B. im *Adversarial Autoencoder* der VAE die Rolle des Generators einnimmt [37].

2.3 Transformer

Einen weiteren wichtigen Beitrag zu modernen generativen Verfahren leistete die *Transformer*-Netzarchitektur, die 2017 von Vaswani et al. vorgestellt wurde [33]. Essenzieller Bestandteil ist ein *Attention*-Mechanismus, der von der selektiven menschlichen Wahrnehmung inspiriert wurde [31]. Attention ermöglicht es dem neuronalen Netz, wichtige Positionen in Ein- oder Ausgabe-Sequenzen zu identifizieren und ihre Abhängigkeiten zu verstehen, um eine geeignete Repräsentation der Sequenz zu berechnen. Während sich frühere Attention-Mechanismen jeweils auf eine einzelne Repräsentation fokussierten, ermöglicht es die *Multi-Headed-Attention* im Transformer, mehrere unterschiedliche Repräsentationen gleichzeitig zu analysieren, um komplexere Zusammenhänge zu lernen. Dies resultiert nicht nur in einer besseren Ergebnisqualität, sondern kann durch die erweiterten Parallelisierungsmöglichkeiten im Vergleich zu früheren Architekturen auch die Trainingszeit verkürzen [33].

Viele der aktuell bekannten großen Sprachmodelle wie BERT oder GPT basieren auf Transformer-Architekturen und kombinieren diese mit *Pre-Training*, um noch universellere Repräsentationen der Daten zu lernen, die durch *Fine-Tuning* an eine Vielzahl von Anwendungsfällen angepasst werden können [29]. *Bidirectional Encoder Representations from Transformers (BERT)* wurde z. B. für die Aufgaben vortrainiert, zufällig maskierte Wörter eines Satzes anhand ihres vorherigen und nachfolgenden Kontexts

vorherzusagen und zu klassifizieren, ob es sich bei einer Eingabesequenz von zwei Sätzen um aufeinanderfolgende Sätze handelt [7]. Ziel des Pre-Trainings des *Generative Pre-Trained Transformer (GPT)* war es hingegen, die nächste Texteinheit (*Token*) auf Basis einer vorausgehenden Sequenz vorherzusagen [25]. Da sich die jeweils erwarteten Eingaben und Ausgaben der Modelle direkt aus dem vorliegenden Gesamtdokument ergeben, ist kein vorheriges Labelling der enorm umfangreichen Textdatenbasis durch Menschen erforderlich. GPT-4 wurde allerdings mit Reinforcement Learning auf Basis von menschlichen Bewertungen verbessert, um die Ausgabertexte nach den Präferenzen der Menschen zu optimieren [25].

Die Fortschritte in der Sprachverarbeitung legten nahe, auch für andere Datenarten universelle Repräsentationen zu lernen. Beispielsweise betrachtet der *Vision Transformer (ViT)* Bilder nach einem ähnlichen Prinzip als Sequenz von Bildabschnitten, um die Bildklassifikation zu verbessern [8]. Der ViT kommt gemeinsam mit einem Text-Transformer im *Contrastive Language-Image Pre-Training (CLIP)* zum Einsatz, um die Übereinstimmung von Texten und Bildern zu bewerten [28]. Die resultierenden Repräsentationen sind essenzieller Teil des Bildgenerierungsmodells DALL-E, welches mit einem Transformer CLIP-Repräsentationen aus Bildunterschriften lernt und als Decoder Diffusionsmodelle nutzt, um neue Bilder auszugeben [2, 30]. Ein Diffusionsmodell ist dabei eine parametrisierte Markov-Kette, die den umgekehrten Diffusionsprozess, entsprechend der schrittweisen Entfernung von Störsignalen aus einem völlig verrauschten Bild, abbildet [14]. Generative Modelle bestehen somit oft aus einer Vielzahl unterschiedlicher KI-Modelle, die auf intelligente Weise verknüpft werden.

2.4 Generatives Reinforcement Learning

Ein weiterer Trend ist die Verknüpfung von generativer KI mit Reinforcement Learning. Neben der Nutzung von menschlichem Feedback zur Optimierung generierter Ausgaben [25] kann umgekehrt auch generative KI den Lernprozess von Agentensystemen verbessern. Deep Q-Networks sind z. B. dazu geeignet, aus hochdimensionalen Zustands- und Aktionsräumen passende Strategien zu lernen, indem sie die Belohnungsfunktion approximieren und nicht wie klassische Algorithmen deterministisch bestimmen.

Das Training solcher Netze zur Konvergenz gegen die optimale Strategie kann sich jedoch sehr langwierig gestalten, insbesondere, wenn die Räume dünn besiedelt sind. Auch lassen sich die Strategien oft nicht unmittelbar auf neue oder veränderte Aufgaben und Umgebungen übertragen, sodass das Training wiederholt werden muss. VAEs können in diesem Fall helfen, die Dimensionalität der Zustände und Aktionen zu reduzieren, um die Komplexität zu reduzieren und so das Training zu beschleunigen. GANs bieten zudem die Möglichkeit, generalisierte Daten aus den Erfahrungen spezifischer Agenten zu generieren. Diese können Agenten anderer Umgebungen über den Replay Buffer als Erfahrung mitgegeben werden [32].

Ansätze wie das *Generative Adversarial Imitation Learning (GAIL)* adressieren außerdem das Szenario, in dem nur Verhaltensmuster (Zustand-Aktions-Paare) eines Experten bekannt sind und kein Feedback zur eigenen Strategie aus der Umgebung erhalten werden kann. In diesem Fall kann der Diskriminator eines GANs ein Bestärkungssignal erzeugen, indem er die Strategie eines Reinforcement-Learning-Algorithmus mit der Strategie des echten Experten vergleicht. Kann der Diskriminator nicht mehr zwischen beiden unterscheiden, hat der Agent die optimale Strategie gelernt [13].

3 Potenziale und Herausforderungen

Neben den großen Effizienzsteigerungen und Automatisierungsmöglichkeiten für Domänen mit sehr umfangreichen verfügbaren Datenmengen bietet generative KI auch für Anwendungsfälle, die bisher aufgrund zu geringer Datenmengen scheiterten, gänzlich neue Perspektiven. Neben der Rekonstruktion beschädigter und fehlender Daten [23] kann auch die Ergänzung echter um synthetische Daten (*Datenaugmentierung*) entscheidende Zusatzinformationen für Machine-Learning-Algorithmen liefern, um ihre Generalisierungsfähigkeit zu verbessern [32].

Gerade im Straßenverkehr fehlen beispielsweise im Kontext des autonomen Fahrens oft Daten seltener und herausfordernder Szenarien, die praktisch nicht in ausreichender Menge erfasst werden können [18]. In diesem Fall haben generierte Datenpunkte das Potenzial, realitätsnah fehlende Erfahrungen zu kompensieren. Dies kann auch

die Verzerrung (*Bias*) der Trainingsdaten reduzieren, die z. B. aufgrund der Häufung eines bestimmten Szenarios in der Überanpassung an dessen Gegebenheiten resultiert. So können z. B. auch Daten, die in einem bestimmten Gebiet erfolgreich und in großen Mengen erfasst wurden, mit generativen Methoden abstrahiert und in anderen Gebieten mit wenig vorliegenden Daten eingesetzt werden [9].

Noch einen Schritt weiter gehen Basismodelle (*Foundation Models*), die auf sehr großen vorhandenen Datenmengen, z. B. multimodalen Verkehrsdaten wie Sensor- und GPS-Informationen, trainiert wurden, um durch geeignete Repräsentationen eine Vielzahl konkreter Anwendungen zu ermöglichen. Foundation Models bieten damit das Potenzial, die operationale Effektivität und Effizienz von KI-Anwendungen im Straßenverkehr zu steigern, indem sie die Flexibilität und Adaptierbarkeit von Modellen an den sich stets verändernden urbanen Raum verbessern [21].

Dazu müssen allerdings bestimmte Qualitätskriterien erfüllt sein. Die *Neuheit* der Datenpunkte soll z. B. sicherstellen, dass es sich bei generierten Datenpunkten um neuartige Beobachtungen handelt, die im Sinne der Privatheit keine Informationen über die Originaldaten preisgeben. Gleichzeitig müssen die synthetischen Daten jedoch auch *repräsentativ* sein und die statistischen Eigenschaften der ursprünglichen Daten korrekt erfassen. Die *Kohärenz* sequenzieller Daten sowie die *Diversität* in Bezug auf die Anzahl ableitbarer Datenpunkte sind weitere wünschenswerte Merkmale. Da sich die Qualitätsmaße teils widersprechen, müssen sie je nach Anwendungsfall unterschiedlich stark gewichtet werden. Dieser Trade-Off stellt eine Herausforderung für die Evaluation und Optimierung von generativen KI-Verfahren dar [9].

Eine weitere Herausforderung ergibt sich aufgrund der hohen Rechenkomplexität der Verfahren. Um eine exzellente Repräsentation großer Datenmengen zu lernen, haben z. B. transformerbasierte Verfahren mit Milliarden einzustellender Parameter eine sehr hohe Rechenkomplexität [31]. Beispielsweise benötigte ein Experiment im Rahmen des CLIP-Trainings 18 Tage Rechenzeit auf einem Rechencluster mit 592 Hochleistungsgrafikkarten [28]. Neueste Modelle tendieren zu noch mehr Parametern. Doch auch die Nutzung der trainierten Modelle zur Inferenz bringt einen hohen

Energieverbrauch mit sich, der täglich weltweit den Bedarf mehrerer 100.000-Einwohner-Städte erreicht [24] und im starken Konflikt zum Wunsch nach mehr Nachhaltigkeit steht. Auch wenn anzunehmen ist, dass sich der Energieverbrauch durch algorithmische Fortschritte im Laufe der Zeit reduzieren kann [4], ist aufgrund der gleichzeitig fortlaufend neu hinzukommenden Anwendungsfälle davon auszugehen, dass der Energiebedarf durch generative KI in den nächsten Jahren weiter steigen wird. Um dem entgegenzuwirken, beschäftigen sich aktuelle Forschungsrichtungen nicht nur mit reinen Software- und Hardwareverbesserungen, sondern auch mit deren gemeinsamem Co-Design [24].

Die hohe Modellkomplexität generativer KI geht jedoch nicht nur mit hohen Rechenbedarfen, sondern auch mit *Halluzinationen* und einer reduzierten *Erklärbarkeit* einher. Da generative Modelle Variationen einer latenten Verteilung erzeugen, ist es trotz Optimierung entsprechender Qualitätsmetriken möglich, dass auch Varianten generiert werden, die in der Realität nicht vorkommen könnten. Bei Sprachmodellen äußert sich Halluzination beispielsweise in Fehlinformationen, die aufgrund der guten Formulierung realistisch wirken. Auch bei anderen Datenarten kann die Validität nicht direkt bewertet werden. Es wäre deshalb umso wichtiger, das Zustandekommen einer bestimmten Ausgabe des Modells nachvollziehen zu können [1]. Bei klassischen maschinellen Lernverfahren wie linearer Regression und Entscheidungsbäumen ist direkt ersichtlich, welchen Einfluss eine bestimmte Eingabegröße bzw. deren Ausprägung auf das Ergebnis hat. Komplexe generative Anwendungsfälle können jedoch mit solchen Methoden nicht ausreichend performant bewältigt werden. Methoden, die mathematisch erklären, inwieweit eine bestimmte Eingabe- oder latente Variable, eine Schicht oder ein Neuron eines Transformers zum Ergebnis des Modells beigetragen hat, sind daher ein aktueller Forschungsgegenstand [1]. Über die Erklärbarkeit hinausgehend verfolgt das LLM *DeepSeek* den Ansatz, logische Schlussfolgerungen (*Reasoning*) eines Modells durch Reinforcement Learning entsprechend der angewandten Strategie abzubilden [6].

Neben der Halluzination kann es auch vorkommen, dass aufgrund der Vielzahl wünschenswerter Optimierungskriterien trotz Neuheitsanforderung sensible Daten preisgegeben werden, mit denen ein Modell ei-

gentlich zur Generalisierung trainiert wurde. *Adversarial Attacks* konstruieren beispielsweise gezielt Eingabedaten für angegriffene Netze, um sie dazu zu bewegen, bestimmte Informationen auszugeben. Gerade in Anwendungsdomänen wie dem autonomen Fahren wären solche Angriffe mit einer direkten Gefahr für den Menschen verbunden. *Deepfakes*, welche die Identität nicht-existierender oder realer Personen durch KI generieren bzw. nachahmen, bergen zudem die Gefahr von Social Engineering und Identitätsdiebstahl zur Manipulation anderer Personen und Systeme. Auch im Bereich der generativen KI entwickeln sich Schutzmechanismen und Angriffe also im ständigen Wettlauf gegeneinander weiter [11].

4 Anwendungen in der Mobilität

4.1 Automatisiertes und autonomes Fahren

Im Straßenverkehr gibt es viele Einsatzmöglichkeiten von KI, um Verkehrsdynamiken besser zu verstehen und vorherzusagen. Durch intelligente Fahrerassistenzsysteme können z. B. Gefahrensituationen besser eingeschätzt und Unfälle vermieden werden. Leider stellen genau diese Herausforderungen eine große Barriere für Anwendungen wie das autonome Fahren dar. Schwierige Bedingungen wie schlechte Sichtverhältnisse bei Nacht, Nebel, Regen und Schnee stellen z. B. eine häufige Unfallursache dar. Jedoch werden auch in absehbarer Zeit nur verhältnismäßig wenige reale Daten solcher seltenen Szenarien vorliegen, da sie nicht beliebig oft in der realen Welt beobachtet und aufgezeichnet werden [5, 36].

SUSTechGAN ist ein GAN, das die Problematik fehlender Bilddaten durch die Generierung seltener Aufnahmen adressiert. Dazu nutzt es verschiedene Attention-Mechanismen, um typische Störungen wie bei Nacht und Regen verschwommen oder verdeckt dargestellte Fahrzeuge zu erlernen. Diese Störungen werden dann auf neue Bilder mit guten Sichtverhältnissen angewandt, um unterschiedliche Wetterbedingungen und Lichtverhältnisse zu simulieren. Durch die Erweiterung der Datenbasis mit simulierten Bildern können Methoden wie diese dazu beitragen, die Robustheit von maschinellen Lernalgorithmen zur Objekterkennung und zum Szenarienvständnis zu verbessern [18].

Um komplexe Unfallursachen wie von Menschen verursachte Fahrfehler, die nicht

eindeutig klassifiziert werden können, in Zeitreihen zu erkennen, kann eine Anomalieerkennung z. B. mit einem C-GAN kombiniert werden. Das C-GAN generiert Vorhersagen für das Fahrerverhalten in den nächsten sechs Sekunden, konditioniert auf dem Verhalten der vergangenen sechs Sekunden. Der Diskriminator erhält dann jeweils ein generiertes und ein echtes Zeitfenster und bewertet die Differenz zwischen beiden. Ein höherer Wert deutet an, dass ein unerwartetes Ereignis stattgefunden hat. Dabei können *multimodale* Daten verarbeitet werden, die sowohl Kameraaufnahmen als auch physiologische Informationen wie Atem- und Herzfrequenz des Fahrers betrachten [27].

Vierorts werden große Mengen an Sensordaten erfasst, um z. B. Trajektorien als Beschreibung der Bewegungsmuster eines Fahrzeugs zu berechnen und Routen zu optimieren. Trajektorien können über Lokalisationsdaten erfasst werden, die z. B. mit entsprechenden Sensoren in Fahrzeugen oder am Straßenrand erfasst werden. Gerade fahrspezifische Lokalisationsdaten geben jedoch inhärent sensible Informationen wie Wohnort, Arbeitsplatz und Fahrgewohnheiten preis. Es ist deshalb aus Datenschutzgründen nicht einfach möglich, die Informationen zu aggregieren und ein globales Modell zu trainieren. Größere Datensätze wären jedoch essenziell, um die breite Einsatzfähigkeit von Modellen sicherzustellen.

Generative KI bietet sich daher an, um synthetische Trajektorien basierend auf echten Datensätzen zu erzeugen. *TrajGAIL* ermöglicht dies mithilfe eines Reinforcement-Learning-basierten Generators, der Aktionen (z. B. links oder rechts abbiegen, geradeaus folgen) zum Übergang zwischen einzelnen Straßensegmenten auswählt. Durch das Feedback des Diskriminators lernt der Generator eine Strategie, um realistische Trajektorien zu generieren. *TrajGAIL* erwies sich u. a. bei der Evaluation mit echten Trajektorien aus Seoul als erfolgreich [5].

4.2 Verkehrsmanagement

Um den Verkehr optimal steuern zu können, wird KI u. a. eingesetzt, um das Verkehrsaufkommen an bestimmten Orten präzise zu prognostizieren. Auch hier gilt das Interesse seltenen, jedoch bedeutenden Extremfällen wie Staus aufgrund von Großveranstaltungen. Während der gewöhnliche Verkehrsfluss einer wöchentlichen Saisonalität un-

terliegt, können Ausnahmesituationen schnell in der großen, normalen Datenmenge untergehen. Lin et al. evaluieren eine GAN-basierte Netzarchitektur, die muster-sensitiv die gesamte Verteilung der Daten lernen soll, um das Verkehrsaufkommen zu präzisieren. Die Vorhersagequalität ist mit der von klassischen *Long Short-Term Memory (LSTM)* Networks zum Lernen von Sequenzen vergleichbar [22].

Generative Modelle können im selben Kontext jedoch auch eingesetzt werden, um seltene Sensordaten zu vermehren. Um die Luftqualität zu verbessern, wurde beispielsweise das neuronale Netz *AirGen* vorgeschlagen, welches Zeitreihen zu Luftqualitätsmessungen auf Basis eines GANs generiert. Durch die damit durchgeführte Datenaugmentierung kann die Performanz prädiktiver Lernalgorithmen verbessert werden [19].

Auch zur Optimierung des Verkehrsmanagements wurden bereits Ansätze mit generativer KI vorgeschlagen. Das Vehicle Routing Problem, bei dem die zurückgelegte Strecke und die damit verbundenen Kosten (z. B. Kraftstoffverbrauch, Schadstoffausstoß) vieler Fahrzeuge gleichzeitig optimiert werden sollen, kann als Graph mit Orten als Knoten und Straßen bzw. Transportwegen als Kanten repräsentiert werden. Für die kombinatorische Optimierung der Kosten lassen sich z. B. VAE und Reinforcement Learning ähnlich wie in GAIL kombinieren [34].

5 Diskussion und Fazit

Generative KI besitzt die Fähigkeit, die unterliegende Wahrscheinlichkeitsverteilung einer Menge an Datenpunkten zu lernen, um auf deren Basis neue Stichproben mit ähnlichen Eigenschaften zu synthetisieren. Diese Möglichkeit stellt eine fundamentale Neuerung gegenüber klassischen maschinellen Lernverfahren dar, die Regeln z. B. anhand vorgegebener Ein- und Ausgaben erlernen.

Dieser Paradigmenwechsel geht mit vielen Potenzialen einher. Gerade für den Straßenverkehr eröffnet sich damit die Möglichkeit, Anwendungsfälle in die Praxis zu überführen, die bisher aufgrund mangelnder Datenqualität und -menge scheitern. Ein eindrucksvolles Beispiel ist die Simulation schlechter Wetterbedingungen und Lichtverhältnisse durch Bildgenerierung, um die Datenbasis für schwierige Situationen beim automatisierten und autonomen Fahren zu erweitern. Auch

im Zusammenspiel mit Reinforcement Learning kann generative KI komplexe Optimierungsprobleme wie das Routing von Fahrzeugen durch die Erzeugung synthetischer Trajektorien bereichern.

Trotz der eindrucksvollen Anwendungserfolge sollte allerdings berücksichtigt werden, dass generative KI nicht für jede Problemart den besten Lösungsansatz darstellt. Gerade bei klassischen Prädiktionsproblemen, z. B. zur Vorhersage des Verkehrsaufkommens und anderer Zeitreihen oder zur reinen Klassifikation von Bildern, können klassische maschinelle Lernverfahren oft ebenso gute Ergebnisse erzielen. Gerade bei einfacheren Problemen bieten Verfahren wie lineare Regression und Entscheidungsbäume den gleichzeitigen Vorteil einer direkten Nachvollziehbarkeit des Zustandekommens der Vorhersagen. Zudem ist ihre Rechenkomplexität deutlich geringer, was den Energieverbrauch für Training und Inferenz reduziert.

Literaturverzeichnis

- [1] Achibat, R. et al. (2024): AttnLRP: Attention-Aware Layer-Wise Relevance Propagation for Transformers. Proceedings of the 41st International Conference on Machine Learning (ICML). DOI=10.5555/3692070.3692076
- [2] Betker, J. et al. (2023): Improving Image Generation with Better Captions. URL=https://cdn.openai.com/papers/dall-e-3.pdf
- [3] Bond-Taylor, S.; Leach, A.; Long, Y.; Willcocks, C. G. (2022): Deep Generative Modelling: A Comparative Review of VAEs, GANs, Normalizing Flows, Energy-Based and Autoregressive Models. IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 44, no. 11, DOI=10.1109/TPAMI.2021.3116668
- [4] Brown, T. B. et al. (2020): Language Models are Few-Shot Learners. Advances in Neural Information Processing Systems 33 (NeurIPS 2020). DOI=10.48550/arXiv.2005.14165
- [5] Choi, S.; Kim, J.; Yeo, H. (2021): TrajGAIL: Generating urban vehicle trajectories using generative adversarial imitation learning. Transportation Research Part C: Emerging Technologies 128, 103091. DOI=10.1016/j.trc.2021.103091
- [6] DeepSeek-AI, Guo, D. et al. (2025): DeepSeek-R1: Incentivizing Reasoning Capability in LLMs via Reinforcement Learning. DOI=10.48550/arXiv.2501.12948
- [7] Devlin, J.; Chang, M.-W.; Lee, K.; Toutanova, K. (2018): BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding. Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics (ACL). DOI=10.18653/v1/N19-1423
- [8] Dosovitskiy, A. et al. (2020): An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale. International Conference on Learning Representations (ICLR). 2021. DOI=10.48550/arXiv.2010.11929
- [9] Eigenschink, P. et al. (2023): Deep Generative Models for Synthetic Data: A Survey. IEEE Access 11, 47304–47320. DOI=10.1109/ACCESS.2023.3275134
- [10] Garg, V. (2024): Generative AI for graph-based drug design: Recent advances and the way forward. Current Opinion in Structural Biology, vol. 84. DOI=10.1016/j.sbi.2023.102769
- [11] Golda, A. et al. (2024): Privacy and Security Concerns in Generative AI: A Comprehensive Survey. IEEE Access 12, 48126–48144. DOI=10.1109/ACCESS.2024.3381611
- [12] Goodfellow, I. et al. (2014): Generative Adversarial Nets. Advances in Neural Information Processing Systems 27 (NIPS). DOI=10.48550/arXiv.1406.2661
- [13] Ho, J.; Ermon, S. (2016): Generative Adversarial Imitation Learning. Advances in Neural Information Processing Systems 29 (NIPS 2016). DOI=10.48550/arXiv.1606.03476
- [14] Ho, J.; Jain, A.; Abbeel, P. (2020): Denoising Diffusion Probabilistic Models. Advances in Neural Information Processing Systems 33 (NeurIPS 2020). DOI=10.48550/arXiv.2006.11239
- [15] Isler, M.; Yesilbel, B. R.; Santos, V.; Bacalhau, L. M. (2024): Usage of Artificial Intelligence for Advertising Creation for Social Media Marketing: ChatGPT Combined with Pictory and DALL-E. In Marketing and Smart Technologies. Proceedings of ICMarkTech 2023, Volume 1, J. L. Reis, J. Zelený, B. Gavurová and J. P. M. d. Santos, Eds. Smart Innovation, Systems and Technologies 386. Springer Nature Singapore; Imprint Springer, Singapore, 73–85. DOI=10.1007/978-981-97-1552-7_6
- [16] Kaswan, K.; Dhatterwal, J.; Malik, K.; Baliyan, A. (2023): Generative AI: A review on Models and Applications. International Conference on Communication, Security and Artificial Intelligence (ICCSAI), DOI=10.1109/ICCSAI59793.2023.10421601
- [17] Kingma, D. P.; Welling, M. (2013): Auto-Encoding Variational Bayes. International Conference on Learning Representations (ICLR). 2014. DOI=10.48550/arXiv.1312.6114
- [18] Lan, G.; Peng, Y.; Hao, Q.; Xu, C. (2024): SUSTechGAN: Image Generation for Object Detection in Adverse Conditions of Autonomous Driving. IEEE Trans. Intell. Veh., 1–10. DOI=10.48550/arXiv.2408.01430
- [19] Le Minh, K.-H.; Le, K.-H. (2021): AirGen: GAN-based synthetic data generator for air monitoring in Smart City. In 6th International Forum on Research and Technologies for Society and Industry. IEEE RTSI: September 6–9, 2021, virtual conference: proceedings. IEEE, Piscataway, NJ, 317–322. DOI=10.1109/RTSI50628.2021.9597364
- [20] Lee, K.; Lim, H.; Yun, G. (2024): A data-driven framework for designing microstructure of multifunctional composites with deep-learned diffusion-based generative models. Engineering Applications of Artificial Intelligence, vol. 129. DOI=10.1016/j.engappai.2023.107590
- [21] Li, Z.; Cui, Z.; Liao, H.; Ash, J.; Zhang, G.; Xu, C.; Wang, Y. (2024): Steering the Future: Redefining Intelligent Transportation Systems with Foundation Models. CHAIN 1, 1, 46–53. DOI=10.23919/CHAIN.2024.100003
- [22] Lin, Y.; Dai, X.; Li, L.; Wang, F.-Y. (2019): Pattern Sensitive Prediction of Traffic Flow Based on Generative Adversarial Framework. IEEE Trans. Intell. Transport. Syst. 20, 6, 2395–2400. DOI=10.1109/TITS.2018.2857224
- [23] Lv, Y.; Chen, Y.; Li, L.; Wang, F.-Y. (2018): Generative Adversarial Networks for Parallel Transportation Systems. IEEE Intell. Transport. Syst. Mag. 10, 3, 4–10. DOI=10.1109/MITS.2018.2842249
- [24] Naffziger, S. (2023): Innovations For Energy Efficient Generative AI. In 2023 International Electron Devices Meeting (IEDM). 9–13 Dec. 2023. IEEE, Piscataway, NJ, 1–4. DOI=10.1109/IEDM45741.2023.10413684
- [25] OpenAI, Achiam, J. et al. (2023): GPT-4 Technical Report. DOI=10.48550/arXiv.2303.08774
- [26] Pinheiro, C. et al.: Variational Autoencoder. In , 111–149. DOI=10.1007/978-3-030-70679-1_5. In: Variational Methods for Machine Learning with Applications to Deep Networks
- [27] Qiu, Y.; Misu, T.; Busso, C. (2019): Driving Anomaly Detection with Conditional Generative Adversarial Network using Physiological and CAN-Bus Data. In ICMI'19. Proceedings of the 2019 International Conference on Multimodal Interaction. ACM Digital Library. ACM, New York, 164–173. DOI=10.1145/3340555.3353749
- [28] Radford, A. et al. (2021): Learning Transferable Visual Models From Natural Language Supervision. Proceedings of the 38th International Conference on Machine Learning (ICML). DOI=10.48550/arXiv.2103.00020
- [29] Radford, A.; Narasimhan, K.; Salimans, T.; Sutskever, I. (2018): Improving Language Understanding by Generative Pre-Training. URL=https://cdn.openai.com/research-covers/language-unsupervised/language_understanding_paper.pdf
- [30] Ramesh, A.; Dhariwal, P.; Nichol, A.; Chu, C.; Chen, M. (2022): Hierarchical Text-Conditional Image Generation with CLIP Latents. DOI=10.48550/arXiv.2204.06125
- [31] Soydaner, D. (2022): Attention mechanism in neural networks: where it comes and where it goes. Neural Comput & Applic 34, 16, 13371–13385. DOI=10.1007/s00521-022-07366-3
- [32] Sun, G.; Xie, W.; Niyato, D.; Mei, F.; Kang, J.; Du, H.; Mao, S. (2025): Generative AI for Deep Reinforcement Learning: Framework, Analysis, and Use Cases. IEEE Wireless Commun., 1–10. DOI=10.1109/MWC.001.2400176
- [33] Vaswani, A.; Shazeer, N.; Parmar, N.; Uszkoreit, J.; Jones, L.; Gomez, A. N.; Kaiser, L.; Polosukhin, I. (2017): Attention Is All You Need. Advances in Neural Information Processing Systems 30 (NIPS 2017). DOI=10.48550/arXiv.1706.03762
- [34] Wang, Q. (2022): VARL: a variational autoencoder-based reinforcement learning Framework for vehicle routing problems. Appl Intell 52, 8, 8910–8923. DOI=10.1007/s10489-021-02920-3
- [35] Xu, H. M.; Mannor, S. (2012): Robustness and generalization. Machine Learning, vol. 86. DOI=10.1007/s10994-011-5268-1
- [36] Yan, H.; Li, Y. (2023): A Survey of Generative AI for Intelligent Transportation Systems: Road Transportation Perspective. DOI=10.48550/arXiv.2312.08248
- [37] Zhai, J.; Zhang, S.; Chen, J.; He, Q. (2018): Autoencoder and Its Various Variants. In SMC 2018. 2018 IEEE International Conference on Systems, Man, and Cybernetics: 7–10 October 2018, Miyazaki, Japan: proceedings. IEEE, Piscataway, NJ, 415–419. DOI=10.1109/SMC.2018.00080

Künstliche Intelligenz im Mobilitätsmanagement: Revolution oder Risiko?

Städte stehen vor einer gewaltigen Herausforderung: Klimaneutralität, bessere Luftqualität und ein effizienteres Verkehrsmanagement – und das am besten alles gleichzeitig realisieren. Bei der Suche nach Lösungen setzen Leipzig und Landau in der Pfalz als Pilotregionen im vom Bundesministerium für Digitales und Verkehr geförderten Forschungsprojekt AIAMO auf Künstliche Intelligenz als Schlüsseltechnologie. Doch wie verändert KI die Verkehrssteuerung wirklich? Kann sie Staus reduzieren, Emissionen senken und dabei auch noch den öffentlichen Nahverkehr stärken? Oder birgt sie unvorhersehbare Risiken? Der folgende Beitrag gibt Einblicke in ein ambitioniertes Vorhaben, das die Mobilität in deutschen Städten grundlegend verändern wird.

Umweltsensitive Verkehrssteuerung für gute Luftqualität in Leipzig

Leipzig gehört zu den 100 europäischen Modellkommunen, die schnelle Klimaneutralität anstreben. Das Ziel besteht darin, erfolgreiche Strategien zu entwickeln, zu erproben und auf andere Städte zu übertragen. Innovative Lösungen, die die spezifischen Herausforderungen der Region ansprechen, werden in Leipzig im Rahmen der „Digitalen Agenda“ zielführend und ämterübergreifend entwickelt und implementiert. Leipzig ist eine wachsende Stadt mit einem dynamischen urbanen Umfeld, in dem sich die Bedürfnisse der Bevölkerung rasch verändern. Besonders deutlich wird dies durch den signifikanten Anstieg der Einwohnerzahl in den letzten Jahren. Dieser Zuwachs führt zu einem steigenden Bedarf an Wohnraum, Infrastruktur und Verkehrsnetzen, wobei der Ausbau des öffentlichen Personennahverkehrs (ÖPNV) im Fokus steht.

EU-Grenzwerte für Luftqualität stellen eine Herausforderung dar

Die Stadt Leipzig steht – wie viele andere Kommunen – vor der Herausforderung, die ab 2030 geltenden strengeren EU-Luftqualitäts-grenzwerte, insbesondere für Stickoxide und Feinstaub, einzuhalten. Die Luftverschmutzung stellt ein ernsthaftes gesundheitliches Risiko dar und erfordert gezielte Maßnahmen zur Reduzierung der Emissionen.

Zur Umsetzung der geforderten Grenzwert-Anpassungen für Feinstaub und Stickoxide wurden zahlreiche Maßnahmen in Gang gesetzt, die Luftqualität zu untersuchen und nachhaltig zu verbessern. Hierfür innovative Lösungen zu entwickeln, ist einer der Schwerpunkte im Forschungsprojekt AIAMO, an dem neben den Verantwortlichen bei der Stadt Leipzig vor allem die AIAMO-Projektpartner Bosch, T-Systems, das Institut für Verkehrssystemtechnik des Deutschen Zentrums für Luft- und Raumfahrt e.V. (DLR) und das Helmholtz-Zentrum für Umweltforschung (UFZ) beteiligt sind. Der Auf- und Ausbau eines KI-gestützten, inter- und multimodalen Verkehrsmanagements soll maßgeblich zu Einhaltung der EU-Vorgaben beitragen und gleichzeitig die städtische Strategie zum

■ Verfasser



Dr. Thomas Trabert
Projektkoordination
Helmholtz Zentrum für
Umweltforschung (UFZ)



Andreas Schmid
Head of Market Solutions
SWARCO

Aufbau Digitaler Zwillinge im Mobilitätsbereich unterstützen. Ziel ist, die Bereiche der Stadt, in denen steigendes Verkehrsaufkommen zu einer höheren Umwelt- und Verkehrsbelastung führen könnte, zu untersuchen und Varianten zur Gegensteuerung vorzuschlagen. Gezielt werden dabei Hotspot-Bereiche, also Gebiete mit erhöhter Verkehrs- und Umweltbelastung, durch KI-gestützte Simulationen abgebildet.

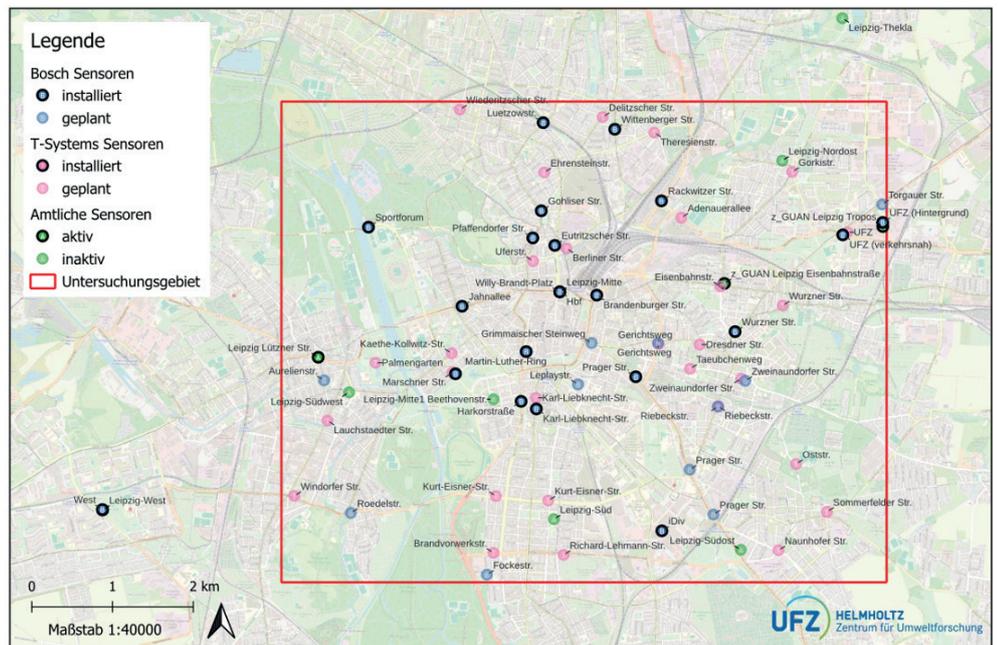


Bild 1: Umweltmessnetz der Pilotregion Leipzig (Quelle: UFZ)

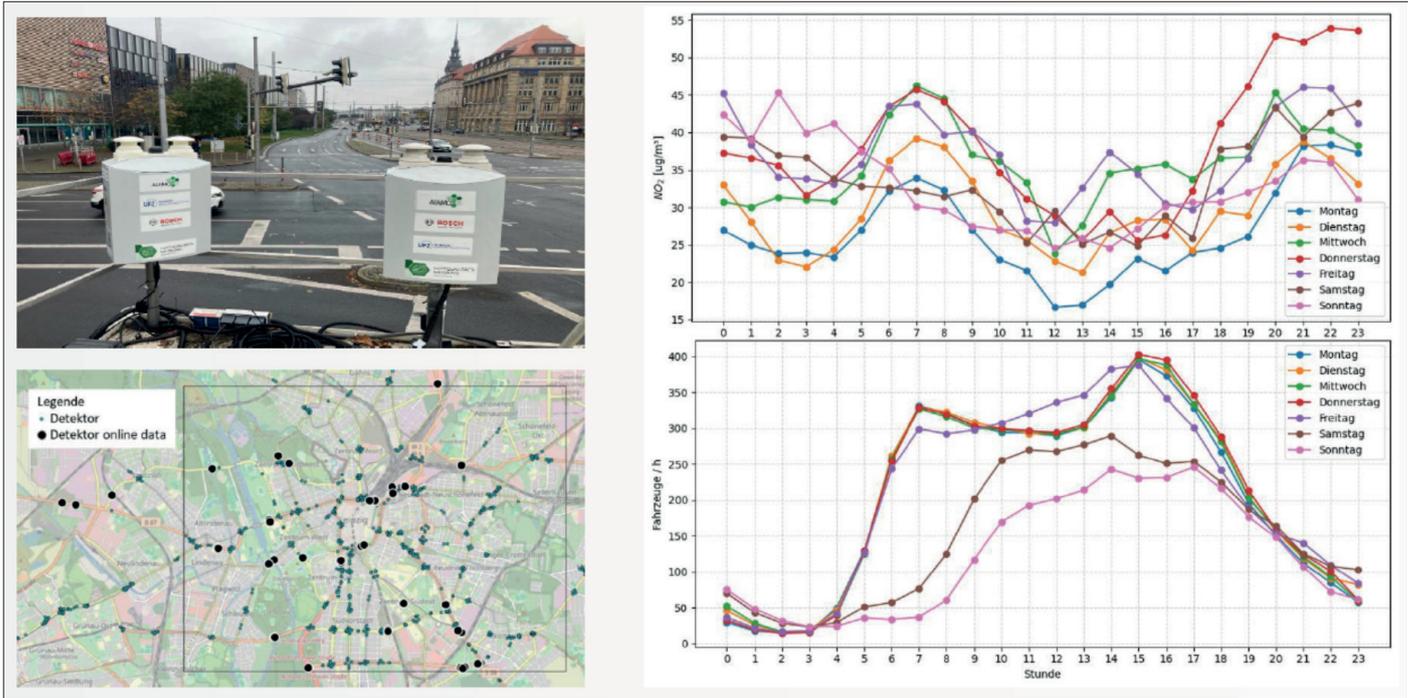


Bild 2: Typischer Wochenverlauf (gemittelt) der Luftqualität (NO₂, oben) und der Fahrzeuge pro Stunde (unten) des Umweltmessnetzes Leipzig. Die gemittelten Werte beziehen sich auf einen Zeitraum vom 10.6. bis 5.8.2024 (Quelle: UFZ/DLR)

Aufbau eines Umweltdatenmessnetzes

Als zentrale Datengrundlage wird in Leipzig zur Überwachung der Luftqualität im Rahmen des Forschungsprojekts ein umfassendes, sensorbasiertes Umweltdatenmessnetz mit Hilfe von Messgeräten von Bosch und T-Systems installiert, das etwa 50 Luftqualitätssensoren umfasst. Auf Basis von Echtzeitdaten, einschließlich relevanter Verkehrsdaten, wird derzeit unter der Federführung des UFZ, gemeinsam mit dem Institut für Verkehrssystemtechnik des DLR ein umweltsensitives Verkehrsmanagement entwickelt. Damit sollen zukünftig der Verkehr in umweltsensiblen Zonen effizient gesteuert und bei Überschreitung von Luftqualitätsgrenzwerten gezielte Maßnahmen ergriffen werden können. Dazu gehören z. B. die Anpassung des Tempolimits, der Verkehrsmengen, die Steuerung des Zuflusses sowie die Förderung umweltfreundlicher Verkehrsmittel und dabei insbesondere die Stärkung des ÖPNV. Ein weiterer wichtiger Ansatz ist die Entwicklung eines Szenarien-basierten Verkehrsmanagements, wie z. B. die gezielte Verkehrssteuerung bei Großereignissen und Events oder bei temporären Baustellen. Darüber hinaus soll die Entwicklung Digitaler Zwillinge für Verkehr (Federführung DLR) und Umwelt (Federführung Bosch) sowie deren Verbindung untereinander entscheidend zur Erreichung der genannten Ziele und langfristig zur Verbesserung des Verkehrsflusses, der Lebensqualität und der Nachhaltigkeit in der Stadt beitragen. Die konkrete Umsetzung und Ausgestaltung der Digitalen Zwillinge wird in der nächsten Ausgabe der Straßenverkehrstechnik noch detaillierter vorgestellt und vertieft.

Die Szenarien der umweltsensitiven Verkehrssteuerung wurden in enger Zusammenarbeit zwischen den Projektpartnern und den lokalen Experten (Amt für Umweltschutz sowie Mobilitäts- und Tiefbauamt) sowie dem Referat Digitale Stadt Leipzig (Projekt Connected Urban Twins) erarbeitet.

KI-gestützte Verkehrssteuerung in Landau in der Pfalz

Landau in der Pfalz gehört als Mittelstadt mit weniger als 100.000 Einwohnern zu einer Kategorie urbaner Räume, die sowohl durch

städtische als auch ländliche Strukturen geprägt sind. Besonders herausfordernd ist die hohe Anzahl an Ein- und Auspendlern, die zu Verkehrsspitzen auf den Hauptverkehrsachsen führt. Insbesondere zu den Stoßzeiten kommt es zu stockendem Verkehr, der sich negativ auf die Umwelt und die Effizienz des Verkehrsflusses auswirkt. Während Leipzig im AIAMO-Projekt vor allem für die umweltsensitive Verkehrssteuerung steht, liegt der Fokus in Landau i. d. Pfalz auf der Optimierung der Verkehrsflüsse mithilfe von KI.

Bild 3 zeigt die von Belastungsspitzen geprägten Streckenzüge. Im Westen befindet sich auch ein beschränkter Bahnübergang, der den Verkehrsfluss zusätzlich unterbricht.

Adaptive Ampelsteuerung durch bestärkendes Lernen

Im Rahmen des Forschungsprojekts AIAMO wird in Landau in der Pfalz eine KI-gestützte Optimierung des Verkehrsflusses erprobt. Die Ampelschaltungen der Hauptfahrtrichtungen auf den wichtigsten Verkehrsachsen werden adaptiv in Abhängigkeit von der aktuellen Verkehrssituation angepasst, um den Verkehrsfluss zu optimieren. Die Umschaltzeitpunkte (im Speziellen die Versatzzeiten) für die „grüne Welle“ passen sich also dynamisch an die Verkehrsdichte an, ohne dass die Umlaufschaltungen an Einzelkreuzungen verändert werden. Der innovative Ansatz besteht darin, die Signalphasen an den Lichtsignalanlagen (LSA) dynamisch und KI-gestützt optimal aufeinander sowie das Verkehrsaufkommen abzustimmen. Dadurch wird der bestehende Programmablauf der Ampelschaltungen nicht grundlegend verändert, sondern passend zur realen Situation feinjustiert. Dieser Eingriff zielt auf eine verbesserte Durchflussrate und reduzierte Anzahl unnötiger Stopps und Anfahrvorgänge, was sich positiv auf den Kraftstoffverbrauch und die Emissionswerte auswirkt.

Die Optimierung erfolgt durch den Einsatz von bestärkendem Lernen (Reinforcement Learning), das auf Basis eines mikroskopischen Simulationsmodells trainiert wird. Dieses Modell bildet den zu beeinflussenden Verkehrskorridor ab (z. B. Layout der Straßen mit Fahrspuren oder Haltelinien) und wird mit realen Detektormesswerten der LSA gespeist. So werden authentische Verkehrssituationen in der Simu-

lation nachgebildet, die als Ausgangspunkt für den Lernprozess der KI dienen. Die KI „erlernt“ für die unterschiedlichen Szenarien der Realität, welche Parameterwahl zum optimalen Ergebnis (z. B. Reduktion der Halte im Streckennetz) führt. Während des tatsächlichen Betriebs kommt dann ausschließlich das angelegte Modell zur Anwendung, die Verkehrssimulation wird nur während der Trainingsphase benötigt.

KI-gestützte Verkehrssteuerung

Zur Verbesserung der Erfassung der Ist-Situation soll an Kreuzungen auch eine KI-gestützte, Trajektorien-basierte Erfassung des Verkehrs erfolgen. Im Unterschied zur bisherigen Nutzung von KI-gestützter Kameraerfassung werden Messdaten nicht allein auf herkömmliche Werte wie Präsenz, Geschwindigkeit oder Fahrzeugklasse an einem Messquerschnitt generiert. Vielmehr werden die Bewegungsdaten einzelner Fahrzeuge über den gesamten erfassten Messbereich erhoben und sowohl für die Kalibrierung des digitalen Zwillings als auch zur Verkehrssteuerung zur Verfügung gestellt. Daten umfassen Informationen wie Anzahl der Fahrzeuge samt deren Entfernungen zum Haltepunkt sowie die Geschwindigkeit – im Sekundenraster. Auch die Quell-Ziel-Beziehung (wie wurde die Kreuzung durchfahren) kann auf dieser Basis direkt gemessen werden und so die sonst übliche Schätzung ersetzen bzw. die Kalibrierung unterstützen.

Im Rahmen der Umsetzung der KI-gestützten Verkehrssteuerung für Landau in der Pfalz wurden bereits wesentliche Schritte realisiert:

- Bestimmung des relevanten Verkehrskorridors für die adaptive Steuerung
- Identifikation und technische Erfassung der relevanten LSA inklusive ihrer verkehrstechnischen Unterlagen (VTU)
- Sammlung und Aufbereitung von Verkehrszählenden der Stadt Landau i. d. Pfalz
- Entwicklung eines Simulationsmodells für den Korridor
- Integration der erhobenen Zählenden als Eingangsgrößen für die Simulation
- Verknüpfung des Simulationsmodells mit einem Machine-Learning-Algorithmus
- Definition einer Belohnungsfunktion zur Bewertung der KI-Steuerung und erste Testläufe

Neben der Verbesserung des Verkehrsflusses ist auch eine Integration des querenden Bahnverkehrs in die Steuerung angedacht. Ein beschränkter Bahnübergang im Westen der Stadt führt regelmäßig zu Unterbrechungen in der Verkehrsbewegung, was die Notwendigkeit einer intelligenten Anpassung der Ampelschaltungen weiter unterstreicht. Hier könnte eine KI-gestützte, vorausschauende Steuerung dazu beitragen, die Wartezeiten an der Bahnschranke zu minimieren und die Verkehrsdynamik auf den Hauptachsen stabil zu halten.

Neue Perspektiven für das Mobilitätsmanagement in Städten und Kommunen

Die in Leipzig und Landau in der Pfalz erprobten Verfahren können

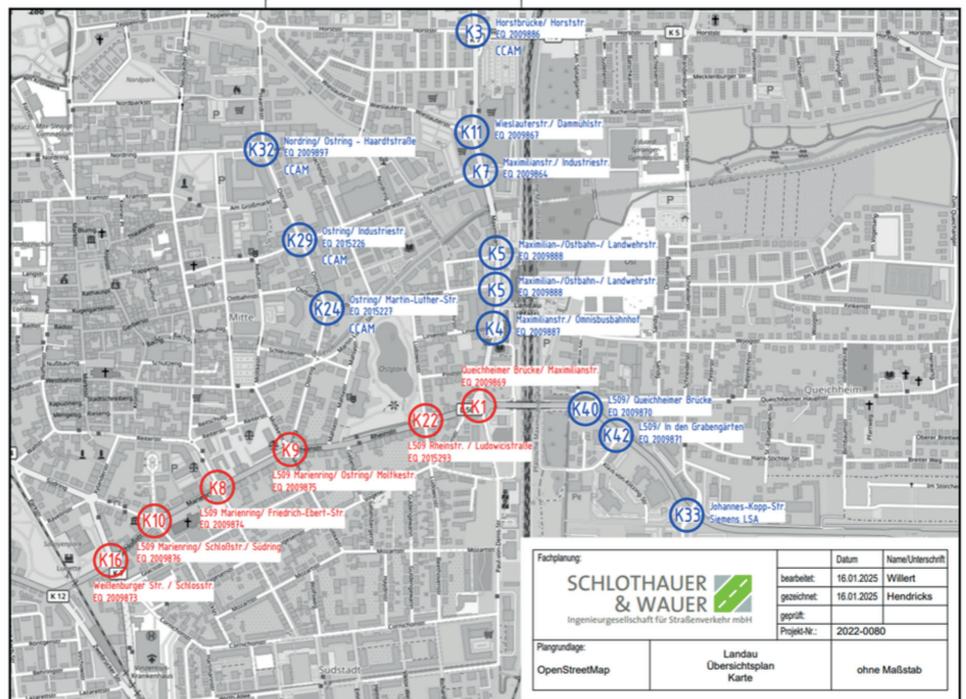


Bild 3: Kreuzungen an stark belasteten Hauptverkehrsachsen in der AIAMO-Pilotregion Landau in der Pfalz (Quelle: Schlothauer & Wauer)

künftig als Blaupause für vergleichbare Mittelstädte dienen, die mit ähnlichen Verkehrsproblemen konfrontiert sind. Ein Schlüsselfaktor für den Erfolg von AIAMO ist die enge und konstruktive Zusammenarbeit mit den Kommunen durch fachspezifische Ansprechpartner und Zugang zur städtischen Infrastruktur in den Pilotregionen.

Das Forschungsprojekt zeigt, wie KI neue, niedrigschwellige Lösungen für die komplexen Herausforderungen mittelgroßer Städte und Kommunen bietet. Die erprobten Methoden in Leipzig und Landau in der Pfalz dienen als Referenz und Basis für eine effiziente, datenbasierte Verkehrssteuerung, die sowohl Umweltaspekte als auch wirtschaftliche Faktoren berücksichtigt.

Durch den AIAMOnexus – eine Kombination aus der Integrationszone zur Datenverknüpfung und leistungsstarken AI Foundation Models – entsteht eine robuste Grundlage für zukunftsfähige KI-Anwendungen im Mobilitätsmanagement. Diese Modelle ermöglichen eine präzisere Analyse von Verkehrsflüssen, optimieren Steuerungsmechanismen und tragen durch Daten-Augmentierung sowie synthetische Ergänzungen zur Schließung von Datenlücken bei.

AIAMO nutzt KI nicht nur zur besseren Auswertung von Messdaten, sondern auch zur Automatisierung und Optimierung verkehrlicher Prozesse. Besonders in Verbindung mit Digitalen Zwillingen und Reinforcement Learning können Verkehrssteuerungssysteme adaptiver, nachhaltiger und wirtschaftlicher gestaltet werden. So eröffnet das Projekt Städten neue Wege, Mobilität effizienter zu managen – ohne zusätzliche Risiken für den Verkehr oder die Umwelt.

Gefördert durch:



aufgrund eines Beschlusses des Deutschen Bundestages



Digitale Zwillinge ermöglichen ein umweltsensitives Mobilitätsmanagement

Städte und Kommunen stehen vor enormen Herausforderungen: Sie streben Klimaneutralität an, müssen strengere Luftschadstoffgrenzwerte einhalten und gleichzeitig den wachsenden Mobilitätsbedarf mit dem Wunsch nach mehr Lebensqualität in Einklang bringen. Verkehrssteuernde Eingriffe erfolgen eher planerisch als operativ und wirken so nicht zeitnah auf permanent wechselnde Verkehrs- und Umweltsituationen. Echtzeitfähige digitale Zwillinge bieten hier neue Möglichkeiten: Sie erfassen aktuelle Bedingungen, analysieren potenzielle Steuerungsmaßnahmen, bewerten deren Auswirkungen auf das Gesamtnetz und leiten daraus kurzfristige, zielgerichtete Handlungsempfehlungen ab. Das vom Bundesministerium für Digitales und Verkehr geförderte Forschungsprojekt AIAMO (Artificial Intelligence And MOBility) kombiniert diesen Ansatz mit Künstlicher Intelligenz (KI), um die Mobilität in deutschen Städten und Kommunen grundlegend neu zu denken. Ziel ist der Aufbau eines digitalen Abbilds von Verkehr und Umwelt – als Grundlage für ein nachhaltiges, datenbasiertes Mobilitätsmanagement.

Bislang beruhen Eingriffe ins Verkehrsgeschehen meist auf einer begrenzten Auswahl festgelegter Steuerungsstrategien für Lichtsignalanlagen (LSA). Diese Programme basieren auf Planungsannahmen, Prognosen und punktuellen Verkehrszählungen. Der flächendeckende Einsatz dynamischer Steuerungsverfahren ist bislang kosten- und zeitintensiv und beschränkt sich auf wenige Verkehrskorridore – eine netzweite Wirkung bleibt aus, Umweltaspekte bleiben meist unberücksichtigt.

Gleichzeitig wird der urbane Verkehr zunehmend von kurzfristigen, zeitlich und räumlich begrenzten Ereignissen geprägt – etwa Baustellen, Großveranstaltungen oder plötzliche Sperrungen. Solche Störungen lassen sich mit den herkömmlichen Steuerungsprogrammen kaum flexibel abbilden. Hinzu kommt der wachsende Handlungsdruck durch strengere Umweltvorgaben. Reaktionszeiten auf Störungen müssen daher deutlich kürzer werden. Würden drohende Grenzwertüberschreitungen frühzeitig erkannt und steuernd adressiert, ließen sich Verkehr und Umwelt gleichermaßen entlasten. Ein intelligentes, adaptives Verkehrsmanagement ist damit Schlüssel zu zukunftsfähigen Städten und Kommunen – und digitale Zwillinge sind wichtige Bausteine dafür.

Digitaler Zwilling – digitales Abbild einer Stadt

Die Auswirkungen verkehrssteuernder Maßnahmen lassen sich derzeit kaum in Echtzeit, mit vertretbarem Aufwand und ausreichender Genauigkeit analysieren – insbesondere dann, wenn es um die komplexe Wechselwirkung zwischen Verkehr und Umwelt geht. Dafür müssen Daten oft aufwendig recherchiert, Nutzungsrechte geklärt, Informationen geprüft und verknüpft sowie Simulationen erstellt und kalibriert werden. Erst dann lassen sich Szenarien analysieren. Dieser Prozess ist zeit- und kostenintensiv – und wenig flexibel gegenüber sich ändernden Rahmenbedingungen.

Ein digitaler Zwilling ist ein virtuelles Abbild eines komplexen Systems, das kontinuierlich mit Echtzeitdaten aus der realen Welt gespeist wird. Dazu zählen nicht nur physische Objekte, sondern auch Abläufe, Prozesse, Beziehungen und Interaktionen innerhalb des Gesamtsystems. Digitale Zwillinge sind damit mehr als reine Datensammlungen: Sie bestehen aus detaillierten Modellen, Simulationen, Algorithmen sowie funktionalen Diensten. Reife Systeme erlauben nicht nur die Analyse, sondern auch Eingriffe in die Realität – inklusive der Bewertung und Anpassung der eingeleiteten Maßnahmen. Im Forschungsprojekt AIAMO entsteht exemplarisch

■ Verfasser



Carsten Dalaff

Projektkoordination
DLR Deutsches Zentrum für
Luft- und Raumfahrt e.V.
Institut für Verkehrs-
systemtechnik



Alexander Sohr

Gruppenleitung Mobilitäts-
und Verkehrsmanagement
DLR Deutsches Zentrum für
Luft- und Raumfahrt e.V.
Institut für Verkehrssystemtik

für die Pilotregion Leipzig ein solcher digitaler Zwilling – mit dem Fokus auf Verkehr und Umwelt.

Ein digitaler Zwilling – oder zwei?

Die Verbindung von Verkehr und Umwelt in einem einzigen digitalen Modell ist hochkomplex. Daher setzt AIAMO zunächst auf zwei spezialisierte digitale Zwillinge: einen für den Verkehrsbereich, einen für die Umwelt. Diese Trennung erlaubt präzisere Modellierung und differenzierte Analysen. Je nach Fragestellung, können sie einzeln oder gemeinsam genutzt werden. Für letzteres werden die beiden Digitalen Zwillinge miteinander gekoppelt.

Der digitale Zwilling Umwelt verarbeitet Luftqualitätsdaten aus dem Umweltdatenmessnetz der Region Leipzig, ergänzt durch aktuelle Wetterdaten, Geländetopologien, Bebauungsinformationen und weitere Einflussgrößen. Auf dieser Basis kann mithilfe eines Ausbreitungsmodells die Luftbelastung räumlich differenziert prognostiziert werden.

Der digitale Zwilling Verkehr bildet das regionale Straßennetz ab, erfasst Verkehrsmengen und -situationen, und ergänzt Lücken in der Datenlage durch Simulation. Gemeinsam ermöglichen beide Zwillinge die Analyse der Wechselwirkungen zwischen Verkehr und Luftqualität – etwa bei erhöhtem Verkehrsaufkommen durch motorisierten Individualverkehr (MIV).

Dieser kombinierte Ansatz schafft die Grundlage für ein umweltsensitives Mobilitätsmanagement: Auf Basis aktueller Daten lassen sich Maßnahmen simulieren, bewerten und optimieren, bevor sie im realen Verkehrsgeschehen umgesetzt werden, etwa durch eine intelligente Steuerung von LSA an besonders belasteten Knotenpunkten und Korridoren.

Der digitale Zwilling Verkehr und Umwelt ist fester Bestandteil der Prozesskette. Er setzt auf dem AIAMO nexus auf, der die Integrationszone sowie leistungsfähige AI Foundation Models umfasst. Darüber werden die erforderlichen Daten kuratiert, qualitätsgesichert und diversifiziert sowie zur Nutzung bereitgestellt und im digitalen Zwilling zu einem digitalen Abbild des Verkehrs und der Umwelt zusammengeführt. Dort erfolgen das Monitoring, die Analyse des Ist-Zustandes sowie die KI-gestützte Ableitung und Bewertung von Handlungsempfehlungen. So entsteht ein durchgängiger, intelligenter und skalierbarer Prozess, der eine effiziente, nahtlose und individualisierte Mobilität unterstützt – mit dem digitalen Zwilling als zentralem Baustein.

Funktionalitäten des digitalen Zwillings Verkehr und Umwelt

Der digitale Zwilling Verkehr und Umwelt bildet nicht nur den aktuellen Zustand ab, sondern ermöglicht auch die Simulation künftiger Szenarien sowie die Entwicklung und Bewertung gezielter Steuerungsmaßnahmen. Die folgende Funktionsübersicht zeigt, wie umfassend der digitale Zwilling aufgestellt ist:

- Darstellung des Umweltdatenmessnetzes
- Monitoring der aktuellen Emissions- und Immissionslage
- Erfassung der aktuellen Verkehrssituation in der Pilotregion
- Kurzfristige Verkehrsprognose zur Erkennung dynamischer Veränderungen
- KI-basierte Hotspot-Analyse
- Wirkungsanalyse verkehrssteuernder Maßnahmen
- Identifikation und Überwachung von Problembereichen mit automatisierter Generierung von Maßnahmen- und Handlungsempfehlungen

Dank der im AIAMOnexus bereitgestellten, konsolidierten und harmonisierten Datenbasis, die im digitalen Zwilling weiter verfeinert wird, lassen sich moderne Analysemethoden aus Statistik, maschinellem Lernen und KI gezielt einsetzen. Sie ermöglichen belastbare Prognosen, realitätsnahe Szenarien-Modellierungen und automatisierte Bewertungen der Wirksamkeit einzelner Maßnahmen.

So analysiert der digitale Zwilling fortlaufend die Verkehrs- und Umweltsituation. Wird ein Hotspot identifiziert – etwa eine drohende Überschreitung von Luftgrenzwerten – erhält das zuständige Verkehrsmanagementsystem automatisiert einen Hinweis. In einem weiteren Schritt werden mithilfe von KI geeignete Steuerungsmaßnahmen generiert. Dabei kombiniert das System unterschiedliche

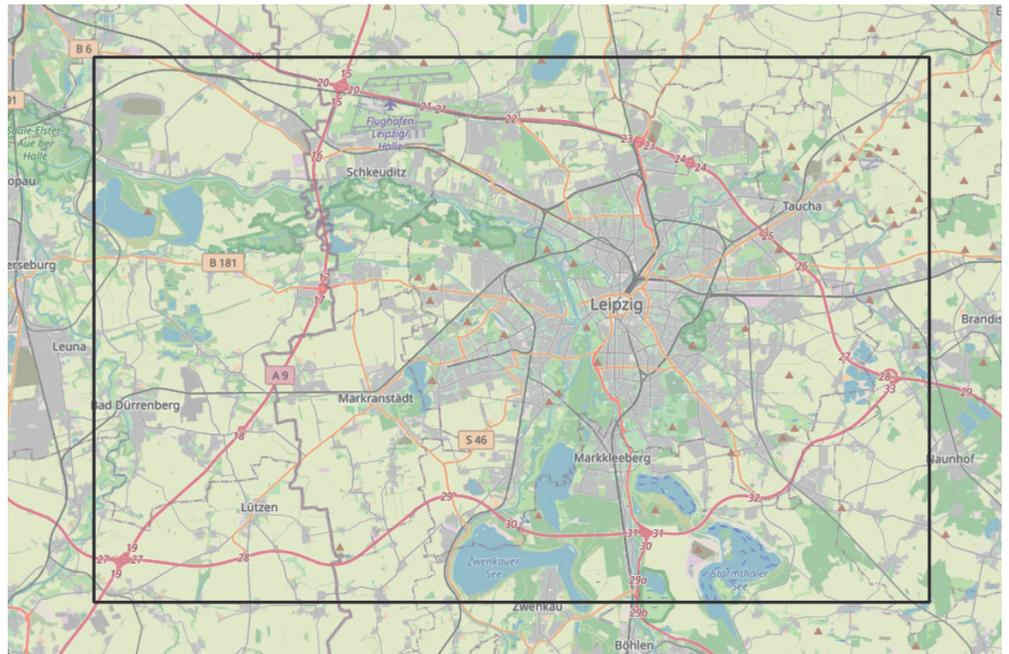


Bild 1: Räumlicher Ausschnitt des digitalen Zwillings Verkehr in der AIAMO Pilotregion Leipzig

Optionen, dimensioniert sie hinsichtlich ihrer Wirkung und berechnet optimierte Maßnahmenbündel.

Diese Empfehlungen unterstützen Verkehrsmanager bei der schnellen und datenbasierten Entscheidungsfindung – mit dem Ziel, Umweltbelastungen zu minimieren und gleichzeitig einen sicheren, nachhaltigen und flüssigen Verkehr in der Stadt zu gewährleisten.

Leipzig als Testfeld für umweltsensitive Verkehrssteuerung

Mit dem digitalen Zwilling lassen sich zentrale Fragestellungen des Verkehrs- und Umweltmanagements fundiert untersuchen: Wie wirken sich verschiedene verkehrssteuernde Maßnahmen auf Verkehrsfluss und Luftqualität in einem Stadtgebiet aus? Und welche Eingriffe sind notwendig, um die Überschreitung lokaler oder überregionaler Umweltgrenzwerte zu vermeiden? Auch die Stadt Leipzig stellt sich diesen Herausforderungen – und beteiligt sich als Pilotregion im Forschungsprojekt AIAMO, um neueste wissenschaftliche Erkenntnisse in der Praxis zu erproben und davon zu profitieren.

Gemeinsam mit den zuständigen Stellen der Stadt wurde zunächst eine umfassende Bedarfs- und Anforderungsanalyse durchgeführt. Auf dieser Grundlage wurde der in Bild 1 dargestellte Betrachtungsraum für den digitalen Zwilling Verkehr definiert – begrenzt durch die Autobahnen A 9, A 14 und A 38. Dieses Gebiet umfasst sowohl den städtischen Raum Leipzigs als auch dessen regionale Verflechtungen und bildet damit einen geschlossenen Verkehrsraum.

Für dieses Gebiet wurde durch das Deutsche Zentrum für Luft- und Raumfahrt e.V. (DLR) ein mesoskopisches Szenario in der Open-Source-Verkehrssimulation SUMO (Simulation of Urban Mobility) – welches ein etabliertes Werkzeug zur realitätsnahen Abbildung komplexer Verkehrsabläufe ist – aufgebaut. Im weiteren Projektverlauf wird dieses Modell durch mikroskopisch präzisere Simulationen ergänzt, insbesondere in den Gebieten mit identifizierten Problemstellungen.

Für die Pilotregion Leipzig wurden die beiden digitalen Zwillinge Verkehr und Umwelt umgesetzt. Der digitale Zwilling Verkehr bildet

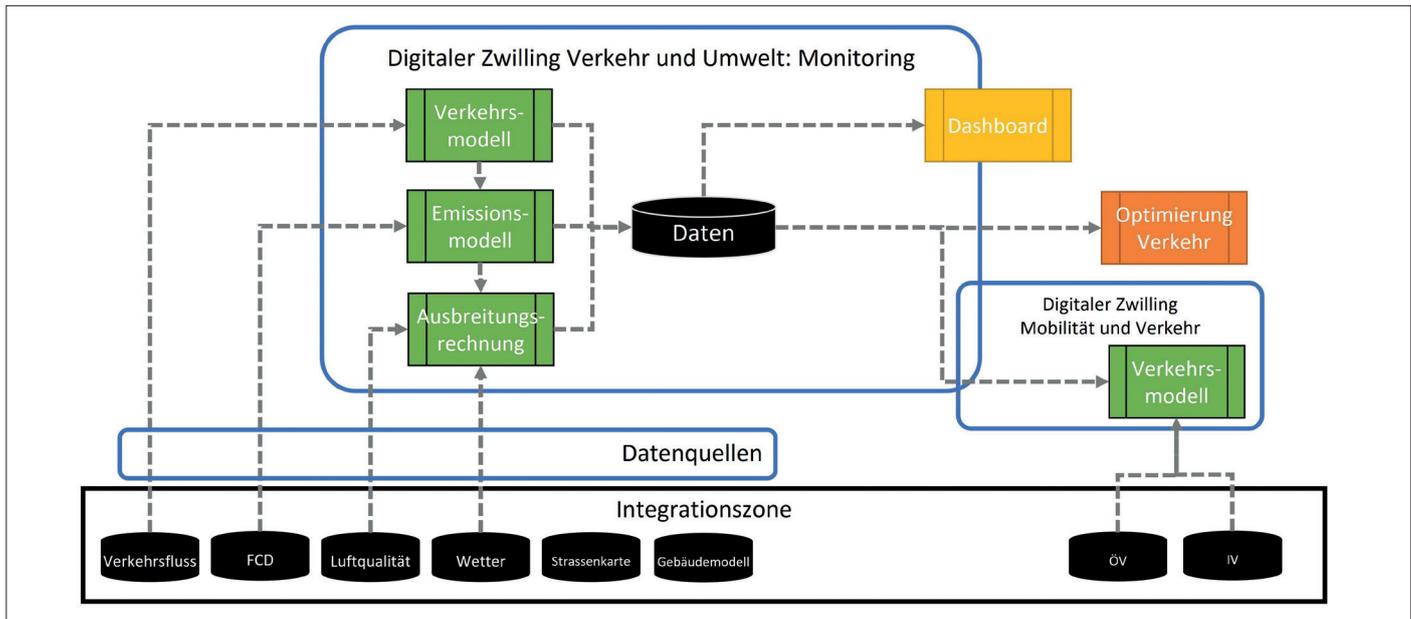


Bild 2: Bausteine des digitalen Zwillings Verkehr und Umwelt

das aktuelle Verkehrsaufkommen auf Basis eines definierten Straßennetzes (Open Street Map) ab und dient darüber hinaus zur Erstellung von Prognosen und Szenarien. Der digitale Zwilling Umwelt beinhaltet die Bausteine zur Berechnung verkehrsbedingter Immissionen und der Luftqualität im definierten Untersuchungsraum.

Verkehrsmodellierung und Datenintegration im digitalen Zwilling Leipzig

Der digitale Zwilling Verkehr basiert auf einer Vielzahl verkehrsbezogener Daten, die in einem integrierten Verkehrsmodell zusammengeführt werden. Untersucht werden unterschiedliche verkehrssteuernde Maßnahmen sowie deren Auswirkungen, einschließlich potenzieller Routenänderungen. Für diese Analysen werden Daten aus dem Großraum Leipzig verwendet (siehe Bild 2).

Ein zentrales Element ist das Umweltmessnetz, das unter Federführung des Helmholtz-Zentrums für Umweltforschung (UFZ) gemeinsam mit dem Umweltamt Leipzig und weiteren städtischen Akteuren aufgebaut wurde. Es ermöglicht die flächendeckende Erfassung und Darstellung von Immissionen und schafft die Grundlage für ein tieferes Verständnis der Zusammenhänge zwischen verkehrsbedingten Emissionen und der Luftqualität.

Zur Erstellung des Verkehrsmodells wurden sowohl Infrastrukturdaten (z. B. Streckennetz) als auch Verkehrsnachfragedaten genutzt. Mit dem perspektivischen Zugang zu weiteren Datensätzen wird das Modell kontinuierlich verbessert – es handelt sich also um einen iterativen Prozess. Zukünftig werden die dafür erforderlichen Daten über die im Projekt AIAMO entwickelte Integrationszone (vgl. Straßenverkehrstechnik 4/2025) zugänglich gemacht, was den Prozess deutlich beschleunigt und vereinfacht.

Neue Perspektiven für das Mobilitätsmanagement in Städten und Kommunen

Der in Leipzig erprobte digitale Zwilling für Verkehr und Umwelt – kombiniert mit dem Umweltmessnetz – dient künftig als Blaupause für weitere Städte, die gezielt auf lokale Verkehrsprobleme und Luftschadstoffbelastungen reagieren möchten. Das Forschungsprojekt AIAMO demonstriert, wie KI praxisnahe Lösungen für die komplexen Anforderungen mittelgroßer Städte und Kommunen ermöglichen kann. Die in Leipzig erprobten Methoden bilden die Grundlage für eine datenbasierte, effiziente Verkehrssteuerung, die Umweltaspekte ebenso berücksichtigt wie wirtschaftliche Rahmenbedingungen.

Herzstück ist der AIAMOnexus – eine intelligente Kombination aus der Integrationszone zur strukturierten Datenverknüpfung und leistungsstarken AI Foundation Models. Diese ermöglichen eine präzise Analyse von Verkehrsflüssen, die Optimierung von Steuermechanismen und die Schließung von Datenlücken durch Daten-Augmentierung und synthetische Ergänzungen.

AIAMO nutzt den digitalen Zwilling für Verkehr und Umwelt nicht nur zur verbesserten Auswertung und Vernetzung von Umweltdaten, sondern auch zur KI-gestützten Entwicklung und Bewertung von Steuerungsmaßnahmen. Durch den Einsatz dieser Technologien können Verkehrsmanagementsysteme künftig flexibler, nachhaltiger und wirtschaftlicher gestaltet werden. Das Projekt eröffnet Städten und Kommunen neue Möglichkeiten, Mobilität intelligenter und ganzheitlicher zu steuern – unter Berücksichtigung der zunehmend komplexen Wechselwirkungen von Verkehr und Umwelt.

Gefördert durch:



aufgrund eines Beschlusses des Deutschen Bundestages



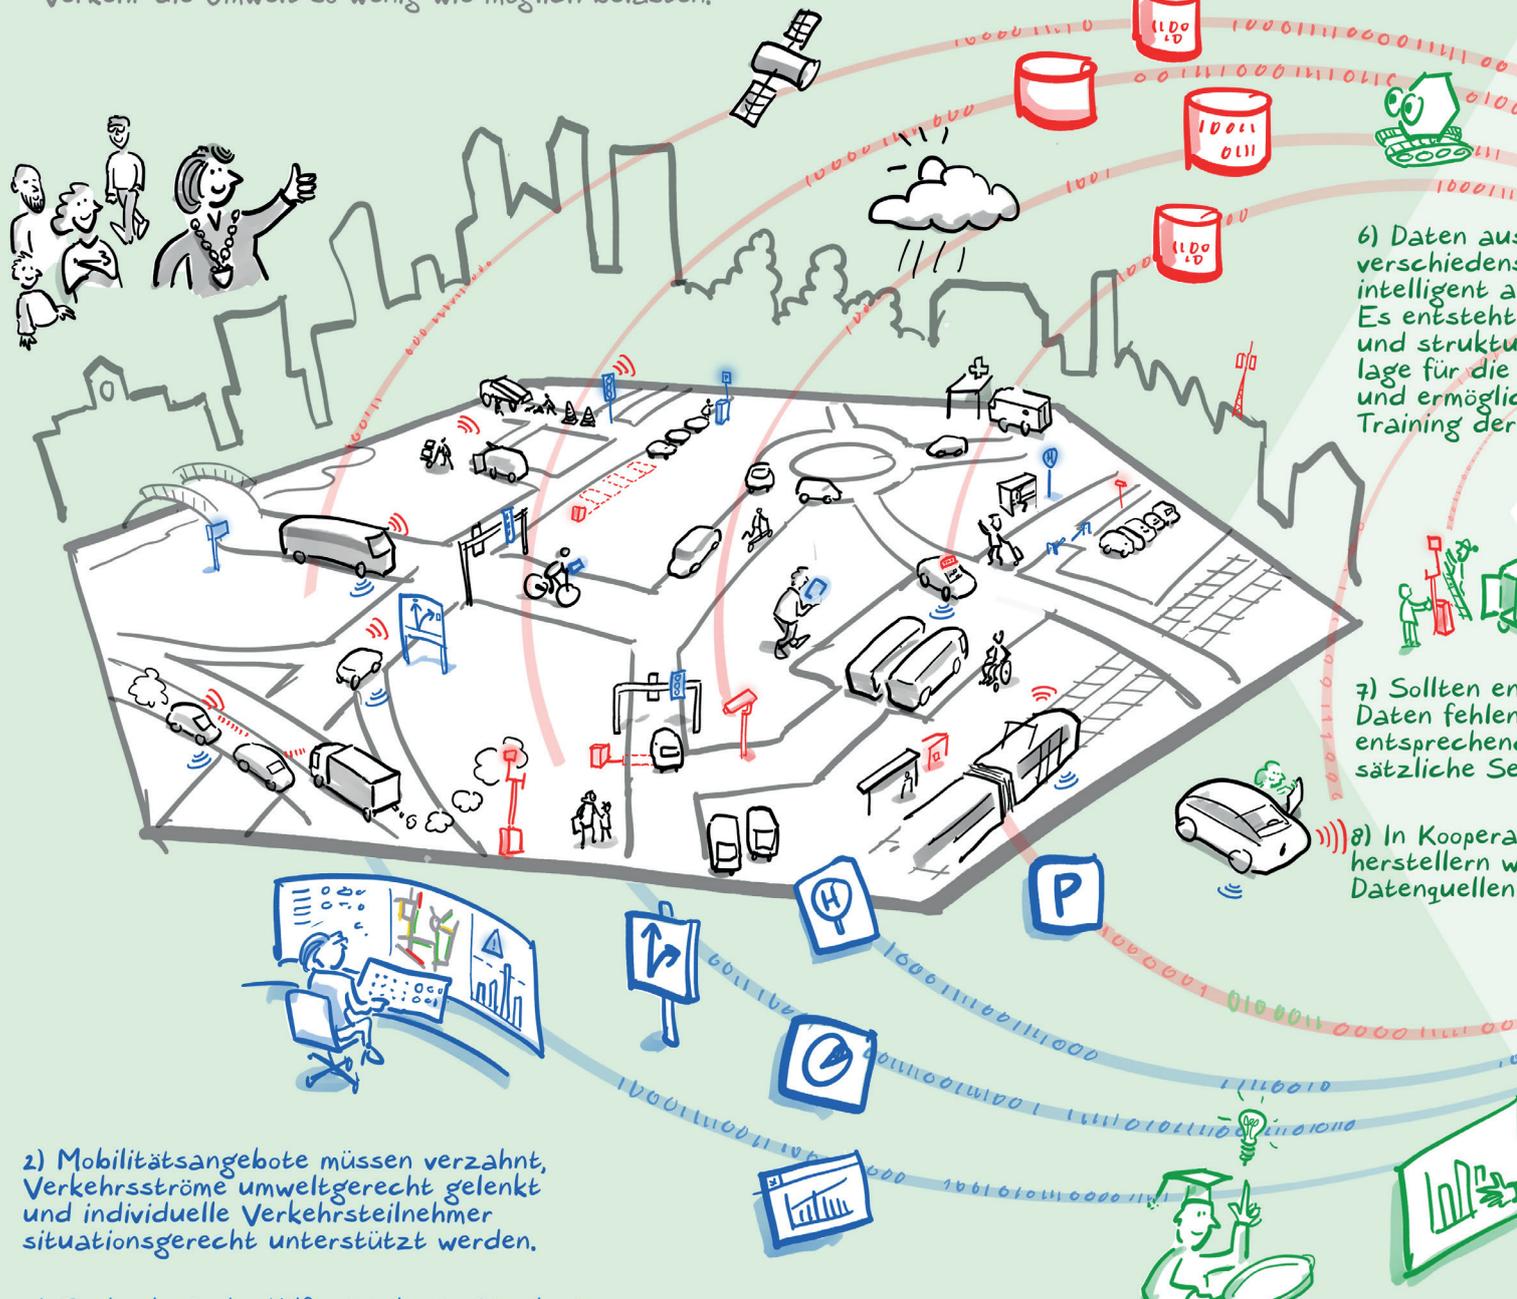
AIAMO - Artificial Intelligence

KI macht Mobilität effizienter,

1) Mobilitätsangebote beeinflussen maßgeblich die Lebensqualität in Städten und Kommunen. Menschen möchten schnell, sicher und bequem von A nach B kommen. Gleichzeitig soll der Verkehr die Umwelt so wenig wie möglich belasten.

4) Bisher sind Datenquellen oft schwer zugänglich. Daten haben häufig nicht die notwendige Qualität und sind selten miteinander verknüpft.

5) Die einfache Anbindung von AIAMO in Kommunen und die Anbindung...



6) Daten aus verschiedenen Quellen werden intelligenter analysiert. Es entsteht eine bessere Struktur und Lage für die Daten, was das Training der KI ermöglicht.

7) Sollten entsprechende Daten fehlen, können entsprechende Sensoren zusätzliche Sensoren...

8) In Kooperation mit Herstellern werden neue Datenquellen erschlossen.

2) Mobilitätsangebote müssen verzahnt, Verkehrsströme umweltgerecht gelenkt und individuelle Verkehrsteilnehmer situationsgerecht unterstützt werden.

3) Technologische Hilfsmittel, wie Simulationen, Prognosen, Verkehrsleitsysteme und Mobilitäts-Apps brauchen Zugang zu Echtzeitdaten, zum Beispiel zur Verkehrslage, Fahrplänen, Wetter und Luftqualität.

10) KI unterstützt die Entwicklung und Entwicklung einfacher, schneller und effizienter. So macht KI...



Intelligence and Mobility sicherer und nachhaltiger!

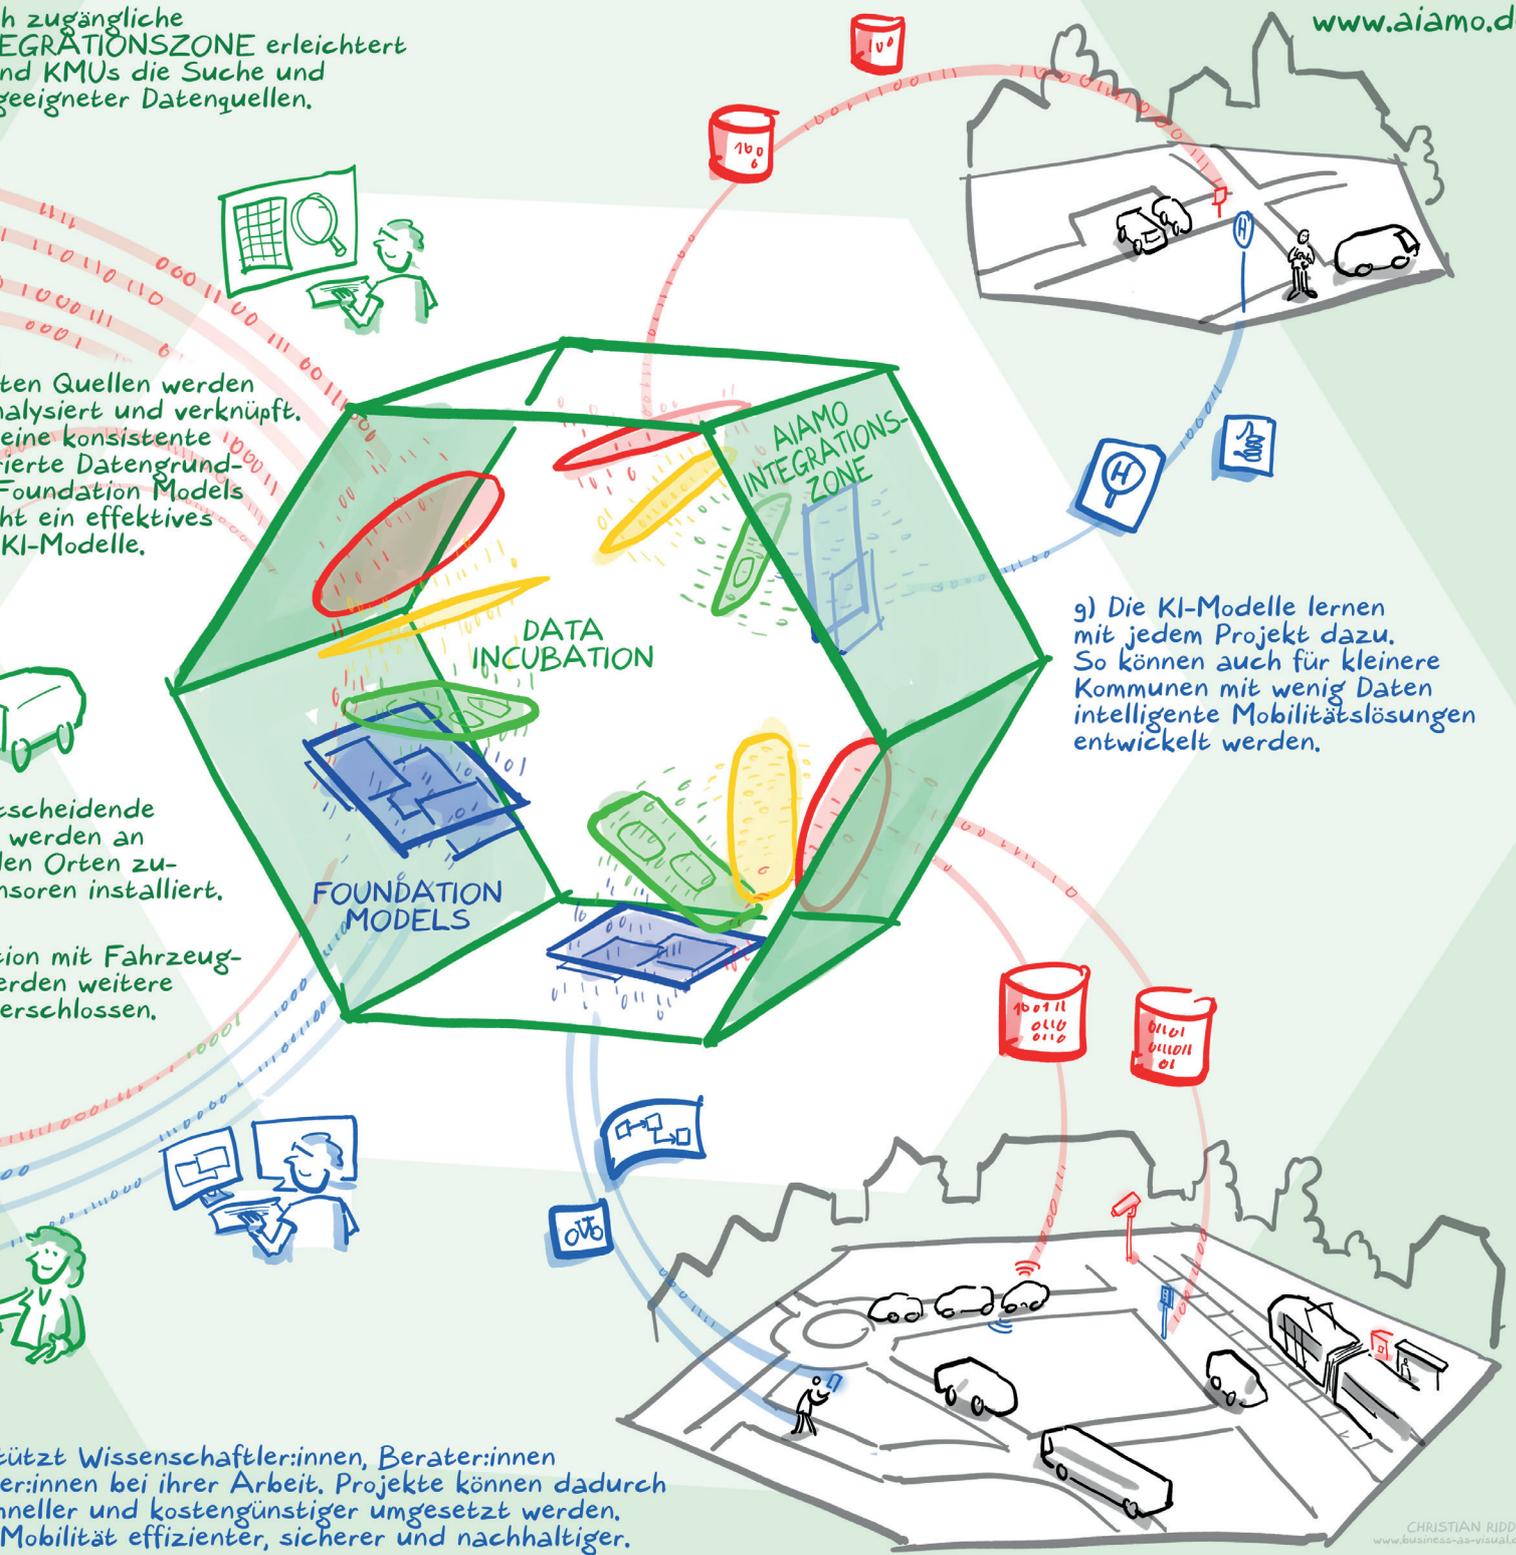
h zugängliche
EGRATIONSZONE erleichtert
nd KMUs die Suche und
geeigneter Datenquellen.

ten Quellen werden
analysiert und verknüpft,
eine konsistente
ierte Datengrund-
Foundation Models
ht ein effektives
KI-Modelle.

escheidende
werden an
en Orten zu-
nsoren installiert.

ion mit Fahrzeug-
werden weitere
erschlossen.

ützt Wissenschaftler:innen, Berater:innen
er:innen bei ihrer Arbeit. Projekte können dadurch
neller und kostengünstiger umgesetzt werden.
Mobilität effizienter, sicherer und nachhaltiger.



g) Die KI-Modelle lernen mit jedem Projekt dazu. So können auch für kleinere Kommunen mit wenig Daten intelligente Mobilitätslösungen entwickelt werden.



Gefördert durch:



aufgrund eines Beschlusses
des Deutschen Bundestages

