

# Künstliche Intelligenz in der automatisierten Mobilität



Version: 1.0



**BERGISCHE  
UNIVERSITÄT  
WUPPERTAL**



**HOCHSCHULE RUHR WEST**  
UNIVERSITY OF APPLIED SCIENCES

**BERGISCHE  
STRUKTUR-UND  
WIRTSCHAFTS-  
FÖRDERUNGS-  
GESELLSCHAFT**

**Geschäftsstelle Centrum für automatisierte Mobilität (CAMO)**

*c/o Bergische Universität Wuppertal*

*Rainer-Gruenter-Str. 21*

*42119 Wuppertal*

**Besucheradresse:**

*Lise-Meitner-Str. 27*

*42119 Wuppertal*

[www.camo.nrw](http://www.camo.nrw)

# KÜNSTLICHE INTELLIGENZ IN DER AUTOMATISIERTEN MOBILITÄT

## INHALTSVERZEICHNIS

<b>EINLEITUNG</b>	<b>7</b>
<b>KÜNSTLICHE INTELLIGENZ</b>	<b>8</b>
<b>WAS IST KI?</b>	<b>10</b>
<b>DEEP LEARNING UND KÜNSTLICHE NEURONALE NETZE</b>	<b>12</b>
<b>BESTANDTEILE EINES KI-SYSTEMS</b>	<b>14</b>
<b>DIE INTELLIGENTE KREUZUNG</b>	<b>16</b>
<b>CHANCEN UND HERAUSFORDERUNGEN</b>	<b>20</b>
<b>ZUSAMMENFASSUNG</b>	<b>21</b>
<b>LITERATUR</b>	<b>22</b>

## CAMO.NRW UNTERSTÜTZT KOMMUNALE AKTEURE

Die Entwicklung, Planung und Umsetzung der Mobilität von Morgen erfordert ein rasches Umdenken und Handeln, da der Transformationsprozess zu einem nachhaltigen Verkehrsraum der Zukunft langwierig sein wird.

Die Bewältigung dieser Aufgaben kann aber nur gelingen, wenn die verschiedenen Akteure im „Innovationssystem Mobilität“ (siehe Abbildung 1) zusammenwirken – von den Herstellern der Fahrzeuge und Technikkomponenten über die Kommunen, die Betreiber des ÖPNV und die Politik bis hin zu den Nutzer:innen der Mobilitätsangebote. Forschungs- und Beratungseinrichtungen liefern Grundlagenwissen, begleiten die Entwicklungen und geben wichtige Impulse für die Praxis. Intermediäre wie z.B. Wirtschaftsförderungen und Verbände unterstützen die Vernetzung der Akteure und vertreten deren Interessen.

Kommunen kommt in diesem andauernden Transformationsprozess eine zentrale Rolle zu. Eine ihrer Kernaufgaben ist es, bedarfsgerechte Mobilität für alle Bevölkerungsgruppen sowie die Wirtschaft sicherzustellen. Auf kommunaler Ebene müssen die Stadt- und Kreisverwaltungen zwei wichtige Aufgaben bewältigen:

- Zum einen übernehmen sie nach dem Regionalisierungsgesetz im Rahmen der Daseinsvorsorge die „Sicherstellung einer ausreichenden Bedienung der Bevölkerung mit Verkehrsleistungen im öffentlichen Personennahverkehr“ (§ 1 RegG).
- Zum anderen müssen sie die Finanzierung des ÖPNVs sicherstellen.

Kommunen sind somit zentrale Gestalter, Anbieter und Betreiber von Infrastruktur-, Verkehrs- und Mobilitätslösungen im Innovationssystem Mobilität.

Auch wenn die konkrete Zukunft der Mobilität in vielen Fällen noch unsicher ist, vernetzt und automatisiert wird sie auf jeden Fall sein. Da erfahrungsgemäß die damit verbundenen Planungs- und Umsetzungsprozesse langwierig sind, müssen sich Kommunen schon heute mit ihren spezifischen Mobilitätsbedarfen und Gestaltungsmöglichkeiten automatisierter Mobilität beschäftigen.

Gilt das nur für die Metropolen und Großstädte dieser Welt? Ganz sicherlich nicht. So zeigt eine Vielzahl von Beispielen von Städten und im ländlichen Raum, dass es auch in Deutschland sinnvolle Anwendungsmöglichkeiten automatisierter und vernetzter Mobilität mit einer Vielzahl positiver Effekte gibt. Es geht dabei nie darum, automatisierte Mobilität der Automatisierung oder der Vernetzung willen einzuführen. Das Ziel sollte immer sein, die (zukünftigen) kommunalen

Mobilitätsaufgaben mit Automatisierung und Vernetzung besser zu lösen als dies mit traditionellen Mitteln möglich ist. Dabei gibt es nicht den einen richtigen Weg, nicht die eine richtige Lösung. Ausgehend von einer Bedarfs- und Potenzialanalyse muss jede Kommune ihre eigenen Ziele, Strategien und Maßnahmen einer zukunftsfähigen Mobilität erarbeiten – automatisierte Mobilität kann ein Teil davon sein.

In Nordrhein-Westfalen müssen Kommunen den Weg zu einem nachhaltigen Verkehrsraum der Zukunft, welcher auch Automatisierte Mobilität berücksichtigt, nicht alleine bestreiten. Dafür wurde als zentrale Anlaufstelle das interdisziplinäre und anwendungsorientierte Zentrum für automatisierte Mobilität (camo.nrw) geschaffen. Mit unserem Leistungsangebot möchten wir kommunale Akteure mit Informations-, Beratungs- und Weiterbildungsangeboten versorgen, um sie bei der Einführung automatisierter und vernetzter Mobilitätslösungen vorzubereiten und zu unterstützen.

Diese Publikation ist Teil einer Themenheftreihe, die kontinuierlich aktualisiert und erweitert wird. Mehr Informationen unter [www.camo.nrw](http://www.camo.nrw).

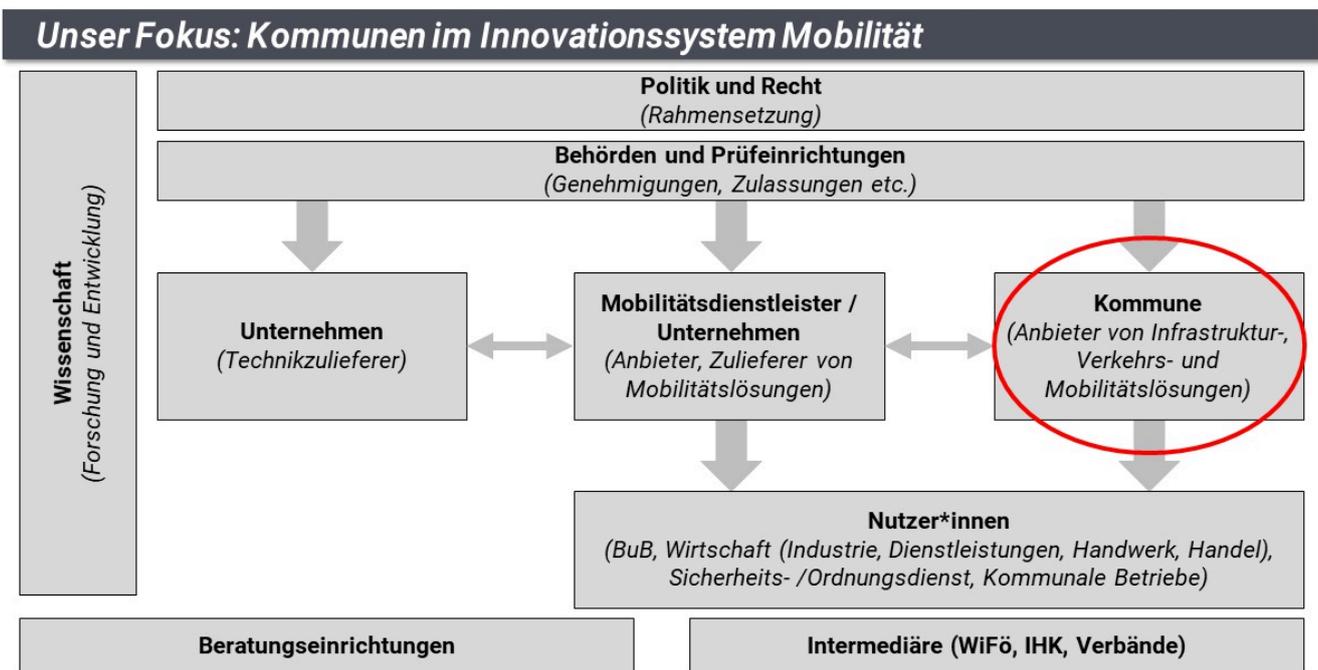


Abbildung 1: Akteure im Innovationssystem Mobilität.



## EINLEITUNG

Individualverkehr, öffentlicher Personennahverkehr (ÖPNV) und der Logistikverkehr werden durch den Einsatz künstlicher Intelligenz (KI) zunehmend automatisiert. Durch diese Automatisierung sollen zukünftig die Verkehrssicherheit erhöht und der Verkehrsfluss maximiert sowie Schadstoffemissionen gesenkt werden.

Ein Kompetenzaufbau im Themenfeld KI ist für Kommunen, als zentrale Gestalter, Anbieter und Betreiber von Infrastruktur-, Verkehrs- und Mobilitätslösungen, von hoher Bedeutung. Sie sind es, die Anforderungen an KI-Systeme formulieren und Potentiale für ihre Bürgerinnen und Bürger abschätzen und bewerten müssen.

In dem vorliegenden Themenheft werden grundlegende Informationen zum Themenfeld der künstlichen Intelligenz bereitgestellt sowie Einblicke in aktuelle Forschungs- und Entwicklungsprojekte gegeben. Zu diesem Zweck wird die Funktionsweise künstlicher Intelligenz erläutert, relevante Begriffe eingeführt und auf die Bestandteile eines KI-Systems eingegangen. Am Beispiel einer "intelligenten Kreuzung" werden die Erkenntnisse im kommunalen Kontext angewendet und vertieft. Intelligente Kreuzungen sind ein Wegbereiter der automatisierten Mobilität, da sie erste Vorteile der Anwendung von KI im kommunalen Umfeld erzielen, z.B. den Verkehrsfluss optimieren ohne das Vorhandensein von automatisierten Fahrzeugen vorauszusetzen. Abschließend werden Chancen und Herausforderungen für Kommunen diskutiert.

# KÜNSTLICHE INTELLIGENZ

Künstliche Intelligenz (KI) ist eine der am stärksten aufstrebenden Technologien der letzten Zeit. In den Bereichen Mobilität und Verkehr wird die KI in Zukunft maßgeblich zur Automatisierung und Steigerung der Effizienz beitragen. Die Entwicklung erster Komponenten intelligenter Systeme, welche auch heute noch verwendet werden, startete bereits 1943 (mehr dazu im folgenden Kapitel). Während die ersten automatisierten Fahrzeuge in den 1960er Jahren noch einer in der Fahrbahn eingelassenen Induktivleitung folgten (Keshav Bimbraw 2015), wurden bereits 1977 in Japan die ersten kamerabasierten Fahrerassistenzsysteme getestet (Graefe und Kuhnert 1992). Die Potentiale beim Einsatz von Methoden der künstlichen Intelligenz beim „Rechnersehen“ wurden zwar erkannt (Dickmanns et al. 1987), aber aufgrund der zu dieser Zeit noch beschränkten Rechnerleistung wurden überwiegend klassische Bildverarbeitungsmethoden angewendet. Erste (Forschungs-)Anwendungen zum automatisierten Lenken durch ein KI-System funktionierten nur bei sehr geringen Geschwindigkeiten (< 2 km/h; (D. Pomerleau 1988)).

2005 gelang es im Rahmen der DARPA Challenge (Buehler et al. 2007), ein Fahrzeug auf einer vereinfachten Strecke vollkommen autonom fahren zu lassen. Zwei Jahre später wurde die Herausforderung zu einer 100 km langen Fahrt in einem Mischverkehr unter Beachtung der geltenden Verkehrsregeln erweitert (Urmson und Whittaker 2008). Seitdem steigt die Verwendung von KI-Systemen in automatisierten Fahrzeugen stetig an. Aber auch im Bereich der Verkehrsüberwachung und -analyse können KI-Systeme helfen, große Datenmengen zu verarbeiten und beispielsweise drohende Kollisionen oder gefährliches Verhalten von Verkehrsteilnehmer:innen zu erkennen. In Zukunft werden sich durch die steigende Leistungsfähigkeit von KI-Systemen viele weitere Möglichkeiten eröffnen. Eine Verwendung von datengetriebenen KI-Systemen setzt jedoch die Berücksichtigung von Fairness, Datenschutz und Verständlichkeit voraus (siehe Infobox KI und die DSGVO). In der nationalen KI-Strategie (Referat Künstliche Intelligenz 2021) hat das Bundesministerium für Bildung und Forschung sich das Ziel gesetzt, Deutschland und Europa zu einem führenden KI-Standort zu machen. Ein Baustein ist der Aufbau einer intelligenten Infrastruktur für KI-Anwendungen, von der auch die öffentliche Verwaltung profitieren soll.

Viele Aspekte der automatisierten Mobilität profitieren schon heute vom Einsatz der KI. Beispiele reichen von Komfortfunktionen (Gesten- und Spracherkennung (T. Kopinski et al. 2015a; H. Detjen et al. 2020; Pablo Sauras-Perez 2017; Shu Wang et al. 2020; Joshua Wheeler 2019; Varun Totakura et al. 2021)) über Methoden zur Unterstützung der Fahraufgabe (Umfeld- und Fahrerzustandserkennung (Haselhoff et al.

2017; Koppers et al. 2020; T. Kopinski et al. 2015b; Haselhoff et al. 2021; Sorin Grigorescu et al. 2019; Kocić et al. 2019)) bis hin zu fahrzeugübergreifenden Themen (Verkehrsdatenanalyse und Verkehrssteuerung (Oyeyemi Olayode et al. 2020)).

## KI und die DSGVO

Die Datenschutzgrundverordnung regelt die Verarbeitung von personenbezogenen Daten. Da die Leistungsfähigkeit der KI maßgeblich auf Daten basiert, muss die DSGVO bei der Entwicklung von KI-Systemen berücksichtigt werden. Dabei sind vor allem Artikel 5, Artikel 22 und Artikel 32 von Bedeutung. Diese regeln die Grundsätze für die sichere Verarbeitung personenbezogener Daten (Transparenz, Datenminimierung, Vertraulichkeit, etc.) und Besonderheiten bei der automatisierten Verarbeitung.

## KI-PROJEKTE

Die Erprobung und Erforschung von KI-Anwendungen werden in Deutschland und der EU in vielen Projekten gefördert. Der Einsatz in sicherheitskritischen Anwendungsfeldern wie beispielsweise Mobilität setzt eine umfangreiche Erprobung und Validierung der Methoden voraus (Sebastian Houben et al. 2021). Durch die Komplexität und fehlende Nachvollziehbarkeit der exakten Funktionsweise von künstlicher Intelligenz muss sie gegen ungewolltes Verhalten abgesichert werden.

In urbanen Gebieten werden automatisierte Fahrfunktionen aufgrund des komplexen Verkehrsgeschehens mit vielen unterschiedlichen Szenarien konfrontiert. Statt einer fest definierten Umgebung, wie sie auf Autobahnen vorhanden ist (kein Querverkehr, getrennte Richtungsfahrbahnen, keine Kreuzungen etc.), treffen im städtischen Umfeld viele unterschiedliche Verkehrsteilnehmer:innen und Mobilitätsformen aufeinander. Aufgrund der Komplexität automatisierter Mobilität im urbanen Raum befassen sich seit dem Jahr 2000 bereits viele Forschungsprojekte mit diesem Thema. Ein Auszug aktueller Projekte wird in Abbildung 2 dargestellt. Das Projekt Ko-HAF beispielsweise befasste sich mit der Automatisierung bei hohen Geschwindigkeiten und ohne querenden Verkehr. Da der Weg zum automatisierten Fahren ein Prozess ist, bei dem der Mensch zunächst noch als Rückfallebene bei Fehlverhalten der Automatisierungsfunktion zur Verfügung stehen muss und er die Verantwortung für das Fahrzeug trägt, befassen sich die Projekte ADAS&me und VI-DAS mit

der Einbindung des Fahrer:innenzustandes in die Fahrfunktion.

Die Grundlage von künstlicher Intelligenz bilden Daten, welche zum Anlernen genutzt werden. Erst durch das Wissen aus den Daten werden die Funktionen "intelligent". Die Projekte KI Delta Learning und KI Wissen, welche aus der VDA Leitinitiative autonomes und vernetztes Fahren entstanden sind, erforschen, wie dieses Wissen effizienter genutzt und bereits vorhandenes Wissen verwendet werden kann. Mit künstlich erstelltem Wissen durch Computersimulationen von Verkehrssituationen kann das Wissen, wie in den Projekten KI Data Tooling, REACT, Cloud LSVA gezeigt, einfach erweitert werden. Die Absicherung und Verifikation von KI-Funktionen sind aufgrund der Komplexität der KI und des Umfelds nicht trivial, sodass eine Absicherung nur für festgelegte Anwendungsgrenzen („Operational Design Domain, OOD“) durchgeführt wird. In vielen Projekten werden deshalb Methoden für eine Sicherstellung der richtigen Funktionsweise der KI-Anwendungen entwickelt.

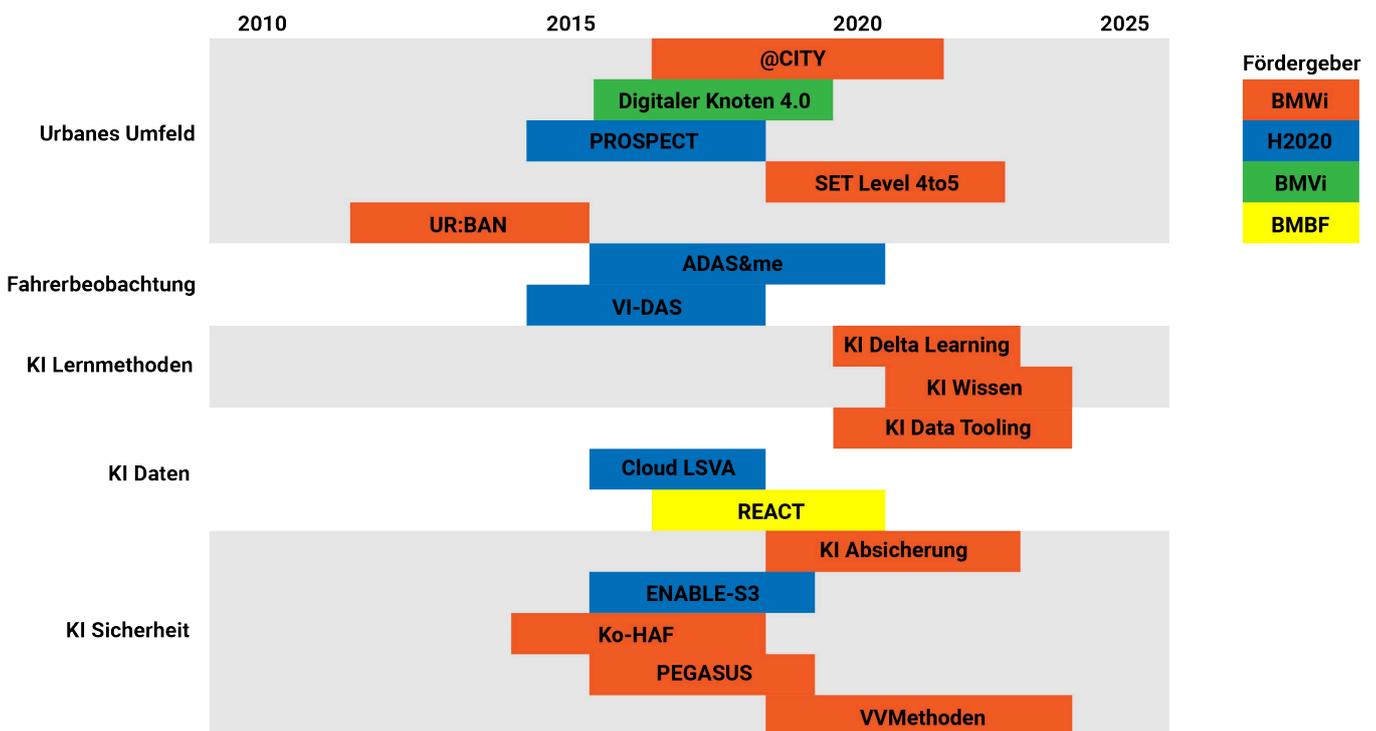


Abbildung 2: KI-Projekte mit Bezug zur automatisierten Mobilität in Deutschland und der EU der letzten Jahre. Quelle: Eigene Darstellung.

## WAS IST KI?

Grundlegend beschreibt die künstliche Intelligenz ein System, dem menschenähnliche Fähigkeiten zugeordnet werden. Dabei werden menschliche, intelligente Verhaltensweisen in einem Modell nachgebildet. Die menschliche Intelligenz bezeichnet die kognitiven Fähigkeiten, das Umfeld wahrzunehmen und die Informationen weiterzuverarbeiten (Weber und Burchardt 2017). Die Verarbeitung der Informationen aus den Wahrnehmungssinnen findet dabei im Gehirn statt. Dieses setzt sich aus mehr als 85 Milliarden Nervenzellen (Azevedo et al. 2009) – auch Neuronen genannt – zusammen. Durch die Vernetzung und Kommunikation dieser Nervenzellen untereinander wird das Gehirn erst leistungsfähig und kann erhaltene Informationen speichern oder in Bewegungsbefehle an die Muskeln umsetzen.

Die Modellierung eines künstlichen Neurons wurde 1943 von McCulloch und Pitts vorgestellt (Warren S. McCulloch und Walter Pitts 1943). Dieses vereinfachte Modell erlaubt die Verarbeitung einfacher Informationen (binäre Signale). Ebenso wie bei den menschlichen Nervenzellen wird durch die Vernetzung vieler künstlicher Neuronen eine Verarbeitung von komplexen Informationen möglich (mehr dazu im Kap. Deep Learning und künstliche neuronale Netze).

Die Fähigkeiten einer künstlichen Intelligenz werden in zwei Kategorien unterteilt (Weber und Burchardt 2017): eine sogenannte starke KI besitzt mindestens gleichwertige, wenn nicht sogar bessere kognitive Fähigkeiten wie sie einem Menschen zugeschrieben werden. Eine schwache KI beschränkt sich auf die Lösung eines konkreten Anwendungsproblems. Derzeit fallen alle praxisrelevanten KI-Systeme in die Klasse der schwachen KI-Systeme, weshalb wir uns in diesem Themenheft auf diese beschränken.

Der Begriff der künstlichen Intelligenz wird heute häufig gleichbedeutend mit maschinellem Lernen oder Deep Learning verwendet, die Begriffe haben jedoch eine unterschiedliche Bedeutung (siehe Abbildung 3). Während Systeme, die der KI zugerechnet werden, allgemeine Systeme beschreiben, die ihre Aufgaben selbstständig lösen können, spricht man beim maschinellen Lernen von Systemen, die ihre Entscheidungsregeln auf Basis der Beobachtung von Daten selbstständig erstellt haben. Aus den Daten werden also automatisierte Entscheidungsregeln abgeleitet und im Gegensatz zu durch Menschen erstellten Regeln (regelbasierte Datenverarbeitung), können diese Systeme sehr leicht und automatisiert auf neue Gegebenheiten angepasst werden. Eine Unterkategorie des maschinellen Lernens ist das Deep Learning unter welchen die Nutzung sogenannter künstlicher neuronaler Netze fällt. Diese Netze verwenden das menschliche Gehirn

### Intelligenz von Maschinen

Alan Turing stellte sich 1950 die Frage, ab wann ein System als intelligent bezeichnet werden kann und definierte so den nach ihm benannten Turing-Test. Wenn bei einem Dialog (schriftlich, da nicht anhand von Erscheinungsbild oder Stimme entschieden werden kann) das künstliche System nicht von einer menschlichen Dialogpartnerin oder einem Dialogpartner unterschieden werden kann, so kann dieses als intelligent bezeichnet werden.

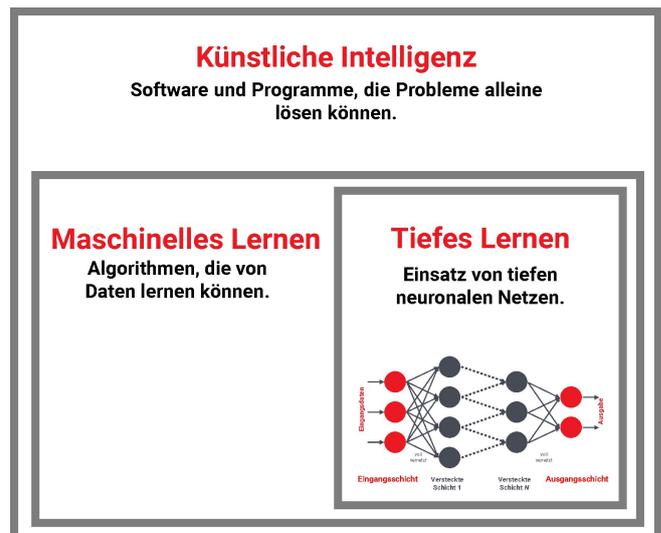


Abbildung 3: Begrifflichkeiten der künstlichen Intelligenz.

Quelle: Eigene Darstellung.

als biologisches Vorbild und bestehen aus einzelnen Neuronen. Im Vergleich zu anderen Methoden haben sich die neuronalen Netzwerke als besonders leistungsfähig im Umgang mit großen Datenmengen erwiesen. Aufgrund der immer weiter steigenden Rechenleistung können diese Netzwerke zunehmend vergrößert werden (Anzahl von Neuronen und Verbindungen) und so in speziellen Anwendungsbereichen eine mit Menschen vergleichbare Leistungsfähigkeit erreichen. Man spricht in diesem Fall von tiefen neuronalen Netzen.

## MASCHINELLES LERNEN

Maschinelles Lernen bzw. ein lernendes System extrahiert Wissen (Regeln) aus Erfahrungen, welche in Form von Daten vorliegen. Dabei ist ausschlaggebend, dass die Regeln nicht explizit benannt werden und das Wissen auch in einem gewissen Rahmen verallgemeinert werden kann. Als Beispiel für die Verallgemeinerung bzw. Generalisierungsfähigkeit soll hier ein Erkennungssystem für Fußgänger:innen dienen. Der Erfahrungsschatz (Trainingsdaten) des lernenden Systems beschränkt sich auf Daten einer begrenzten Anzahl von Fußgänger:innen, die das System für das Lernen verwenden kann. Für den Einsatz in der Praxis ist es allerdings notwendig, auch Fußgänger:innen zu erkennen, die nicht Teil des Erfahrungsschatzes sind. Das lernende System muss also auch mit ungesehenen Daten umgehen können, sprich: generalisieren können.

Je nach Anwendungsfall und Datenlage kommen verschiedene Lernstile zum Einsatz, die sich am menschlichen Vorbild orientieren. Im Kontext eines KI-Systems spricht man auch vom Trainingsprozess, der eine Anpassung des KI-Systems an die Daten ermöglicht. Die am häufigsten verwendeten Lernstile sind das überwachte, unüberwachte und bestärkende Lernen.

- Der Mensch als Lehrender: Beim überwachten Lernen wird dem KI-System für jede Eingabe die gewünschte, wahre Ausgabe (Annotation) präsentiert. Die Parameter des Systems werden beim Lernen durch Algorithmen so optimiert, dass die Ausgabe des Systems sich der gewünschten Ausgabe annähert. Die Parameter repräsentieren die Regeln/Merkmale der Entscheidungsfindung (bspw. Formen und Farben bei der Erkennung von Straßenverkehrsschildern). Beispiele für das überwachte Lernen sind die Klassifikation, Regression (vgl. Infobox Modellvarianten), Objekterkennung oder Textübersetzung.
- Strukturen finden: Im Vergleich zum überwachten Lernen liegt beim unüberwachten Lernen keine Annotation der gewünschten Ausgabe vor. Aufgabe des KI-Systems ist es, Gemeinsamkeiten in den Daten zu finden. Diese können dadurch gruppiert (Clustering, vgl. Infobox Modellvarianten) und Anomalien in den Eingaben detektiert werden.
- Lernen durch Belohnung: Bestärkendes Lernen wird verwendet, um Systeme (Agenten) zu trainieren, die durch eine Interaktion mit der Umwelt geprägt sind und in dieser Umwelt Entscheidungen treffen müssen. Als Agent wird ein eigenständig handelndes (lernendes) Softwaresystem

### Modellvarianten

Die Klassifikation bezeichnet eine kategorische Einordnung der Eingangsdaten. Dies kann beispielsweise ein klassischer Spam-Filter sein, der E-Mails anhand von Merkmalen (Sender, Schlagwörtern, ...) verschiedenen Kategorien (E-Mail- oder Spamordner) zuordnet. Auf Bilddaten angewendet lassen sich mit diesem Verfahren die Bilder ganzheitlich kategorisieren (z. B. in Bilder mit Fußgänger:innen oder Bilder mit Fahrzeugen). Falls zusätzlich noch eine Positionsinformation der Objekte bestimmt wird, spricht man auch von einer Objekterkennung (siehe Objekterkennung). Eine Klassifikation eignet sich auch für die Ermittlung frei befahrbarer Verkehrswege für das automatisierte Fahren. In diesem Kontext spricht man auch von einer semantischen Segmentierung. Das Clustering beschreibt die Zuordnung der Daten in nicht vorher bekannte Gruppen und gehört somit zu den unüberwachten Lernverfahren. Im Gegensatz zur Klassifikation und dem Clustering werden bei der Regression numerische Werte bestimmt. Dies können zum Beispiel Börsenkurse, Verkehrsstärke, -dichte oder Geschwindigkeitswerte sein.

bezeichnet. Jede Handlung des Agenten wird mittels einer Bewertungsfunktion "belohnt". Ziel des Agenten ist es, die durch die Aktionen erhaltene Gesamtbelohnung zu maximieren. Ein solcher Agent könnte zum Beispiel ein automatisiertes Fahrzeug steuern. Wird das Fahrzeug in der Spurmitte gehalten, erhält der Agent eine Belohnung, bei einer Abweichung oder einem Unfall eine Bestrafung (negative Belohnung). Mit dem Ziel, die Gesamtbelohnung zu maximieren, wird der Agent versuchen durch, seine Aktionen das Fahrzeug immer in der Spurmitte zu halten.

# DEEP LEARNING UND KÜNSTLICHE NEURONALE NETZE

Basiert ein KI-System auf einem (tiefen) neuronalen Netzwerk, so spricht man von Deep Learning. Als ein Teilgebiet des maschinellen Lernens weist Deep Learning derzeit bei komplexen Daten und Aufgaben oft die beste Leistungsfähigkeit auf. Dieser Schub an besserer Leistung im Vergleich zu anderen Verfahren des maschinellen Lernens basiert vor allem auf der Menge der verfügbaren Daten, mit denen die Systeme trainiert werden, und der hohen Zahl an verfügbaren Parametern der neuronalen Netzwerke.

Basierend auf den Arbeiten von McCulloch und Pitts, welche 1943 mit ihrer vereinfachten Modellierung eines Neurons die Umsetzbarkeit solcher Komponenten aufzeigten, wurde von Rosenblatt das sogenannte Perzeptron (siehe Infobox: Das Perzeptron) entwickelt (Rosenblatt 1957).

Werden zwischen der Eingabe- und Ausgabeschicht des Perzeptrons noch weitere Schichten eingefügt, spricht man von einem mehrlagigen Perzeptron. Zwischen zwei Schichten sind die einzelnen Neuronen mit Gewichten miteinander verbunden und ergeben das künstliche neuronale Netzwerk (siehe Abbildung 5). Jedes Neuron löst dabei eine einfache Aufgabe, welche durch das Lernen erst dynamisch bestimmt wird. Durch die Verknüpfung vieler Neuronen lassen sich so komplexe Zusammenhänge abbilden und vielschichtige Eingaben verarbeiten.

Werden die Informationen im Netzwerk nur vorwärts von der Eingabeschicht zur Ausgabe geleitet, spricht man von einem vorwärtsgerichteten Netzwerk. Das ein- oder mehrlagige Perzeptron ist zum Beispiel ein solches. Diese Netzwerke werden hauptsächlich beim überwachten Lernen und bei nicht zeitlich zusammenhängenden Daten eingesetzt. Zur Abbildung einer zeitlichen Komponente, werden zwischen den Schichten Rückverbindungen zu einer der vorherigen Schichten eingebaut. Solche Netzwerke bezeichnet man als rekurrente Netzwerke. Durch die Rückverbindungen können zeitliche Abfolgen besser vorhergesagt werden, da sich das Netzwerk an vorherige Eingaben "erinnern" kann. Sie werden vor allem bei der Text- und Sprachverarbeitung sowie beim Verfolgen von Objekten eingesetzt. Im Gegensatz zu dem normalen mehrlagigen Perzeptron werden bei einem Faltungsnetzwerk die Gewichte in Form von sogenannten Filtern mehrfach genutzt, um wiederkehrende Muster in den Daten abzubilden. Faltungsnetzwerke werden dort eingesetzt wo innerhalb der Eingangsdaten ein örtlicher (z.B. Bilddaten) oder zeitlicher Zusammenhang (z.B. Audiodaten) gegeben ist und somit die Muster mehrfach in den Daten (z.B. ein konkretes Eingangsbild bei dem vier Reifen eines Autos sichtbar sind) vorkommen können. In Abbildung 4 sind die gelernten Filter

eines Netzwerkes abgebildet, welches auf Bilddaten trainiert wurde. Muster in tieferen Schichten repräsentieren komplexe und hierarchisch aufgebaute Merkmale. Während in den vorderen Schichten einfache Merkmale wie Kanten oder Farben erkannt werden, werden diese Merkmale in tieferen Schichten zu Mustern wie Gesichtern oder Formen zusammengefasst.

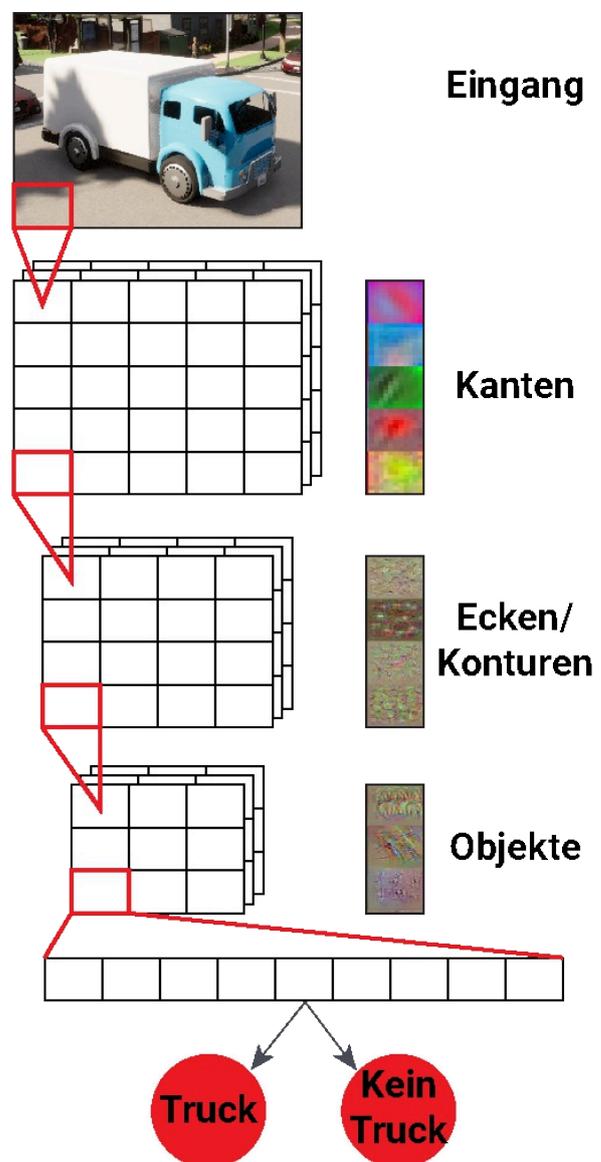


Abbildung 4: In einem Faltungsnetzwerk repräsentierte Merkmale nach Tiefe der Schicht aufgeschlüsselt. In den vorderen Schichten werden einfache Muster und Merkmale wie Kanten oder Farben repräsentiert. In tieferen Schichten werden diese zu komplexeren Merkmalen zusammengefasst.  
Quelle: Eigene Darstellung.

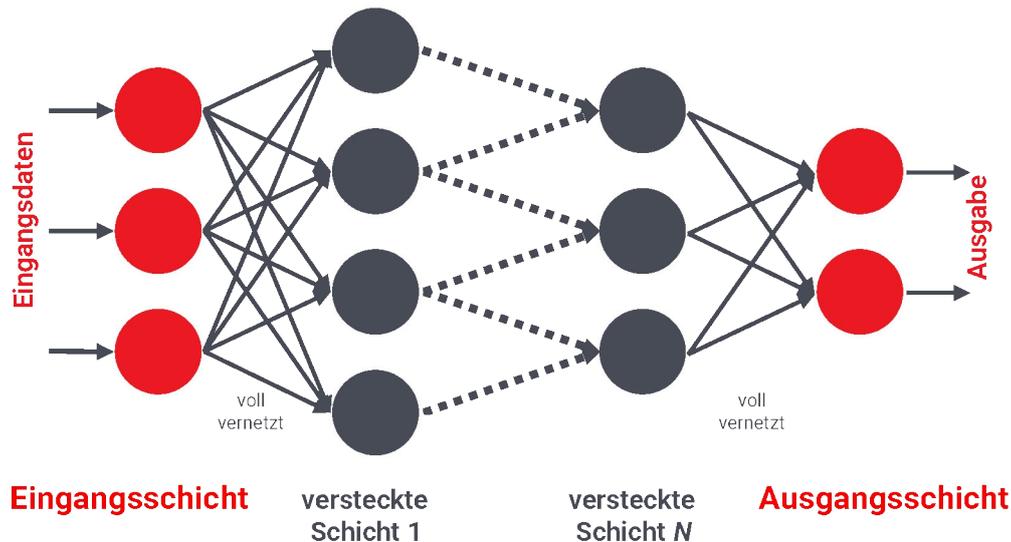


Abbildung 5: Aufbau eines künstlichen neuronalen Netzwerkes mit einer Eingangsschicht (links), einer Ausgangsschicht (rechts) und den dazwischen liegenden versteckten Schichten. Quelle: Eigene Darstellung.

### Das Perzeptron

Abbildung 6: Perzeptron. Quelle: Eigene Darstellung.

Das Perzeptron (siehe Abbildung 6) besteht aus einem einzigen Neuron und arbeitet nach dem bekannten EVA-Prinzip, jedoch mit dem Unterschied, dass die Regeln der Verarbeitungsschicht erst durch das Training bestimmt werden. Die "Regeln" des Perzeptrons werden durch die Gewichte  $w_n$  (auch Parameter genannt) definiert, welche mit den Eingangswerten  $x_n$  multipliziert werden. Eine Aktivierungsfunktion bestimmt anhand der Summe der gewichteten Eingangswerte die Ausgabe des Perzeptrons. Die einfachste Aktivierungsfunktion ist ein Schwellwert. Wird dieser erreicht oder überschritten, gibt das Perzeptron als Funktionsausgang  $y=1$  aus, ansonsten  $y=0$ . Diese binäre Entscheidungsfunktion kann genutzt werden, um beispielsweise einem Bild die Kategorie Fußgänger:in oder Fahrzeug zuzuordnen. Durch die Verwendung anderer Aktivierungsfunktionen können anstatt der kategorischen Werte auch numerische Werte (bspw. ein Geschwindigkeitswert) bestimmt werden.

### EVA-Prinzip

Das EVA-Prinzip (Eingabe–Verarbeitung–Ausgabe) beschreibt das Grundscheema der Datenverarbeitung. Es ist grundsätzlich zustandslos, d. h. jede Eingabe wird unabhängig der vorherigen verarbeitet. Beispielhaft lässt sich dieses bei Texteingabe am Computer zeigen. Die Eingabe beschreibt den Tastendruck an der Tastatur. Anschließend verarbeitet die Recheneinheit des Computers diese Eingabe, indem sie diese analysiert und einem Programm (zum Beispiel einem Textverarbeitungsprogramm) zuordnet. In der Ausgabe wird der neue Text dann als Ergebnis auf dem Bildschirm angezeigt.

## BESTANDTEILE EINES KI-SYSTEMS

Um ein KI-System für eine Problemstellung zu entwickeln, müssen zunächst die Anforderungen und die dafür in Frage kommenden Datenquellen (z. B. Sensoren) erarbeitet werden. Bei einer Verkehrsüberwachung von Fahrzeugen eignen sich meistens Kameras sowie LiDAR- und Radar-Sensoren. Die aus der Quelle gewonnenen Daten werden in einer Datenauswahl auf die Anforderungen geprüft und vorselektiert. Je nach Aufgabe können auch bereits vorhandene Datensätze verwendet werden. Anschließend werden im Training die Parameter des KI-Systems so lange optimiert, bis bei der Evaluation die in den Anforderungen spezifizierte Genauigkeit erreicht wird. Dieser Prozess lässt sich nach einer Inbetriebnahme wiederholen, um auf veränderte Randbedingungen zu reagieren oder neu erworbene Daten zu integrieren. Sobald das Modell den Anforderungen entspricht, kann dieses in Betrieb genommen werden. Für eine wertschöpfende Nutzung von Fahrzeug-, Mobilitäts- und Verkehrsdaten werden leistungsfähige und skalierbare KI-Systeme, inklusive der zugehörigen IT-Infrastruktur sowie eines effizienten Daten-

managements, benötigt. Eine Grundvoraussetzung und zugleich Hürde für die Entwicklung digitaler Services und Produkte in der Kommune ist der Aufbau geeigneter Datenbanken. In Abbildung 7 sind die einzelnen Bestandteile des KI-Systems aufgelistet und deren Abhängigkeiten dargestellt.

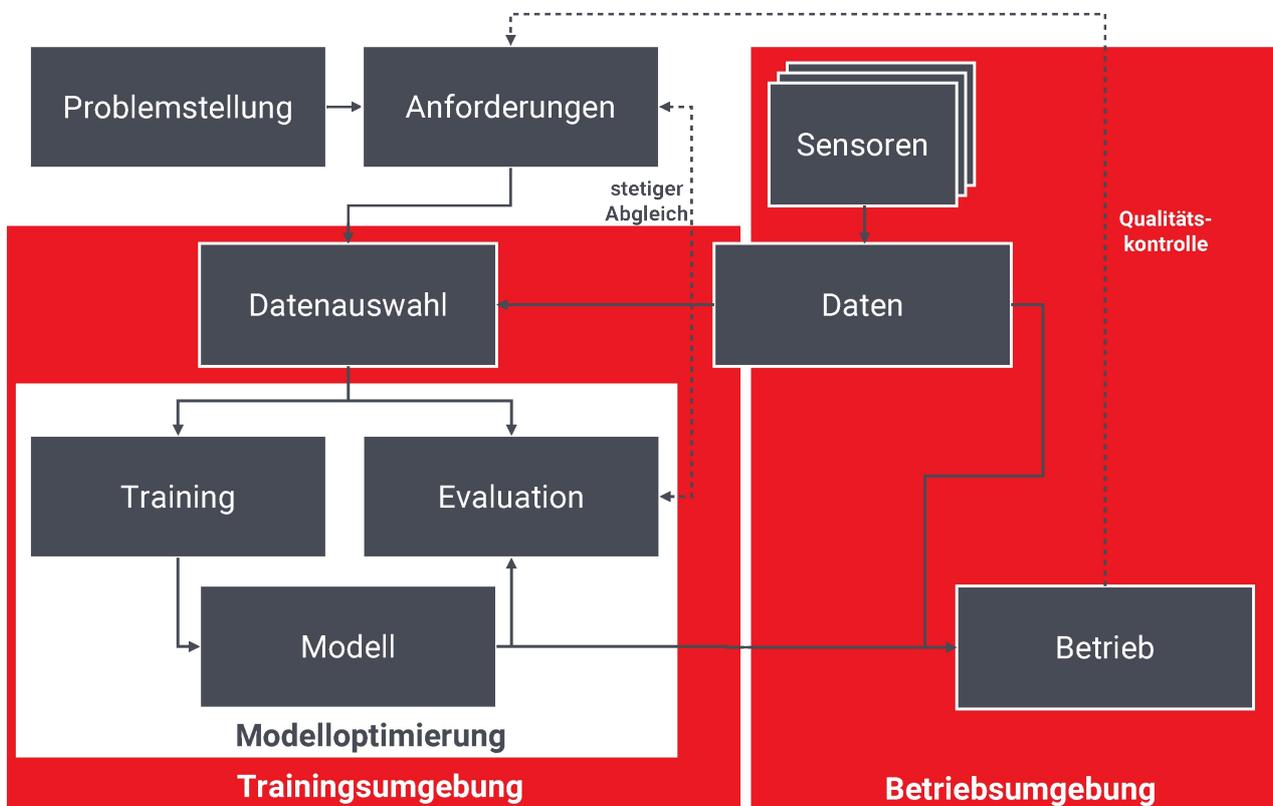


Abbildung 7: Bestandteile eines KI-Systems, unterteilt in die Trainings- und Betriebsumgebung. In der Trainingsumgebung wird die Basis des KI-Systems (das Modell bzw. Netzwerk) mit ausgewählten Daten der Sensoren angeleitet. In der Betriebsumgebung kann dieses dann mit den Sensordaten die Aufgaben des Anwendungsfalls bearbeiten. Quelle: Eigene Darstellung.

## INFRASTRUKTUR

Das Training von künstlichen neuronalen Netzen ist aufgrund der schieren Größe der Netze und der damit hohen Zahl an nötigen mathematischen Operationen sehr rechenintensiv. Grafikkarten (GPUs) eignen sich hervorragend für diese Aufgabe, da sie, im Gegensatz zu den seriell arbeitenden Hauptprozessoren (CPUs), viele kleine parallel nutzbare Recheneinheiten besitzen. Ursprünglich wurden GPUs entwickelt, um grafiklastige Berechnungen zu beschleunigen. Es stellte sich jedoch heraus, dass sich damit auch andere rechenintensive Aufgaben wie Deep Learning sehr gut bearbeiten lassen. Darüber hinaus existieren Recheneinheiten, die speziell für KI-Anwendungen mit z.B. hohem Speicherbedarf konzipiert wurden. Zur Vermeidung der hohen Anschaffungskosten der Trainingshardware bieten kommerzielle Cloud Anbieter das Training über ihre Online-Cluster an. Auch zum Betrieb von KI-basierten Funktionen muss eine geeignete IT-Infrastruktur (niedrige Latenz bei Echtzeitanwendungen, geringes Ausfallrisiko durch z. B. Redundanz, Sicherheitsvorkehrungen gegen unbefugten Zugriff etc.) vorhanden sein. Der Betrieb erfordert im Allgemeinen nicht dieselbe Rechen- oder Speicherkapazität wie der Trainingsprozess, dennoch werden dedizierte GPUs oder KI-Chips benötigt. Je nach Anwendungsfall eignet sich eine zentrale oder dezentrale Herangehensweise. Während bei dem zentralen Ansatz (siehe Abbildung 8) ein zentrales Rechenzentrum für viele Sensoren zuständig ist, besitzt beim dezentralen Ansatz (siehe Abbildung 9) jeder Sensor (oder eine Gruppe von Sensoren) eine eigene Verarbeitungseinheit (so genanntes Edge Computing). Das ist vor allem bei zeitkritischen Anwendungen von Vorteil, da die Sensordaten nicht übertragen, sondern ressourcenschonend an Ort und Stelle verarbeitet werden.

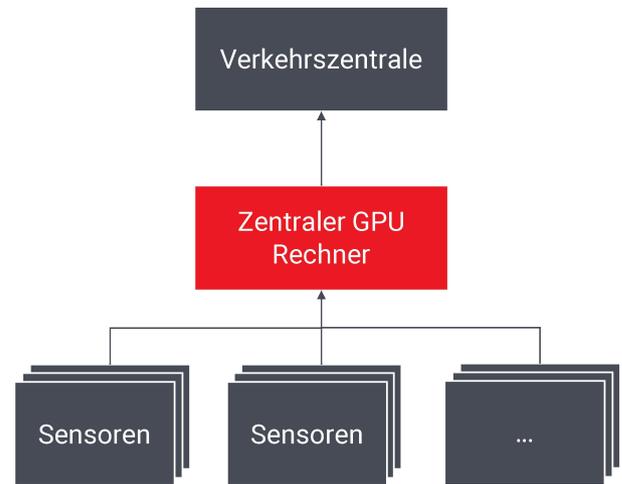


Abbildung 8: Zentrale Anbindung von KI-Anwendungen. Quelle: Eigene Darstellung.

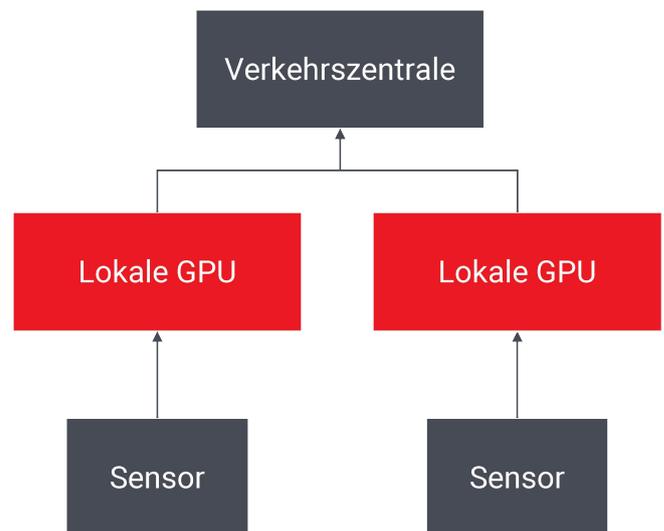


Abbildung 9: Dezentrale Anbindung von KI-Anwendungen. Quelle: Eigene Darstellung.

## DIE INTELLIGENTE KREUZUNG

An einer intelligenten und vernetzten Kreuzung werden viele Themenbereiche der künstlichen Intelligenz vereint. Intelligente Kreuzungen sind als ein Baustein für die Digitalisierung der Verkehrsinfrastruktur zu verstehen und bilden die Basis für eine mehrschichtige, intelligente Verkehrssteuerung (siehe Abbildung 10). Durch die Ausrüstung von neuralgischen Verkehrsknoten (z. B. unfallträchtige Kreuzung) mit Sensoren und einer Kommunikationstechnik sowie der Einführung automatisierter Fahrzeuge und einer Vernetzung mit weiteren Verkehrsteilnehmer:innen wird die Menge an Echtzeit-Verkehrsdaten massiv zunehmen. Die intelligente Analyse dieser Verkehrsdaten mit maschinellen Lernverfahren und Deep Learning ermöglicht sowohl eine Optimierung der Verkehrslage auf lokaler (Knotensteuerung, Grüne Welle) als auch auf globaler Ebene (gesamte Verkehrssituation, Netzmanagement). Von der Analyse und Prognose profitieren nicht nur die Effizienz des Verkehrs, sondern auch die Verkehrssicherheit. Zusätzlich kann die intelligente Kreuzung dazu beitragen, die Einführung automatisierter Fahrzeuge zu beschleunigen, da die Umfelderkennung dieser Fahrzeuge durch die Informationen der Infrastruktursensorik entlastet bzw. erweitert wird. Die Verkehrsdaten bieten darüber hinaus wertvolle Informationen für eine Verkehrsplanung, da beispielsweise Spitzenstunden und das tägliche Verkehrsaufkommen präzise erfasst werden können.

### PROJEKTE

In Deutschland wurden einige Kreuzungen in Pilotprojekten mit entsprechender Sensorik ausgestattet, um den Betrieb im Mischverkehr mit automatisierten und nichtautomatisierten Fahrzeugen sowie Fußgänger:innen und Radfahrer:innen zu erproben. Im Rahmen des Projektes "Digitaler Knoten 4.0" des DLR (Kaul et al. 2019) wurde das digitale Testfeld AIM (Anwendungsplattform Intelligente Mobilität) umgesetzt. Dabei wurden unterschiedliche Verkehrsbereiche, wie Kreuzungen und Bahnübergänge, in Braunschweig mit unterschiedlicher Sensorik und Kommunikationstechnik ausgestattet, um den Verkehr zu erfassen und entsprechend der aktuellen Verkehrslage optimiert leiten zu können. In dem vom BMWi geförderten Projekt Ko-PER (Reiner Wertheimer, WM&C) wurden die erfassten Daten der Infrastruktur- sowie Fahrzeugsensoren fusioniert. Dadurch ist es möglich, ein umfassenderes Abbild des Umfeldes zu erhalten. Mit Hilfe dieses Abbildes (digitaler Zwilling) konnten die vernetzten Fahrzeuge auch Verkehrsteilnehmer:innen erfassen, welche sich nicht im Sichtbereich der eigenen Fahrzeugsensorik befinden. Im Projekt KoMoD (BMVI - Kooperative Mobilität im digitalen Testfeld Düsseldorf – KoMoD 2021) arbeiteten 16 Partner aus Industrie und Forschung sowie Verkehrsbetreiber

zusammen daran, in Düsseldorf ein Testfeld für automatisiertes und vernetztes Fahren zu erproben. Dabei wurden intelligente Lichtsignalanlagen eingerichtet, welche mittels einer hybriden Kommunikation mit den Verkehrsteilnehmer:innen und dem Einsatz von künstlicher Intelligenz den Verkehr regeln. Durch Funkeinheiten am Straßenrand wurden den Fahrzeugen die Karteninformationen sowie die Signalphasen übermittelt.

### ANWENDUNGSBEISPIEL: KI ZUR VERMEIDUNG VON KOLLISIONEN AN KREUZUNGEN

Kreuzungen weisen mit 15 % (Pschenitza und Michael 2017) aller Unfälle in Deutschland ein sehr hohes Unfallrisiko auf. Häufig ist das Übersehen des querenden Verkehrs die Ursache. Durch die umliegende Bebauung sind Kreuzungsbereiche im innerstädtischen Bereich oft nicht vollständig einsehbar. Mit einer Umfelderkennung und der Vorhersage von zukünftigem Verhalten der anderen Verkehrsteilnehmer:innen (Trajektorienvorhersage) kann querender Verkehr frühzeitig erkannt und vor ihm gewarnt werden. Die dazu notwendige Kommunikation kann durch eine Fahrzeug-zu-Infrastruktur Kommunikation oder eine digitale Beschilderung geschehen. Die Verwendung von infrastrukturseitiger Sensorik ermöglicht eine bessere Einbindung von Fahrzeugen, welche nicht über automatisierte Fahrfunktionen oder eine Kommunikationsschnittstelle verfügen, da auch über die Infrastruktur kommuniziert werden kann (dynamische Verkehrszeichen oder Lichtsignale). Um die Kreuzung mit Hilfe der künstlichen Intelligenz sicher zu gestalten, müssen die einzelnen Bestandteile des KI-Systems bestimmt werden (siehe Abbildung 7). Der Aufbau der beiden benötigten KI-Modelle für eine Objekterkennung und Trajektorienvorhersage unterscheidet sich grundlegend. Die Funktionsweise wird in den folgenden Abschnitten näher erläutert.

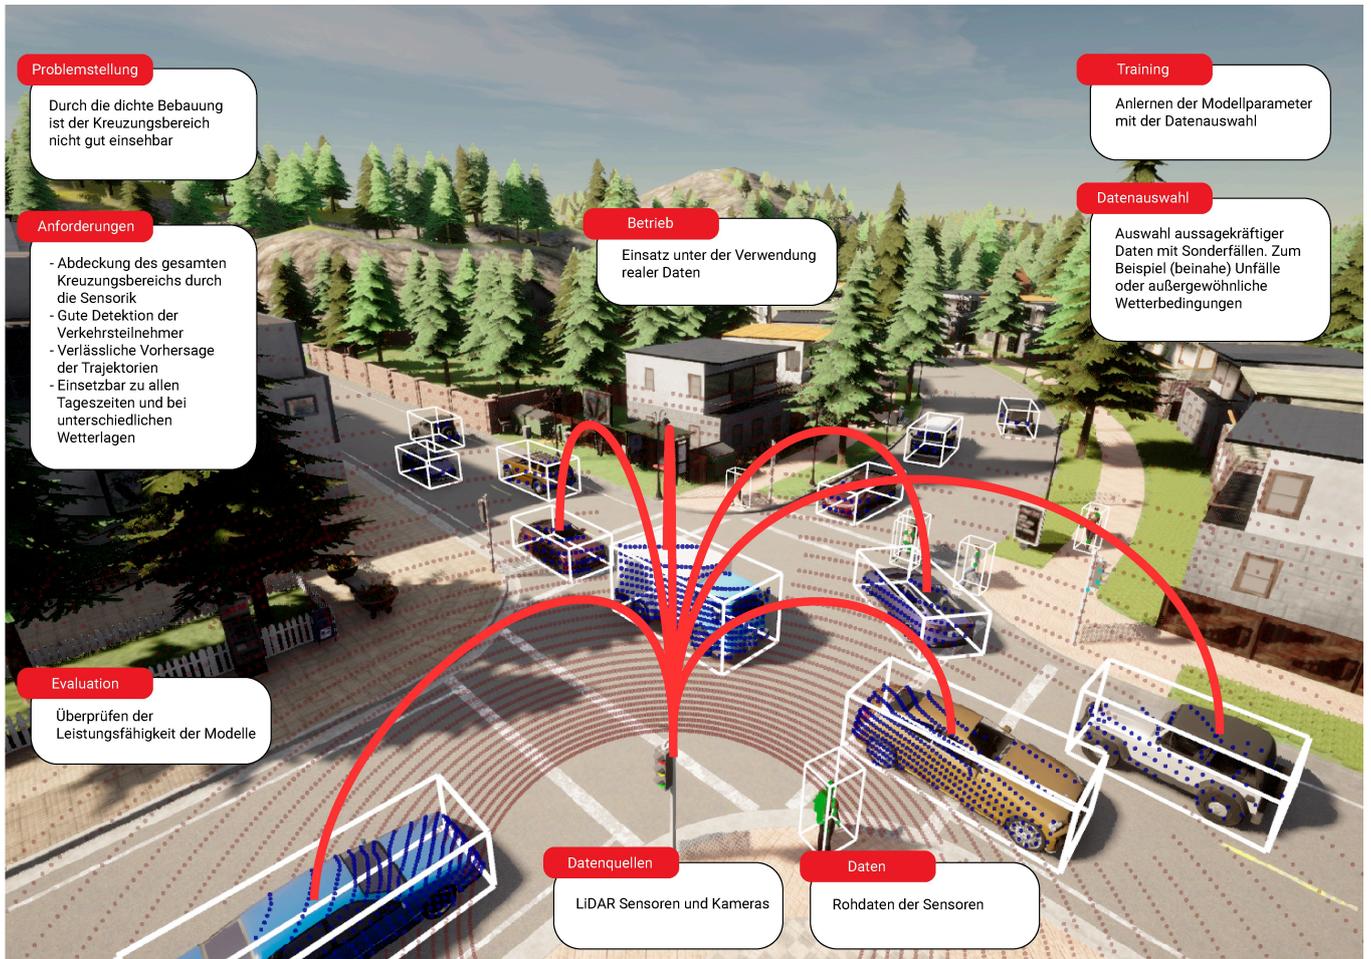


Abbildung 10: Beispielhafte Umfelderkennung an einer Kreuzung mit einem auf einer Ampel montierten LiDAR Sensor. Durch eine Kommunikationsschnittstelle werden die Informationen mit nahen Fahrzeugen geteilt. Quelle: Eigene Darstellung. Bildmaterial: Dosovitskiy et al. 2017.

## OBJEKTERKENNUNG

Aufgabe der Objekterkennung ist es, Positionsinformationen von Verkehrsteilnehmer:innen aus beispielsweise Kamera- oder LiDAR-Daten abzuleiten. Die sogenannten Detektoren übernehmen diese Aufgabe und werden unter anderem mit Faltungsnetzen umgesetzt. Das KI-System löst dabei typischerweise zwei Aufgaben. Die Verkehrsteilnehmer:innen werden lokalisiert und jeweils einer Kategorie (PKW, LKW, Fußgänger:innen etc.) zugeordnet. Die Zuordnung zu den einzelnen Kategorien ermöglicht eine verkehrsmittelscharfe Analyse und Prognose des Verkehrsaufkommens.

Die in diesem Zusammenhang genutzten Faltungsnetze erkennen gelernte Muster in den Eingangsdaten. Dieser Prozess wird auch als Merkmalsextraktion bezeichnet. Bereiche mit einem hohen Musteraufkommen werden anschließend separat durch vorwärtsgerichtete Netzwerke klassifiziert und die Position verfeinert. So können mehrere Objekte (Fahrzeuge, Fußgänger:innen, ...) auf einem Eingangsbild lokalisiert und zugeordnet werden (siehe Abbildung 11). Moderne Architekturen erreichen bereits Detektionsgeschwindigkeiten von wenigen Millisekunden und liefern auch mit eingeschränkter Rechenkapazität eine hohe Genauigkeit. Daher eignen sich diese Verfahren für einen dezentralen Ansatz, bei dem die „Intelligenz“ direkt im Sensor verortet ist. Methoden der Objekterkennung werden deshalb sowohl bei statisch montierten (Verkehrsüberwachung) als auch bei sich bewegenden Sensoren (Fahrerassistenzkamera) eingesetzt. Im Vergleich zu herkömmlichen Detektionsverfahren mit manuell definierten Mustern bietet der KI-Ansatz eine höhere Anpassungsfähigkeit an unterschiedliche Wetter- und Lichtbedingungen. Vorausgesetzt wird hierbei jedoch ein möglichst diverser Datensatz für den Trainingsprozess des Detektors.

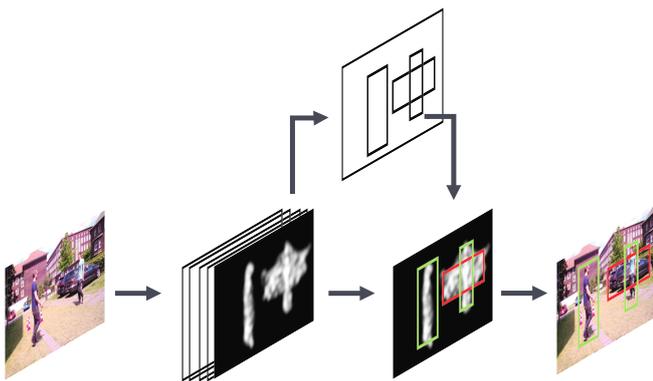


Abbildung 11: Typischer Aufbau eines Objektdetektors und Ablauf der Datenverarbeitung. Quelle: Eigene Darstellung.

## TRACKING- UND VORHERSAGEMODELLE

Die im letzten Abschnitt beschriebene Objekterkennung liefert eine Momentaufnahme des Verkehrsgeschehens, die allerdings noch keine zeitliche Komponente enthält. Die zeitliche Dimension ist beispielweise für eine Bestimmung von Geschwindigkeiten der Verkehrsteilnehmer:innen von Bedeutung. Aus dieser Zusatzinformation können Verkehrsgrößen wie Verkehrsfluss oder mittlere (makroskopische) Geschwindigkeit abgeleitet werden. Genau an dieser Schnittstelle setzen sogenannte Trackingverfahren und Vorhersagemodelle für Trajektorien an. Eine Trajektorie beschreibt dabei den Weg-Zeit-Verlauf von Verkehrsteilnehmer:innen (siehe Abbildung 12). Die Verfahren verknüpfen die Informationen einer Verkehrsteilnehmerin oder eines Verkehrsteilnehmers (Detektionen der Objekte) über die Zeit hinweg und ermöglichen durch die so entstehende Geschwindigkeitsinformation eine Vorhersage des zukünftigen Verhaltens.

In der Praxis werden örtliche Verhaltensvorhersagen meist auf Basis von physikalischen Modellen getroffen. In diesen sind die Bewegungsmöglichkeiten sowie die Unsicherheiten der Vorhersage abgebildet (z.B. mit einem sog. Kalman Filter). Das reine Befolgen der physikalischen Gesetze beschreibt das reale Verkehrsgeschehen allerdings oft nur näherungsweise, da die Intention der Fahrzeugführerin oder des Fahrzeugführers, eine Interaktion mit anderen Verkehrsteilnehmer:innen oder der Kontext (Ampeln, Kurven etc.) unberücksichtigt bleibt. Im Kontrast dazu verwenden "lernende" Vorhersagemodelle, welche auch auf neuronalen Netzen basieren können, bestimmte Muster und Regeln der Verkehrsteilnehmer:innen, die aus Beobachtungen bzw. Daten automatisiert abgeleitet werden. Neben der aktuellen Position und den historischen Bewegungsdaten können hierbei noch kontextuelle Informationen wie Tageszeiten, Wetter oder die direkte Umgebung einfach integriert werden. So kann beispielsweise abgebildet werden, dass Fußgänger:innen in der Nähe von Ampeln oder Zebrastreifen eine höhere Wahrscheinlichkeit haben, die Straße zu queren. Lernende Systeme, die eine zeitliche Komponente aufweisen, werden im Allgemeinen mit rekurrenten Netzwerken umgesetzt.

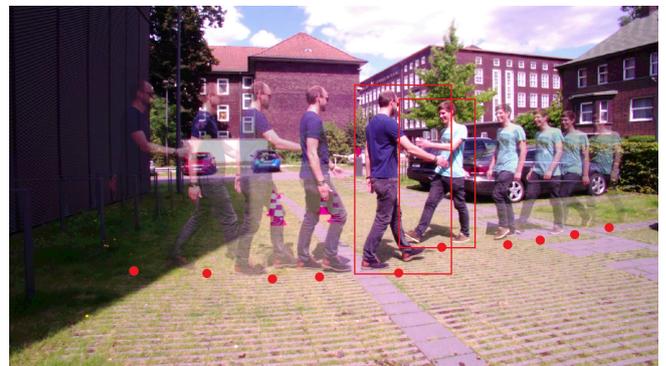


Abbildung 12: Tracking von Fußgänger:innen. Über den zeitlichen Verlauf der Objektdetektionen wird die Trajektorie bestimmt. Quelle: Eigene Darstellung.

## VERKEHRSTEUERUNG

Die Erweiterung des Sichtfeldes zur Kollisionsvermeidung ist nur eine Problemstellung, bei der die Methoden der künstlichen Intelligenz zur Umfelderkennung und Trajektorienvorhersage verwendet werden können. Ein Vorteil der intelligenten Objekterkennung mit Kameras oder LiDAR-Sensoren ist die Skalierbarkeit. Im Vergleich zu den herkömmlichen Kontaktschleifen an Lichtsignalanlagen können nicht nur Fahrzeuge erkannt werden, sondern auch Personen, Verkehrsschilder und Fahrspuren. Die Informationen aus den KI-Systemen lassen sich einfach auf andere Anwendungsfälle übertragen.

Durch das Verfolgen der Position der Verkehrsteilnehmer:innen über die Zeit lassen sich detaillierte Aussagen über die punktuelle Verkehrslage treffen. Um ein netzweites Abbild der Verkehrslage zu erhalten, müssen diese Daten jedoch an verschiedenen Standorten erhoben werden. Die Detektion der Verkehrsteilnehmer:innen kann hier über neuronale Netze zur Objekterkennung erfolgen. Werden diese Verkehrsdaten mit Positionsinformationen (GNSS), Uhrzeiten und Wochentagen verknüpft, lassen sich so genaue Modelle für die Verkehrsdynamik und -planung erstellen. Des Weiteren ist es auf Basis dieser Daten möglich, eine Verkehrsprognose durchzuführen.

Der Einsatz von intelligenten Verkehrsbeeinflussungsanlagen ermöglicht eine an die aktuelle Verkehrssituation angepasste Verkehrssteuerung. Dadurch wird nicht nur die Fahrtdauer für die Fahrer verkürzt, sondern auch die Emissionen der Fahrzeuge reduzieren sich durch kürzere Wartezeit und weniger Stop & Go (siehe Abbildung 13). Darüber hinaus wird es unter anderem möglich, die Fahrten von Rettungsdiensten oder des ÖPNV zu optimieren (Karsten Lemmer 2019). Beispielsweise hat das Dresdner Verkehrsmanagementsystem VAMOS (Technische Universität Dresden) gezeigt, dass durch die Zusammenführung verschiedener Informationsquellen eine optimierte Verkehrssteuerung ermöglicht wird.

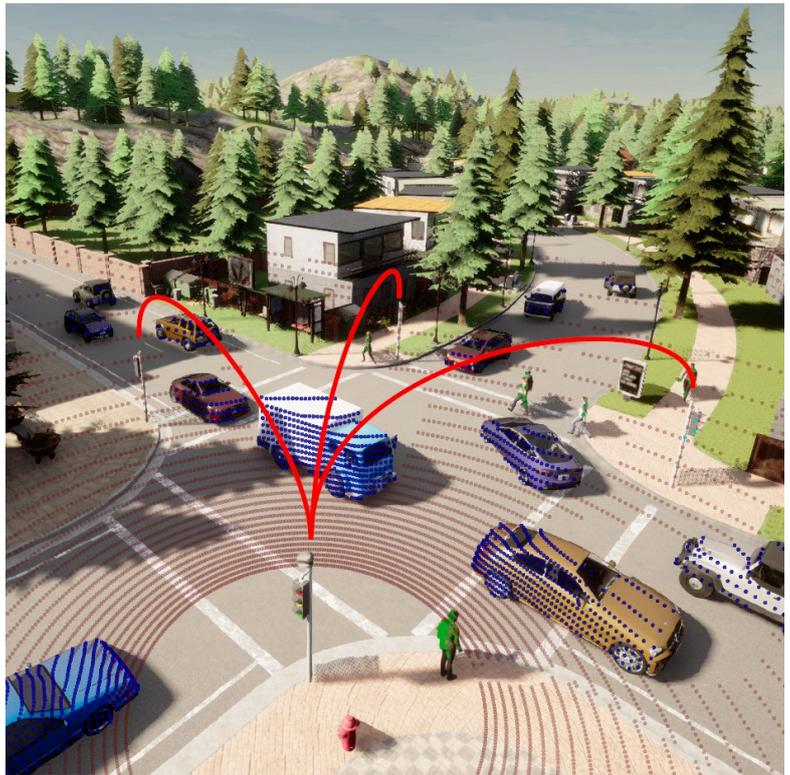


Abbildung 13: Durch die Erfassung der Verkehrsteilnehmer:innen im Kreuzungsbereich kann die Ampelsteuerung optimiert werden, um beispielsweise die Wartezeiten zu verkürzen. Quelle: Eigene Darstellung. Bildmaterial: Dosovitskiy et al. 2017.

# CHANCEN UND HERAUSFORDERUNGEN

## CHANCEN

Der Einsatz von KI-basierten Funktionen bietet Kommunen viele Möglichkeiten, ihre Verkehrssituation und Mobilitätsangebote zu verbessern und zu erweitern. So steigt die Verkehrssicherheit in und die Attraktivität der Kommune für Bürger:innen. Die Optimierung des Verkehrs durch die in diesem Themenheft beispielhaft gezeigte Aufrüstung von Kreuzungen mit intelligenter Sensorik ist nur eine Möglichkeit, den nächsten Schritt in Richtung automatisierter Mobilität zu gehen. Viele kleine Anwendungsfälle wie eine intelligente Ampelsteuerung und Verkehrsleitung sowie eine Parkplatzsuche und -prognose können umgesetzt werden. Neben diesen Einsatzfeldern, welche größtenteils den motorisierten Individualverkehr und ÖPNV betreffen, lässt sich auch die Koordination der verkehrsmittelübergreifenden Mobilität (d. h. die Nutzung mehrerer Verkehrsmittel wie Auto, Bus, Bahn, Fahrrad, Scooter und zu Fuß) durch intelligente Algorithmen optimieren. Solche Angebote (MaaS, "Mobility as a Service") helfen, die Verkehrswende zu bewältigen, indem sie eine nachhaltige Mobilität ermöglichen und den Gebrauch des motorisierten Individualverkehrs senken. Die Daten über einen Datenmarktplatz (bspw. [www.mdm-portal.de](http://www.mdm-portal.de)) bereit zu stellen, erlaubt auch externen Anbietern digitale Angebote in einer Kommune zu schaffen. Dazu zählen automatisierte Shuttlebusse und Lieferfahrzeuge sowie die automatisierte Parkplatzsuche oder eine intelligente verkehrsmittelübergreifende Navigation.

## HERAUSFORDERUNGEN

Trotz der hohen Leistungsfähigkeit von KI-basierten Systemen weisen diese noch einige Schwächen auf. Aufgrund der hohen Zahl an Parametern solcher Systeme sind die Entscheidungsprozesse nicht transparent und nachvollziehbar (auch "Black-Box" genannt). Die Erklärbarkeit und Absicherung der Systeme wird in aktuellen Forschungsprojekten, wie beispielsweise KI-Absicherung ([www.ki-absicherung-projekt.de](http://www.ki-absicherung-projekt.de)), erforscht. Durch die in diesem Projekt entwickelten Methoden und Maßnahmen soll es auch möglich werden, die Auswirkung von Angriffen auf KI-Systeme zu minimieren. Die sogenannten Adversarial Attacks beschreiben das mutwillige Täuschen eines KI-Systems durch das Verändern der Eingangsdaten. Das können kleine Aufkleber mit Mustern auf Verkehrsschildern sein, welche die im Netzwerk gelernten Muster aktivieren und so zu falschen Ausgaben führen.

Bei der Konzipierung von KI-Systemen müssen Aspekte wie Datenschutz und Fairness berücksichtigt werden. Da es sich

bei der KI um ein System handelt, welches seine Entscheidungsregeln auf Basis von Daten lernt, können den Datenschutz betreffende Regeln schwierig bis gar nicht im Nachhinein implementiert werden, sondern müssen von Anfang an berücksichtigt werden (Privacy-by-Default). Dies ist vor allem relevant, wenn die KI-Systeme mit personenbezogenen Daten (Bildern, Kennzeichen etc.) trainiert werden. Durch die Verwendungen anonymer oder anonymisierter Daten werden KI-Systeme datenschutzkonform. Dies steht jedoch im Widerspruch zu der Voraussetzung, möglichst viele und variable Daten zum Lernen der Systeme zu verwenden, um hohe Genauigkeiten zu erreichen. Beispielsweise würde das Verpixeln von Gesichtern in Trainingsdaten dazu führen, dass Personen im Realbetrieb nicht oder schlecht erkannt werden, da die entsprechenden Muster für die Gesichtserkennung fehlen oder das System einen falschen Zusammenhang zwischen Körper und einem verpixelten Bereich, wie er im Realbetrieb nicht vorkommt, gelernt hat.

Das Problem der Fairness ist bereits in anderen KI-gestützten Einsatzbereichen aufgetreten. So sind in vielen Datenbanken, die zum Training von KI-Systemen genutzt werden, überdurchschnittlich viele hellhäutige Männer im Alter von 18 bis 40 Jahren abgebildet (Yang et al.) und dies hat auch Auswirkungen (Wilson et al.) auf die damit gelernten KI-Systeme. Diese Diskriminierung durch Reproduktion von Stereotypen wird häufig ungewollt (Dastin 2018) von den KI-Systemen abgebildet. Sie werden ungewollt unfair. Neben anderen ethischen Richtlinien, nach denen eine KI agieren soll, fordert die deutsche Ethik-Kommission (Ethik-Kommission 2017) des BMVI daher, dass eine KI fair entscheiden und alle Menschen gleich behandeln soll.

Durch das Vordringen in sicherheitsrelevante Bereiche werden immer höhere Anforderungen an die KI-Systeme gestellt. So muss die funktionale Sicherheit der KI-Systeme garantiert werden, damit in unvorhergesehenen Fällen das System keine möglicherweise fatalen Entscheidungen trifft (Verband der TÜV e. V. 2020). Zur Förderung von Standards und Normen im Bereich der KI haben DIN und DKE in einem gemeinsamen Projekt mit dem Bundesministerium für Wirtschaft und Energie und zusammen mit ca. 300 Fachleuten aus Wirtschaft, Wissenschaft, öffentlicher Hand und Zivilgesellschaft an der Normungsroadmap Künstliche Intelligenz gearbeitet. Die darin beschriebenen Empfehlungen sollen helfen, KI-Anwendungen sicherer, verständlicher und zuverlässiger werden zu lassen. Durch den Einsatz von Normen wird auch die Zusammenarbeit unterschiedlicher Akteure verbessert.

---

## ZUSAMMENFASSUNG

### **KI BESCHLEUNIGT AUTOMATISIERTE MOBILITÄT**

Die automatisierte und vernetzte Mobilität wird in Zukunft maßgeblich durch eine effiziente und intelligente Interpretation der anfallenden Daten geprägt sein. Für eine optimale Steuerung des Verkehrs und die Umfelderkennung automatisierter Fahrzeuge stellt die künstliche Intelligenz eine Schlüsseltechnologie dar. Eine zusätzliche Vernetzung bietet darüber hinaus weitreichendes Potential für eine KI-gesteuerte verkehrsmittelübergreifende Koordination des Verkehrs. Aber auch für weitere Anwendungsfälle lassen sich die Stärken von KI-Systemen nutzen.

### **MOBILITÄTSDATEN INTELLIGENT NUTZEN**

Durch die Analyse von Verkehrsdaten und einer Verkehrsprognose lassen sich Verkehrsleitsysteme bedarfsgerecht und automatisiert steuern. Sie helfen, die vorhandene Infrastruktur effizienter zu nutzen, die Ressourcen zu schonen und Emissionen zu reduzieren. Kreuzungen bieten aufgrund des hohen Verkehrsaufkommens und des Unfallrisikos ein großes Potenzial, diese durch KI-Anwendungen sicherer zu gestalten.

### **REGULIERUNGEN FÜR DIE ABSICHERUNG VON KI WERDEN AUF DEN WEG GEBRACHT**

Trotz des großen Potenzials der KI-Anwendungen muss auch in Zukunft auf die Sicherheit, den Datenschutz, die Verständlichkeit und die Fairness der verwendeten Systeme geachtet werden. Diese Punkte müssen bei der Entwicklung von KI-Funktionen berücksichtigt werden, um eine Akzeptanz bei den Nutzern zu erreichen. Die Normungroadmap von DIN und DKE beschreibt Empfehlungen wie KI-Anwendungen umgesetzt sind, um sicher und zuverlässig zu sein.

## LITERATUR

- Azevedo, Frederico A. C.; Carvalho, Ludmila R. B.; Grinberg, Lea T.; Farfel, José Marcelo; Ferretti, Renata E. L.; Leite, Renata E. P. et al. (2009): Equal numbers of neuronal and nonneuronal cells make the human brain an isometrically scaled-up primate brain. In: *The Journal of comparative neurology* 513 (5), S. 532–541. DOI: 10.1002/cne.21974.
- BMVI - Kooperative Mobilität im digitalen Testfeld Düsseldorf – KoMoD (2021). Online verfügbar unter <https://www.bmvi.de/SharedDocs/DE/Artikel/DG/AVF-projekte/komod.html>, zuletzt aktualisiert am 18.06.2021, zuletzt geprüft am 18.06.2021.
- Buehler, Martin; Iagnemma, Karl; Singh, Sanjiv (2007): DARPA Grand Challenge. The Race of the Century. Berlin, Heidelberg: Springer-Verlag Berlin Heidelberg (Springer Tracts in Advanced Robotics, 36).
- D. Pomerleau (1988): ALVINN: An Autonomous Land Vehicle in a Neural Network. In: undefined. Online verfügbar unter <https://www.semanticscholar.org/paper/ALVINN%3A-An-Autonomous-Land-Vehicle-in-a-Neural-Pomerleau/7786bc6c25ba38ff0135f1bdad192f6b3c4ad0b3>.
- Dastin, Jeffrey (2018): Amazon scraps secret AI recruiting tool that showed bias against women. In: Reuters Media, 10.10.2018. Online verfügbar unter <https://www.reuters.com/article/us-amazon-com-jobs-automation-insight/amazon-scraps-secret-ai-recruiting-tool-that-showed-bias-against-women-idUKKCN1MK08G?edition-redirect=uk>, zuletzt geprüft am 10.03.2021.
- Dickmanns, Ernst D Prof. Dr.-Ing.; Graefe, V. Prof. Dr. rer.nat.; Niegel, W. Prof. Dr. rer.nat. (1987): Definitionsphase PROMETHEUS, Pro-Art. Universität der Bundeswehr München. Online verfügbar unter [http://www.dyna-vision.de/main/Text\\_PDF/1987%20AbschlBerDefPhase%20Pro-Art\\_UBM.pdf](http://www.dyna-vision.de/main/Text_PDF/1987%20AbschlBerDefPhase%20Pro-Art_UBM.pdf).
- Ethik-Kommission (2017): Automatisiertes und Vernetztes Fahren. Hg. v. BMVI. Online verfügbar unter <https://connectedautomateddriving.eu/wp-content/uploads/2017/07/084-dobrindt-bericht-der-ethik-kommission.pdf>.
- Graefe, Volker; Kuhnert, Klaus-Dieter (1992): Vision-based Autonomous Road Vehicles. In: Ichiro Masaki (Hg.): *Vision-based Vehicle Guidance*. New York, NY: Springer New York (Springer Series in Perception Engineering), S. 1–29. Online verfügbar unter [https://doi.org/10.1007/978-1-4612-2778-6\\_1](https://doi.org/10.1007/978-1-4612-2778-6_1).
- H. Detjen; S. Geisler; S. Schneegass (2020): Maneuver-based Control Interventions During Automated Driving: Comparing Touch, Voice, and Mid-Air Gestures as Input Modalities. In: 2020 IEEE International Conference on Systems, Man, and Cybernetics (SMC). 2020 IEEE International Conference on Systems, Man, and Cybernetics (SMC), S. 3268–3274.
- Haselhoff, Anselm; Kronenberger, Jan; Kuppens, Fabian; Schneider, Jonas (2021): Towards Black-Box Explainability With Gaussian Discriminant Knowledge Distillation. In: *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, S. 21–28. Online verfügbar unter [https://openaccess.thecvf.com/content/CVPR2021W/SAIAD/html/Haselhoff\\_Towards\\_Black-Box\\_Explainability\\_With\\_Gaussian\\_Discriminant\\_Knowledge\\_Distillation\\_CVPRW\\_2021\\_paper.html](https://openaccess.thecvf.com/content/CVPR2021W/SAIAD/html/Haselhoff_Towards_Black-Box_Explainability_With_Gaussian_Discriminant_Knowledge_Distillation_CVPRW_2021_paper.html).
- Haselhoff, Anselm; Nunn, Christian; Muller, Dennis; Meuter, Mirko; Roese-Koerner, Lutz (2017): Markov random field for image synthesis with an application to traffic sign recognition. In: *IEEE Intelligent Vehicles Symposium* (Hg.): 28th IEEE Intelligent Vehicles Symposium. June 11-14, 2017, Redondo Beach, California, USA. *IEEE Intelligent Vehicles Symposium; Intelligent Vehicles Symposium; IV; Workshop Deep Learning for Vehicle Perception; Workshop Multi-Sensor Fusion and Extended Object Tracking; Workshop on Machine Vision and Interfaces in Data Fusion Platforms for Automated Driving; Workshop CPSS-based Parallel Driving*. [Piscataway, NJ]: IEEE. Online verfügbar unter <http://dx.doi.org/10.1109/ivs.2017.7995907>.
- Joshua Wheeler (2019): Automatic Speech Recognition System Considerations for the Autonomous Vehicle (SAE Technical Paper, 2019-01-0861). Online verfügbar unter <https://www.sae.org/publications/technical-papers/content/2019-01-0861/>.
- Karsten Lemmer (2019): Neue autoMobilität II. Kooperativer Straßenverkehr und intelligente Verkehrssteuerung für die Mobilität der Zukunft. Hg. v. acatech. acatech. Online verfügbar unter <https://www.acatech.de/publikation/neue-automobilitaet-ii/>.

- Kaul, Robert; Barthauer, Mirko; Bläsche, Jens; Böhm, Michael; Dobmeier, Stefan; Ehmen, Günter; Verkehrssystemtechnik, Institut für (2019): DK4.0 - Digitaler Knoten 4.0; Gestaltung und Regelung städtischer Knotenpunkte für sicheres und effizientes, automatisiertes Fahren im gemischten Verkehr : Verbundbericht des Gesamtvorhabens : Laufzeit des Vorhabens: 01.12.2016-31.05.2019, Berichtszeitraum: 01.12.2016-31.05.2019. Braunschweig: [Deutsches Zentrum für Luft- und Raumfahrt e.V. (DLR), Institut für Verkehrssystemtechnik].
- Keshav Bimbraw (2015): Autonomous cars: Past, present and future a review of the developments in the last century, the present scenario and the expected future of autonomous vehicle technology. In: undefined. Online verfügbar unter <https://www.semanticscholar.org/paper/Autonomous-cars%3A-Past%2C-present-and-future-a-review-Bimbraw/c9079b5b7f8e5bba3dfb60f977a647bad025f6e0>.
- Kocić, Jelena; Jovičić, Nenad; Drndarević, Vujo (2019): An End-to-End Deep Neural Network for Autonomous Driving Designed for Embedded Automotive Platforms. In: Sensors (Basel, Switzerland) 19 (9). DOI: 10.3390/s19092064.
- Kuppers, Fabian; Kronenberger, Jan; Shantia, Amirhossein; Haselhoff, Anselm (2020): Multivariate Confidence Calibration for Object Detection. In: Proceedings, 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops. Virtual, 14-19 June 2020. Los Alamitos, California: IEEE Computer Society, Conference Publishing Services. Online verfügbar unter <http://dx.doi.org/10.1109/cvprw50498.2020.00171>.
- Oyeyemi Olayode; Lagouge Tartibu; Modestus Okwu (2020): Application of Artificial Intelligence in Traffic Control System of Non-Autonomous Vehicles at Signalized Road Intersection. In: Procedia CIRP 91. DOI: 10.1016/j.procir.2020.02.167.
- Pablo Sauras-Perez (2017): A Voice and Pointing Gesture Interaction System for Supporting Human Spontaneous Decisions in Autonomous Cars. In: undefined. Online verfügbar unter <https://www.semanticscholar.org/paper/A-Voice-and-Pointing-Gesture-Interaction-System-for-Sauras-Perez/6c848f0dc13eb4d769502ccc29d98c7246639401>.
- Pschenitzka; Michael (2017): Berichte der ADAC Unfallforschung. Kreuzungsunfälle. ADAC Unfallforschung im ADAC Technik Zentrum Landsberg/Lech.
- Referat Künstliche Intelligenz (Hg.) (2021): KI Strategie Deutschland. Bundesministerium für Bildung und Forschung. Online verfügbar unter <https://www.ki-strategie-deutschland.de/home.html>, zuletzt aktualisiert am 21.04.2021, zuletzt geprüft am 21.04.2021.
- Reiner Wertheimer. WM&C: Forschungsinitiative Ko-FAS, zuletzt geprüft am 18.06.2021.
- Rosenblatt, F. (1957): The Perceptron, a Perceiving and Recognizing Automaton Project Para: Cornell Aeronautical Laboratory (Report: Cornell Aeronautical Laboratory). Online verfügbar unter [https://books.google.de/books?id=P\\_XGPgAACAAJ](https://books.google.de/books?id=P_XGPgAACAAJ).
- Sebastian Houben; Stephanie Abrecht; M. Akila; Andreas Bär; F. Brockherde; P. Feifel et al. (2021): Inspect, Understand, Overcome: A Survey of Practical Methods for AI Safety. In: undefined. Online verfügbar unter <https://www.semanticscholar.org/paper/Inspect%2C-Understand%2C-Overcome%3A-A-Survey-of-Methods-Houben-Abrecht/6568e28775eec63e9ad6903aaedde91001d797e5>.
- Shu Wang; Jiahao Cao; Kun Sun; Q. Li (2020): SIEVE: Secure In-Vehicle Automatic Speech Recognition Systems. In: undefined. Online verfügbar unter <https://www.semanticscholar.org/paper/SIEVE%3A-Secure-In-Vehicle-Automatic-Speech-Systems-Wang-Cao/d62f09bbc7290b442c81d85a9a2960744a89ccef>.
- Sorin Grigorescu; Bogdan Trasnea; Tiberiu Cocias; Gigel Macesanu (2019): A survey of deep learning techniques for autonomous driving. In: Journal of Field Robotics 37 (8). DOI: 10.1002/rob.21918.
- T. Kopinski; A. Gepperth; U. Handmann (2015a): A Real-Time Applicable Dynamic Hand Gesture Recognition Framework. In: 2015 IEEE 18th International Conference on Intelligent Transportation Systems. 2015 IEEE 18th International Conference on Intelligent Transportation Systems, S. 2358–2363.
- T. Kopinski; J. Eberwein; S. Geisler; U. Handmann (2015b): Touch versus mid-air gesture interfaces in road scenarios - measuring driver performance degradation. In: 2015 IEEE 18th International Conference on Intelligent Transportation Systems. 2015 IEEE 18th International Conference on Intelligent Transportation Systems, S. 661–666.
- Technische Universität Dresden: VAMOS Portal. Online verfügbar unter <https://vamosportal.de/>.
- Urmson, C.; Whittaker, W. (2008): Self-Driving Cars and the Urban Challenge. In: IEEE Intell. Syst. 23 (2), S. 66–68. DOI: 10.1109/MIS.2008.34.
- Varun Totakura; Bhargava Reddy Vuribindi; E. Madhusudhana Reddy (2021): Improved Safety of Self-Driving Car using Voice Recognition through CNN. In: IOP Conf. Ser.: Mater. Sci. Eng. 1022 (1), S. 12079. DOI: 10.1088/1757-899X/1022/1/012079.
- Verband der TÜV e. V. (2020): Wird Künstliche Intelligenz im Auto geprüft? Berlin. Online verfügbar unter [http://www.vdtuev.de/tuevislizenz/dok\\_view?oid=820149](http://www.vdtuev.de/tuevislizenz/dok_view?oid=820149).

Warren S. McCulloch; Walter Pitts (1943): A logical calculus of the ideas immanent in nervous activity. In: Bulletin of Mathematical Biophysics 5 (4), S. 115–133. DOI: 10.1007/BF02478259.

Weber, Mathia; Burchardt, Aljoscha (2017): Künstliche Intelligenz. Wirtschaftliche Bedeutung, gesellschaftliche Herausforderungen, menschliche Verantwortung. Hg. v. Bitkom e.V. und DFKI. Online verfügbar unter <https://www.bitkom.org/noindex/Publikationen/2017/Sonstiges/KI-Positionspapier/171012-KI-Gipfelpapier-online.pdf>.

Wilson; Benjamin, Hoffman; Judy, Morgenstern; Jamie: Predictive Inequity in Object Detection. In: CVPR, Bd. 2019.  
Yang, Kaiyu; Qinami, Klint; Fei-Fei, Li; Deng, Jia; Russakovsky, Olga: Towards Fairer Datasets: Filtering and Balancing the Distribution of the People Subtree in the ImageNet Hierarchy. In: Association for Computing Machinery, S. 547–558. Online verfügbar unter <https://dl.acm.org/doi/abs/10.1145/3351095.3375709>.

Goodfellow, Ian; Bengio, Yoshua; Courville, Aaron (2016): Deep Learning: MIT Press. Online verfügbar unter <http://www.deeplearningbook.org>.

Dosovitskiy, Alexey; Ros, German; Codevilla, Felipe; Lopez, Antonio; Koltun, Vladlen: CARLA: An Open Urban Driving Simulator. In: Proceedings of the 1st Annual Conference on Robot Learning, S. 1-16.

## IMPRESSUM

Herausgeber

**camo.nrw**  
CENTRUM FÜR AUTOMATISIERTE MOBILITÄT

**Geschäftsstelle Centrum für automatisierte Mobilität (CAMO)**  
c/o Bergische Universität Wuppertal  
Rainer-Gruenter-Str. 21  
42119 Wuppertal

**Besucheradresse:**  
Lise-Meitner-Str. 27  
42119 Wuppertal



EUROPÄISCHE UNION  
Investition in unsere Zukunft  
Europäischer Fonds  
für regionale Entwicklung



**EFRE.NRW**

Investitionen in Wachstum  
und Beschäftigung

Diese Studie wurde aus Mitteln des Europäischen Fonds für regionale Entwicklung (EFRE) gefördert.

## **Autoren**

**Kronenberger, Jan, M.Sc.**

Hochschule Ruhr West  
Institut Informatik

**Trelenberg, Kevin, B.Sc.**

Hochschule Ruhr West  
Institut Informatik

**Detjen, Henrik, M.Sc.**

Hochschule Ruhr West  
Institut Positive Computing

**Geisler, Stefan, Prof. Dr. rer. nat.**

Hochschule Ruhr West  
Institut Positive Computing

**Handmann, Uwe, Prof. Dr.-Ing.**

Hochschule Ruhr West  
Institut Informatik

**Haselhoff, Anselm, Prof. Dr.-Ing.**

Hochschule Ruhr West  
Institut Informatik

**Malzahn, Nils, Dipl.-Inform.**

Hochschule Ruhr West  
Institut Positive Computing

Trotz sorgfältiger inhaltlicher Kontrolle kann seitens des camo.nrw keine Garantie oder Haftung für Vollständigkeit, Richtigkeit und Aktualität der Angaben übernommen werden.

Die in diesem Themenheft dargestellten Ergebnisse basieren auf Recherchen bis einschließlich März 2021.

Dieses Themenheft wurde aus Mitteln des Europäischen Fonds für regionale Entwicklung (EFRE) gefördert.

**camo.nrw**  
CENTRUM FÜR AUTOMATISIERTE MOBILITÄT



EUROPÄISCHE UNION  
Investition in unsere Zukunft  
Europäischer Fonds  
für regionale Entwicklung



EFRE.NRW  
Investitionen in Wachstum  
und Beschäftigung

Geschäftsstelle Centrum für automatisierte Mobilität (CAMO)  
c/o Bergische Universität Wuppertal  
Rainer-Gruenter-Str. 21  
42119 Wuppertal

Besucheradresse:  
Lise-Meitner-Str. 27  
42119 Wuppertal

+49 202 / 439 1164  
kontakt@camo.nrw



HOCHSCHULE RUHR WEST  
UNIVERSITY OF APPLIED SCIENCES

BERGISCHE  
STRUKTUR-UND  
WIRTSCHAFTS-  
FÖRDERUNGS-  
GESELLSCHAFT