

Offener Multisensordatensatz für die Entwicklung der Umfeldwahrnehmung beim vollautomatischen Fahren

Für die Umfeldwahrnehmung beim automatisierten Fahren im Eisenbahnbetrieb werden auch maschinelle Lernverfahren (ML) zum Einsatz kommen. Die für deren Entwicklung notwendigen Datensätze sind derzeit aber kaum öffentlich verfügbar. In einem Projekt des DZSF sowie der DB Netz AG im Rahmen der Sektorinitiative Digitale Schiene Deutschland wurde ein Multisensordatensatz für ML erstellt und veröffentlicht.



1. Einleitung

Beim automatisierten Fahren im Bahnbetrieb (engl. „Automatic Train Operation“, ATO) übernehmen technische Systeme Aufgaben, die zuvor das Betriebspersonal und insbesondere der Triebfahrzeugführer (Tf) erfüllt hat. ATO birgt Potenziale u.a. hinsichtlich der Steigerung der Energieeffizienz, der Verbesserung der Pünktlichkeit und der Erhöhung der Kapazität und Flexibilität des Schienenverkehrs [1].

Bei ATO werden verschiedene Automatisierungsgrade (engl. „Grade of Automation“, kurz: GoA) unterschieden. Beim Automatisierungsgrad 2 (kurz „GoA 2“) übernehmen die Züge das Anfahren, Beschleunigen und Bremsen auf dafür ausgerüsteten Strecken. Der Tf übernimmt nur noch die Streckenbeobachtung und greift bei Unregelmäßigkeiten ein. Seit September 2022 fahren im Kooperationsprojekt „Digitale S-Bahn Hamburg“ der Digitalen Schiene Deutschland (DSD), Siemens und der Stadt Hamburg die ersten vier Züge in GoA 2 im Fahrgastbetrieb [2].

Bei höheren Automatisierungsgraden müssen technische Systeme zunehmend komplexere Aufgaben übernehmen. Beim fahrerlosen (GoA 3) wie auch beim unbegleiteten (GoA 4) Fahrbetrieb überwacht kein Tf im Zug oder Teleoperator aus der Ferne permanent den Fahrweg und dessen Umgebung auf mögliche Hindernisse. Sofern diese Aufgabe bei Bahnen in offenen Systemen weiterhin zugeseitig realisiert wird, bedeutet das, dass technische Sys-



Dr. Roman Tilly

Wissenschaftlicher Referent Data Science und Leiter des Projekts
Deutsches Zentrum für Schienenverkehrsforschung beim Eisenbahn-Bundesamt
tillyr@dzsf.bund.de



Dr. Rustam Tagiew

Wissenschaftlicher Referent Künstliche Intelligenz
Deutsches Zentrum für Schienenverkehrsforschung beim Eisenbahn-Bundesamt
tagiewr@dzsf.bund.de



Dr. Philipp Neumaier

Lead of Data-Factory & Data Acquisition & Engineering
Digitale Schiene Deutschland
DB Netz AG
philipp.neumaier@deutschebahn.com



Patrick Denzler

Component Lead Data Curation, Management & Quality
Digitale Schiene Deutschland
DB Netz AG
patrick.denzler@deutschebahn.com



Dr. Karsten Schwalbe

Fachgruppenleiter „Mathematische Methoden und Algorithmen“ und Leiter des Projektes
FusionSystems GmbH
karsten.schwalbe@fusionsystems.de



Tobias Klockau

Expert Data Selection and Data Format
Digitale Schiene Deutschland
DB Netz AG
tobias.klockau@deutschebahn.com



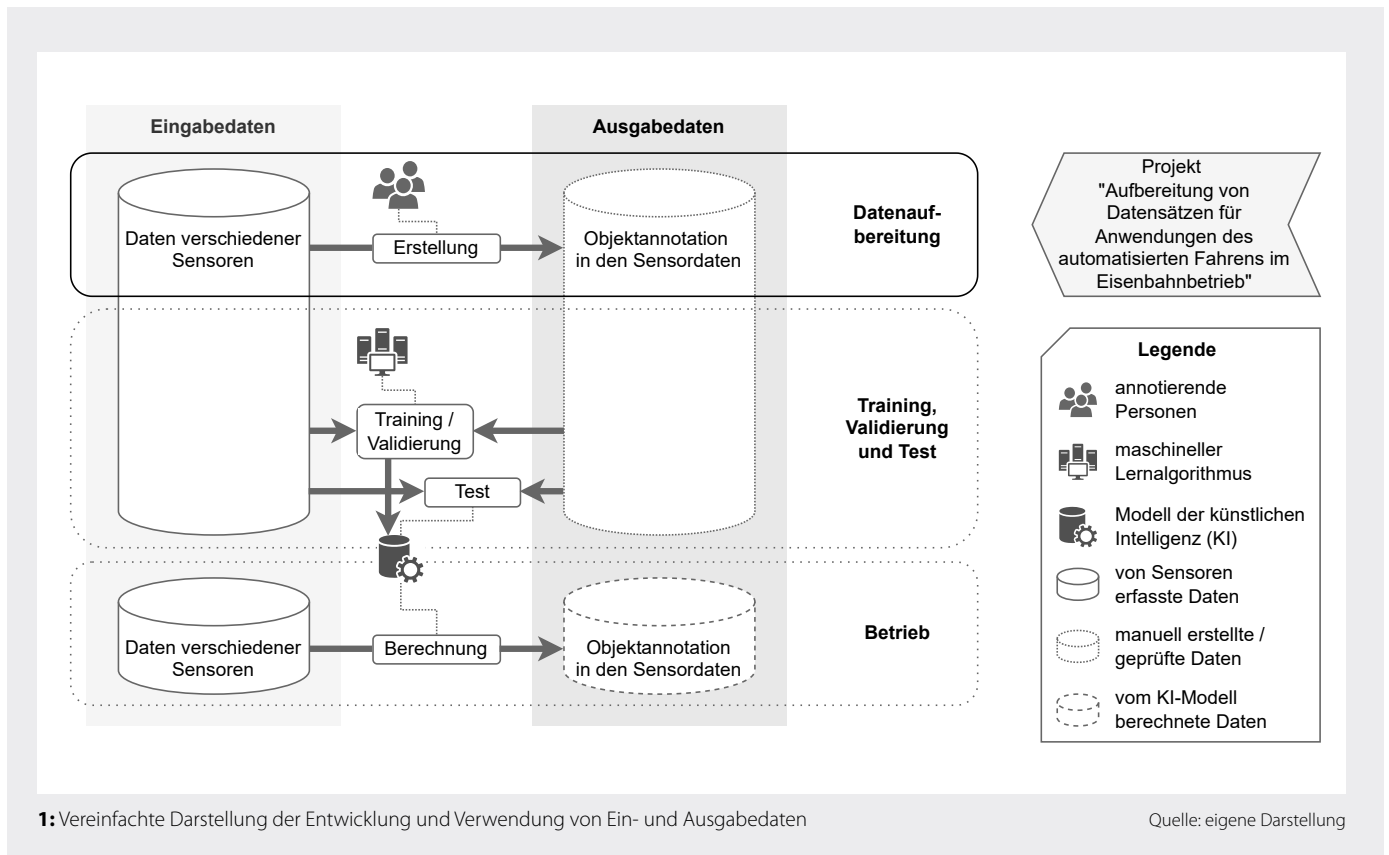
Pavel Klasek

Wissenschaftlicher Referent Automatisierung
Deutsches Zentrum für Schienenverkehrsforschung beim Eisenbahn-Bundesamt
klasekp@dzsf.bund.de



Dr. Martin Köppel

Component Lead of Data Annotation
Digitale Schiene Deutschland
DB Netz AG
martin.koepfel@deutschebahn.com



1: Vereinfachte Darstellung der Entwicklung und Verwendung von Ein- und Ausgabedaten

Quelle: eigene Darstellung

teme am Zug die Aufgabe übernehmen müssen und bei unterschiedlichen Witterungs- und Sichtverhältnissen und auf unterschiedliche Distanzen Objekte verschiedenster Art und Erscheinungsform mit der notwendigen Zuverlässigkeit erkennen können müssen.

Für die Wahrnehmung von Objekten im Umfeld des Zuges werden voraussichtlich Kombinationen aus an der Fahrzeugfront angebrachten Kamera-, LiDAR- und Radarsensoren zum Einsatz kommen [3]. In Verbindung mit intelligenter Software müssen diese Systeme die erfassten Sensordaten interpretieren können, um auf Ereignisse reagieren und beispielsweise eine Schnellbremsung einleiten zu können. Im Projekt „Sensors4Rail“ testet die DSD seit 2019 zusammen mit führenden Unternehmen aus der Bahn- und Automobilbranche mit einem eigens dafür ausgerüsteten Triebzug die Leistungsfähigkeit solcher Systeme [4]. Während die Entwicklung der Sensorik schon fortgeschritten ist, steht die Entwicklung der Auswertungssoftware noch am Anfang.

Die Auswertung der Sensordaten bei ATO erfolgt durch Künstliche Intelligenz (KI) und voraussichtlich auch durch solche KI-Modelle, die mit Algorithmen des

Maschinellen Lernens (ML) auf Basis von geeigneten Trainings-, Validierungs- und Testdaten entwickelt wurden. Für einige Objektklassen, die auch außerhalb des Bahnbetriebs vorkommen (z.B. Personen, Straßenfahrzeuge, Tiere), existieren Datensätze oder sogar KI-Modelle, die auch für die Entwicklung der Objekterkennung bei ATO genutzt werden können [5]. Bei ATO müssen aber auch bahnspezifische Objekte (z.B. Schienen, Oberleitungsmasten, Signale, Prellböcke) in Bahnbetriebsumgebungen zuverlässig erkannt werden. Hierfür sind bisher nur sehr wenige offene verfügbare Datensätze bekannt, beispielsweise RailSem19 [6], FRSign [7] und RAWPED [8]. Diese Datensätze enthalten allerdings nur annotierte Daten von Farbbildkameras und keine anderen Sensormodalitäten.

Im Projekt „Aufbereitung von Datensätzen für Anwendungen des automatisierten Fahrens im Eisenbahnbetrieb“ haben das Deutsche Zentrum für Schienenverkehrsforschung (DZSF) beim Eisenbahn-Bundesamt (EBA), die DB Netz AG im Rahmen der DSD sowie die FusionSystems GmbH einen Multisensordatensatz speziell für den Bahnbereich erstellt. Ziel war es, eine erste Referenz für Trainings-, Validierungs- und Testdaten für die Objekterkennung bei

ATO zur Verfügung zu stellen. Dieser Beitrag stellt die Vorgehensweise bei der Datenaufbereitung und den veröffentlichten Datensatz dar.

Das DZSF veröffentlicht den in Englisch dokumentierten Datensatz als „Open Sensor Data for Rail 2023“ (OSDaR23) [9] zusammen mit der Annotationsvorschrift (engl.) und dem Forschungsprojektbericht (www.dzsf.bund.de). Die DB Netz AG veröffentlicht eine Software-Entwicklungsbibliothek für die einfache Verwendung des Datensatzes in Python (https://github.com/DSD-DBS/raillabel). Zur Visualisierung des Datensatzes kann beispielsweise der WebLabel Player (https://github.com/Vicomtech/weblabel) der Vicomtech Forschungsstiftung (https://www.vicomtech.org/en/) genutzt werden. (Hinweis: Vicomtech war nicht Teil des Projekts, und es bestehen ansonsten derzeit keine Beziehungen zwischen DZSF und Vicomtech.)

2. Umfeldwahrnehmung an der Spitze des Zuges bei ATO

Die Umfeldwahrnehmung ist aus bahnbetrieblicher Sicht bei der Überwachung des Fahrwegs und dessen Umgebung auf mögliche Hindernisse von großer Bedeutung.

Tabelle 1: Technische Spezifikationen der Sensoren

Sensor	Spezifikation
Hochauflösende Farbbildkameras	
Sensordaten	Farbbilder (8 Bit, PNG)
Anzahl Sensoren	3
Auflösung	4112 x 2504 px
Abtastfrequenz	10 Hz (synchronisiert)
Ausrichtung	in Fahrtrichtung schräg links, zentral und schräg rechts
Niedrigauflösende Farbbildkameras	
Sensordaten	Farbbilder (8 Bit, PNG)
Anzahl Sensoren	3
Auflösung	2464 x 1600 px
Abtastfrequenz	10 Hz (synchronisiert)
Ausrichtung	in Fahrtrichtung schräg links, zentral und schräg rechts
Infrarotkameras	
Sensordaten	Graustufenbilder (8 Bit, PNG)
Anzahl Sensoren	3
Auflösung	640 x 480 px
Abtastfrequenz	10 Hz (synchronisiert)
Ausrichtung	in Fahrtrichtung schräg links, zentral und schräg rechts
Langstrecken-LiDAR	
Sensordaten	3D Punktwolke (PCD)
Anzahl Sensoren	3
Abtastpunkte insgesamt	50.000 – 84.000 Punkte /Frame
Abtastfrequenz	10 Hz (synchronisiert)
Ausrichtung	zentral
Mittelbereichs-LiDAR	
Sensordaten	3D Punktwolke (PCD)
Anzahl Sensoren	1
Abtastpunkte insgesamt	60.000 – 115.000 Punkte /Frame
Abtastfrequenz	10 Hz (synchronisiert)
Kurzstrecken-LiDAR	
Sensordaten	3D Punktwolke (PCD)
Anzahl Sensoren	2
Abtastpunkte insgesamt	20 000 – 40 000 Punkte /Frame
Abtastfrequenz	10 Hz (synchronisiert)
Radar	
Sensordaten	Graustufenbilder (8 Bit, PNG), kartesische Vogelperspektive
Anzahl Sensoren	1
Auflösung	2856 x 1428 px
Abtastfrequenz	4 Hz (synchronisiert)
Inertiale Messeinheit (IMU)	
Sensordaten	Lineare und rotatorische Beschleunigung
Anzahl Sensoren	4
Abtastfrequenz	100/10 Hz
GPS/GNSS	
Sensordaten	Latitude & Longitude in WGS84
Anzahl Sensoren	4
Abtastfrequenz	100/10 Hz

Daneben kann sie aber auch dazu dienen, Infrastrukturobjekte zu identifizieren, beispielsweise für die hochgenaue Selbstlokalisierung des Zuges.

Die Wahrnehmung von Objekten im Umfeld umfasst unter anderem folgende Bildanalyseaufgaben (vgl. [10]):

Detektion: Die prinzipielle Anwesenheit von Objekten wahrnehmen.

Erkennung: Grundsätzliche Objekteigenschaften (z.B. Größe, Geometrie) wahrnehmen.

Klassifikation: Objekte und ihre Attribute bekannten Klassen und Attributausprägungen zuordnen.

Identifikation: Objekte über Sensoren oder Zeitpunkte hinweg wiedererkennen und verfolgen.

Lokalisierung: Objekte im Raum lokalisieren.

Vorhersage: Das zukünftige Verhalten von Objekten (insbesondere deren Bewegung) prognostizieren.

Einige dieser Aufgaben können mit klassischer Software gelöst werden, für einige wird aber voraussichtlich ML erforderlich sein. Vereinfacht dargestellt, erlernt beim ML ein Algorithmus anhand von Beispielen, Entscheidungen zu treffen beziehungsweise Berechnung zu erstellen, ohne dass die Regeln beziehungsweise Funktionen hierfür explizit (von Menschen) vorgegeben werden müssen. ML-Algorithmen benötigen dafür Beispiele der Eingabedaten und der zugehörigen korrekten Ausgabedaten. Im Fall der Bildanalyse kann es sich dabei beispielsweise um ein Farbbild eines Kamerasensors (Eingabedaten) handeln, dem Daten darüber, welche Objekte sich an welcher Position auf dem Bild befinden, zugeordnet sind (Ausgabedaten). Aus einer Vielzahl solcher Beispiele können ML-Algorithmen dann generalisierte Funktionen ableiten, anhand derer aus Eingabedaten die Ausgabedaten mit möglichst wenig Fehlern berechnet werden können. Die Gesamtheit dieser Funktionen wird auch als „Modell“ und die Optimierung (im Sinne der Minimierung einer Verlustfunktion) des Modells als „Training“ bezeichnet. Die optimalen Parameter eines Modells werden im Rahmen des Trainings anhand des Validierungsdatensatzes eingestellt. Wie zuverlässig Modelle dann tatsächlich sind, lässt sich exemplarisch mittels (bei Training und Validierung nicht verwendeten) Testdaten ermitteln. Das Ziel des ML ist in der Regel, sowohl Falsch-Negativ-Fehler (relevantes Objekt nicht erkannt) als auch Falsch-Posi-

tiv-Fehler (fälschlicherweise ein relevantes Objekt erkannt) auf ein akzeptables Maß zu minimieren. Trainierte und getestete Modelle können dann im Betrieb verwendet werden, um aus neuen, beim Training und Test noch unbekanntem Eingabedaten die Ausgabedaten zu berechnen, also beispielsweise auf neuen Kamerabildern Objekte zu erkennen.

Grundlage für ML sind Datensätze aus Ein- und Ausgabedaten, anhand derer ein ML-Algorithmus „lernen“ kann. Bei der Objekterkennung bei ATO sind die Eingabedaten etwa Sensordaten, die die relevanten Bereiche (z.B. Fahrweg vor dem Zug) mit den geeigneten Modalitäten (z.B. Farbe, räumliche Distanz, Wärmeabstrahlung) erfassen. Außerdem müssen die zu erkennenden Objekte (z.B. Personen, Gleise) in den geplanten Einsatzumgebungen (z.B. Bahnhof, freie Strecke, Rangiergleis) und über mehrere Zeitpunkte in Folge erfasst sein. Die Ausgabedaten umfassen alle Daten, die das zu entwickelnde ML-Modell aus den Eingabedaten ableiten können soll. Das sind beispielsweise Koordinaten (bezogen auf einzelne Sensordaten) der Bereiche, in denen sich zu erkennende Objekte befinden, Klassifizierungen der Objekte oder Ausprägungen von Objektattributen. Diese Daten werden auch als „Annotationen“ bezeichnet und müssen überwiegend manuell erstellt oder zumindest manuell geprüft werden, um sicherzustellen, dass die ML-Algorithmen die korrekten Ausgabedaten als „Lernziele“ erhalten.

Bild 1 fasst die Entwicklung und Verwendung von Ein- und Ausgabedaten bei Datenaufbereitung, Training/Validierung/Test und Betrieb vereinfacht zusammen.

3. Entwicklung eines offenen Multisensordatensatzes

Bei der Entwicklung des Trainings-, Validierungs- und Testdatensatzes für die Objekterkennung bei ATO sind die wesentlichen Komponenten der Sensordatensatz (Eingabedaten für Training/Test/Validierung), die Annotationsvorschrift (Vorgaben für die manuelle Erstellung der Annotationen) und der annotierte Datensatz.

3.1. Sensorkonfiguration und Sensordatensatz

Der im Rahmen des Projektes annotierte Sensordatensatz wurde in mehreren Datenerhebungsfahrten in Hamburg durch die DB Netz AG aufgezeichnet. Der Datensatz umfasst reguläre Betriebsumgebun-



2: Sensorkonfiguration am Datenerhebungsfahrzeug

Quelle: DB Netz AG

Tabelle 2: Übersicht der annotierten Objektgruppen und -klassen

Gruppe	Dynamische Objekte	Schienenobjekte	Statische Objekte	Spezielle Objekte
Klassen	Person	Gleis	Oberleitungsmast	Flamme
	Menschenmenge	Übergang	Signalmast	Rauch
	Zug	Weiche	Signal	
	Wagons		Signalbrücke	
	Fahrrad		Prellbock	
	Gruppe von Fahrrädern			
	Motorrad			
	Straßenfahrzeug			
	Tier			
	Gruppe von Tieren			
	Rollstuhl			
	Hemmschuh			

gen und -situationen. Einige besondere Situationen und Objekte (Flammen und Rauch) wurden gestellt.

Die Sensorkonfiguration umfasste insgesamt sechs Farbbildkameras, drei Infrarotkameras (IR), sechs LiDAR-Sensoren mit unterschiedlichen Reichweiten und Erfassungsbereichen, einen Radar-Sensor sowie Positions- und Beschleunigungssensoren. Die wesentlichen technischen Spezifikationen sind in Tabelle 1 aufgeführt. Die Sensoren wurden an der Spitze eines Gleisarbeitsfahrzeugs montiert und zueinander kalibriert. Bild 2 zeigt die Montage der Sensoren an der Spitze des Fahrzeugs. Die Erfassungsbereiche der Sensoren erfassten den Bereich vor und teilweise seitlich des Fahrzeugs und überschneiden sich zum Teil.

Die Daten eines Sensors zu einem Erhebungszeitpunkt werden als „Frame“ bezeichnet. Der Zusammenschluss der Frames aller Sensoren zu einem Erhebungszeitpunkt wird als „Multisensor-Frame“ (M-Frame) bezeichnet. Zusammengehörige M-Frames in zeitlicher Abfolge bilden eine Sequenz. Die Frames der verschiedenen Sensoren wurden parallel und zeitlich synchronisiert aufgenommen. Um die niedrigere Abtastfrequenz des Radars auszugleichen, wurden Dubletten der Radar-Frames eingefügt. Die Punktdaten der LiDARs liegen als fusionierte Punktdaten vor.

Da die Sensordaten reguläre Betriebsumgebungen und -situationen abdecken, wurden auch personenbezogene Daten wie Gesichter und Kfz-Kennzeichen erfasst. Die-

Der Multisensor-Datensatz OSDaR23 umfasst rund 204.000 Annotationsobjekte aus 20 verschiedenen Objektklassen.

se wurden vor der Veröffentlichung mittels Weichzeichner unkenntlich gemacht.

3.2. Annotationsvorschrift

Eine Annotationsvorschrift bildet die Grundlage für die manuelle Erstellung eines Annotationsdatensatzes durch die annotierenden Personen. Eine Annotationsvorschrift definiert

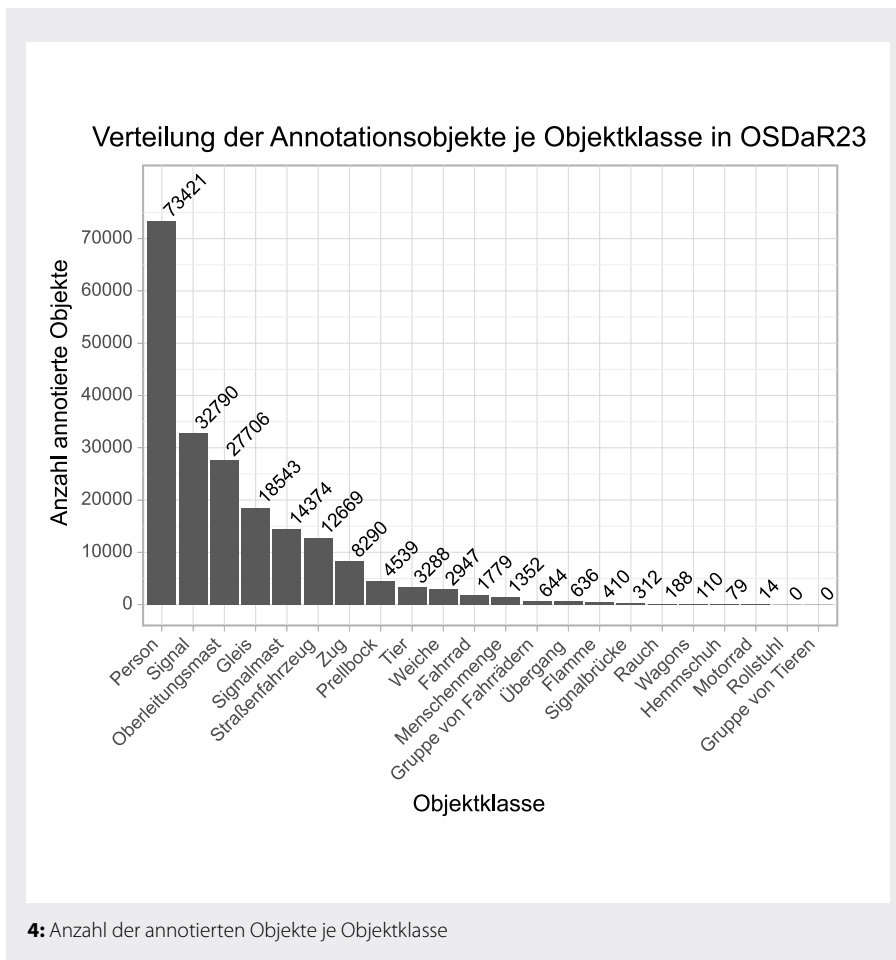
- für welche Sensordaten die Vorschrift anwendbar ist,
- welche Annotationsarten (Geometrien, Attribute) für die Annotation verwendet werden,
- welche Objektklassen (z.B. Personen, Fahrzeuge) annotiert werden,
- die allgemeinen und klassenspezifischen Annotationsregeln für die Erstellung der Annotationen (Erstellung der Geometrien, Klassenzuordnung, Auswahl der Attributausprägungen usw.) und
- das Format, in dem die Annotationen gespeichert werden.

Die Annotationsvorschrift im Projekt bezieht sich auf die beschriebenen Sensordaten (Bilder aus Farbbild- und IR-Kameras sowie dem Radar, Punktdaten aus den LiDARen). In den Kamera- und Radar-Frames kommen als zweidimensionale (2D) Annotationsgeometrien achsenparallele und rotierte Rechtecke (engl. „Bounding Box“), Polylinien und Polygone zum Einsatz. Die Rechtecke und Polygone fassen die annotierten Objekte in den Sensorbildern möglichst genau ein, die Polylinien folgen bestimmten Konturen von Objekten. Im LiDAR kommen dreidimensionale (3D) Quader und Polylinien sowie semantische Segmentierungen zum Einsatz. Quader und Polylinien fassen Objekte analog zu den 2D-Annotationen ein beziehungsweise markieren Konturen. Bei semantischen Segmentierungen werden einzelne LiDAR-Punkte einem Objekt zugeordnet.

Mittels dieser Geometrien wurden Objekte aus 22 verschiedenen Klassen aus vier Gruppen annotiert (s. Tabelle 2). Alle

Homepageveröffentlichung unbefristet genehmigt für Deutsches Zentrum für Schienenverkehrsforschung (DZSF), DB Netz AG, FusionSystems GmbH / Rechte für einzelne Downloads und Ausdrücke für Besucher der Seiten genehmigt / © DVV Media Group GmbH

3: Beispiel eines M-Frames mit Daten aller Sensoren und Annotationsgeometrien Quelle: DZSF



Objektannotationen besitzen Tracking-IDs, anhand derer sie in allen M-Frames einer Sequenz demselben Realweltobjekt zugeordnet werden können. Die Annotationsdaten wurden im Format ASAM OpenLABEL [11] gespeichert. Details zu Klassenattributen, Annotationsregeln und dem Speicherformat sind im Projektbericht und in der separat veröffentlichten Annotationsvorschrift dargestellt.

3.3. Annotierter Datensatz

Der annotierte Datensatz OSDaR23 [9] umfasst 21 Sequenzen (unterteilt in 45 Teilsequenzen) mit insgesamt 1534 annotierten M-Frames und rund 204.000 Annotationsobjekten. Ein Annotationsobjekt bezeichnet dabei die Annotation eines in einem Sensor zu einem Zeitpunkt erfassten Realweltobjekts. Ein Realweltobjekt wird typischerweise in mehreren Sensoren und über mehrere Zeitpunkte erfasst und ist deshalb in mehreren Annotationsobjekten abgebildet. Bild 3 zeigt ein Beispiel eines M-Frames mit Eingabedaten aller bildgebenden Sensoren und Ausgabedaten in Form von Annotationsgeometrien der Annotationsobjekte.

Um eine große Vielfalt von Objektklassen und Umgebungen abzudecken und gleichzeitig die Nachverfolgung von Objekten zu ermöglichen, enthält der Datensatz sowohl mehrere kürzere Sequenzen von verschiedenen Orten und Situationen mit jeweils zehn M-Frames als auch einige längere Sequenzen (40 bis 100 M-Frames).

Die häufigsten Annotationsobjekte sind Personen (z. B. Fahrgäste, Betriebspersonal) gefolgt von verschiedenen Arten von Infrastrukturobjekten (Signale, Fahrleitungsmasten, Gleise, Signalmasten, Prellböcke), Straßenfahrzeugen und Zügen. Bild 4 gibt einen Überblick der Verteilung der Annotationsobjekte über die Objektklassen. (Die spezifizierten Objektklassen „Rollstuhl“ und „Gruppe von Tieren“ waren im annotierten Teil der Sensordaten nicht vorhanden.)

4. Ergebnisse und Ausblick

Die Projektergebnisse können für die Entwicklung von KI-Modellen für die Objekterkennung bei ATO verwendet werden. OSDaR23 [9] ist nach Kenntnis der Autoren der erste Datensatz speziell für den Bahnbereich, der diese Vielzahl an Sensoren und Sensormodalitäten und zugleich eine Vielzahl von Objektklassen und Annotati-

onsgeometrien umfasst und prinzipiell alle genannten Bildanalyseaufgaben abdeckt.

Es sind aber voraussichtlich weitere Datensätze erforderlich, um Umfeldwahrnehmungssysteme mit der nötigen Genauigkeit zu entwickeln. Weitere Datensätze sollten dabei

- Sensordaten mit verschiedenen Sensor-konfigurationen erfassen,
- quantitativ die Datenmenge vergrößern,
- qualitativ die erfassten Objektklassen und -attribute, Geometrien, Umgebungen, Situationen und Ereignisse erweitern und dabei
- insbesondere (voraussichtlich gestellte) kritische und Störfallereignisse abdecken.

Der veröffentlichte Datensatz und die Annotationsvorschrift können als Referenz für diese Erweiterungen dienen. Alle Akteure im Bahnsektor sind eingeladen, sich hieran zu beteiligen und nach Möglichkeit Datensätze durch Veröffentlichung auch einem breiteren Kreis in Forschung und Entwicklung zugänglich zu machen.

Der annotierte Datensatz wird weiterhin in der Data-Factory der DSD verwendet [12]. Die Data-Factory ist eine Plattform für die systematische Bereitstellung und Verarbeitung von Sensordaten für die Entwicklung von KI-Funktionen und für die Simulation fotorealistischer Bahnszenarien sowie künstlicher Sensordaten. In der Data-Factory werden auf Basis des annotierten Datensatzes KI-Funktionalitäten entwickelt sowie simulierte Sensordaten mit den Realdaten verglichen.

Das DZSF setzt die Aktivitäten bei Aufbereitung und Veröffentlichung von Sensordaten mit Unterstützung der DB Netz AG im Rahmen der DSD fort. Im Folgeprojekt „Weiterentwicklung der offenen Datengrundlagen für die Objekterkennung und -klassifizierung mittels künstlicher Intelligenz beim automatisierten Fahren im Schienenverkehr“ werden weitere annotierte Multisensordaten, die in anderen Umgebungen und voraussichtlich mit zwei verschiedenen Sensorkonfigurationen erhoben wurden, erstellt.

5. Danksagung

Die Autoren danken ihren Kollegen Dr. Kai Hofmann (DZSF), Florian Reiniger, Markus-Franz Ziegler, Volker Eiselein, Martin Boekhoff, Arne Jacobs (alle DB Netz AG) sowie Michael Scheithauer, Kai-Uwe Kaden und Kevin Förster (alle FusionSystems GmbH) für die Unterstützung im Projekt. ●

Literatur

- [1] BMDV (2018): Autonomes Fahren im Schienenverkehr. FE-Nr. 97.370/2016.
- [2] Schröder, J.; Gonçalves, C.; Dickgiesser, B.; Talg, M. (2021): Digitale S-Bahn Hamburg, DER EISENBAHNINGENIEUR, 10/2021.
- [3] Klotz, C.; Leinhos, D.; Ponholzer, F.; Witte, S.; Sprute, D. (2022): Test- und Trainingsdaten für ATO-Perzeptionssysteme – Anforderungen an ein Messsystem, ETR - Eisenbahntechnische Rundschau, 10/2022.
- [4] Hauswald, C.; Spiegel, D.; Kreyenberg, D.; Fiack, A. (2022): Digitale Schiene Deutschland testet im Projekt Sensor4Rail erstmals sensorbasierte Wahrnehmungssysteme im Bahnbetrieb, Deine Bahn, 4/2022.
- [5] Tagiew, R.; Buder, T.; Tilly, R.; Hofmann, K.; Klotz, C. (2021): Datensätze für das autonome Fahren als Grundlage für GoA3+, ETR - Eisenbahntechnische Rundschau, 9/2021.
- [6] Zendel, O.; Murschitz, M.; Zeilinger, M.; Steining, D.; Abbasi, S.; Beleznai, C. (2019): Railsem19: A dataset for semantic rail scene understanding, IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops (CVPRW). S. 1221–1229, 2019.
- [7] Harb, J.; Reben, N.; Chosidow, R.; Roblin, G.; Potarsov, R.; Hajri, H. (2020): FRSign: A large-scale traffic light dataset for autonomous trains [online]. Verfügbar unter: <https://arxiv.org/abs/2002.05665>.
- [8] Toprak, T.; Belenlioglu, B.; Aydin, B.; Guzelis, C.; Selver, M. A. (2020). Conditional weighted ensemble of transferred models for camera based onboard pedestrian detection in railway driver support systems, IEEE Transactions on Vehicular Technology. Bd. 69, Nr. 5. 5041–5054, 2020.
- [9] Tilly, R.; Neumaier, P.; Schwalbe, K.; Klasek, P.; Tagiew, R.; Denzler, P.; Klockau, T.; Köppel, M. (2023): Open Sensor Data for Rail 2023 (OSDaR23) [Datensatz]. Verfügbar unter: <https://doi.org/10.57806/11ko3te4>.
- [10] Leinhos, D.; Flatt, H.; Witte, S. (2022): Sensorik als technische Voraussetzung für ATO-Funktionen, Deutsches Zentrum für Schienenverkehrsforschung beim Eisenbahn-Bundesamt, Dresden.
- [11] Association for Standardization of Automation and Measuring Systems, 2021. ASAM OpenLABEL [online]. Verfügbar unter: <https://www.asam.net/standards/detail/openlabel/>.
- [12] Digitale Schiene Deutschland und P. Neumaier (2022): Die Data Factory – „Datenproduktion“ für das Training von KI-Software [online]. Verfügbar unter: <https://digitale-schiene-deutschland.de/aktuelles/Data-Factory>.

Summary

Open multi sensor data set for the development of environment perception in fully automated driving

For the perception of the environment in automated driving in the full rail range, machine learning methods (ML) will also be applied. However, the data sets necessary for their development are barely available to the public at the moment. In a project of DZSF and DB Netz AG within the framework of the sector initiative Digitale Schiene Deutschland, a multi-sensor dataset (colour image, infrared, lidar, radar) for ML was created and published under Creative Commons licence, containing around 204,000 object annotations.