



*understand.ai* fokussiert auf die automatisierte Datenanalyse, Datenannotation und Extraktion von Simulationsszenarien für autonome Fahrzeuge.

© understand.ai

## DATENVEREDELUNG BEIM AUTOMATISIERTEN FAHREN

# Annotationsprojekte effizient gestalten

Um Algorithmen KI-basierter Systeme für das autonome oder hochautomatisierte Fahren zu trainieren, müssen immense Datenmengen gesammelt und weiterverarbeitet werden. Es gilt, zahlreiche Herausforderungen zu bewältigen, damit selbstfahrende Autos künftig ihre Umwelt mit allen wesentlichen Details wahrnehmen, die richtigen Entscheidungen treffen und Menschen sicher an ihr Ziel bringen.

**G**ehen wir zunächst der Frage nach, warum die für das Training benötigten Datenmengen so groß sein müssen: Mit KI-basierten Systemen lassen sich schnell gute Fortschritte erzielen. Allerdings lässt der über die Zeit erzielbare Fortschritt ab einem gewissen Punkt stark nach. Insbesondere muss sichergestellt werden, dass Fahrsysteme auch mit sehr selten vorkommenden Szenarien (rare events) sinnvoll und sicher umgehen können. In der Folge werden immer mehr und qualitativ höherwertige Daten benötigt, um anspruchsvolle KI-basierte Fahrfunktionen sicher nutzbar zu machen (Bild 1).

Grundsätzlich müssen KI-Funktionen in Produktionssystemen eine sehr hohe Zuverlässigkeits-Schwelle überschreiten, bevor sie in der Realität eingesetzt

werden können. Dies gilt insbesondere für das automatisierte Fahren, da die damit einhergehenden Sicherheitsrisiken erheblich sind. Die tragischen Unfälle mit Fahrzeugen von Uber und Tesla sind mahnende Beispiele. Entsprechend fordern Zulassungsstellen immer anspruchsvollere Absicherungsmaßnahmen für höherwertige Fahrfunktionen, damit deren korrekte Funktionsweise garantiert werden kann. Da diese Absicherungsmaßnahmen oft auf Kilometer-Vorgaben beruhen, bringen sie die Notwendigkeit zur Verarbeitung sehr großer Datenmengen mit sich (Bild 2).

### Beispiel aus der Praxis

Das nachstehende Rechenbeispiel soll ein Gefühl dafür vermitteln, welche Da-

tenmengen verarbeitet werden müssen, um ein kombiniertes Radar- und Kamerasystem (Sensorsystem) abzusichern. Im Beispiel muss die korrekte Funktionsweise des Sensorsystems über eine Distanz von 300.000 km mit einem vorgegebenen Mix an Fahr-Szenarien nachgewiesen werden. Dabei liefert das Sensorsystem eine Objektliste, die das Umfeld des Fahrzeuges beschreibt.

Um die Korrektheit der Objektliste des Sensorsystems überprüfen zu können, wird eine Vergleichsliste, die so genannte Ground Truth, benötigt. Diese wird mit Hilfe eines Referenzsensor-Sets, bestehend aus Kamera und LiDAR erzeugt. Das Referenzsensor-Set wird in Form einer Roof-Top-Box zusätzlich zu den zu überprüfenden Sensoren im

Fahrzeug installiert. Der Datenstrom des Referenzsensor-Sets wird mittels eines Annotations-Prozesses in die Ground Truth-Objektliste überführt. Durch den systematischen Vergleich beider Objektlisten werden Abweichungen erkannt und es können Korrekturmaßnahmen abgeleitet werden (Bild 3).

**Aufwandsabschätzung**

Zur Abschätzung des Annotations-Aufwandes – der immer noch zu einem signifikanten Anteil von Menschen übernommen wird – werden nachstehende Annahmen zu den Parametern des Referenzsensor-Aufbaus zu Grunde gelegt.

- LiDAR Frequenz:: 10 Frames/Sekunde
- Erreichte Durchschnittsgeschwindigkeit: 45 km/h
- Durchschnittliche Anzahl von Objekten (Fahrzeuge, Fußgänger, Motorräder) pro Frame: 30 Objekte/Frame

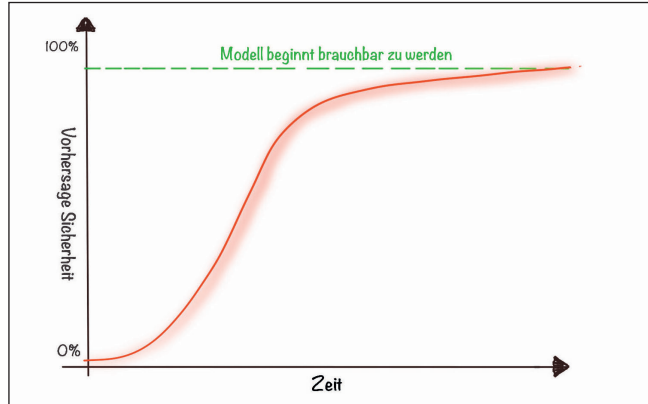
Beispielrechnung:

Fahrzeit in Sekunden:  $300.000 \text{ km} / 45 \text{ km/h} = 6.666 \text{ h} = 23.997.600 \text{ s}$

Anzahl an Frames:  $23.997.600 \text{ s} * 10 \text{ f/s} = 239.976.000 \text{ f}$


Anzahl Objekte:  $239.976.000 \text{ f} * 30 \text{ o/f} = 7.199.280.000 \text{ o}$

Es ergibt sich also ein Annotations-Bedarf von ca. 7 Milliarden Objekten. State-of-the-Art Systeme erzielen einen Durchsatz von ca. 2,5 s pro Objekt im 3D-Raum (siehe Bild 4). Die benötigte Zeit ist Ende-zu-Ende, also über alle Annotations-, Review- und Korrekturschritte hinweg, vom Import bis zum Export gemessen.



**Bild 1: Lernfortschritt im zeitlichen Verlauf.**

© understand.ai



**Bild 2: Schwellwert, ab dem ein Modell einsetzbar wird.**

© understand.ai

- Zeitaufwand in Sekunden:  $7.199.280.000 \text{ o} * 2,5 \text{ s/o} = 17.998.200.000 \text{ s}$
- Arbeitszeit:  $17.998.200.000 \text{ s} = 4.999.500 \text{ h} = 624.937 \text{ t}$

Bei einer Projektlaufzeit von 3 Jahren (220 Arbeitstage pro Jahr) wäre dementsprechend ein Annotations-Team mit einer durchschnittlichen Größe von 950 Personen notwendig.


Die Schlussfolgerung dieser Beispielrechnung: Die Herausforderung liegt in der Bereitstellung eines Daten-Annotations-Systems, dass ständig in der Lage ist, 950 Personen mit hinreichend viel Arbeit zu versorgen und dabei – über alle Mitarbeiter und Fähigkeits-Level hin-

weg – bei vorgegebener Zielqualität – eine durchschnittliche Bearbeitungszeit pro Objekt von 2,5 s ermöglicht. Darüber hinaus muss die durchschnittliche Bearbeitungszeit pro Objekt (und damit der Kosten) im Verlauf des Projektes weiter gesenkt werden. Um die beschriebene Herausforderung zu meistern, müssen mehrere kritische Prozessschritte, ohne Medienbrüche ablaufen.

**Data Collection**

Für das Sammeln der Daten werden ausreichend Fahrzeuge auf der Straße benötigt, damit die benötigten Daten-

# eMobility Measurement Technology



Messtechnik für die Mobilität von Morgen

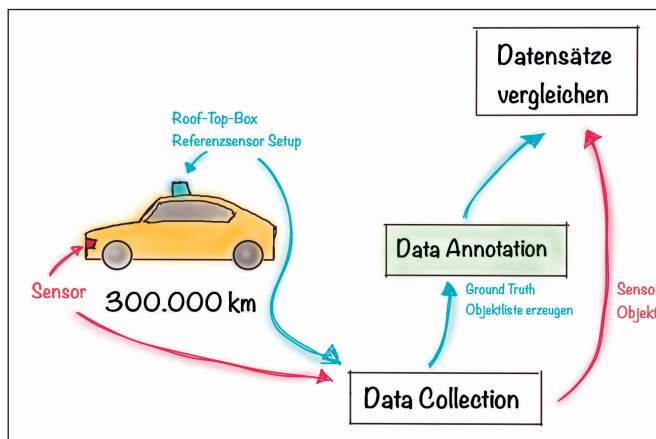


Bild 3: Aufbau eines Absicherungs-Projektes. © understand.ai




Bild 4: Darstellung annotierter Objekte im 3-D-Raum. © understand.ai

mengen eingefahren und zur Weiterverarbeitung bereitgestellt werden können. Das von dSpace angebotene Autera-System ermöglicht die zuverlässige Aufzeichnung der Sensor- und Telemetriedaten im Fahrzeug und eine bruchlose Weitergabe der Daten

Bevor die aufgezeichneten Daten weiterverarbeitet werden können, müssen sie entsprechend der für die jeweiligen Region gültigen Datenschutz-Verordnung anonymisiert werden. Das bedeutet, dass identifizierende Merkmale wie Nummernschilder und Gesichter, teilweise auch GPS Daten, unkenntlich gemacht werden müssen (Bild 5). Die Anonymisierung muss idealerweise vollautomatisch und mit hinreichender Geschwindigkeit vorgenommen werden, um nicht zum Flaschenhals für das Gesamtprojekt zu werden. Understand.ai bietet hierfür mit dem Anonymizer eine Lösung an, die diese notwendigen Anforderungen ausgezeichnet erfüllt und in zahlreichen Projekten Ihre Zuverlässigkeit unter Beweis gestellt hat.

**Data Selection**

Für Trainingsprojekte ist es unabdingbar, eine sinnvolle Reduktion der Daten vorzunehmen. Dabei müssen genau diejenigen Szenarien ausgewählt werden, die den größten Lerngewinn für die zu trainierenden Algorithmen bieten. Dieser Vorgang ist zu Beginn der Entwicklungsphase relativ einfach; in Bild 1 ist jedoch erkennbar, wie sich der erzielbare Fortschritt ab einem gewissen Punkt stark verlangsamt. Zu Beginn des Trainings sind sehr viele der aufgenommenen Szenarien neu für den Algorithmus oder liegen noch nicht in ausreichender

Anzahl vor. In dieser Phase werden schnell Fortschritte erzielt. Mit fortschreitender Reife der Algorithmen wird es jedoch immer schwieriger interessante Daten zu "finden". Wahrscheinlich können dann nur noch im Abstand von einigen tausend Kilometern wertvolle, neue Szenarien aufgezeichnet werden. Dies macht immer größere Testflotten notwendig. Spätestens jetzt werden die gängigen Ansätze über dedizierte Testflotten mit eigenen Testfahrern zum limitierenden Faktor. Einen anderen Weg geht Tesla: Dank standardmäßig verbauter Sensoren fahren die Kunden mit Ihren Fahrzeugen die Daten ein. Damit kann Tesla auf eine fast unbegrenzte Datenmenge zugreifen – einschließlich der anfangs erwähnten "rare-events"

**Data Annotation**

Im nächsten Schritt müssen die ausgewählten Daten annotiert werden. Das Ergebnis sind hochgenaue und detaillierte Objektlisten. Obwohl bei der Offline-Annotation (im Gegensatz zur Echtzeiterkennung im Fahrzeug während der Fahrt) auf eine Vielzahl von Hilfsmitteln und modernste Technik mit nahezu unbegrenzter Rechenpower zurückgegriffen werden kann, bleibt doch ein relevanter Teil an manueller Arbeit zu erledigen. Im oben ausgeführten Beispiel sind selbst bei einer 95%igen Automatisierung immer noch 395.954.000 Objekte manuell zu annotieren.


Um das Level an manueller Arbeit so weit wie möglich zu senken und bei gegebenen Qualitätsanforderungen den notwendigen Durchsatz zu erreichen, kommen eine Reihe unterschiedlicher Automatisierungs-Strategien zum Ein-

satz:

- Regression: Hier geht es um die Box-Tightness, also die Passgenauigkeit der Annotation. Übliche Labelinganforderungen gehen von 2 – 4 Pixeln Toleranz aus. Understand.ai setzt auf Deep-Learning basierte Techniken, um Boxen automatisch passgenau einzustellen.
- Object Detection: Die automatische Detektion von Objekten kann helfen, viel Zeit bei der Lokalisierung und Identifikation von Objekten einzusparen. Insbesondere im 3D-Raum kann die Lokalisierung für weit vom Sensor entfernte Objekte mit nur noch geringer LiDAR Abdeckung sehr viel Zeit in Anspruch nehmen.
- Classification: Für bestimmte Objekteigenschaften wie Blinker, Bremslichter, Verkehrsschilder, Verdeckungen und ähnliches setzt understand.ai ebenfalls KI-basierte Systeme ein, um ganz erheblich Zeit einzusparen und die Qualität zu optimieren.

**Model Based Interpolation, Extrapolation & Propagation**

Durch Interpolation, bei der nur Keyframes manuell annotiert werden, die dazwischen liegenden Frames aber automatisch, kann ein hoher Automatisierungsgrad erreicht werden. Dabei sind Objekte, die auf zwischen liegenden Frames erscheinen oder verschwinden, eine besondere Herausforderung. Auch sind Standard-Interpolationsverfahren wenig hilfreich, da zu ungenau. Einen Lösungsansatz stellen modellbasierte Interpolations-, Extrapolations und Pro-



**Bild 5: Kennzeichen und Gesichter werden anonymisiert (rechts im Bild).**

© understand.ai

der Beispielrechnung Leerlauf ergeben. Zudem muss es über Mechanismen verfügen, mit denen die anfallende Arbeit möglichst intelligent auf die Labeling Crew verteilt werden kann. Dadurch wird sichergestellt, dass das Team zur richtigen Zeit an den richtigen Aufgaben arbeitet, um das Projekt voran zu bringen.

**Fazit**

Nur mit den richtigen Daten, in der richtigen Qualität und der richtigen Menge können anspruchsvolle Fahrfunktionen in Produktion gebracht werden. Mit den von understand.ai und dSpace entwickelten Systemen zur Large-Scale-Datenveredelung kann diese Herausforderung gemeistert werden. ■ (oe)

[www.dspace.com](http://www.dspace.com)



**Daniel Rödler** ist Produkt Manager bei understand.ai.

pagations-Verfahren dar. Hiermit werden typische Bewegungsmuster für Objektklassen erlernt und daraus natürliche Bewegungsabläufe abgeleitet. Die Interpolationsraten können dadurch deutlich erhöht werden. Eine entscheidende Komponente für ein Annotationsprojekt ist das Workflow Management System. Es muss hinreichend flexibel sein, um unterschiedlichste Projektanforderungen abdecken

zu können. Understand.ai setzt Workflows beliebiger Komplexität aus einzelnen Bausteinen zusammen. Diese Bausteine können entweder manuelle Arbeitspakete zur Folge haben oder automatisiert Aufgaben durchführen. Es muss hochverfügbar sein, um den permanenten Fluss der Daten durch die Annotations-Produktionslinie zu gewährleisten. Fällt das System aus, würde sich für die 950 Labeling-Experten aus



**emotive**

Testing Next Generation

Komplexität beherrschen • barrierefrei, einfach  
prozesssicher • 100% standardkonform

Open Test Framework  
Open Test Runtime  
Open Test Player



[www.emotive.de](http://www.emotive.de)

**OTX**  
ISO 13209