

The challenge of using artificial intelligence in autonomous driving

Michael Sachse, André Müller, Klaus Krumbiegel
 Hochschule Mittweida, Technikumplatz 17, 09648 Mittweida

Durch die steigende Leistungsfähigkeit von Prozessoren und Datenübertragungstechniken hat die Entwicklung und Anwendung von künstlicher Intelligenz, exemplarisch das maschinelle Lernen (engl. Machine Learning – ML) und die Methode des Deep Learning, in den letzten Jahren stark an Bedeutung gewonnen. Hierbei stellt sich die Frage, wie diese Technologien in einem weiteren zukunftssträchtigen Entwicklungsfeld, zum Beispiel bei der Entwicklung moderner Mobilitätskonzepte und hochautomatisierter/autonomer Fahrzeuge, eingesetzt werden können.

Potentielle Möglichkeiten der Anwendung von AI im Entwicklungsprozess eines hochautomatisierten Fahrzeugs werden vorgestellt, aber auch die entscheidenden Herausforderungen diskutiert. Darüber hinaus wird der Unterschied zwischen verschiedenen Ansätzen ausgeführt. Dazu werden sowohl Randbedingungen als auch Herausforderungen mit Hilfe eines einfachen Beispiels aus dem täglichen Verkehrsgeschehen veranschaulicht.

1. Einleitung

Der Einsatz von Künstlicher Intelligenz ist einer der aktuellen Trends und Forschungsschwerpunkte verschiedenster Domänen in Wirtschaft und Forschung. Dabei wird der Begriff oft sehr weit gefasst – von eher klassischen intelligent erscheinenden Algorithmen und statistischen Methoden, bis hin zu selbstlernenden Systemen, etwa auf Basis von künstlichen neuronalen Netzen.

Die Verwendung von künstlichen Intelligenzen stellt die Automotive Industrie nicht nur technologisch, sondern auch methodisch vor Herausforderungen. Aktuelle Entwicklungsprozesse, z.B. basierend auf Automotive Spice, benötigen Anforderungen als Grundlage für die Entwicklung von Software. Der Einsatz von Neuronalen Netzen mit sichtbaren Schichten steht diesem entgegen. Diese Herausforderung wird auch im Rahmen des SOTIF-Normierungsvorhabens diskutiert [1]. Resultierend sollte ein besonderes Augenmerk auf die Spezifikation der gewünschten Funktionalität in Kombination mit Anwendungsfällen und Szenarien gelegt werden. Die relevanten Szenarien für die Anwendungsfälle und die Funktion werden in Kategorien eingeteilt, welche in Abbildung 1 dargestellt sind. Das Ziel ist es unbekannte und gefährdende Szenarien zu minimieren.

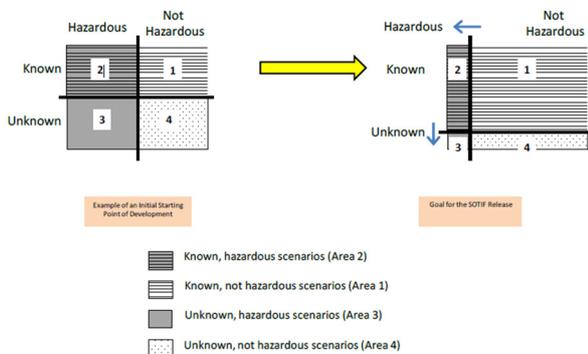


Abbildung 1: Scenario Classification and SOTIF-Goal [1]

2. Entscheidungskette an einem Beispiel

Der Informationsfluss im Fahrzeug kann angelehnt an die Informationsverarbeitung des Menschen in verschiedene Phasen unterteilt werden. Die Wahrnehmung der Umgebung erfolgt mit Hilfe von Sensoren oder aber auch a priori Wissen (z.B. Karten). Die daraus resultierenden Daten müssen anschließend verarbeitet und mögliche Situationen oder Szenarien antizipiert werden. Basierend auf diesen Informationen kommt es zu einer Entscheidung der Fahrstrategie und folgender Umsetzung.

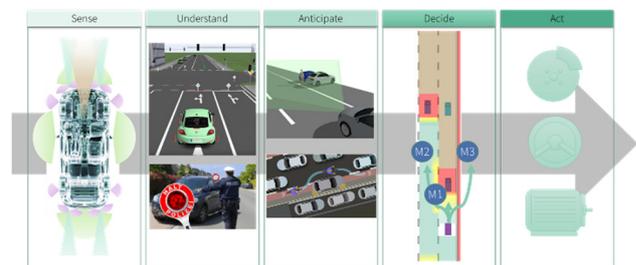


Abbildung 2: Verarbeitungskette im Fahrzeug

In der Sensorik werden schon seit einigen Jahren Mechanismen der künstlichen Intelligenz angewendet. Insbesondere im Bereich der kamerabasierten Umfelderkennung erfolgt mit Hilfe von Machine Learning die Detektion und Klassifikation von Objekten wie Fahrzeugen, LKWs und Verkehrszeichen. In der Analyse und Interpretation der aktuellen Situation ist die Nutzung von Machine Learning ebenfalls möglich oder sogar in spezifischen Problemen erforderlich.

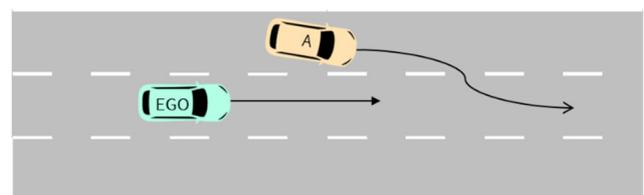


Abbildung 3: Einscherserszenario

Eine nahezu alltägliche Situation stellt das Einscheren eines anderen Fahrzeugs im Straßenverkehr dar. Für den heutigen Stand der Technik beinhaltet dieses Szenario eine Vielzahl von Herausforderungen. So lässt sich das genannte Szenario mit über 20 Parametern abbilden, welche untereinander Abhängigkeiten haben und deren Werte lediglich einen konkreten Zeitpunkt beschreiben und nur bedingt zeitliche Abhängigkeiten repräsentieren. Darüber hinaus ist die weitere Entwicklung des Szenarios nicht eindeutig, selbst wenn physikalische Grenzen betrachtet werden. Tabelle 1 zeigt eine Auswahl an möglichen Parametern.

x_A	Abstand in X-Richtung Ego zu Fahrzeug A
y_A	Abstand in Y-Richtung Ego zu Fahrzeug A
vx_A	Geschwindigkeit in X-Richtung von Fahrzeug A
vy_A	Geschwindigkeit in Y-Richtung von Fahrzeug A
ax_A	Beschleunigung in X-Richtung von Fahrzeug A
ay_A	Beschleunigung in Y-Richtung von Fahrzeug A
α_A	Kurswinkel von Fahrzeug A
L_t	Typ der Ego Fahrspur
L_w	Breite der Ego Fahrspur
	Etc...

Tabelle 1: Mögliche Parameter zur Szenariobeschreibung

Bei der Prozessierung des Szenarios sind in der Regel mehrere Softwaremodule beteiligt. Die Funktionalität soll dafür über klare deterministische Regeln und Modelle als Anforderungen beschrieben und implementiert werden. Dafür wird eine Vielzahl von Parametern eingeführt, welche voneinander abhängen und die Funktionalität beeinflussen. Klassische Beispiele für solche Parameter sind Schwellwerte für Entscheidungen, die Trajektorienberechnung und -auswahl oder Regelungsparameter. In einem autonomen Fahrzeug kann nach heutigem Stand der Technik von mehreren tausend bis zehntausenden Parametern ausgegangen werden.

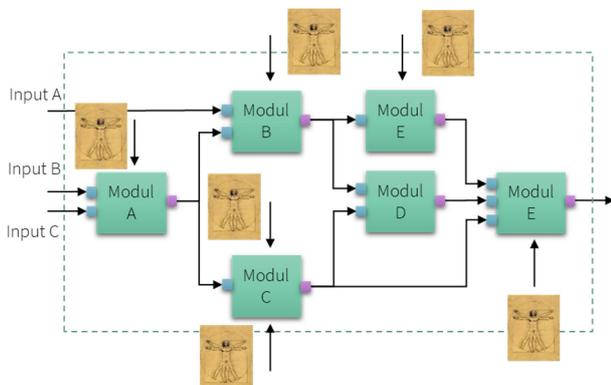


Abbildung 4: SW-Architekturschema einer Entscheidungskette

Die manuelle Kalibrierung dieser Anzahl an Parametern, insbesondere in Abhängigkeit von den Szenario-Parametern, ist zeitlich sehr aufwendig und somit nicht praktikabel. Hinzu kommt, dass in der Regel die Lösungen und Funktionen eine Abstraktion der Realität darstellen und so unter anderem, nicht lineare Zusammenhänge in meist linearisierten Regeln abgebildet werden. Die manuelle Einstellung eines Parameters bezüglich der Verbesserung eines Szenarios kann zu einer Verschlechterung eines anderen Szenarios führen, was für den menschlichen Entwickler auf Grund der Komplexität nicht vorhersehbar ist.

Eine weitere Herausforderung stellen die zumeist gegensätzlichen Ziele aus den Bereichen Komfort und Sicherheit dar. So kann eine Fahrfunktion mit einer gewählten Parametrierung sicher ausgelegt sein, widerspricht aber gewissen Anforderungen an den Fahrkomfort. Weiterhin muss die Gesamtheit von auftretenden oder zu beherrschenden Fahrsituationen betrachtet werden, denn eine sichere Auslegung einer Fahrfunktion in Bezug auf eine Einzelsituation kann das Risiko in einer anderen Fahrsituation erhöhen.

3. Kalibrierung der Entscheidungskette

Wie bereits erwähnt, ist die Kalibrierung von mehreren Parametern auf Grund der gegenseitigen Beeinflussung über eine Entscheidungskette manuell nur schwer möglich. Aus diesem Grund kann ein Parameteroptimierungsablauf bezüglich der Entscheidungskette entwickelt werden. Dieser Workflow ist grob in Abbildung 2 dargestellt und unterstützt den Ansatz der szenarienbasierten Funktionsentwicklung.

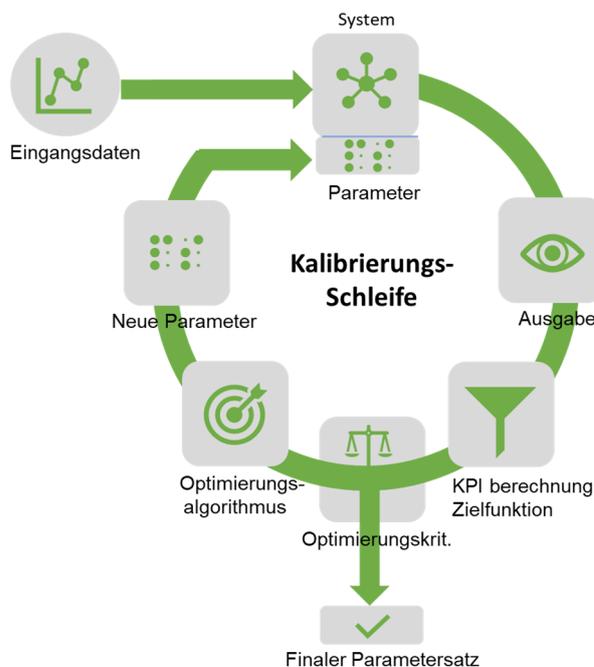


Abbildung 5: Optimierungsworkflow

Die Szenarien mit ihren vielfältigen Parametern stellen die Eingangsdaten dar. Die Parameter der im System beteiligten SW-Module sollen nun mit Hilfe von Optimierungsschleifen kalibriert werden. Die verschiedenen Kriterien aus den Bereichen Komfort und Safety können in eine Zielfunktion oder Nebenbedingung für die Optimierung einfließen. Bezogen auf das Einschereerbeispiel können dies zum Beispiel eine Kritikalitätsmetrik, die Verletzung eines definierten Sicherheitsabstands und die Verzögerung des Egofahrzeugs sein.

Die Wahl der Szenarioparameter als Input für die Kalibrierungsschleife ist von entscheidender Bedeutung, um die Bereiche Komfort und Sicherheit angemessen abzudecken. Eine Optimierung ausschließlich basierend auf kritischen Szenarien ist demzufolge nicht zielführend. Wiederum können sich durch eine vollfaktorielle Zerlegung des Parameterraumes von mehr als 20 Parametern wie im oben beschriebenen Einschereerszenario schnell mehrere Millionen Szenarien ergeben.

Um dem Ressourcen- und Zeitaufwand schließlich gerecht zu werden, müssen Samplingmethoden des Design of Experiment (DoE) zur effizienten Abdeckung des Szenariotesttraums mit dem Parameteroptimierungsworkflow verknüpft werden.

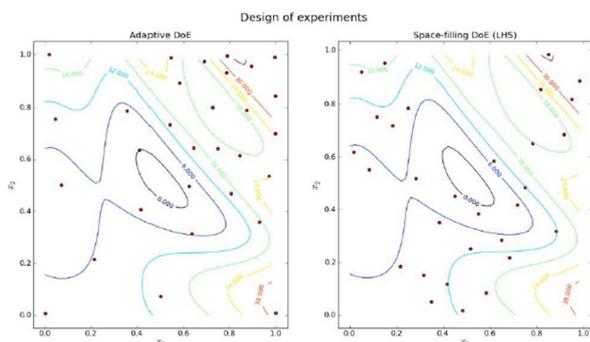


Abbildung 6: 2D-Beispielgrafik DoE-Sampling Methoden

Eine weitere wesentliche Herausforderung ist die Wahl des Optimierungsverfahrens für die Parameter. Auf Grund der Komplexität und nichtlinearer Zusammenhänge kann der Einsatz klassischer Algorithmen an seine Grenzen stoßen und möglicherweise zu keinem verwertbaren Ergebnis führen. Hier ergibt sich die Möglichkeit KI-basierte Methoden einzusetzen, auch wenn das System selbst noch ein regelbasiertes ist, da es auf Anforderungen beruht. So könnte z.B. ein nichtlineares ML Modell wie beispielsweise eine Support Vector Machine (SVM) eingesetzt werden, um einen funktionalen Zusammenhang zwischen den Stellparametern und der Zielfunktion herzustellen. Die SVM transformiert den Merkmalsraum mittels Kernel-Funktion in einen dualen Raum, in dem mittels Hyperebenen die Datenpunkte getrennt werden. Durch Rücktransformation wird eine nichtlineare Trennung im ursprünglichen Raum erzeugt. Für den Optimierungsschritt wird die resultierende Funktion schließlich optimiert, z.B. mittels eines genetischen Algorithmus, der als Werkzeug im Rahmen von KI-

Anwendungen bereits erfolgsversprechende Resultate erzielt hat (vgl. [2]). Weitere Optimierungsverfahren, welche an dieser Stelle zum Einsatz kommen können, sind das Nelder-Mead-Verfahren, Partikelschwarmoptimierung und diverse Greedy Algorithmen.

4. Validierung der Entscheidungskette mit KI

Wie bereits beschrieben, können KI-basierte Verfahren an unterschiedlichen Stellen der Verarbeitungskette autonomer Fahrfunktionen zum Einsatz kommen. Neben der Verwendung in der Sensorik, wurde bereits die Verwendung im Bereich der Softwareentwicklung, z.B. bei der Kalibrierung der SW-Module erwähnt. Wieviel Potenzial sich hinter dem Thema tatsächlich verbirgt, wird deutlich, wenn man sich einem weiteren wesentlichen Bestandteil der Entwicklungskette autonomer Fahrfunktionalitäten widmet, dem komplexen Thema der Validierung von Funktionskomponenten.

Tatsächlich birgt der Bereich Validierung große Herausforderungen, da immer mehr autonome Fahrfunktionalitäten in der Simulation abgetestet werden müssen. In diesem Zusammenhang stellt sich die Frage, welche Szenarien konkret getestet werden müssen. Neben den Szenarien, die für die Kalibrierung verwendet wurden, sollten weitere kritische Szenarien identifiziert und getestet werden. Das SOTIF-Normierungsvorhaben sieht vor, bei der Entwicklung von autonomen Fahrfunktionalitäten die Anzahl der unbekannt und gefährdenden Szenarien zu minimieren, jedoch wird sowohl die Auswahl mittels eines vollfaktoriellen Ansatzes, als auch die Auswahl durch geeignete DoE Methoden nicht ausreichen, diese vollständig zu identifizieren.

Neben den Samplingmethoden des DoE, die eine möglichst effiziente Abdeckung des Parameterraumes anstreben und so auch kritische Szenarien identifizieren können, ist ein weiterer Ansatz für die Erkennung der relevanten Szenarien zielführend: Reinforcement Learning gesteuertes Testen der autonomen Fahrfunktionalitäten.



Abbildung 7: Validierungsworkflow mit KI-basiertem Agenten zur Szenariowahl

Im Rahmen dieser Methodik entscheidet ein sogenannter Agent über die konkreten Szenarien, die nacheinander getestet werden. Das Ziel des Agenten ist dabei, die einzelnen Parameter für das Szenario (also z.B. Geschwindigkeit in X-Richtung des Fahrzeugs A) so zu wählen, dass die implementierte Funktionalität herausgefordert wird und, wenn möglich, Grenzen für sicherheitsrelevante Kenngrößen verletzt werden. Das Verhalten des Agenten wird dabei über eine Belohnungsfunktion erzwungen, welche der Zielfunktion aus der Kalibrierung entsprechen kann, wobei hier das umgekehrte Optimierungsproblem gelöst wird. Je höher der Wert, desto sicherheitskritischer ist die Situation und desto größer die Belohnung für den Agenten. Der Agent wählt unter Berücksichtigung einer definierten Explore-Rate eine zufällige Kombination von Parameterwerten. Mit einer festgelegten Schrittweite für eine Parameteranpassung werden die für die Fahrfunktionalität kritischsten Szenarien im Laufe der Simulationen gezielt identifiziert und getestet ohne sämtliche Parameterkombinationen testen zu müssen. Das könnte den Simulationsaufwand erheblich reduzieren.

5. Realisierung der Entscheidungskette durch KI

Neben der Unterstützung der Entwicklung von autonomen Fahrfunktionen stellt sich die Frage, inwieweit KI auch Bestandteil der eigentlichen Funktion sein kann. D.h. die regelbasierten SW-Module mit einer großen Anzahl an Kalibrierungsparametern werden durch KI-basierte Module ersetzt. Wie bereits erwähnt, ist dies im Falle der kamerabasierten Umfelderkennung bereits State of the Art. Hier sind die einfachen klassischen Bildverarbeitungsalgorithmen hinsichtlich Prognosegüte weit unterlegen, so dass sich die Frage nach der Zulässigkeit der Verwendung der KI mittlerweile erübrigt.

Zusätzlich zum Bereich der Sensorik sind sämtliche Prozesse der Planung für den Einsatz von KI aus technischer Sicht potenziell interessant. Ein Beispiel findet sich in der Pfadplanung in Form der Berechnung der Trajektorie auf Basis von Umgebungsinformationen. Die Trajektorie gibt vor, wo sich das Fahrzeug während der folgenden Zeitschritte jeweils befinden sollte. Ein Ansatz, eine solche Funktionalität zu erlernen, könnte beispielsweise über Prinzipien des Reinforcement Learning erfolgen, die schon in Abschnitt 4 vorgestellt wurden (siehe auch [3]). Für den konkreten Fall übernimmt der Agent die Funktion, wird im Rahmen von ausgewählten Szenarien getestet und erhält Feedback in Form einer Belohnungsfunktion, die unterschiedliche KPIs (Key Performance Indicator z.B. Kollision ja/nein oder Eintauchtiefe in den Sicherheitsabstand) berücksichtigt. Auf Basis dieses Feedbacks passt der Agent wiederum die Funktion an, also ändert z.B. die longitudinale Beschleunigung in Abhängigkeit der Szenarioparameter.

Aber auch die Verwendung von KI in der Funktion und den damit verbundenen Entwicklungs- und Validierungsprozessen bringt einige Herausforderungen mit sich. Laut [1] sind dies u.a.

- Unvollständige Trainingsdaten und somit nicht aussagekräftige Modelle.
- Ungünstige Wahl von Trainingsdaten und somit Erlernen falscher Korrelationen.
- Ungünstige Wahl der Testdaten und somit ungenügende Verifizierung der gelernten Modellparameter.
- Keine unmittelbare oder unzureichende Beeinflussung des Trainingsprozesses durch den Menschen.

Bezogen auf die Entwicklung autonomer Fahrfunktionen bedeutet dies insbesondere, dass auf einer repräsentativen Menge von Szenarien gelernt werden sollte, wobei sichergestellt werden muss, dass auch die relevante Menge der kritischen Situationen erfasst und vom Modell verstanden wird. Die geeignete Kombination und Menge von Realdaten und simulativen Daten ist entscheidend für die Qualität.

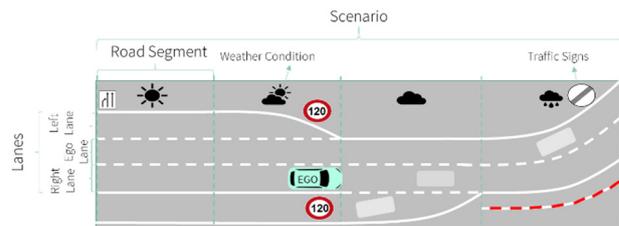


Abbildung 8: Visualisierung der Szenarienvielfalt

Allein durch die große Menge an Parametern bei der Definition eines Szenarios, Positionen, Geschwindigkeiten, Beschleunigungen, Wiedereinflüsse, Fahrbahnverlauf, etc. führt eine vollfaktorielle Zerlegung bei Berücksichtigung sämtlicher möglicher Parameterkombinationen schnell zu einer Menge an Szenarien, die von keinem Rechner dieser Welt in überschaubarer Zeit simuliert werden können. Ein simples Rechenbeispiel mit 200 Parametern und 10 Variationen führt beispielsweise zu 10^{200} Szenarien. Zum Vergleich kommt die Schätzung der Anzahl der Atome im Universum auf gerade mal 10^{96} . Diese Herausforderung löst auch die KI nicht.

Literaturverzeichnis

- [1] ISO/DIS 21448 - Road vehicles — Safety of the intended functionality
- [2] Jia, Weikuan & Zhao, Dean & Ding, Ling. (2016). An optimized RBF neural network algorithm based on partial least squares and genetic algorithm for classification of small sample. Applied Soft Computing. 48. 10.1016/j.asoc.2016.07.037.
- [3] Rose, Dominic & Mair, Jamie & Garrahan, Juan. (2021). A reinforcement learning approach to rare trajectory sampling. New J. Phys. 23 013013.