



Systematisches Testen für autonomes Fahren

Autonomes Fahren ist der Schlüssel zu ökologischer und ökonomischer Mobilität. Robo-Test der Universität Stuttgart hat eine Pilotumgebung geschaffen, mit der mithilfe von KI-basierten Clustering automatisch Testszenarien abgeleitet und somit automatisierte Fahrsysteme effizient und effektiv validiert werden können.



AUTOREN



Prof. Dr. Christof Ebert ist Geschäftsführer der Vector Consulting Services GmbH, Stuttgart, sowie Professor an der Universität Stuttgart und an der Sorbonne Université in Paris, Frankreich.



Prof. Dr. Michael Weyrich ist Direktor des Instituts für Automatisierungstechnik und Softwaresysteme der Universität Stuttgart.



Benjamin Lindemann, M. Sc. ist Leiter Robo-Test am Institut für Automatisierungstechnik und Softwaresysteme der Universität Stuttgart.



Sarada Preethi Chandrasekar, M. Sc. ist Werkstudentin bei der Robert Bosch GmbH, Stuttgart, und Wissenschaftliche Mitarbeiterin an der Universität Stuttgart.

Die derzeit entwickelte neue Generation von zumindest teilweise autonomen Fahrzeugen (Autonomous Vehicles, AVs) muss alle im Fahrbetrieb auftretenden Situationen berücksichtigen. Bevor Leben der künstlichen Intelligenz eines automatischen oder autonomen Fahrsystems oberhalb von SAE-Level 2 anvertraut werden kann, müssen Algorithmen und Technologie rigoros verifiziert werden, um ihr Verhalten zu validieren. Die Homologation und das Vertrauen der Gesellschaft hängen vollständig davon

ab, keinen einzigen Unfall zu verursachen, der von einem menschlichen Fahrer hätte vermieden werden können. Die Erwartungen an AVs sind hoch, selbst wenn man weiß, dass die meisten Unfälle auf unachtsames Fahren durch Menschen zurückzuführen sind. Genau das ist die Herausforderung bei der systematischen Prüfung solcher automatischen und autonomen Systeme [1-4].

Trotz offensichtlicher Vorteile des automatischen Fahrens wächst das Misstrauen in die Zuverlässigkeit. In dem Maß, wie

die autonome Funktionalität in Fahrzeugen zunimmt, nimmt auch die mit dem Software-Stack verbundene Komplexität zu. Die zugrunde liegenden Algorithmen sind schwer verständlich und damit intransparent. Herkömmliche Testmethoden können die subtilen Veränderungen in einem AV-Software-Stack, die aufgrund der dynamischen Umgebung auftreten, nicht abdecken. Aus statistischer Sicht sollten AVs mehr als 15 Milliarden km auf der Straße gefahren werden, um so eine 95-prozentige Sicherheit zu gewähr-

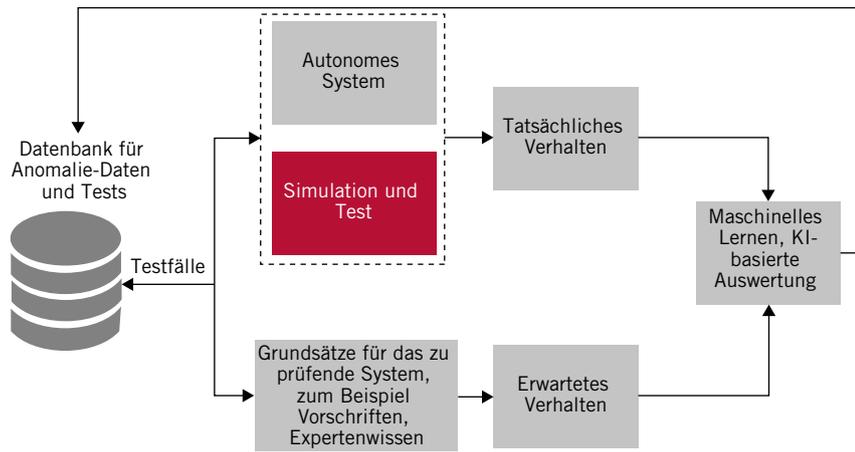


BILD 1 Intelligente Validierung und Homologierung von autonomen Systemen (© Robo-Test)

leisten, dass die AVs 20 % sicherer sind als Fahrzeuge mit menschlichen Fahrern [1]. Dieser hohe Validierungsaufwand, die Vorlaufzeit und die Kosten verlangen nach intelligenten Tests, die dem Bedürfnis nach Effizienz, Transparenz und hohem Qualitätsniveau gerecht werden.

GRUNDLAGEN DER VALIDIERUNG VON AV

Automatische Funktionen und autonome Systeme in Fahrzeugen haben komplexe Wechselwirkungen mit der realen Welt. Dies wirft viele Fragen zur Validierung

von autonomen Fahrzeugsystemen auf. Für das systematische Testen von AVs müssen daher verschiedene Fragen vorab beantwortet werden [3, 4]:

- Was ist die spezifizierte Funktionalität?
- Folgt das System der Spezifikation?
- Sind alle relevanten und kritischen Situationen sowie ihre Korrelationen ausreichend spezifiziert?
- Was ist die beabsichtigte Funktionalität, und ist sie sicher?
- Wie kann man die Entscheidungsfindung zurückverfolgen und anschließend darüber urteilen? Wie kann man sie überwachen?

- Wie definiert man die Zuverlässigkeit im Fehlerfall?
- Was ist, wenn eine Funktionalität versehentlich, durch falschen Entwurf oder durch böswillige Kompromittierung ausfällt?
- Welches negative Ergebnis muss in jedem Fall verboten werden?
- Welches adaptive oder lernende Subsystem wird welche Art von Regressionstest benötigen?
- Welche Informationen über Software-Updates und maschinelles Lernen müssen den Fahrern in Anlehnung an UNECE R156 zum Software Update Management verständlich zur Verfügung gestellt werden?

Durch eine kosteneffiziente und dennoch formal nachvollziehbare Validierungsmethodik kann automatisiertes Fahren auf den Straßen ermöglicht werden. Die Methodik deckt dabei die kleinste Änderung in der Interaktion zwischen der Umgebung und dem AV-Software-Stack unter dem Gesichtspunkt der funktionalen Sicherheit ab. Intelligente Tests mit der Auswahl geeigneter Fahrscenarien eliminieren die aus statistischer Sicht notwendigen gefahrenen Kilometer und reduzieren so den Validierungsaufwand. Systematisches kognitives Testen ermöglicht es, jene Kombinationen von Szenarien und deren Permutationen auszuwählen und zu testen, die zu Todesfällen

Optimierungsmethode	Testmethode	Testmodell	KPI	Kriterien			
				KI/ML-Modell	Feedback-abhängige Stichprobenauswahl	KPI gemessen	Clusteranalyse
Zufalls-generierung	Pseudozufalls-generierung	Florida-Poly-AV-Verification-Framework	Szenario-basierte Abdeckung	x	x	x	-
	Metamorphes modellbasiertes testen	Autonome Drohnen-Software	Keine Informationen	x	-	-	-
Suchbasierte Datengenerierung	Adaptive Probenahme mit Gaußscher Regression	Szenariobibliothek generiert auf der Basis von Testfunktionen	Präzision, Abdeckung, Konvergenz, Laufzeit	-	x	x	x
	Genetischer Algorithmus	BeamNG.AI und DeepDriving	Keine Informationen	x	x	-	-
Reinforcement Learning	Geschlossener Anlagentest mit RL	Surrogate-Modell basierend auf Naturalistic Driving Data (NDD)	Sicherheits- und Funktionalitätsfaktoren	-	x	x	-
	Automatisiertes Testen von AVs mit RL	Apollo AV-Stack	Keine Informationen	x	x	-	-
SAT-Löser	Beobachtungs-basierte Erstellung einer minimalen Testsuite für AVs	Testmodelle basierend auf Fahrzeugaufzeichnungsdaten	Keine Informationen	x	x	-	-

TABELLE 1 Überblick über aktuelle AV-Prüfmethoden (ML: Maschinelles Lernen, RL: Reinforcement Learning) (© Robo-Test)

und Verletzungen führen können. **BILD 1** zeigt den grundlegenden Ansatz, der für KI-gesteuerte Tests verwendet wird [1-4]. Das klassische Testorakel wird durch erwartete Verhaltensweisen angetrieben, die automatisch aus Gesetzen, Vorschriften, Anomalien, situativen Korrelationen, Grenzfällen und Kritikalitätsbeurteilung bestimmt werden.

Im Folgenden wird erläutert, wie man mit KI-basiertem Clustering automatisch Testszenarien ableiten kann. Robo-Test der Universität Stuttgart hat eine Pilotumgebung zur Ableitung praktikabler Branchenlösungen geschaffen [2]. Mit kognitiven Testmethoden, Situationsbewusstsein und geeigneter Indexierung kann die Testeffizienz gesteigert werden. Die Schlussfolgerung: Die systematische Validierung muss die klassische Abdeckung mit Szenario-basierten Tests und neuartigen kognitiven Testverfahren integrieren. Es werden verschiedene neue intelligente Validierungsmethoden und -werkzeuge entwickelt, die eine intelligente Validierung von autonomen Systemen unterstützen können. Neue Validierungsstrategien müssen eingesetzt werden, beginnend mit testorientiertem Anforderungs-Engineering (Requirements Engineering). Diese müssen sich weiterentwickeln zu situationsbezogener Abdeckung und kognitivem Testen. Aufgrund zunehmend unzureichender Basisspezifikationen müssen technische Unzulänglichkeiten in Bezug auf die Sicherheit der beabsichtigten Funktionalität entlang des Lebenszyklus berücksichtigt werden [4]. Die Simulation muss die Speisung mehrerer Sensoren vorsehen, wie zum Beispiel Video-streaming für Kameras, aber auch tatsächliche Objektbewegungen für Radar und Lidar.

AV-TESTS IN DER PRAXIS

Methoden und Werkzeuge zur Verifikation und Validierung von AVs nutzen zunehmend KI, die auf umfangreiche Datenanalysen und adaptives Lernen mittels Heuristiken aufbaut, um die Softwarequalität dynamisch zu verbessern [5, 6]. Klassische Brute-Force-Tests werden aktuell mit pseudo-zufälliger Testgenerierung als Optimierungsmethode angereichert, um die minimal nötigen Testszenarien für ein AV zu generieren. Die funktionale Szenarienabdeckung wird als wichtiger Leistungsindikator

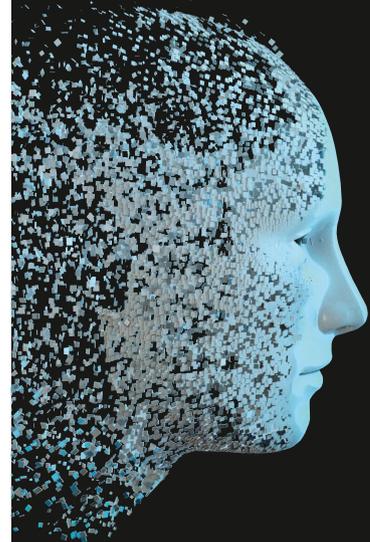
(Key Performance Indicator, KPI) verwendet, um solche Algorithmen zu bewerten. Metamorphe Modelle werden eingesetzt, um eine große Anzahl von Testfällen zufällig aus einem Modell zu generieren und zu gruppieren. Mithilfe eines solchen metamorphen Ansatzes werden äquivalente Szenarien auf der Grundlage der Ergebnisse gruppiert.

Eine Alternative dazu ist eine adaptive Stichprobentechnik unter Verwendung eines Gaußschen Regressionsverfahrens, um aus dem Szenario-Parameterraum automatisch diejenigen Fälle zu identifizieren, die die sicheren Grenzen mit wenigen Simulationen verletzen. Verstärkungslernen (Reinforcement Learning, RL) unterstützt dabei, um diejenigen kritischen Testfälle im gegebenen funktionalen Szenario-Raum zu bestimmen, die einen gegebenen Schwellenwert verletzen.

Um eine reale Leistungsbewertung zu erreichen, wird eine Methode zur Erstellung von Testfällen für die Validierung von AVs eingeführt. Hierbei werden Aufzeichnungen von Verkehrssituationen mit Satisfiability (SAT)-lösungsbasierter Optimierung verwendet, um eine minimale Testsuite zu erstellen, die beim Zertifizierungsprozess helfen könnte. Dies ermöglicht den formalen Nachweis, ob der Minimalismus durch den manuellen Vergleich von Testfällen erreicht wird. **TABELLE 1** zeigt eine vergleichende Analyse der aktuellen AV-Testmethoden auf der Grundlage eines AV-Modells, das zur Validierung, zum Darstellen der Abhängigkeit des Optimierungsalgorithmus vom Rückkopplungswert für die Auswahl der nächsten Stichprobe, zur KPI-Messung und zur Clustering-Analyse verwendet wird. Bei der Betrachtung aktueller AV-Testmethoden ergeben sich folgende Herausforderungen:

- Die Generierung von Testszenario-Bibliotheken für AVs wird auf der Grundlage des Modells oder einer Testfunktion, die auf Fahrdaten mit Menschen basiert, durchgeführt. Diese Modelle sind nützlich, aber möglicherweise nicht vollständig auf die Implementierung des KI-Software-Stacks ausgerichtet.
- Es gibt aktuelle Optimierungsansätze, die sich auf konkrete Randfälle beschränken, aber die Leistungsmessung dieser Algorithmen in der Perspektive der Kritikalitätsabdeckung fehlt in vielen Forschungsstudien.

Keramik der Zukunft.



Das ganze Fachwissen der Keramikttechnologie, in allen anwendungsrelevanten Bereichen auf technisch-wissenschaftlichem Niveau mit den neuesten signifikanten Trends und Entwicklungen. Informieren Sie sich fünf Mal im Jahr mit der exklusiven Kombination aus **Printausgabe** und **interaktivem E-Magazin** sowie der **einzigartigen Wissensdatenbank** des **Online-Archivs mit pdf-Download**.

**JETZT
KOSTENLOS
TESTEN!**



www.meinfachwissen.de/keramischezeitschrift

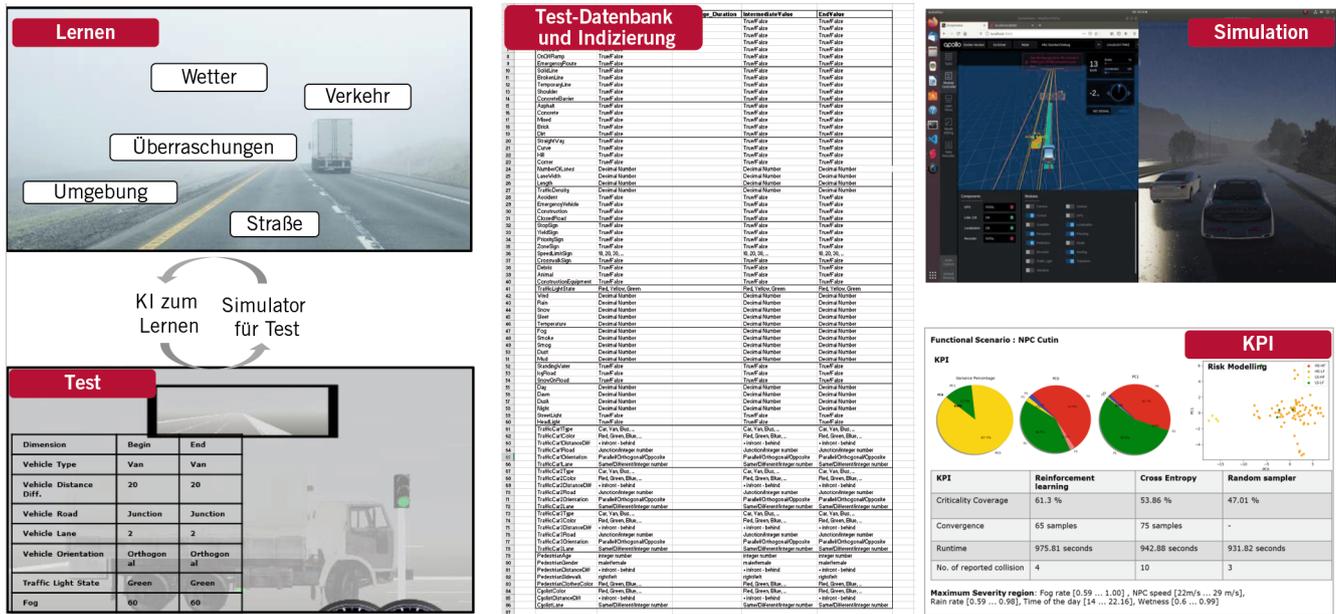


BILD 2 Testumgebung mit Indexierung, Testauswahl, Simulations-Engine und AV-KPI (© Robo-Test)

– Die Reduzierung der Dimensionen wird eine Schlüsselrolle spielen, um effiziente Regressionen zu erreichen und muss bei der Validierung von AVs vertieft erforscht werden.

Um auf dem aktuellen Stand der Praxis aufzubauen und die genannten Lücken zu schließen, müssen intelligente AV-Tests eine konkrete Szenario-Indizierung für jede konkrete Probe entwickeln, die in dem gegebenen Szenario-Raum vorhanden ist, mit dem damit verbundenen Risiko. Die Risikomodellierung wird wiederum von der Berechnung des Schweregrads und der Häufigkeit des Auftretens jedes konkreten Szenarios abhängen. Eine auf RL basierende Optimierungstechnologie wird dabei helfen, auf intelligente Weise kritische Grenzfälle im gegebenen funktionalen Szenario-Raum einzugrenzen. Techniken wie die auf dem Hauptkomponentenanalysator basierende Dimensionsreduzierung in den generierten konkreten Szenarien werden das anfängliche komplexe funktionale Szenario auf sinnvolle Hauptkomponenten reduzieren. Auf dieser Grundlage ist es möglich, die Kritikalitätsabdeckung der für ein gegebenes funktionales Szenario verwendeten AV-Validierungstechnik zu berechnen.

BILD 2 zeigt eine Momentaufnahme aus einer Testumgebung mit KI-basierendem Testen autonomer Systeme. Sie bildet die Grundlage der beschriebenen Metho-

den und dient als Basis für den systematischen Test von AVs. Die Testfälle werden mit einer Testbeschreibungssprache definiert, und diese Testfälle werden mithilfe eines modellbasierten Testansatzes, für den ein Testmodell erstellt wird, automatisch abgeleitet. Die Abbildung des Testmodus auf die AV-Simulation erlaubt es, Szenarien zu extrahieren und geeignete Testfälle zu generieren, die automatisch ausgeführt und ausgewertet werden. BILD 2 (links) zeigt die Testumgebung, die sowohl für den realen Antrieb (Brute Force) als auch für die Simulation verwendet wird. In BILD 2 (Mitte) ist ein Auszug aus der Indexierungsdatenbank dargestellt, mit der bestimmte Situationen erneut getestet und dem Simulator zugeführt werden. BILD 2 (rechts) zeigt die zugrunde liegende KPI-Engine zur Auswertung verschiedener AV-Stacks.

ZUSAMMENFASSUNG

Das Vertrauen in autonome Systeme hängt von deren Validierung ab. Die AV-Validierung muss daher effizient, transparent und zuverlässig sein. Das Vertrauen der Öffentlichkeit in autonome Fahrzeugsysteme hängt stark von der algorithmischen Transparenz und der kontinuierlichen Validierung ab. Nur verlässliche automatische Systeme werden akzeptiert. Die Universität Stuttgart

hat mit Robo-Test eine Pilotumgebung geschaffen, mit der mithilfe von KI-basiertem Clustering automatisch Test-szenarien abgeleitet und somit automatisierte Fahrssysteme effizient und effektiv validiert werden können.

LITERATURHINWEISE

[1] Gangopadhyay, B.; et al.: Identification of test cases for automated driving systems using Bayesian optimization. IEEE Intelligent Transportation Systems Conference (ITSC), Auckland (Neuseeland), 2019

[2] N. N.: robo-test at University of Stuttgart. Online: <https://www.roboto-test.com>, aufgerufen: 1. November 2020

[3] Kalra, N.; Paddock, S. M.: Driving to safety: How many miles of driving would it take to demonstrate autonomous vehicle reliability? Transportation Research, Part A: Policy and Practice (2016), Band 94, S. 182-193

[4] Ebert, C.; Weyrich, M.: Validation of Autonomous Systems. In: IEEE Software 36 (2019), Nr. 5, S. 15-23

[5] Santori, M.; Hall, D. A.: Tackling the test challenge of next generation ADAS vehicle architecture. National Instruments, 2016. Online: http://download.ni.com/evaluation/automotive/Next_Generation_ADAS_Vehicle_Architectures.pdf, aufgerufen: 1. November 2020

[6] Shalev-Shwartz, S.; et. al.: On a Formal Model of Safety and Scalable Self-Driving Cars. Online: <https://www.mobileye.com/responsibility-sensitive-safety>, aufgerufen: 1. November 2020

[7] Ebert, C.: Systematisches Requirements Engineering. Heidelberg: dpunkt.verlag, 2019

READ THE ENGLISH E-MAGAZINE
 Test now for 30 days free of charge:
www.ATZelectronics-worldwide.com



Die DNA von Metrofunk

für Systemerhalt
hinter der Kulisse



Metrofunk Kabel-Union GmbH

Lepsiusstraße 89, 12165 Berlin, Tel. 030 79 01 86 0

info@metrofunk.de – www.metrofunk.de

