

## Automatisiertes Fahren

# KI-basierte Generierung sicherheitskritischer Testfälle

Der Sicherheitsnachweis für automatisierte Fahrfunktionen benötigt neue und effiziente Methoden. Szenariobasierte Testmethoden in Kombination mit der KI-basierten Exploration hochdimensionaler Parameterräume sind eine Möglichkeit, automatisiert unbekannte und kritische Testfälle für diese Fahrfunktion zu erzeugen.

**Dr.-Ing. Raphael Pfeffer, Michael Hefenbrock, Martin Herrmann**

Eine der zentralen Herausforderungen für die Markteinführung des automatisierten Fahrens ist es, die Sicherheit der Funktionen nachzuweisen. Ein Fehlverhalten des Systems kann – neben wirtschaftlichen Schäden – für Passagiere und Menschen im Umfeld des Systems tödliche Konsequenzen haben. Im Vergleich zu herkömmlichen Assistenz- und Regelsystemen steigt der Testaufwand um Größenordnungen. Klassische Freigabeverfahren, die sich auf kilometerbasierte Erprobungsfahrten stützen, sind nicht einsetzbar, da sie nicht unter ökonomisch sinnvollen Bedingungen durchgeführt werden können.

Methoden zur Virtualisierung und Simulationen sind in vielen Domänen bereits etabliert und tragen dazu bei, den Test- und Validierungsaufwand erheb-

lich zu reduzieren. Der Vorteil dieser Methoden liegt darin, dass diese zum einen den Testdurchsatz, also die Anzahl durchführbarer Tests pro Zeit, massiv erhöhen, zum anderen gezielt kritische Situationen betrachtet werden können. Allerdings sind diese Methoden dahingehend limitiert, dass nur das abgebildet und getestet werden kann, was auch a priori den Entwicklern und Testern bekannt ist. Unbekannte Situationen können weder zuverlässig noch ohne Zuhilfenahme weiterer Methoden erzeugt werden.

### Szenariobasiertes Testen in der Simulation

In den letzten Jahren wurden zunehmend auf die Sicherheit verschiedene Standards und Normen etabliert,

wie die ISO 26262 oder die ISO 21448 (SOTIF). Insbesondere Safety of the intended Functionality (SOTIF) fordert für den Nachweis der Sicherheit den Einsatz szenariobasierter Testmethoden. Ein Szenario beschreibt dabei eine zeitliche Entwicklung von einzelnen Szenen, die wiederum über verschiedene Aktionsmuster oder Handlungen der enthaltenen Akteure ineinander überführt werden. Es bietet damit die Grundlage für eine Abbildung und Durchführung sicherheitsrelevanter Testfälle in der Simulation und beinhaltet in seiner Definition alle Komponenten, die zur Beschreibung der Operational Design Domain (ODD) einer automatisierten Fahrfunktion notwendig sind. Szenarien lassen sich auf verschiedenen Abstraktionsstufen beschreiben (**Bild 1**). Während funktionale

Szenarien häufig über sprachliche Beschreibungen der zugrundeliegenden Semantik dargestellt werden, umfassen logische Szenarien die jeweiligen Grenzen einzelner Parameter und ihre etwaige Verteilung.

Logische Szenarien können aus funktionalen abgeleitet, über entsprechende Formate, zum Beispiel OpenDrive [1] oder OpenScenario [2], maschinell verarbeitet und beispielsweise direkt in der Simulation abgebildet werden. Tatsächlich ausführbar werden diese logischen Szenarien über die Erzeugung einzelner

		Funktionale Szenarien	Logische Szenarien	Konkrete Szenarien
Statische Elemente	Ebene 1	Straße: 2-streifige Autobahn mit Rechtskurve und Abfahrt	Straße: - Breite Fahrstreifen [2,3..3,5m] - Kurvenradius [0,6..0,9m] - Position Abfahrt [100..500m] - Steigung [-5..5°] - ...	Straße: - Breite Fahrstreifen [3,0m] - Kurvenradius [0,7m] - Position Abfahrt [300m] - Steigung [2,5°] - ...
	Ebene 2	Leitinfrastruktur: Verkehrszeichen für Geschw.-begrenzungen und teilweise fehlende Fahrstreifenmarkierungen	Leitinfrastruktur: - Pos. Verkehrs-z. [0..500m] - Geschw.-begrenz. [80..120km/h] - Fehl. Markierung [0..80%] - Pos. fehlende Mark. [0..500m] - ...	Leitinfrastruktur: - Pos. Verkehrs-z. [500m] - Geschw.-begrenz. [100km/h] - Fehl. Markierung [50%] - Pos. fehlende Mark. [225m] - ...
	Ebene 3	Temporäre Überlagerungen	...	...
Dyn. Elemente	Ebene 4	Bewegliche Objekte	...	...
	Ebene 5	Umweltbedingungen	...	...
	Ebene 6	V2X Kommunikation	...	...
		Informale, sprachliche Beschreibungen	> 100 Parameter für stat. Elemente > 100 Parameter für dyn. Elemente	Kombinatorisch: > 10 <sup>200</sup> Varianten für Testfälle (theoretisch)

Bild 1: Abstraktionsstufen von Szenarien © RevoAI

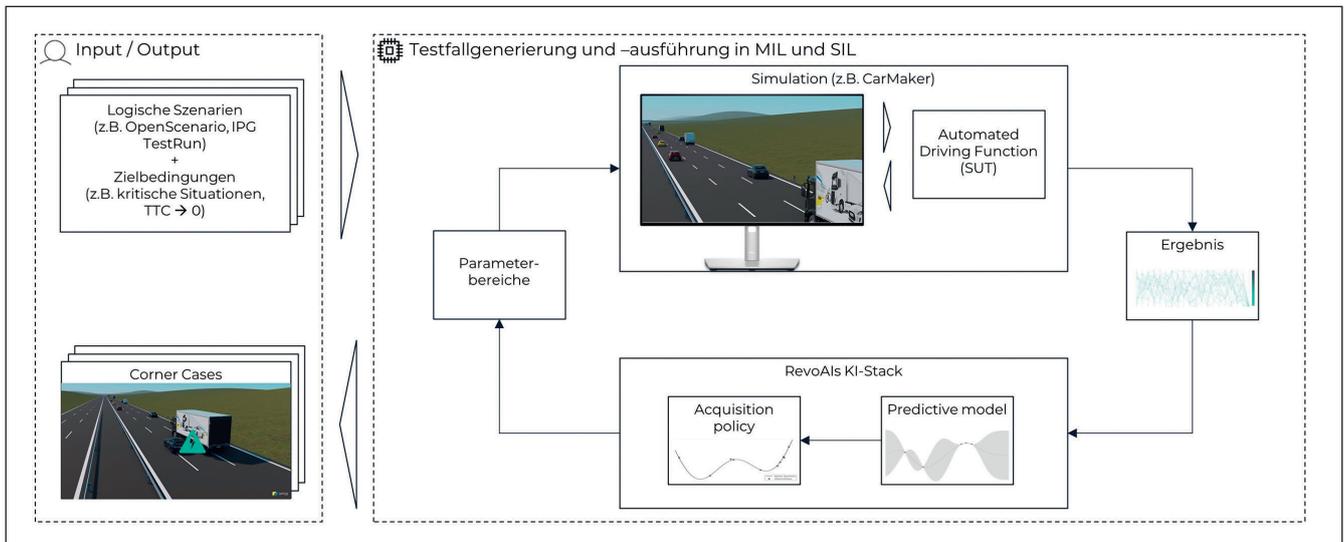


Bild 2: Gesamtumgebung zur KI-basierten Generierung von kritischen Testfällen © RevoAI

konkreter Szenarien, die wiederum feste Parameterwerte aus der Menge der logischen Szenarien aufweisen.

**Automatische KI-basierte Generierung relevanter Testfälle**

Simulationsumgebungen, wie Car-Maker von IPG Automotive, bilden die Elemente eines Szenarios in hoher Detailtiefe durch eine Vielzahl von Parametern ab. Bereits durchschnittlich komplexe Szenarien können so eine Parameterzahl von jeweils weit über 100, oftmals über 1.000, für die statischen Komponenten beispielsweise Fahrbahn, Markierungen oder Beschilderungen sowie die dynamischen Komponenten wie andere Verkehrsteilnehmer aufweisen. Auf diese Weise können zwar gezielt einzelne Testfälle oder schmale Testbereiche geprüft werden, der Großteil dieser sich ergebenden hochdimensionalen Parameterräume lässt sich jedoch nicht mit herkömmlichen

Methoden effizient durchsuchen. Nimmt man zum Beispiel nur zehn verschiedene Ausprägungen je Parameter und geht von insgesamt 200 statischen und dynamischen Parametern aus, ergibt sich durch Kombinatorik bereits eine hypothetische Menge möglicher Testfälle, die in der Größenordnung weit über der Gesamtzahl an Atomen im Universum [3] liegt. Es stellt sich die Frage, in welchen Bereichen dieses möglichen Testraums es sich überhaupt lohnt, Tests durchzuführen und wo erhöhte Wahrscheinlichkeiten für Fehler des zu testenden Systems vermutet werden können.

Die Methode zur KI-basierten Generierung von Szenarien und Testfällen adressiert diesen Nachteil des fehlenden oder zumindest unvollständigen a-priori-Wissens. Statt der aufwendigen manuellen Parametrierung und Überprüfung einzelner Testfälle werden Modelle des maschinellen Lernens – nachfolgend als KI-Stack bezeichnet – einge-

setzt. Diese Modelle generieren, auf Basis der bisherigen Ergebnisse fortwährend lernend, vollautomatisiert neue Simulationsläufe und identifizieren dabei die Schwachstellen des System Under Tests (SUT) – ohne dass der Entwickler oder Tester diese Simulationsläufe selbst modellieren oder die Schwachstellen des Systems kennen muss.

RevoAI stellt für diesen Zweck ein Softwaretool bereit, das sich in die existierenden Entwicklungsumgebungen einbinden lässt und diese nahtlos erweitert (Bild 2). Idealerweise existieren in diesem Stadium die zu entwickelnden und zu testenden Systeme entweder als Modell in der Simulation (MiL/SiL) oder als physische Komponente in einem Prüfstand (HiL). Durch die direkte Anbindung an diese Simulationsumgebungen, wie CarMaker, lernt RevoAls integrierter KI-Stack automatisch mit jedem ausgeführten Test neues Wissen über die zu testenden Systeme. Zu die-

sem Zweck werden über die Anbindungsschnittstellen die Simulations- oder Prüfstandsergebnisse automatisch aufgenommen und dem KI-Stack zur internen Modellbildung zur Verfügung gestellt. Auf Basis des internen Modell-Updates wählt der KI-Stack selbstständig neue Parametersets aus, die an die Simulations- und Entwicklungs-Toolchain gesendet und dort ausgeführt werden. Der Zyklus beginnt anschließend von vorn. Mit zunehmendem Lernfortschritt sucht die KI auf Basis ihres eigenen Wissensfortschritts gezielt den Parameterraum nach den relevanten Testfallregionen ab. Der gesamte Ablauf erfolgt dabei vollständig automatisiert. Der Anwender muss lediglich die Ausgangskonfiguration in Form des gewünschten logischen Szenarios – zum Beispiel zweispurige Autobahn mit Geschwindigkeitsbegrenzung und Verkehr – festlegen. Je nach vorhandener Rechenkapazität arbeiten sowohl Simulation als auch KI-Stack hochgradig parallelisiert, sodass beispielsweise über Nacht viele Tausende relevante Tests automatisch erzeugt, durchgeführt und analysiert werden können.

### Nutzung aus Anwenderperspektive

Entwickler und Tester können mit der KI-basierten Generierung von Testfällen gezielt und automatisiert die Schwach-

stellen des SUT herausfinden und analysieren. Zu diesem Zweck lassen sich der KI bestimmte Ziele oder Suchbedingungen mitgeben. Für die Analyse der funktionalen Sicherheit kann es beispielsweise das Ziel sein, potenzielle Crash- oder Beinahe-Crash-Situationen zu finden, die auf ein Fehlverhalten des SUT zurückzuführen sind. Für diesen Fall können bereits zur Laufzeit der Simulation unter Rückgriff auf virtuelle Sensoren/Beobachter geeignete Messergebnisse erfasst werden, beispielsweise die Time-to-Collision, und der KI als Zielgröße zugewiesen werden. In der Simulationsumgebung CarMaker steht für diesen Zweck bereits ein Sensorportfolio zur Verfügung. Metriken für die Ziele oder Suchbedingungen können dabei zu Beginn vom Anwender unter Kenntnis der Sensor-/Beobachtermodelle der Simulation selbst zusammengestellt werden oder es kann einfach auf vordefinierte, bereitgestellte Templates für Sicherheitsmetriken in der RevoAI Software-Umgebung zurückgegriffen werden. Sowohl während der Durchführung der Testfallgenerierung als auch am Ende werden dem Anwender Analysewerkzeuge bereitgestellt, die aufzeigen, welche der generierten konkreten Szenarien und Testfälle die zuvor individuell definierten Zielbedingungen erfüllen und beispielsweise sicherheitskritische Situationen für

das SUT darstellen. Des Weiteren bietet der KI-Stack eine Abschätzung über ähnliche Test- und Fehlerfälle, vergleichbar mit Äquivalenzklassen beim klassischen Software-Test, und stellt diese auf einen Blick gruppiert dar. So kann der Entwickler anschließend gezielt die gefundenen, unterschiedlichen Fehler des SUT analysieren und beheben.

■ (eck)

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

### Quellenverzeichnis

- [1] <https://www.asam.net/standards/detail/opendrive/>  
 [2] <https://www.asam.net/standards/detail/openscenario/>  
 [3] <https://www.greelane.com/wissenschaft-technologie-mathematik/wissenschaft/number-of-atoms-in-the-universe-603795/>



**Dr.-Ing. Raphael Pfeffer** ist Managing Director bei RevoAI in Karlsruhe. [raphael.pfeffer@revoai.de](mailto:raphael.pfeffer@revoai.de) © RevoAI



**Michael Hefenbrock** arbeitet als Head of Artificial Intelligence bei RevoAI in Karlsruhe. © RevoAI



**Martin Herrmann** ist Business Development Manager ADAS & Automated Driving bei IPG Automotive in Karlsruhe. © IPG Automotive

**INONET**  
www.inonet.com

# MAYFLOWER® - B17 - LiQuid

Hochleistung für KI  
5-fach GPU Power  
Flüssigkeitsgekühlt



**ADAS**  
& AUTONOMOUS VEHICLE  
TECHNOLOGY EXPO  
21.-23. Juni in Stuttgart  
Halle 6 - Stand: 6614

intel  
partner  
IoT Industrial  
Specialist