

Anwendung von Kausalmodellen im Szenario-basierten Testen

tilo.linz@imbus.de, daniel.ebenhoech@efs-techhub.com,
robert.maier@oth-regensburg.de, juergen.mottok@oth-regensburg.de

Abstract: Das vorliegende Papier präsentiert eine neue Methodik für das Szenario-basierte Testen automatisierter Fahrfunktionen im Rahmen der ISO 21448 (Sicherheit der Sollfunktion). Durch Verwendung struktureller Kausalmodelle (SCMs) soll der Evaluationsprozess hochautomatisierter Fahrzeugsysteme verbessert und damit deren Sicherheit und Zuverlässigkeit erhöht werden. Unter Nutzung von SCMs analysiert die vorgestellte Methodik systematisch kausale Zusammenhänge zwischen verschiedenen Risikofaktoren des untersuchten Systems und dessen Betriebsumgebung und identifiziert automatisiert potenzielle Parameterkombinationen, welche Systemsicherheit beeinflussen. Dieser Ansatz erlaubt die Absicherung automatisierter Fahrfunktionen, beispielsweise eines Notbremsassistenten, in dem vorhersehbare Risiken ermittelt und als Testparametrierung für relevante Szenarien bereitgestellt werden.

Das HolmeS3-Vorgehensmodell kombiniert hierbei Expertenwissen mit probabilistischen Datenanalysen, um robuste Kausalmodelle zu entwickeln, die sowohl durch Simulation als auch durch reale Tests validiert werden können. Die Nutzung Kausaler Inferenz ermöglicht die Generierung kritischer Testfälle, bekannt als „Edge und Corner Cases“, die für das Testen untersuchter Fahrzeugsysteme unerlässlich sind. Dieser fokussierte Testansatz hilft, die bei üblichem Vorgehen auftretende Testfall-Explosion zu begrenzen, indem gezielt hochrelevante Parameterkombinationen identifiziert werden, die die Systemleistung potenziell (negativ) beeinflussen.

Die vorgestellte Methodik, die im Rahmen des F&E-Projekts HolmeS3¹ entwickelt wurde, bietet Transparenz, Vergleichbarkeit, Erklärbarkeit und Nachvollziehbarkeit in den Modellierungs- und Testprozessen. Sie unterstützt die Einhaltung der ISO 21448-Norm und legt den Grundstein für die kausalitätsgetriebene Entwicklung sicherer und zuverlässiger Automobiltechnologie. Die Werkzeuge und Methoden des Projekts sind über den Automobilsektor hinaus für alle cyberphysischen Systeme anwendbar, die eine rigorose Sicherheitsvalidierung erfordern.

Keywords: Szenario-basiertes Testen, Kausales Modell, Kausale Inferenz, Absicherung hochautomatisierter Fahrfunktionen, ISO 21448 SOTIF, autonomes Fahren, autonome Systeme, Cyber-physical Systems, Softwaretest, Softwarequalität

1. Motivation und Inhalt

Die Norm ISO 21448 „Safety of the Intended Functionality“ [SOTIF] legt strenge Maßstäbe fest, die moderne Kraftfahrzeuge bezüglich ihrer Systemsicherheit erfüllen müssen. SOTIF fordert u.a., dass das System „Fahrzeug“ jederzeit sicher agiert. Hierzu muss das Fahrzeug bzw. die betreffende automatisierte Fahrfunktion (z.B. ein Notbremsassistent) nicht nur seine intendierte Funktion korrekt ausführen, sondern auch Risiken (die sich aus seiner Funktion oder Fehlfunktion ergeben) erkennen und angemessen behandeln. Ein Notbremsassistent (NBA) muss beispielsweise die fahrende Person warnen, wenn ein vom NBA benötigter Sensor ausgefallen ist.

Die Ursachen von Abweichungen der spezifizierten Sollfunktion werden typischerweise bereits im Entwicklungsprozess sorgfältig erhoben und analysiert. Hierzu müssen die Entwicklungsteams ein umfassendes Verständnis über die beteiligten Fahrzeugsysteme, deren Sollfunktionalität, ihrer Wechselwirkungen und auch möglicher und denkbarer Fehlfunktionen erarbeiten.

Im weiteren Absicherungsprozess muss dann überprüft werden, ob sich das System in den identifizierten Risikosituationen ausreichend risikomindernd verhält. Dies ist zusätzlich zur Prüfung des Systems auf korrektes Verhalten im „Normalbetrieb“ zu leisten. Aus der hohen Anzahl an variierbaren Parametern (Parameter des Fahrzeugs und seiner Subsysteme und Parameter der zu betrachtenden Fahrscenarien) ergibt sich für diese beiden Testaufgaben eine extrem hohe Anzahl auszuführender Testfälle bzw. auszuführender Testabläufe.

Hier setzt das Projekt HolmeS3 an, das „Strukturelle Kausale Modelle“ (SCMs) verwendet, um die kausalen Zusammenhänge zwischen verschiedenen Risiko-Einflussfaktoren systematisch zu analysieren. Diese Modelle helfen, wechselwirkende Einflussfaktoren zu erfassen und deren komplexe Wirkpfade aufzuzeigen, z.B. wie Geschwindigkeit, Wetterbedingungen und das Eingreifen von Sicherheitssystemen die Fahrzeugsicherheit beeinflussen. Die Kombination

¹ F&E Projekt der Projektpartner Ostbayerische Technische Hochschule Regensburg (OTH), e:fs TechHub GmbH, Ingolstadt und imbus AG, Möhrendorf, durchgeführt im Zeitraum 10/2020 bis 12/2023, gefördert durch das Bayerische Staatsministerium für Wirtschaft, Landesentwicklung und Energie (StMWi), im Rahmen der Initiative Künstliche Intelligenz – Autonome Mobilität.

von Domänenwissen von Experten und detaillierten Datenanalysen führt zu robusten Modellen, die simulativ oder im realen Versuch validierbare Ergebnisse liefern.

Eine mathematische Analyse solcher Kausaler Modelle kann dann Kombinationen von Randwerten (Corner Cases) liefern, die dazu beitragen, eine Testfallexplosion bei der Parametrisierung des Testobjekts und des jeweiligen Fahrzenarios zu vermeiden.

Der vorliegende Artikel erklärt zunächst die Grundlagen Kausaler Modelle und den Prozess zur Modellerstellung. Anschließend wird erklärt, wie Kausale Modelle mittels Kausaler Inferenz quantitativ analysiert werden können und welche Informationen dadurch gewonnen werden können. Dies beinhaltet u.a. die Generierung von Corner Cases, die dann als Testdatenkombinationen im weiteren Szenario-basierten Absicherungsprozess zur Verfügung gestellt werden. In diesem Zusammenhang wird eine Definition der Testmethode „Szenario-basiertes Testen“ vorgestellt und die Methode in Relation zu verschiedenen Anwendungskontexten eingeordnet. Abschließend wird die im Projekt HolmeS3 von den Partnern entwickelte Toolkette vorgestellt und aufgezeigt, wie Szenario-basiertes Testen unter Anwendung von Kausalmodellen in der Praxis eingesetzt wird.

2. Lösungsidee und Überblick

Die HolmeS3-Methodik verfolgt einen integrierten Ansatz, um die Absicherung hochautomatisierter Fahrzeuge bzw. hochautomatisierter Fahrfunktionen begleitend zum Entwicklungsprozess zu unterstützen. Die folgende Abbildung zeigt schematisch die wesentlichen Bausteine der HolmeS3-Methodik:

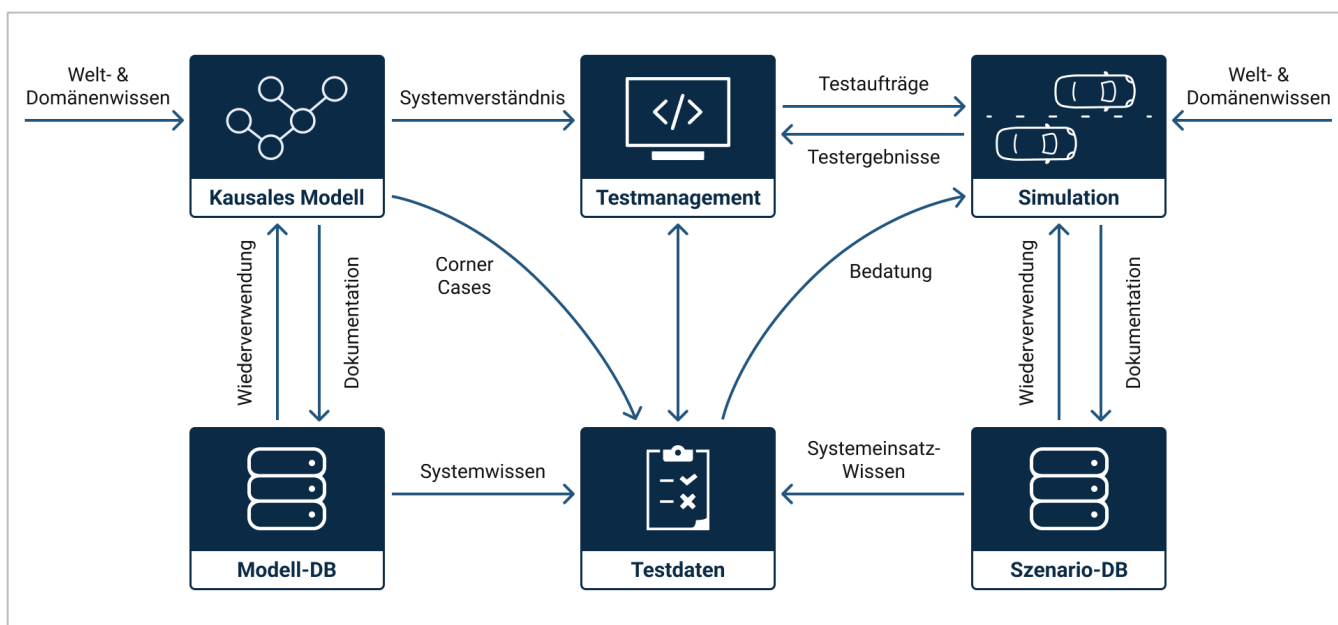


Abbildung 1: HolmeS3-Prozesskette zur Anwendung Kausaler Modelle im Szenario-basierten Testen

Kausales Modell

Die Grundlage der HolmeS3-Methodik bildet die Erstellung eines Kausalen Modells, das auf einem fundierten Verständnis der Systemanforderungen (Requirements, RQs) basiert. Diese Modelle werden in einer zentralen Modell-Datenbank (Modell-DB) gespeichert und dokumentiert, wodurch Wiederverwendung und kontinuierliche Verbesserung gefördert werden. Das Kausale Modell fungiert als Kernstück zur Visualisierung und Analyse komplexer Systeminteraktionen. Dabei werden kritische Szenarien, die mit Corner Case-Werten parametrisiert sind, identifiziert und hervorgehoben, um besondere Aufmerksamkeit auf potenziell gefährliche oder unerwartete Systemreaktionen zu lenken.

Kausale Inferenz

Die Kausale Inferenz bildet die Grundlage für die Identifikation und Generierung von Corner Cases. Durch die Analyse von Ursache-Wirkungs-Beziehungen im Modell können spezifische Szenarien identifiziert werden, die potenziell gefährliche oder unerwartete Systemreaktionen hervorrufen. Diese Corner Cases sind essenziell für das Testen der Robustheit des Systems gegenüber unvorhergesehenen Ereignissen. Ein zentrales Element der HolmeS3-Methodik ist die Entwicklung einer kausalen Metrik, die die Stärke des Einflusses einzelner Variablen auf das Ergebnis quantifiziert. Diese Metrik ermöglicht es, wichtige von unwichtigen Faktoren zu unterscheiden und somit die Modellierung auf die kritischen Einflussgrößen zu konzentrieren. Durch diese Fokussierung können Ressourcen effizienter genutzt und die

Modellgenauigkeit erhöht werden. Die kausale Metrik wird dabei als Formel des Estimanden für die Kausale Inferenz verwendet und kann so effektiv zur Analyse von Corner Cases beitragen.

Testmanagement

Der Testmanagement-Baustein macht die erstellten Kausalen Modelle für den Absicherungsprozess zugreifbar. Hierzu stellt er Möglichkeiten zur Abfrage der in der Modell-DB vorhandenen Kausalen Modelle zur Verfügung. Anhand der Modellvariablen (z.B. Fahrzeuggeschwindigkeit, Wetterbedingungen etc.) kann dann bei der Erstellung von Testfällen beurteilt und entschieden werden, welche Variablen in den Testfällen abgedeckt werden müssen. Die modellierten kausalen Beziehungen liefern darüber hinaus Hinweise, ob und welche Variablen in Kombination zu betrachten und daher durch entsprechende Testdatenkombinationen abzudecken sind. Die generierten Corner Cases können dann genutzt werden, um eine Mindestabdeckung dieser Kombinationen zu erhalten, oder als Ausgangspunkt oder Muster, um weitere Kombinationen manuell zu ergänzen.

Als zweiten Datenpool macht der Testmanagement-Baustein auch die im Projekt oder im Unternehmen verfügbaren Simulationsszenarien verfügbar. Hierzu stellt er Möglichkeiten zur Abfrage der Repositories bereit, in denen die entsprechenden Szenario-Dateien verwaltet werden. Aus den dort vorhandenen Szenario-Dateien können einzelne Szenarios selektiert und mit den Testdaten parametrisiert werden, die wie oben beschrieben auf Basis der Kausalen Modelle erstellt wurden. Jedes solche „Paket“ aus Szenario-Datei und Testdatentabelle kann dann als „Testauftrag“ an eine angeschlossene, vorhandene Simulationsumgebung zur Ausführung übergeben werden.

Simulation

Eine Szenario-Datei beschreibt eine bestimmte Verkehrssituation und eine Fahraufgabe, die vom jeweiligen zu testenden Fahrzeug oder von dessen zu testender Fahrfunktion zu bestehen ist. Um solche „Testfahrten“ möglichst schnell und zu niedrigen Kosten abzuwickeln, werden diese (statt in der realen Welt) in zunehmendem Maße virtuell, in einem Simulator (z.B. [IPG CarMaker]) durchgeführt. Dieses Vorgehen erlaubt es auch, Tests schon in sehr frühen Entwicklungsphasen des Entwicklungsprozesses und in großer Variantenanzahl durchzuführen.

Innerhalb der HolmeS3-Toolkette erhält der Simulator seine Testaufträge wie oben beschrieben vom HolmeS3 Testmanagement-Baustein. Dieser führt dann den jeweiligen Simulationslauf automatisch durch und stellt anschließend die erzeugten Simulations-Protokolle dem Testmanagement-Baustein als Ergebnisdaten bzw. Testprotokolle bereit. Der Testmanagement-Baustein sammelt diese Daten ein und archiviert sie.

Synergie und Integration

Der beschriebene HolmeS3-Workflow integriert kausale Modellierung, Testmanagement und Simulation in einer geschlossenen Prozesskette, die es ermöglicht, aus initialen Wissensangaben präzise Erkenntnisse zu gewinnen und diese zur kontinuierlichen Verbesserung der Systemleistung der Testobjekte zu nutzen. Der Ansatz fördert dabei auch die Analyse von potenziellen Risiken und Problembereichen, sowohl in den spezifizierten Fahrszenarien, als auch (anhand der Kausalen Modelle) bezüglich des Systemverhaltens der Testobjekte.

3. Kausale Modellierung

Ein Kausales Modell ist eine mathematische Darstellung, die Ursache-Wirkungs-Beziehungen abbildet. Diese Beziehungen sind sowohl qualitativ als auch quantitativ und zeigen, wie die Variablen des Modells zueinander stehen. Ein kausaler Graph visualisiert diese Beziehungen als Knoten und Kanten. Die Knoten repräsentieren die Variablen, während die Kanten die kausalen Verbindungen und deren Richtung darstellen. Beispielsweise könnte ein Knoten "Ego_Geschwindigkeit" und ein anderer "Windlast" sein, verbunden durch eine Kante, die den Einfluss der Geschwindigkeit des Ego-Fahrzeugs auf die Windlast zeigt. Der Einfluss, der durch die gerichtete Kante vermittelt wird, wird auch als unabhängiger Mechanismus bezeichnet. Diese Unabhängigkeit beruht auf der Annahme, dass die Mechanismen isoliert wirken und eine Änderung eines Mechanismus keine Auswirkungen auf andere Mechanismen im Modell hat.

Die Verfeinerung eines Kausalen Modells kann funktionale Mechanismen und Wahrscheinlichkeitsverteilungen oder eine Kombination aus beidem umfassen. Funktionale Mechanismen erklären die Prozesse, die die Ursache-Wirkungs-Beziehungen bestimmen, indem sie beschreiben, wie eine Änderung in einer Ursache zu einer Änderung in der Wirkung führt. Zum Beispiel kann ein funktionaler Mechanismus erklären, wie eine höhere Geschwindigkeit die Windlast auf das Ego-Fahrzeug quantitativ beeinflusst.

In der Kausalen Inferenz, die Ursache-Wirkungs-Beziehungen untersucht, gibt es zwei grundlegende Herangehensweisen: Das Rubin Kausale Modell [RCM] und das Strukturelle Kausale Modell (SCM). Das HolmeS3-Projekt nutzt das SCM, das auf graphischen Modellen basiert. Diese Modelle verwenden kausale Graphen, um Einflussfaktoren und Wirkungen zu visualisieren.

Ein Strukturelles Kausales Modell (SCM) [Pearl] ist ein 4er-Tupel $\langle U, V, \mathcal{F}, P(U) \rangle$, wobei

- U ist eine Menge von Hintergrundvariablen, auch exogene Variablen genannt, die durch Faktoren außerhalb des Modells bestimmt werden;
- V ist eine Menge $\{V_1, V_2, \dots, V_n\}$ von Variablen, die endogen genannt werden und durch andere Variablen im Modell bestimmt werden – das heißt, Variablen in $U \cup V$;
- \mathcal{F} ist eine Menge von Funktionen $\{f_1, f_2, \dots, f_n\}$ wobei jede f_i eine Abbildung von (den jeweiligen Domänen von) $U_i \cup Pa_i$ nach V_i ist, wobei $U_i \subseteq U$, $Pa_i \subseteq V \setminus V_i$, und die gesamte Menge \mathcal{F} eine Abbildung von U nach V bildet. Das heißt, für $i = 1, \dots, n$, ist jedes $f_i \in \mathcal{F}$ so, dass $v_i \leftarrow f_i(p a_i, u_i)$,

d.h. es weist V_i einen Wert zu, der von (den Werten von) einer ausgewählten Menge von Variablen in $U \cup V$ abhängt und $P(U)$ ist eine Wahrscheinlichkeitsfunktion, die über der Domäne von U definiert ist. [Pearl]

Die Definition eines SCM angewendet auf ein Minimalbeispiel könnte die exogenen Einflussgrößen, also jene Größen, die nicht Teil des Systems sind, hier Niederschlag und Temperatur, auf die endogene Systemgröße Reibwert wie folgt modellieren, wobei der funktionale Zusammenhang hier nur beispielhaft eine mögliche und vereinfachte Ausprägung der Modellierung aufzeigt:

$$U = \{N, T\}, \quad V = \{R\}, \quad \mathcal{F} = \{f_R\}$$

$$f_r : R = a * N + b * e^T$$

Das SCM im kommenden Abschnitt „Erstellung eines Kausalen Modells am Beispiel eines Notbremsassistenten“ beinhaltet eine detailliertere Modellierung dieses Wirkzusammenhangs, der die Wirklichkeit viel treffender abbildet.




Abbildung 2: Die graphische Repräsentation eines Kausalen Strukturmodells (SCM)

Die Erstellung eines Kausalen Modells kann in zwei Vorgehensweisen eingeteilt werden:

- **Causal Discovery:** Hierbei werden Algorithmen eingesetzt, um äquivalente kausale Graphen aus Beobachtungsdaten zu generieren.
- **Experteninterviews:** Diese Methode verwendet geleitete und strukturierte Gespräche mit Fachexperten, um kausale Zusammenhänge zu identifizieren und in Kausale Modelle zu überführen.

Diese Vorgehensweisen können kombiniert werden, um sowohl menschliches Fachwissen als auch die in den Causal Discovery Algorithmen anwendbare künstliche Intelligenz ausgewogen zu nutzen. Experten ermitteln Ursache-Wirkungs-Beziehungen, während statistische Algorithmen die Ergebnisse validieren.

Bei der Modellerstellung muss zunächst die Problemstellung, die das Kausale Modell lösen soll, definiert und verfeinert werden. Hier liegt der Fokus auf der von der SOTIF-Norm adressierten Behandlung von Sicherheitsbedenken, die sich aus funktionalen Unzulänglichkeiten oder Leistungsbeschränkungen ergeben, die zu gefährlichen Situationen führen können, selbst wenn kein Systemfehler vorliegt. Im Fall einer automatischen Fahrfunktion besteht die Aufgabe darin, ein Testszenario so zu parametrisieren, dass das System ein unerwünschtes Verhalten – im SOTIF-Sinne von "potentially hazardous behaviors" oder "unintended behaviors" zeigt, wie z.B. eine unnötige Gefahrenbremsung oder eine Kollision.

Im nächsten Schritt werden Einflussfaktoren identifiziert, die dieses unbeabsichtigte Verhalten verursachen können. Bei Experteninterviews werden diese Faktoren strukturiert und als gerichteter azyklischer Graph dargestellt, der das SCM strukturell abbildet. Oft werden dabei weitere Faktoren identifiziert, die zuvor nicht berücksichtigt wurden.

Der letzte Schritt in der Erstellung des Kausalen Modells ist die qualitative Erfassung der Ursache-Wirkungs-Beziehungen und das probabilistische Verhalten der Einflussfaktoren. Dies umfasst sowohl die mathematische Abbildung von Mechanismen als auch der Wahrscheinlichkeitsverteilungen der Variablen. Quellen für diese Mechanismen sind Fachliteratur, aktuelle Forschungsarbeiten und Datensätze, die durch maschinelles Lernen analysiert werden können.

Unabhängige Mechanismen und Wiederverwendbarkeit

Der kausale Daten generierende Prozess der einzelnen Variablen eines Systems besteht aus autonomen Modulen, die sich gegenseitig nicht informieren oder beeinflussen. Im probabilistischen Fall bedeutet dies, dass die bedingte Verteilung jeder Variablen, gegeben ihre Ursachen (d.h. ihr Mechanismus), die anderen bedingten Verteilungen nicht informiert oder beeinflusst. Falls wir nur zwei Variablen haben, reduziert sich dies auf eine Unabhängigkeit zwischen der Ursprungsverteilung und dem Mechanismus, der die Wirkungsverteilung erzeugt. [Schoelkopf]

Dies impliziert eine hohe Wiederverwendbarkeit von Teilmodellen, da jeder funktionale Zusammenhang (in einem Modul) unabhängig modelliert und validiert werden kann, ohne die anderen zu beeinflussen. Diese Modularität reduziert den Zeitaufwand für die Modellierung erheblich, da bestehende, gut validierte Teilmodelle in neuen Kontexten wiederverwendet werden können, anstatt jedes Mal von Grund auf neu erstellt zu werden.

Experteninterviews

Die best practice, die im Laufe des F&E-Projekts für Experteninterviews erarbeitet wurde, besteht in einem moderierten und mehrschrittigen Prozess mit den jeweiligen Fachexperten. Insbesondere haben wir Kreativ- und Organisationstechniken angewandt, die aus der Abschlussarbeit „Konzeption und visuelle Ausarbeitung eines benutzerzentrierten Tools zur geführten Assoziation und Extraktion von Expertenwissen in kausalen Strukturmodellen“ [Skidan] heraus entstanden sind. Die Erkenntnisse aus den Nutzerinterviews mit Domänenexperten im Rahmen der Abschlussarbeit sowie die Rückmeldungen und Zusammenfassungen aus verschiedenen Workshops lieferten die Grundlage für die Weiterentwicklung der Experteninterviews auf den aktuellen Reifegrad. Der aktuelle Kenntnisstand favorisiert den Wechsel zwischen Einzelarbeit und Arbeit in Kleingruppen mit anschließender Präsentation und Zusammenführung der neuen Teilergebnisse mit den vorangegangenen. Aus den gewonnenen Erfahrungen und Rückmeldungen aus früheren Interviews ist ein Experteninterviewkonzept mit fünf Phasen (einschließlich Pitch-Phase) hervorgegangen.

Während der Modellerstellung ist es wichtig, kontinuierlich mit Fachexperten zu kommunizieren und deren Wissen in den Prozess einzubinden.

Kausale Inferenz

In diesem Abschnitt wird auf die Kausale Inferenz als ein zentrales Element des HolmeS3-Lösungsansatzes detailliert eingegangen. Kausale Inferenz ermöglicht es grundsätzlich, Fragen an ein Kausales Modell zu stellen und präzise Antworten zu erhalten. Dieser Prozess ist entscheidend, um Ursache-Wirkungs-Beziehungen in komplexen Systemen zu analysieren, zu verstehen und schlussendlich zu quantifizieren. Mit dieser Methodik können wir vorhersagen, wie Variationen in einer oder mehreren Variablen Änderungen in anderen Variablen hervorrufen, was die Entwicklung und Absicherung komplexer Systeme unterstützt.

Kausale Fragestellungen wie „Hätte der Crash verhindert werden können, wenn der Bremsassistent 0,2 Sekunden früher aktiviert worden wäre?“ sind von zentraler Bedeutung für Wissenschaft und Wirtschaft. Die Analyse solcher Fragen trägt maßgeblich zur Optimierung und Verbesserung komplexer Systeme bei. Im HolmeS3-Ansatz wird die Kausale Inferenz zur Untersuchung und Analyse expliziter und impliziter Zusammenhänge in Automotivesystemen verwendet. Diese Methode basiert auf Elementen der Wahrscheinlichkeitstheorie, statistischen Modellen und Graphentheorie. Ein tiefes Verständnis und die sorgfältige Implementierung dieser Techniken ermöglichen detaillierte Einblicke in die Systemmechanismen, die für deren Analyse und Verbesserung unerlässlich sind.

Im Rahmen der verwendeten SCMs ist es möglich, kausale Fragen zu stellen und zu beantworten. Diese Methodik nutzt drei Ebenen der kausalen Fragestellung, wie sie in Pearls Leiter der Kausalität [Pearl] dargestellt sind:

- **Assoziative Fragen:** Untersuchung von Korrelationen zwischen Variablen.
- **Interventionelle Fragen:** Aktive Veränderung kausaler Mechanismen, um direkte Auswirkungen zu verstehen.
- **Kontrafaktische Fragen:** Analyse hypothetischer Szenarien, um zu verstehen, was passiert wäre, wenn eine Variable anders gewesen wäre.

Es existieren umfangreiche Literatur und zahlreiche Instrumente im Bereich der Kausalen Inferenz. Dazu zählen der Do-Calculus [Huang], c-Komponenten [Tian], sowie die Identifizierung von gemeinsamen und bedingten Interventionsverteilungen aus Beobachtungsdaten [Shpitser2006a, Shpitser2006b]. Diese Arbeiten unterstützen die Entscheidungsfindung und Evaluierung von Richtlinien und tragen wesentlich zum umfassenden Verständnis der Kausalen Inferenz bei. Ein weiteres wichtiges Teilgebiet ist die Transportierbarkeit bzw. kausale Datenfusion [Bareinboim], die darauf abzielt, Informationen aus verschiedenen Regimen und Domänen zu kombinieren, um Antworten auf kausale Fragen zu liefern, die ansonsten nicht beantwortbar wären.

Die Anwendung der Kausalen Inferenz auf Fahrerassistenzsysteme ist besonders nützlich, um die Auswirkungen von Interventionen oder Szenarioveränderungen zu analysieren. Sie ermöglicht die Vorhersage, wie Änderungen in Variablen wie etwa Geschwindigkeit oder Straßenbedingungen die Zielvariablen, z.B. den Bremsweg beeinflussen.

Die Bedeutung der kausalen Inferenz reicht weit über die theoretische Analyse hinaus. Durch die Kombination von Kausalen Modellen und Szenario-basiertem Testen können realistische, sichere und effiziente Systeme entwickelt werden, die nicht nur den heutigen Anforderungen des Straßenverkehrs gerecht werden, sondern auch die Grundlage für zukünftige Innovationen in der automobilen Sicherheitstechnologie bilden.

Im HolmeS3-Ansatz wurden sowohl parametrische als auch nichtparametrische Ansätze verfolgt und implementiert. Ein bedeutender Teil unserer Forschung war die Umsetzung der Abduktion, die zur Kausalattribution dient. Hierbei werden ausgehend von Beobachtungen mögliche Ursachen abduziert, um assoziative, interventionelle und kontrafaktische Fragen zu beantworten.

Durch diese Ansätze konnten wir tiefgehende Einblicke und präzise Antworten auf kausale Fragen im Kontext von Fahrerassistenzsystemen gewinnen, was zur fortlaufenden Verbesserung und Optimierung dieser Systeme beitragen kann.

Erstellung eines Kausalen Modells am Beispiel eines Notbremsassistenten

Der folgende Abschnitt zeigt anhand eines praktischen Beispiels [Maier], wie ein Kausales Modell für einen Notbremsassistenten (NBA) erstellt wird. Der Notbremsassistent eignet sich die Methode darzulegen, da die Sollfunktion intuitiv verständlich, dennoch im Detail komplex ist. Notbremsassistenten sind eine gereifte Fahrfunktion, werden seit über einem Jahrzehnt eingesetzt und es existieren öffentlich zugängliche Spezifikationen. Außerdem verfügt ein Notbremsassistent über diverse Pfade an äußeren Einflussfaktoren, wie visuell basierte Sensorsysteme (Kamera, LiDAR), als auch direkte physikalische Zusammenhänge mit der Umgebung (z.B. Reibung). Von besonderem Interesse ist in diesem Zusammenhang der nichtlineare Einfluss von Temperatur und Niederschlag auf den Reibwert.

Modellkontext

Ein Kausales Modell kann - wie jedes Modell - ein reales technisches System nicht vollständig beschreiben und stellt nur eine vereinfachte Abbildung der Realität dar. Daher ist es wichtig, den Modellkontext vor der Erstellung des Modells genau zu definieren. Der Modellkontext wird aus den Anforderungen an das Modell abgeleitet und beschreibt die expliziten Annahmen sowie die Aspekte, die bewusst ausgeklammert werden.

Im Kausalen Modell für Notbremsassistenten betrachten wir ein einziges Szenario, bei dem ein Fahrzeug (Ego) hinter einem anderen Fahrzeug (Agent) auf einer geraden Straße fährt. Beide Fahrzeuge fahren in dieselbe Richtung mit konstanter Geschwindigkeit. Die Sensorik des Ego-Fahrzeugs kann die relative Geschwindigkeit und den Abstand zwischen den beiden Fahrzeugen in Echtzeit messen. Es wird angenommen, dass der Notbremsassistent keine Informationen über den aktuellen Reibungskoeffizienten hat und mit einem angenommenen Wert für die Bremsverzögerung arbeitet. Der Notbremsassistent berechnet einen Schwellwert für die Distanz zwischen den Fahrzeugen. Wenn der Fahrzeugabstand für die jeweilige Relativgeschwindigkeit kleiner wird als dieser Schwellwert, leitet der Assistent eine Vollbremsung ein.

Das Modell vergleicht die Distanz, bei der eine Vollbremsung eingeleitet wird, mit der minimalen Distanz, die erforderlich ist, um eine Kollision zu vermeiden. Die Differenz dieser Werte repräsentiert den fehlenden Bremsweg und dient als Indikator für die Kollisionsstärke.

Identifizierung von Einflussfaktoren

Ausgehend vom Modellkontext wurden eine Literaturrecherche sowie mehrere Interviews mit Experten durchgeführt, um mögliche Einflussfaktoren auf die Variable „Fehlender Bremsweg bei Kollision“ zu identifizieren. Der resultierende kausale Graph beschreibt die kausalen Zusammenhänge, enthält jedoch noch keine quantitativen Informationen.

Datenquellen zur Quantifizierung

Um die Zusammenhänge im Modell zu quantifizieren, wurden weitere Experteninterviews durchgeführt und verschiedene Datenquellen herangezogen:

- **Verteilungen der exogenen Variablen:**
 - Daten aus der realen Welt: typische Verteilungen von Lufttemperatur, Niederschlags- und Nebelintensität in Deutschland ([DWD], [Statista]).
 - Daten aus technischen Spezifikationen: angenommene Bremsverzögerung des Ego-Fahrzeugs ([Küçükay]).
- **Mechanismen der endogenen Variablen:**
 - Ergebnisse aus CARLA-Simulationen: funktionale Zusammenhänge zwischen Detektionsdistanz und Umgebungsparametern.
 - Wissenschaftliche Publikationen: Modelle für Reibungskoeffizienten ([Lahayne], [Hippi], [MODLAB]).
 - Physikalische Formeln: Ableitungen für relative Geschwindigkeit, Bremsverzögerung und Bremsweg ([Küçükay]).

Beispielsweise wird die Variable „Algorithmusbremungskritische Distanz“ durch folgende Formel beschrieben:

$$d_{alg} = \frac{\Delta v^2}{2 \cdot a_a} + U_{da}, \text{ wobei}$$

d_{alg} - Schwellwert für die Distanz zwischen beiden Fahrzeugen, in m

Δv - relative Geschwindigkeit (Differenz zwischen Ego- und Agent-Geschwindigkeit), in m/s

a_a - die vom Notbremsassistent angenommenen Bremsverzögerung des Ego-Fahrzeugs (stammt aus der technischen Spezifikation), in m/s²

U_{da} - Noise-Variable, die statistisches Rauschen repräsentiert

Zusammenfassung des Modells

Das vollständige Kausale Modell für den Notbremsassistenten umfasst die Verteilungen und Mechanismen aller Variablen im Modell. Diese umfassen u.a.:

- Daytime (Tageszeit): Gleichverteilung
- Fog (Nebel): Halbnormalverteilung
- Precipitation (Niederschlag): Halbnormalverteilung
- Algorithm braking critical distance (Schwellwert für die Distanz): Physikalische Berechnung
- Relative speed (Relative Geschwindigkeit): Annahme urbaner Geschwindigkeiten
- Friction (Reibung): Abhängigkeit von Temperatur und Niederschlag
- Distance at first detection (Distanz beim Detektieren): Funktionaler Zusammenhang aus CARLA-Simulation
- Assumed deceleration of ego vehicle (Angenommene Bremsverzögerung): Normalverteilung
- Deceleration of ego vehicle (Tatsächliche Bremsverzögerung): Physikalische Berechnung
- Minimum distance required to stop safely (Sicherer Mindestabstand): Physikalische Berechnung
- Temperature (Temperatur): Normalverteilung
- Lack of braking distance (Fehlender Bremsweg): Indikator für Kollisionsstärke
- Ego speed (Ego-Geschwindigkeit): Normalverteilung
- Agent speed (Agent-Geschwindigkeit): Normalverteilung

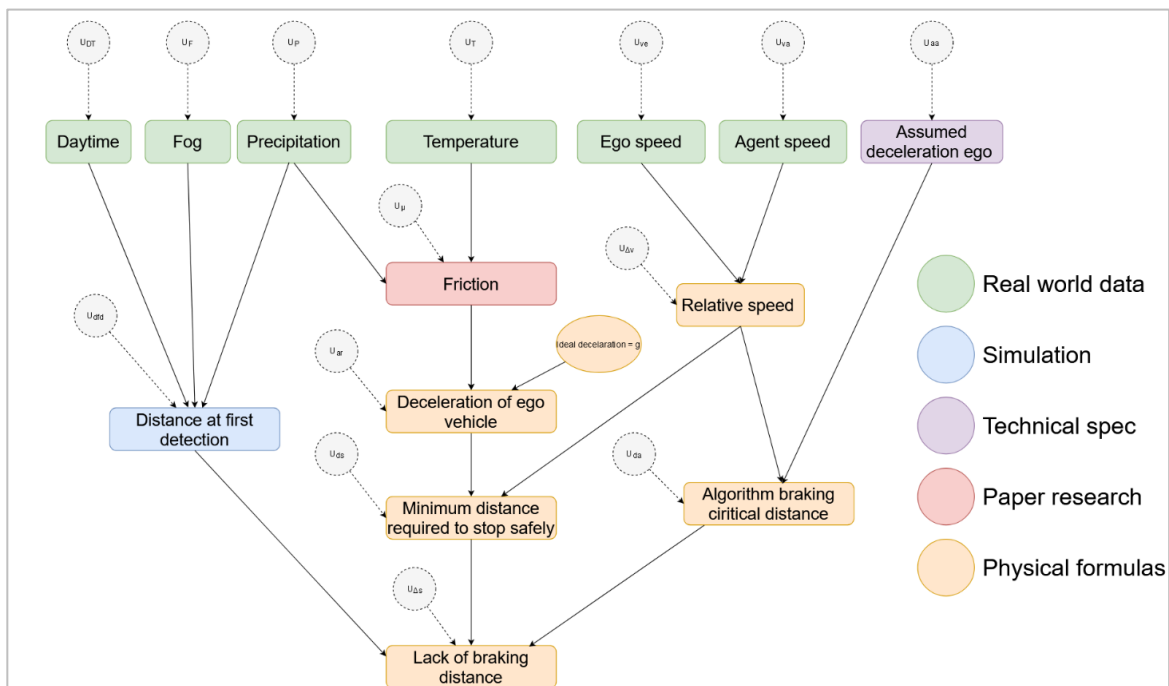


Abbildung 3: Die graphische Repräsentation als SCM des gegenständlichen Notbremsassistentenmodells.

Einsatz Kausaler Modelle zur Identifikation von Corner Cases

Die Definition von Corner Cases (Randfälle) [SPEC91381] lautet wie folgt: Ein Corner Case ist ein "Szenario, in dem die Ausprägungen von einem oder mehr Parametern innerhalb der Fähigkeiten des Systems liegen, in ihrer Kombination aber zu einem Zustand führen, der die Fähigkeiten des Systems herausfordert." Diese Randfälle sind besonders kritisch für die Absicherung automatisierter Fahrfunktionen und gleichzeitig schwierig zu finden. Im Rahmen des Forschungsprojekts haben wir untersucht, wie die Suche nach Corner Cases mithilfe kausaler Methoden ermöglicht beziehungsweise verbessert werden kann.

Ein kausaler Graph charakterisiert eine reale und unter bestimmten Annahmen beweisbare sog. Independence Map. Eine weitere Vereinfachung der Simulation führt daher zu einer Verbesserung ihrer Laufzeit. Dies bedeutet, dass die Kombinationen von Einflussfaktoren, die im Kausalgraphen nicht zusammenhängen, bei der Corner Case- Suche nicht mit

Optimierungsverfahren und ggf. anschließend in der Simulation nicht variiert werden müssen. Der entscheidende Vorteil ergibt sich weiterhin daraus, dass ein Kausalmodell die kausale Zuordnung von Ursache-Wirkungs-Prinzipien über die reine assoziative Zuordnung hinaus ermöglicht. Erst der Einsatz von Interventionen bzw. kontrafaktisch definierten Zuschreibungen (notwendige und hinreichende Ursache von Einflussfaktoren) ermöglicht die Umsetzung von Strategien zur Identifizierung von Corner Cases.

Ein Beispiel für einen Corner Case unseres NBA-Modells (siehe Kapitel 3.2.1) ist eine Temperatur um 0°C (niedrigster Reibwert tritt bei diesen Temperaturen auf) zusammen mit mittelstarkem Niederschlag. Wenn man nur die extremen Werte der einzelnen Variablen getestet hätte, wäre dieser problematische Corner Case nicht gefunden worden.

Wir entwickelten verschiedene Ansätze, um Kausale Modelle für die Suche von Corner Cases zu verwenden, und testeten diese an unserem NBA-Modell. Kritische Fälle, die die Fähigkeiten des Systems herausfordern, zeichnen sich durch besonders hohe Werte für "fehlender Bremsweg" aus, da diese Fälle unzureichende Notbremsungen darstellen. Unsere Ansätze lassen sich grob in zwei Schritte unterteilen:

1. **Auffinden von kritischen Parameterkombinationen:** Zunächst explorierten wir die verschiedenen möglichen Parameterkombinationen, indem wir das natürliche Verhalten des Modells untersuchten und zufällig gefundene Parameterkombinationen analysierten, die zu schweren Kollisionen führten. Diese Methode garantiert jedoch nicht, dass alle Corner Cases gefunden werden. Um gezielter nach kritischen Kombinationen zu suchen, integrierten wir Causal Reinforcement Learning [BareinboimCRL] in den ersten Schritt. Hierbei agiert ein Agent auf dem Kausalen Modell und lernt durch Rückmeldungen aus seiner Umgebung gezielt kausale Fragen zu stellen.
2. **Bewertung der Parameterkombinationen:** Der zweite Schritt umfasst die genauere Untersuchung und Bewertung der gefundenen Parameterkombinationen. Für einen Anwender unserer Methode ist es wichtig zu verstehen, warum eine kritische Situation entsteht und welche Parameter dafür relevant sind. Hierfür nutzten wir zwei Ansätze:
 - Anpassung der "Probability of Necessity" und "Probability of Sufficiency" auf unser Problem: Diese Metriken sind weit verbreitet und in Standardwerken wie [Pearl] definiert. Wir entwickelten eine interventionelle Metrik, um die Relevanz von Parametern für das Auftreten kritischer Fälle zu bewerten.
 - Verwendung der Kausalstruktur-basierten Ursachenanalyse [Budhathoki]: Diese Methode bewertet die einzelnen Knoten mithilfe kontrafaktischer Fragestellungen und Shapley-Werten bezüglich ihres Einflusses auf einen beobachteten Ausreißerwert.

Anwendung in der Praxis

Für Nutzer unseres Tools gestaltet sich die Corner Case-Suche wie folgt. Zunächst werden folgende Informationen vom Nutzer benötigt:

- **Zielvariable** für die Corner Cases (z.B. "fehlender Bremsweg").
- **Einflussknoten** (z.B. "Regen", "Nebel", "Temperatur", "Ego-Geschwindigkeit").
- **Kritische Werte** (z.B. hoher Wert für fehlenden Bremsweg).

Basierend auf diesen Eingaben werden Corner Case-Kandidaten automatisch bestimmt und hinsichtlich ihrer Ursachen bewertet. Die Ursachenanalyse wird in Form eines Histogramms an den Nutzer weitergegeben. Die graphische Benutzeroberfläche mit den Ergebnissen zeigt den kausalen Graphen, eine Tabelle mit Corner Cases und ein Histogramm, das die Einflussstärke der einzelnen Parameter darstellt.

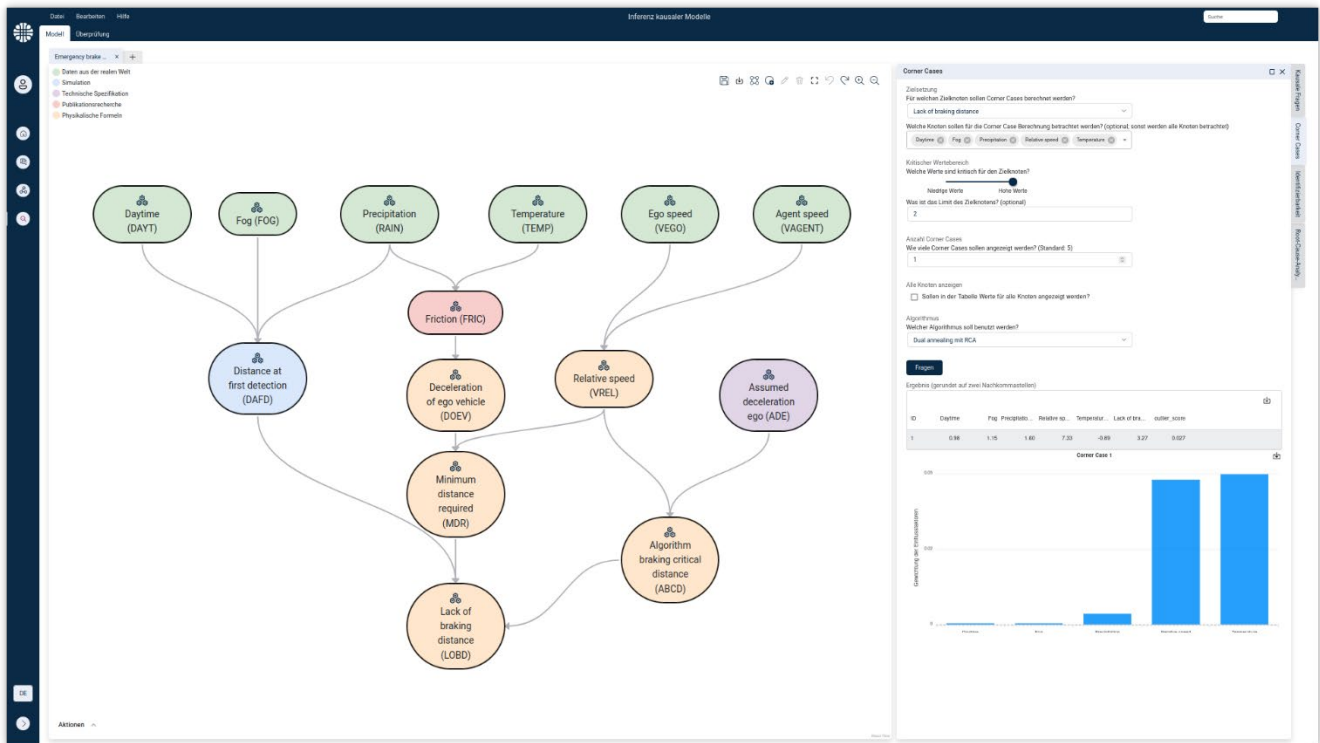


Abbildung 4: Corner Case- Suche mit kausalen Methoden

In der Tabelle sieht man die gefundenen kritischen Parameterkombinationen. Eine Zeile repräsentiert einen Corner Case. Beispielsweise zeigt die erste Zeile, dass um 24.59 Uhr bei 1,6 mm/h Regen, einer Relativgeschwindigkeit von 7,33 m/s und einer Temperatur von $-0,89^{\circ}\text{C}$ ein schwerer Unfall passiert. Im darunter stehenden Balkendiagramm ist veranschaulicht, welcher Knoten wie viel zum Auftreten des Corner Cases beigetragen hat. Je höher der Balken, desto mehr trägt der spezifische Wert der Variablen zum Auftreten des Corner Cases bei.

4. Szenario-basiertes Testen

Eine immer wichtiger werdende Methode zur Absicherung von hochautomatisierten Fahrfunktionen (ADS) und autonomen Fahrzeugen ist das sogenannte „Szenario-basierte Testen“.

Definition²

Unter Szenario-basiertem Testen versteht man, „das Testen des Verhaltens eines Cyber-Physical-Systems (z.B. eines autonomen Fahrzeugs) oder einer Komponente oder einer Funktion davon innerhalb eines Szenarios durch Ausführen des Szenarios mittels Simulation oder in der realen Welt“.

Anwendungsdomänen

Szenario-basiertes Testen ist nicht auf den Einsatz in der Automobilindustrie begrenzt, sondern kann auch zur Absicherung anderer Arten autonomer Systeme eingesetzt werden. Beispiele sind die Verifikation und Validierung (V&V) von autonom fahrenden Zügen, autonom operierenden Robotik-Systemen, autonomen Wasserfahrzeugen, oder von autonom fliegenden Systemen, wie z.B. Drohnen (s.a. [Linz]). Das gemeinsame Kennzeichen dieser Beispiele ist, dass das Testobjekt („System Under Test“, SUT) ein „Cyber-Physical System“ (CPS) ist, und demzufolge die besonderen Merkmale und Risiken solcher CPS den V&V-Prozess prägen. Die folgende Abbildung veranschaulicht die Breite der Anwendungsdomänen:

² [ASAM], [SOTIF], [Steimle], [Ulbrich] u.a. einschlägige Literatur geben Definitionen des Begriffs „Szenario“, aber erstaunlicherweise keine Definition für „Szenario-basiertes Testen“. Die hier angegebene Definition wurde im Rahmen des HolmeS3-Projekts erarbeitet, inkl. der in Abbildung 5 gezeigten Einordnung in unterschiedliche Anwendungskontexte.

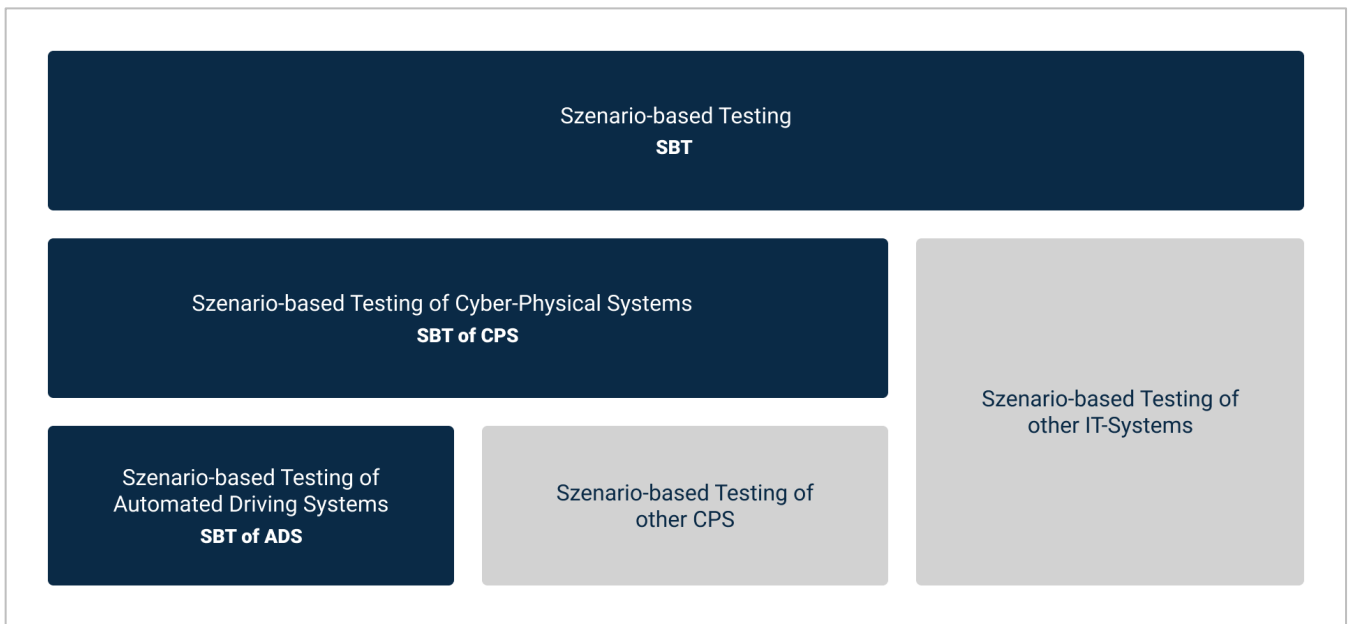


Abbildung 5: Anwendung von Szenario-basiertem Testen in unterschiedlichen Kontexten

Testszenarioszenarien

Eine wesentliche Anforderung bezüglich der Erstellung und Auswahl der im Absicherungsprozess herangezogenen Szenarios ist, dass durch eine geeignete Menge unterschiedlicher Szenarios die Umwelt, in der das betreffende System im echten Betrieb operiert oder operieren könnte, hinreichend abgedeckt wird. Für den Test eines Notbremsassistenten könnte man beispielsweise die folgenden beiden Szenarios heranziehen:

1. Als „einfaches“ Szenario: eine gerade, einspurige städtische Straße, auf der (vor dem zu testenden Fahrzeug) ein zweites Fahrzeug vorausfährt.
2. Als „schwieriges“ Szenario: eine Innenstadt-Kreuzung mit Ampeln, Fußgängerüberwegen und mehreren Fahrzeugen, die in den unterschiedlichen Richtungen über die Kreuzung fahren.

Im Rahmen der ISO 21448 werden diese beiden Kategorien durch eine Aufteilung in bekannte/unbekannte sowie kritische und unkritische Szenarios aus Sicht möglicher Risiken im Absicherungsprozess aufgeteilt.

Diese Liste lässt sich leicht um etliche weiteren Szenarios erweitern, die ebenfalls herangezogen werden sollten. Darüber hinaus sollte oder muss im Test dann jedes der identifizierten Szenarios mit unterschiedlichen Parametrierungen ausgeführt werden: beispielsweise mit unterschiedlichen Geschwindigkeiten des Ego-Cars, mit unterschiedlichen Wetterbedingungen oder Lichtverhältnissen etc. Als Resultat ergibt sich eine sehr hohe Anzahl von Tests bzw. Testläufen, die ausgeführt werden müssen. Auch wenn diese Tests „nur“ als Simulation „im Rechner“ ausgeführt werden, ist der Testdurchführungsaufwand enorm und die Frage ist: welche Szenarios mit welcher Parametrierung sind die relevantesten?

Corner Cases

Genau hierzu liefert die HolmeS3-Methodik eine Antwort, in Form der aus Kausalen Modellen errechneten Corner Cases. Denn jeder Corner Case ist eine konkrete Parameterbelegung, die die Fahrfunktion bzw. das Fahrzeug in eine (relativ zur im Kausalen Modell gewählten Zielgröße) „kritische Situation“ steuert (z.B. Mindestabstand unterschritten, zulässige Temperatur überschritten, etc.). Im simulierten Testlauf kann dann beobachtet und geprüft werden, ob das Testobjekt hier (noch) wie gewünscht funktioniert bzw. reagiert.

Die HolmeS3-Methodik behauptet nicht und stellt auch nicht sicher, dass eine bestimmte Anzahl von auf diese Weise errechneter Corner Cases alle denkbaren anderen Testdatenkombinationen ohne Verlust der Testaussagekraft ersetzen können. Die HolmeS3-Methodik liefert jedoch ein transparentes und quantitatives Verfahren zur risiko-gesteuerten Auswahl einer Teilmenge relevanter Datenkombinationen in Form dieser Corner Cases. Damit kann die HolmeS3-Methodik einen sehr wichtigen Beitrag zu der von [SOTIF] geforderten Risikoargumentation leisten.

5. Überblick über die Toolchain

Die in Abbildung 1 gezeigten Methoden-Bausteine wurden in der HolmeS3-Toolkette durch zwei Hauptkomponenten realisiert: Whyond und TestBench SBT. Diese Tools sind sowohl einzeln einsetzbar als auch in Kombination, um eine umfassende und effiziente Testumgebung zu schaffen.

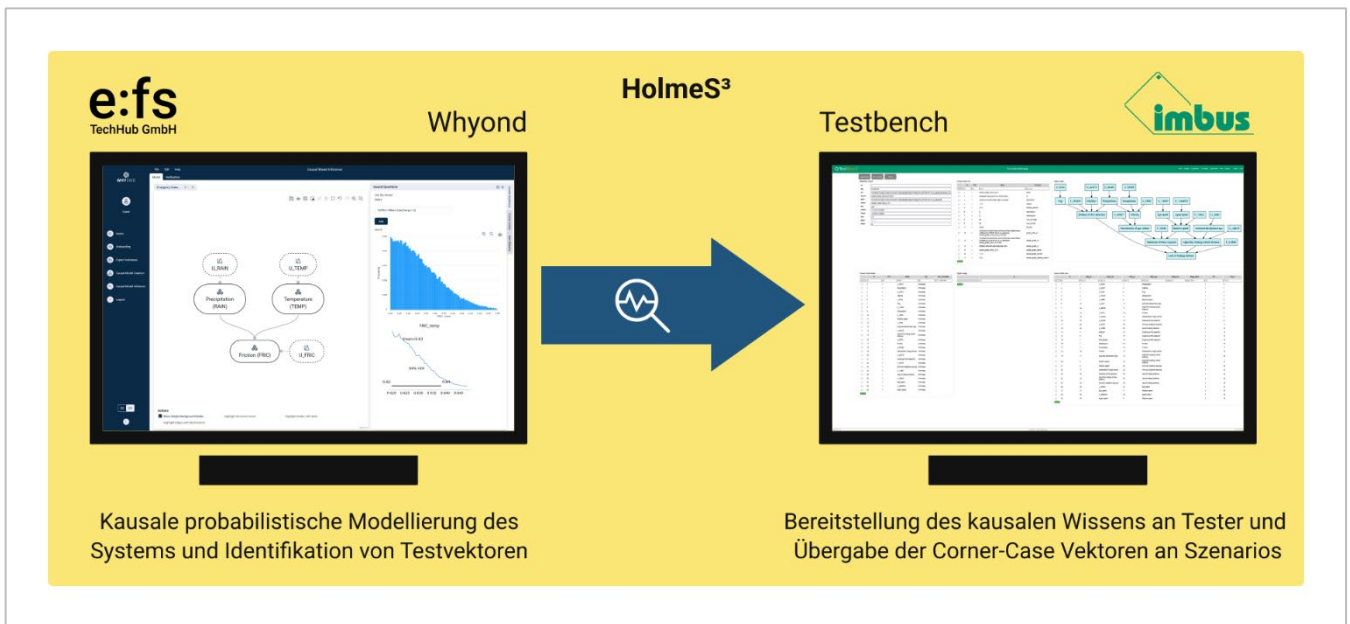


Abbildung 6: Screenshots Whyond und TestBench SBT

Whyond [Whyond] ist eine Web-basierte Anwendung, die von der efs GmbH entwickelt wurde. Sie dient der Erstellung und Berechnung Kausaler Modelle und bietet folgende Hauptfunktionen:

- **Kausale Modellierung:** Nutzer können intuitive grafische Oberflächen nutzen, um kausale Graphen zu erstellen, die komplexe systemische Beziehungen darstellen. Diese Modelle dienen als Grundlage für die Simulation und Analyse von Systemverhalten unter verschiedenen Bedingungen.
- **Kausale Inferenz:** Nach der Erstellung der Modelle ermöglicht Whyond die Durchführung von Kausalen Inferenzen. Diese Funktion erlaubt es, Hypothesen über die Auswirkungen von Veränderungen innerhalb des Systems systematisch zu testen und zu validieren.

Die Kombination dieser Funktionen macht Whyond zu einem leistungsstarken Werkzeug für Ingenieure und Forscher, die tiefgreifende Einblicke in die Funktionsweise ihrer Systeme gewinnen und potenzielle Verbesserungen identifizieren möchten.

TestBench SBT ist eine weitere zentrale Komponente der HolmeS3-Toolkette, wurde von der imbus AG entwickelt und ergänzt die [Testbench] Produktfamilie der imbus AG mit einer Lösung für Szenario-basiertes Testen. TestBench SBT bietet folgende Funktionsblöcke:

- **Manage Scenarios:** Ermöglicht den Zugriff auf und die Verwaltung von Szenario-Repositories. Nutzer können vorhandene Szenarien einsehen, bewerten und für Tests auswählen.
- **Design Tests:** Nutzer können Tests spezifizieren, die auf den zuvor modellierten Szenarien basieren. Dabei lassen sich spezifische Testdaten generieren und Szenarien entsprechend konfigurieren.
- **Manage Tests:** Diese Funktion bietet eine Übersicht über existierende Tests und deren Ergebnisse.
- **Run Scenarios:** Ausgewählte Tests und Szenarien können zur Ausführung an angekoppelte Szenario-Simulatoren übergeben werden, um das Verhalten der automobilen Systeme unter realistischen Bedingungen zu testen.

Die Integration von Whyond und TestBench SBT ermöglicht eine nahtlose Überführung von theoretischen Modellen und Hypothesen in praktische Testszenarien. Diese Synergie verstärkt die Fähigkeit, komplexe automotiv Systeme zu analysieren, zu testen und letztlich sicherer zu gestalten. Durch den Einsatz dieser Tools kann nicht nur die Effizienz der Entwicklungs- und Testprozesse erhöht, sondern auch die Zuverlässigkeit und Sicherheit der Endprodukte signifikant verbessert werden.

6. Zusammenfassung und Ausblick

Das HolmeS3-Projekt hat eine Methodik und eine zugehörige Toolkette entwickelt, die es Anwendern ermöglicht, Kausalmodelle zu erstellen und aus diesen Modellen berechnete Corner Cases für das Szenario-basierte Testen zu nutzen.

Die Diskussionen (im Rahmen der Modellerstellung) über kausale Zusammenhänge (zwischen Systemvariablen, Umweltvariablen und ggf. weiterer Einflußgrößen) und ihrer Stärke und Relevanz hilft dem Team, sein Wissen über das zu entwickelnde System zu vertiefen und zu einer gemeinsamen Auffassung zu konsolidieren. Die erstellten Kausalmodelle dokumentieren dieses erarbeitete Wissen in einer strukturierten, auch für Außenstehende leicht nachvollziehbaren Weise und erleichtern dadurch u.a. auch die von [SOTIF] geforderte "Sicherheitsargumentation" für die betreffende Fahrfunktion.

Durch Nutzung der aus den Kausalmodellen generierten Corner Cases, kann im Testprozess die Abdeckung “kritischer” Variablenwert-Kombinationen gezielter erreicht werden. Durch eine Fokussierung der Testfallvarianten auf diese Corner Cases kann darüberhinaus eine Priorisierung der Testfälle zu Gunsten der Corner Cases (an Hand der Kausalmodelle) begründet werden. Darauf aufsetzend können dann Entscheidungen über die Reduktion der (theoretisch zu betrachtenden) Testfallvarianten auf kleinere Teilmengen besser begründet werden.

Aktuell erproben wir die HolmeS3-Methodik und Toolkette im Rahmen von Pilotprojekten mit Partnern in der Automobilindustrie. Sowohl die Methodik als auch die Tools sind aber nicht auf den Einsatz im Bereich Automotive beschränkt. Eine Anwendung ist aus Sicht der HolmeS3-Projektpartner in allen Projekten möglich, wo sicherheitskritische Cyber-Physical-Systems entwickelt werden, also beispielsweise bei der Entwicklung komplexer bzw. (teil-)autonomer Roboter oder in der Bahnindustrie bei der Entwicklung fahrerloser Zugsysteme.

Die HolmeS3-Lösung wird durch die Partner efs und imbus auch nach Abschluß der geförderten Phase des HolmeS3-Projekts betreut und weiterentwickelt. Beide Partner stehen bei Fragen zur Einführung und Anwendung der Methodik für kausale Modellierung und Szenario-basiertes Testen gerne zur Verfügung, aber auch für Fragen zu Customizing, Integration und Einführung der HolmeS3-Toolkette in vorhandene Entwicklungsprozesse.

7. Quellen

Webseiten aufgerufen 07/24

- [ASAM] ASAM OpenSCENARIO, File formats for the description of the dynamic content of driving and traffic simulators, ASAM e.V., <https://www.asam.net/standards/detail/openscenario-xml/>, <https://www.asam.net/standards/detail/openscenario-dsl/>
- [Bareinboim] Pearl, J., & Bareinboim, E. (2011). Transportability of Causal and Statistical Relations: A Formal Approach. *Proceedings of the AAAI Conference on Artificial Intelligence*, 25(1), 247-254, <https://doi.org/10.1609/aaai.v25i1.7861>
- [Hippi] Hippi, Marjo & Juga, Ilkka & Nurmi, Pertti. (2010). A statistical forecast model for road surface friction, https://www.researchgate.net/publication/271133153_A_statistical_forecast_model_for_road_surface_friction
- [Huang] Yimin Huang and Marco Valtorta. “Pearl’s Calculus of Intervention Is Complete”. en. In: *Proceedings of the Twenty-Second Conference on Uncertainty in Artificial Intelligence. UAI’06*. Arlington, Virginia, USA: AUAI Press, July 2006, pp. 217–224, <https://dl.acm.org/doi/10.5555/3020419.3020446>
- [IPG CarMaker] Simulations-Lösung der Firma IPG Automotive GmbH, <https://www.ipg-automotive.com/de/produkte-loesungen/software/carmaker/>
- [Küçükay] Küçükay, F. (2022). *Abbremsung und Bremssysteme*. In: *Grundlagen der Fahrzeugtechnik*, Springer Vieweg, Wiesbaden, https://doi.org/10.1007/978-3-658-36727-5_18
- [Lahayne] Lahayne, O., Pichler, B., Reihnsner, R. et al. Rubber Friction on Ice: Experiments and Modeling, *Tribol Lett* 62, 17 (2016), <https://doi.org/10.1007/s11249-016-0665-z>
- [Linz] Linz Tilo, *Testing Autonomous Systems*. In: Goericke S. (eds) *The Future of Software Quality Assurance*, Springer Cham., 2020, https://doi.org/10.1007/978-3-030-29509-7_5
- [Maier] R. Maier, L. Grabinger, D. Urlhart and J. Mottok, "Causal Models to Support Scenario-Based Testing of ADAS," in *IEEE Transactions on Intelligent Transportation Systems*, vol. 25, no. 2, pp. 1815-1831, Feb. 2024, <https://doi.org/10.1109/TITS.2023.3317475>
- [MODLAB] *Climatological studies of road friction*, http://www.modlab.lv/klimats/produkti/road/Road_notebook.html
- [Pearl] Judea Pearl. *Causality: models, reasoning, and inference*, en. 2. ed., repr. with corr. Cambridge: Cambridge University Press, 2013, <https://www.cambridge.org/core/journals/econometric-theory/article/abs/causality-models-reasoning-and-inference-by-judea-pearl-cambridge-university-press-2000/DA2D9ABB0AD3DAC95AE7B3081FCDF139>
- [RCM] https://en.wikipedia.org/wiki/Rubin_causal_model
- [Schoelkopf] Schoelkopf, B., Janzing, D., & Peters, J. (2017). *Elements of Causal Inference: Foundations and Learning Algorithms*. MIT Press. ISBN: 9780262037313

- [Shpitser2006a] Ilya Shpitser and Judea Pearl. “Identification of Joint Interventional Distributions in Recursive Semi-Markovian Causal Models”. In: In Proceedings of the Twenty-First National Conference on Artificial Intelligence. Menlo Park, CA, July 2006, pp. 1219–1226. (Visited on 09/16/2020). https://www.researchgate.net/publication/221606257_Identification_of_Joint_Interventional_Distributions_in_Recursive_Semi-Markovian_Causal_Models
- [Shpitser2006b] Ilya Shpitser and Judea Pearl. “Identification of Conditional Interventional Distributions”, en. In: Proceedings of the Twenty-Second Conference on Uncertainty in Artificial Intelligence. UAI’06. Arlington, Virginia, USA: AUAI Press, July 2006, pp. 437–444, <https://dl.acm.org/doi/abs/10.5555/3020419.3020472>
- [Skidan] Katharina Romanow, ehem. Skidan, Bachelorarbeit, Konzeption und visuelle Ausarbeitung eines nutzerzentrierten Tools zur geleiteten Assoziation und Extraktion von Expertenwissenin kausalen Strukturmodellen, Technische Hochschule Ingolstadt, 2022
- [SOTIF] ISO 21448:2022, Road vehicles — Safety of the intended functionality (SOTIF), <https://www.iso.org/standard/77490.html>
- [Steimle] Markus Steimle, Till Menzel, Markus Maurer, Towards a Consistent Terminology for Scenario-Based Development and Test Approaches for Automated Vehicles: A Proposal for a Structuring Framework, a Basic Vocabulary, and its Application, Institute of Control Engineering, Technische Universität Braunschweig
- [Testbench] Testmanagement-Lösung der Firma imbus AG, <https://www.testbench.com/>
- [Tian] Jin Tian. “Studies in Causal Reasoning and Learning”, PhD thesis. Los Angeles: Department of Computer Science, University of California, 2002, https://ftp.cs.ucla.edu/pub/stat_ser/r309.pdf
- [Ulbrich] S. Ulbrich, T. Menzel, A. Reschka, F. Schuldt, and M. Maurer, “Defining and substantiating the terms scene, situation, and scenario for automated driving,” in 2015 IEEE Int. Conf. Intell. Transp. Syst., 2015, pp. 982–988, <https://doi.org/10.1109/ITSC.2015.164>
- [Whyond] Lösung zur Kausalen Modellierung der Firma efs, <https://www.efs-techhub.com/efs-portfolio/loesungen/whyond>