

## **Absicherung der Umfeldwahrnehmung von hoch- und vollautomatisierten Fahrzeugen**

**M. Berk**, Technische Universität München<sup>1</sup>

Dr. **O. Schubert**, AUDI AG<sup>2</sup>, Ingolstadt

**H.-M. Kroll**, AUDI AG<sup>2</sup>, Ingolstadt

Dr. **B. Buschardt**, AUDI AG<sup>2</sup>, Ingolstadt

Prof. Dr. **D. Straub**, Technische Universität München<sup>1</sup>

<sup>1</sup> Engineering Risk Analysis Group

<sup>2</sup> Entwicklung Radar- / Lasersensorik automatisiertes Fahren

### **Kurzfassung**

Der Sicherheitsnachweis automatisierter Fahrfunktionen ist eine der größten Herausforderungen in der Entwicklung von hoch- und vollautomatisierten Fahrsystemen. Eine zentrale Rolle hat hierbei die Bestimmung der Zuverlässigkeit der Umfeldwahrnehmung basierend auf z.B. Lidar, Radar, Kamera und Ultraschallsensoren, deren Fehler sicherheitskritisch sein können. In diesem Beitrag geben wir einen Überblick, wie die Zuverlässigkeit der Umfeldwahrnehmung bestimmt und nachgewiesen werden kann. Dabei gehen wir auf zwei Fragen ein: 1.) Wie können Zuverlässigkeitsziele für die Umfeldwahrnehmung festgelegt werden? 2.) Wie können die geforderten Ziele nachgewiesen werden?

Um diesen Fragestellungen zu begegnen, stellen wir einen Ansatz vor, der durch eine geeignete funktionale Beschreibung des automatisierten Fahrsystems in Verbindung mit Methoden der Systemzuverlässigkeitstheorie die Absicherungsfalle überwindet. Die Absicherungsfalle besteht in dem extrem hohen Absicherungsaufwand, der zur Freigabe der automatisierten Fahrsysteme notwendig ist. Ein speziell entwickeltes Lernverfahren ermöglicht es außerdem, unter Ausnutzung von Redundanzen in der Umfeldsensorik, Aussagen über Sensorfehlerraten zu machen, ohne dass eine Referenzwahrheit benötigt wird. Aufgrund der Vielschichtigkeit dieses Themas bestehen noch weitere Herausforderungen. Nicht vollständig gelöst sind beispielsweise die mathematische Modellierung von Systemänderungen, die explizite Modellierung von Wahrnehmungsfehlern, welche in der Sensordatenfusion entstehen oder die Quantifizierung der statistischen Abhängigkeit von Wahrnehmungsfehlern zwischen verschiedenen Sensortechnologien.

## **Abstract**

One of the key challenges in the development of highly automated driving systems is the demonstration of system safety. Central to the safety of an automated driving system is the reliability of the environment perception provided by radar, camera, lidar and ultrasonic sensors because perception errors are safety-critical. In this work, we give a comprehensive overview on how to demonstrate the reliability of the environment perception. Two questions are of particular importance: 1.) How can one derive reliability requirements for the environment perception and the respective environment perceiving sensors? 2.) How can one demonstrate that the environment perception complies with the requirements?

To address these questions, we present an approach that is able to overcome the approval trap for automated driving systems. The approval trap is due to the unfeasibly large test effort required to demonstrate the automated driving systems' safety. This approach is based on a suitable functional description of the automated driving system in combination with system reliability methods. Additionally we give a short overview on a statistical learning framework, which enables to estimate sensor error rates by exploiting sensor redundancies. This learning framework does not require a reference truth. Further challenges associated with demonstrating the reliability of the environment perception exist. Future work should for instance try to mathematically model changes and updates to the automated driving systems, explicitly model the perception errors that are due to the sensor data fusion and study the statistical perception error dependence of different sensor technologies in detail.

## **1. Die Absicherung der Umfeldwahrnehmung**

Eine der größten Herausforderungen in der Entwicklung von hoch- und vollautomatisierten Fahrsystemen ist der Nachweis der Systemsicherheit [1 bis 5]. Neben möglichen Produkthaftungsrisiken für die Hersteller im Falle fehlerhafter Produkte ist eine ausreichend hohe Sicherheit auch eine wesentliche Voraussetzung für die gesellschaftliche Akzeptanz und die Zulassung von automatisierten Fahrsystemen [6, 7]. Der Bericht der Ethikkommission zum automatisierten und vernetzten Fahren fordert beispielsweise: „Die Zulassung von automatisierten Systemen ist nur vertretbar, wenn sie im Vergleich zu menschlichen Fahrleistungen zumindest eine Verminderung von Schäden im Sinne einer positiven Risikobilanz verspricht.“ [8]. Die Auffassung, dass das automatisierte Fahren mindestens so sicher sein muss wie das menschliche Fahren, findet sich auch vielfach in der Literatur und wird beispielsweise durch menschliche Unfallraten konkretisiert [1, 2, 4]. Ein wichtiger Aspekt für die Sicherheit von automatisierten Fahrzeugen ist die Zuverlässigkeit der Umfeldwahrnehmung von Lidar, Radar, Kamera und Ultraschallsensoren [7, 9]. In diesem Beitrag stellen wir Herausforderungen und Lösungsansätze zum Nachweis der Zuverlässigkeit der Umfeldwahrnehmung vor.

Derzeit gibt es (noch) keine umfassenden Standards und Normen für die Entwicklung sicherer automatisierter Fahrsysteme und einer zuverlässigen Umfeldwahrnehmung. Die ISO 26262 deckt nicht alle Aspekte der Sicherheit eines automatisierten Fahrsystems ab, beispielsweise keine Unzulänglichkeiten in der Umfeldwahrnehmung [2, 3, 10]. Schwerpunkt der ISO-Betrachtung sind zufällige Hardware Fehler. Die Methoden der ISO 26262 lassen sich nicht direkt auf die Entwicklung einer sicheren Umfeldwahrnehmung übertragen, weil es kaum möglich ist, die funktionalen Anforderungen für alle erdenklichen Situationen, Fahrzeugvarianten und Ausprägungen der Umwelt umfassend zu definieren. Speziell die Ausprägungen der Umwelt (Witterungsbedingungen, Beleuchtungsverhältnisse, Verschmutzungen auf Sensoren...) sind jedoch zentral für die Leistungsfähigkeit der Umfeldsensorik [12 bis 16]. Deswegen muss für den Nachweis der Sicherheit eines automatisierten Fahrsystems und dessen Umfeldwahrnehmung zusätzlich zur funktionalen Sicherheit die Sicherheit der gewünschten Funktionalität (englisch: SOTIF, safety of the intended functionality) betrachtet werden.

Ein SOTIF-Nachweis für das automatisierte Fahren und die Umfeldwahrnehmung ist mit etablierten Testverfahren der Automobilindustrie jedoch nicht direkt möglich [7]. Szenario-basierte Absicherungsmethoden unter Verwendung von detaillierten Testfall-Spezifikationen in Szenariokatalogen haben die Einschränkung, dass eine automatisierte Fahrfunktion eine nahezu unendliche Vielfalt an Situationen und Umfeldausprägungen beherrschen muss [3]. Feldtests im Realverkehr erfordern eine kaum zu bewältigende Anzahl an Testkilometern [1, 2, 4, 16] und

ausreichend realistische und umfassende virtuelle Testmethoden zur alleinigen Anwendung sind derzeit nicht bekannt [2, 17].

Im Kontext dieser Herausforderungen stellen sich zwei zentrale Fragen: Wie können Zuverlässigkeitsziele für die Umfeldwahrnehmung festgelegt werden? Und wie können die gewählten Zuverlässigkeitsziele nachgewiesen werden? Diese Fragestellungen waren Gegenstand eines mehrjährigen Forschungsprojektes. Der vorliegende Beitrag gibt einen kurzen Überblick über die wichtigsten Ergebnisse des Forschungsprojektes basierend auf folgenden Publikationen [7, 16, 18 bis 21].

## **2. Validierung der Sicherheit automatisierter Fahrsysteme**

Für eine Akzeptanz von automatisierten Fahrzeugen durch die Gesellschaft, die Zulassungsbehörden, den Gesetzgeber und auch im Sinne des Reputationsrisikos der Hersteller selbst ist der Nachweis der Systemsicherheit zu führen. Sicherheit ist in der DIN 31000 wie folgt definiert: "Sicherheit ist eine Sachlage, bei der das Risiko nicht größer als das Grenzkrisiko ist." [22]. In der ISO 26262 ist die (allgemeine) Sicherheit im englischen Original: "the absence of unreasonable risk" [11]. Unreasonable risk wird dann definiert als: "risk judged to be unacceptable in a certain context according to valid societal moral concepts" [11]. Aus dieser Definitionen der Sicherheit folgt, dass ein Sicherheitsnachweis dem Nachweis eines akzeptablen (Rest-) Risikos entspricht.

Es ist eine weit verbreitete Ansicht, dass das akzeptable Risiko für automatisierte Fahrzeuge durch das derzeit akzeptierte Risiko des menschlichen Fahrens bestimmt ist [1, 2, 4, 8]. In [7] weisen wir darauf hin, dass weitere Ansätze zur Ableitung von ethisch fundierten Akzeptanzkriterien für technologische Risiken in der Literatur beschrieben werden [23 bis 26] und auch verschiedene kognitive Verzerrungen (engl. cognitive biases) in der öffentlichen Risikowahrnehmung [26 bis 28] in der Diskussion des akzeptablen Risikos beachtet werden sollten.

## 2.1. Die Absicherungsfalle

Es ist bekannt, dass ein akzeptables Risiko für automatisierte Fahrzeuge nicht ohne weiteres empirisch (d.h. induktiv) in Feldtests nachgewiesen werden kann [1, 2, 4, 16]. Für diesen Sachverhalt wurde z.B. in [1] der Begriff der Absicherungsfalle geprägt.

Hier wird die Absicherungsfalle mit einem Bayes'schen Ansatz beispielhaft in Bild 1 dargestellt. Dazu wird rein hypothetisch angenommen, dass das nachzuweisende akzeptable Risiko durch eine fatale Unfallrate von  $\lambda_{\text{TLS}_{\text{sys}}} = 10^{-9} \text{ h}^{-1}$  bestimmt ist. Dieses Nachweisziel gilt zum Beispiel für katastrophale Unfälle in der zivilen Luftfahrt [29].

Die Bild 1 zugrunde liegenden Berechnungen lassen sich zusammenfassen [16]:

- 1.) Wahl eines Poisson Modells für die Anzahl der Unfälle  $x$  im Zeitintervall  $t$  bei gegebener Unfallrate des Systems  $\lambda_{\text{sys}}$ .
- 2.) Bestimmung der a posteriori Verteilung von  $\lambda_{\text{sys}}$  bei gegebener Anzahl an Unfällen  $x$  im Zeitintervall  $t$  mit Bayes'scher Inferenz [30].
- 3.) Die prädiktive Wahrscheinlichkeit  $\Pr(\lambda_{\text{sys}} < \lambda_{\text{TLS}_{\text{sys}}} | x, t)$ , dass das Sicherheitsziel  $\lambda_{\text{TLS}_{\text{sys}}}$  bei gegebenem  $x$  und  $t$  eingehalten wird, aus der a posteriori Verteilung ableiten.
- 4.)  $\lambda_{\text{TLS}_{\text{sys}}} = 10^{-9} \text{ h}^{-1}$  und verschiedene  $x = 1, 2, 3 \dots$  in  $\Pr(\lambda_{\text{sys}} < \lambda_{\text{TLS}_{\text{sys}}} | x, t)$  einsetzen.
- 5.) Es wird gefordert, dass die Wahrscheinlichkeit  $\Pr(\lambda_{\text{sys}} < \lambda_{\text{TLS}_{\text{sys}}} | x, t)$  ein oberes Limit überschreiten muss, beispielsweise  $\Pr(\lambda_{\text{sys}} < \lambda_{\text{TLS}_{\text{sys}}} | x, t) \geq 0.95$ .
- 6.) Für jedes  $x$  nach  $t$  auflösen.

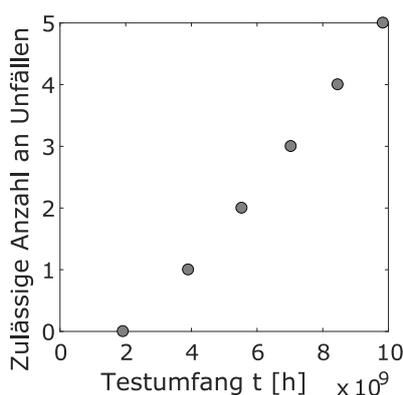


Bild 1: Nach [16] abgeleitete maximale Anzahl an erlaubten Unfällen im notwendigen Testumfang  $t$  für einen empirischen Nachweis einer Unfallrate von  $\lambda_{\text{TLS}_{\text{sys}}} = 10^{-9} \text{ h}^{-1}$ .

Wie in Bild 1 ersichtlich, wird für den empirischen Nachweis von  $\lambda_{\text{TLS}_{\text{sys}}} = 10^{-9} \text{ h}^{-1}$  im besten Fall ein Testumfang von ca.  $2 \cdot 10^9 \text{ h}$  benötigt. In diesem Testumfang darf dann aber kein Systemversagen auftreten, was nur wahrscheinlich ist, wenn die tatsächliche Unfallrate wesentlich kleiner als  $\lambda_{\text{TLS}_{\text{sys}}}$  ist.

## 2.2. Systemzuverlässigkeitstheorie und funktionale Dekomposition

Ein Testumfang wie oben beispielhaft für  $\lambda_{\text{TLS}_{\text{sys}}} = 10^{-9} \text{ h}^{-1}$  abgeleitet ist nicht mit empirischen Methoden zu bewältigen. Das gilt auch für weniger strenge Nachweisziele als  $10^{-9} \text{ h}^{-1}$ , welche noch im Bereich gesellschaftlich akzeptierter Risiken liegen. Daher zeigen wir nachfolgend alternative Strategien zum Sicherheitsnachweis auf, basierend auf [7].

Nachdem ein induktiver (empirischer) Nachweis der Sicherheit auf Ebene des Gesamtsystems kaum möglich ist, kann der Nachweis der Systemsicherheit nur deduktiv unter Einbezug der Zuverlässigkeit der Komponentenebene beziehungsweise der Zuverlässigkeit der Unterfunktionen erfolgen. Zu diesem Zweck wurden die Systemzuverlässigkeitstheorie und Techniken für Gefahrenanalysen entwickelt, welche vielfach in der Luftfahrt, Raumfahrt, dem Bauwesen und der zivilen Nukleartechnik angewandt werden [31 bis 33].

Die Idee ist es, die Zuverlässigkeit des automatisierten Fahrsystems durch die Zuverlässigkeit der Unterfunktionen zu beschreiben (funktionale Dekomposition). Die Zuverlässigkeit wird dann auf der Ebene der Unterfunktionen nachgewiesen. Inspiriert vom klassischen Regelungsparadigma Sense-Plan-Act aus der Robotik lässt sich ein automatisiertes Fahrsystem beispielsweise in einer hohen hierarchischen Ebene durch die Unterfunktionen der Wahrnehmung (Umfeldmodell), die automatisierte Fahrfunktion (Interpretation und Handlungsplanung) und die Aktorik (Umsetzung der Handlungsplanung) beschreiben. Bild 2 zeigt das entsprechende Zuverlässigkeitsblockdiagramm des Systems, das einem Seriensystem mit drei Komponenten entspricht.

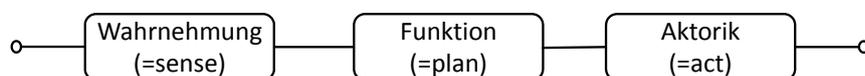


Bild 2: Zuverlässigkeitsblockdiagramm eines automatisierten Fahrsystems. Angepasst von [7].

Das in Bild 2 dargestellte Seriensystem versagt, wenn mindestens eine der Komponenten einen sicherheitskritischen Fehler macht, welcher zu einem Unfall führt. Auf der sicheren Seite liegend, lässt sich die Fehlerrate des Seriensystems über die sicherheitskritischen Fehlerraten der Komponenten / Unterfunktionen beschreiben [34, 35]:

$$\lambda_{\text{sys}} \approx \lambda_{\text{Wahr.}} + \lambda_{\text{Funktion}} + \lambda_{\text{Aktorik}} \quad (1)$$

Die Systemfehlerrate ist also approximiert durch die Summe der sicherheitskritischen Fehlerraten der Wahrnehmung  $\lambda_{\text{Wahr.}}$ , der Funktion  $\lambda_{\text{Funktion}}$  und der Aktorik  $\lambda_{\text{Aktorik}}$ .

Im Folgenden wird nur  $\lambda_{\text{Wahr.}}$  weiter betrachtet. Dazu wird die Funktionalität der Wahrnehmung in weitere Unterfunktionen unterteilt. Eine erste Ausgangsbasis dafür stellt das generische Funktionsblockdiagramm der Wahrnehmung in Bild 3 dar. Das Ziel dieser Beschreibung ist, es die Zuverlässigkeit der Umfeldwahrnehmung auf Ebene der Einzelsensoren nachzuweisen. Wie in Bild 3 gezeigt, wird das Umfeld von einer Reihe potentiell redundanter Sensoren mit überlappenden Sichtbereichen erfasst [9]. Die Wahrnehmung der Einzelsensoren wird dann gewöhnlich durch die Sensordatenfusion mithilfe von geeigneten Assoziations- und Trackingalgorithmen in ein zentrales Umfeldmodell überführt [36 bis 38]. Es wird hier angenommen, dass ein Voting (k-aus-n) auf Basis der Einzelsensoren dazu dient, einen Track zu validieren [5, 16, 19, 39]. Bei  $n = 3$  redundanten Sensoren mit überlappendem Sichtbereich wäre ein mögliches Voting, dass mindestens 2-aus-3 Sensoren einen Track bestätigen müssen, damit der Track an die Handlungsplanung der automatisierten Fahrfunktion weitergegeben wird.

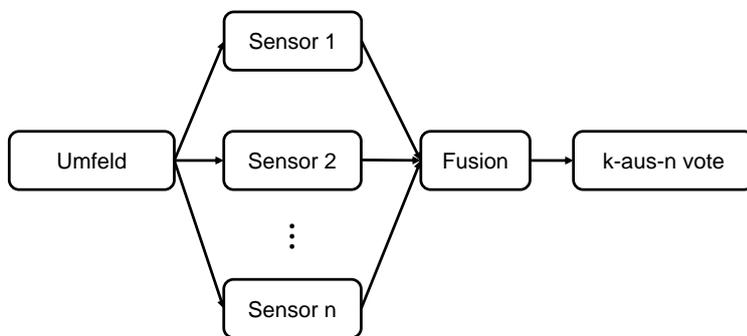


Bild 3: Generisches Funktionsblockdiagramm für die Umfeldwahrnehmung eines automatisierten Fahrsystems. Angepasst von [7].

### **2.3. Herausforderungen bei der Absicherung der Umfeldwahrnehmung**

Die Bedeutung und Notwendigkeit der Bestimmung der Zuverlässigkeit der Umfeldwahrnehmung wird in Abschnitt 2.2 deutlich. Bei der Absicherung der Umfeldwahrnehmung gibt es jedoch eine Reihe an Herausforderungen [7]:

- Die Absicherungsfalle gilt auch für  $\lambda_{\text{Wahr.}}$  der Umfeldwahrnehmung.
- Die konkrete Definition von Wahrnehmungsfehlern ist nicht trivial.
- Die Erhebung einer Referenzwahrheit (Ground Truth) zur Identifikation von Wahrnehmungsfehlern ist aufwändig.
- Die Wahrnehmungsperformance der Sensoren ist abhängig von den Umgebungsbedingungen.
- Wahrnehmungsfehler in verschiedenen Sensoren sind korreliert.
- Systemänderungen haben einen Einfluss auf  $\lambda_{\text{Wahr.}}$ .

Die genannten Herausforderungen werden in [7] im Detail diskutiert.

## **3. Die Zuverlässigkeit der Umfeldwahrnehmung am Beispiel der Existenzunsicherheit**

Auf Basis der funktionalen Dekomposition und der Beschreibung der Umfeldwahrnehmung in Abschnitt 2.2 wird hier ein Ansatz zur Ableitung von Zuverlässigkeitsanforderungen an die Einzelsensoren vorgestellt. Im Speziellen wird dabei die Existenzunsicherheit bei Sensoren betrachtet, d.h. die Unsicherheit darüber, ob existierende Objekte auch wirklich detektiert werden oder ob nicht existierende Geisterobjekte von den Sensoren angezeigt werden [40].

### **3.1. Sicherheitsrelevante Wahrnehmungsfehler**

Zu den Wahrnehmungsfehlern mit der größten Sicherheitsrelevanz gehören false-negative (FN) und false-positive (FP) Fehler [5, 38]. Das ist intuitiv verständlich, da zum Beispiel ein FN Fehler ein nicht erkanntes Hindernis sein kann, oder ein FP Fehler eine Notbremsung auslösen kann. Diese Fehler treten in der Domäne der Existenzunsicherheiten auf und werden hier auf der Ebene des objektbasierten Umfeldmodells betrachtet (Objektlisten) [40, 41].

Die Performance der Umfeldwahrnehmung hinsichtlich der Existenzunsicherheit lässt sich über die Signalentdeckungstheorie beschreiben [42 bis 44]. Im Rahmen der Signalentdeckungstheorie lässt sich die Performance der Wahrnehmung konkret über die Probability of Detection (POD) und Probability of False Alarm (PFA) beschreiben [7, 18, 42 bis 44]. Die POD ist die konditionale true-positive (TP) Wahrscheinlichkeit:

$$\text{POD} = \Pr(D = 1 | \text{Obj} = 1) \quad (2)$$

Wobei  $D = 1$  bedeutet, dass die Wahrnehmung ein Objekt anzeigt und  $\text{Obj} = 1$  bedeutet, dass ein reales Objekt existiert. Die PFA ist die konditionale FP Wahrscheinlichkeit:

$$\text{PFA} = \Pr(D = 1 | \text{Obj} = 0) \quad (3)$$

$\text{Obj} = 0$  bedeutet entsprechend, dass kein reales Objekt existiert.

Diesen Wahrscheinlichkeiten liegt eine binäre Objektdefinition zugrunde (entweder ein Objekt existiert oder nicht, und entweder ein Objekt wird angezeigt oder nicht). Da in einem Umfeldmodell aber mehrere Objekte vorkommen, muss zunächst eine binäre Interpretation der Objektdetektion gefunden werden, um die Performance der Objektdetektion auch durch die POD und PFA beschreiben zu können. Eine einfache Möglichkeit ist es, einen eingeschränkten Bereich im Umfeld zu betrachten. In diesem eingeschränkten Bereich existiert dann entweder mindestens ein oder kein reales Objekt. Die POD und die PFA können durch sensorinterne Detektionsschwellen variiert werden, was zu einer Receiver Operating (ROC) Characteristic Kurve führt [42 bis 44].

Da es sich bei der POD und PFA um Wahrscheinlichkeiten von diskreten Ereignissen handelt, die nicht direkt im Bezug zur kontinuierlichen Zeit stehen, wird eine Beziehung zur FP Fehlerrate  $\lambda_{\text{FP}}$  und zur FN Fehlerrate  $\lambda_{\text{FN}}$  hergestellt [7]:

$$\lambda_{\text{FP}} = \text{PFA} \cdot \Pr(\text{Obj} = 0) \cdot \frac{1}{\Delta t} \quad (4)$$

wobei  $\Pr(\text{Obj} = 0)$  die Wahrscheinlichkeit ist, dass zu einem beliebigen Zeitpunkt kein reales Objekt im relevanten Bereich des Umfeldmodells vorhanden ist. Während die PFA als Wahrscheinlichkeit einheitslos ist, hat  $\lambda_{\text{FP}}$  die Einheit [1/h].  $\Delta t$  in Gleichung 4 entspricht dem Zeitintervall eines diskreten Zeitschrittes. In erster Näherung kann  $\Delta t$  durch die gewählte Multi-Zyklus Validierungsheuristik (siehe [9, 38, 40]) motiviert sein. Nach dieser Heuristik muss eine Objektdetektion mehrere Messzyklen hintereinander auftreten, um als valide zu gelten. D.h. nur die Fehler, welche länger als die gewählte Multi-Zyklus Validierungszeit auftreten, können sicherheitsrelevant werden. Wenn ein Objekt beispielsweise drei Messzyklen hintereinander detektiert werden muss, um als valide zu gelten, dann entspricht  $\Delta t$  der dreifachen Zykluszeit. Eine detailliertere Betrachtung der zeitlichen Aspekte sprengt den Rahmen dieses Beitrages.

Analog gilt für  $\lambda_{\text{FN}}$  [7]:

$$\lambda_{\text{FN}} = (1 - \text{POD}) \cdot \Pr(\text{Obj} = 1) \cdot \frac{1}{\Delta t} \quad (5)$$

### 3.2. Anforderungen an die Wahrnehmungszuverlässigkeit

Abschnitt 3.1 gibt einen formalen Rahmen für die Beschreibung der Wahrnehmungszuverlässigkeit in der Existenzunsicherheitsdomäne auf Ebene des fusionierten Umfeldmodells vor. Die Metriken aus Abschnitt 3.1 sind aber ohne Einschränkungen auch auf die objektbasierten Umfeldmodelle der Einzelsensoren anwendbar. Beispielsweise bezeichnen  $\text{POD}_i$  und  $\text{PFA}_i$  die jeweiligen Metriken für Sensor  $i$ .

Mithilfe des k-aus-n Votings (siehe Bild 3) wird in diesem Kapitel ein Zusammenhang zwischen der Zuverlässigkeit der Einzelsensoren und der Wahrnehmungszuverlässigkeit des fusionierten Umfeldmodells hergestellt. Dabei werden hier Unzulänglichkeiten der Fusion wie zum Beispiel fehlerhafte Objekt-zu-Track Zuordnungen nicht explizit berücksichtigt. Implizit berücksichtigt das folgende Vorgehen aber teilweise auch Fehler in der Fusion, da je nach Definition bzw. Interpretation der Wahrnehmungsfehler beispielsweise ein FN Fehler auf Einzelsensorebene auch über eine fehlerhafte Assoziation in der Fusion auftreten kann. Des Weiteren wird von einer objektbasierten dezentralen Sensordatenfusion [36] ausgegangen.

Wie bereits in Abschnitt 2.2 beschrieben, wird hier angenommen, dass ein Track bzw. eine Objektdetektion im fusionierten Umfeldmodell nur dann an die nachfolgende Handlungsplanung der automatisierten Fahrfunktion weitergegeben wird, wenn mindestens k-aus-n Einzelsensoren die Objektdetektion bestätigen. Nach dieser Logik tritt ein FP Fehler am Ausgang der Fusion dann auf, wenn mindestens  $k$  der Sensoren den FP Fehler machen. Ein FN Fehler tritt mit dieser Logik dann auf, wenn mindestens  $n - k + 1$  Sensoren den Fehler machen. Außerdem muss z.B. ein FP Fehler in mehreren Einzelsensoren natürlich auch an einer ähnlichen Position auftreten, damit die FP Fehler der Einzelsensoren auch miteinander assoziiert werden und damit das k-aus-n Voting passieren. Diese räumlichen Aspekte werden hier nicht weiter betrachtet.

Da das Ziel hier die Ableitung von Zuverlässigkeitsanforderungen ist, wird jedem Einzelsensor die gleiche Zielfehlerrate zugewiesen. D.h. alle Einzelsensoren  $i = 1, \dots, n$  erhalten einen identischen Zielwert  $\text{POD}_i = \text{POD}_{\text{sensor}}$  und  $\text{PFA}_i = \text{PFA}_{\text{sensor}}$ , welche nach Gleichungen 4 und 5 in kontinuierliche Fehlerraten überführt werden können. Um in diesem Zusammenhang die statistische

Abhängigkeit der Wahrnehmungsfehler in verschiedenen Einzelsensoren zu berücksichtigen, modellieren wir das Auftreten der Wahrnehmungsfehler mit dem Beta-Binomialmodell [7, 16, 19]:

$$\Pr(K = k) = \binom{n}{k} \frac{\Gamma(\alpha + \beta) \cdot \Gamma(\alpha + k) \cdot \Gamma(\beta + n - k)}{\Gamma(\alpha) \cdot \Gamma(\beta) \cdot \Gamma(\alpha + \beta + n)} \quad (6)$$

$\Pr(K = k)$  ist die Wahrscheinlichkeit, dass genau  $k$ -aus- $n$  Sensoren eine Detektion anzeigen.  $\alpha$  und  $\beta$  sind die Modellparameter und  $\Gamma(a) = \int_0^\infty u^{a-1} \cdot \exp(-u) du$  ist die Gamma Funktion. Die Modellparameter sind definiert als:

$$\alpha = \frac{p \cdot (1-\rho)}{\rho}, \beta = \frac{(1-p) \cdot (1-\rho)}{\rho} \quad (7)$$

Je nachdem ob FN oder FP Fehler betrachtet werden, entspricht  $p$  entweder  $\text{POD}_{\text{sensor}}$  oder  $\text{PFA}_{\text{sensor}}$ .  $\rho$  ist der Korrelationskoeffizient von FP oder FN Fehlern in den Einzelsensoren. Beispielsweise ist  $\rho_{\text{FP}}$  definiert als:

$$\rho_{\text{FP}} = \frac{\Pr(D_i=1|D_j=1, Obj=0) \cdot \text{PFA}_i - \text{PFA}_i^2}{\text{PFA}_i - \text{PFA}_i^2} \approx \Pr(D_i = 1 | D_j = 1, Obj = 0) \quad (8)$$

Näherungsweise gilt für  $\text{PFA}_i^2 \ll \text{PFA}_i$ , dass  $\rho_{\text{FP}}$  der konditionalen Wahrscheinlichkeit  $\Pr(D_i = 1 | D_j = 1, Obj = 0)$  eines FP Fehlers in Sensor  $i$  gegeben eines FP Fehlers in Sensor  $j$  entspricht.  $\rho_{\text{FN}}$  ist analog definiert. Im Falle von statistischer Unabhängigkeit ist  $\rho = 0$ . Dann entspricht Gleichung 6 dem Binomialmodell.

Die PFA auf Ebene des fusionierten Umfeldmodells ergibt sich dann aus der  $\text{PFA}_{\text{sensor}}$  des Einzelsensors und Gleichungen 6-7:

$$\text{PFA} = \sum_{i=k}^n \Pr(K = k | p = \text{PFA}_{\text{sensor}}, \rho_{\text{FP}}) \quad (9)$$

Analog gilt:

$$\text{POD} = \sum_{i=k}^n \Pr(K = k | p = \text{POD}_{\text{sensor}}, \rho_{\text{FN}}) \quad (10)$$

Um die Anforderungen an die Sensoren abzuleiten, muss beispielsweise  $\text{POD}_{\text{sensor}}$  aus  $\text{POD}$  bestimmt werden. D.h.  $\text{POD}_{\text{sensor}}$  wird mit einer inversen Berechnung aus Gleichung (10) bestimmt. Der Zusammenhang zur Fehlerrate ist durch Gleichung (5) gegeben.

### 3.3. Numerisches Beispiel

Es wird ein hypothetisches Nachweisziel für FP und FN Fehler von  $\lambda_{\text{TLS}_{\text{FP}}} = \lambda_{\text{TLS}_{\text{FN}}} = 10^{-9} \text{ h}^{-1}$  angenommen.  $\lambda_{\text{TLS}_{\text{FP}}}$  und  $\lambda_{\text{TLS}_{\text{FN}}}$  werden mit Gleichungen 4 und 5 in Zuverlässigkeitsanforderungen für PFA und POD auf Ebene des Umfeldmodells überführt. In diesen Umrechnungen wird von  $\Delta t = 0.5 \text{ s}$  ausgegangen. Vereinfachend und auf der sicheren Seite liegend wird dabei  $\text{Pr}(Obj = 0)$  und  $\text{Pr}(Obj = 1)$  in den Gleichungen 4 und 5 zu eins gesetzt. Anschließend werden die korrespondierenden Nachweisziele  $\text{PFA}_{\text{sensor}}$  und  $\text{POD}_{\text{sensor}}$  für die Einzelsensoren mit Gleichungen 9-10 abgeleitet und mit Gleichungen 4 und 5 wieder in Fehlerraten überführt. Das Ergebnis ist für verschiedene Werte des Korrelationskoeffizienten  $\rho$  und verschiedene Voting Mechanismen (das  $k$  in  $k$ -aus- $n$  variiert) in Bild 4 dargestellt. Bild 4a) zeigt ein System mit  $n = 3$  redundanten und Bild 4b) mit  $n = 5$  redundanten Sensoren.

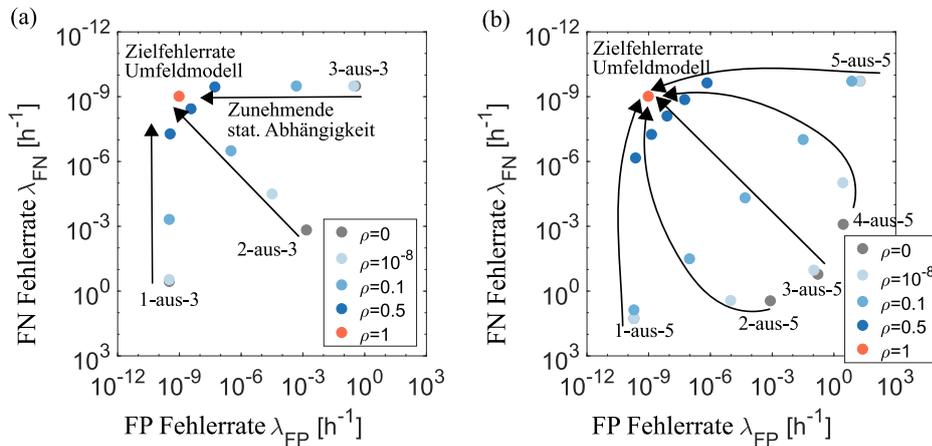


Bild 4: Zuverlässigkeitsanforderungen der Einzelsensoren unter verschiedenen  $k$ -aus- $n$  Voting Mechanismen um eine Zielfehlerrate von  $\lambda_{\text{TLS}_{\text{FP}}} = \lambda_{\text{TLS}_{\text{FN}}} = 10^{-9} \text{ h}^{-1}$  im Umfeldmodell zu erreichen. In (a) besteht das System aus  $n = 3$  und in (b) aus  $n = 5$  Einzelsensoren.  $\lambda_{\text{TLS}_{\text{FP}}} = \lambda_{\text{TLS}_{\text{FN}}} = 10^{-9} \text{ h}^{-1}$  entspricht dem Nachweisziel für das Umfeldmodell am Ausgang der Fusion. Die Punkte stellen die Anforderungen an die Einzelsensoren für verschiedene Werte von  $\rho$  dar. Je größer die statistische Abhängigkeit der Fehler in den Einzelsensoren, desto strenger sind die Anforderungen an die Einzelsensoren.

Unter der Annahme der statistischen Unabhängigkeit der Fehler in den Einzelsensoren, mit dreifacher Sensorredundanz ( $n = 3$ ) und einem 2-aus-3 Voting ergeben sich nach den Berechnungen in Bild 4 sowohl für FP als FN Fehler eine Anforderung an die Einzelsensoren von ca.  $\approx 1.5 \cdot 10^{-3} \text{ h}^{-1}$ . Dieses Nachweisziel lässt sich mit einem Testumfang in der Größenordnung von 1000 h empirisch nachweisen. Diese Größenordnung ist im Verhältnis zu dem Testumfang aus Abschnitt 2.1 auf Systemebene zu sehen. Wie gezeigt, kann durch die funktionale Dekomposition einer modularen Systemarchitektur

(deduktive Systembetrachtung) der Nachweis der Systemsicherheit empirisch (induktiv) auf Basis der Unterfunktionen / Komponenten nun erfolgen.

Selbstverständlich ist dabei jedoch die Annahme der statistischen Unabhängigkeit der Fehler in den Einzelsensoren zu hinterfragen. Selbst wenn die Annahme der statistischen Unabhängigkeit zwischen Einzelsensoren nicht gerechtfertigt ist, sollte für Sensoren mit unterschiedlichen physikalischen Messprinzipien (Radar, Kamera, Lidar) zumindest nur eine schwache statistische Abhängigkeit gelten. Das würde immer noch zu einer deutlichen Reduktion des Nachweisziels auf Einzelsensorebene verglichen mit dem Gesamtsystem führen. Unter vollständiger statistischer Abhängigkeit der Fehler in den verschiedenen Sensoren entspricht das Nachweisziel der Einzelsensoren dem Nachweisziel des Gesamtsystems (orange Punkt in Bild 4). Es wird darauf hingewiesen, dass das Beta-Binomialmodell außerdem nicht in der Lage ist gewisse extreme Arten der statistischen Abhängigkeit explizit zu berücksichtigen.

Eine weitere wesentliche Voraussetzung für die Berechnungen in Bild 4 ist die Sensorredundanz. Die Sensorredundanz kann jedoch in gewissen Situationen eingeschränkt sein, beispielsweise könnte eine Kamera in der Nacht oder ein Lidar aufgrund von Verschmutzungen auf dem Sensor zeitweise eine systematisch zu schwache Leistungsfähigkeit aufweisen. Dann muss entweder die Verfügbarkeit der automatisierten Fahrfunktion eingeschränkt werden, die systematischen Effekte mit Sicherheitsmechanismen abgeschwächt werden (z.B. Beleuchtung und Reinigung) oder die Berechnungen in Bild 4 entsprechend angepasst werden (Bsp. 80% der Zeit kann von  $n = 3$  ausgegangen werden und 20% der Zeit nur von  $n = 2$ ).

#### **4. Bestimmung der Wahrnehmungszuverlässigkeit**

Während Abschnitt 2 und 3 beschreiben, wie Zuverlässigkeitsanforderungen für die Wahrnehmung und der zugehörige Testumfang abgeleitet werden können, geht es in diesem Abschnitt um die Bestimmung der Wahrnehmungszuverlässigkeit. Zur Bestimmung der Wahrnehmungszuverlässigkeit lassen sich grob folgende Methoden unterscheiden, jede mit unterschiedlichen Vor- und Nachteilen:

- Qualitative und semi-quantitative Analyse Methoden
- Tests auf dem Prüfgelände
- Virtuelle Simulationen
- Feldtests durch Realfahrten

#### **4.1. Kurzübersicht**

Qualitative und semi-quantitative Methoden sind zum Beispiel eine Gefahrenanalyse, eine Ereignisbaumanalyse (ETA), eine Fehlerbaumanalyse (FTA), Fehlermöglichkeits- und -einflussanalyse (FMEA) [31]. Diese Methoden werden meist zu Beginn der Entwicklung eines technischen Systems angewandt, um Gefahren, Fehler und Versagensquellen zu identifizieren und um das Risiko des Systems initial abzuschätzen. Ein Vorteil ist, dass damit ein tiefes Verständnis über das System aus der Sicherheitsperspektive bereits früh in der Entwicklung erlangt wird, Versagensquellen identifiziert werden und Sicherheitsmaßnahmen definiert werden können. Ein klarer Nachteil ist jedoch, dass quantitative Abschätzungen in diesem Stadium nicht vollumfänglich aussagekräftig sind, da diese meist auf Expertenwissen beruhen und nicht aus Daten abgeleitet werden.

In [18] haben wir eine Methode vorgestellt, um über kontrollierte Tests auf dem Prüfgelände statistisch fundierte Aussagen über die Wahrnehmungszuverlässigkeit zu treffen. Dabei wird die Abhängigkeit der Wahrnehmungsperformance von Einflussfaktoren der Umgebung (Niederschlag, Temperatur, Beleuchtungsverhältnisse...) gelernt. Eine Verknüpfung der Wahrscheinlichkeit der Einflussfaktoren mit der Wahrnehmungsperformance führt zu einem reduzierten Testaufwand verglichen mit Realfahrten. Ein Vorteil dieser Methode ist es, dass die Tests zu einem gewissen Grad reproduzierbar sind. Ein Nachteil ist, dass (ebenfalls zu einem gewissen Grad) die wesentlichen Einflussfaktoren der Wahrnehmungsperformance (Schneefall, Gischt, Beleuchtungsverhältnisse...) bereits bekannt und messbar sein müssen. Aufgrund der Komplexität können Interaktionen zwischen den Einzelfaktoren nur begrenzt berücksichtigt werden.

Eine weitere Möglichkeit zur Abschätzung der Wahrnehmungszuverlässigkeit sind virtuelle Simulationen [2, 17]. Der Vorteil von Simulationen ist, dass in der virtuellen Umgebung eine große Anzahl an Kilometern mit vergleichsweise geringem Aufwand getestet werden können. Die Schwierigkeit ist es jedoch, sicherzustellen, dass die relevanten Effekte mit Einfluss auf die Performance der Umfeldwahrnehmung auch realitätsnah in der Simulation modelliert werden. Zum einen muss dafür a priori bekannt sein, welche Effekte relevant sind, zum anderen muss die Validität der Simulation nachgewiesen werden. Beides ist herausfordernd und es existiert derzeit keine umfassende Simulationsmethode zur Absicherung der Umfeldwahrnehmung.

Die realistischste Methode zur Abschätzung der Wahrnehmungszuverlässigkeit sind Feldtests durch Realfahrten [2, 17]. Diese berücksichtigen automatisch Faktoren mit Einfluss auf die Wahrnehmungsperformance durch die Situationsvielfalt im regulären Straßenverkehr, unter der Bedingung, dass die Tests repräsentativ sind. Eine Herausforderung ist jedoch die Erstellung einer

Referenzwahrheit (ground truth) im Realverkehr in Kombination mit dem hohen erforderlichen Testumfang. Hierfür wird zum einen eine Referenzsensorik mit sehr hoher Performance benötigt und zum anderen teilweise auf manuelles Labeln der Daten zurückgegriffen. Es stellt sich daher die Frage, ob nicht auch Aspekte der Wahrnehmungszuverlässigkeit unter Ausnutzung der Redundanz der Seriensensoren ohne eine Referenzsensorik gelernt werden können. Diese Fragestellung haben wir in [19] detailliert untersucht. Solange das zugrunde liegende statistische Abhängigkeitsmodell für Wahrnehmungsfehler in verschiedenen Sensoren adäquat ist, kann die korrekte Wahrnehmungszuverlässigkeit auch ohne Referenzwahrheit gelernt werden [19].

#### 4.2. Bestimmung der Wahrnehmungszuverlässigkeit ohne Referenzwahrheit durch Flottendaten

Das Konzept zum Lernen der Wahrnehmungszuverlässigkeit ohne Referenzwahrheit aus [19] haben wir in [21] weiterentwickelt. Hier präsentieren wir eine kurze Zusammenfassung dieses Konzeptes, welches zum Ziel hat, die Wahrnehmungszuverlässigkeit aus Flottendaten abzuschätzen.

Dem Lernen ohne Referenz liegt ein statistisches Modell für die gemeinsame Wahrscheinlichkeit der unbekanntenen Wahrheit und der durch die Sensoren angezeigten Detektionen zugrunde. Die Struktur dieses statistischen Modells ist in Bild 5 durch ein Bayes'sches Netzwerk dargestellt.

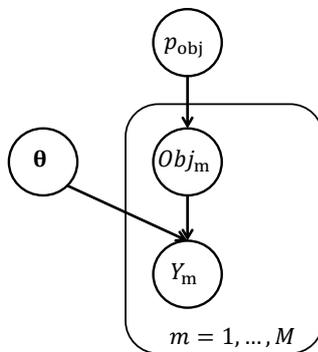


Bild 5: Struktur des statistischen Modells zum Lernen der Sensorfehlerraten ohne Referenz, dargestellt als Bayes'sches Netzwerk. Aus [21].

$p_{obj}$  ist die mittlere Wahrscheinlichkeit, dass in einem bestimmten Bereich des Umfelds mindestens ein Objekt vorhanden ist.  $Obj_m$  ist eine Indikatorvariable, die anzeigt ob zum diskreten Zeitpunkt  $m$  ein Objekt vorhanden ist oder nicht. Ohne Referenzwahrheit ist der Zustand von  $Obj_m$  unbekannt, mit Referenzwahrheit ist der Zustand von  $Obj_m$  bekannt. Die Modellparameter  $\theta$  beinhalten beispielsweise die  $POD_i$  und  $PFA_i$  aller Sensoren und zusätzliche Parameter für die Modellierung der statistischen Abhängigkeit der Sensorfehler.  $Y_m$  ist die beobachtbare Variable für jeden Zeitpunkt  $m$  und identifiziert eine spezifische Kombination an Detektionen in den verschiedenen Sensoren. Bei  $n$  redundanten

Sensoren gibt es im binären Fall  $2^n$  Kombinationen an Detektionen durch die verschiedenen Sensoren, welche den Ereignisraum von  $Y_m$  beschreiben.

Die Likelihood der Modellparameter  $\theta$  ergibt sich dann aus der Mischverteilung von  $Y_m$  hinsichtlich  $Obj_m$ . Über die Likelihood können mit gängigen statistischen Lernverfahren wie zum Beispiel der Bayes'schen Parameterschätzung [30] die Modellparameter  $\theta$  gelernt werden. Auch hier gilt, solange das statistische Modell die Abhängigkeitsstruktur des Problems angemessen beschreibt, werden die korrekten  $POD_i$  und  $PFA_i$  der Sensoren gelernt. Bild 6 zeigt beispielhaft Ergebnisse dieser Methodik in einem numerischen Experiment [21].

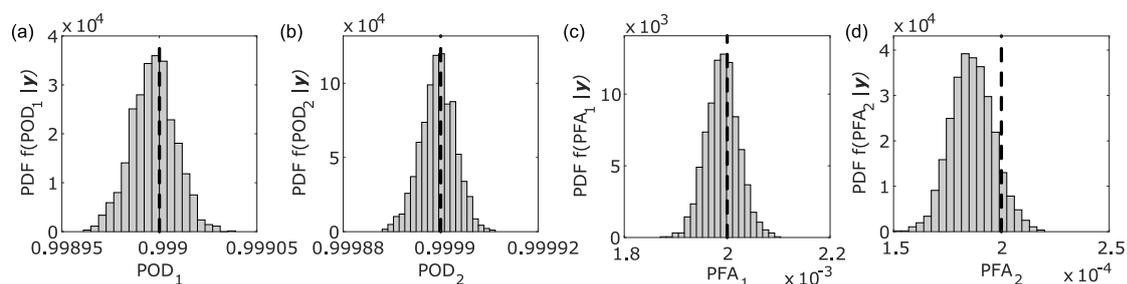


Bild 6: Beispielhafte Ergebnisse des Lernverfahrens ohne Referenz. Die Histogramme approximieren die a posteriori Verteilung der  $POD_i$  und  $PFA_i$  von Sensoren 1 und 2. Die gestrichelten Linien stellen die zugrunde liegende virtuelle Wahrheit dar. Aus [21].

## 5. Zusammenfassung und Ausblick

Dieser Beitrag stellt die Problemstellung und Lösungsansätze zur Absicherung der Umfeldwahrnehmung vor. Wir zeigen, wie Anforderungen an die Wahrnehmungszuverlässigkeit abgeleitet werden können und geben einen kurzen Überblick über Methoden zur Bestimmung der Wahrnehmungszuverlässigkeit.

Speziell haben wir am Beispiel der Umfeldwahrnehmung einen Lösungsweg aufgezeigt, mit dem die Absicherungsfalle für automatisierte Fahrsysteme überwunden werden kann. Diese Lösung bedient sich bekannter Methoden der Systemzuverlässigkeitstheorie. Der Ansatz ist es, die Zuverlässigkeit des Gesamtsystems durch die Zuverlässigkeit der Unterfunktionalitäten bzw. Systemkomponenten zu beschreiben. Aufgrund von Redundanzen auf der Komponentenebene lässt sich die Systemzuverlässigkeit durch einen beherrschbaren Aufwand empirisch auf der Komponentenebene nachweisen. Zentral hierbei ist es jedoch auch, statistische Abhängigkeiten zu berücksichtigen. Zukünftige Forschungsarbeit sollte daher die statistische Abhängigkeit von Wahrnehmungsfehlern in verschiedenen Sensortechnologien (z.B. Radar, Kamera, Lidar) genauer untersuchen. Außerdem sollte der Einfluss der Sensordatenfusion auf die Wahrnehmungszuverlässigkeit näher betrachtet werden und

die hier diskutierten Modelle sollten erweitert werden, um Fehlerquellen der Sensordatenfusion explizit zu berücksichtigen.

Des Weiteren haben wir einen Ansatz zusammengefasst, der es erlaubt, Aspekte der Wahrnehmungszuverlässigkeit ohne Referenzwahrheit unter Ausnutzung von Sensorredundanzen zu lernen. Dieser Ansatz ermöglicht es, die Wahrnehmungszuverlässigkeit aus Flottendaten zu lernen, wodurch mit relativ geringem Aufwand eine sehr hohe Situationsvielfalt erreicht wird. Eine wichtige Voraussetzung für diesen Ansatz ist ein adäquates statistisches Abhängigkeitsmodell für Wahrnehmungsfehler in verschiedenen Sensoren. Zukünftige Forschungsarbeit sollte sich daher zusätzlich der Abhängigkeitsstruktur von Wahrnehmungsfehlern in verschiedenen Sensortechnologien widmen.

#### Literaturangaben

- [1] Winner, H.: ADAS, Quo Vadis? In: Winner, H., Hakuli, S., Lotz, F. u. Singer, C. (Hrsg.): Handbook of Driver Assistance Systems. Cham: Springer International Publishing 2016, S. 1557–1584
- [2] Wachenfeld, W. u. Winner, H.: The Release of Autonomous Vehicles. In: Maurer, M., Gerdes, J. C., Lenz, B. u. Winner, H. (Hrsg.): Autonomous Driving. Berlin, Heidelberg: Springer Berlin Heidelberg 2016, S. 425–449
- [3] Weitzel, A., Winner, H., Peng, C., Geyer, S., Lotz, F. u. Sefati, M.: Absicherungsstrategien für Fahrerassistenzsysteme mit Umfeldwahrnehmung. [Bericht zum Forschungsprojekt FE 82.0546/2012]. Berichte der Bundesanstalt für Straßenwesen Fahrzeugtechnik, Bd. 98. Bremen: Fachverl. NW 2014
- [4] Kalra, N. u. 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 94 (2016), S. 182–193
- [5] Shalev-Shwartz, S., Shammah, S. u. Shashua, A.: On a Formal Model of Safe and Scalable Self-driving Cars. arXiv preprint arXiv:1708.06374 (2017)
- [6] Deutscher Bundestag: Produkthaftungsgesetz. 1989
- [7] Berk, M., Schubert, O., Kroll, H.-M., Buschardt, B. u. Straub, D.: Automotive environment perception: Safety analysis for automated driving vehicles. In Bearbeitung (2018)
- [8] Automatisiertes und vernetztes Fahren. Eingesetzt durch den Bundesminister für Verkehr und digitale Infrastruktur, Ethik-Kommission, 2017
- [9] Winner, H., Hakuli, S., Lotz, F. u. Singer, C. (Hrsg.): Handbook of Driver Assistance Systems. Cham: Springer International Publishing 2016

- [10] Weitzel, A.: Objektive Bewertung der Kontrollierbarkeit nicht situationsgerechter Reaktionen umfeldsensorbasierter Fahrerassistenzsysteme, Technischen Universität Darmstadt Dissertation. Darmstadt 2013
- [11] Norm ISO 26262-1:2011(E); 2011. Road vehicles — Functional safety — Part 1: Vocabulary
- [12] Rasshofer, R. H., Spies, M. u. Spies, H.: Influences of weather phenomena on automotive laser radar systems. *Advances in Radio Science* 9 (2011), S. 49–60
- [13] Rivero, J. R. V., Tahiraj, I., Schubert, O., Glassl, C., Buschardt, B., Berk, M. u. Chen, J.: Characterization and simulation of the effect of road dirt on the performance of a laser scanner. 2017 IEEE 20th International Conference on Intelligent Transportation Systems (ITSC). 2017, S. 1–6
- [14] Blevis, B.: Losses due to rain on radomes and antenna reflecting surfaces. *IEEE Transactions on Antennas and Propagation* 13 (1965) 1, S. 175–176
- [15] Ishimaru, A.: Wave propagation and scattering in random media and rough surfaces. *Proceedings of the IEEE* 79 (1991) 10, S. 1359–1366
- [16] Berk, M., Kroll, H.-M., Schubert, O., Buschardt, B. u. Straub, D.: Bayesian Test Design for Reliability Assessments of Safety-Relevant Environment Sensors Considering Dependent Failures. SAE Technical Paper. SAE International 2017
- [17] Wachenfeld, W. u. Winner, H.: The New Role of Road Testing for the Safety Validation of Automated Vehicles. In: Watzenig, D. u. Horn, M. (Hrsg.): *Automated Driving: Safer and More Efficient Future Driving*. Cham: Springer International Publishing 2017, S. 419–435
- [18] Berk, M., Kroll, H.-M., Schubert, O., Buschardt, B. u. Straub, D.: Zuverlässigkeitsanalyse umfelderfassender Sensorik. Eine stochastische Methodik zur Berücksichtigung von Umgebungseinflüssen am Beispiel von LiDAR Sensoren. *Fahrerassistenz und automatisiertes Fahren*. 32. VDI-VW-Gemeinschaftstagung. VDI-Berichte, Bd. 2288. Düsseldorf: VDI Verlag GmbH 2016, S. 455–475
- [19] Berk, M., Schubert, O., Kroll, H.-M., Buschardt, B. u. Straub, D.: Reliability assessment of safety-critical sensor information: Does one need a reference truth? Eingereicht in *IEEE Transactions on Reliability* (2017)
- [20] Berk, M., Dura, M., Vargas Rivero, J. R., Schubert, O., Kroll, H.-M., Buschardt, B. u. Straub, D.: A Stochastic Physical Simulation Framework to Quantify the Effect of Rainfall on Automotive Lidar. In: Eingereicht in *WCX SAE World Congress Experience 2019*
- [21] Berk, M., Schubert, O., Kroll, H.-M., Buschardt, B. u. Straub, D.: Reliability Assessment of Safety-Critical Sensor Information in Automated Driving Vehicles through Fleet Learning. In *Bearbeitung* (2018)
- [22] Norm DIN 31000:2011-05. General principles for the safe design of products

- [23] Starr, C.: Social Benefit versus Technological Risk. *Science* 165 (1969) 3899, S. 1232–1238
- [24] Foundations and fallacies of risk acceptance criteria. ROSS (NTNU) 201001, Johansen, I. L., Trondheim 2010
- [25] Häring, I.: Risk Acceptance Criteria. In: Häring, I. (Hrsg.): *Risk Analysis and Management: Engineering Resilience*. Singapore: Springer Singapore 2015, S. 313–342
- [26] Fischhoff, B., Slovic, P., Lichtenstein, S., Read, S. u. Combs, B.: How safe is safe enough? A psychometric study of attitudes towards technological risks and benefits. *Policy Sciences* 9 (1978) 2, S. 127–152
- [27] Slovic, P.: Perception of risk. *Science* 236 (1987) 4799, S. 280–285
- [28] Tversky, A. u. Kahneman, D.: Judgment under Uncertainty. Heuristics and Biases. *Science* 185 (1974) 4157, S. 1124–1131
- [29] AC 25.1309-1A. System Design and Analysis, Federal Aviation Administration, 1988
- [30] Gelman, A.: *Bayesian data analysis*. Texts in statistical science. Boca Raton Fla. u.a.: CRC Press 2014
- [31] Ericson, C. A.: *Hazard analysis techniques for system safety*. Hoboken, New Jersey: Wiley 2005
- [32] Lyu, M. R.: *Handbook of software reliability engineering*. Computing McGraw Hill. New York: McGraw Hill 1996
- [33] Rausand, M. u. Høyland, A.: *System reliability theory. Models, statistical methods, and applications*. Wiley series in probability and statistics Applied probability and statistics. Hoboken, NJ: Wiley-Interscience 2004
- [34] Ditlevsen, O. D. u. Madsen, H. O.: *Structural reliability methods*. Chichester, New York: J. Wiley & Sons 1999, ©1996
- [35] LECTURE NOTES IN ENGINEERING RISK ANALYSIS, Straub, D., München 2017
- [36] Darms, M.: Data Fusion of Environment-Perception Sensors for ADAS. In: Winner, H., Hakuli, S., Lotz, F. u. Singer, C. (Hrsg.): *Handbook of Driver Assistance Systems*. Cham: Springer International Publishing 2016, S. 549–566
- [37] Durrant-Whyte, H. u. Henderson, T. C.: Multisensor Data Fusion. In: Siciliano, B. u. Khatib, O. (Hrsg.): *Springer Handbook of Robotics*. 2016, S. 867–892
- [38] Mählich, M.: Filtersynthese zur simultanen Minimierung von Existenz-, Assoziations- und Zustandsunsicherheiten in der Fahrzeugumfelderfassung mit heterogenen Sensordaten. Zugl.: Ulm, Univ., Diss, 2009. Schriftenreihe des Instituts für Mess-, Regel- und Mikrotechnik. Ulm: Univ. Ulm 2009
- [39] Bock, F., Siegl, S. u. German, R.: Mathematical Test Effort Estimation for Dependability Assessment of Sensor-based Driver Assistance Systems. 2016 42st Euromicro Conference on Software Engineering and Advanced Applications (SEAA)

- [40] Dietmayer, K.: Predicting of Machine Perception for Automated Driving. In: Maurer, M., Gerdes, J. C., Lenz, B. u. Winner, H. (Hrsg.): *Autonomous Driving*. Berlin, Heidelberg: Springer Berlin Heidelberg 2016, S. 407–424
- [41] Dietmayer, K. C. J., Reuter, S. u. Nuss, D.: Representation of Fused Environment Data. In: Winner, H., Hakuli, S., Lotz, F. u. Singer, C. (Hrsg.): *Handbook of Driver Assistance Systems*. Cham: Springer International Publishing 2016, S. 567–603
- [42] Swets, J. A.: *Signal detection theory and ROC analysis in psychology and diagnostics. Collected papers*. Psychology Press 2014
- [43] Peterson, W., Birdsall, T. u. Fox, W.: The theory of signal detectability. *Transactions of the IRE professional group on information theory* 4 (1954) 4, S. 171–212
- [44] Fawcett, T.: An introduction to ROC analysis. *Pattern Recognition Letters* 27 (2006) 8, S. 861–874